

**JOSÉ BONIFÁCIO MARTINS FILHO**

**MODELAGEM DA DEMANDA HÍDRICA ATUAL E FUTURA DA CULTURA DA  
SOJA EM GOIÁS UTILIZANDO PRODUTOS DE SENSORIAMENTO REMOTO**

**Botucatu  
2025**



**JOSÉ BONIFÁCIO MARTINS FILHO**

**MODELAGEM DA DEMANDA HÍDRICA ATUAL E FUTURA DO CULTIVO DA  
SOJA EM GOIÁS UTILIZANDO PRODUTOS DE SENSORIAMENTO REMOTO**

Tese apresentada à Faculdade de  
Ciências Agronômicas da Unesp Câmpus  
de Botucatu, para obtenção do título de  
Doutor em Engenharia Agrícola.

Orientador(a): Dr. Lineu Neiva Rodrigues

**Botucatu**

**2025**

M386m      Martins Filho, José Bonifácio  
Modelagem da demanda hídrica atual e futura do cultivo da  
soja em Goiás utilizando produtos de sensoriamento remoto /  
José Bonifácio Martins Filho. -- Botucatu, 2025  
104 p. : tabs., mapas

Tese (doutorado) - Universidade Estadual Paulista (UNESP),  
Faculdade de Ciências Agrônômicas, Botucatu  
Orientador: Lineu Neiva Rodrigues

1. agricultura irrigada. 2. reanálises climáticas. 3. mudanças  
climáticas. 4. quebra de produtividade. 5. água azul. I. Título.

**CERTIFICADO DE APROVAÇÃO**

**TÍTULO DA TESE:** MODELAGEM DA DEMANDA HÍDRICA ATUAL E FUTURA DA CULTURA DA SOJA EM GOIÁS UTILIZANDO PRODUTOS DE SENSORIAMENTO REMOTO

**AUTOR:** JOSÉ BONIFÁCIO MARTINS FILHO

**ORIENTADOR:** LINEU NEIVA RODRIGUES

Aprovado como parte das exigências para obtenção do Título de Doutor em Engenharia Agrícola, pela Comissão Examinadora:

Pesquisador Doutor LINEU NEIVA RODRIGUES (Participação Virtual)  
Cerrados / EMBRAPA

Documento assinado digitalmente

 LINEU NEIVA RODRIGUES  
Data: 19/05/2025 17:37:53-0300  
Verifique em <https://validar.iti.gov.br>

Prof. Dr. JOÃO JOSÉ DA SILVA JÚNIOR (Participação Virtual)  
/ Universidade de Brasília

Documento assinado digitalmente

 JOAO JOSE DA SILVA JUNIOR  
Data: 21/05/2025 11:07:28-0300  
Verifique em <https://validar.iti.gov.br>

Prof.<sup>a</sup> Dr.<sup>a</sup> CAROLINA CARVALHO ROCHA SENA (Participação Virtual)  
Agronomia / Universidade Estadual de Goiás

Documento assinado digitalmente

 CAROLINA CARVALHO ROCHA SENA  
Data: 20/05/2025 12:19:21-0300  
Verifique em <https://validar.iti.gov.br>

Prof. Dr. FERNANDO BRAZ TANGERINO HERNANDEZ (Participação Virtual)  
Fitossanidade Engenharia Rural e Solos / Faculdade de Engenharia de Ilha Solteira UNESP

Documento assinado digitalmente

 FERNANDO BRAZ TANGERINO HERNANDEZ  
Data: 20/05/2025 10:04:10-0300  
Verifique em <https://validar.iti.gov.br>

Prof. Dr. JOÃO CARLOS CURY SAAD (Participação Virtual)  
Engenharia Rural e Socioeconomia / Faculdade de Ciências Agrômicas de Botucatu UNESP

Documento assinado digitalmente

 JOAO CARLOS CURY SAAD  
Data: 23/05/2025 07:34:59-0300  
Verifique em <https://validar.iti.gov.br>

Botucatu, 15 de maio de 2025



## **AGRADECIMENTOS**

Agradeço a Deus pela vida e pela sua misericórdia sem fim, a Ele que nos dias turbulentos me deu forças para nunca desistir dos meus objetivos, guiando meus passos e sedimentando o meu caminho.

À Universidade Estadual Paulista "Júlio de Mesquita Filho" pela oportunidade e por proporcionar a estrutura necessária para meu crescimento profissional e pessoal.

Ao meu orientador, Dr. Lineu Neiva Rodrigues, pela atenção, confiança e orientação ao longo dessa jornada. Foi uma honra tê-lo como orientador.

Aos professores que compõem o corpo docente do Programa de Pós-Graduação em Engenharia Agrícola pelo empenho e dedicação no processo de ensino e aprendizagem.

Aos meus familiares por me ensinarem sobre a relevância da perseverança e do valor da união familiar em todos os momentos. Em especial aos meus avós (*in memoriam*), Artur Muniz e Antônia do Carmo, pelo exemplo que foram em vida de amor, sabedoria e força que seguirá comigo para sempre.

A todos os amigos e colegas que tive a honra de conhecer durante essa trajetória em Botucatu, e que se tornaram uma rede de apoio e confiança mútua para vida profissional e pessoal, e que contribuíram direta ou indiretamente para conclusão deste trabalho.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

A todos que me incentivaram, muito obrigado.





## RESUMO

No Brasil, de maneira geral, existe uma carência de dados climáticos, nas escalas adequadas, necessários para o gerenciamento de recursos hídricos. Em regiões como o Cerrado, onde a agricultura é intensiva e fortemente dependente da disponibilidade de água, é importante que se desenvolva um planejamento estratégico, que viabilize o desenvolvimento sustentável da agricultura na região. A escassez de dados, entretanto, limita a adoção de modelos matemáticos e, conseqüentemente, dificulta a inclusão de cenários nos planos de desenvolvimento, o que, muitas vezes, leva a simplificações nas tomadas de decisão. A carência dessas informações pode ser superada a partir de alternativas abrangendo o sensoriamento remoto, como por exemplo as reanálises de dados climáticos. Diante desse contexto, este estudo teve como propósito estimar a demanda hídrica e a produtividade atual e futura da cultura da soja no estado de Goiás utilizando produtos de sensoriamento remoto e modelos de previsão climática. Foi realizado o download de dados de precipitação e variáveis necessárias para estimativa da evapotranspiração de referência (ET<sub>o</sub>) oriundas do INMET/ANA e das reanálises Nasa Power (NP) e Era5-Land (EL). Foram utilizados indicadores estatísticos para a análise de desempenho dos dados estimados por reanálises e os vieses corrigidos pelo método de escalonamento linear. A demanda hídrica atual do cultivo da soja foi categorizada em demanda por água azul e verde. A demanda hídrica futura foi estimada a partir de dados de projeções futuras disponibilizados pelo CPTEC/INPE. A modelagem da produtividade da soja foi realizada a partir de modelo de penalização pelo déficit hídrico proposto por Doorenbos e Kassam (1977) e por Monteiro *et al* (2017). Todas as simulações realizadas consideraram duas datas de semeadura, 15 de outubro e 10 de novembro. Os resultados indicaram maiores valores de erros nas estimativas de ET<sub>o</sub> e precipitação com dados oriundos da reanálise EL quando comparada ao NP. Os cenários climáticos para os períodos de 2040-2070 e 2070-2099 apontam uma redução expressiva na contribuição da água verde para a demanda hídrica da soja no estado de Goiás, especialmente no cenário SSP5-8.5, que antecipa uma diminuição significativa nas precipitações. Este estudo evidencia o impacto significativo das mudanças climáticas na produtividade da soja em Goiás, com penalizações pelo déficit hídrico crescentes nos cenários futuros, especialmente no SSP5-8.5 (2070-2099), onde perdas superiores a 50% foram observadas em diversos municípios. A análise das datas de plantio revelou que, embora a semeadura em 10 de novembro apresente menores perdas em cenários intermediários, as condições climáticas futuras em cenários pessimistas tornam ambas as datas igualmente vulneráveis.

**Palavras-chave:** agricultura irrigada; reanálises climáticas; mudanças climáticas; quebra de produtividade; água azul; água verde.



## ABSTRACT

In Brazil, there is a general lack of climate data at appropriate scales necessary for water resource management. In regions such as the Cerrado, where agriculture is intensive and highly dependent on water availability, it is crucial to develop strategic planning that enables the sustainable development of agriculture in the region. However, data scarcity limits the adoption of mathematical models and, consequently, hinders the inclusion of scenarios in development plans, often leading to simplified decision-making. This lack of information can be addressed through alternatives involving remote sensing, such as climate data reanalysis. In this context, the objective of this study was to estimate the water demand and the current and future productivity of soybean crops in the state of Goiás using remote sensing products and climate forecasting models. Precipitation data and variables necessary for estimating reference evapotranspiration (ET<sub>o</sub>) were downloaded from INMET/ANA and the reanalysis datasets NASA Power (NP) and ERA5-Land (EL). Statistical indicators were used to assess the performance of reanalysis-derived data, and biases were corrected using the linear scaling method. The current water demand for soybean cultivation was categorized into blue and green water demand. Future water demand was estimated using future projection data provided by CPTEC/INPE. Soybean yield modeling was performed using the water deficit penalty model proposed by Doorenbos and Kassam (1977) and Monteiro *et al.* (2017). All simulations considered two sowing dates: October 15 and November 10. The results indicated higher error values in ET<sub>o</sub> and precipitation estimates using EL reanalysis data compared to NP. Climate scenarios for the periods 2040-2070 and 2070-2099 indicate a significant reduction in green water contribution to soybean water demand in Goiás, particularly under the SSP5-8.5 scenario, which projects a substantial decrease in precipitation. This study highlights the significant impact of climate change on soybean productivity in Goiás, with increasing penalties due to water deficit in future scenarios, especially under SSP5-8.5 (2070-2099), where losses exceeding 50% were observed in several municipalities. The analysis of planting dates revealed that although sowing on November 10 results in lower losses under intermediate scenarios, future climate conditions in pessimistic scenarios make both dates equally vulnerable.

**Keywords:** irrigated agriculture; climate reanalysis; climate change; yield gap; blue water; green water.



## LISTA DE ILUSTRAÇÕES

|                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                          |    |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 1 - Produção de soja no estado de Goiás por município (2023).....                                                                                                                                                                                                                                                                                                                                                                                                                                                 | 23 |
| Figura 2 - Mapa do Brasil com destaque para o bioma Cerrado (a), Bioma Cerrado com destaque para o estado de Goiás (b) e Estado de Goiás (c).....                                                                                                                                                                                                                                                                                                                                                                        | 37 |
| Figura 3 - Capacidade de água disponível (CAD) no estado de Goiás.....                                                                                                                                                                                                                                                                                                                                                                                                                                                   | 38 |
| Figura 4 - Estações pluviométrica (a) e meteorológicas (b).....                                                                                                                                                                                                                                                                                                                                                                                                                                                          | 39 |
| Figura 5 - 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 (1988-2008).....                                                                                                                                                                                                                                                                                            | 50 |
| Figura 6 - Desempenho estatístico da ETo diária estimada pela reanálise a) NP após correção de viés e ETo estimada pela reanálise b) EL após correção de viés.....                                                                                                                                                                                                                                                                                                                                                       | 52 |
| Figura 7 - Desempenho estatístico da ETo mensal estimada pela reanálise a) NP após correção de viés e ETo estimada pela reanálise b) EL após correção de viés.....                                                                                                                                                                                                                                                                                                                                                       | 53 |
| Figura 8 - Desempenho estatístico da precipitação diária estimada pela reanálise a) NP após correção de viés e a precipitação estimada pela reanálise b) EL após correção de viés.....                                                                                                                                                                                                                                                                                                                                   | 55 |
| Figura 9 - Desempenho estatístico da precipitação mensal estimada pela reanálise a) NP após correção de viés e a precipitação estimada pela reanálise b) EL após correção de viés.....                                                                                                                                                                                                                                                                                                                                   | 56 |
| Figura 10 - Balaço hídrico climatológico médio para os 20 municípios com maior produção de soja em Goiás a partir dos dados do Nasa Power referência (1988-2022), Figura (a), cenário SSP2-4.5, para período de 2040-2070, Figura (b) e 2070-2099, Figura (c) e cenário SSP5-8.5 para período 2040-2070, Figura (d) e 2070-2099, Figura (e). As porcentagens apresentadas no interior das figuras representam a fração do excedente ou déficit hídrico relativo correspondente a cada mês em relação ao total anual..... | 59 |

|                                                                                                                                                                                                                                                                                                                                                                                                                                        |    |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 11 - Distribuição temporal dos índices de anomalia de chuva médio para os 20 municípios com maior produção de soja em Goiás para cenário SSP2-4.5, para período de 2040-2099, Figura (a), e cenário SSP5-8.5 para período 2040-2099, Figura (b).....                                                                                                                                                                            | 62 |
| Figura 12 - Necessidade hídrica total da cultura da soja, para uma frequência de excedência igual a 20%, para as semeaduras em 15 de outubro e 10 de novembro, com base nos dados do Nasa Power corrigidos, para o período de 1988-2022. Destacando em verde a fração da demanda suprida com água da chuva e em azul a fração suprida com a irrigação.....                                                                             | 65 |
| Figura 13 - Necessidades hídricas médias, para os vinte municípios, considerando as contribuições provenientes da água da chuva, (verde), e da irrigação (azul), para as semeaduras da soja em 15 de outubro, e 10 de novembro, com base nos dados do Nasa Power corrigidos, para o período de 1988-2022.....                                                                                                                          | 67 |
| Figura 14 - Necessidade hídrica total da cultura da soja, para os vinte municípios maiores produtores, para frequência de excedência igual a 20%, para as semeaduras em 15 de outubro e 10 de novembro, para o cenário SSP2-4.5 períodos 2040-2070, Figuras (a) e (b), e 2070-2099, Figuras (c) e (d).....                                                                                                                             | 69 |
| Figura 15 - Necessidade hídrica total da cultura da soja, para os vinte municípios maiores produtores, para frequência de excedência igual a 20%, para as semeaduras em 15 de outubro e 10 de novembro, para o cenário SSP5-8.5 períodos 2040-2070, Figuras (a) e (b), e 2070-2099, Figuras (c) e (d).....                                                                                                                             | 72 |
| Figura 16 - Aumento da demanda hídrica total (DHT) projetada para os diferentes períodos e cenários de semeadura da soja. SSP2-4.5: 2040-2070 em 15 de outubro (a) e 10 de novembro (b); 2070-2099 em 15 de outubro (c) e 10 de novembro (d); SSP5-8.5: 2040-2070 em 15 de outubro (e) e 10 de novembro (f); 2070-2099 em 15 de outubro (g) e 10 de novembro (h).....                                                                  | 75 |
| Figura 17 - Contribuições hídricas médias (%) provenientes da chuva (verde) e da irrigação (azul), para as semeaduras da soja em 15 de outubro e 10 de novembro, com base nos dados do NP para o período de referência (de 1988 a 2022) e para os períodos de 2040-2070 e 2070-2099, nos cenários SSP2-4.5 e SSP5-8.5.....                                                                                                             | 77 |
| Figura 18 - 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 SSP2-4.5 períodos 2040-2070, Figuras (c) e (d), e 2070-2099, Figuras (e) e (f); cenário SSP5-8.5 períodos 2040-2070, Figuras (g) e (h), e 2070-2099, Figuras (i) e (j)..... | 80 |

|                                                                                                                                                                                   |    |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 19 - Desempenho do modelo calibrado de estimativa de produtividade média da soja ( $\text{kg ha}^{-1}$ ) nos 20 municípios com maior produtividade de soja em Goiás.....   | 83 |
| Figura 20 - Produtividades potencial tecnológica média, Produtividades médias observadas (IBGE) e produtividades médias estimadas pelo modelo, para o período de 2015 a 2022..... | 85 |





## LISTA DE TABELAS

|                                                                                                                                                                                                                                                                                                                           |    |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Tabela 1 – Municípios com maior quantidade produzida de soja (toneladas) e área total irrigada (hectares) por município.....                                                                                                                                                                                              | 25 |
| Tabela 2 – Coeficientes de cultivo ( $K_c$ ) para estágio inicial, intermediário e final do ciclo da soja.....                                                                                                                                                                                                            | 30 |
| Tabela 3 – Índices médios de eventos extremos de precipitação, para os vinte municípios, para os períodos de semeaduras da soja em 15 de outubro e 10 de novembro, com base nos dados do NP para o período de referência (1988 a 2022) e para os períodos de 2040-2070 e 2070-2099, nos cenários SSP2-4.5 e SSP5-8.5..... | 78 |
| Tabela 4 – Desempenho do modelo calibrado de estimativa de produtividade da soja ( $\text{kg ha}^{-1}$ ) em municípios de Goiás.....                                                                                                                                                                                      | 84 |



## SUMÁRIO

|             |                                                                                                      |            |
|-------------|------------------------------------------------------------------------------------------------------|------------|
| <b>1</b>    | <b>INTRODUÇÃO.....</b>                                                                               | <b>19</b>  |
| <b>2</b>    | <b>REVISÃO DE LITERATURA.....</b>                                                                    | <b>23</b>  |
| <b>2.1</b>  | <b>Agricultura irrigada em Goiás .....</b>                                                           | <b>23</b>  |
| <b>2.2</b>  | <b>Precipitação .....</b>                                                                            | <b>26</b>  |
| <b>2.3</b>  | <b>Evapotranspiração.....</b>                                                                        | <b>27</b>  |
| <b>2.4</b>  | <b>Produtos de sensoriamento remoto .....</b>                                                        | <b>30</b>  |
| <b>2.5</b>  | <b>Água verde e azul na agricultura.....</b>                                                         | <b>31</b>  |
| <b>2.6</b>  | <b>Mudanças climáticas .....</b>                                                                     | <b>32</b>  |
| <b>2.7</b>  | <b>Quebra de produtividade causada pelo déficit hídrico .....</b>                                    | <b>34</b>  |
| <b>3</b>    | <b>MATERIAL E MÉTODOS.....</b>                                                                       | <b>37</b>  |
| <b>3.1</b>  | <b>Área de estudo .....</b>                                                                          | <b>37</b>  |
| <b>3.2</b>  | <b>Base de dados meteorológicos observados .....</b>                                                 | <b>38</b>  |
| <b>3.3</b>  | <b>Dados de precipitação observados.....</b>                                                         | <b>39</b>  |
| <b>3.4</b>  | <b>Evapotranspiração de referência (ET<sub>o</sub>) .....</b>                                        | <b>40</b>  |
| <b>3.5</b>  | <b>Bases de dados meteorológicos – Reanálises climáticas .....</b>                                   | <b>40</b>  |
| <b>3.6</b>  | <b>Análise do desempenho das reanálises .....</b>                                                    | <b>42</b>  |
| <b>3.7</b>  | <b>Correção de viés nos dados de reanálises .....</b>                                                | <b>43</b>  |
| <b>3.8</b>  | <b>Demanda de água verde e azul para a soja .....</b>                                                | <b>44</b>  |
| <b>3.9</b>  | <b>Estimativa da demanda hídrica futura da soja .....</b>                                            | <b>45</b>  |
| <b>3.10</b> | <b>Balanço hídrico climatológico .....</b>                                                           | <b>46</b>  |
| <b>3.11</b> | <b>Índice de anomalias de chuva .....</b>                                                            | <b>46</b>  |
| <b>3.12</b> | <b>Modelagem da produtividade da cultura da soja .....</b>                                           | <b>47</b>  |
| <b>4</b>    | <b>RESULTADOS E DISCUSSÃO.....</b>                                                                   | <b>50</b>  |
| <b>4.1</b>  | <b>Análise dos dados observados .....</b>                                                            | <b>50</b>  |
| <b>4.2</b>  | <b>Avaliação da acurácia da evapotranspiração e precipitação .....</b>                               | <b>51</b>  |
| <b>4.3</b>  | <b>Balanço hídrico atual e futuro e anomalias de chuva .....</b>                                     | <b>58</b>  |
| <b>4.4</b>  | <b>Estimativa, atual e futura, das demandas de água verde e azul para<br/>a cultura da soja.....</b> | <b>63</b>  |
| <b>4.5</b>  | <b>Modelagem da produtividade atual e futura da cultura da soja .....</b>                            | <b>79</b>  |
| <b>5</b>    | <b>CONCLUSÕES.....</b>                                                                               | <b>87</b>  |
|             | <b>REFERÊNCIAS.....</b>                                                                              | <b>88</b>  |
|             | <b>APÊNDICE A.....</b>                                                                               | <b>102</b> |

**APÊNDICE B..... 103**

## 1 INTRODUÇÃO

No início da década de 1970, com o fortalecimento da pesquisa agropecuária, observou-se uma expansão da fronteira agrícola brasileira, que foi gradualmente subindo do Sul (clima temperado) até o Cerrado (clima tropical). Atualmente, o Brasil exerce um papel fundamental na produção global de alimentos, destacando-se como um dos principais produtores e exportadores de diversas commodities agrícolas (Hosono; Hongo, 2016; Rudorff; Risso, 2015).

O Cerrado com cerca de 200 milhões de hectares, equivale a 24% do território brasileiro, essa região engloba total ou parcialmente 13 estados brasileiros (Rodrigues *et al.*, 2023). Desta área total, cerca de 22,4 milhões hectares são de terras consideradas de alta aptidão agrícola, sendo cultivadas com culturas anuais e perenes (PROJETO MAPBIOMAS, 2022).

O Cerrado brasileiro apresenta um regime climático caracterizado por uma estação chuvosa e outra seca bem definidas, o que torna a irrigação um componente fundamental para garantir a sustentabilidade da produção agrícola (Rodrigues, 2024). Essa região concentra mais de 4,1 milhões de hectares de áreas irrigadas, com a predominância histórica de sistemas de aspersão por pivô central. Destaca-se, atualmente que 75% dos pivôs centrais instalados no Brasil estão concentrados nesse bioma, evidenciando sua importância no contexto da agricultura irrigada nacional (Sano *et al.*, 2024; Althoff; Rodrigues, 2019).

O estado de Goiás, com 98% da sua área fazendo parte do Cerrado (Rodrigues *et al.*, 2023), produz em média 10,9% da produção de grãos do Brasil (IBGE, 2023). Em 2020, foram mais de 5,4 milhões de hectares utilizados para a produção de feijão, milho e soja, totalizando, respectivamente, 351.454; 11.838.775 e 12.837.120 toneladas (IBGE, 2023).

A soja (*Glycine max*) é principal cultura de valor econômico de Goiás, é uma commodity produzida principalmente para fins de alimentação animal. É uma planta de metabolismo C3, que a partir dos programas de melhoramento genético, tem apresentado melhorias na produtividade e adaptabilidade a diferentes condições climáticas. A sojicultura tem impulsionado a economia de Goiás e foi a atividade com um valor bruto de produção de cerca de R\$ 41,3 bilhões em 2022 (IBGE, 2023).

Goiás possui cerca de 3,9 mil equipamentos de pivôs em operação, irrigando uma área total de 261,4 mil ha (ANA, 2020). Embora Goiás apresente potencial de

crescimento da área irrigada de mais 4,3 milhões de hectares (Dourado Neto *et al.*, 2022), já se observa no estado um crescimento nas disputas pelo uso de recursos hídricos, em bacias hidrográficas estratégicas para o desenvolvimento da agricultura irrigada, indicando que o crescimento da irrigação nessa região tem que ser planejado (Rodrigues *et al.*, 2015).

Qualquer planejamento que vise o crescimento sustentável da agricultura irrigada nessa região deverá utilizar, entre suas estratégias, cenários de produção agrícola, construídos com base em diferentes estratégias de manejo de irrigação. Para elaboração desses cenários, a aplicação de ferramentas computacionais, fundamentadas em modelos matemáticos, são essenciais. Uma das dificuldades na utilização dessas ferramentas de apoio à decisão é a carência de dados hidroclimáticos para a estimativa da oferta e da demanda hídrica.

No Brasil, de maneira geral, existe uma carência de dados climáticos, necessários para o planejamento agrícola e gerenciamento de recursos hídricos. Por exemplo, a maior parte do Cerrado é carente de dados hidrometeorológicos e de informações técnicas que viabilizem estimativas confiáveis de demanda e de oferta hídrica em trechos específicos de cursos de água em bacias hidrográficas da região (Althoff *et al.*, 2020). Essa falta de dados, especialmente para bacias hidrográficas de pequena dimensão, tem prejudicado a gestão de recursos hídricos e tem trazido insegurança aos usuários, em especial em bacias hidrográficas nas quais a agricultura irrigada é predominante.

Os produtos originados de sensoriamento remoto têm sido aplicados com êxito na modelagem de diversos eventos hidroclimáticos, principalmente, na modelagem hidrológica com modelos distribuídos aplicados a regiões com escassez de dados (Jiang; Wang, 2019). Esses produtos apresentam potencial de aplicação que estão sendo cada vez mais explorado (Worqlul *et al.*, 2014; Li, 2012), apresentando grande relevância por melhor representar fenômenos de caráter espaço-temporal.

