



Applicability of Ensemble Modeling Techniques in Water Requirement Simulations

Ahmad Jafarzadeh^{1*}, Abbas Khashei-Siuki^{1,2} and Ali Shahidi³

Article type:

Research Article

Article history:

Submitted: 5 May 2023

Revised: 8 August 2023

Accepted: 28 August 2023

Available Online: 28 August 2023

How to cite this article:

Jafarzadeh, A., Khashei-Siuki, A., and Shahidi, A. (2023). Applicability of Ensemble Modeling Techniques in Water Requirement Simulations. *Saffron Agronomy & Technology*, 11(2), 163-182.

DOI: 10.22048/jsat.2023.394323.1486

Abstract

Ensemble modelling is expanding in several areas of engineering, especially different aspects of water engineering. Accurate estimation of saffron water requirement (SWR), an essential strategic production of the agriculture sector, is a crucial and influencing act in local water planning of this region. Hence, this study aimed to check the applicability of ensemble modelling in enhancing SWR at Birjand, Southern Khorasan, Iran. The actual water requirement of saffron was recorded in the field lysimetric laboratory at the University of Birjand. The simulation of water requirement was conducted utilizing Decision Tree Regression (DTR) with input climate features. Additionally, Boosting and Bagging methods were employed to establish and enhance the ensemble process of soil water requirement (SWR) simulations. To track the effectiveness of any method, some comparative tests were designed, such as statistical criteria (RMSE and MAE) detection, Violin plot analysis, over/underestimation, times series comparison, and error improvement test. Results indicated that although the acceptable performance of DTR in simulating SWR, the probable improvement was potentially felt. Derived results confirmed that supervised ensemble modelling (Boosting) could enhance the accuracy of DTR by more than 30 percent (reducing absolute error from 36 mm to 23.65 mm), resulting in declining RMSE from 0.44 mm to 0.07 mm. Further, different experiment outcomes revealed that the Boosting algorithm quality is more appealing than DTR and Bagging outputs.

Keywords: Artificial Intelligence, Error improvement, Lysimetric lab, Supervised ensemble modelling, Violin plot analysis.

1 - Saffron Institute, University of Torbat Heydarieh, Torbat Heydarieh, Iran

2 - Professor, Department of Water Engineering, University of Birjand, Birjand.

3 - Associated Professor, Department of of Water Engineering, University of Birjand, Birjand, Iran.

Corresponding author: mnt.jafarzadeh@gmail.com



مقاله پژوهشی

ارزیابی عملکرد روش‌های مدل‌سازی گروهی در شبیه‌سازی نیاز آبی زعفران

احمد جعفرزاده^{۱*}، عباس خاشعی سیوکی^۱ و علی شهیدی^۳

تاریخ دریافت: ۵ اردیبهشت ۱۴۰۲

تاریخ بازنگری: ۱۷ مرداد ۱۴۰۲

تاریخ پذیرش: ۶ شهریور ۱۴۰۲

جعفرزاده، ا.، خاشعی سیوکی، ع.، و شهیدی، ع. (۱۴۰۲). ارزیابی عملکرد روش‌های مدل‌سازی گروهی در شبیه‌سازی نیاز آبی زعفران، زراعت و فناوری زعفران، ۱۱(۲): ۱۸۲-۱۶۳.

