



Uncertainty analysis of DSSAT plant model parameters in estimating cotton yield using GLUE

Alireza Akbari¹ , Mohsen Pourreza Bilondi,²  , Abbas Khashei-siuki³ , Mahdi kalanaki⁴ ,
Ameneh Mianabadi⁵ 

¹ Department of Water Engineering, Faculty of Agriculture, University of Birjand, Birjand, Iran. E-mail:

alirezaakbari11374@gmail.com

² Corresponding Author, Department of Water Engineering, Faculty of Agriculture, University of Birjand, Birjand, Iran. E-mail:

mohsen.pourreza@birjand.ac.ir

³ Department of Water Engineering, Faculty of Agriculture, University of Birjand, Birjand, Iran. E-mail:

abbaskhashei@birjand.ac.ir

⁴ Department of Irrigation and Drainage, Joint Cooperation Program, Imam Khomeini International University (IKIU) and Wageningen University and Research (WUR), Imam Khomeini University, Qazvin, Iran. E-mail:

kalanaki_mahdi@yahoo.com

⁵ Department of Ecology, Institute of Science and High Technology and Environmental Sciences, Graduate University of Advanced Technology, Kerman. Iran. E-mail: a.mianabadi@kgut.ac.ir

ABSTRACT

Simulation models are widely used by users in different fields. One of famous category of these models is plant growth models, which significantly assist agricultural specialists in optimizing different parameters influencing plant growth. Since the calibration of model parameters may not adequately analyze and identify their actual values, the need of studies related to uncertainty analysis of model parameters beside their calibration has become an unavoidable requirement in recent decades. This research examined the uncertainty of ecotype parameters in the DSSAT plant model for cotton using the GLUE algorithm, which is based on Monte Carlo simulation. Some parameters used in this model were kept constant and set to reasonable, pre-determined values (available in the software's technical guide). Observed performance data from four irrigation treatments of this crop were utilized to obtain the posterior distribution of the parameters. A comparison of this results with a similar previous simulation conducted in the same study area (Ghorbani Baravati et al., 2023), which focused only on parameter calibration, indicates a significant and satisfactory superiority of the GLUE algorithm linked through a coded written in the MATLAB environment.

Keywords: uncertainty, Monte Carlo, crop model, Birjand

Article Type: Research Article

Article history: Received: 07 July 2024 Revised: 12 September 2024 Accepted: 01 October 2024 ePublished: 21 December 2024

1. Introduction

Crop growth simulation models are extensively used for various agricultural studies, including optimal crop selection, irrigation management, and assessing climate change impacts. Among these models, the DSSAT (Decision Support System for Agrotechnology Transfer) is particularly prominent for its ability to simulate growth, yield, and other dynamics for 34 different crops. The DSSAT model integrates various components such as soil, weather, crop management, and genetic factors to provide comprehensive insights into crop performance (Jones et al., 2003). Accurate parameter calibration in this model is crucial for reliable simulations. However, the inherent variability and uncertainty in parameter values pose significant challenges. Uncertainty can arise from various sources, including measurement errors, spatial and temporal variability, and model structure. Addressing these uncertainties is essential to enhance the reliability and accuracy of the model predictions. The Generalized Likelihood Uncertainty Estimation (GLUE) algorithm offers a robust framework for quantifying and incorporating parameter uncertainty into model simulations (Beven & Binley, 1992). In this study, we focus on the application of the GLUE algorithm to the DSSAT model for cotton, aiming to improve the model's predictive accuracy by accounting for parameter uncertainty. We utilize observational data from different irrigation treatments to calibrate the model and evaluate the posterior probability distributions of the parameters.

2. Materials and Methods

The study used data from a 2009 experiment conducted at the Birjand University research farm. The DSSAT v4.5 model was employed, requiring inputs such as weather, soil properties, and crop management data. Four irrigation treatments (50%, 75%, 100%, and 125% of crop water requirement) were tested to evaluate the GLUE algorithm's performance in estimating model parameters.

3. Results and discussion

The results demonstrated that the GLUE algorithm effectively estimated the probability distributions of the DSSAT model parameters for cotton. The algorithm's performance was compared with previous models lacking uncertainty assessments, showing significant improvements in simulation accuracy (Qasemi et al., 2019). The findings highlighted the importance of considering parameter uncertainty for better

predictive accuracy and model reliability.

4. Conclusions

The GLUE algorithm, through Monte Carlo simulations, provides a robust method for assessing and incorporating parameter uncertainty in crop growth models like DSSAT. This approach enhances the model's reliability in predicting crop performance under varying conditions, which is crucial for agricultural planning and management.

5. References

- Jones, J. W., Hoogenboom, G., Porter, C. H., Boote, K. J., Batchelor, W. D., Hunt, L. A., Wilkens, P.W., Singh, U., Gijssman, A.J., & Ritchie, J. T. (2003). *The DSSAT cropping system model*. *European Journal of Agronomy*, 18(3-4), 235-265. [https://doi.org/10.1016/S1161-0301\(02\)00107-7](https://doi.org/10.1016/S1161-0301(02)00107-7)
- Beven, K., & Binley, A. (1992). The future of distributed models: model calibration and uncertainty prediction. *Hydrological Processes*, 6(3), 279-298. <https://doi.org/10.1002/hyp.3360060305>
- Qasemi, M., Darzi-Naftchali, A., & Kamgar-Haghighi, A. A. (2019). Parameterization and evaluation of DSSAT/CANEGRO model for sugarcane under Khuzestan climatic conditions using GLUE method. *Journal of Agricultural Science and Technology*, 21(5), 1199-1210. <http://dx.doi.org/10.2134/agronj2010.0302>

6. Conflict of Interest

Authors declared no conflict of interest.

Cite this article: Akbari, A., Pourreza Bilondi, M., khashei-siuki, A., Kalanaki, M., & Mianabadi, A. (2024). Uncertainty analysis of DSSAT plant model parameters in estimating cotton yield using GLUE, *Advanced Technologies in Water Efficiency*, 4(4), 19-34. <https://doi.org/10.22126/atwe.2024.10960.1135>

Publisher: Razi University

© The Author(s)





بررسی عدم قطعیت پارامترهای مدل گیاهی DSSAT در بر آورد عملکرد گیاه پنبه با استفاده از روش GLUE

علیرضا اکبری^۱، محسن پوررضا بیلندی^۲، عباس خاشعی سیوکی^۳، مهدی کلانکی^۴، آمنه میان آبادی^۵

^۱ گروه علوم ومهندسی آب، دانشکده کشاورزی، دانشگاه بیرجند، بیرجند، ایران. رایانامه: alirezaakbari11374@gmail.com

^۲ نویسنده مسئول، گروه علوم ومهندسی آب، دانشکده کشاورزی، دانشگاه بیرجند، بیرجند، ایران. رایانامه: mohsen.pourreza@birjand.ac.ir

^۳ گروه علوم ومهندسی آب، دانشکده کشاورزی، دانشگاه بیرجند، بیرجند، ایران. رایانامه: abbaskhashei@birjand.ac.ir

^۴ گروه آبیاری و زهکشی، برنامه همکاری مشترک دانشگاه بین المللی امام خمینی (ره) و دانشگاه واخنینگن هلند، دانشگاه بین المللی امام خمینی (ره)، قزوین، ایران. رایانامه: kalanaki_mahdi@yahoo.com

^۵ گروه اکولوژی، پژوهشکده علوم محیطی، پژوهشگاه علوم و تکنولوژی پیشرفته و علوم محیطی، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته، کرمان، ایران.