Estimativas de precipitação podem ser realizadas a partir de produtos de satélites tais como o CHIRPS v2.0 (Funk *et al.*, 2015) e MSWEP v2.2 (Beck, 2018) e produtos de reanálises de dados climáticos como MERRA-2 (Gelaro, 2017; Reichle, 2017) JRA-55 (Kobayashi, 2015), ERA-20CM (Hersbach *et al.*, 2015), ERA5 (Hersbach *et al.*, 2020) e, ERA5-Land (Muñoz Sabater, 2021).

Os produtos de reanálise podem ser complementares aos recursos já existentes, como, por exemplo, sensores de satélites e VANTS, para estimativas

de elementos climáticos. Esses produtos correspondem a um conjunto de dados organizados em grade, específicos para um determinado período, derivado do uso de técnicas de assimilação de dados (Blacutt, 2015). Nota-se, no entanto, que existem poucos estudos sobre a qualidade e aplicação de produtos de reanálise para o Cerrado brasileiro.

Ademais, tem se tornado comum a obtenção de dados meteorológicos em plataformas globais de monitoramento de tempo e clima, tais como a ERA-Interim do ECMWF (Muñoz Sabater, 2021) e Nasa Power (Stackhouse *et al.*, 2015). Essas plataformas consistem em bancos de dados que têm sido utilizados para preencher falhas em séries temporais de dados de superfície (Giovanella *et al.*, 2021), realizar estimativa da deficiência hídrica no solo (Aparecido *et al.*, 2019), entre outros estudos abrangendo agrometeorologia (Marín *et al.*, 2019) e mudanças climáticas (Yang *et al.*, 2024).

A avaliação dos produtos da Nasa Power e ERA5-Land, para a estimativa de temperatura próxima a superfície e umidade relativa do ar para a região norte do Iraque e sul da Itália, foi satisfatória (Tayyeh; Mohammed, 2023; Pelosi, *et al.*, 2020). Essas reanálises foram utilizadas também com êxito na modelagem de produtividade agrícola (Aparecido *et al.*, 2020) e no estudo de eventos climáticos extremos e potencial eólico em regiões para produção de energia renovável (Braga, *et al.*, 2021).

A produção agrícola é dependente do clima. O aumento da variabilidade climática, tem aumentado as incertezas na produção de alimentos. Para as próximas décadas, é esperado que diversos setores da economia sejam afetados pelas mudanças climáticas, especialmente a agricultura (Thayer *et al.*, 2020). O aumento tanto da duração da estação seca quanto da concentração das chuvas em períodos curtos, aumentará o estresse hídrico das culturas, podendo aumentar também a demanda por irrigação na região.

Tal cenário pode intensificar-se, caso as projeções climáticas para a região do Cerrado se confirmem, as quais sugerem um aumento da temperatura, prolongamento da estação de seca e uma redução na disponibilidade hídrica (Chou *et al.*, 2014a; Rodrigues *et al.*, 2024). Nesse contexto, será cada vez mais necessário que haja um planejamento estratégico de intensificação da irrigação, considerando os possíveis impactos de diferentes estratégias de manejo de irrigação na sustentabilidade dos sistemas de produção da agricultura regional.

Um dos principais parâmetros empregados na avaliação dos impactos das condições climáticas e das práticas de manejo 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 maneira integrada, os três pilares fundamentais da sustentabilidade, o ambiental, o econômico e o social.

No aspecto ambiental, reduzir a quebra de produtividade é um objetivo crucial ao mitigar a necessidade de expansão e 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).

## **1.1 Objetivos**

### **1.1.1 Geral**

Estimar a demanda hídrica e a produtividade atual e futura da cultura da soja no estado de Goiás utilizando produtos de sensoriamento remoto e modelos de previsão climática.

### **1.1.2 Específicos**

- Avaliar a acurácia dos dados de precipitação e evapotranspiração de longo prazo obtidos a partir de produtos de sensoriamento remoto;
- Estimar a demanda de água total e as contribuições de águas verde e azul, atual e futura, da cultura da soja no estado de Goiás;
- Estimar a produtividade atual e futura da cultura da soja a partir do balanço hídrico climatológico.



## 2 REVISÃO DE LITERATURA


### 2.1 Agricultura irrigada em Goiás

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

A agropecuária é uma das principais atividades econômicas do estado de Goiás, é responsável por 11,4% do PIB estadual e emprega cerca de 300 mil pessoas (IMB, 2022). Nesse contexto, o principal cultivo de interesse econômico em Goiás é a cultura da soja que ocupa área de cerca de 4,5 milhões de hectares de área plantada (IBGE, 2023).

Na Figura 1 é apresentada a produção de soja (em toneladas) por município no território goiano. O sudoeste do estado de Goiás é a microrregião com maior quantidade produzida de grãos. O município de Rio Verde se destaca como o maior produtor de soja (1,6 milhão de toneladas) no estado.

**Figura 1- Produção de soja no estado de Goiás por município (2023)**



Fonte: Elaborado a partir de dados do IBGE (2023).

O aumento expressivo da demanda global por soja nas últimas duas décadas tem sido impulsionado, em grande parte, pelo crescimento do consumo na China, que se

consolidou como o principal importador da oleaginosa brasileira. As projeções indicam uma tendência contínua de expansão desse mercado, refletindo a importância estratégica da soja na cadeia produtiva, especialmente na fabricação de farelo e óleo, produtos essenciais para a indústria de alimentos e a nutrição animal (Zhao *et al.*, 2021).

Nesse contexto, o Cerrado brasileiro, com destaque para o estado de Goiás, desponta como um agente fundamental na ampliação da oferta de grãos para atender a essa crescente demanda mundial. A disponibilidade de vastas áreas agrícolas aptas para a expansão da produção, aliada ao aumento da adoção de tecnologias de irrigação, torna essa região altamente estratégica para o fortalecimento da produção nacional. A agricultura irrigada, ao mitigar os impactos da variabilidade climática e permitir a intensificação dos cultivos, possibilita um incremento significativo na produtividade, contribuindo para a consolidação do Brasil como um dos principais fornecedores globais de soja.

Na tabela 1 são apresentados os 20 municípios com maior quantidade produzida de soja e área irrigada total de cada município. O município de Cristalina é o terceiro maior produtor de soja (1.006.500 ton) e maior com área irrigada total (62.089 ha).

**Tabela 1- Municípios com maior quantidade produzida de soja (toneladas) e área total irrigada (hectares) por município**

| Latitude | Longitude | Município       | Quantidade produzida (ton) | Área irrigada (ha) | Área irrigada/ área plantada (ha) |
|----------|-----------|-----------------|----------------------------|--------------------|-----------------------------------|
| -17.79   | -50.91    | Rio Verde       | 1638000                    | 13337              | 2%                                |
| -17.86   | -51.40    | Jataí           | 1170000                    | 9909               | 2%                                |
| -16.76   | -47.60    | Cristalina      | 1006500                    | 62089              | 11%                               |
| -17.33   | -50.68    | Paraúna         | 596400                     | 15558              | 7%                                |
| -17.36   | -51.08    | Montividiu      | 553800                     | 2010               | 1%                                |
| -18.17   | -47.95    | Catalão         | 472000                     | 5769               | 3%                                |
| -17.72   | -48.17    | Ipameri         | 404000                     | 7271               | 4%                                |
| -17.57   | -52.54    | Mineiros        | 385000                     | 18058              | 6%                                |
| -18.42   | -52.55    | Chapadão do Céu | 342000                     | 10339              | 5%                                |
| -16.64   | -48.61    | Silvânia        | 310250                     | 3629               | 13%                               |
| -17.63   | -47.78    | Campo Alegre    | 290000                     | 10479              | 10%                               |
| -17.29   | -49.03    | Piracanjuba     | 281400                     | 2061               | 2%                                |
| -16.23   | -47.91    | Luziânia        | 275603                     | 8420               | 7%                                |
| -18.21   | -49.73    | Bom Jesus       | 254000                     | 10068              | 7%                                |
| -15.13   | -48.25    | Padre Bernardo  | 252525                     | 3284               | 3%                                |
| -17.82   | -50.58    | Santa Helena de | 252000                     | 14731              | 11%                               |
| -18.01   | -49.41    | Goiatuba        | 222870                     | 26355              | 15%                               |
| -17.39   | -50.38    | Acreúna         | 188700                     | 6922               | 5%                                |
| -14.45   | -48.46    | Niquelândia     | 182400                     | 3523               | 4%                                |
| -16.95   | -51.80    | Caipônia        | 174000                     | 2777               | 2%                                |

**Fonte:** IBGE, 2023/ ANA, 2020. Elaborado pelo autor.

De acordo com informações do atlas da irrigação (ANA, 2020) Goiás possui 669 mil hectares de área irrigada com diferentes métodos e sistemas de irrigação, sendo a irrigação por pivô predominante no estado. Portanto, considerando a área plantada em 2022 de 7,68 milhões de hectares estima-se que mais de 90% da área agrícola do estado se caracteriza como agricultura de sequeiro.

A partir de informações do levantamento “Uso da Água na Agricultura de Sequeiro no Brasil” (ANA; IBGE, 2020), considerando os anos entre 2013 e 2017, o cultivo em sequeiro de soja no estado de Goiás, teve em média déficit hídrico na ordem de 12%.

Pesquisas sugerem que a área irrigada no Cerrado pode ser aumentada a partir de uma perspectiva de uso sustentável da água (Althoff *et al.*, 2021). Sendo observada a tendência de expansão da irrigação por pivôs no Cerrado (Althoff; Rodrigues, 2019) e em especial no estado de Goiás (Pereira Júnior, 2017).

A expansão da agricultura irrigada no estado, se não for conduzida de maneira planejada e sustentável, pode intensificar os conflitos pelo uso da água, dada a crescente competição entre os diferentes setores usuários desse recurso. Dessa forma, torna-se essencial a adoção de estratégias que promovam a redução da captação hídrica nos mananciais, conciliando as demandas dos múltiplos usuários.

Um planejamento integrado das bacias hidrográficas, fundamentado em princípios de gestão eficiente e equitativa, é uma abordagem fundamental para otimizar o uso da água. Nesse contexto, a implementação de tecnologias de irrigação mais eficientes e a adoção de boas práticas agrícolas são medidas estratégicas para minimizar o impacto sobre os recursos hídricos, garantindo a segurança hídrica e a sustentabilidade produtiva. Dessa forma, a gestão eficiente da irrigação em Goiás deve estar alinhada as diretrizes legais, promovendo a harmonização entre o desenvolvimento agrícola e a conservação dos recursos hídricos (Goiás, 2012).

## **2.2 Precipitação**

No ciclo hidrológico, a precipitação é o elemento que se traduz como o retorno da água condensada na atmosfera para a superfície terrestre. As chuvas são o componente de entrada do balanço hídrico que mais influenciam na agricultura, nas cidades e no meio ambiente como um todo (Minuzzi; Lopez, 2014).

A importância sobre a dinâmica espaço-temporal e intensidade das chuvas é ressaltada em estudos para identificação de épocas adequadas de plantio na agricultura de sequeiro (Rocha, 2021), para compreender o potencial erosivo das chuvas (Oliveira, 2021), riscos de alagamentos (Vestena *et al.*, 2020), entre outras áreas.

A precipitação é comumente registrada por pluviômetros e sensores que medem essa variável meteorológica diretamente em superfície. Entretanto devido a baixa densidade de pontos de medições não é possível estabelecer uma uniformidade espacial e temporal das chuvas para grandes extensões (Althoff *et al.*, 2020), essa limitação tem sido superada a partir da utilização de dados de reanálise climáticas.

O estado de Goiás, segundo a Rede Hidrometeorológica Nacional possui cerca de 493 pontos de medições entre estações pluviométricas e meteorológicas (ANA, 2020), sendo esse número insuficiente para a compreensão dos eventos hidroclimáticos na totalidade do território (Althoff *et al.*, 2020). Investimentos em novas

estações de medição em superfície são dispendiosos e nem todos os países podem arcar com tais despesas (Rivera *et al.*, 2023).

A obtenção de estimativas de dados de precipitação a partir de sensoriamento remoto deu-se no início de 1960 com o lançamento do satélite TIROS I (Television and InfraRed Observation Satellite), a partir de então, com o desenvolvimento de novos recursos como radares, sensores e reanálises climáticas, as informações de eventos pluviométricos puderam ser facilmente adquiridas (Liu, 2015).

Os produtos originados do sensoriamento remoto têm sido aplicados com êxito na modelagem de diversos eventos hidroclimáticos, principalmente, para a modelagem hidrológica com modelos distribuídos aplicados a regiões com escassez de dados (Jiang; Wang, 2019). Esses produtos apresentam potencial de aplicação que estão sendo cada vez mais explorado (Worqlul *et al.*, 2014; Li, 2012), apresentando grande relevância por melhor representar fenômenos de caráter espaço-temporal.

As informações a respeito das chuvas são especialmente relevantes para agricultura, haja visto que quando a precipitação não é suficiente e adequadamente distribuída ao longo do ciclo fisiológico das culturas é necessário suprir a demanda hídrica das plantas através da irrigação (Hoekstra *et al.*, 2011).

Tendo em vista que a precipitação é uma das variáveis meteorológicas mais difíceis de estimar (Tapiador *et al.*, 2012) e que os dados de reanálises, por vezes podem não reproduzir fidedignamente as condições reais observadas em superfície, logo podem apresentar tendenciosidades ou erros nas variáveis obtidas, é necessário que os dados de estimativas de precipitação oriundos de reanálises devam ser submetidos a uma validação adequada (Jiménez-Jiménez *et al.*, 2021; Gruber *et al.*, 2022).

### **2.3 Evapotranspiração**

A evapotranspiração é conceituada como a transferência da água do sistema solo-planta para atmosfera em função das condições do tempo. Nesse processo, o componente evaporativo diz respeito a evaporação da água no solo, somado a umidade transpirada pelas superfícies dos vegetais (Reichardt; Timm, 2012).

Há métodos diretos e indiretos para a estimativa de evapotranspiração. Os lisímetros são os principais equipamentos para determinação desse parâmetro de forma direta, entretanto é um método de alto custo e demorado (Pereira *et al.*, 1997),

como alternativa tem-se métodos indiretos que se utilizam de equações que requerem variáveis atmosféricas (Silva *et al.*, 2018).

Há modelos que para a estimativa da evapotranspiração consideram apenas a temperatura do ar, como, por exemplo, os métodos de Thornthwaite (1955) e de Hargreaves (1974). Propostas simplificadas, porém, mais robustas combinam mais de uma variável, a exemplo tem-se os métodos de Priestley e Taylor (1972) e de Makkink (1957) que requerem além de temperatura, dados de radiação solar.

Apesar de existir diversas metodologias, a abordagem descrita no Boletim FAO-56 é considerada o procedimento padrão para obtenção da Evapotranspiração de Referência ETo, descrevendo a ETo como sendo aquela que acontece em condições específicas, representando a demanda hídrica de uma cultura rasteira não submetida a déficit hídrico (Allen *et al.*, 1998). Entretanto, uma das limitações atribuídas a esse método é que ele requer um número maior de variáveis meteorológicas que podem não estar disponíveis para a área ou intervalo de tempo de interesse (Mokhtari *et al.*, 2018).

A ETo também pode ser estimada indiretamente através de imagens de satélites, a partir da aplicação de algoritmos como por exemplo o SEBAL (*Surface Energy Balance Algorithm for Land*) (Bastiaanssen *et al.*, 1998), METRIC (*Mapping EvapoTranspiration at high Resolution with Internalized Calibration*) (Allen; Tasumi & Trezza, 2007), SAFER (*Simple Algorithm for Evapotranspiration Retrieving*) (Teixeira, 2010).

Andrade *et al.* (2015) utilizaram imagens MODIS para determinar a ETo a partir do algoritmo SAFER em áreas do Mato Grosso do Sul e concluíram que se trata de ferramentas úteis para o planejamento agrícola. Os produtos do sensor MODIS também podem ser aplicadas para determinação da evapotranspiração atual (ETa), Lima *et al.* (2014) encontraram valores coerentes de ETa para bacias hidrográficas de Goiás.

Uma alternativa de fonte dados que tem sido amplamente utilizada em estudos climáticos é a *Prediction of World Wide Energy Resources* da *National Aeronautics and Space Administration* (NASA POWER). Trata-se de uma plataforma que disponibiliza gratuitamente dados em grids, compilados de fontes de superfícies, oceanos e sensoriamento remoto, com resolução espacial de 1° (latitude-longitude) (Maldonado Junior *et al.*, 2019). A potencialidade do uso do sistema Nasa Power para estudos agrometeorológicos tem sido atestada por pesquisas realizadas em regiões

indianas (Srivastava *et al.*, 2020), na Itália (Negm *et al.*, 2017) e no Brasil (Aparecido *et al.*, 2020).

Para fins agrícolas, tem-se a aplicação do conceito de Evapotranspiração do cultivo (ET<sub>c</sub>), que diz respeito a evapotranspiração potencial de um cultivo de interesse agrônômico. Conforme proposto por Doorenbos e Pruitt (1977) a ET<sub>c</sub> pode ser estimada a partir do produto da ET<sub>o</sub> por um coeficiente de cultivo (K<sub>c</sub>), sendo ET<sub>o</sub> referente ao requerimento atmosférico, divergindo entre localidades, enquanto o K<sub>c</sub> varia segundo a cultura, o seu estágio de desenvolvimento e com o clima a qual está submetida (Allen *et al.*, 1998).

Diversas pesquisas de campo são realizadas com o objetivo de determinar os valores adequados de K<sub>c</sub> para cada fase do ciclo de desenvolvimento de uma cultura. O procedimento mais amplamente utilizado consiste na aplicação de lisímetros de pesagem, os quais permitem a medição da evapotranspiração real da cultura e em seguida relacionam com a ET<sub>o</sub>. Dessa forma, torna-se possível estimar os valores diários de K<sub>c</sub> para qualquer espécie vegetal de interesse (Bariviera, 2020).

Entretanto, em razão dos elevados custos associados aos equipamentos e às operações de pesquisas em campo, existem alternativas para a estimativa de K<sub>c</sub>. Uma dessas alternativas é o uso de sensoriamento remoto, que permite a estimativa da ET<sub>c</sub>, por exemplo através de índices de vegetação (Marcial-Pablo *et al.*, 2021). Outra abordagem consiste no ajuste de valores de K<sub>c</sub> previamente determinados em algumas regiões, os quais podem ser adaptados para novas localidades a partir de dados climáticos específicos, proporcionando uma estimativa prática e de baixo custo (EMBRAPA, 2021).

Na Tabela 2 são apresentados os valores de K<sub>c</sub> inicial, intermediário e final do cultivo da soja considerando os coeficientes apresentados no Boletim FAO-56 (Allen *et al.*, 1998), e valores obtidos em pesquisas e ajustes para áreas do Cerrado.

**Tabela 2 - Coeficientes de cultivo (Kc) para estágio inicial, intermediário e final do ciclo da soja**

| Fonte                          | inicial | intermediário | final |
|--------------------------------|---------|---------------|-------|
| Allen <i>et al.</i> (1998)     | 0,50    | 1,15          | 0,50  |
| Bastos <i>et al.</i> (2007)    | 0,40    | 1,05          | 0,80  |
| Silva <i>et al.</i> (2020)     | 0,56    | 1,5           | 0,90  |
| Bariviera <i>et al.</i> (2020) | 0,47    | 1,15          | 0,89  |
| Kc FAO ajustado para Goiás     | 0,60    | 1,1           | 0,40  |

Até meados da década de 1960 era desconhecida a influência do teor de água no solo no processo de transpiração das plantas (DENMEAD; SHAW, 1962), após entendido o impacto da umidade do solo para os vegetais, tornou-se comum estudos de estimativa de ETc para diferentes culturas. Atualmente, dados de evapotranspiração são indispensáveis para gestão de recursos hídricos e modelagem da agricultura a partir do clima (Ongaratto; Bortolin, 2020).

## 2.4 Produtos de sensoriamento remoto

O aprimoramento tecnológico dos satélites ao longo dos últimos anos permitiu avanços para além da simples observação de parâmetros atmosféricos, atualmente, esses recursos subsidiam estudos complexos sobre o clima em diversas regiões do mundo (Nascimento; Oliveira, 2018).

A aplicação dos métodos de estimativas de variáveis meteorológicas a partir de sensoriamento remoto têm aumentado. O baixo custo e aplicabilidade dessa técnica em diversas áreas de estudo são vantagens frequentemente mencionada em pesquisas científicas (Pinto *et al.*, 2014). Por outro lado, a baixa resolução espacial de alguns produtos e problemas com nebulosidade são comumente relatadas como desvantagens dessa tecnologia (Serrão *et al.*, 2016; Salgado *et al.*, 2019).

O monitoramento das variáveis meteorológicas remotamente tem auxiliado no conhecimento da distribuição espaço-temporal da precipitação e evapotranspiração (Diogo, 2020), portanto infere-se que o sensoriamento remoto é uma técnica que pode subsidiar o planejamento agrícola em áreas com ausência de dados de superfície.

Nesse contexto, dados meteorológicos de reanálises têm sido amplamente utilizados pois além de serem disponibilizados gratuitamente, apresentam abrangência global e temporal satisfatórias para aplicações e pesquisas na agricultura



(Maldonado *et al.*, 2019), construção civil (Stackhouse *et al.*, 2015), aquecimento da terra (Wang *et al.*, 2015) entre outras abordagens.

Muitas pesquisas utilizam informações oriundas de reanálises climáticas sem uma avaliação preliminar do nível de acurácia e sem um ajuste de viés. A utilização desses dados sem a análise de desempenho e correção prévia pode resultar em análises que também contém incertezas e podem gerar conclusões equivocadas.

Embora, atualmente, haja diversas opções de obtenção de elementos meteorológicos é necessário avaliar o desempenho dessas diferentes fontes de dados afim de compreender o grau de incerteza dessas estimativas e somente depois estabelecer uma aplicação direta dessas informações para aplicações, como por exemplo na agricultura.

Os dados estimados por reanálises, por vezes podem não reproduzir fidedignamente as condições reais observadas em superfície, logo podem apresentar tendenciosidades ou erros nas variáveis obtidas, logo os dados de reanálises devem ser submetidos a uma análise de desempenho adequada (Jiménez-Jiménez *et al.*, 2021; Gruber *et al.*, 2022).

Existem diversos métodos de correção de viés que podem ser utilizados para superar os vieses em dados de reanálises, dentre eles alguns comumente usados são a abordagem de escala linear (Lenderink *et al.*, 2007) e transformação de energia da precipitação (Leander *et al.*, 2008).

De acordo com Rodrigues e Braga (2021) a precisão da ETo diária estimada com o conjunto de dados Nasa Power após correção de viés aumenta quando comparada com os resultados obtidos a partir dos dados brutos da reanálise, os autores registraram a tendência de redução significativa dos erros de estimativa.

## **2.5 Água verde e azul na agricultura**

Historicamente, o conceito de água verde e azul foi estabelecido a princípio por Falkenmark (1995) na Conferência da Organização das Nações Unidas para Agricultura e Alimentação (FAO), entretanto essa abordagem vem sendo discutida por outros pesquisadores ao longo das últimas décadas que aplicaram esses conceitos em diferentes setores.

Conceitualmente para o setor da agricultura, tem-se por definição que água verde é aquela oriunda da precipitação natural que está contida em um solo não saturado e

está à disposição para ser absorvida pelas plantas, já água azul é àquela armazenada em corpos hídricos (lagos, rios, reservatórios artificiais etc.) e que precisam ser captadas para aplicação nos cultivos agrícolas com uso de irrigação (Hoekstra *et al.*, 2011).

A contabilização dos componentes verde e azul na agricultura são essenciais para melhor alocação dos recursos hídricos, como por exemplo indicar em quais regiões podem se desenvolver cultivos anuais com uma menor necessidade de irrigação e como a agricultura de sequeiro pode ser mais bem planejada (Dey; Remesan, 2022; Rodrigues *et al.*, 2023).

Diversos modelos e métodos são aplicados para categorizar os recursos hídricos verdes e azuis em diferentes escalas espaciais e temporais. O modelo SWAT (Soil and Water Assessment Tool) foi utilizado na Bacia do Rio Weihe, China por Zhao *et al.*, (2016), para verificar como as mudanças no uso da terra podem interferir na disponibilidade de água verde e azul. Utilizando o modelo FAO-CROPWAT, Surendran *et al.* (2015) modelaram o requerimento de água verde e azul de cultivos anuais no distrito de Palakkad, Índia.

Da totalidade de água utilizado na agricultura, cerca de 80% se trata de água verde (Chiarelli *et al.*, 2020), entretanto a disponibilidade de água verde é limitada, principalmente em regiões de clima tropical como Cerrado que são caracterizadas por duas estações, uma estação chuvosa e outra seca. Essas circunstâncias evidenciam a necessidade de infraestrutura de irrigação, para garantir segurança hídrica e consequentemente segurança alimentar.