چکیده

مدل‌سازی گروهی به‌عنوان یک مقوله نوظهور در بسیاری از رشته‌های مهندسی به‌خصوص زمینه‌های مختلف مهندسی آب در حال گسترش است. تخمین دقیق نیاز آبی زعفران به‌عنوان محصول راهبردی شرق کشور یکی از مهم‌ترین اقدامات تأثیرگذار در برنامه‌ریزی منابع آب منطقه خواهد بود. از این‌رو، این پژوهش اقدام به بررسی عملکرد مدل‌سازی گروهی در بهبود مدل‌سازی نیاز آبی زعفران در منطقه بیرجند استان خراسان جنوبی کرد. داده‌های واقعی نیاز آبی زعفران در سال دوم کشت در گام نخست در محل آزمایشگاه لایسی‌متری دانشگاه بیرجند جمع‌آوری شد. مدل‌سازی نیاز آبی زعفران با استفاده از داده‌های اقلیمی و نیاز آبی زعفران در بستر ماشین یادگیری درخت تصمیم انجام شد. همچنین، از دو روش Boosting و Bagging جهت ارتقای نتایج مدل درخت تصمیم استفاده شد. به‌منظور کمی کردن اثر مدل‌سازی گروهی آزمون‌های مقایسه‌ای متعددی نظیر شاخص‌های ارزیابی (RMSE و MAE)، مقایسه توزیع پراکنش داده‌ها (تحلیل وایولین Violin assessment)، ارزیابی کم/بیش تخمینی، مقایسه سری زمانی و تحلیل بهبود خطا استفاده شد. نتایج نشان داد که علی‌رغم دقت و کارایی نسبی مدل درخت تصمیم در شبیه‌سازی نیاز آبی زعفران، امکان بهبود نتایج همچنان وجود دارد. همچنین، نتایج اثبات کرد که مدل‌سازی گروهی ظرفیت بالقوه‌ی خوبی در زمینه ارتقای نتایج دارد. به‌طوری‌که یادگیری گروهی بانظارت (Boosting) دقت مدل درخت تصمیم را بیش از ۳۰ درصد بهبود بخشید (کاهش قدر مطلق خطا از ۳۶ میلی‌متر به ۲۳/۶۵ میلی‌متر) و این موضوع عامل کاهش RMSE را از ۰/۴۴ میلی‌متر به ۰/۰۷ میلی‌متر شد. علاوه‌بر این، نتایج آزمون‌های مقایسه‌ای تأیید کرد که خروجی تولید شده توسط روش Boosting از کیفیت بسیار بهتری نسبت به خروجی مدل درخت تصمیم و روش Bagging برخوردار است.

کلمات کلیدی: بهبود خطا، تحلیل وایولین، لایسی‌متر، یادگیری گروهی نظارتی، هوش مصنوعی.

۱- پژوهشگر پژوهشکده زعفران، دانشگاه تربت حیدریه، تربت حیدریه، ایران.

۲- استاد، گروه مهندسی آب، دانشگاه بیرجند، ایران.

۳- دانشیار گروه علوم و مهندسی آب، دانشگاه بیرجند، بیرجند، ایران.

*- نویسنده مسئول: mnt.jafarzadeh@gmail.com

مقدمه

منابع عدم قطعیت بسیار زیاد و متنوعی در فرآیند مدل سازی وجود دارد که به طور قابل توجهی نتایج را تحت تأثیر خود قرار می دهد (Chapagain et al., 2022). عدم قطعیت ناشی از منابع و داده های ورودی، پارامترها و ساختار مدل، دانش ناکافی از محیط پیرامون (Günther et al., 2019) در کنار عدم قطعیت متأثر از باقیمانده ی خطا (Jafarzadeh et al., 2022) از جمله مهم ترین بخش های تأثیرگذار در شناخت عدم قطعیت است. در حال حاضر، تلاش بسیاری از پژوهشگران در اقصی نقاط دنیا روی شناسایی و رفع این عوامل تولید خطا متمرکز شده است تا در کنار فرآیند مدل سازی ضمن پرداخت به این عوامل یک نتیجه نزدیک به واقعیت را ارائه دهند (Dertimanis et al., 2019). نتیجه نهایی تحلیل عدم قطعیت شناسایی منابع ایجاد خطا و تحلیل مبتنی بر واقعیت است. البته این موضوع در شبیه سازی و تخمین نیاز آبی زعفران کمتر مورد توجه پژوهشگران قرار گرفته است. از طرف دیگر، بررسی یافته های پژوهش های اخیر در زمینه کمی سازی و شناسایی منابع عدم قطعیت بیان گر این واقعیت است که همواره بخش مشخصی از عدم قطعیت وجود دارد که نمی توان به راحتی مورد شناسایی و رفع اثر قرار گیرد (Zhou et al., 2022). همچنین، بعضی از نتایج صراحتاً اذعان می کنند که همیشه با اتکا به یک مدل تنها نمی توان به نتایج قابل اعتماد دست پیدا کرد (Jafarzadeh et al., 2022) و در بیشتر اوقات کاربرد همزمان چند مدل می تواند منجر به اعتمادپذیری بیشتر نتایج شود. از طرف دیگر، شبیه سازی و تخمین نیاز آبی زعفران از جمله زمینه هایی است که به کار بست مدل سازی گروهی و تحلیل عدم قطعیت کمتر توجه شده است.