رایانامه: a.mianabadi@kgut.ac.ir

چکیده

امروزه مدل های شبیه سازی در همه علوم به وفور توسط کاربران مورد استفاده قرار می گیرد. دسته ای از این مدل ها، مدل های شبیه سازی رشد گیاهی هستند که به متخصصین کشاورزی در بهینه کردن فاکتورهای مختلف تأثیرگذار بر رشد گیاه کمک فراوانی می کند. از آنجا که واسنجی پارامترهای مدل های شبیه سازی به تنهایی نمی تواند مقدار مناسب برای آنها را تحلیل کند فلذا در دهه اخیر به ضرورت مطالعات مرتبط با تحلیل عدم قطعیت پارامترهای مدل در کنار واسنجی آنها ضرورتی اجتناب ناپذیر است. در این تحقیق عدم قطعیت پارامترهای اکو تاییپی مدل گیاهی DSSAT برای گیاه پنبه توسط الگوریتم GLUE که مبتنی بر شبیه سازی مونت کارلو است مورد بررسی قرار گرفت. سایر پارامترهای مورد استفاده این مدل ثابت و برابر با مقادیر معقول و از پیش تعیین شده (موجود در راهنمای فنی نرم افزار) در نظر گرفته شد. از داده های مشاهده شده عملکرد در ۴ تیمار آبیاری این محصول جهت بدست آوردن توزیع پسین احتمالاتی پارامترها و سایر مقادیر معیارهای ارزیابی عملکرد استفاده شد. مقایسه نتایج این معیارها با شبیه سازی مشابه قبلی انجام شده در همین منطقه مورد مطالعه توسط قربانی برواتی و همکاران (۱۴۰۲) که صرفاً به واسنجی پارامترها پرداخته بود، نشان از برتری محسوس و قابل قبول الگوریتم GLUE لینک شده توسط رابط کدنویسی شده در محیط Matlab می دهد.

واژه های کلیدی: عدم قطعیت، مونت کارلو، مدل گیاهی، بیرجند

نوع مقاله: مقاله پژوهشی

سابقه مقاله: دریافت: ۱۷ تیر ۱۴۰۳ اصلاح: ۲۲ شهریور ۱۴۰۳ پذیرش: ۱۰ مهر ۱۴۰۳ چاپ الکترونیکی: ۰۱ دی ۱۴۰۳

استناد: اکبری، ع.، پوررضا بیلندی، م.، خاشعی سیوکی، ع.، کلانکی، م.، و میان آبادی، آ. (۱۴۰۳). بررسی عدم قطعیت پارامترهای مدل گیاهی DSSAT در بر آورد عملکرد گیاه پنبه با استفاده از روش GLUE، فناوری های پیشرفته در بهره وری آب، ۴(۴)، ۱۹-۳۴.

<https://doi.org/10.22126/atwe.2024.10960.1135>



مقدمه

مدل‌های شبیه‌سازی گیاهان زراعی برای انجام مطالعات مختلف از جمله انتخاب گیاه و رقم مناسب، تعیین ویژگی‌های گیاهی، تعیین بهترین مدیریت زراعی، تعیین آبیاری بهینه، مدیریت مصرف آب، پیش‌بینی اثر تغییر اقلیم بر رشد و عملکرد محصول و تخمین عملکرد بالقوه به کار می‌روند (مارین و همکاران^۱، ۲۰۱۱). مدل‌های گیاهی با در نظر گرفتن اثرات متقابل بین پارامترها و متغیرهای ورودی مربوط به خاک، آب، هوا و گیاه به شبیه‌سازی مراحل رشدی گیاه می‌پردازند (لی و همکاران^۲، ۲۰۱۸). خروجی این مدل‌ها می‌تواند به مدیریت و برنامه‌ریزی‌های بهتر برای تولید مناسب و بهینه محصولات کشاورزی کمک کند (فرشی و همکاران^۳، ۱۹۸۷، پانگ و له تی^۴، ۱۹۹۸، و زندپارسا و همکاران^۵، ۲۰۰۶). از این مدل‌ها می‌توان برای کاربردهای مختلفی از جمله طراحی الگوی کاشت بهینه، تعیین عوامل مدیریتی مناسب، تناسب شرایط رشد گیاه با شرایط محیط و برنامه‌های اصلاحی گیاهان زراعی استفاده نمود (بنایان و همکاران، ۱۳۹۱). تاکنون مدل‌های زیادی برای شبیه‌سازی رشد و نمو گیاهان توسعه یافته است (لندیوار و همکاران^۶، ۱۹۸۳، سلطانی و همکاران^۷، ۲۰۰۴، ون اویجن^۸، ۲۰۰۲، ویسلر و همکاران^۹، ۱۹۸۶) که از آن میان می‌توان به مدل‌های DSSAT (جونز و همکاران^{۱۰}، ۲۰۰۳)، APSIM (کیتینگ و همکاران^{۱۱}، ۲۰۰۳)، STICS (بریسون و همکاران^{۱۲}، ۲۰۰۳) و AquaCrop (وانویترخت و همکاران^{۱۳}، ۲۰۱۴) اشاره کرد. یکی از مدل‌هایی که برای شبیه‌سازی رشد گیاه استفاده می‌شود مدل سیستم پشتیبانی تصمیم برای انتقال فناوری کشاورزی (DSSAT^{۱۴}) است. مدل DSSAT برنامه کاربردی است که شامل مدل‌های شبیه‌سازی رشد برای ۳۴ گیاه است. این مدل با استفاده از طیف وسیعی از برنامه‌های آب‌وهوا، خاک، ژنتیک، مدیریت گیاه و مجموعه داده‌های تجربی پشتیبانی می‌شود و طول دوره رشد، عملکرد، دینامیک سیستم ریشه، تأثیر آب موجود در خاک و نیتروژن موجود در خاک بر فتوسنتز، تعادل کربنی و تعادل آبی را شبیه‌سازی می‌کند (جونز و همکاران، ۲۰۰۳). مدل DSSAT اگر به خوبی واسنجی و ارزیابی شده باشد، برای شبیه‌سازی استراتژی‌های مدیریت زراعی و آبیاری کارآمد مفید است (گریبای و همکاران^{۱۵}، ۲۰۱۹). نمونه تحقیق خاتا و همکاران^{۱۶} (۲۰۲۳) در ایالت تامیل نادو هندوستان مثال خوبی از یک واسنجی و صحت سنجی این مدل برای گیاه پنبه است که نتایج قابل قبولی را ارائه داد. برای واسنجی مدل باید ضرایب ژنتیکی برای ارقام جدید تعیین شود که این کار با کمک بخش GENCALC امکان‌پذیر است. این مدل شامل مجموعه‌ای از برنامه‌های مستقل بوده که با یکدیگر کار می‌کنند و مدل‌های رشد گیاهی در مرکز آن قرار دارند. در این مدل پایگاه‌های داده آب‌وهوا، خاک، شرایط آزمایش، اندازه‌گیری‌ها و اطلاعات ژنتیکی برای به‌کارگیری مدل در وضعیت‌های مختلف، توصیف می‌شود و بنابراین می‌توان اثرات مختلف رطوبت و یا اقلیم را بر روی پارامترهای مدل بررسی کرد (کومار و همکاران^{۱۷}، ۲۰۲۳).