Embora sejam reconhecidos os custos iniciais e de manutenção para aplicação de água via irrigação na agricultura, é consenso a importância dessa técnica. Siebert e Petra (2010) avaliaram a produtividade global de arroz e cana de açúcar para o período de 1998–2002 e identificaram que caso nesses cultivos não tivessem utilizado água azul haveria quebra de safra em cerca de 39% e 31%, respectivamente.

## **2.6 Mudanças climáticas**

O estudo dos impactos das mudanças climáticas na economia mundial tem sido foco nas últimas décadas, pesquisas apontam que os eventos climáticos extremos podem se tornar mais frequentes e afetar ecossistemas agrícolas, urbanos e naturais (Huang *et al.*, 2023). Assim, para que se possa estabelecer estratégias eficazes

visando mitigar as consequências das mudanças climáticas é essencial abordar a temática dos cenários climáticos futuros especialmente para o setor agrícola, que será um dos setores mais impactados (Michalak, 2019).

Devido à natureza complexa dos sistemas climáticos, que são influenciados por uma variedade de fatores bióticos e abióticos, a previsão do clima futuro a longo prazo não pode alcançar o mesmo nível de precisão e certeza das previsões de curto prazo. Em face dessa limitação, foram desenvolvidos modelos de previsão que projetam cenários futuros, os quais visam proporcionar uma compreensão mais aprofundada sobre o comportamento climático no horizonte temporal futuro (Almagro *et al.*, 2020).

Esses cenários são chamados de SSPs (Caminho Socioeconômico Compartilhado) e combinam os aspectos políticos, econômicos e sociais, e suas interferência nas emissões de gases do efeito estufa e como isso pode acarretar maior retenção energia na atmosfera, dessa forma promovendo o aumento da temperatura global (IPCC, 2021).

Atualmente, são disponibilizados muitos modelos climáticos como por exemplo modelo HadGEM2-ES (Hadley Center Global Environment Model) (Collins, 2011) MIROC5 (Model for Interdisciplinary Research on Climate 5) (Watanabe, 2011), BESM (Biwako Environmental Simulation Model) (Kawamiya, 2003), CANESM2 (Canadian Earth System Model 2) (Arora, 2012).

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

O SSP2-4.5 foi projetado para representar um cenário intermediário, no qual as emissões de gases de efeito estufa seguem uma dinâmica de estabilização, resultando em um forçamento radiativo de aproximadamente  $4,5 \text{ W/m}^2$  até 2100. Esse cenário projeta uma elevação da temperatura global em torno de  $1,5^\circ\text{C}$  acima dos níveis pré-industriais, com variações estimadas limitadas a  $2^\circ\text{C}$ . Embora apresente riscos climáticos menos severos comparado a outros cenários, o SSP2-4.5 ainda implica mudanças climáticas significativas, incluindo eventos climáticos extremos e impactos na segurança alimentar (IPCC, 2021; Silva *et al.*, 2023).

O cenário SSP5-8.5 reproduz condições caracterizadas pelo crescimento contínuo das emissões de gases de efeito estufa ao longo do século XXI, levando a

um forçamento radiativo superior a  $8,5 \text{ W/m}^2$  até 2100 e a um aquecimento global médio de  $3,6^\circ\text{C}$  acima dos níveis pré-industriais, com variações entre  $2,8^\circ\text{C}$  e  $4,6^\circ\text{C}$ . Esse cenário está altamente relacionado a impactos climáticos, incluindo eventos extremos mais frequentes e intensos, elevação acelerada do nível do mar, perda significativa da biodiversidade e riscos graves para a segurança alimentar e hídrica, além de desafios socioeconômicos decorrentes da degradação ambiental (IPCC, 2021).

Com base nos dados de precipitação gerados pelo HadGEM2-ES, Wen et al (2024) modelaram de maneira consistente a ocorrência de secas em áreas agrícolas de Fujian, China para as décadas de 2050 a 2080 para os cenários SSP2-4.5 e SSP2-8.5. Aplicando este modelo e os mesmos cenários Sondermann (2022) avaliou que há tendência futura de diminuição de dias frios até 2070 e aumento de dias secos consecutivos bacia do Rio Doce em Minas Gerais.

## **2.7 Quebra de produtividade causada pelo déficit hídrico**

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, 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 na China, Wang *et al.* (2023) relatam que a quebra de produtividade causada pelo déficit hídrico alcança até 45% nesta cultura. Esses dados apontam para a magnitude dos impactos hídricos sobre a produtividade agrícola, evidenciando a necessidade de intervenções que minimizem esses problemas.

O termo quebra de produtividade vem do inglês *yield gap*, que também pode ser traduzido como lacuna de produtividade, independente da nomenclatura, o sentido é que este indicador expressa a diferença entre a produtividade potencial (PP) e produtividade real (PR) observada no campo (Zhao *et al.*, 2023). Os primeiros estudos sobre quebra de produtividade iniciaram na década de 1960 com a comparação de dados de produtividade potencial comparados aos dados médios de produtividade

observados em campo (WIT, 1965). Com o passar dos anos mais pesquisas sobre essa temática se consolidaram nas décadas de 1980 e 1990 (Evans; Fischer, 1999).

Para conceituar o termo quebra de produtividade, inicialmente é essencial introduzir os conceitos de níveis de produtividade e quais fatores a influenciam. De maneira objetiva, a PP é um parâmetro teórico pois se trata do rendimento da cultura que cresce e se desenvolve em condições ótimas, ou seja, aquele obtido numa situação em que não há déficit hídrico, as doenças, pragas e ervas daninhas são eficazmente controladas e há fornecimento adequado de nutrientes pela solução do solo para o sistema radicular (Dias; Sentelhas, 2018).

Os fatores que influenciam a produtividade potencial de uma cultura são comumente denominados determinantes. Esses fatores incluem a concentração atmosférica de dióxido de carbono ( $\text{CO}_2$ ), a radiação solar, a temperatura, além de atributos fisiológicos específicos da cultura, como a eficiência na interceptação da luz solar e a conversão dessa energia em biomassa (Rizzo *et al.*, 2021). Para estimar a produtividade potencial, utilizam-se modelos que simulam os processos fisiológicos e biofísicos da planta, permitindo calcular a produção de matéria seca com base em condições ideais de cultivo (Sentelhas *et al.*, 2016).

No que se refere a PR, ela corresponde ao rendimento efetivamente alcançado em campo pelo produtor, sendo possível sua obtenção em diferentes escalas espaciais, desde que haja a coleta e monitoramento desses dados por partes interessadas. Um exemplo disso são os levantamentos oficiais realizados em nível municipal pelo IBGE. Esse indicador reflete, as condições reais enfrentadas pela cultura ao longo de seu ciclo produtivo, abrangendo desde as condições climáticas e de manejo até a incidência de pragas e doenças (FAO; DWFI, 2015; IBGE, 2023).

Portanto, a PR obtida é influenciada pelos fatores determinantes, mas também pelos fatores limitantes (déficit nutricional e hídrico) e fatores redutores (controle de plantas daninhas, pragas e doenças), representando uma medida prática da produtividade agrícola em condições reais de cultivo, em contraste com o rendimento potencial obtido em condições ideais simuladas (Visses *et al.*, 2018).

Com a evolução dos critérios e o aprofundamento da compreensão acerca dos fatores que influenciam o crescimento e o desenvolvimento das culturas agrícolas, diversos autores propuseram diferentes níveis de rendimento para análise e estudo. Entre esses, um dos mais avaliados é o conceito de produtividade atingível (Videla-Mensegue *et al.*, 2024). Essa é definida como o nível de rendimento alcançado quando

são aplicadas as melhores práticas de manejo agrícola, considerando, porém, que a demanda hídrica das culturas seja suprida exclusivamente pela precipitação natural, ou seja sem o uso de irrigação (Battisti *et al.*, 2018).

Em um cenário de agricultura de sequeiro, tem-se que o déficit hídrico pode limitar o crescimento e desenvolvimento dos cultivos de forma severa, portanto o rendimento atingível é aquele obtido em que há limitação pelo suprimento hídrico, não exclusivamente pelo próprio fator déficit hídrico que pode ser acarretado por baixa ou má distribuição de precipitação, mas esta limitação pode também estar relacionada com as propriedades físicas do solo, que afetam a profundidade do enraizamento bem como a capacidade do solo em reter água (Zhao *et al.*, 2023).


Para fechar a lacuna de produtividade pelo déficit hídrico e tornar o cultivo de alimentos menos vulnerável a variabilidade climática, são estratégias viáveis o ajuste de datas de plantio, implantação de sistemas de irrigação adequados, uso de cultivares tolerantes à seca e melhoria das propriedades físico-hídricas do solo (Visses *et al.*, 2018; Zhao *et al.*, 2023).

### 3. MATERIAL E MÉTODOS

#### 3.1 Área de estudo

O estado de Goiás (Figura 2), com área aproximada de 340.242,856 km<sup>2</sup> (IBGE, 2021), possui cerca de 98% do seu território inserido no bioma Cerrado (Rodrigues, 2023; Bolfe; Sano, 2020). De acordo com a classificação climática de Köppen, no Goiás predomina o clima tropical com estação seca no inverno (Aw), entretanto, há zonas climáticas em microrregiões do estado classificadas como Am, Cwa e Cwb (Cardoso *et al.*, 2014; Novais, 2020).


**Figura 2 - Mapa do Brasil com destaque para o bioma Cerrado (a), Bioma Cerrado com destaque para o estado de Goiás (b) e Estado de Goiás (c)**



Há uma diversidade de classes de solo no território goiano, entretanto predomina o Latossolos em aproximadamente 45% da área do estado (Sano *et al.*, 2024). No que concerne à vegetação, a região apresenta diversas formações de vegetação, com predominância de espécies herbáceas e arbustivo-herbáceas, até formações savânicas, que contemplam estratos arbóreos, arbustivo-herbáceo e árvores de pequeno porte dispersas em um substrato gramíneo. Além disso, observam-se formações florestais, onde espécies arbóreas estabelecem um dossel contínuo (Sano *et al.*, 2007; Ribeiro; Walter, 2008).

A capacidade de água disponível (%) para os solos do estado de Goiás é apresentado na Figura 3. Mais de 85% dos municípios goianos apresentam CAD superior a 0,100 %.

**Figura 3 - Capacidade de água disponível (CAD) no estado de Goiás**



**Fonte:** Elaborado a partir de dados da Agência Nacional de Águas (2020).

### 3.2 Base de dados meteorológicos observados

Os dados históricos utilizados neste trabalho foram obtidos do banco 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>).

Para a seleção das estações meteorológicas e do período de coleta de dados observacionais, foram seguidas as diretrizes da Organização Meteorológica Mundial (WMO, 2017), que recomenda a obtenção de dados de fontes oficiais e confiáveis, garantindo a integridade e representatividade das informações climáticas, e verificação da existência de erros grosseiros que podem ter ocorrido por falha humana ou de equipamentos. Além disso foram estabelecidos os seguintes critérios: 1) mínimo de 20 anos de dados diários observados; 2) Período com menor incidência de falhas nas medições (< 10%); 3) Período de início de operação e/ou desativação das estações; e 4) período compatível com as séries históricas de dados oriundos de reanálises climáticas.

Após análise de consistência dos dados observados, baseado nos critérios de disponibilidade, adequabilidade e qualidade dos dados, foi determinado como período



de dados observados válidos o intervalo entre 1988 e 2008 (1º de janeiro de 1998 até 31 de dezembro de 2008), totalizando 20 anos de dados.

Nas simulações, foram utilizados dados de precipitação (mm), temperatura máxima e mínima do ar (°C), umidade relativa do ar (%), velocidade média do vento a 10 m de altura ( $\text{m s}^{-1}$ ) (posteriormente corrigida para 2 m de altura) e insolação (h).


Na Figura 4 estão indicadas as localizações das 81 estações pluviométricas (4a) e 10 estações meteorológicas (4b) utilizadas como base das simulações. Os detalhes relativos ao nome do município e coordenadas geográficas exatas podem ser consultadas nas tabelas 1 e 2 do Apêndice I.

### 3.3 Dados de precipitação observados

Para o estado de Goiás, foram identificadas um total de 490 estações pluviométricas, conforme registros disponíveis no sistema Hidroweb (<https://www.snirh.gov.br/hidroweb/apresentacao>), mantido pela Agência Nacional de Águas (ANA). Após a aplicação dos critérios de seleção, foram selecionadas 81 estações pluviométricas (Figura 4a).

As falhas observadas nas séries de dados de precipitação foram preenchidas pelo método da ponderação regional (Diaz *et al.*, 2018), considerando os três pontos de medição pluviométricos mais próximos com dados disponíveis.

**Figura 4 - Estações pluviométrica (a) e meteorológicas (b)**



### 3.4 Evapotranspiração de referência (ET<sub>o</sub>)

Para estimativa da ET<sub>o</sub>, (Equação 1), utilizou-se o procedimento descrito no documento Boletim FAO 56 (Allen *et al.*, 1998).

$$ET_o = \frac{0,408\Delta(R_n - G) + \gamma \frac{900}{T + 273} U_2 (e_s - e_a)}{\Delta + \gamma(1 + 0,34U_2)} \quad (1)$$

Em que

ET<sub>o</sub> = evapotranspiração de referência (mm dia<sup>-1</sup>); R<sub>n</sub> = resultado do balanço de radiação solar (MJ m<sup>-2</sup> dia<sup>-1</sup>); Δ = declividade da curva de pressão de vapor com relação à temperatura (kPa °C<sup>-1</sup>); U<sub>2</sub> = velocidade registrada do vento a 2 m de altura (m s<sup>-1</sup>); G = fluxo de calor no solo (MJ m<sup>-2</sup> dia<sup>-1</sup>); γ = valor da constante psicométrica (kPa °C<sup>-1</sup>); T = temperatura média do ar (°C); e<sub>s</sub> = pressão de saturação do vapor (kPa).

Foram obtidos registros de 14 estações convencionais e 28 estações automáticas no estado de Goiás. Após a aplicação dos critérios de seleção, foram selecionadas dez estações meteorológicas (Figura 4b). Os Códigos, nomes dos municípios e coordenadas geográficas das estações meteorológicas das estações selecionadas podem ser consultadas na tabela 1 do Apêndice I.

Os procedimentos para correção de falhas nas séries históricas de dados de insolação, umidade relativa do ar e velocidade do vento foram realizados de acordo com recomendação de Allen *et al.* (1998). A correção de falhas em séries históricas de temperatura máxima e mínima do ar foi realizada por regressão linear (Bier; Ferraz, 2017; Dias; Soares, 2021).

### 3.5 Bases de dados meteorológicos – Reanálises climáticas

Neste trabalho, foram utilizadas as bases de dados meteorológicos, obtidas de reanálises climáticas, fornecidas pelo Nasa Power (NP) (<https://power.larc.nasa.gov/>) e pela ERA5-LAND (EL) (<https://cds.climate.copernicus.eu/cdsapp#!/dataset/reanalysisera5land?tab=overview>)

. Essas bases foram escolhidas devido à sua aplicação prévia em diversas pesquisas agrometeorológicas, bem como à qualidade e confiabilidade das estimativas que apresentaram em pesquisas já realizadas. Ambas as fontes de dados foram amplamente avaliadas em diferentes regiões do mundo, demonstrando resultados satisfatórios em termos de acurácia e consistência (Yang *et al.*, 2024; Tayyeh; Mohammed, 2023; Giovanella *et al.*, 2021; Aparecido *et al.*, 2020;). Somado a isso, essas reanálises possuem uma ampla cobertura temporal, abrangendo o período de dados observacionais disponíveis, entre 1988 e 2022, o que possibilitou uma comparação entre as estimativas geradas por esses produtos e as séries temporais observadas pelas estações meteorológicas de Goiás. Esse fator é crucial para validar os dados fornecidos pelas reanálises e garantir a consistência dos resultados em relação às condições climáticas reais observadas.

O Nasa Power é gerado para todo o globo com uma resolução espacial de  $1^\circ \times 1^\circ$  (latitude/longitude), em escala horária, com cobertura temporal de 1981 até quase o presente (Stackhouse *et al.*, 2015). O conjunto de dados ERA5-Land também é gerado para todo o globo com resolução espacial de  $0,1^\circ \times 0,1^\circ$ , em escala horária, com cobertura temporal de 1950 até o presente (Muñoz Sabater, 2021).

Os dados foram baixados em arquivo de formato Net.CDF, e extraídos para os municípios indicados na Figura 3 e na Tabela 1 e 2 do Apêndice I, em formato CSV considerando o mesmo intervalo de tempo usados para os dados medidos em superfície pelas estações meteorológicas (1988-2008), os dados foram ajustados para o fuso -3 UTC e SIRGAS2000.

Para cálculo da ETo, no caso do conjunto de dados ERA5-Land, a umidade relativa do ar (URA) foi calculada utilizando procedimento descrito por Allen *et al.* (1998) com base na temperatura do ponto de orvalho (K), Equação 2 a 4.

$$URA = 100 \frac{e_a}{e_o(T)} \quad (2)$$

$$e_a = 0.610 \exp\left(\frac{17.27 \cdot T_o}{T_o + 237.3}\right) \quad (3)$$

$$e_o(T) = 0.6108 \exp\left(\frac{17.27 \cdot T_m}{T_m + 237.3}\right) \quad (4)$$

Em que:

$e_a$ = Pressão real de vapor (kPa);  $e_o$ = pressão de saturação de vapor a temperatura do ar (kPa);  $T_o$  = Temperatura do ponto de orvalho (°C);  $T_m$ = Temperatura média do ar (°C).

A velocidade média diária do vento a 10 m foi estimada a partir de dados das componentes  $U_{10}$  e  $V_{10}$ , disponibilizados do conjunto ERA5-Land (equação 5) (Silva, *et al.* 2015). Posteriormente, a velocidade média diária a 2 m foi estimada a partir da equação 6.

$$|\vec{V}_{10}| = \sqrt{u_{10}^2 + v_{10}^2} \quad (5)$$

$$V_2 = V_{10} \left( \frac{4.87}{\ln(67.8Z - 5.42)} \right) \quad (6)$$

Em que:

$V_{10}$  = Velocidade do vento na altura 10 m ( $m s^{-1}$ );  $V_2$  = Velocidade do vento na altura 2 m ( $m s^{-1}$ );  $v_{10}$  = Componente norte do vento de 10 m ( $m s^{-1}$ );  $u_{10}$  = Componente leste do vento de 10 m ( $m s^{-1}$ ).

### 3.6 Análise do desempenho das reanálises

Para avaliação da acurácia dos valores simulados de ETo e de precipitação diários estimados pelas reanálises Nasa Power e ERA5-Land, foram utilizadas as seguintes estatísticas: erro médio de viés (MBE, equação 7), erro médio absoluto (MAE, equação 8) (Abro, 2020), raiz do erro quadrático médio (RMSE, equação 9), Concordância de Wilmott (d) (equação 10), coeficiente de determinação ( $R^2$ , equação 11), índice de eficiência de Nash – Sutcliffe Efficiency (NSE, equação 12) (Nash; Sutcliffe, 1970) e índice de eficiência de Kling-Gupta (KGE, equação 13) (Gupta, 2009).

$$MBE = \frac{1}{n} \sum_{i=1}^m (Sim_i - Obs_i) \quad (7)$$

$$MAE = \frac{1}{n} \sum_{i=1}^m |Sim_i - Obs_i| \quad (8)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^m (Obs_i - Sim_i)^2} \quad (9)$$

$$d = 1 - \frac{\sum_{i=1}^n (Obs_i - sim_i)^2}{\sum_{i=1}^n (|Sim_i - \overline{Obs}| + |Obs_i - \overline{Obs}|)} \quad (10)$$

$$R^2 = \frac{\sum_{i=1}^n (Obs_i - \bar{Obs}_i) i (Sim_i - \bar{Sim}_i)}{\sqrt{\sum_{i=1}^n (Obs_i - \bar{Obs}_i)^2} \sqrt{\sum_{i=1}^n (Sim_i - \bar{Sim}_i)^2}} \quad (11)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (Q_{obsi} - Q_{simi})^2}{\sum_{i=1}^n (Q_{obsi} - Q_{meani})^2} \quad (12)$$

$$KGE = 1 - \sqrt{(r - 1)^2 + (\beta - 1)^2 + (\gamma - 1)^2} \quad (13)$$

Sendo:

$$r = \frac{\sum_{i=1}^n (Obs_i - \bar{Obs}_i)}{\sqrt{\sum_{i=1}^n (Obs_i - \bar{Obs}_i)^2} \sqrt{\sum_{i=1}^n (Sim_i - \bar{Sim}_i)^2}} \quad (14)$$

$$\beta = \frac{\mu_s}{\mu_o} \quad (15)$$

$$\gamma = \frac{CV_s}{CV_o} = \frac{\frac{\sigma_s}{\mu_s}}{\frac{\sigma_o}{\mu_o}} \quad (16)$$

Em que:

$n$  = número de observações;  $Obs_i$  e  $Sim_i$  = valores simulados de ETo e precipitação com base nos dados de reanálise, no dia  $i$ ;  $\bar{O}$  e  $\bar{S}$  = média aritmética dos observados e simulados de ETo e de precipitação;  $CV_s$  = coeficiente de variação da ETo e da precipitação calculados com base em dados observados;  $CV_o$  = coeficiente de variação da ETo e da precipitação calculados com base nos dados de reanálise;  $\sigma_s$  = desvio padrão da ETo e da precipitação calculados com base em dados observados;  $\sigma_o$  = desvio padrão da ETo e da precipitação calculados com base nos dados de reanálise.

### 3.7 Correção de viés nos dados de reanálises

Para correção de viés, foi utilizado o método de escalonamento linear (Lenderink *et al.*, 2007). O método consiste na determinação de um coeficiente de correção

baseado na razão entre dados observados em superfície e dados de obtidos por reanálises (Equação 17 e 18).

$$ET_{oc} = ET_{o(sim)} \left( \frac{\overline{ET_{oobs}}}{\overline{ET_{osim}}} \right) \quad (17)$$

$$P_{(c)} = P_{(sim)} \left( \frac{\overline{P_{obs}}}{\overline{P_{sim}}} \right) \quad (18)$$

Em que:

$ET_{(c)}$  = Evapotranspiração de referência com correção de viés;  $ET_{o(sim)}$  = Evapotranspiração de referência obtida a partir de dados de reanálises;  $\overline{ET_{oobs}}$  = média diária da Evapotranspiração de referência obtida com dados observados;  $\overline{ET_{osim}}$  = média diária da Evapotranspiração de referência obtida com dados oriundos de reanálises.  $P_{(c)}$  = Precipitação com correção de correção de viés;  $P_{(sim)}$  = Precipitação obtida a partir de dados de reanálises;  $\overline{P_{obs}}$  = média diária da precipitação observada;  $\overline{P_{sim}}$  = média diária da precipitação oriunda de reanálises.

### 3.8 Demanda de água verde e azul para a soja

Para estimativa da demanda hídrica da cultura da soja foi utilizado o conjunto de dados de reanálise Nasa Power com correção de viés, pois esses dados apresentaram melhor acurácia. A evapotranspiração da cultura foi calculada pelo produto da evapotranspiração de referência pelo coeficiente de cultura ( $K_c$ ), ajustados para o estado de Goiás, considerando três estágios, inicial, intermediário e final, respectivamente de 0,60; 1,10 e 0,40 (EMBRAPA, 2021).

Para modelagem do conteúdo de água no solo durante o período de cultivo (AD), foi utilizada a equação 19:

$$AD = AD_{i-1} + P_{efe} + L_{ir} - ET_c \quad (19)$$

Em que:

$AD_{i-1}$  = água disponível no dia i-1 (mm);  $P_{efe}$  = precipitação efetiva (mm);  $ET_c$  = evapotranspiração da cultura (mm) e  $L_{ir}$  = Lâmina de irrigação (mm).

Foram estabelecidas as seguintes suposições para a modelagem da demanda hídrica: fator de disponibilidade hídrica (f) igual a 0,5 (SANTOS *et al.*, 2020); a irrigação é realizada com objetivo de evitar que a água disponível atinja o ponto de armazenamento crítico (0,5); profundidade efetiva do sistema radicular igual a 60 cm (Aparecido *et al.*, 2021); foi utilizado um valor de CAD (mm) para cada município (ANA, 2020); a ascensão capilar foi desconsiderada; conteúdo de água superior a

capacidade campo é perdido por percolação e escoamento superficial (Rodrigues; Moreira, 2015).

Para estimativa do requerimento hídrico da cultura da soja foram considerados 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), foram realizadas simulações de plantio de 1988 a 2022 com os dados do Nasa Power com correção de viés, com data de semeadura em 15 de outubro e 10 de novembro, conforme recomendação pelo Calendário de Plantio e Colheita de Grãos no Brasil (CONAB, 2022) e seguindo regulamento sanitário pertinente (MAPA, 2023).

Com as demandas hídricas estimadas, foram calculadas as probabilidades de não excedência para o nível de 80% de probabilidade.

### 3.9 Estimativa da demanda hídrica futura da soja

Para estimativa da demanda hídrica futura da cultura da soja foram utilizados os dados climatológicos diários de dois períodos distintos de 2040 a 2070 e 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/>).