مدل سازی گروهی (Ensemble modeling) در حال حاضر یک تفکر جدید است که هدف غایی آن بهبود نتایج مدل سازی

و کاهش عدم قطعیت کل است. در این نوع مدل سازی از توانمندی چند مدل به صورت همزمان استفاده می شود و کاربر درصدد آن است تا نقاط قوت چند مدل را تجمیع کند (Ardabili et al., 2020). دامنه کاربرد مدل سازی گروهی بسیار گسترده بوده و در حال حاضر زمینه های مختلفی از مهندسی به خصوص مهندسی آب را در گرفته است. مطالعات در تغییر اقلیم (Ashrafzadeh et al., 2019)، بارش-رواناب (Nourali et al., 2016)، نفوذ عمقی و تغذیه سطحی (Sajedi-Hosseini et al., 2018)، آب زیرزمینی (Jafarzadeh et al., 2021)، از جمله این پژوهش ها است. از نظر مفهوم، مدل سازی گروهی می تواند به روش هایی اطلاق شود که در آن ها از روی یک سری شبیه سازی چندین نمونه جدید تولید می شود و در نهایت با یکدیگر ترکیب شده و یک خروجی بهبود یافته تولید شود. همچنین در حالت پیچیده تر به روش هایی که از خروجی چندین مدل شبیه ساز استفاده می کنند تا یک شبیه سازی ارتقاء یافته را تولید کنند نیز در این تعریف می گنجند. از این منظر، می توان روش های گروهی را به سه دسته مهم تقسیم بندی کرد: روش های ترکیبی، میانگین گیری و ماشین های یادگیری گروهی (Nisbet et al., 2009). ساختار این روش ها، الگوریتم های مورد استفاده و دامنه کاربرد هر کدام از آن ها تا حد بسیار زیادی با یکدیگر متفاوت است.

در روش های ترکیبی کاربر می تواند به صورت همزمان از خروجی چندین مدل شبیه ساز اعم از ماشین یادگیری، مدل های مفهومی ساده و یکپارچه، مدل های تحلیلی، نیمه-توزیعی، توزیعی و حتی عددی استفاده کند. از منظر مفهوم، روش های ترکیبی خود شامل روش هایی نظیر میانگین گیری ساده (Simple Model Averaging- SMA)، مدل گروهی برتر (Multi Models Super Ensemble- MMSE) و مدل گروهی برتر اصلاح شده (Modified MMSE- M3SE)

مدل یادگیری ماشین، دقت پیش‌بینی را بهبود می‌بخشد. این روش باعث کاهش خطا و بهبود عملکرد مدل یادگیری می‌شود و به خصوص در مسائل پیش‌بینی، طبقه‌بندی و تشخیص الگو کاربرد دارد. ایده اصلی ELM، به پایه گذاران معروف این روش یعنی Leo Breiman و Adele Cutler باز می‌گردد. آنها اولین بار در سال ۱۹۹۶ این روش را برای بهبود دقت در طبقه‌بندی محصولات بکار گرفتند (Breiman, 2001). در سال‌های اخیر مطالعات بسیار زیادی، در بخش‌های مختلف مهندسی آب، کارایی این نوع از مدل‌سازی گروهی را مورد بررسی قرار داده‌اند (Joshi et al., 2023; Sarıgöl et al., 2023; Jamei et al., 2023). به‌عنوان مثال، در یک مطالعه مقایسه‌ای (Mirzaei et al., 2021) عملکرد روش Boosting را در زمینه تهیه نقشه‌های حساسیت سیلاب مورد بررسی قرار دادند. ایشان تعدادی از مؤلفه‌های فیزیوگرافی و هیدرولوژیکی را به‌عنوان ورودی و پهنه‌های سیلاب را به‌عنوان خروجی در سه مدل جمعی تعمیم یافته (Generalized Additive Model- GAM)، درخت تصمیم (Decision Tree-DT) و نسبت فراوانی (Frequency Ratio- FR) در نظر گرفتند. نتایج پژوهش آن‌ها حاکی از آن بود که کاربست مدل‌سازی گروهی از طریق روش Boosting توانسته است که دقت شبیه‌سازی را تا حد قابل قبولی ارتقا دهد. همچنین در یک پژوهش جدید و خلاقانه (Başakın et al., 2023) با استفاده از قابلیت‌های روش Boosting و تحلیل طیف منفرد (Singular Spectrum Analysis-SSA) اقدام به معرفی یک روش جدید جهت ارتقای نتایج شبیه‌سازی ماشین‌های یادگیری کردند. ایشان کارایی روش پیشنهادی خود را در زمینه تخمین تبخیر- تعرق پتانسیل با بعضی از ماشین‌های یادگیری رایج نظیر درخت تصمیم مورد ارزیابی قرار دادند و ادعان داشتند که دقت این روش در مقایسه با ماشین‌های یادگیری دیگر بسیار بهتر است. علی‌رغم کاربرد گسترده و ترویج بسیار زیاد این نوع مدل‌سازی