¹ Marin et al

² Li et al

³ Farshi et al

⁴ Pang & Letey

⁵ Zand-Parsa et al

⁶ Landivar et al

⁷ Soltani et al

⁸ van Oijen

⁹ Whisler et al

¹⁰ Jones et al

¹¹ Keating et al

¹² Brisson et al

¹³ Vanuytrecht et al

¹⁴ Decision Support System for Agrotechnology Transfer

¹⁵ Garibay et al

¹⁶ Khatua et al

¹⁷ Kumar et al

افزایش پیچیدگی مدل‌های گیاهی می‌تواند شبیه‌سازی بهتر و دقیق‌تری از خصوصیات گیاهان ارائه دهد، اما از طرفی ارزیابی آن‌ها نیز با چالش مواجه می‌شود. با وجود عمومیت کاربرد مدل‌های گیاهی، در صورتی که نتوان مقدار بهینه برای پارامترهای آنها تعیین نمود، کاربرد آنها با مشکل مواجه می‌شود؛ بنابراین برای حصول نتایج قابل اطمینان از مدل‌ها باید میزان عدم قطعیت خروجی و پارامترهای کلیدی آنها تعیین شده و مورد بررسی قرار گیرد. دو جزء اصلی مدل‌های گیاهی فیزیک مدل و مقادیر پارامترهای مدل است (گاردنر و همکاران^۱، ۱۹۹۰) که در تعیین میزان کارایی مدل نقش به‌سزایی دارند و اهمیت آن‌ها زمانی که از مدل‌ها برای پیش‌بینی تولید گیاه در زمان‌ها و مکان‌های متفاوت استفاده می‌شود، بیشتر خواهد شد. باتوجه به اینکه اغلب مدل‌های گیاهی به پارامترهای ورودی زیادی نیاز دارند و اندازه‌گیری همه این پارامترها در همه جا امکانپذیر نیست و همچنین باتوجه به تغییرپذیری مکانی و زمانی پارامترها، تعیین این مقادیر و بررسی عدم قطعیت آنها برای هر منطقه با استفاده از روش‌های مناسب اهمیت بسیاری در افزایش دقت خروجی مدل‌ها دارد. تورلی و فورد^۲ (۲۰۰۹) عدم قطعیت را به معنی نبود یا کمبود اطلاعات درباره وضعیت موجود و یا نتایج یک فرایند تعریف کرده‌اند. در فرایند مدل-سازی به دلیل ساده‌سازی فرآیندها و فرضیات استفاده شده نتایج شبیه‌سازی کاملاً با واقعیت مطابقت ندارد و بنابراین تفاوت بین نتایج مدل و مقادیر اندازه‌گیری شده یا مشاهده شده نشان از عدم قطعیت مدل باشد. منابع این عدم قطعیت می‌تواند شامل کمبود اطلاعات و داده‌های ورودی، خطا در داده‌های ورودی و یا تغییرپذیری ساختار و پارامترهای مدل باشد (تورلی و فورد، ۲۰۰۹).

همان‌طور که ذکر شد یکی از منابع عدم قطعیت مدل‌ها، پارامترهای مدل‌هاست که این پارامترها قبل از استفاده از مدل باید در فرایند واسنجی بر اساس میزان مطابقت خروجی مدل با مقادیر اندازه‌گیری شده تخمین زده شود (ژیوی و همکاران^۳، ۲۰۱۱). اما پارامترهایی که از طریق واسنجی به دست می‌آیند نیز ممکن است تحت تأثیر عدم قطعیت ناشی از داده‌های ورودی، ساختار مدل، داده ناکافی و نادقیق، دانش ناکافی یا اطلاعات ناقص باشند (بیون^۴، ۲۰۰۷). در چنین شرایطی یافتن یک سری منحصر به فرد برای پارامترهای بهینه امکان‌پذیر نیست. به طوری که سری‌های مختلف پارامترها می‌تواند نتایج یکسانی در روند واسنجی داشته باشد و نمی‌توان یک سری پارامتر یکتا را به‌عنوان پارامترهای واسنجی شده در شبیه‌سازی به کاربرد. علاوه بر این، با فرض یافتن سری بهینه در دوره واسنجی، عدم قطعیت در پارامترهای مدل باعث می‌شود که شبیه‌سازی برای دوره‌ای غیر از دوره واسنجی قابل اطمینان نباشد (سیوان و بورک^۵، ۱۹۹۴، هاپکینز و لیپولد^۶، ۱۹۹۶). در این شرایط برای واسنجی پارامترهای مدل باید روشی را انتخاب نمود که به‌جای تخمین یک مقدار منحصر به فرد برای پارامترهای مدل، تابع توزیع آنها را بر اساس داده‌های مشاهداتی و خروجی مدل نشان دهد. باتوجه به اهمیت عدم قطعیت پارامترهای مدل، روش‌های متعددی باهدف کمی‌سازی آن ارائه شده است که یکی از این روش‌ها، روش عمومی عدم قطعیت تشابهات (GLUE^۷) است که توسط بیون و بینلی^۸ (۱۹۹۲) توسعه یافت. در این روش با فرض پذیرش این که پارامترهای بهینه منحصر به فرد (یکتا) وجود ندارد، با استفاده از روش شبیه‌سازی مونت‌کارلو چندین سری پارامترهای مختلف ایجاد شده، نتایج حاصل از سری‌های مختلف بر اساس نسبت اعتمادشان وزن گرفته و سپس از این وزن‌ها برای تعیین توزیع احتمالاتی پیش‌بینی استفاده می‌شود.

مبانی نظری و پیشینه پژوهش

روش GLUE مورد استفاده بسیاری از محققان در مدل‌سازی‌ها قرار گرفته است که دلیل آن سادگی مفهوم، کاربرد و اجرای آن است (بلاسون و همکاران^۹، ۲۰۰۸). مطالعاتی نیز برای واسنجی مدل DSSAT با روش GLUE انجام شده است که به برخی از آنها اشاره

¹ Gardner et al

² Turley & Ford

³ Zhiwei et al

⁴ Beven

⁵ Sievänen & Burk

⁶ Hopkins & Leibold

⁷ Generalized Likelihood Uncertainty Estimation

⁸ Beven & Binley

⁹ Blasone et al

می‌شود. در ایران قاسمی و همکاران (۱۳۹۸) به واسنجی و ارزیابی مدل DSSAT/CANEGRO برای نیشکر رقم CP۶۱۴-۵۷ در شرایط اقلیمی خوزستان با استفاده از روش GLUE پرداختند. مدل CANEGRO دارای ۲۰ پارامتر ژنتیکی است که به‌منظور کاهش تعداد آن‌ها، واسنجی انجام شد. مقایسه پیش‌بینی‌ها و شبیه‌سازی‌های مدل نشان داد که راندمان مدل برای وزن خشک هوایی برابر با ۰/۶۹ تا ۰/۷۵، وزن خشک ساقه برابر با ۰/۶۷ تا ۰/۷ تا ۰/۷ و ساکارز برابر با ۰/۱۸ تا ۰/۲۵ است.

لی و همکاران^۱ (۲۰۱۸) به برآورد پارامترهای ژنتیکی مدل DSSAT/CERES-Wheat با روش GLUE برای تولید گندم زمستانه پرداختند. در این مطالعه، داده‌های میدانی تجربی از طریق مجموعه‌ای از آزمایش‌های میدانی پنج ساله (۲۰۰۸-۲۰۱۳) در یک سایت میدانی در یکن، چین جمع‌آوری شد. نتایج نشان داد که روش GLUE می‌تواند پارامترهای ژنتیکی گندم شامل شاخص سطح برگ شبیه سازی شده (LAI)، زیست توده بالای زمین (AGB)، نیتروژن بالای زمین (AGN) و عملکرد دانه (GY) را به دقت برآورد کند. بودهابون و همکاران^۲ (۲۰۱۸) مدل CERES-Rice را استفاده کردند و ضرایب ژنتیکی مدل را با استفاده از روش GENCALC و GLUE تخمین زدند که نتایج آنها نشان داد مقدار RMSE نرمال شده برای شبیه‌سازی تاریخ گرده‌افشانی، تاریخ رسیدگی و وزن دانه با روش GLUE به ترتیب ۳/۶۷، ۲/۵ و ۳/۶۸ و با روش GENCALC به ترتیب ۳/۹۷، ۳/۶۹ و ۳/۶۸ به دست آمد که نشان از برتری نسبی روش GLUE دارد. جونز و همکاران (۲۰۱۱) با استفاده از روش GLUE پارامترهای مدل DSSAT را برای دو رقم ذرت و سویا در اسپانیا تخمین زدند. نتایج آنها نشان دهنده تخمین بهتر پارامترها با روش GLUE (خطای نسبی زیر ۱۰٪) نسبت به مقادیر پیش‌فرض و مقادیر تخمین زده شده با سعی و خطا (خطای نسبی بالای ۱۰٪) بود. مارین و همکاران (۲۰۱۱) از مدل DSSAT/CANEGRO برای تخمین شاخص سطح برگ، ماده خشک، میزان ساکاروز و محتوی آب خاک برای گیاه نیشکر در برزیل استفاده کردند. پارامترهای مدل با روش GLUE تخمین زده شد. نتایج حاصل نشان از دقت مناسب مدل در تخمین متغیرهای مورد بررسی داشت. هی و همکاران^۳ (۲۰۰۹) از مدل CERES-Maize از DSSAT استفاده کردند و پارامترهای مدل را برای ذرت شیرین در کالیفرنیا شمالی با روش GLUE تخمین زدند. نتایج ایشان نشان داد که مدل پس از واسنجی با روش GLUE پیش‌بینی مناسبی از عملکرد ماده خشک، تاریخ گرده‌افشانی و تاریخ برداشت ارائه داد (خطای نسبی ۴/۴ درصد برای سال ۲۰۰۵ و ۲/۴ درصد برای سال ۲۰۰۶). پارامترهای خاک نیز با دقت مناسبی تخمین زده شد.