Foram utilizados os dados de ETo, estimados pelo método de Penman-Monteith, e precipitação do modelo HadGEM2-ES, para os cenários SSP5-8.5 e SSP2-4.5. Os dados foram submetidos a um processo de correção de viés, que se baseou na aplicação do mapeamento quantil empírico. Este procedimento permite a comparação das curvas de probabilidade acumulada entre as variáveis observadas e aquelas simuladas pelo modelo climático (Chou *et al.*, 2014a; Chou *et al.*, 2014b).

Para avaliar o impacto das mudanças climáticas na variação da demanda hídrica total (DHT) e nas suas contribuições verde e azul, foram utilizados os índices de extremo de precipitação: CDD = Número máximo, durante o ciclo da cultura, de dias consecutivos com menos de 1mm; CWD= Número máximo, durante o ciclo da cultura, de dias consecutivos com mais de 1mm; R25mm= Número de dias durante o ciclo da cultura com mais de 25mm/dia; R50 = Número de dias, durante o ciclo da cultura, com mais de 50mm/dia; Rx1day = Precipitação máxima diária durante o ciclo da cultura.

ciclo da cultura; Rx1day = Precipitação máxima durante cinco dias consecutivos durante o ciclo da cultura.

### 3.10 Balanço hídrico climatológico

O balanço hídrico climatológico normal (BHC) foi calculado utilizando-se a metodologia proposta por Thornthwaite e Mather (1955), (Equações 20 - 25), e a base de dados de reanálise que apresentou o melhor desempenho.

$$Se (P - ETo)_i < 0 = \begin{cases} NAC_i = NAC_{i-1} + (P - ETo)_i \\ ARM_i = CAD \times e^{\frac{(NAC_i)}{CAD}} \end{cases} \quad (20)$$

$$Se (P - ETo)_i \geq 0 = \begin{cases} ARM_i = (P - ETo)_i + ARM_{i-1} \\ NAC_i = CAD \times \ln \frac{(ARM_i)}{CAD} \end{cases} \quad (21)$$

$$ALT_i = ARM_i - ARM_{i-1} \quad (22)$$

$$Se ETR_i = \begin{cases} P + |ALT_i|, se ALT < 0 \\ ETP_i, se ALT \geq 0 \end{cases} \quad (23)$$

$$DEF_i = ETo_i - ETR_i \quad (24)$$

$$EXC_i = \begin{cases} 0, se ARM_i < CAD \\ (P - ETo)_i - ALT_i, se ARM_i = CAD \end{cases} \quad (25)$$

Em que:

CAD = capacidade de água disponível (mm); P = precipitação (mm); ETP = evapotranspiração potencial (mm); ETR = evapotranspiração real (mm); ARM = armazenamento de água no solo (mm); EXC = excedente hídrico (mm); DEF = deficiência hídrica (mm); NAC = valor de (P-ET<sub>o</sub>) negativo; ALT = alteração do armazenamento de água no solo do mês atual e do mês anterior (mm) e, i = mês atual.

### 3.11. Índice de anomalias de chuva



Para mensurar a ocorrência de evento extremos de chuva ou de seca, foi utilizado o índice de anomalias de chuva (IAC), com metodologia desenvolvido por Rooy (1965) para classificar as magnitudes de anomalias de precipitação positivas (equação 26) e negativas (equação 27):

$$IAC \text{ positivo} = 3 \left[ \frac{(P - P_1)}{(P_{maxh} - P_1)} \right] \quad (26)$$

$$IAC \text{ negativo} = -3 \left[ \frac{(P - P_1)}{(P_{minh} - P_1)} \right] \quad (27)$$

Em que:

P = precipitação para ano em que foi gerado o IAC (mm);  $P_1$  = precipitação média anual da série histórica (mm);  $P_{maxh}$  = a média das dez maiores chuvas anuais da série histórica (mm); e  $P_{minh}$  = média das dez menores chuvas anuais da série histórica (mm).

O IAC é classificado em diferentes categorias conforme os valores obtidos, permitindo uma avaliação quantitativa e qualitativa das condições pluviométricas. Quando o IAC apresenta valores superiores a 4, a condição é classificada como "Extremamente Chuvosa". Para valores compreendidos entre 2 e 4, a classificação atribuída é "Muito Chuvosa". No intervalo de 0 a 2, o IAC é categorizado como "Chuvoso". Por outro lado, quando o índice se situa entre -2 e 0, a condição é definida como "Seca". Valores entre -4 e -2 são classificados como "Muito Seco", e, por fim, quando o IAC é inferior a -4, a condição é considerada "Extremamente Seca". Essa estratificação permite uma análise detalhada e precisa das anomalias de precipitação, contribuindo para a compreensão dos padrões climáticos e suas variações.

### 3.12 Modelagem da produtividade da cultura da soja

A estimativa da quebra de produtividade da soja devido ao déficit hídrico foi realizada com base no modelo proposto por Doorembos e Kassam (1977), no qual a perda de produtividade (%) é expressa pela equação 28:

$$Qp = 1 - ky \times \left[ 1 - \left( \frac{ETr}{ETc} \right) \right] \quad (28)$$

Em que:

Qp= Quebra de produtividade (%); Ky= Fator de resposta de rendimento; ETr= evapotranspiração real (mm) e ETc= Evapotranspiração máxima da cultura (mm).

Os valores de Ky utilizados nas simulações foram de acordo com os estádios fenológicos da soja, conforme recomendado por Farias *et al.* (2024): Ky1 = 0 (emergência até V2), Ky2 = 0,12 (V2 ao R1), Ky3 = 0,36 (R1 ao R5) e Ky4 = 0,57 (R5 ao R7). A quebra de produtividade foi projetada para o período futuro (2040–2099) com base nos cenários climáticos SSP2-4.5 e SSP5-8.5, gerados pelo modelo HadGEM-ES, e comparada ao período histórico (1988–2022).

Para calibração do modelo tradicional, foi utilizada a metodologia de Monteiro *et al.* (2017), que propôs a utilização da produtividade potencial tecnológica (PPt), que equivale a produtividade potencial máxima teórica obtido pelo modelo de Doorembos e Kassam (1977). A produtividade potencial tecnológica foi calculada a partir da tendência da produtividade observada (Tp) historicamente, que foi obtida por regressão linear da produtividade real (Pr) ao longo do tempo tendo como base os dados do IBGE. As variações observadas nos valores de Tp são resultados de diversos fatores, tais como clima, disponibilidade hídrica no solo e manejo agrícola. A PPt foi calculada pela equação:

$$PPt = Tp \times \alpha p \quad (29)$$

Em que:  $\alpha p$  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 ( $Ky^*$ ), que reflete a sensibilidade da cultura ao déficit hídrico. Quando  $Ky^* > 1$ , a cultura apresenta maior resposta ao déficit hídrico; quando  $Ky^* < 1$ , a resposta é reduzida. Assim, a produtividade real (Pr) é estimada pela equação:

$$\frac{Pr}{PPt} = Qp = 1 - (ky \times Ky^*) \times \left[ 1 - \left( \frac{ETr}{ETc} \right) \right] \quad (30)$$

Para calibrar o modelo, os valores iniciais de  $ky^*$  e  $\alpha p$  foram atribuídos como 1, ajustando-se 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.

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  $\alpha_p$  e  $Ky^*$ , garantindo uma análise individualizada das condições locais.

Considerando que a janela usual de plantio no estado de Goiás se estende por aproximadamente 60 dias, abrangendo o período entre meados de outubro e meados de dezembro, foram identificadas as épocas de semeadura predominantes com base nos levantamentos anuais conduzidos pela CONAB. A partir dessa análise, selecionaram-se três datas representativas para a realização das simulações para a modelagem da produtividade a partir do déficit hídrico: 15 de outubro, 10 de novembro e 15 de dezembro. Essas datas foram definidas considerando que, respectivamente, correspondem a 25%, 50% e 25% da produtividade total registrada no município e intervalo analisado.


Dessa forma, a produtividade estimada final foi obtida a partir da média ponderada dos valores simulados para essas três datas específicas, refletindo a distribuição temporal do plantio no estado. Tal abordagem se justifica pelo fato de que, conforme indicado pela CONAB, a janela de plantio na região pode abranger até dois meses, o que demanda a consideração de diferentes momentos de semeadura na modelagem da produtividade (Monteiro *et al.* 2017).

## 4 RESULTADOS E DISCUSSÃO

### 4.1 Análise dos dados observados

Os dados médios mensais de precipitação, ETo e temperatura, oriundos das estações meteorológicas do estado de Goiás, para o período de 1988 a 2008, são apresentados na Figura 5. Historicamente o estado apresenta uma sazonalidade marcante no regime de chuvas, caracterizado por uma estação chuvosa que compreende os meses de outubro a março e estação não chuvosa abrangendo de abril a setembro. A média mensal no período chuvoso é de 223 mm enquanto no período seco é de 30 mm.

**Figura 5 - 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 (1988-2008)**



A ETo apresentou variação ao longo do ano, refletindo as mudanças sazonais típicas de regiões no Cerrado. Os menores valores médios de ETo mensal, foram registrados em maio (80,1 mm) e junho (74,7 mm), o que reflete a menor demanda evaporativa associada às temperaturas reduzidas e à menor incidência de radiação solar durante o inverno. Em contrapartida, os maiores valores mensais ETo foram registrados em setembro (114,2 mm) e 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, comuns do

período de transição para a estação chuvosa no Cerrado, quando a atmosfera apresenta alta demanda evaporativa.

Observou-se que entre maio e setembro, a precipitação média diária permaneceu abaixo de 5 mm, o que é característico do período de baixa disponibilidade hídrica. Por outro lado, dezembro e janeiro, meses tipicamente mais chuvosos, registraram médias de 9,1 mm e 8,8 mm, respectivamente. A maior variabilidade na precipitação diária ( $CV = 41,8\%$ ) foi observada no mês de abril, que é um mês de transição entre as estações chuvosa e seca.

Essa variabilidade reforça a incerteza sobre a definição exata do início e fim da estação chuvosa no Cerrado, frequentemente descrita em vários estudos como composta por seis meses secos e seis meses chuvosos. No entanto, outros estudos indicam que o mais adequado seria considerar cinco meses de chuva (novembro a março) e cinco meses de seca (maio a setembro), com outubro e abril sendo meses de transição. Essa incerteza sobre o início efetivo do período chuvoso pode impactar diretamente a definição da data ideal de plantio, uma vez que a semeadura precoce pode enfrentar déficit hídrico, enquanto o atraso pode comprometer o ciclo da cultura, especialmente em sistemas de sequeiro (Althoff *et al.*, 2024).

Os menores valores de  $ET_o$  foram em média igual a  $2,5 \text{ mm dia}^{-1}$ , observados no mês junho; já os maiores valores foram em média igual a  $4,0 \text{ mm dia}^{-1}$ , observados nos meses de setembro e outubro. Durante o período analisado, observou-se que os meses de julho e agosto apresentaram maior dispersão nos valores de  $ET_o$  diária, com valores de  $CV$  de 6 e 6,4 % respectivamente. Em contrapartida, identificou-se uma menor variabilidade ( $CV = 1,5\%$ ) no mês de fevereiro.


#### **4.2 Avaliação da acurácia da evapotranspiração e da precipitação**

Após a correção de viés, observou-se redução do erro absoluto médio (MAE) de aproximadamente 67%, nas estimativas provenientes do Nasa Power (NP), e de 83%, nas estimativas do ERA5-Land (EL). Avaliando a acurácia da  $ET_o$ , obtida com os dados após a correção, observou-se que, de maneira geral, as estimativas de  $ET_o$  calculadas com o conjunto de dados oriundos da reanálise NP apresentou um melhor desempenho quando comparada ao EL.

Na Figura 6 apresenta-se regressão linear entre os valores diários de  $ET_o$  estimados pela reanálise Nasa Power, Figura (a), e EL, Figura (b). Analisando a reta

1:1 (linha vermelha), na Figura (a), pode-se observar uma leve tendência do NP em superestimar a ETo. Já, em relação ETo estimada a partir dos dados do EL, não foi possível observar uma tendência muito clara, indicando uma maior dispersão dos dados em torno da reta de regressão.

**Figura 6 - Desempenho estatístico da ETo diária estimada pela reanálise a) NP após correção de viés e ETo estimada pela reanálise b) EL após correção de viés**



A análise da acurácia dos dados de reanálise NP, na estimativa da ETo, indicou desempenho satisfatório, com correlação positiva ( $r = 0,77$ ) com elevada proporção da variância da variável dependente sendo explicada pela variável independente ( $R^2 = 0,84$ ).


O erro absoluto médio ( $MAE = 0,42 \text{ mm.dia}^{-1}$ ) sugere que, embora as estimativas apresentem um desvio em relação aos valores reais, esse erro pode ser considerado relativamente baixo, reforçando a confiabilidade do modelo para aplicações práticas. O coeficiente de eficiência de Nash-Sutcliffe ( $NSE = 0,50$ ) indicou que o NP apresenta um desempenho moderado, sendo superior ao uso da média climatológica como preditor, o que demonstra que, apesar das incertezas, esse modelo ainda é uma alternativa viável para estimativas de ETo em locais com escassez de medições diretas. Além disso, o coeficiente de determinação revela que aproximadamente 84% da variabilidade da ETo observada pode ser explicada pelas estimativas do modelo, sugerindo que, embora não seja perfeito, o NP consegue reproduzir, em boa medida, o comportamento da ETo estimada com dados observados.

Por outro lado, as estimativas de ETo, obtidas pela reanálise EL, apresentaram desempenho pior, com correlação positiva ( $r = 0,49$ ) e baixa proporção da variância da variável dependente sendo explicada pela variável independente ( $R^2 = 0,39$ ). O

erro absoluto médio ( $0,78 \text{ mm.dia}^{-1}$ ) indicou que as discrepâncias entre os valores estimados e os observados são mais expressivas do que no caso da reanálise NP, evidenciando uma menor confiabilidade do EL. O coeficiente de eficiência NSE ( $-0,62$ ) mostrou que as estimativas desse modelo são menos acuradas do que o uso da média climatológica como preditor, sugerindo baixa acurácia e alta incerteza nas projeções de ETo. O coeficiente de determinação ( $0,38$ ) indica que apenas 38% da variabilidade da ETo observada foi explicada pelas estimativas do modelo, o que reforça sua limitação na reprodução do comportamento real da ETo.

A Figura 7 apresenta o desempenho das estimativas de ETo oriundas do NP e EL na escala mensal. Observou-se uma melhora no  $R^2$ , atingindo 0,88 para o NP e 0,64 para o EL. Além disso, o NSE aumentou para 0,96 (NP) e 0,93 (EL), indicando maior aderência das estimativas aos valores observados. A correlação das estimativas do NP (0,93) foi 15% superior à do EL (0,80), evidenciando maior acurácia do NP na representação da variabilidade da ETo quando houve a agregação dos valores diários para escala mensal.

**Figura 7- Desempenho estatístico da ETo mensal estimada pela reanálise a) NP após correção de viés e ETo estimada pela reanálise b) EL após correção de viés**



O aumento do  $R^2$  e do NSE na escala mensal indicou uma redução dos erros diários, reduzindo a dispersão das estimativas, como é possível observar ao comparar as figuras 7 e 8. Por outro lado, o aumento do MAE na escala mensal indicou que, embora a correlação resultou em uma melhoria, a soma dos erros individuais ao longo do tempo pode elevar as discrepâncias absolutas entre os valores estimados e observados.

Na análise diária da ETo, observou-se que erros individuais podem ser menores, mas quando agregados em períodos mais longos (mês), podem se propagar,

aumentando o desvio absoluto total. Assim, a menor dispersão na escala mensal melhora o ajuste estatístico das séries, mas a soma dos desvios diários resulta em maiores erros absolutos acumulados. Visto que se verificou MAE de 1,76 mm mês<sup>-1</sup> para o NP e 2,95 mm mês<sup>-1</sup> para o EL. Isso explica que a agregação temporal influencia diretamente na magnitude dos erros.

Os desvios observados na acurácia da ETo, calculadas com o conjunto de dados oriundos da reanálise NP e EL, nos municípios, podem estar associadas a fatores climáticos e ambientais inerentes a cada localidade. Mas essencialmente refletem que as estimativas podem sofrer variações espaciais devida à variabilidade climática mais acentuada em algumas regiões, visto que o estado apresenta diferentes zonas climáticas com variações nos padrões de chuva e também na temperatura ao longo do extenso território de Goiás (Novais, 2020).

O desempenho do conjunto de dados do Nasa Power foi avaliado por Srivastava (2020) para a estimativa de ETo em uma estação no Norte da Índia, que obtiveram boa concordância com os dados observados, reportando viés de 0,154 mm RMSE= 0,34 e  $r= 0,96$ .

Jiménez-Jiménez *et al.*, (2021) utilizaram os dados do Nasa Power para estimar a ETo diária na região de Lagunera no México e verificaram valores de RMSE 1,15 mm d<sup>-1</sup>, embora os autores recomendem o uso da reanálise quando não há dados de observados disponíveis, também destacaram que a velocidade do vento oriunda do Nasa Power não foi confiável para região estudada.

Pelosi *et al.*, (2020) avaliaram o desempenho da ETo diária obtida a partir de dados do conjunto ERA5-Land de 38 estações na região Sul da Itália, e encontraram valores de viés percentual entre -17% a 19%, evidenciando subestimativa e superestimava dos valores calculados a partir desta reanálise, Os autores reconhecem que os modelos do ERA5-Land podem resultar em dados com incertezas e vieses significativos, e que estimativas mais precisas podem ser obtidas com a combinação de dados da reanálise ERA5-Land com dados de satélites.

As vantagens da correção de viés na precisão nas estimativas de ETo diária foi observada por Paredes *et al.*, (2020) ao avaliar o conjunto de dados ERA-Interim, os autores reportaram diminuição no valor de RSME de 0,78 para 0,57 e aumento de R<sup>2</sup> de 0,89 para 0,91.

De acordo com Rodrigues & Braga (2021), a acurácia da ETo diária estimada com o conjunto de dados Nasa Power após correção de viés aumenta quando comparada




com os resultados obtidos a partir dos dados brutos da reanálise, os autores registraram a tendência de redução significativa dos erros de estimativa (RMSE e BIAS).

Após a correção de viés, observou-se redução do erro absoluto médio (MAE) de cerca 5%, nas estimativas provenientes do NP, e de 6%, nas estimativas do EL. Avaliando a acurácia da precipitação, obtida com os dados após a correção de viés, observou-se que, de maneira geral, as estimativas de chuva diária oriundas do conjunto de dados NP apresentaram um melhor desempenho quando comparada ao EL.

Os indicadores estatísticos das estimativas de precipitação diária oriundas reanálises NP e EL após a correção de viés, considerando os 81 postos pluviométricos, são apresentados na Figura 8. Com base nas retas 1:1, verificou-se que ambas as reanálises tendem a subestimar levemente a precipitação diária em comparação a precipitação real observada.

**Figura 8 - Desempenho estatístico da precipitação diária estimada pela reanálise a) NP após correção de viés e a precipitação estimada pela reanálise b) EL após correção de viés**




As estimativas de precipitação oriundas do NP apresentaram desempenho razoável ( $R^2 = 0,71$ ), sugerindo uma associação moderada entre as chuvas estimadas e observadas. Ao considerar o erro médio absoluto de  $4,52 \text{ mm.dia}^{-1}$ , observou-se uma discrepância pequena nas estimativas diárias da precipitação. Já o coeficiente de eficiência NSE (0,31) indicou que as estimativas são razoáveis, e que o modelo apresentou uma capacidade preditiva superior ao uso da média. Além disso, o coeficiente de determinação ( $R^2 = 0,71$ ) indica que 71% da variação dos dados medidos pode ser explicada pelas estimativas do modelo, evidenciando sua relativa capacidade de representar padrões pluviométricos ocorridos.

No que diz respeito as estimativas de precipitação obtidas pela EL, os resultados indicam um pior desempenho quando comparado aos dados da reanálise NP. O coeficiente de correlação de 0,42 é baixo e sugere uma relação fraca entre os valores estimados e os observados. O erro médio absoluto ( $4,66 \text{ mm dia}^{-1}$ ) evidencia uma discrepância ainda maior do que aquela observada no NP. No entanto, o coeficiente de eficiência de Nash-Sutcliffe próximo de zero ( $\text{NSE} = 0,10$ ) indica que as estimativas do EL não são mais eficazes do que o uso de uma média climatológica simples, tornando-se, portanto, pouco confiáveis. O coeficiente de determinação ( $R^2 = 0,66$ ) revela que apenas 66% da variação da precipitação observada é explicada pelo modelo, reforçando sua menor acurácia em relação ao NP.

Estudos anteriores também reportaram que estimativa de precipitação por sensoriamento remoto apresenta maior dispersão em escala diária, tornando sua precisão mais limitada. No entanto, quando foram agregadas na escala mensal, as estimativas se aproximaram mais dos valores medidos em postos pluviométricos. Por exemplo, os dados diários do NP apresentaram  $R^2$  de 0,71, enquanto o EL obteve um  $R^2$  de 0,66, ambos com elevada dispersão entre os valores estimados e medidos (Figura 8).

Ao considerar a escala mensal (Figura 9), as estimativas do NP apresentaram correlação de 0,98, muito próxima ao EL (0,97), porém ligeiramente maior. O coeficiente NSE também foi maior para o NP (0,96) em comparação ao EL (0,93). Além disso, o MAE do NP foi aproximadamente 30% inferior ao do EL, indicando maior acurácia nas estimativas.

**Figura 9 - Desempenho estatístico da precipitação mensal estimada pela reanálise a) NP após correção de viés e a precipitação estimada pela reanálise b) EL após correção de viés**



Observou-se que houve uma melhora expressiva no desempenho das estimativas, com o  $R^2$  do NP aumentando para 0,97 e o do EL para 0,96. Isso pode ser explicado pelo fato dos erros individuais tenderem a se compensar, equilibrando as discrepâncias diárias e resultando em um valor médio mensal mais representativo da precipitação medida nos postos pluviométricos. Ainda assim, a reanálise NP demonstrou desempenho superior ao EL, explicando melhor a variabilidade dos dados observados por apresentar coeficiente de determinação ligeiramente superior.

Ao avaliar as estimativas de precipitação em escala diária para o território da Espanha, Cebolla *et al.*, (2023) observaram que as estimativas da reanálise Era5-Land representaram adequadamente os padrões espaciais e as tendências temporais da precipitação da área estudada, entretanto, segundo os autores o pior desempenho da reanálise é obtido durante os meses de verão, com uma superestimação generalizada.

Os dados de precipitação mensal da reanálise Era5-Land foram avaliados por Longo-Minnolo *et al.*, (2022) para bacia do rio Simeto na Itália que obtiveram valores de MAE entre 18,26 e 49,32 mm. Os autores concluíram que muitas incertezas da reanálise Era5-land estão relacionadas as condições microclimáticas específicas da região estudada, e recomendam aplicação de métodos de correção de viés para aumentar a acurácia dos dados estimados.

O desempenho da variação espaço-temporal da precipitação oriunda da reanálise ERA5 foi avaliada por Jiao *et al.*, (2021) para territórios chineses que verificaram bons níveis de acurácia, sendo reportado coeficiente de correlação linear variando entre 0,79 a 0,95, os autores também destacaram que o bom desempenho das estimativas estava diretamente relacionado com a distribuição topográfica.

#### **4.3 Balanço hídrico atual e futuro e anomalias de chuva**


Na Figura 10 são apresentados os extratos dos balanços hídricos climatológicos médio dos 20 municípios com maior produção de soja no estado de Goiás, com base nos dados de referência (1988-2022), para períodos 2040 a 2070 e 2070 a 2099 a partir dos cenários SSP2-4.5 e SSP5-8.5.

No período de referência (1988-2022) foram observados excedentes hídricos nos meses de janeiro, fevereiro, março, abril, novembro e dezembro. Em média, o excedente hídrico nesses meses foi igual a 100,2 mm. O maior excedente hídrico foi observado no mês de dezembro, representando 25% do total. O menor excedente

hídrico, representando 2% do total, foi observado no mês de abril. Resultados semelhantes foram observados 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.

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

**Figura 10 - Balaço hídrico climatológico médio para os 20 municípios com maior produção de soja em Goiás a partir dos dados do Nasa Power referência (1988-2022), Figura (a), cenário SSP2-4.5, para período de 2040-2070, Figura (b) e 2070-2099, Figura (c) e cenário SSP5-8.5 para período 2040-2070, Figura (d) e 2070-2099, Figura (e). As porcentagens apresentadas no interior das figuras representam a fração do excedente ou déficit hídrico relativo correspondente a cada mês em relação ao total anual**



Para o cenário SSP2-4.5 e o período de 2040 a 2070, observou-se a concentração dos excedentes hídricos nos meses de dezembro, janeiro, fevereiro e março. Em comparação ao período de referência, houve redução de dois meses de excedente (novembro e abril). Nesse cenário, o déficit hídrico se estende por sete meses, começando em abril, com uma intensidade baixa (0,7% do total de déficit) indo até

outubro (9,5 %). Destaca-se uma atenuação do déficit no mês de agosto, com um valor de 121,2 mm, o que representa percentualmente 24% do total.