می‌شود. منطق اساسی و ریاضی این روش‌ها، بر اصلاح واریانس است به‌طوری‌که واریانس حاصل از ادغام مدل‌های مختلف با واریانس مشاهدات بسیار هم‌خوانی داشته باشد (Rezaei et al., 2022). در میانگین‌گیری می‌توان به روش‌های میانگین وزن‌دهی شده (Weighted Averaging Modeling- WAM) و میانگین‌گیری بیزی (Bayesian Model Averaging- BMA) اشاره کرد. در این روش‌ها یک میانگین حسابی از خروجی روش‌های مختلف تولید می‌شود که نسبت به مدل‌های ورودی، از دقت و عملکرد بهتری برخوردار است. مهم‌ترین وجه تمایز روش‌های WAM و BMA در چگونگی تخمین وزن مدل‌های ورودی است. در مدل WAM از یک بهینه‌سازی خطی با تابع هدف حداقل مربعات جهت تخمین وزن استفاده می‌شود. در حالی‌که، در روش BMA یک مفهوم احتمالاتی مبتنی بر قانون بیز (Bayes Theorem) جهت تخمین وزن مدل‌های ورودی به کار گرفته می‌شود. به‌روزترین رویکرد مدل‌سازی گروهی، یادگیری گروهی ماشین (Ensemble Learning Machine- ELM) است که روش‌های Boosting و Bagging از جمله مهم‌ترین آن‌ها به شمار می‌رود. منطق اساسی این دسته از مدل‌سازی گروهی، ارتقای خروجی شبیه‌سازی یک ماشین یادگیری پایه هم‌زمان با فرآیند مدل‌سازی است (Zounemat-Kermani et al., 2021). در این روش‌ها، از یک فرآیند یادگیری تکراری که به رویکردهای متفاوتی نظیر نمونه‌گیری و یادگیری نظارتی مجهز شده است، استفاده می‌شود تا تعداد بسیار زیادی خروجی تولید شود. در نهایت نیز با در نظر گرفتن تمام جوانب، یک خروجی مورد وفاق تولید می‌شود.

به‌دلیل توسعه روز افزون کاربرد هوش مصنوعی و کاربرد چشم‌گیر آن در علوم مختلف، به‌طور خاص مهندسی آب، توجه بسیاری از علاقمندان مدل‌سازی گروهی به سمت استفاده از یادگیری گروهی ماشین جلب شده است (Zounemat-Kermani et al., 2021). یادگیری گروهی، از جمله روش‌های پرکاربرد و موثر در هوش مصنوعی است که با ادغام چندین

گروهی بر پایه یادگیری ماشین توسعه بسیار چشم‌گیری داشته است که البته در حوزه نیاز آبی زعفران، زیاد مورد توجه قرار نگرفته است. همچنین، توجه به نیاز آبی زعفران، خود یکی دیگر از جنبه‌های نوآوری این پژوهش است که مطالعات گذشته از آن غفلت کرده‌اند. در این پژوهش کوششی نو در زمینه معرفی مدل‌سازی گروهی انجام شده است و تلاش بر این است که با ارائه نتایج کاربردی یک راهنمایی مناسب جهت پیاده‌سازی و انتخاب درست روش‌های موجود صورت بگیرد.