بنا به آنچه ذکر شد، هدف مطالعه حاضر تخمین پارامترهای مدل DSSAT و بررسی عدم قطعیت آن در شبیه‌سازی رشد پنبه (رقم ورامین) با استفاده از روش GLUE است. به این منظور از پژوهشی که برای شبیه‌سازی رشد این محصول در مزرعه تحقیقاتی دانشگاه بیرجند و با استفاده از مدل CERES-COTTON نسخه 4.5 DSSAT انجام شده بود، استفاده شد.

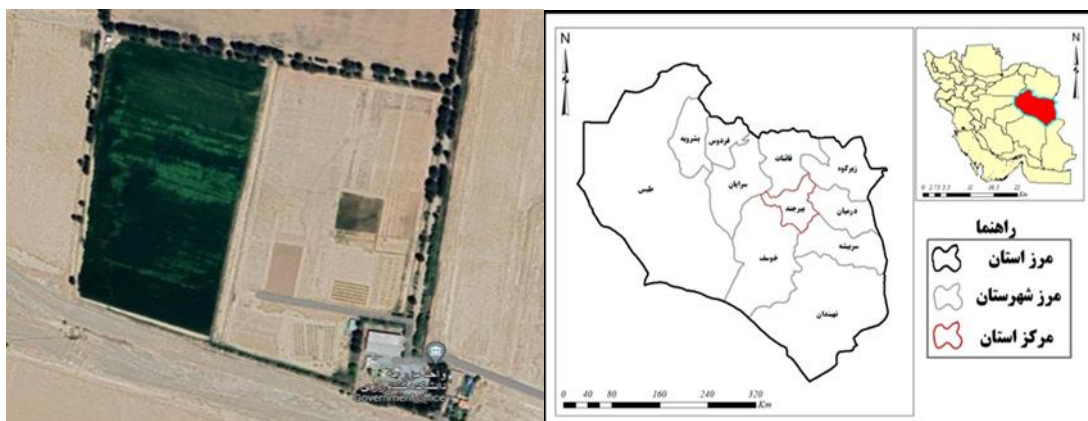
روش پژوهش

در این تحقیق از مطالعه انجام شده در سال ۱۳۸۸ در مزرعه تحقیقاتی دانشگاه بیرجند با عرض جغرافیایی ۵۳° و ۳۲° شمالی و طول جغرافیایی ۱۳° و ۵۵° شرقی و با ارتفاع ۱۴۸۰ متر از سطح دریا استفاده شد (قربانی برواتی و همکاران، ۱۴۰۲). بر اساس اطلاعات ایستگاه همدیدی بیرجند، میانگین بارش سالانه در منطقه ۱۷۰ میلی‌متر می‌باشد. بیشترین بارش ماهیانه آن در اسفند ماه به میزان ۴۲/۳ میلی‌متر به‌وقوع پیوسته است.

¹ Lei et al

² Buddhagoon et al

³ He et al



شکل ۱. موقعیت مزرعه مورد مطالعه (مزرعه تحقیقاتی دانشگاه بیرجند)

انتخاب و آماده‌سازی قطعه زمین مناسب برای اجرای طرح در اوایل مهرماه ۱۳۸۸ انجام پذیرفت. مراحل کاشت، داشت و برداشت محصول پنبه از ۸ اردیبهشت ماه ۱۳۸۹ لغایت ۱۰ آبان ۱۳۸۹ ادامه داشت. میزان آبیاری بر اساس محاسبه نیاز آبی گیاه پنبه تعیین و اعمال شد. برای بررسی اثر تنش آبی بر عملکرد پنبه، چهار تیمار آبیاری شامل I۱، I۲، I۳ و I۴ به ترتیب معادل ۵۰، ۷۵، ۱۰۰ و ۱۲۵ درصد عمق آب موردنیاز گیاه، در نظر گرفته شد. لازم به ذکر است که در مطالعه فوق رقم ورامین کشت شد.

مدل DSSAT

در این تحقیق از مدل DSSAT نسخه 4.5 استفاده شده است. این مدل توسط مؤسسه ICASA¹ و در سال ۲۰۱۲ میلادی ارائه شد. برای اجرای مدل DSSAT اطلاعات آب و هوا، خاک، مدیریت زراعی و رقم زراعی به‌عنوان ورودی‌های مدل موردنیاز است که باید به شکل فایل‌های سازماندهی مشخص شده در اختیار مدل قرار گیرد. فایل ورودی X شامل اطلاعات مدیریت زراعی است که توسط زیر مدل XBUILD به مدل ارائه می‌شود. فایل اطلاعات خاکشناسی نیز با استفاده از زیرمدل SBUILD وارد مدل می‌شود. اطلاعات هواشناسی که از ایستگاه هواشناسی بیرجند اخذ شد، توسط زیر مدل Weather Man برای مدل تعریف می‌شود. فایل A شامل مشخصات تولیدی گیاه از جمله عملکرد نهایی، ماده خشک نهایی، حداکثر شاخص سطح برگ تولیدی و فایل T برای روند تغییرات صفات در طول زمان رشد نیز از جمله فایل‌های مورد استفاده در مدل است.

داده‌های موردنیاز

داده‌های موردنیاز برای اجرای مدل DSSAT شامل داده‌های هواشناسی، ویژگی‌های خاک محل آزمایش و اطلاعات مربوط به عملکرد و فنولوژی مشاهداتی گیاه (مدیریت گیاه) است. داده‌های هواشناسی شامل دمای روزانه حداقل و حداکثر، بارش و تابش خورشیدی روزانه و اطلاعات خاک شامل درصد رس، سیلت، سنگ‌ریزه، اسیدیته و کربن آلی موجود در خاک است. داده‌های مدیریت گیاه شامل نام مؤسسه و ایستگاه تحقیقاتی به اختصار، سال و شماره آزمایش، نوع گیاه کشت شده، کد مزرعه پژوهشی، فایل‌های خاک و هواشناسی ساخته شده در هر یک از مراحل قبل، پارامترهای آنالیز خاک مثل چگالی ظاهری، رطوبت، درصد کربن آلی، نوع رقم کشت شده، تاریخ کاشت و جوانه‌زنی، روش کاشت و توزیع دانه‌ها در زمین، تراکم دانه‌ها در هنگام کاشت و جوانه‌زنی، فاصله بین ردیف‌ها، عمق کاشت، تاریخ، حجم آب مورد استفاده برای هر آبیاری، روش آبیاری، راندمان آبیاری، روش مورد استفاده برای کوددهی به زمین، تاریخ برداشت، مشخص نمودن مرحله‌ای از رشد که برداشت صورت می‌گیرد، انتخاب نوع تیمارهای مورد بررسی در تحقیق از میان اطلاعات ورودی، انتخاب تاریخ شروع شبیه‌سازی و گزینش پارامترهای دلخواه جهت شبیه‌سازی است.