Ao se considerar o mesmo cenário, para o período mais distante de 2070 a 2099, observou-se uma diminuição considerável do excedente hídrico estimado para o mês de dezembro, que passou a apresentar um valor de 48,7 mm, o que representa cerca de 16,2% do total 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 verificados nos meses de julho (109,4 mm) e 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.

No cenário SSP5-8.5, projeta-se que o déficit hídrico se estenda para a maioria dos meses, abrangendo o período de abril a novembro. O déficit atinge valores superiores a 100 mm entre julho e agosto, com o mês de agosto registrando o percentual mais alto de 21,5% do total anual de déficit hídrico, esse valor representa um aumento de 57% em relação ao déficit observado em agosto no período de referência.

Além disso, somente há excedente hídrico durante o primeiro trimestre do ano, sendo 20,9; 46,6 e 32,5% distribuídos respectivamente nos meses de janeiro, fevereiro e março. Nesse contexto, quando comparado ao período de referência observou-se uma redução significativa no excedente hídrico, com uma diminuição de 78% em janeiro, 42% em fevereiro e 57% em março, evidenciando uma diminuição da disponibilidade de água em períodos que, tradicionalmente, são caracterizados por volumes precipitação mais expressivos.

Ao avaliar o armazenamento de água no solo projetado para o período de 2070 a 2099, no cenário SSP5-8.5, observou-se uma conjuntura mais severa, caracterizada pela intensificação da redução do armazenamento hídrico no solo, especialmente nos meses de julho (15,8%), agosto (19,3%) e setembro (17,8%). Os menores déficits foram observados em abril (2,4%) e novembro (5,8%). No primeiro trimestre do ano, os excedentes hídricos mensais foram inferiores a 50 mm, o que indica uma redução significativa da quantidade de água no solo quando comparado ao período de referência. Sendo o maior excedente no mês de março apresentando 45,4% do total de excedente hídrico.

Os resultados indicam uma modificação significativa no balanço hídrico climatológico para os períodos futuros projetados pelo modelo HadGEM2-ES, com um

aumento do déficit hídrico e uma diminuição do excedente hídrico, o que reflete uma provável alteração nos padrões de precipitação e evapotranspiração ao longo do tempo.


A intensificação desses fenômenos sugere que, em ambos os cenários, as mudanças climáticas acarretariam um aumento da ETo e uma diminuição das precipitações durante os meses mais críticos, comprometendo o armazenamento de água no solo ao longo do ano para volumes inferiores a 100 mm.

Ao se comparar os cenários SSP2-4.5 e SSP5-8.5 para o período de 2040 a 2070, as projeções do cenário SSP2-4.5 indicam condições relativamente mais amenas, uma vez que preveem um maior armazenamento de água no solo e menor intensidade no déficit hídrico durante os meses secos, em comparação com o cenário SSP5-8.5. Enquanto janeiro é o mês com o maior excedente hídrico no cenário SSP2-4.5, com 114,2 mm, no cenário SSP5-8.5, esse valor ocorre em fevereiro, com apenas 73,1 mm. Ambos os cenários apontam para o agosto como o mês com o maior déficit hídrico, sendo que no cenário SSP5-8.5, a intensidade desse déficit é ligeiramente mais alta, 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 emissão SSP2-4.5 projeta um incremento no excesso de água disponível no mês de março, com um valor de 93,2 mm, enquanto o mês de agosto apresenta maior déficit hídrico, com um valor de 126,8 mm. Em comparação, o cenário SSP5-8.5 prevê um aumento mais moderado na disponibilidade de água em março, alcançando 42,7 mm, e um déficit mais acentuado em agosto, com 139,3 mm. A diferença entre os cenários SSP2-4.5 e SSP5-8.5 em relação ao excedente e déficit hídrico evidencia a influência do grau de emissões de gases de efeito estufa na dinâmica climática e na gestão dos recursos hídricos ao longo do final do século XXI.

Na figura 11 são apresentados os índices de anomalia de chuva (IAC) com base nos dados médios de precipitação dos 20 municípios com maior produção de soja em Goiás para os cenários SSP2-4.5, para período de 2040-2099 e cenário SSP5-8.5 para período 2040-2099.

**Figura 11- Distribuição temporal dos índices de anomalia de chuva médio para os 20 municípios com maior produção de soja em Goiás para cenário SSP2-4.5, para período de 2040-2099, Figura (a), e cenário SSP5-8.5 para período 2040-2099, Figura (b). Em azul tem-se anomalias positivas e em vermelho anomalias negativas**



A análise dos dados de IAC para o cenário SSP2-4.5, no período de 2040 a 2099, mostra uma predominância de anos classificados como secos e muito secos, evidenciando uma possível tendência de redução da precipitação natural ao longo do tempo. A distribuição das classificações revelou que 7 anos foram classificados como extremamente chuvosos, 5 anos como muito chuvosos, 5 anos como chuvosos, 9 anos como secos, 8 anos como muito secos e 26 anos como extremamente secos. Esses números demonstram uma predominância dos anos com condições secas, principalmente os classificados como extremamente secos, que representaram 43% dos anos analisados.

Os extremos positivos de precipitação foram registrados nos anos 2077 (IAC = 15,3) e 2046 (IAC = 9,1), seguidos de 2047 (IAC = 9,7) e 2076 (IAC = 9,3), que se destacam como os mais chuvosos do período. Já os extremos negativos, que



representam os períodos mais secos, ocorreram nos anos 2084 (IAC = -12,8), 2067 (IAC = -11,3) e 2059 (IAC = -10,3), seguidos de 2083 (IAC = -10,0). Esses valores indicam anos de severa estiagem, possivelmente impactando negativamente os recursos hídricos e a produtividade agrícola.

As projeções para o cenário SSP5-8.5 entre os anos de 2040 e 2099 indicaram uma tendência ainda mais acentuada de eventos extremos, particularmente em relação à seca. O número de anos classificados como Extremamente Seco foi de 39, tornando esta a categoria dominante. Os anos de 2060, 2080 e 2086 foram exemplos notáveis de condições extremamente secas, com IACs de -10; -10,2 e -9,7, respectivamente. A categoria Muito Seco ocorreu em 10 anos, enquanto Seco foi registrado em apenas 2 anos.

Por outro lado, anos classificados como Extremamente Chuvoso foram observados em 5 ocasiões (2047, 2048, 2075, 2076 e 2077), e a categoria Muito Chuvoso apareceu em apenas 1 ano (2046). O número reduzido de eventos chuvosos reflete uma tendência clara de redução na precipitação anual, indicando um possível agravamento dos eventos de seca prolongada sob o cenário de emissões mais elevadas (SSP5-8.5).

A comparação entre os dois cenários indicou que, embora ambos apresentem uma predominância de eventos secos, no cenário SSP5-8.5 acentua-se esse padrão, com uma frequência ainda maior de anos Extremamente Secos. Isso reforça a hipótese de que cenários de maior emissão de gases de efeito estufa potencializam as condições climáticas extremas, exigindo estratégias de adaptação mais eficazes para mitigar seus impactos na agricultura irrigada e na gestão recursos hídricos para os demais usuários.

#### **4.4 Estimativa, atual e futura, das demandas de água verde e azul para produção da cultura da soja**

Na Figura 12 apresenta-se, para duas datas de semeadura, as quantidades de águas verde e azul necessárias para a produção da soja. A análise foi feita para os vinte municípios de Goiás com maior produção de soja, considerando uma frequência de excedência igual a 20%.

Analisando os resultados, observou-se que, em média, para o plantio em 15 de outubro, a água verde representou 85% (332,4 mm) do total da demanda hídrica e


89% (337,1 mm), em 10 de novembro. Niquelândia, com 378 mm e 380 mm, foi o município que recebeu a maior contribuição de água verde em ambas as datas de semeadura. Por outro lado, Montividiu foi o município que recebeu a menor contribuição de água verde, em 15 de outubro (300 mm), enquanto Mineiros registrou o menor valor em 10 de novembro (306 mm).

No que diz respeito a água azul, essencial para evitar déficits hídricos para a cultura, apresentou uma média geral de 57,2 mm, para o plantio em 15 de outubro, e 40,4 mm em 10 de novembro, evidenciando uma redução na necessidade de irrigação quando o plantio ocorre mais tarde. O maior valor de necessidade de água azul (irrigação) foi registrado em Niquelândia, com 110 mm em outubro, e 102 mm, em novembro, reforçando a necessidade de maior suplementação hídrica nesse município. Em contrapartida, Mineiros apresentou a menor demanda por água azul em ambas as datas, com 25 mm em outubro e apenas 5 mm em novembro. Essa dinâmica indicou que, mesmo com a variação entre municípios, a água verde continua sendo o principal recurso hídrico para atender à demanda das culturas.

O coeficiente de variação da água verde para a cultura da soja apresentou valores relativamente baixos para ambas as datas de semeadura analisadas, sendo de 6,8%, para o plantio realizado em 15 de outubro, e de 6,1%, para aquele realizado em 10 de novembro, indicando uma segurança hídrica em relação a água da chuva. Para a semeadura em outubro, a água azul apresentou um CV igual a 39,6% e igual a 57,1%, em novembro.

Analisando esses resultados, nota-se, portanto, que, historicamente, o plantio em novembro está associado a um regime pluviométrico mais favorável, reduzindo a necessidade de irrigação suplementar. Por outro lado, no plantio de outubro, a menor disponibilidade de chuvas faz com que a cultura dependa mais da irrigação, aumentando proporcionalmente a participação da água azul na demanda hídrica total e tornando seu requerimento mais constante.

**Figura 12 - Necessidade hídrica total da cultura da soja, para uma frequência de excedência igual a 20%, para as semeaduras em 15 de outubro e 10 de novembro, com base nos dados do Nasa Power corrigidos, para o período de 1988-2022. Destacando em verde a fração da demanda suprida com água da chuva e em azul a fração suprida com a irrigação**



CP= Caiapônia; NI=Niquelândia; AC= Acreúna; GO= Goiatuba; 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= Cristalina; JA= Jataí; RV= Rio Verde.

Analisando a Figura 12, nota-se, para os dois períodos simulados, que a maior parte da demanda hídrica da cultura da soja, foi suprida com água da chuva, representando em média 80% da DHT, na maioria dos municípios analisados. Para a semeadura em outubro, a contribuição média advinda da água da chuva representou 85,3% da DHT. Já para a semeadura realizada em novembro, a proporção de água verde se eleva para 89,3%, enquanto a participação da água azul se reduz para 10,7%.

Em suma, verificou-se que a DHT, para o cultivo da soja, variou entre 325 e 488 mm, dependendo do período de plantio. Para a semeadura em 15 de outubro, Figura 12a, a DHT foi em média igual a 389,5 mm, maior do que a DHT com data de plantio em novembro de 377,5 mm, Figura 12b.

Na análise dos dados referentes à semeadura de 15 de outubro, observou-se uma maior variabilidade espacial na DHT, sendo a maior diferença igual a 66%, observada entre os municípios de Niquelândia e Montividiu. O município de Niquelândia, localizado na mesorregião Norte do estado de Goiás, apresentou a maior DHT, com um total de 488 mm. Observou-se que cerca de 77% da DHT, nesse município, pode ser suprida pela precipitação. Já, no município de Montividiu, situado na mesorregião Sudoeste Goiano, a DHT foi 33% inferior, dos quais 91% podem ser supridos por precipitação natural.

Na semeadura em 10 de novembro, verificou-se maior DHT em Niquelândia (482 mm) e a menor em Mineiros (311 mm). Niquelândia apresentou uma necessidade de irrigação igual a 22% da DHT. Por outro lado, em Mineiros, a maior parte da DHT pode ser suprida pela precipitação natural (98%), com apenas 2% de necessidade de irrigação, indicando que as condições pluviométricas dessa região, no período de plantio de novembro, foram favoráveis o suficiente para garantir o desenvolvimento da soja sem a necessidade de grandes volumes de complementação hídrica através de irrigação.

Uma análise comparativa entre as duas datas de plantio indicou que, em 90% dos municípios, a contribuição maior da água da chuva para atendimento da DHT ocorre em novembro. Um exemplo disso é o município de Cristalina, onde o aproveitamento da chuva efetiva aumentou em cerca de 9% quando o plantio ocorreu nesse mês. Naturalmente, nesse mês, foi observada menor necessidade de irrigação para atender à DHT. Essa redução na lâmina de irrigação foi registrada em 95% dos municípios analisados. Um caso específico é o de Padre Bernardo, onde o plantio em novembro resultou em uma diminuição de 50% na lâmina de irrigação em comparação com o plantio realizado em outubro.

A diminuição da lâmina de irrigação, sem redução do rendimento da cultura, indica a possibilidade de aumentar a produtividade de uso da água simplesmente adequando a data de semeadura. Esses resultados indicam que, ao adotar uma estratégia de plantio que leve em consideração os padrões climáticos e as necessidades hídricas da soja, é possível reduzir o número de eventos de irrigação, os custos associados a prática de irrigar e a demanda por água azul, contribuindo para redução das disputas pelo uso da água.

A determinação de épocas de semeadura da soja é essencial para evitar quebra de safra (Evangelista *et al.*, 2017). Esses autores também destacam que a ocorrência de veranicos se intensificou no cerrado, e ressaltaram a importância dos dados para a elaboração de estratégias de gestão de risco hídrico para a cultura da soja.


O requerimento hídrico durante o ciclo total da soja em regiões de clima tropical pode variar entre 350 e 800 mm e pode sofrer influência diferentemente da época de plantio, condições meteorológicas e variedade cultivada (França *et al.*, 2024).

Caetano *et al.*, (2023) avaliaram a evapotranspiração do cultivo de soja, no município de Silvânia-Go, nas safras de 2016/17, 2017/18 e 2018/19, e observaram,

respectivamente, valores 337,7; 396,9 e 425,3 mm por ciclo. Demanda hídrica coerente com os valores identificados neste trabalho.

Ao avaliar a dinâmica temporal da DHT e suas componentes, em termos médios, verificou-se que a possibilidade de maior contribuição da água verde para suprir a DHT ocorreu na semeadura de novembro (309 mm) em comparação com outubro (305 mm), enquanto a necessidade de água azul foi menor em novembro (15 mm) do que em outubro (17 mm). Esse comportamento sugere que a semeadura mais tardia tende a se beneficiar de uma maior disponibilidade hídrica natural, reduzindo, consequentemente, a necessidade de irrigação suplementar como é possível verificar na variação temporal média das contribuições hídricas azul e verde dos 20 municípios avaliados (Figura 13). Por outro lado, antecipar a semeadura da soja, traz benefícios em relação ao plantio da próxima safra, normalmente milho “safrinha”. Nesse contexto, a irrigação agrega valor trazendo maior segurança.

**Figura 13 - Necessidades hídricas médias, para os vinte municípios, considerando as contribuições provenientes da água da chuva, (verde), e da irrigação (azul), para as semeaduras da soja em 15 de outubro, e 10 de novembro, com base nos dados do Nasa Power corrigidos, para o período de 1988-2022**




Ao avaliar a recorrência histórica dessas tendências, observa-se que em 68% do tempo (23 anos), a necessidade de complementar a DHT por meio da irrigação (água azul) foi menor em novembro do que em outubro, e em 74% dos anos, a água verde foi maior em novembro do que em outubro. Esses resultados reforçam a hipótese de que a semeadura tardia, além de aproveitar melhor as precipitações, reduz a dependência da irrigação, tornando-se uma alternativa potencialmente mais eficiente do ponto de vista hídrico.

Por exemplo, no ano de 2014, apesar da água verde ter sido ligeiramente menor em novembro (325 mm) do que em outubro (330 mm), a necessidade de irrigação foi menor para a semeadura tardia (59 mm contra 92 mm). Isso sugere que a distribuição da precipitação ao longo do ciclo da cultura possibilitou uma menor necessidade complementar a DHT por meio da água azul, mesmo quando a disponibilidade total de água verde foi reduzida.

Dessa forma, baseado na análise dos dados, constata-se que a escolha da data de semeadura é uma estratégia interessante a ser adotada pelos tomadores de decisão no que concerne ao uso de recursos hídricos na cultura da soja. A semeadura em novembro, na maioria dos anos analisados, mostrou-se mais eficiente no aproveitamento da água verde, reduzindo a necessidade de irrigação e, conseqüentemente, os custos associados ao uso de água azul. Esses resultados reforçam a importância do planejamento agrícola baseado em análises históricas do clima, contribuindo para um manejo mais sustentável dos recursos hídricos.

Na Figura 14 apresenta-se, para as duas datas de semeadura, as demandas municipais de águas verde e azul necessárias para a produção da soja. Essa análise foi feita considerando as demandas observadas nos cenários futuros SSP2-4.5, para os períodos de 2040-2070, Figuras (a) e (b), e 2070-2099, Figuras (c) e (d).

**Figura 14 - Necessidade hídrica total da cultura da soja, para os vinte municípios maiores produtores, para frequência de excedência igual a 20%, para as semeaduras em 15 de outubro e 10 de novembro, para o cenário SSP2-4.5 períodos 2040-2070, Figuras (a) e (b), e 2070-2099, Figuras (c) e (d)**



CP= Caiapônia; NI=Niquelândia; AC= Acreúna; GO= Goiatuba; 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= Cristalina; JA= Jataí; RV= Rio Verde.

Analisando as Figuras 14a e 14b, nota-se as contribuições advindas da água verde não variaram muito entre os dois períodos de semeadura, representando 373 mm, em 15 de outubro, e 376 mm, em 10 de novembro, correspondendo, respectivamente, 80% e 82% da contribuição da água verde na DHT. Já, a água azul passou de 20%, em outubro, para 18% em novembro. O que demonstra um comportamento semelhante quando comparada a dinâmica da variação da DHT do período de referência.

Para cenário SSP2-4.5, de 2040-2070, verificou-se um aumento na variabilidade da água azul alcançando 21,7% em outubro e 28,9% em novembro, com uma dinâmica de variabilidade semelhante ao observado no período de referência, o qual também foi notado um aumento na variabilidade do componente azul dos meses de outubro para novembro. Em ambos os casos essa elevação na variabilidade sugere maior incerteza na disponibilidade hídrica, mas é essencial destacar que embora tenha sido observado aumentos nos componentes verde e azul da DHT, a variação de ambas as datas seguem a mesma tendência de aumento.

Bom Jesus de Goiás está entre os municípios que apresentaram a maior DHT. Nesse município, no cenário SSP2-4.5, período de 2040 a 2070, a DHT atinge um valor igual a 519 mm na semeadura de outubro, um incremento de 40% em relação ao período de referência. Deste aumento, 51% foram devido a um melhor aproveitamento da água da chuva, enquanto os 49% restantes foram atribuídos à maior necessidade de irrigação. Em contraste, no município de Niquelândia, observou-se um aumento bem menos expressivo na DHT, de apenas 14 mm, sendo que 28% desse incremento foi proveniente da precipitação e 71% da irrigação.

A menor DHT foi observada no município de Montividiu, que apresentou uma demanda hídrica de 430 mm. Desse total, em média, cerca de 82% dessa demanda poderia ser atendida pela chuva, sendo necessário complementar cerca de 77,4 mm com água azul. Com semeadura em 10 de novembro, verificou-se uma redução da DHT de 0,94%, sendo que 83% poderiam ser atendidas pela chuva (Figura 14a e 14b). Entretanto, nesse mesmo município, em comparação com o período de referência, observou-se, na semeadura em outubro, um aumento na demanda de 32,3%, dos quais 52% poderiam ser supridas pela chuva e 48% ao crescimento da demanda por água azul. Enquanto, para a semeadura em 10 de novembro, registrou-se um aumento de 34,4% (109 mm) na DHT, sendo que 45% desse incremento poderia ser suprida da chuva e restante da irrigação.

Nesse caso, é relevante destacar que, embora na semeadura de novembro a água azul tenha apresentado um aumento percentual superior ao da água verde, em termos absolutos, a demanda por água azul é menor em novembro do que em outubro. Esse comportamento indica que, apesar do crescimento relativo da participação da água azul, a variação total da DHT ainda é mais influenciada pela água verde nas condições simuladas para período de 2040 a 2070 no cenário SSP2-4.5.

O panorama projetado para o período de 2070 a 2099, com base no cenário SSP2-4.5 (Figura 14c e 14d), indicou que, em termos médios, comparado com o período histórico, a contribuição de água verde, para suprir a DHT, aumentou de 332,4 mm para 395 mm (+18,8%) e de 337,1 mm para 399 mm (+18,4%), nas semeaduras de 15 de outubro e de 10 de novembro, respectivamente. A necessidade de irrigação seguiu essa mesma tendência, aumentando de 57,2 mm para 98 mm (+71,3%), em 15 de outubro, e de 40,4 mm para 99 mm (+145%), em novembro. Comparando com o período histórico (referência), a contribuição da irrigação em novembro era menor




que em outubro, mas essa diferença desaparece no futuro. O CV da água azul também reduz, passando de 39,6% para 28,1% (outubro) e de 57,1% para 32,3% (novembro).

Analisando as Figuras 14c e 14d, constata-se que os maiores aumentos DHT, na semeadura em 15 de outubro, foram observados nos municípios de Bom Jesus, Silvânia e Goiatuba, com valores de 164 mm, 151 mm e 142 mm, respectivamente. Para esses municípios, o aumento da necessidade de irrigação, em comparação ao período de referência, representou cerca de 40%, em Bom Jesus, 62%, em Silvânia, e em 42%, em Goiatuba. Além disso, os resultados indicaram que os municípios de Caiapônia e Jataí apresentaram os menores aumentos na demanda de irrigação, com incrementos de 9 mm e 7 mm, respectivamente.

Comparando o cenário SSP2-4.5, para o período de 2070 a 2099, com o período histórico, na semeadura de 10 de novembro, observou-se um aumento da contribuição da água verde nos municípios de Bom Jesus (175 mm), Rio Verde (111 mm) e Caiapônia (94 mm). Destacam-se, nesse contexto, os municípios de Silvânia (110 mm) e Luziânia (95 mm) como aqueles com os maiores incrementos no requerimento de água via irrigação.

Analisando as Figuras 15a e 15b (período de 2040 a 2070) e 15c e 15d (período de 2070 a 2099), para o cenário SSP5-8.5, para as datas de semeadura de 15 de outubro e de 10 de novembro, nota-se que a variação dos componentes hídricos verde e azul apresentaram padrões diferentes daqueles observados no período histórico e no cenário SSP2-4.5.

**Figura 15 - Necessidade hídrica total da cultura da soja, para os vinte municípios maiores produtores, para frequência de excedência igual a 20%, para as semeaduras em 15 de outubro e 10 de novembro, para o cenário SSP5-8.5 períodos 2040-2070, Figuras (a) e (b), e 2070-2099, Figuras (c) e (d)**



CP= Caiapônia; NI=Niquelândia; AC= Acreúna; GO= Goiatuba; 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= Cristalina; JA= Jataí; RV= Rio Verde.

Analisando as duas datas de semeadura, nota-se que a água verde apresentou valores médios muito próximos 400 mm para 15 de outubro e 398 mm para 10 de novembro. A baixa variação relativa do CV (3,9% para outubro e 4,2% para novembro) indica que a contribuição da água verde para DHT entre os municípios é pouco variável, sugerindo que a escolha da data de plantio, neste cenário não afetará tanto esse componente como ocorreu no período histórico e cenário SSP2-4.5. Entretanto, há uma leve tendência de aumento de água verde em novembro para alguns municípios, como Bom Jesus de Goiás e Santa Helena de Goiás.

Por outro lado, a água azul apresenta diferenças mais expressivas entre as datas de plantio. A média do componente azul é maior em novembro (145 mm) do que em outubro (130 mm), e a variabilidade dos valores entre os municípios também aumenta, conforme indicado pelos coeficientes de variação: 28,3% para outubro e 31,6% para novembro. Essa maior variação sugere que a dependência de irrigação pode ser menos previsível na data de semeadura posterior, possivelmente devido a uma maior incerteza na disponibilidade hídrica.

Para a semeadura em outubro, os municípios de Bom Jesus e Rio Verde apresentaram os maiores aumentos na contribuição de água verde, o que corresponde a um incremento de 51% e 86%, respectivamente, na DHT projetada em relação ao período de referência. Por outro lado, o aumento da necessidade de irrigação foi mais pronunciado nos municípios de Goiatuba (130 mm) e Ipameri (120 mm), com a água azul representando 57% e 64%, respectivamente, do aumento total da DHT, quando comparado ao período histórico. Esses resultados indicam que, em algumas regiões, a maior contribuição da precipitação efetiva pode levar a um aproveitamento mais eficiente dos recursos hídricos, como observado em Bom Jesus e Rio Verde, onde a água verde representou uma parte significativa do atendimento da DHT. No entanto, em municípios como Goiatuba e Ipameri, o aumento da DHT foi amplamente suprido pelo aporte de água azul, evidenciando uma maior dependência de água azul para complementar a oferta natural no período de 2040-2070 e cenário SSP5-8.5.