مواد و روش‌ها

منطقه مورد مطالعه

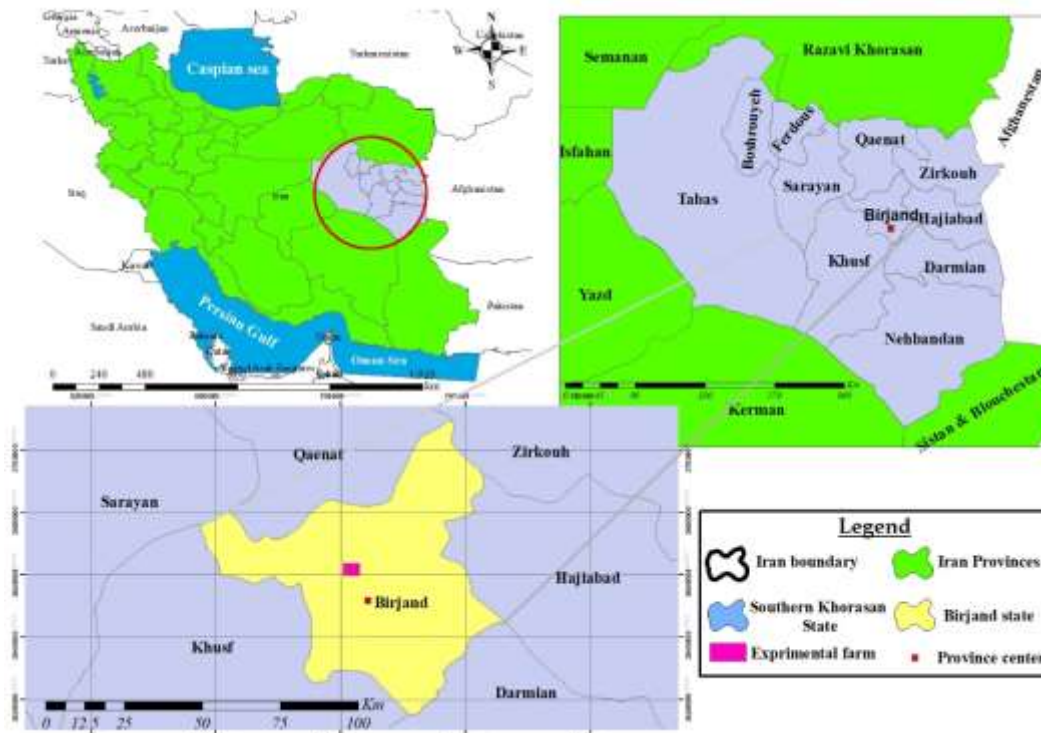
شهر بیرجند مرکز استان خراسان جنوبی در شمال رشته کوه‌های باقران و در محدوده‌ی ۵۹ درجه و ۱۳ ثانیه طول جغرافیایی و با ۳۲ درجه و ۵۳ ثانیه عرض جغرافیایی قرار گرفته است (شکل ۱). در حال حاضر، به دلیل پیامدهای تغییر اقلیم و گرمایش جهانی، مقدار بارندگی سالانه در محدوده مطالعاتی بیرجند به زیر ۱۰۰ میلی‌متر در سال کاهش پیدا کرده است. این در حالی است که، مقدار مقدار بارش سالانه براساس دوره بازگشت درازمدت ۳۰ ساله حدود ۱۵۰ میلی‌متر گزارش شده است. همچنین، متوسط دمای سالانه منطقه حدود ۱۶/۵ درجه سانتی‌گراد و متوسط تبخیر پتانسیل سالانه تقریباً ۲۶۸۰ میلی‌متر برآورد می‌گردد. براساس شاخص اقلیمی امبرژه و دومارتن، اقلیم منطقه از نوع خشک و بیابانی است (Nazeri Tahroudi & Ramezani, 2021).

نیاز آبی زعفران

به‌منظور اندازه‌گیری نیاز آبی زعفران، از داده‌های اندازه‌گیری شده نیاز آبی در سال دوم کشت زعفران در آزمایشگاه لایسی‌متر دانشگاه بیرجند استفاده شد.