¹ International Crop Architecture Standards for Agricultural Applications

مراحل اجرای روش GLUE برای تحلیل عدم قطعیت مدل DSSAT

در این مطالعه از روش GLUE (که در بخش مقدمه توضیح داده شد) برای واسنجی مدل DSSAT و تحلیل عدم قطعیت پارامترها استفاده شد. در روش GLUE ابتدا برای هر پارامتر تابع توزیع احتمال اولیه (تابع توزیع پیشین) انتخاب می‌شود که این تابع توزیع می‌تواند یکنواخت و یا هر تابع مناسب برازش داده شده دیگری نیز باشد. سپس با اجرای روش GLUE تابع توزیع جدیدی برای پارامترهای مدل به دست می‌آید که به آن تابع توزیع پسین گفته می‌شود (ماکوسکی و همکاران^۱، ۲۰۰۶). در این مطالعه برای پارامترهای مدل پیشنهادی تابع توزیع پیشین یکنواخت در نظر گرفته شد. سپس باید بردار مجموعه پارامترها باتوجه به تعداد پارامترها تعیین شده و N عدد از مجموعه پارامترها از تابع توزیع پیشین به طور تصادفی انتخاب شود. به این منظور در این مطالعه از روش نمونه‌گیری مربع لاتین^۲ (LHS) استفاده شد. روش LHS (مک کی و همکاران^۳، ۱۹۷۹) با نمونه‌گیری در فواصل مساوی در فضای پارامترها باعث کاهش واریانس و افزایش دقت شبیه‌سازی مونت‌کارلو بدون نیاز به افزایش نمونه‌ها می‌شود. در این مطالعه ۱۰۰ هزار نمونه برای اجرای مدل انتخاب شد. پس از آن باید با N انتخاب انجام شده، مدل موردنظر را اجرا نموده و بر اساس شبیه‌سازی مدل و مقادیر واقعی تابع درست‌نمایی (likelihood) را محاسبه نمود. در این مطالعه رابطه معکوس واریانس خطا (بیون و باینلی، ۱۹۹۲) به‌عنوان معیار درست‌نمایی استفاده شده است.

$$L = \left(\frac{\sum_{j=1}^n (O_j - Y(\theta_i))^2}{n-2} \right)^{-1} \quad (1)$$

در این رابطه L معیار درست‌نمایی، O_j مقادیر اندازه‌گیری شده، θ_i مجموعه نام پارامترها (هر مجموعه پارامتر مشتمل بر کل پارامترهای هست که در پروسه واسنجی به کار می‌رود)، $Y(\theta_i)$ مقدار برآورد شده توسط مدل و n تعداد داده‌ها می‌باشد. هرچه مقدار درست‌نمایی بزرگتر باشد، تطابق بیشتری بین مقادیر اندازه‌گیری و مقادیر برآورد شده وجود دارد.

پس از محاسبه تابع درست‌نمایی، با مرتب‌کردن نزولی مقادیر درست‌نمایی و با در نظر گرفتن آستانه قابل‌پذیرش^۴، درصدی از ۱۰۰ هزار تکرار مدل که منجر به بهترین شبیه‌سازی (بیشترین مقدار درست‌نمایی) شده‌اند، به‌عنوان مجموعه پارامترهای قابل قبول انتخاب می‌شود. در این مطالعه آستانه قابل‌پذیرش یک درصد در نظر گرفته شد. پس از انتخاب مجموعه پارامترهای قابل قبول، با محاسبه وزن‌های درست‌نمایی (معادله (۲))، عدم قطعیت خروجی مدل محاسبه می‌شود.

$$p_i = \frac{L_i}{\sum_{i=1}^k L_i} \quad (2)$$

در این معادله p_i وزن درست‌نمایی مجموعه پارامتر نام و k تعداد مجموعه پارامترهای قابل قبول می‌باشد. مقادیر p_i که مجموع آن‌ها برابر یک می‌باشد تابع چگالی احتمال را می‌دهند. در نهایت با محاسبه بازه اطمینان ۹۵٪ محدوده عدم قطعیت پیش‌بینی مدل در روش GLUE محاسبه می‌شود که تقریبی از همه انواع منابع خطای شبیه‌سازی می‌باشد (وروخ و همکاران^۵، ۲۰۰۸). تمام مراحل فوق با ارتباط دادن مدل گیاهی DSSAT و کد GLUE در محیط برنامه نویسی MATLAB اجرا شد.

¹ Makowski et al

² Latin Hypercube Sampling

³ McKay et al

⁴ Acceptable Sample Rate

⁵ Vrugt et al

معیارهای ارزیابی عدم قطعیت

برای تولید محدوده اطمینان ۹۵ درصد، ۲/۵ درصد از حدود بالا و پایین داده‌های شبیه سازی شده به‌عنوان داده‌های شبیه سازی شده پرت حذف شدند و حدود باقیمانده به‌عنوان محدوده اطمینان ۹۵ درصد به دست آمد. برای تحلیل کمی عدم قطعیت از معیارهای P_{CI} و d استفاده شد.

$$P_{CI} = \frac{NQ_{observed}}{NQ_{ALL}} \times 100 \quad (3)$$

در معادله ۶ P_{CI} درصد قرارگیری داده‌های اندازه‌گیری شده در محدوده اطمینان ۹۵ درصد، $NQ_{observed}$ تعداد داده‌های مشاهداتی که در بازه اطمینان قرار گرفته‌اند و NQ_{ALL} تعداد کل داده‌های مشاهداتی است. طبق این رابطه معیار P_{CI} بر حسب درصد بیان می‌شود و هر چه قدر عدد به دست آمده از این شاخص به ۱۰۰ نزدیک‌تر باشد نشان دهنده دقت بالاتر شبیه‌سازی مدل است. رابطه زیر نحوه محاسبه معیار d را نشان می‌دهد. تغییرات معیار d بین صفر و یک است و هرچه قدر مقدار آن به صفر نزدیک‌تر باشد نشان‌دهنده شبیه‌سازی مناسب است.

$$d = \frac{1}{n} \sum_{i=1}^n \frac{\text{limit}_{U,i} - \text{limit}_{L,i}}{Q_{O,i}} \quad (4)$$

در این معادله $\text{limit}_{U,i}$ حد بالای محدوده اطمینان در i امین مقدار شبیه‌سازی، $\text{limit}_{L,i}$ حد پایین محدوده اطمینان در i امین مقدار شبیه سازی، $Q_{O,i}$ مقداری که برای متغیر موردنظر مشاهده شده است و n تعداد کل داده‌های اندازه‌گیری شده است. معیار d پهنای نرمال شده محصور بین حد بالا و پایین متغیر شبیه‌سازی شده در سطح اطمینان موردنظر است.

معیارهای ارزیابی مدل

برای ارزیابی نتایج مدل DSSAT از سنج‌های آماری ضریب تعیین (R^2)، میانگین خطا (ME) و جذر میانگین مربعات خطای نرمال شده (NRMSE) استفاده شد.

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_o - x_m)^2}{\sum_{i=1}^n (x_o - \bar{x}_o)^2} \quad (5)$$

$$ME = \frac{\sum_{i=1}^n (x_m - x_o)}{n} \quad (6)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_m - x_o)^2}{n}} \quad (7)$$

$$NRMSE = \frac{RMSE}{(\bar{x}_o)} \quad (8)$$

که در این روابط X_m مقادیر شبیه‌سازی شده، X_0 مقادیر مشاهده شده، n تعداد کل مشاهدات و \bar{X}_0 مقدار متوسط متغیر مشاهده شده است.


یافته‌ها

در این مطالعه برای ارزیابی عدم قطعیت پارامترهای مدل DSSAT، ۴ پارامتر اکوتایپی^۱ شامل زمان بین جوانه‌زنی گیاه و ظهور گل (EM-FL)، زمان بین اولین گل و اولین غلاف (FL-SH)، زمان بین اولین گل و اولین بذر (FL-SD) و زمان بین اولین بذر و بلوغ فیزیولوژی (SD-PM) انتخاب شدند و بقیه پارامترها ثابت در نظر گرفته شدند. برای اجرای الگوریتم GLUE، تابع توزیع پیشین این ۴ پارامتر به صورت تابع یکنواخت و با حد بالا و پایین به شرح جدول (۱) انتخاب شد. بر این اساس مقدار EM-FL بین ۱۰ تا ۵۵ روز، مقدار FL-SH بین ۱ تا ۱۲ روز، مقدار FL-SD بین ۶ تا ۲۵ روز و مقدار SD-PM بین ۲۰ تا ۵۵ روز در نظر گرفته شد.