Sob as condições do cenário SSP5-8.5 e período de 2040 a 2070, para a data de semeadura em 10 de novembro, observou-se um aumento da contribuição da água da chuva, para suprimento da DHT, em Bom Jesus (+128 mm) e Mineiros (+79 mm), quando comparado aos valores de referência para a mesma data. Foram registrados aumentos na necessidade de irrigação, particularmente nos municípios de Caiapônia (+180 mm), Ipameri (+165 mm) e Goiatuba (+160 mm), em comparação com os requerimentos de irrigação para a mesma data no período de referência. Os resultados indicam que, embora alguns municípios, como Bom Jesus e Mineiros, possam se beneficiar de um aumento da contribuição da precipitação natural, outros, como Caiapônia, Ipameri e Goiatuba, mostram uma crescente dependência de irrigação para suprir a demanda hídrica.

Ao se analisar o período de 2070 a 2099, projetados pelo cenário SSP5-8.5, verificou-se que Ipameri, com DHT igual a 776 mm, foi o município que apresentou a maior demanda, para a semeadura em 15 de outubro. Desse total, 486 mm (62,6%) será suprido pela água verde e 290 mm (37,4%), pela água azul. Para o plantio em 10 de novembro, a demanda total reduz para 734 mm, com 454 mm (61,9%) de água Verde e 280 mm (38,1%) de água azul. Essa redução indica uma leve diminuição da necessidade hídrica total ao retardar a data de plantio, mas mantém uma proporção relativamente constante entre os componentes verde e azul.

Caiapônia foi o município que apresentou a menor DHT. Para o plantio em 15 de outubro, a demanda total foi de 684 mm. Da DHT total, 64,9% poderão ser supridos pela água Verde e 35,1% pela água azul. No plantio de 10 de novembro, a demanda hídrica total diminui para 600 mm, redução de 12%, 63,3% podendo ser suprido pela água Verde e 36,7% pela água Azul. Essa redução de 84 mm reforça a tendência de menor demanda quando a semeadura ocorre mais tarde, acompanhada de uma leve mudança na distribuição dos componentes hídricos projetados para as décadas de 2070 a 2099 no cenário SSP5-8.5.

O comportamento do coeficiente de variação também fornece informações importantes para as condições de requerimento hídrico simuladas para o período de 2070 a 2099, sob cenário SSP58.5. Para a o componente verde, o CV, em 15 de outubro, foi de 2,7%, indicando uma distribuição mais uniforme entre os municípios, enquanto, em 10 de novembro, esse valor aumentou para 4,4%, sugerindo maior variabilidade. Já para a água azul, o CV é maior, com 23,5%, em 15 de outubro, e 21,0%, em 10 de novembro, evidenciando maior dispersão dos valores da demanda de irrigação.

As estimativas dos componentes de águas verde e azul, no cenário SSP5-8.5, para o período de 2070 a 2099, indicou que, para a data de semeadura de 15 de outubro, os municípios de Catalão e Cristalina apresentam os maiores aumentos na DHT, com valores de 356 mm e 345 mm, respectivamente. Em Catalão, 42% desse aumento poderá ser suprido pela água verde e 58% pela à água azul. Em Cristalina, a distribuição é semelhante, com 49% da DHT sendo suprida pela água verde e 51% pela água azul. Esses resultados indicam que, em comparação com os dados de referência, a demanda de água azul será maior e cada vez mais importante para a produção sustentável da cultura da soja no estado de Goiás. A crescente dependência de água azul em relação à água verde reflete uma diminuição na contribuição da precipitação efetiva, implicando que o manejo hídrico deve ser ajustado para compensar as flutuações na disponibilidade de água da chuva.


Para a data de semeadura em 10 de novembro, as estimativas para o cenário SSP5-8.5, no período de 2070 a 2099, indicaram que, em todas as localidades analisadas, o aumento da contribuição da água azul (irrigação) supera a da água verde (precipitação) em relação aos dados históricos. Os maiores aumentos na DHT foram observados nos municípios de Padre Bernardo (264 mm), Ipameri (346 mm) e

Bom Jesus (361 mm). Nessas localidades, a maior parte do aumento na DHT será suprida pela irrigação, representando 85%, 63% e 59% do total, respectivamente.

Esses resultados evidenciam uma crescente dependência da irrigação para suprir a demanda hídrica da soja no cenário projetado. Nos municípios analisados, a maior parte do incremento na DHT será atendida por água captada e fornecida via irrigação. A redução da disponibilidade de água verde e o aumento da participação da água azul indicam a importância de planejar e implementar estratégias de irrigação que possam compensar a redução de precipitação, assegurando a viabilidade da produção agrícola nas condições climáticas futuras previstas para o cenário SSP5-8.5.

Na Figura 16 apresentam-se as projeções dos aumentos da demanda hídrica total (DHT) para os 20 municípios, considerando os cenários climáticos SSP2-4.5 e SSP5-8.5 em dois períodos futuros (2040-2070 e 2070-2099). Os valores indicam o incremento na DHT em relação ao período histórico, refletindo nas alterações nas necessidades hídricas da cultura da soja devido às mudanças climáticas.

**Figura 16 - Aumento da demanda hídrica total (DHT) projetada para os diferentes períodos e cenários de semeadura da soja. SSP2-4.5: 2040-2070 em 15 de outubro (a) e 10 de novembro (b); 2070-2099 em 15 de outubro (c) e 10 de novembro (d); SSP5-8.5: 2040-2070 em 15 de outubro (e) e 10 de novembro (f); 2070-2099 em 15 de outubro (g) e 10 de novembro (h)**



Os resultados indicaram uma tendência de crescimento progressivo na DHT ao longo do tempo. No período de 2040-2070, observou-se um aumento médio de 19,7% na DHT para o cenário SSP2-4.5 em 15 de outubro, enquanto para 10 de novembro o crescimento médio foi de 22,5%. No período de 2070-2099, os valores foram ainda


mais expressivos, com acréscimos de 26,8% para 15 de outubro e 32% para 10 de novembro. Enquanto no cenário SSP5-8.5, os aumentos projetados para 2040-2070 foram de 36,4% em 15 de outubro e 43,7% em 10 de novembro. No período de 2070-2099, a intensificação da DHT foi ainda mais pronunciada, com incrementos médios de 73,3% para 15 de outubro e 66,8% para 10 de novembro, indicando um cenário futuro de demanda hídrica substancialmente maior.

A análise espacial evidenciou variações nos impactos da DHT entre os municípios. Em Cristalina, no Leste Goiano, os aumentos são expressivos em todos os cenários, com o menor acréscimo registrado para a semeadura em 10 de novembro no cenário SSP2-4.5 (2040-2070), atingindo 25,4%, enquanto o maior incremento ocorreu no cenário SSP5-8.5 (2070-2099), com um aumento de 92% em relação ao período histórico. Em contraste, Santa Helena, no Sudoeste de Goiás, apresenta variações mais modestas. O menor crescimento foi de apenas 3% para a semeadura em 15 de outubro no cenário SSP2-4.5 (2040-2070), enquanto o maior aumento, de 47%, ocorreu na mesma data de semeadura, porém no cenário SSP5-8.5 (2070-2099).

A Figura 17 ilustra a contribuição percentual média, considerando os vinte municípios com maior produção de soja no estado de Goiás, das águas verde e azul, utilizando os dados do NP para o período de referência (de 1988 a 2022), e para os períodos de 2040-2070 e 2070-2099, nos cenários SSP2-4.5 e SSP5-8.5. Durante o período de referência, observou-se que a água verde correspondia, em média, a 85% da DHT, na semeadura em outubro, e a 89%, em novembro. Nesse contexto, a água azul representou uma menor proporção em novembro (11%) em comparação com outubro (15%).

A água verde representa maior parte da DHT, contribuindo com 85% da DHT, na semeadura em outubro, e a 89%, em novembro ao considerar o período de referência. No entanto nos cenários futuros há uma tendência de redução dessa participação, especialmente no cenário mais crítico (SSP5-8.5), no qual a contribuição da água verde cai para 69 a 67% no final do século, aumentando consequentemente a dependência da água azul (Figura 17).

**Figura 17- Contribuições hídricas médias (%) provenientes da chuva (verde) e da irrigação (azul), para as semeaduras da soja em 15 de outubro e 10 de novembro, com base nos dados do NP para o período de referência (de 1988 a 2022) e para os períodos de 2040-2070 e 2070-2099, nos cenários SSP2-4.5 e SSP5-8.5**



Essas mudanças na composição da DHT podem estar relacionadas a ocorrência de extremos climáticos apresentados na Tabela 3. Observou-se um aumento do CDD nos cenários futuros, principalmente no cenário SSP5-8.5, indicando períodos secos mais prolongados. Somado a isso, há um aumento na intensidade das chuvas extremas (Rx1day e Rx5days), o que sugere eventos mais concentrados e menor infiltração de água no solo, reduzindo a disponibilidade de água verde para as culturas.

A redução do número de dias úmidos consecutivos (CWD) também indica uma menor regularidade das chuvas, o que pode comprometer a reposição hídrica do solo, impactando diretamente a água verde e elevando o requerimento de irrigação. Dessa forma, com a intensificação dos extremos climáticos, a dependência da água azul tende a crescer, elevando os desafios para a gestão de recursos hídricos na agricultura de Goiás.

**Tabela 3 - Índices médios de eventos extremos de precipitação, para os vinte municípios, para os períodos de semeaduras da soja em 15 de outubro e 10 de novembro, com base nos dados do NP para o período de referência (1988 a 2022) e para os períodos de 2040-2070 e 2070-2099, nos cenários SSP2-4.5 e SSP5-8.5**

|                                      | Data   | CDD<br>(dias) | CWD<br>(dias) | R25mm<br>(dias) | R50mm<br>(dias) | Rx1day<br>(mm) | Rx5days<br>(mm) |
|--------------------------------------|--------|---------------|---------------|-----------------|-----------------|----------------|-----------------|
| Período de referência<br>(1988-2022) | 15/out | 5,5           | 29,0          | 6,9             | 0,8             | 52,0           | 121,1           |
|                                      | 10/nov | 6,3           | 27,0          | 6,4             | 0,7             | 52,1           | 119,7           |
| SSP2-4.5<br>(2040-2070)              | 15/out | 14,5          | 26,5          | 7,3             | 1,1             | 55,7           | 135,0           |
|                                      | 10/nov | 11,7          | 27,7          | 8,4             | 1,3             | 57,2           | 140,8           |
| SSP2-4.5<br>(2070-2099)              | 15/out | 13,4          | 25,3          | 7,2             | 1,3             | 56,8           | 139,3           |
|                                      | 10/nov | 9,9           | 25,7          | 8,4             | 1,5             | 59,9           | 143,9           |
| SSP5-8.5<br>(2040-2070)              | 15/out | 17,3          | 25,6          | 6,8             | 1,1             | 55,5           | 134,7           |
|                                      | 10/nov | 13,5          | 26,8          | 8,0             | 1,3             | 57,3           | 140,0           |
| SSP5-8.5<br>(2070-2099)              | 15/out | 17,8          | 27,4          | 6,1             | 1,0             | 52,3           | 119,1           |
|                                      | 10/nov | 13,0          | 28,3          | 7,4             | 1,4             | 58,0           | 132,0           |

CDD = Número máximo, durante o ciclo da cultura, de dias consecutivos com menos de 1mm; CWD= Número máximo, durante o ciclo da cultura, de dias consecutivos com mais de 1mm; R25mm= Número de dias durante o ciclo da cultura com mais de 25mm/dia; R50 = Número de dias, durante o ciclo da cultura, com mais de 50mm/dia; Rx1day = Precipitação máxima diária durante o ciclo da cultura; Rx5days = Precipitação máxima durante cinco dias consecutivos durante o ciclo da cultura.

Analisando o cenário RCP4.5, para o período de 2070-2099, referente à data de semeadura em 15 de outubro, observa-se uma redução no CWD, passando de 27 dias no período de referência para 25,3 dias. Essa diminuição indica uma menor continuidade das precipitações, resultando em maior irregularidade na disponibilidade hídrica. Nesse contexto há um comprometimento do fornecimento de água verde no solo. Para a data de semeadura em 10 de novembro, no mesmo cenário, verifica-se um aumento no Rx1day, que passa de 52,0 mm no período referência para 59,9 mm, enquanto o índice de Rx5days cresce de 121,1 mm para 143,9 mm.

Essa maior concentração das chuvas em curtos intervalos temporais reduz a eficiência da infiltração no solo, favorecendo o escoamento superficial e limitando a possibilidade do aproveitamento da água verde, como observado no período de referência que apresenta índices de intensidade de chuva menos danosos. Esse padrão de distribuição pluviométrica menos uniforme pode impactar negativamente a disponibilidade hídrica para as culturas.

No cenário SSP5-8.5 (2040-2070) e semeadura realizada no dia 15 de outubro, o índice R25mm aumenta de 6,4 dias (período de referência) para 6,8 dias, enquanto o



índice R50mm aumenta de 0,7 dias para 1,1 dias. Isso mostra uma redução de chuvas regulares e aumento de eventos extremos, prejudicando a recarga gradual da umidade no solo e elevando a necessidade de água azul.

No cenário SSP5-8.5 (2070-2099) para o ciclo da cultura iniciado em 15 de outubro, o CDD médio aumenta de 6,3 (período de referência) para 17,8 dias indicando períodos de seca mais longos. Isso reduz o armazenamento da água no solo e a recarga hídrica natural, reduzindo assim a água verde disponível para a cultura da soja.


No cenário SSP5-8.5, para o período de 2070 a 2099, a contribuição da água verde sofreu uma redução acentuada, alcançando 69% para a semeadura em 15 de outubro e 67% para 10 de novembro. Diferentemente do período de referência, o adiamento da semeadura para novembro não resultou em maior contribuição da precipitação, mas sim em um aumento na necessidade de irrigação. Esse resultado pode estar relacionado ao aumento no índice Rx1day, que atinge 58 mm em novembro, sugerindo que a distribuição das chuvas durante o ciclo da cultura ocorre de forma concentrada, dificultando a infiltração e o armazenamento no solo. Como consequência, tem-se que a necessidade de água azul se eleva para 31% em outubro e 33% em novembro, o que torna a irrigação uma estratégia imperativa para garantir bons níveis de produtividade diante de tal cenário.

A diminuição da contribuição da água verde, associada ao adiamento da semeadura, indica uma crescente dependência da irrigação em cenários com menor disponibilidade hídrica, como previsto no SSP5-8.5. O aumento dos eventos extremos de precipitação e a maior variabilidade climática evidenciam a necessidade de ajustes nas práticas de manejo agrícola, incluindo estratégias para retenção de água no solo e uso eficiente da irrigação, a fim de mitigar os impactos das mudanças climáticas sobre a produção.

#### **4.5 Modelagem da produtividade atual e futura da cultura da soja**

A Figura 18 apresenta a penalização da produtividade da soja causada pelo déficit hídrico considerando uma frequência de excedência de 20% para diferentes datas de semeaduras. Os dados foram obtidos para os cenários climáticos SSP2-4.5 e SSP5-8.5, projetados para o período futuro de 2040 a 2099, em comparação com o período de referência histórico (1988-2022).

**Figura 18 - 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 SSP2-4.5 períodos 2040-2070, Figuras (c) e (d), e 2070-2099, Figuras (e) e (f); cenário SSP5-8.5 períodos 2040-2070, Figuras (g) e (h), e 2070-2099, Figuras (i) e (j)**



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 SSP2-4.5 (2040-2070) e 34,5% menor para o mesmo cenário no período de 2070 a 2099. No

cenário SSP5-8.5, a redução foi ainda mais acentuada, sendo 57,6% inferior no período de 2040 a 2070 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 de produtividade da semeadura em 15 de outubro nos cenários futuros de mudança climática, especialmente sob condições mais extremas (SSP5-8.5).

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 SSP2-4.5 no intervalo de 2040 a 2070, e 57% menores quando comparados ao período de 2070 a 2099. No cenário SSP5-8.5, essa diferença tornou-se ainda mais expressiva, com a Qp sendo 66,7% menor entre 2040 e 2070 e atingindo uma redução de 80% no período de 2070 a 2099 quando comparados a quebra de produtividade do período de 1988 a 2022.

Para o período de referência, os menores valores de Qp, foram nas datas de semeadura de 15 de outubro (6,9%) e 10 de novembro (4,1%), ambas foram observadas no município de Montividiu. Os maiores valores foram observados em Padre Bernardo, com plantio em 15/out (15,38%), e 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 2040-2070, a penalização para várias localidades ultrapassa 15%, como em Cristalina (15,6% em 15/out) e Goiatuba (16,6% em 15/out). Os valores são ligeiramente menores em novembro, que reduziram para 14,6% em Cristalina e 15,1% para Goiatuba.

Observou-se um aumento da penalização ao longo do tempo, com valores maiores projetados para o cenário SSP5-8.5. Para muitos municípios, as penalizações no período 2070–2099 mais que dobraram em relação ao período 2040–2070. Em Luziânia, a penalização aumentou de 24,3% (2040–2070) para 66,4% (2070–2099), na data de plantio de 10 de novembro, representando mais que o 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 significativo.

É importante destacar que municípios que tradicionalmente apresentam alta produtividade, como Silvânia e Niquelândia, podem enfrentar desafios mais

acentuados no período 2070–2099, com penalizações de 56,1% (Silvânia, 15/out) e 52,8% (Niquelândia, 10/nov) considerando o cenário SSP5-8.5. Isso demonstra que mesmo regiões com melhor histórico agrícola também estão muito vulneráveis às mudanças climáticas mais extremas.

No período 2040–2070, 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 um pouco menores, visto que a média da Qp para este período no cenário SSP2-4.5 é de 14,2% em outubro e 12,1% em novembro, portanto uma diferença de 2,1%. No cenário SSP5-8.5 também é observada essa dinâmica visto que em média a Qp em outubro foi 26,1% e em novembro 25,4%, uma redução pequena de 0,7%.

Entretanto, ao avaliar as datas de semeadura para o período 2070-2099, ambos os cenários demonstraram que a data de semeadura em novembro culmina em perdas mais expressivas. A média da Qp no cenário SSP2-4.5 em 15 de outubro é de 16,9% contra 19,6% em novembro. No cenário SSP5-8.5 a Qp para semeadura em outubro é 31,5% enquanto em novembro é de 41,1%.

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


Aparecido *et al.* (2021) desenvolveram um modelo 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 quebra de produtividade pelo déficit hídrico da soja é o aumento da profundidade do perfil do solo, uma prática que poderia resultar em incrementos de produtividade de até 2.500 kg/ha, dependendo das condições locais.

Na Figura 19 apresenta-se o desempenho do modelo calibrado para a estimativa da produtividade média da soja ( $\text{kg ha}^{-1}$ ) a partir de dados observados pelo IBGE nos 20 municípios com maior produtividade no estado de Goiás. A relação entre as duas

variáveis apresentou um coeficiente de determinação ( $R^2$ ) de 0,99, indicando uma forte aderência entre os valores estimados e observados.

**Figura 19 - Desempenho do modelo calibrado de estimativa de produtividade média da soja ( $\text{kg ha}^{-1}$ ) nos 20 municípios com maior produtividade de soja em Goiás**



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

As estatísticas apresentadas na Tabela 4 indicam o desempenho do modelo de previsão da produtividade de soja, em escala municipal, para os principais municípios produtores desse grão no estado de Goiás. Pode-se observar nessa Tabela que o modelo simulou adequadamente a produtividade da soja em todos os municípios, com  $R^2$  maior 0,84.

**Tabela 4 - Desempenho do modelo calibrado de estimativa de produtividade da soja ( $\text{kg ha}^{-1}$ ) em municípios de Goiás**

| Município       | R <sup>2</sup> | MAE    | RMSE   | MBE     | d    |
|-----------------|----------------|--------|--------|---------|------|
| Acreúna         | 0,95*          | 267,50 | 268,48 | 267,50  | 0,91 |
| Bom Jesus       | 0,97*          | 13,32  | 14,46  | -13,32  | 0,97 |
| Caiapônia       | 0,91*          | 239,60 | 240,10 | 239,60  | 0,90 |
| Campo Alegre    | 0,92*          | 68,90  | 80,64  | -67,50  | 0,92 |
| Catalão         | 0,97*          | 64,76  | 68,75  | -64,76  | 0,98 |
| Chapadão do Céu | 0,96*          | 65,12  | 65,14  | 65,12   | 0,98 |
| Cristalina      | 0,93*          | 81,27  | 85,20  | -81,27  | 0,98 |
| Goiatuba        | 0,96*          | 67,90  | 72,13  | -67,90  | 0,91 |
| Ipameri         | 0,97*          | 90,44  | 90,69  | 90,44   | 0,98 |
| Jataí           | 0,85*          | 121,55 | 137,51 | -118,36 | 0,96 |
| Luziânia        | 0,99*          | 126,35 | 126,56 | 126,35  | 0,95 |
| Mineiros        | 0,87*          | 98,95  | 100,50 | 98,95   | 0,96 |
| Montividiu      | 0,97*          | 98,15  | 98,15  | -98,15  | 0,98 |
| Niquelândia     | 0,97*          | 11,86  | 12,06  | -11,86  | 0,95 |
| Padre Bernardo  | 0,94*          | 94,58  | 113,67 | -94,58  | 0,98 |
| Paraúna         | 0,91*          | 80,36  | 80,42  | -80,36  | 0,94 |
| Piracanjuba     | 0,93*          | 52,13  | 59,32  | 47,87   | 0,93 |
| Rio Verde       | 0,93*          | 41,73  | 48,95  | 23,97   | 0,97 |
| Santa Helena    | 0,97*          | 77,39  | 82,64  | -64,71  | 0,94 |
| Silvânia        | 0,84*          | 22,70  | 35,98  | -18,52  | 0,92 |

\*significativo a 5% de probabilidade pelo teste T.

Os valores de erro médio de viés (MBE) apontaram para uma subestimativa na maioria das localidades analisadas (60%), com destaque para os municípios de Jataí ( $-118,36 \text{ kg ha}^{-1}$ ) e Montividiu ( $-98,15 \text{ kg ha}^{-1}$ ), onde os valores de viés foram mais pronunciados.

Os maiores valores de erro absoluto foram registrados em Acreúna ( $\text{MAE}=267 \text{ kg ha}^{-1}$ ), seguido por Caiapônia ( $\text{MAE}=239,60 \text{ kg ha}^{-1}$ ) e Luziânia ( $\text{MAE}=126,35 \text{ kg ha}^{-1}$ ), indicando discrepâncias mais acentuadas entre os valores previstos e observados. Os menores erros absolutos ocorreram em Niquelândia ( $\text{MAE}=11,86$ ), seguido por Bom Jesus ( $\text{MAE}=13,32 \text{ kg ha}^{-1}$ ), evidenciando um excelente desempenho do modelo nesses municípios.


O RMSE, por sua vez, apresentou uma tendência similar ao MAE, com os maiores valores em Acreúna ( $\text{RMSE}=268,48$ ) e os menores em Niquelândia ( $\text{RMSE}=12,06$ ). 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 encontrado.

Silva *et al.* (2020) aplicaram a mesma metodologia para estimar a produtividade do algodão em municípios do Nordeste brasileiro, obtendo erros de estimativa que variaram de 15 a 582 kg ha<sup>-1</sup>. Segundo os autores, os maiores desvios podem ser atribuídos a fatores que não são contemplados pelo modelo, tais como surtos de pragas e doenças, uso de diferentes genótipos e mudanças nas práticas de manejo e 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 ao serem comparados com os dados oficiais disponibilizados pelo IBGE.

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 20). A quebra de produtividade (Qp%) é conceituada como a diferença relativa entre produtividade potencial tecnológica e a produtividade observada (dados do IBGE).

**Figura 20 - Produtividades potencial tecnológica média, Produtividades médias observadas (IBGE) e produtividades médias estimadas pelo modelo, para o período de 2015 a 2022**



CP= Caiapônia; NI=Niquelândia; AC= Acreúna; GO= Goiatuba; 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= Cristalina; JA= Jataí; RV= Rio Verde.

Entre os municípios analisados, os valores de produtividade média observada variaram entre 3.066,2 kg ha<sup>-1</sup> (Niquelândia) e 3.647,8 kg ha<sup>-1</sup> (Luziânia), indicando uma diferença de cerca de 19% no desempenho produtivo entre os municípios com maior e menor média de produtividade real de soja.

A quebra de produtividade apresentou uma variação entre os municípios analisados, oscilando entre valores próximos a 0,11% e máximos a 12%. O menor impacto de perdas foi registrado em municípios onde a produtividade observada esteve muito próxima produtividade potencial tecnológica, como por exemplo em Jataí que apresentou produtividade potencial tecnológica de 3516,3 kg ha<sup>-1</sup> e produtividade real de 3512,5 kg ha<sup>-1</sup>.