گروهی، هنوز کارایی این روش در زمینه بهبود نتایج نیاز آبی محصولات کشاورزی مورد بررسی عمیق قرار نگرفته است. جمع‌بندی مطالب فوق نشان می‌دهد که پژوهش‌های بیشتری در خصوص بررسی مدل‌سازی گروهی، علی‌الخصوص روش Boosting، در مطالعات تخمین نیاز آبی محصولات کشاورزی مورد نیاز است. این موضوع در خصوص زعفران، راهبردی‌ترین محصول کشاورزی شرق کشور، دو چندان است. در حال حاضر، در بیشتر مناطق شرق کشور امکانات آزمایشگاهی جهت اندازه‌گیری دقیق نیاز آبی زعفران وجود ندارد و عموماً ضرایب گیاهی برآورد شده در مزارع تحقیقاتی به کل منطقه تعمیم داده می‌شود که نتیجه‌ای جز انتشار عدم قطعیت در محاسبات را نخواهد داشت. در چنین شرایطی، یکی از بهترین راه‌حل‌های ممکن استفاده از هوش مصنوعی جهت تخمین نیاز آبی زعفران. فناوری هوش مصنوعی این قابلیت را دارد تا با استفاده از از داده‌های واقعی و طی فرآیند آموزش ارتباط درونی بین ورودی‌های مشخص و خروجی مدنظر را کشف کند و در شرایطی که صرفاً داده‌های ورودی موجود است میزان خروجی مطلوب را شبیه‌سازی کند. راه‌حل پیشنهادی این پژوهش برای پاسخ به این نگرانی که طول کم نمونه‌های موجود در مدل‌سازی نیاز آبی می‌تواند از عملکرد هوش مصنوعی بکاهد، استفاده از مدل‌سازی گروهی است. این حقیقت، جایگاه و اهمیت مدل‌سازی گروهی را جهت بهبود نتایج شبیه‌سازی نیاز آبی زعفران کاملاً مشخص می‌کند.

بررسی مطالعات مربوطه دلالت بر این دارد که به کاربرد مدل‌سازی گروهی برای ارتقای نتایج شبیه‌سازی نیاز آبی محصولات کشاورزی، به‌خصوص زعفران، زیاد توجه نشده است و برای مشخص شدن جنبه‌های مختلف این نوع از مدل‌سازی پژوهش‌های بیشتری لازم است. از طرف دیگر بررسی آخرین دست‌آوردهای مدل‌سازی گروهی تأکید می‌کند که مدل‌سازی



شکل ۱- نقشه جغرافیایی نمایش دهنده‌ی منطقه مورد مطالعه
Figure 1- Geographic map showing the location of case study.

یک ماه بعد اولین آبیاری بنه‌های زعفران انجام شد و پس از ۱۰ روز بنه‌ها شروع به گل‌دهی کردند که این مرحله ۲۵ روز طول کشید. آبیاری با تناوب هفت روز و به روش کرتی انجام شد و آب مورد نیاز از طریق لوله‌کشی به هر کدام از لایسی‌مترها انتقال داده شد. همچنین، میزان آب اختصاص داده شده به هر کدام از لایسی‌مترها از طریق یک کنتور حجمی ثبت شد. دوره آبیاری و فصل رشد زعفران در سال دوم کشت از تاریخ ۱۸ آبان ۱۳۹۹ آغاز شد و تا تاریخ ۱۷ اردی‌بهشت ۱۴۰۰ ادامه داشت که در این مدل تعداد چهار بارش با حجم $21/3$ میلی‌متر در منطقه مورد مطالعه به وقوع پیوست. در طی این مدت میزان رطوبت موجود در داخل هر لایسی‌متر با یک دستگاه رطوبت سنج (TDR 150 Spectrum) اندازه‌گیری شد تا اطمینان حاصل شود که همواره رطوبت در حد ظرفیت زراعی در اختیار گیاه قرار