جدول ۱. تابع توزیع پیشین (یکنواخت) برای ۴ پارامتر مورد بررسی مدل DSSAT.

پارامتر	حد پایین	حد بالا
EM-FL	10	55
FL-SH	1	12
FL-SD	6	25
SD-PM	20	55

با اجرای الگوریتم GLUE تابع توزیع پسین ۴ پارامتر فوق به دست آمد که در شکل (۲) ارائه شده است. به جز پارامتر FL-SH که تابع توزیع آن دارای چولگی است، تابع توزیع ثانویه بقیه پارامترها تقریباً به شکل تابع توزیع نرمال به دست آمده است که میانگین و انحراف معیار آنها در جدول (۲) آمده است. میانگین ۴ پارامتر فوق به ترتیب ۲۹، ۹، ۱۵ و ۴۰ روز با انحراف معیار ۵/۱، ۱/۴، ۲/۴ و ۴/۴ روز است.



شکل ۲. تابع توزیع پسین برای ۴ پارامتر مورد بررسی مدل DSSAT

¹ ecotype

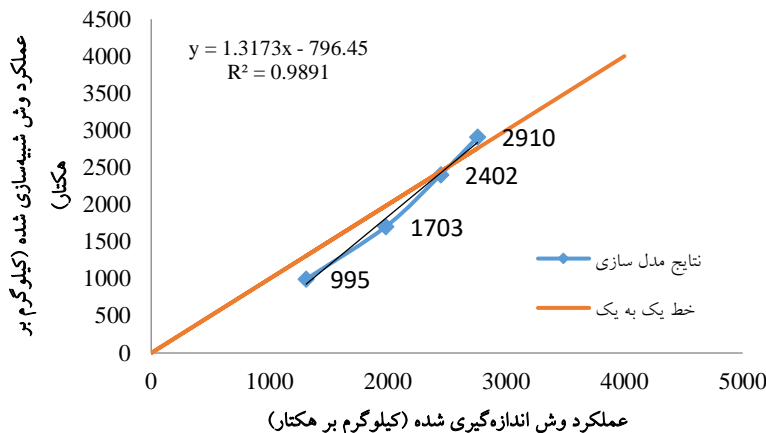
جدول ۲. میانگین و انحراف معیار تابع توزیع پسین برای ۴ پارامتر مورد بررسی مدل DSSAT.

پارامتر	میانگین	انحراف معیار
EM-FL	29	5.1
FL-SH	9	1.4
FL-SD	15	2.4
SD-PM	40	4.4

مقادیر بهینه پارامترهای مورد بررسی که منجر به بهترین شبیه‌سازی شده است، در جدول (۳) مشاهده می‌شود. همبستگی مقادیر عملکرد وش پنبه حاصل از اجرای مدل با مقادیر بهینه ۴ پارامتر مذکور و مقادیر اندازه‌گیری شده عملکرد وش برای هر ۴ تیمار آبیاری در شکل (۳) ارائه شده است. همانطور که در شکل دیده می‌شود، اگرچه مدل عملکرد وش پنبه رقم ورامین را کمتر از عملکرد وش اندازه‌گیری شده شبیه‌سازی کرده است (ME = -147 kg/ha)، اما به طور کلی مقادیر بهینه ۴ پارامتر تخمین زده شده با الگوریتم GLUE منجر به تخمین مناسبی از عملکرد وش شده است (R2 = 0.99, ME = -147 kg/ha و NRMSE = 0.106). نتایج حاصل از اجرای الگوریتم GLUE نشان می‌دهد که این الگوریتم برای تخمین پارامترهای EM-FL, FL-SH, FL-SD و SD-PM بهتر از واسنجی ساده انجام شده در مطالعه قربانی برواتی و همکاران (۱۴۰۲) به روش سعی و خطا است (R2 = 0.91, ME = -281 kg/ha و NRMSE = 0.18). مقادیر دو معیار ارزیابی PCI (۱۰۰٪) و d (۱.۴) در جدول (۴) نیز نشان دهنده اجرای قابل قبول الگوریتم GLUE در برآورد پارامترهای مدل است.

جدول ۳. مقادیر بهینه پارامترهای مورد بررسی

پارامتر	مقدار بهینه
EM-FL	28.5
FL-SH	9.4
FL-SD	15.3
SD-PM	38.5



شکل ۳. همبستگی عملکرد وش پنبه شبیه سازی با مقادیر بهینه ۴ پارامتر مذکور و مقادیر اندازه گیری شده عملکرد وش برای هر ۴ تیمار آبیاری در برابر نمودار خط یک به یک

مطابق با خط رگرسیون برازش داده شده و مقدار p value برابر با 0.055، فرض صفر (شیب خط رگرسیون از لحاظ آماری تفاوت معنی داری با شیب خط یک به یک ندارد) با سطح اطمینان ۵ درصد قبول می شود و در نتیجه تفاوت معنی داری با خط یک به یک ندارد و مدل شبیه سازی می تواند مدل مناسبی باشد.

جدول ۴. معیارهای ارزیابی الگوریتم GFLUE در بررسی عدم قطعیت مدل DSSAT

مقدار	فاکتور
100%	P_{CI}
1.4	d

بحث

شکل تابع توزیع پسین نشان دهنده درجه عدم قطعیت تخمین است (هی و همکاران، ۲۰۰۹). بر اساس این شکل محدوده پارامتر EM-FL بین ۱۰ تا ۴۷، FL-SH بین ۳ تا ۱۲، FL-SD بین ۶ تا ۲۳ و SD-PM بین ۲۲ تا ۵۵ تخمین زده شده است. باتوجه به این که شکل تابع توزیع پسین همه پارامترها با تابع توزیع پیشین آنها (توزیع یکنواخت که از مقادیر احتمال برابر به ازای تمام مقادیر بازه اولیه پارامتر حکایت دارد) تفاوت دارد، بنابراین عدم قطعیت آنها کاهش یافته است (هی و همکاران، ۲۰۰۹). همانطور که در بخش یافته ذکر شد، به جز پارامتر FL-SH که تابع توزیع آن دارای چولگی است، تابع توزیع ثانویه بقیه پارامترها تقریباً به شکل تابع توزیع نرمال به دست آمده است. اگر تابع توزیع پسین به تابع توزیع نرمال نزدیک باشد، به این معنی است که داده های اندازه گیری شده دارای اطلاعات کافی برای تخمین مقدار پارامترها است (شفیعی و همکاران، ۲۰۱۴). در غیر این صورت ممکن است نتایج تحت تأثیر خطای ساختار مدل یا خطای سیستماتیک داده های ورودی باشد که باید در این شرایط از روش هایی استفاده نمود که تأثیر این دو خطا را با هم در نظر می گیرد. در مواردی که تابع توزیع پسین پارامتری دارای نقطه بیشینه مشخصی باشد، نشان دهنده حساسیت مدل نسبت به آن پارامتر است و اگر تابع توزیع پسین پارامتری یکنواخت باشد، مدل به آن

پارامتر حساس نیست (پوررضا و همکاران^۱، ۲۰۱۷). شکل (۲) نشان می‌دهد که مدل DSSAT به هر ۴ پارامتر حساس است و بنابراین تخمین دقیق آنها بر خروجی مدل اثر دارد.

نتیجه‌گیری

نظر به اهمیت پرداختن به مسئله عدم قطعیت پارامترهای مدل‌سازی، در این مطالعه به ارزیابی عدم قطعیت پارامترهای مدل رشد گیاهی DSSAT در شبیه‌سازی عملکرد گیاه پنبه پرداخته شد. داده‌های عملکرد رشد گیاه پنبه با کمک داده‌های مزرعه‌ای مزرعه تحقیقاتی دانشگاه بیرجند (اقتباس شده از قربانی برواتی و همکاران، ۱۴۰۲) در ۴ سناریو آبیاری مختلف مورد استفاده قرار گرفت.