As maiores quebras ocorreram em localidades onde a produtividade observada ficou significativamente abaixo da produtividade potencial, indicando que o déficit hídrico médio durante o período analisado resultou em um impacto maior no rendimento da soja. Por exemplo, em Acreúna que apresentou Qp de 12%, sendo observada a produtividade potencial de 3740,6 kg ha<sup>-1</sup> contra a produtividade real de 3295,1 kg ha<sup>-1</sup>.

De acordo com Monteiro *et al.* (2017), ao avaliar 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 ajustes adequados não são realizados. Esses autores enfatizaram que a calibração do modelo em escala municipal apresentou desempenho superior quando comparada às escalas regional e nacional, evidenciando maior precisão na representação das condições locais.



## 5 CONCLUSÕES

Estimativas mais confiáveis de evapotranspiração de referência e precipitação foram fornecidas pela reanálise Nasa Power quando comparada as estimativas da reanálise Era5-Land para a área estudada.

Os dados oriundos de reanálises climáticas podem ajudar a superar a carência de dados meteorológicos medidos em superfície, entretanto é necessária a prévia validação e correção desses dados.

Os cenários climáticos projetados para os períodos de 2040-2070 e 2070-2099 indicam uma diminuição na contribuição da água verde para a demanda hídrica da soja em Goiás, especialmente sob o cenário SSP5-8.5, que prevê menores volumes de precipitação. Enquanto a água verde representa, em média, 85% da DHT no período de referência, essa proporção cai para cerca de 75-80% nos cenários futuros, aumentando a dependência da irrigação.

As mudanças climáticas projetadas para os cenários SSP2-4.5 e SSP5-8.5 têm potencial de impactar a produtividade da soja no estado de Goiás, especialmente devido ao aumento do déficit hídrico. O modelo agrometeorológico utilizado mostrou-se eficaz para estimar a produtividade da soja em escala municipal, 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 SSP5-8.5 no período de 2070-2099, onde foram observadas perdas superiores a 50% em diversos municípios, como Luziânia e Silvânia. Além disso, as datas de plantio, que atualmente permitem certo grau de mitigação, tornam-se menos relevantes em cenários futuros devido à intensificação dos eventos extremos, como alterações nos padrões de precipitação.

## REFERÊNCIAS

- ABRO, M. I. Statistical and qualitative evaluation of multi-sources for hydrological suitability inflood-prone areas of Pakistan. **Journal of Hydrology**, Amsterdam, v. 588, n. 4, p. 125-117, 2020.
- ALMAGRO, A.; OLIVEIRA, P. T. S.; ROSOLEM, R.; HAGEMANN, S.; NOBRE, C. A. Performance evaluation of Eta/HadGEM2-ES and Eta/MIROC5 precipitation simulations over Brazil. **Atmospheric Research**, [s. l.], v. 244, p. 105-115, 2020.
- ALLEN, R. G.; TASUMI, M.; TREZZA, R. Satellite-Based Energy Balance for Mapping Evapotranspiration with Internalized Calibration (METRIC)- Model. **Journal of Irrigation and Drainage Engineering**, Reston, v. 133, n. 4, p. 380-394, 2007.
- ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. **Crop evapotranspiration: Guidelines for computing crop water requirements** FAO Irrigation and Drainage Paper 56. Roma: FAO, 1998. 300 p.
- ALTHOFF, D.; DIAS, S. H. B.; FILGUEIRAS, R.; RODRIGUES, L. N. ETo-Brazil: A Daily Gridded Reference Evapotranspiration Data Set for Brazil (2000–2018). **Water Resources Research**, [s. l.], v. 56, n. 7, p.1-16, 2020.
- ALTHOFF, D.; RODRIGUES, L. N.; SANO, E. E.; BETTIOL, G. M. O. O clima do Cerrado. In: RODRIGUES, L. N. (org.). **Agricultura irrigada no Cerrado: subsídios para o desenvolvimento sustentável**. 2. ed. rev. e ampl. Brasília, DF: Embrapa, 2024. p. 156-183.
- ALTHOFF, D.; RODRIGUES, L.N.; SILVA, D.D. Assessment of water availability vulnerability in the Cerrado. **Applied Water Science**, [s. l.], v.11, n.176, p. 1-14, 2021.
- ALTHOFF, D.; RODRIGUES, L. N. The expansion of center-pivot irrigation in the cerrado biome. **IRRIGA**, Botucatu, v. 1, n.1, p. 56-61, 2019.
- ANDRADE, R. G.; TEIXEIRA, A. H. C.; LEIVAS, J. F.; NOGUEIRA, S. F.; SILVA, G. B. S.; VICTORIA, D. C.; FACCO, A. G. Estimativa da evapotranspiração e da biomassa de pastagens utilizando o algoritmo SAFER e imagens MODIS. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2015, João Pessoa-PB. **Anais...** João Pessoa, PB: INPE, 2015, p. 3664-3670.
- ANA; IBGE - Agência Nacional de Águas, Instituto Brasileiro de Geografia e Estatística. **Uso da água na agricultura de sequeiro no Brasil (2013-2017)**. Brasília: ANA; IBGE, 2020. 63 p.
- APARECIDO, L. E. O.; TORSONI, G. B.; MESQUITA, D. Z.; MENESES, K. C.; MORAES, J. R. S. C. Modelagem da produtividade do milho safrinha em função das condições climáticas do Mato Grosso do Sul. **Revista Brasileira de Climatologia**, [s. l.], n. 16, v. 26, p. 155- 174, 2020.

APARECIDO, L.E.O.; TORSONI, G.B.; SILVA, C. M. R.; MENESES K.C.; 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**, [s. l.], v.12, n. 23, p. 5151–5164, 2021.

APARECIDO, L.E.O.; ROLIM, G.S.; DE MORAES, J.R.S.C.; TORSONI, G.B.; DE MENESES, K.C.; COSTA, C.T.S. Acurácia da reanálise ERA-Interim do ECMWF e sua aplicação na estimativa da deficiência hídrica no estado do Paraná, Brasil. **Revista Brasileira de Meteorologia**, [s. l.], v. 34, n. 4, p. 515-528, 2019.

ARORA, V. K. The Canadian Earth System Model version 2 (CanESM2): Model description and evaluation. **Geoscientific Model Development**, [s. l.], v, 5, n. 1, p. 1053-1078, 2012.

ALVES, E. S.; RODRIGUES, L. N.; OLIVEIRA, R. A.; 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**, Campina Grande, v. 25, n.11, p.750-757, 2021.

BARIVIERA, G. Dual crop coefficient for the early-cycle soybean cultivar SoyTech 815 RR. *Revista Brasileira de Engenharia Agrícola e Ambiental*, Campina Grande, v. 24, n. 2, p. 75–81, 2020.

BASTIAANSEN, W. G. M.; PELGRUMA, H.; WANG, J.; MA, Y.; MORENO, J. F.; ROERINKA, G. J.; WALA, T. V. A remote sensing surface energy balance algorithm for land (SEBAL): 1. **Journal of Hydrology**, Amsterdam, v. 212, n. 1-4, p. 198-212, 1998.

BASTOS, E. A.; ANDRADE JÚNIOR, A. S.; SILVA, C. R.; DEL AGUILA, R. M.; CAMPECHE, L. F. M. S.; SOUZA, C. F. Coeficiente de cultivo da soja no Vale do Gurgueia, PI. In: CONGRESSO BRASILEIRO DE AGROMETEOROLOGIA, 15., 2007, Aracaju. **Anais** [...]. Aracaju: [s.n.], 2007, p. 16-29..

BATTISTI, R.; SENTELHAS, P. C.; PASCOALINO, J. A. L.; SAKO, H.; DANTAS, J. P. S.; MORAES, M. F. Soybean yield gap in the areas of yield contest in Brazil. **International Journal of Plant Production**, v. 12, [s. l.], n. 3, p. 159–168, 2018.

BECK, H. E. Daily evaluation of 26 precipitation datasets using Stage-IV gauge-radar data for CONUS. **Hydrology and Earth System Sciences**, Göttingen, v. 23, n. 2, p. 207–224, 2018.

BIER, A. A.; FERRAZ, S. E. T. Comparação de Metodologias de Preenchimento de Falhas em Dados Meteorológicos para Estações no Sul do Brasil. **Revista Brasileira de Meteorologia**, [s. l.], v. 32, n. 2, 215-226, 2017.

BLACUTT, L. A.; HERDIES, D. L.; GONÇALVES, L. G. G.; VILA, D.; ANDRADE, A. M. Precipitation comparison for the CFSR, MERRA, TRMM3B42 and Combined Scheme datasets in Bolivia, **Atmospheric Research**, [s. l.], v. 163, n.12, p. 117-131, 2015.

BOLFE, É. L.; SANO, E. E.; CAMPOS, S. K. (eds.). **Dinâmica agrícola no Cerrado: análises e projeções**. Brasília: Embrapa, 2020. v. 1, 308 p. ISBN 978-85-7035-951-3.

BRAGA, R. A. H. W.; SANTOS, E. B.; BARROS, M. F, BASTOS, J. L. Validação de dados de vento da reanálise ERA5-LAND para estimativa de potencial eólico no Estado do Rio de Janeiro. **Revista Brasileira de Energia**, [s. l.], v. 27, n. 4, p. 142-166, 2021.

CAETANO, L. R.; SILVA, S. M. C.; MORAES, M. J.; MELO, F. R.; OLIVEIRA, A. L. R.; FIGUEIRÓ, L. S. P.; SANTOS, L. C. Influência do veranico na demanda hídrica da soja cultivada em três safras no Centro Oeste brasileiro. **Peer Review**, [s. l.], v. 5, n. 24, p. 363–379, 2023.

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**, Boa Vista, v.8, n.16, p.40-55, 2014.

CHIARELLI, D.D.; PASSERA, C.; ROSA L.; DAVIS, K.F.; RULLI, M.C. The green and blue crop water requirement WATNEEDS model and its global gridded outputs. **Scientific Data**, [s. l.], v1, n. 7, p1-14, 2020.

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. and 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, 2014a.

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. and MARENGO, J. Assessment of Climate Change over South America under RCP 4.5 and 8.5 Downscaling Scenarios. **American Journal of Climate Change**, Boston, v. 3, n. 1, p. 512- 527, 2014b.

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.

COLLINS, M. The HadGEM2 family of models for climate change projections. **Geoscientific Model Development**, [s. l.], v, 4, p. 1029-1054, 2011.

DENMEAD, O. T.; SHAW, R. H. Availability of Soil Water to Plants as Affected by Soil Moisture Content and Meteorological Conditions. **Agronomy jornal**, [s. l.], v. 54, n.1, p. 385-390, 1962.

DEY. A.; REMESAN, R. Multimodel quantification of green and blue water components and its error propagations through parameter transferability approach across input choices, **Journal of Hydrology**, Amsterdam, v.607, n. 12, p. 1-13, 2022.

DIAS, A. S.; SOARES, W. A. Uso de metodologias de preenchimento de falhas para estimativas de dados de precipitação. **Research, Society and Development**, Brasília, v. 10, n. 5, p. 1-11, 2021.

DIAS, E. B.; SENTELHAS, P. C. Sugarcane yield gap analysis in Brazil – A multi-model approach for determining magnitudes and causes. **Science of The Total Environment**, Amsterdam, v. 637-638, p. 1127-1136, 2018.

DIOGO, A. M. **Análise da distribuição espacial da fenologia de vegetação, precipitação e evapotranspiração, com base em imagens de sensoriamento remoto orbital em Angola**. 2020. Dissertação (mestrado em Sensoriamento Remoto) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2020.

DIAZ, C. C. F.; PEREIRA, J. A. S.; NÓBREGA, R. S.; ARAUJO, M. N. Comparação de dados estimados por dois diferentes métodos para o preenchimento de falhas de precipitação pluvial na bacia do rio Pajeú, Pernambuco, Brasil. **Revista Brasileira de Climatologia**, [s. l.], v. 22, n. 14, p. 324 - 339, 2018.

DOOREMBOS, J.; PRUITT, W. O. **Crop water requirements**. Rome: FAO, 1977. 144 p. (FAO Irrigation and Drainage Paper, 24).

DOURADO NETO, D.; COUTINHO, P. A. Q.; BARRETTO, A. P.; ARAUJO, M. A. E.; FENDRICH, A. N.; SAFANELLI, J. L.; MAULE, R. F.; SBITKOWSKI, A. L.; FONTENELLE, T. H.; BELÉM, F. C. Potencial da adoção da agricultura irrigada no Brasil. In: PAOLINELLI, A.; DOURADO NETO, D.; MANTOVANI, E. C. (org.). **Agricultura irrigada no Brasil: políticas públicas**. Piracicaba: ESALQ; Viçosa: ABID, 2022. p. 209 : il. DOI:10.11606/9786587391212. Disponível em: <https://doi.org/10.11606/9786587391212>. Acesso em: 12 fev. 2024.

EDREIRA, JIR, MOURTZINIS, S., CONLEY, SP, ROTH, AC, CIAMPITTI, IA, LICHT, M.A. Avaliação das causas de lacunas de produtividade em áreas agrícolas com diversidade de clima e solos. **Agricultural and Forest Meteorology**, [s. l.], v.247, n. 1, p. 170–180, 2017.

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, 17 p.

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária. **Necessidade hídrica da Soja**. 2021. Disponível em:< <https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/soja/pre-producao/caracteristicas-da-especie-e-relacoes-com-o-ambiente/exigenciasclimaticas/agua#:~:text=A%20necessidade%20total%20de%20%C3%A1gua,da%20dura%C3%A7%C3%A3o%20do%20seu%20ciclo.>> Acesso em abril 2024.

EVANGELISTA, B. A.; SILVA, F. A. M.; SIMON, J.; CAMPOS, L. J. M.; VALE, T. M. **Zoneamento de risco climático para determinação de épocas de semeadura da cultura da soja na região MATOPIBA**. Palmas, TO: Embrapa Pesca e Aquicultura, 2017.

EVANS, L. T.; FISCHER, R. A. Yield potential: its definition, measurement and significance. **Crop Science**, [s. l.], v. 39, n. 1, p. 1544–1551, 1999.

FALKENMARK, M. **Coping with water scarcity under rapid population growth**. Conferência dos Ministros da SADC; Pretoria, África do Sul, 1995.

FARIAS, D. B. S.; RODRIGUES, L. N.; ALEMAN, C. C.; CECON, P. R. Estimation of soybean crop water deficit sensitivity index. **Scientia Agricola**, [s. l.], v.81, n.2, p. 1-8, 2024.

FUNK, C.; PETERSON, P.; LANDSFELD, M.; PEDREROS, D.; VERDIN, J.; SHUKLA, S.; HUSAK, G.; ROWLAND, J.; HARRISON, L.; HOELL, A.; MICHAELSEN, J. The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. **Science Data**, [s. l.], v. 2, n.1, p.1-21, 2015.

FRANÇA, A. C. F.; COELHO, R. D.; GUNDIM, A. S.; COSTA, J. O.; QUILOANGO-CHIMARRO, C. A. Effects of different irrigation scheduling methods on physiology, yield, and irrigation water productivity of soybean varieties. **Agricultural Water Management**, [s. l.], v. 293, n. 10, p. 1-10, 2024.

FAO; DWFI. **Yield gap analysis of field crops – Methods and case studies**. Roma: FAO, 2015. (FAO Water Reports, n. 41). 82 p.

GIOVANELLA, T. H.; OLIVEIRA, F. C.; MARCHI, V. A. A.; TLUSZCZ, J. Desempenho de Métodos de Preenchimento de Falhas em Dados de Evapotranspiração de Referência para Região Oeste do Paraná. **Revista Brasileira de Meteorologia**, [s. l.], v. 36, n. 3, p.415-422, 2021.

GELARO, R. The modern-era retrospective analysis for research and applications, version 2 (MERRA-2). **Journal of Climate**, Boston, v. 30, n. 14, p. 5419–5454, 2017.

GOIÁS. Conselho Estadual de Recursos Hídricos. **Legislação de Recursos Hídricos do Estado de Goiás**. 1. ed. Goiânia: Secretaria do Meio Ambiente e Recursos Hídricos, 2012. 314 p.

CEBOLLA, J.; RATTAYOVA, V.; SALAZAR-GALÁN, S.; FRANCÉS, F. Evaluation of ERA5 and ERA5-Land reanalysis precipitation datasets over Spain (1951–2020). **Atmospheric Research**, [s. l.], v. 284, n. 10, p. 1-18, 2023.

GRUBER, K.; REGNER, P.; WEHRLE, S.; ZEYRINGER, M.; SCHMIDT, J. Towards global validation of wind power simulations: A multi-country assessment of wind power simulation from MERRA-2 and ERA-5 reanalyses bias-corrected with the global wind atlas, **Energy**, [s. l.], v. 238, n.12, p.1-11, 2022.

GUPTA, H. V. Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. **Journal of Hydrology**, Amsterdam, v. 377, n. 1–2, p. 80–91, 2009.

HARGREAVES, G. H. Estimation of potential and crop evapotranspiration. **Transactions of the ASAE**, St. Joseph, v. 17, n. 4, p. 701-704, 1974.

HERSBACH, H.; PEUBEY, C.; SIMMONS, A.; BERRISFORD, P.; POLI, P.; DEE, D. ERA-20CM: a twentieth-century atmospheric model ensemble. **Quarterly Journal of the Royal Meteorological Society**, Chichester, v. 141, n. 691 p. 2350–2375, 2015.

HERSBACH, H.; BELL, B.; BERRISFORD, P.; HIRAHARA, S.; HORÁNYI, A.; MUÑOZ-SABATER, J.; NICOLAS, J.; PEUBEY, C.; RADIUS, R.; SCHEPERS, D.; SIMMONS, A.; SUSI, M.; TOBIN, I.; TOVO-NIETO, R.; ULLRICH, R.; BUONTEMPO, C.; THÉPAUT, J.-N.; DEE, D. The ERA5 global reanalysis. **Quarterly Journal of the Royal Meteorological Society**, Chichester, v. 146, n. 730, p. 1999–2049, 2020.

HOEKSTRA, A. Y.; CHAPAGAIN, A. K.; ALDAYA, M. M.; MEKONNEN, M. M. **Manual de avaliação da pegada hídrica: estabelecendo o padrão global**. Londres: Earthscan, 2011.

HOSONO, A.; HONGO, Y. Desenvolvimento da agricultura do Cerrado: o caminho para se tornar um importante celeiro global. In: HOSONO, A.; ROCHA, C. M. C.; HONGO, Y. (eds.). **Development for Sustainable Agriculture**. Londres: Palgrave Macmillan, 2016. p.14-25.

HUANG, Z.; TAN, X.; WU, X.; TAN, X.; FU, J.; LIU, B. Long-term changes, synoptic behaviors, and future projections of large-scale anomalous precipitation events in China detected by a deep learning autoencoder, **Journal of Climate**, Boston, v. 36, n.12, p. 4133-4149, 2023.

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. 2023.

IMB – Instituto Mauro Borges de Estatísticas e Estudos Socioeconômicos. **Goiás em dados 2022**. Goiânia: IMB, 2022. Disponível em: [https://www.imb.go.gov.br/index.php?option=com\\_content&view=article&id=2361:goias-em-dados-2022&catid=19&Itemid=151](https://www.imb.go.gov.br/index.php?option=com_content&view=article&id=2361:goias-em-dados-2022&catid=19&Itemid=151). Acesso em: out. 2022.

IPCC – Intergovernmental Panel on Climate Change. **Climate Change 2013: The Physical Science Basis**. Contribution of Working Group I to the Fifth Assessment Report of the IPCC. Cambridge: Cambridge University Press, 2013.

IPCC – Intergovernmental Panel on Climate Change. **Summary for Policymakers**. In: **Climate Change 2021: The Physical Science Basis**. Contribution of Working Group I to the Sixth Assessment Report of the IPCC. Masson-Delmotte, V. (eds.). Cambridge: Cambridge University Press, 2021. p. 3-32.

JIANG, D.; WANG, K. The role of satellite-based remote sensing in improving simulated streamflow: A review. **Water**, Basel, v. 11, n. 8, p. 10–14, 2019.

JIAO, D., XU, N., YANG, F.; XU, K. Evaluation of spatial-temporal variation performance of ERA5 precipitation data in China. **Scientific Reports**, London, v. 11, n. 17956, p. 1–13, 2021.

JIMÉNEZ-JIMÉNEZ, S. I.; OJEDA-BUSTAMANTE, W.; INZUNZAIBARRA, M. A. & MARCIAL-PABLO, M. J. Analysis of the NASA-POWER system for estimating reference evapotranspiration in the Comarca Lagunera, Mexico. **Ingeniería Agrícola y Biosistemas**, Cidade do México, v. 13, n. 2, p. 201–226, 2021.

KAWAMIYA, M. The development of the BESM (Biwako Environmental Simulation Model) and its applications to climate studies. **Journal of the Meteorological Society of Japan**, Tóquio, v. 81, p. 121–148, 2003.

KOBAYASHI, S. The JRA-55 reanalysis: General specifications and basic characteristics. **Journal of the Meteorological Society of Japan**, Tóquio, v. 93, n. 1, p. 5–48, 2015.

LEANDER, R., BUIHAND, T.A., VAN DEN HURK, B.J.J.M., DE WIT, M.J.M. Estimated changes in flood quantiles of the river Meuse from resampling of regional climate model output. **Journal of Hydrology**, Amsterdam, v. 351, n. 4, p. 331–343, 2008.

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**, Göttingen, v. 11, n. 3, p. 1145–1159, 2007.

LI, X. H. Suitability of the TRMM satellite rainfalls in driving a distributed hydrological model for water balance computations in Xinjiang catchment, Poyang lake basin. **Journal of Hydrology**, Amsterdam, v. 426–427, p. 28–38, 2012.

LIU, Z. Comparison of precipitation estimates between version 7 3-hourly TRMM Multi-satellite Precipitation Analysis (TMPA) near-real-time and research products. **Atmospheric Research**, [s. l.], v. 53, n. 1, 2015.

LONGO-MINNOLO, G.; VANELLA, D.; CONSOLI, S.; PAPPALARDO, S.; RAMÍREZ-CUESTA, J. M. Assessing the use of ERA5-Land reanalysis and spatial interpolation methods for retrieving precipitation estimates at basin scale, **Atmospheric Research**, [s. l.], v. 271, n.10, p. 1-13, 2022.

NASCIMENTO, D. T. F.; OLIVEIRA, I. J. Aplicação das estimativas de precipitação do Tropical Rainfall Measuring Mission (TRMM) no estudo da pluviometria habitual e excepcional de Goiás e Distrito Federal. **Revista Brasileira de Geografia Física**, Recife, v.11, n.05, p. 1664-1679, 2018.

NASH, J. E.; SUTCLIFFE, J. V. River flow forecasting through conceptual models part I – A discussion of principles. **Journal of Hydrology**, Amsterdam, v. 10, n. 3, p. 282–290, 1970.



NEGM, A.; JABRO, J. PROVENZANO, G. Assessing the suitability of American National Aeronautics and Space Administration (NASA) agro-climatology archive to predict daily meteorological variables and reference evapotranspiration in Sicily, Italy, **Agricultural and Forest Meteorology**, [s. l.], v.244–245, n. 5, p. 111-121, 2017.

NOVAIS, G. T. Classificação climática aplicada ao Estado de Goiás e ao Distrito Federal, Brasil. **Boletim Goiano de Geografia**, Goiânia, v. 40, n. 1, p. 1–29, 2020.

MAKKINK, G. F. Ekzamento de la formulo de Penman. **Netherlands Journal of Agricultural Science**, Wageningen, v. 5, n.1, p. 290-305, 1957.

MALDONADO JUNIOR, W.; VALERIANO, T. T. B.; ROLIM, G. S. EVAPO: A smartphone application to estimate potential evapotranspiration using cloud gridded meteorological data from NASA-POWER system. **Computers and electronics in agriculture**, [s. l.], v. 156, n. 1, p. 187-192, 2019.

MARCIAL-PABLO, M.D.J.; ONTIVEROS-CAPURATA, R.E.; JIMÉNEZ-JIMÉNEZ, S.I.; OJEDA-BUSTAMANTE, W. Maize Crop Coefficient Estimation Based on Spectral Vegetation Indices and Vegetation Cover Fraction Derived from UAV-Based Multispectral Images. **Agronomy**, Basel, v. 11, n. 1, p. 2–19, 2021.

MAPA - Ministério da Agricultura e Pecuária. **PORTARIA SDA/MAPA Nº 886, DE 12 DE SETEMBRO DE 2023**. Calendários de semeadura de soja safra. Brasília: Ministerio da Agricultura e Pecuária, 22 set. 2023. Disponível em: [https://www.gov.br/agricultura/ptbr/assuntos/sanidadeanimalavegetal/sanidadevegetal/PORTARIA\\_SDA\\_MAPA\\_N\\_886\\_DE\\_12\\_DE\\_SETEMBRO\\_DE\\_2023\\_\\_PORTARIA\\_SDA\\_MAPA\\_N\\_886\\_DE\\_12\\_DE\\_SETEMBRO\\_DE\\_2023\\_\\_DOU\\_\\_Imprensa\\_Nacional.pdf](https://www.gov.br/agricultura/ptbr/assuntos/sanidadeanimalavegetal/sanidadevegetal/PORTARIA_SDA_MAPA_N_886_DE_12_DE_SETEMBRO_DE_2023__PORTARIA_SDA_MAPA_N_886_DE_12_DE_SETEMBRO_DE_2023__DOU__Imprensa_Nacional.pdf). Acesso em: 05 maio, 2024.