توصیف مشخصات لایسی‌مترها در ادامه همین قسمت تشریح می‌شود: بدین منظور، تعداد سه لایسی‌متر دایره‌ای پلیمری جهت برآورد نیاز آبی زعفران و سه لایسی‌متر جهت برآورد نیاز آبی چمن (به‌عنوان گیاه مرجع) پیاده‌سازی شد (شکل ۲). قطر لایسی‌مترها و ارتفاع آن‌ها به ترتیب $0/9$ و ۱ متر در نظر گرفته شد. در انتهای هر لایسی‌متر یک شیب $6/7$ درصدی اعمال شد و ۱۵ سانتی‌متر انتهایی آن با گراول دانه درشت پر شد تا شرایط را برای زهکشی بهتر فراهم کند. در حین حفاری ترانسه‌های لایسی‌مترها، تمام نمونه‌های خاک برداشت شده به مکان اول خودش برگردانده شد. تحلیل مؤلفه‌های کیفی خاک منطقه نشان می‌دهد که بافت غالب منطقه لومی است. کشت زعفران در تاریخ ۱۰ شهریور ۱۳۹۷ با تراکم شش تن در هکتار و در عمق ۱۷ الی ۲۵ سانتی‌متری سطح زمین انجام شد. درست

شرایط بدون تبخیر، در همان ابتدای کشت و احداث لایسی مترها، یکی از لایسی مترهای بدون گیاه را تا حد اشباع آبیاری کرده و بعد از گذشت مدت زمان ۲۴ ساعت، مقدار رطوبت لایسی متر اندازه گیری شد تا از این طریق مقدار رطوبت ظرفیت زراعی بدون تبخیر به درستی برآورد گردد.

دارد (شکل ۲). علاوه بر این، آب زهکش شده در انتهای هر لایسی متر درون یک تانک ۲۰ لیتری ذخیره شده و همزمان با اندازه گیری رطوبت خاک، مقدار آب زهکش شده نیز ثبت می گردید. باید توجه داشت که در این آزمایشگاه، به منظور اطمینان از تعیین درست رطوبت در حد ظرفیت زراعی و در



شکل ۲- نمایش توصیفی از آزمایشگاه لایسی متر دانشگاه بیرجند

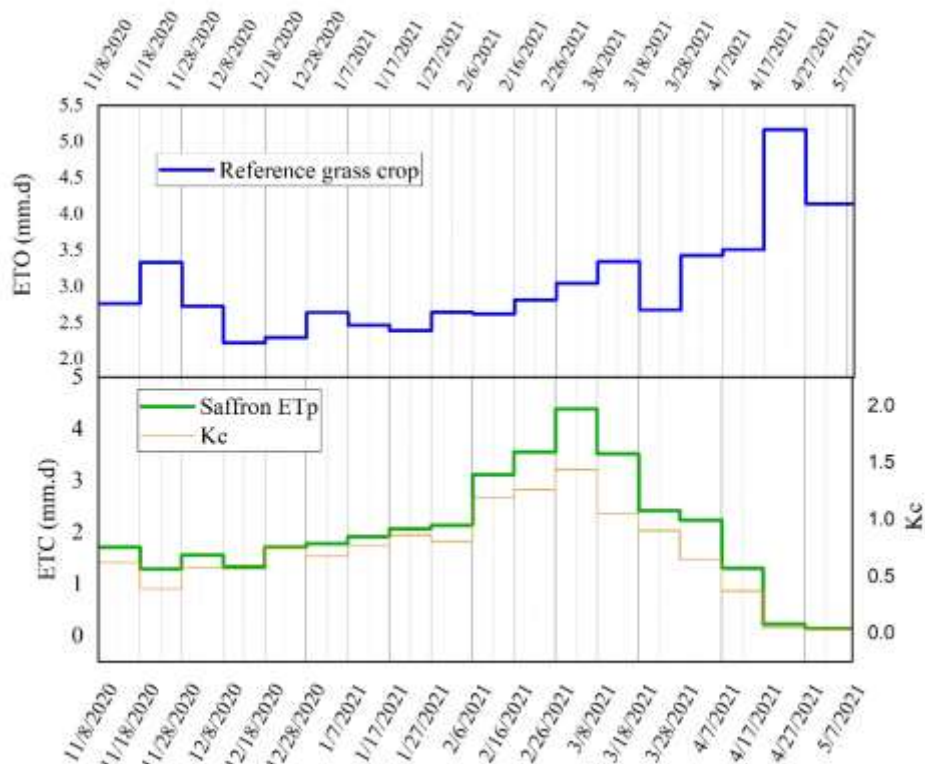
Figure 2- Descriptive illustration of lysimetric laboratory facilities implemented in the University of Birjand.