مدل‌سازی با کمک مدل گیاهی DSSAT و فرایند خودکار نمودن شبیه‌سازی‌ها (تغییر پارامترهای موردنظر در فایل‌های ورودی) توسط کدی نوشته شده در محیط MATLAB انجام گردید تا با کمک الگوریتم GLUE که بر اساس شبیه‌سازی مونت‌کارلو اقدام به تولید سری پارامترهای مختلف در بازه از پیش تعیین شده می‌کند؛ تحلیل عدم قطعیت نتایج ارزیابی گردد.

نتایج توزیع‌های پسین پارامترهای این مطالعه نشان داد که ۴ پارامتر اکو تایی مورد بررسی در این مطالعه شامل زمان بین جوانه‌زنی گیاه و ظهور گل (EM-FL)، زمان بین اولین گل و اولین غلاف (FL-SH)، زمان بین اولین گل و اولین بذر (FL-SD) و زمان بین اولین بذر و بلوغ فیزیولوژی (SD-PM) دارای عدم قطعیت بوده و بنابراین به‌جای یک مقدار منحصربه‌فرد برای این پارامترها بهتر است از تابع توزیع آنها استفاده شود. همچنین نشان داده شد که اجرای الگوریتم GLUE با دقت مناسبی می‌تواند محدوده اولیه را باریک‌تر کرده و بنابراین عدم قطعیت پارامترها را کاهش دهد. همچنین مقادیر بهینه به دست آمده از اجرای الگوریتم GLUE (مربوط به بهترین شبیه‌سازی) نسبت به مقادیر واسنجی شده با روش ساده سعی و خطا در مطالعه قربانی برواتی و همکاران (۱۴۰۲) منجر به نتایج بهتری در تخمین عملکرد و ش گیاه پنبه شده است (مقایسه مقادیر NRMSE) که این مسئله نشان‌دهنده عملکرد قابل قبول الگوریتم GLUE برای تخمین پارامترها است. همانطور که ذکر شد در این مطالعه تنها از ۴ پارامتر اکو تایی مدل DSSAT استفاده شد و بقیه با کمک مقادیر معرفی شده در راهنمای فنی ثابت در نظر گرفته شد. حال آنکه در مطالعات آینده می‌توان پارامترهای بیشتری را در نظر گرفته و مدل را واسنجی نمود. در این صورت عملکرد و ش پنبه را می‌توان با دقت بالاتری تخمین زد.

منابع

- بنایان اول، محمد، نظامی، احمد، گنجعلی، علی، و باقری عبدالرضا. (۱۳۹۱). استفاده از تکنیک مونت‌کارلو- زنجیره مارکف همراه با یک مدل ساده برای شبیه‌سازی تولید نخود در استان خراسان، پژوهش‌های زراعی ایران، ۱۰ (۴)، ۶۳۴-۶۴۲
<https://doi.org/10.22067/gsc.v10i4.20334>
- قاسمی، محبوبه، ناصری، عبدعلی، و معاضد، هادی. (۱۳۹۸). پارامتریابی و ارزیابی مدل DSSAT/CANEGRO برای نیشکر رقم CP-۵۷-۶۱۴ در شرایط اقلیمی خوزستان، تحقیقات آب و خاک ایران، ۵۰ (۶)، ۱۳۳۱-۱۳۴۰
<https://doi.org/10.22059/ijswr.2018.259986.667944>
- قربانی برواتی، فاطمه، نجفی مود، محمد حسین، رضانی، یوسف، و خاشعی سیوکی، عباس. (۱۴۰۲). اثر تغییر اقلیم بر رشد و عملکرد پنبه (منطقه مورد مطالعه: دشت بیرجند)، مجله تحقیقات آب و خاک ایران، ۵۴ (۸)، ۱۱۳۱-۱۱۴۵
<https://doi.org/10.22059/ijswr.2023.321555.668931>

References

- Bannayan Aval, M., Nezami, A., Ganjeali, A., & Bagheri, A. (2012). Simulation of Chickpea Production in Khorasan Provinces Using a Simple Crop Model and Markov Chain Monte Carlo

¹ Pourreza et al

technique. *Iranian Journal of Field Crops Research*, 10(4), 634-642. <https://doi.org/10.22067/gsc.v10i4.20334>[In Persian]

- Beven, K. (2007). Towards integrated environmental models of everywhere: uncertainty, data and modelling as a learning process. *Hydrology and Earth System Sciences*, 11(1), 460-467. <https://doi.org/10.5194/hess-11-460-2007>
- Blasone, R.-S., Vrugt, J. A., Madsen, H., Rosbjerg, D., Robinson, B. A., & Zyvoloski, G. A. (2008). Generalized likelihood uncertainty estimation (GLUE) using adaptive Markov Chain Monte Carlo sampling. *Advances in Water Resources*, 31(4), 630-648. <https://doi.org/10.1016/j.advwatres.2007.12.003>
- Brisson, N., Gary, C., Justes, E., Roche, R., Mary, B., Ripoche, D., Zimmer, D., Sierra, J., Bertuzzi, P., Burger, P., Bussi re, F., Cabidoche, Y., Cellier, P., Debaeke, P., Gaudill re, J., H nault, C., Maraux, F., Seguin, B., & Sinoquet, H. (2003). An overview of the crop model stics. *European Journal of Agronomy*, 18(3-4), 309-332. [https://doi.org/10.1016/S1161-0301\(02\)00110-7](https://doi.org/10.1016/S1161-0301(02)00110-7)
- Buddhagoon, C., Jintrawet, A., & Hoogenboom, G. (2018). Methodology to estimate rice genetic coefficients for the CSM-CERES-Rice model using GENCALC and GLUE genetic coefficient estimators. *The Journal of Agricultural Science*, 156(4), 482-492. <https://doi.org/10.1017/S0021859618000527>
- Farshi, A. A., Feyen, J., Belmans, C., & De Wijnngaert, K. (1987). Modelling of yield of winter wheat as a function of soil water availability. *Agricultural Water Management*, 12(4), 323-339. [https://doi.org/10.1016/0378-3774\(87\)90007-2](https://doi.org/10.1016/0378-3774(87)90007-2)
- Gardner, R. H., Dale, V. H., & O'Neill, R. V. (1990). Error Propagation and uncertainty in process modeling. In Dixon, R. K., Meldahl, R. S., Ruark, G. A., & Warren, W. G. editors. Forest Growth: Process Modeling of Response to Environmental Stress. *Timber Press*, Portland, 208-219. https://link.springer.com/chapter/10.1007/1-4020-4663-4_3
- Garibay, V. M., Kothari, K., Ale, S., Gitz, D. C., Morgan, G. D., & Munster, C. L. (2019). Determining water-use-efficient irrigation strategies for cotton using the DSSAT CSM CROPGRO-cotton model evaluated with in-season data. *Agricultural Water Management*, 223, 105695. <https://doi.org/10.1016/j.agwat.2019.105695>
- Ghasemi, M., Naseri, A., & Moazed, H. (2019). Parameterization and Evaluation of the DSSAT-CANEGRO Model for Sugarcane CP57-614 in Khuzestan Climate Condition. *Iranian Journal of Soil and Water Research*, 50(6), 1331-1340. <https://doi.org/10.22059/ijswr.2018.259986.667944> [In Persian]
- Ghorbani Baravati, F., Najafi Mood, M. H., Ramezani, Y., & Khashei, A. (2023). Impact of climate change on cotton growth and yield (case study: Birjand Plain). *Iranian Journal of Soil and Water Research*, 54(8), 1131-1145. <https://doi.org/10.22059/ijswr.2023.321555.668931>[In Persian]
- He, J., Dukes, M. D., Jones, J. W., Graham, W. D., & Judge, J. (2009). Applying glue for estimating ceres-maize genetic and soil parameters for sweet corn production. *American Society of Agricultural and Biological Engineers*, 52(6), 1907-1921. <https://elibrary.asabe.org/abstract.asp?aid=29218>
- Hopkins, J. C., & Leipold, R. J. (1996). On the dangers of adjusting the parameter values of mechanism-based mathematical models. *Journal of Theoretical Biology*, 183(4), 417-427. <https://doi.org/10.1006/jtbi.1996.0232>
- Jones, J., Hoogenboom, G., Porter, C., Boote, K., Batchelor, W., Hunt, L., Wilkens, P., Singh, U., Gijsman, A., & Ritchie, J. (2003). The DSSAT cropping system model. *European Journal of Agronomy*, 18(3-4), 235-265. [https://doi.org/10.1016/S1161-0301\(02\)00107-7](https://doi.org/10.1016/S1161-0301(02)00107-7)
- Jones, J. W., He, J., Boote, K. J., Wilkens, P., Porter, C. H., & Hu, Z. (2015). Estimating DSSAT cropping system cultivar-specific parameters using Bayesian techniques. *In Methods of introducing system models into agricultural research*, 365-393. <https://doi.org/10.2134/advagricssystemmodel2.c13>