MARÍN, P. J.A.; RENDÓN, A.M.; SALAZAR, J.F. STUART, M. J. WRF downscaling improves ERA-Interim representation of precipitation around a tropical Andean valley during El Niño: implications for GCM-scale simulation of precipitation over complex terrain. **Climate Dynamics**, Heidelberg, v. 52, n. 10, p. 3609–3629, 2019.

MICHALAK, D. Adapting to climate change and effective water management in Polish agriculture - at the level of government institutions and farms. **Ecohydrology & Hydrobiology**, Warsaw, v. 20, n. 1, p. 134–141, 2019.

MINUZZI, R.B.; LOPEZ, F.Z. Variabilidade de índices de chuva nos estados de Santa Catarina e Rio Grande do Sul. **Bioscience Journal**, Uberlândia, v. 30, n. 3, p. 697–706, 2014.

MOKHTARI, A.; NOORY, H.; VAZIFEDOUST, M.; BAHRAMI, M. Estimating net irrigation requirement of winter wheat using model-and satellite-based single and basal crop coefficients. **Agricultural water management**, [s. l.], v. 208, n.10, p. 95-106, 2018.

MONTEIRO, J. E. B. A.; ASSAD, E. D.; SENTELHAS, P. C.; AZEVEDO, L. C. Modeling of corn yield in Brazil as a function of meteorological conditions and technological level. **Pesquisa Agropecuária Brasileira**, Brasília, v. 52, n. 3, p. 137-148, 2017.

MONTEIRO, J. E. B. A.; AZEVEDO, L. 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**, Brasília, v. 48, n. 2, p. 123-131, 2013.

MUÑOZ SABATER J., DUTRA, E., AGUSTÍ-PANAREDA, A., ALBERGEL, C., ARDUINI, G., BALSAMO, G., BOUSSETTA, S., CHOULGA, M., HARRIGAN, S., HERSBACH, H., MARTENS, B., MIRALLES, D. G., PILES, M., RODRÍGUEZ-FERNÁNDEZ, N. J., ZSOTER, E., BUONTEMPO, C., AND THÉPAUT, J.-N.: ERA5-Land: A state-of-the-art global reanalysis dataset for land applications. **Earth System Science Data**, Göttingen, v. 13, n. 10, p. 4349–4383, 2021.

ONGARATTO, J. M.; BORTOLIN, T. A. Comparação entre métodos de estimativa de evapotranspiração de referência no município de São José dos Ausentes (RS), Brasil. **Engenharia Sanitária e Ambiental**, São Paulo, v. 26, n. 5, p. 979–987, 2020.

OLIVEIRA, J. A. M. Erosividade da chuva no município de Juramento-MG no período de 1987 a 2019. **Revista Brasileira de Geografia Física**, Recife, v.14, n. 4, p. 1852-1860, 2021.

OLIVEIRA, L. M. M.; Suzana M. G. L. MONTENEGRO, B. B. da SILVA, ANTONINO, Antonio C. D.; MOURA, A. E. S. S. Evapotranspiração real em bacia hidrográfica do Nordeste brasileiro por meio do SEBAL e produtos MODIS. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.18, n.10, p.1039–1046, 2014.

PAREDES, P.; PEREIRA, L. S.; ALMOROX, J.; DAROUICH, H. Reference grass evapotranspiration with reduced data sets: parameterization of the FAO Penman-Monteith temperature approach and the Hargreaves-Samani equation using local climatic variables. **Agricultural Water Management**, [s. l.], v. 240, n.10, 2020.

PEREIRA, A. R.; MANIEIRO, M. A.; VILLA NOVA, N. A.; SÉ, G. C. **Evapo(transpi)ração**. Piracicaba: FEALQ, 1997. 183 p.

PEREIRA JÚNIOR, L. C. **O uso da água em Goiás, potencialidade, demanda para irrigação por pivôs centrais e perspectivas**. 2017. Dissertação (Mestrado em Ciências Ambientais) – Universidade Federal de Goiás, Goiânia, 2017.

PELOSI, A.; TERRIBILE, F.; D'URSO, G.; CHIRICO, G. B. Comparison of ERA5-Land and UERRA MESCAN-SURFEX reanalysis data with spatially interpolated weather observations for the regional assessment of reference evapotranspiration. **Water**, Basel, v. 12, n. 6, p. 1669–1682, 2020.

PRIESTLEY, C. H. B.; TAYLOR, R. J. On the assessment of surface heat flux and evaporation using large-scale parameters. **Weather Review**, Boston, v. 100, n. 2, p. 81-92, 1972.

PROJETO MAPBIOMAS. **Mapeamento anual de cobertura e uso da terra no Cerrado – Coleção 7**. [S. l.]: MapBiomass, 2023. Disponível em: <https://brasil.mapbiomas.org/wp->

[content/uploads/sites/4/2023/10/MapBiomass\\_CERRADO\\_2022\\_09092022\\_1\\_.pdf](#).

Acesso em: 25 out. 2024.

PINTO, C. E. T.; MENEZES, P. H. B. J.; MARTINEZ, J. M.; ROIG, H. L.; VILLAR, R. A. E. Uso de imagens MODIS no monitoramento do fluxo de sedimentos no reservatório de Três Marias. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 18, n. 5, p. 507-516, 2014.

REICHLE, R. H. Land Surface Precipitation in MERRA-2. **Journal of Climate**, Boston, v. 30, n.5, p. 1643–1664, 2017.

REICHARDT, K.; TIMM, L. C. **Solo, planta e atmosfera**. 2. ed. São Paulo: Manole, 2012.

RIBEIRO, J. F.; WALTER, B. M. T. As principais fitofisionomias do bioma Cerrado. In: SANO, S. M.; ALMEIDA, S. P.; RIBEIRO, J. F. (eds.). **Cerrado: ecologia e flora**. Brasília, DF: Embrapa Informação Tecnológica, 2008. p. 151-212.

RIVERA, A.; PONCE, P.; MATA, O.; MOLINA, A.; MEIER, A. Local Weather Station Design and Development for Cost-Effective Environmental Monitoring and Real-Time Data Sharing. **Sensors**, Basel, v. 23, n. 9, p. 2–26, 2023.

RIZZO, G.; MONZON, J. P.; ERNST, O. Cropping system-imposed yield gap: Proof of concept on soybean cropping systems in Uruguay. **Field Crops Research**, Amsterdam, v. 260, n. 1, p. 1–10, 2021.

ROCHA, T. B. C. Indicadores de Veranicos e de Distribuição de Chuva no Ceará e os Impactos na Agricultura de Sequeiro. **Revista Brasileira de Meteorologia**, [s. l.], v. 36, n. 3, p. 579-589, 2021.

RODRIGUES, G. C.; BRAGA, R. P. Estimation of Daily Reference Evapotranspiration from NASA POWER Reanalysis Products in a Hot Summer Mediterranean Climate. **Agronomy**, Basel, v. 11, n. 2077, p. 2–17, 2021.

RODRIGUES, L. N. **Agricultura irrigada no cerrado: subsídios para o desenvolvimento sustentável** – Brasília, DF: Embrapa, 2023, 503 p.

RODRIGUES, L. N.; MOREIRA, J. M. M. A. P. Desenvolvimento de um modelo de simulação de estratégias de irrigação. In: INOVAGRI INTERNATIONAL MEETING, 3., 2015, Fortaleza. **Anais** [...]. Fortaleza: INOVAGRI/INCTEI, 2015. P. 12-24.

RODRIGUES, L. N. (Org.). **Agricultura irrigada no cerrado: subsídios para o desenvolvimento sustentável** [recurso eletrônico]. Brasília, DF: Embrapa, 2023. 200 p.: il. color. ISBN 978-65-89957-83-6. Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1154164/1/Agricultura-Irrigada-digital.pdf>. Acesso em: 17 jun. 2024.

RODRIGUES, L. N. (Org.). **Agricultura irrigada no cerrado: subsídios para o desenvolvimento sustentável** [recurso eletrônico]. 2. ed. rev. e ampl. – Brasília, DF: Embrapa, 2024. 503 p.: il. color.; 16 × 22 cm. ISBN 978-65-5467-049-4. Disponível

em: <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1165534/1/Agricultura-Irrigada-2a-ed-1.pdf>. Acesso em: 17 jan. 2025.

ROOY, M. P. V. A Rainfall Anomaly Index independent of time and space. **Notos**, De Bilt, v. 14, n. 1, p. 43–48, 1965.

RUDORFF, B.; RISSO, J. Agrosatélite Geotecnologia Aplicada. **Análise Geoespacial da Dinâmica das Culturas Anuais no Bioma Cerrado**: 2000 a 2014. Florianópolis, SC: Agrosatélite Geotecnologia Aplicada Ltda., 2015. 34 p.

SALGADO, C. B.; CARVALHO JUNIOR, O. A. DE; GOMES, R. A. T.; GUIMARÃES, R. F. Análise da interferência de nuvens na classificação de séries temporais MODIS-NDVI na região da Amazônia, município de Capixaba, Acre. **Sociedade & Natureza**, Uberlândia, v. 31, n. 1, p. 1–20, 2019.

SANTOS, E. F.; SANTOS, S. R.; CARVALHO, A. J.; ASPIAZU, I.; OLIVEIRA, P. M. Soil water availability for drip-irrigated common bean crop. **Pesquisa Agropecuária Tropical**, Goiânia, v. 50, n. 1, p. 1–10, 2020.

SANO, E. E.; MAGALHÃES, I. A. L.; RODRIGUES, L. N.; BOLFE, É. L. Spatio-Temporal Dynamics of Center Pivot Irrigation Systems in the Brazilian Tropical Savanna (1985–2020). **Water**, Basel, v. 16, n. 13, p. 1–15, 2024.

SANO, E. E.; ROSA, R.; BRITO, J. L. S.; FERREIRA, L. G. **Mapeamento de cobertura vegetal do bioma Cerrado: estratégias e resultados** [recurso eletrônico]. Planaltina, DF: Embrapa Cerrados, 2007. 33 p. Disponível em: <http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/570887>. Acesso em: 17 jun. 2022.

SENTELHAS, P. C.; BATTISTI, R.; MONTEIRO, L. A.; DUARTE, Y. C. N.; VISSÉS, F. A. Yield gap – conceitos, definições e exemplos. **Informações Agronômicas**, Campinas, v. 1, n. 155, p. 9-12, 2016.

SERRÃO, E. A. O.; WANZELER, R. T. S.; SANTOS, C. A.; GONÇALVES, L. J. M.; LIMA, A. M. M.; ROCHA, E. J. P. Avaliação estatística entre as estimativas de precipitação da constelação GPM com satélite TRMM: uma análise a bacia hidrográfica do Rio Solimões. **Revista Brasileira de Climatologia**, [s. l.], v. 18, p. 256- 275, 2016.

SETIYA, P.; SATPATHI, A.; NAIN, A. S.; DAS, B. Comparação de modelos de previsão de rendimento de trigo baseados no clima para diferentes distritos de Uttarakhand usando técnicas estatísticas e de aprendizado de máquina. **Journal of Agrometeorology**, New Delhi, v. 24, n. 3, p. 255–261, 2022.

SIEBERT, S.; PETRA, D. Quantifying blue and green virtual water contents in global crop production as well as potential production losses without irrigation. **Journal of Hydrology**, Amsterdam, v. 384, n. 3–4, p. 198–217, 2010.

SILVA, A. F. G.; ZAPAROLI, E. L.; FISCH, G.; SOUZA, M. B. Uma Análise da Aplicação de Três Métodos Estatísticos para o Cálculo do Desvio Padrão da Direção do Vento na Região Tropical. **Revista Brasileira de Meteorologia**, [s. l.], v. 30, n. 2, p. 45-54, 2015.

SILVA, E. J.; COELHO, F.; SILVA, W. P.; SILVA, M. V. Sensoriamento remoto no monitoramento da qualidade dos recursos hídricos. **Cadernos UniFOA**, Volta Redonda, v. 12, n. 33, p. 121–130, 2018.

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. p. 6.

SILVA, G. K.; MARCOS JÚNIOR, A. D.; LIMA, C. E. S.; SILVA, M. V. M.; SILVEIRA, C. S. Projeções de Mudanças Climáticas do modelo Eta e CMIP5 para as Bacias dos rios São Francisco e Paraíba do Sul, Brasil. **Revista Brasileira de Meteorologia**, [s. l.], v. 38, p. 1-16, 2023.

SILVA, F. D. S.; COSTA, R. L.; ROCHA JÚNIOR, R. L.; GOMES, H. B.; AZEVEDO, P. V.; SILVA, V. P. R.; 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**, [s. l.], v. 35, n. Especial, p. 903-912, 2020.

SRIVASTAVA, P.K.; SINGH, P.; MALL, R.K.; RAJANI K. PRADHAN, M. B.; AKHILESH G. Performance assessment of evapotranspiration estimated from different data sources over agricultural landscape in Northern India. **Theoretical and Applied Climatology**, Berlin, v. 140, n. 1, p. 145–156, 2020.

SRIVASTAVA, P.K., HAN, D., ISLAM, T. et al. Seasonal evaluation of evapotranspiration fluxes from MODIS satellite and mesoscale model downscaled global reanalysis datasets. **Theoretical and Applied Climatology**, Berlin, v. 124, n. 3, p. 461–473, 2016.

SONDERMANN, M. Climate change projections and impacts on the eucalyptus plantation around the Doce River basin, in Minas Gerais, Brazil. **Climate Services**, Amsterdam, v. 28, n. 1, p. 1–15, 2022.

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.

TAPIADOR, F. J.; TURK, F. J.; PETERSEN, W.; HOU, A. Y.; GARCÍA-ORTEGA, E.; MACHADO, L. A. T.; ANGELIS, C. F.; SALIO, P.; KIDD, C.; HUFFMAN, G. J.; CASTRO, M. D. Global precipitation measurement: methods, datasets and applications. **Atmospheric Research**, [s. l.], v. 104-105, n. 1-2, p. 70–97, 2012.

TAYYEH, H. K.; MOHAMMED, R. Analysis of NASA POWER reanalysis products to predict temperature and precipitation in Euphrates River basin, **Journal of Hydrology**, Amsterdam, v. 619, n. 1, p. 1–10, 2023.

TEIXEIRA, A. H. C. Determining regional actual evapotranspiration of irrigated crops and natural vegetation in the São Francisco river basin (Brazil) using remote sensing

and Penman-Monteith equation. **Remote Sensing**, Basel, v. 2, n. 5, p. 1287-1319, 2010.

THORNTHWAITE, C. W.; MATHER, J. R. The water balance. Centerton: Drexel Institute of Technology. **Climatology**, [s. l.], v. 8, n. 1, p.104-112, 1955.

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**, Basel, v. 8, n. 1, p. 10–16, 2020.

SURENDRAN, U.; SUSHANTH, C.M.; MAMMEN, G.; JOSEPH, E.J. Modelling the Crop Water Requirement Using FAO-CROPWAT and Assessment of Water Resources for Sustainable Water Resource Management: A Case Study in Palakkad District of Humid Tropical Kerala, India, **Aquatic Procedia**, [s. l.], v. 4, n. 1, p. 1211–1219, 2015.

VESTENA, L. R.; ALMEIDA, D. E. F.; GEFFER, E. Análise espacial e temporal da distribuição dos alagamentos e inundações na cidade de Guarapuava, **Brazilian Journal of Development**, Curitiba, v. 6, n. 5, p. 24923–24941, 2020.

VIDELA-MENSEGUE, H.; CÓRDOBA, M.; CAVIGLIA, O. P.; SADRAS, V. O. Soybean yield and water productivity gaps associate with ENSO-dependent effects of fungicide, sowing date and maturity group. **European Journal of Agronomy**, Amsterdam, v. 155, n. 1, p. 1-9, 2024.

VISSES, F. de A.; SENTELHAS, P. C.; PEREIRA, A. B. Lacuna de produtividade da cultura da mandioca como medida de segurança alimentar: um exemplo para as principais regiões produtoras brasileiras. **Food Security**, Dordrecht, v. 10, n. 6, p. 1191–1202, 2018.

WANG, S.; PAN, M.; MU, Q.; SHI, X.; MAO, J.; BRÜMMER, C.; JASSAL, R. S.; KRISHNAN, P.; LI, J.; BLACK, T. A. Comparing evapotranspiration from eddy covariance measurements, water budgets, remote sensing, and land surface models over Canada. **Journal of Hydrometeorology**, Boston, v. 16, n. 4, p. 1540-1559, 2015.

WANG, Y., LING, X., MA, C. Can China get out of soy dilemma? A yield gap analysis of soybean in China. **Agronomy for Sustainable Development**, Paris, v. 43, n. 1, p. 47-56, 2023.

WATANABE, M. MIROC5 model documentation, **Geoscientific Model Development**, [s. l.], v. 4, n.1, p. 201-224, 2011.

WILLMOTT, C.J. Statistics for evaluation and comparison of models. **Journal of Geophysical Research**, Washington, v.1, n.5, p.8995-9005, 1985.

WMO – World Meteorological Organization. Guidelines on the Calculation of Climate Normals. Genebra: WMO, 2017.

WEN, Y.; FEI, Y.; FAN, Y.; YANG, A.; WANG, B.; GAO, P. P.; SCOTT, D. Development of a probabilistic agricultural drought forecasting (PADF) framework under climate change. **Agricultural and Forest Meteorology**, Amsterdam, v. 350, n. 1, p. 1-10, 2024.

WORQLUL, A. W. et al. Comparison of rainfall estimations by TRMM 3B42, MPEG and CFSR with ground-observed data for the Lake Tana basin in Ethiopia.

**Hydrology and Earth System Sciences**, Göttingen, v. 18, n. 12, p. 4871, 2014.

WTO – World Trade Organization. **World Trade Report 2023**. Disponível em: [https://www.wto.org/english/res\\_e/booksp\\_e/wtr23\\_e/wtr23\\_e.pdf](https://www.wto.org/english/res_e/booksp_e/wtr23_e/wtr23_e.pdf). Acesso em: jun. 2023.

YANG, Y.; CHEN, R. S.; DING, Y. J.; LI, H. Y.; LIU, Z. W. Changes in global land surface frozen ground and freeze-thaw processes during 1950–2020 based on ERA5-Land data, **Advances in Climate Change Research**, Beijing, v. 15, n. 2, p. 265–274, 2024.

ZHAO, A.; ZHU, X.; LIU, X.; PAN, Y.; ZUO, D.; Impacts of land use change and climate variability on green and blue water resources in the Weihe River Basin of northwest China, **CATENA**, Amsterdam, v. 137, n. 1, p. 318–327, 2016.

ZHAO, H.; CHANG, J.; HAVLÍK, P.; VAN DIJK, M.; VALIN, H.; JANSSENS, C.; MA, L.; BAI, Z.; HERRERO, M.; SMITH, P.; OBERSTEINER, M. A futura demanda por alimentos da China e suas implicações para o comércio e o meio ambiente. **Nature Sustainability**, Londres, v. 4, n. 12, p. 1042–1051, 2021.

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**, Amsterdam, v. 293, n. 10, p. 1–11, 2023.

**APÊNDICE A - Código, municípios e coordenadas geográficas das estações meteorológicas da área de estudo**

| Código da estação | Município   | Latitude | Longitude | Altitude |
|-------------------|-------------|----------|-----------|----------|
| 83526             | Catalão     | -18,17   | -47,96    | 857,98   |
| 83523             | Itumbiara   | -18,41   | -49,19    | 491,55   |
| 83522             | Ipameri     | -17,72   | -48,17    | 778,14   |
| 83464             | Jatai       | -17,92   | -51,72    | 669,84   |
| 83423             | Goiânia     | -16,67   | -49,26    | 748,53   |
| 83379             | Formosa     | -15,55   | -47,34    | 938,68   |
| 83376             | Pirenópolis | -15,85   | -48,97    | 766,92   |
| 83374             | Goiás       | -15,94   | -50,14    | 508,68   |
| 83368             | Aragarças   | -15,90   | -52,25    | 327,03   |
| 83332             | Posse       | -14,09   | -46,37    | 830,35   |



**APÊNDICE B - Municípios e coordenadas geográficas das estações pluviométricas da área de estudo**

| Latitude | Longitude | Município              |
|----------|-----------|------------------------|
| -14,13   | -47,51    | Alto Paraíso de Goiás  |
| -15,77   | -51,10    | Santa Fé de Goiás      |
| -13,33   | -50,20    | São Miguel do Araguaia |
| -16,14   | -48,60    | Alexania               |
| -18,97   | -51,93    | Aporé                  |
| -15,89   | -51,85    | Aragarças -2           |
| -15,9    | -52,24    | Aragarças -3           |
| -16,91   | -49,45    | Aragoiania             |
| -16,31   | -51,47    | Arenópolis             |
| -14,93   | -51,08    | Aruana                 |
| -16,21   | -52,17    | Bom Jardim de Goiás    |
| -15,25   | -51,16    | Britania               |
| -18,24   | -48,86    | Buriti                 |
| -16,67   | -50,65    | Cachoeira de Goiás     |
| -16,95   | -51,80    | Caiaponia              |
| -13,79   | -48,57    | Campinaçu              |
| -13,04   | -46,78    | Campos Belos           |
| -18,17   | -47,95    | Catalão                |
| -13,80   | -47,46    | Cavalcante             |
| -15,28   | -49,55    | Ceres                  |
| -16,30   | -50,56    | Córrego do Ouro        |
| -17,20   | -48,72    | Cristinópolis          |
| -14,53   | -49,96    | Crixas                 |
| -17,28   | -49,38    | Cromínia               |
| -16,72   | -52,32    | Doverlândia            |
| -17,34   | -49,93    | Edeia                  |
| -13,87   | -49,07    | Estrela do Norte       |
| -15,37   | -50,50    | Faina                  |
| -15,56   | -47,34    | Formosa                |
| -15,33   | -49,12    | Goianésia              |
| -16,67   | -49,26    | Goiânia                |
| -16,52   | -49,02    | Goianápolis            |
| -15,94   | -50,14    | Goiás                  |
| -18,10   | -50,03    | Goiatuba               |
| -16,35   | -49,50    | Inhumas                |
| -17,72   | -48,17    | Ipameri                |
| -16,32   | -50,91    | Israelândia            |
| -16,03   | -49,80    | Itaberaí               |

---

|        |        |                          |
|--------|--------|--------------------------|
| -15,82 | -50,61 | Itapirapuã               |
| -15,56 | -49,94 | Itapuranga               |
| -18,76 | -51,35 | Itaruma                  |
| -18,34 | -49,61 | Itumbiara                |
| -15,76 | -49,34 | Jaraguá                  |
| -17,86 | -51,40 | Jataí - 2                |
| -17,70 | -51,89 | Jataí - 3                |
| -17,81 | -49,63 | Joviânia                 |
| -17,98 | -48,68 | Marzagão                 |
| -15,54 | -50,70 | Matrinchã                |
| -17,98 | -50,34 | Maurilândia              |
| -15,06 | -48,17 | Mimoso de Goiás          |
| -15,94 | -51,36 | Montes Claros de Goiás   |
| -17,36 | -51,08 | Montividiu               |
| -17,73 | -49,12 | Morrinhos                |
| -14,74 | -50,58 | Mozarlândia              |
| -15,02 | -49,89 | Nova América             |
| -14,33 | -50,73 | Nova Crixas 2            |
| -13,69 | -50,80 | Nova Crixas 3            |
| -13,74 | -46,88 | Nova Roma                |
| -13,24 | -49,50 | Novo Planalto            |
| -15,54 | -48,55 | Palmeiras de Bernardo    |
| -16,80 | -49,93 | Palmeiras de Goiás       |
| -17,33 | -50,68 | Paraúna 1                |
| -14,76 | -49,58 | Pilar de Goiás           |
| -17,29 | -49,03 | Piracanjuba              |
| -16,42 | -51,82 | Piranhas                 |
| -15,85 | -48,96 | Pirenópolis              |
| -17,52 | -49,44 | Pontalina                |
| -13,41 | -49,16 | Porangatu                |
| -14,09 | -46,36 | Posse                    |
| -14,43 | -49,72 | Santa Terezinha de Goiás |
| -13,40 | -46,32 | São Domingos             |
| -14,71 | -47,52 | São João                 |
| -13,53 | -50,19 | São Miguel do Araguaia   |
| -14,80 | -46,25 | Sítio D'abadia           |
| -16,66 | -49,49 | Trindade                 |
| -13,51 | -48,75 | Trombas                  |
| -14,56 | -49,14 | Uruaçu                   |
| -15,50 | -49,69 | Uruana                   |
| -17,11 | -49,69 | Varjão                   |
| -16,75 | -48,53 | Vianópolis               |

---