- Khatua, R., Panneerselvam, S., Geethalakshmi, V., & Jeyakumar, P. (2023). Calibration and Validation of DSSAT (CROPGRO) Model for Winter Irrigated Cotton in Coimbatore, Tamil Nadu, India. *International Journal of Plant & Soil Science*, 35(22), 752-760. <https://journalijpss.com/index.php/IJPSS/article/view/4187>
- Keating, B., Carberry, P., Hammer, G., Probert, M., Robertson, M., Holzworth, D., Huth, N., Hargreaves, J. N., Meinke, H., Hochman, Z., McLean, G., Verburg, K., Snow, V., Dimes, J., Silburn, M., Wang, E., Brown, S., Bristow, K., Asseng, S., ... & Smith, C. (2003). An overview of APSIM, a model designed for farming systems simulation. *European Journal of Agronomy*, 18(3-4), 267-288. [https://doi.org/10.1016/S1161-0301\(02\)00108-9](https://doi.org/10.1016/S1161-0301(02)00108-9)
- Kumar, R., Mishra, S. K., Singh, K., Al-Ashkar, I., Iqbal, M. A., Muzamil, M. N., ... & El Sabagh, A. (2023). Impact analysis of moisture stress on growth and yield of cotton using DSSAT-CROPGRO-cotton model under semi-arid climate. *PeerJ*, 11. <https://doi.org/10.7717/peerj.16329>
- Landivar, J. A., Baker, D. N., & Jenkins, J. N. (1983). Application of GOSSYM to genetic feasibility studies. I. Analyses of fruit abscission and yield in Okra-Leaf Cottons 1. *Crop Science*, 23(3), 497-504. <https://doi.org/10.2135/cropsci1983.0011183X002300030014x>
- Li, Z., He, J., Xu, X., Jin, X., Huang, W., Clark, B., Yang, G., & Li, Z. (2018). Estimating genetic parameters of DSSAT-CERES model with the GLUE method for winter wheat (*Triticum aestivum* L.) production. *Computers and Electronics in Agriculture*, 154, 213-221. <https://doi.org/10.1016/j.compag.2018.09.009>
- Makowski, D., Hillier, J., Wallach, D., Andrieu, B., & M.H. Jeuffroy. (2006). Parameter estimation for crop models. In D. Wallach, D. Makowski, & J. Jones (Eds.) , Working with Dynamic Crop Models: Evaluating, Analyzing, Parameterizing and Using Them. *Elsevier*, Amsterdam, 101-150. https://www.researchgate.net/publication/233858512_Parameter_estimation_for_crop_models
- Marin, F. R., Jones, J. W., Royce, F., Suguitani, C., Donzeli, J. L., Filho, W. J. P., & Nassif, D. S. P. (2011). Parameterization and evaluation of predictions of DSSAT/CANEGRO for Brazilian sugarcane. *Agronomy Journal*, 103(2), 304-315. <https://doi.org/10.2134/agronj2010.0302>
- McKay, M. D., Beckman, R. J., & Conover, W. J. (1979). A comparison of three methods for selecting values of input variables in the analysis of output from a computer code. *Technometrics*, 21(2), 239-245. <http://dx.doi.org/10.1080/00401706.1979.10489755>
- Pang, X., & Letey, J. (1998). Development and evaluation of ENIRO-GRO, an integrated water, salinity, and nitrogen model. *Soil Science Society of America Journal*, 62, 1418-1427. <https://www.scrip.org/reference/referencespapers?referenceid=3122307>
- Pourreza-Bilondi, M., Samadi, S. Z., Akhoond-Ali, A. M., & Ghahraman, B. (2017). Reliability of semiarid flash flood modeling using Bayesian framework. *Journal of Hydrologic Engineering*, 22(4), 05016039. [http://dx.doi.org/10.1061/\(ASCE\)HE.1943-5584.0001482](http://dx.doi.org/10.1061/(ASCE)HE.1943-5584.0001482)
- Shafiei, M., Ghahraman, B., Saghafian, B., Davary, K., Pande, S., & Vazifedoust, M. (2014). Uncertainty assessment of the agro-hydrological SWAP model application at field scale: A case study in a dry region. *Agricultural Water Management*, 146, 324-334. <https://doi.org/10.1016/j.agwat.2014.09.008>
- Sievänen, R., & Burk, T. E. (1994). Fitting process-based models with stand growth data: problems and experiences. *Forest Ecology and Management*, 69(1-3), 145-156. [https://doi.org/10.1016/0378-1127\(94\)90225-9](https://doi.org/10.1016/0378-1127(94)90225-9)
- Soltani, A., Torabi, B., Zeinali, E., & Sarparast, R. (2004). Response of Chickpea to photoperiod as a qualitative long-day plant. *Asian Journal of Plant Sciences*, 3(6), 705-708. <https://doi.org/10.3923/ajps.2004.705.708>

- Turley, M. C., & Ford, E. D. (2009). Definition and calculation of uncertainty in ecological process models. *Ecological Modelling*, 220(17), 1968–1983. <https://doi.org/10.1016/j.ecolmodel.2009.04.046>
- Van Oijen, M. (2002). On the use of specific publication criteria for papers on process-based modelling in plant science. *Field Crops Research*, 74(2–3), 197–205. [https://doi.org/10.1016/S0378-4290\(01\)00211-8](https://doi.org/10.1016/S0378-4290(01)00211-8)
- Vanuytrecht, E., Raes, D., Steduto, P., Hsiao, T. C., Fereres, E., Heng, L. K., Garcia Vila, M., & Mejias Moreno, P. (2014). AquaCrop: FAO's crop water productivity and yield response model. *Environmental Modelling & Software*, 62, 351–360. <https://doi.org/10.1016/j.envsoft.2014.08.005>
- Vrugt, J. a., ter Braak, C. J. F., Clark, M. P., Hyman, J. M., & Robinson, B. a. (2008). Treatment of input uncertainty in hydrologic modeling: Doing hydrology backward with Markov chain Monte Carlo simulation. *Water Resources Research*, 44, 1–52. <https://doi.org/10.1029/2007WR006720>
- Whisler, F., Acock, B., Baker, D., Fye, R., Hodges, H., Lambert, J., & Lemmon, H. (1986). Crop simulation models in agronomic systems. *Advances in Agronomy*, 40, 141–208. <http://books.google.com/books?hl=en&lr=&id=HVG0VkgDouUC&oi=fnd&pg=PA141&dq=Crop+simulation+model+in+agronomic+systems&ots=5F6iiJ8pZL&sig=Tyghz8iX5JRcFYfEeOnZs0TSGgk>
- Zand-Parsa, S., Sepaskhah, A. R., & Ronaghi, A. (2006). Development and evaluation of integrated water and nitrogen model for maize. *Agricultural Water Management*, 81(3), 227–256. <https://doi.org/10.1016/j.agwat.2005.03.010>
- Zhiwei, J., Zhongxin, C., Qingbo, Z., & Jianqiang, R. (2011). Global sensitivity analysis of CERES-Wheat model parameters. *Transactions of the CSAE*, 27(1), 236–242. <http://dx.doi.org/10.3969/j.issn.1002-6819.2011.01.038>