شد. شکل (۳) مقادیر اندازه گیری شده تبخیر- تعرق پتانسیل (ET_o- نیاز آبی گیاه مرجع چمن)، نیاز آبی گیاه زعفران (ET_c- Saffron ET_p) و ضرایب گیاهی این محصول را نشان می دهد. براساس داده های اندازه گیری شده در محل آزمایشگاه تحقیقاتی دانشگاه بیرجند، مقدار ET_o و ET_c برای سال دوم کشت به ترتیب ۵۴۳ و ۳۶۵ میلی متر برآورد گردیده است. لازم به ذکر است که کیفیت و دقت داده های ثبت شده در آزمایشگاه لایسی متر پیش از این و در پژوهش هایی نظیر Khashei Siuki et al. (2020) بررسی و صحت آن ها مورد تأیید قرار گرفته است.

به منظور برآورد نیاز آبی زعفران و چمن با استفاده از معادله بیلان رطوبتی در داخل هر لایسی متر، مقدار نیاز آبی هر محصول طبق رابطه ی زیر محاسبه شد:

$$ET_c = I + P - D \pm \Delta s \quad (1)$$

در این رابطه، ET_c: مقدار نیاز آبی محصول (mm)، I: مقدار آب آبیاری (mm)، P: مقدار بارش (mm)، D: محتوای آب زهکشی شده (mm) و Δs: اختلاف محتوای رطوبتی خاک (mm) را نشان می دهد. مقدار نیاز آبی برای چمن و زعفران در هر هفته و برای هر لایسی متر اندازه گرفته شد و پس از انتهای دوره میانگین نیاز آبی سه لایسی متر در مقیاس ۱۰ روزه محاسبه



شکل ۳- نمایشی از مقادیر اندازه‌گیری شده تبخیر- تعرق پتانسیل (ردیف اول) و نیاز آبی زعفران (ردیف دوم مشخص شده با خط سبز) در کنار ضرایب گیاهی برآورد شده (ردیف دوم مشخص شده با خط نارنجی)

Figure 3- Description of actual ETO (blue line showed on first panel) and saffron water requirement (green line showed on second panel) along with evaluated crop coefficients (orange line showed on second panel).

نهایی با دقت و قابلیت بالاتر تولید می‌شود. یکی از مشهورترین الگوریتم‌های Boosting، الگوریتم AdaBoost (Adjusting Freund and Boosting) است که در سال ۱۹۹۷ توسط Freund and Schapire معرفی شد (Freund et al., 1999). همچنین شاخه‌های دیگری از این روش وجود دارند که از جمله آن‌ها می‌توان به Gradient Boosting و eXtreme Gradient Boost (XGBoost) اشاره کرد. در این روش‌ها، مجموعه‌ای از خروجی چندین یادگیرنده ضعیف ایجاد می‌شود که با ترکیب آن‌ها، یک یادگیرنده قوی با دقت بالا تولید می‌شود.

روش کار این الگوریتم بدین گونه است که در ابتدا لازم است برای شبیه‌سازی یک مجموعه‌ی داده، یک ماشین

یادگیری گروهی ماشین (ELM)

در این پژوهش دقت و عملکرد روش ELM در زمینه بهبود نتایج ماشین یادگیری مورد ارزیابی قرار گرفت که توضیحات لازم به تفکیک روش‌های استفاده شده در ادامه ارائه شده است:

روش Boosting

این الگوریتم یکی از روش‌های مهم در حوزه یادگیری ماشین است که قادر است الگوریتم‌های یادگیری ضعیف را به الگوریتم‌های قوی تبدیل کند. در این روش، در هر مرحله، یک یادگیرنده ضعیف با دقت کم ایجاد می‌شود و با تمرین و اعمال تنظیمات تکراری، از خطاهای آن کاسته می‌شود. سپس، با ترکیب تخمین‌های این یادگیرنده‌های ضعیف، یک پیش‌بینی

در طی فرآیند یادگیری گروهی با آموزش روی داده‌های ارائه شده، خروجی مدنظر را شبیه‌سازی کند. در این پژوهش به منظور تحقق این امر از رگرسیون درخت تصمیم استفاده شد (Decision Tree Regression- DTR). عملکرد بسیار موفق این روش در مطالعات مشابه قبلاً به دفعات زیادی گزارش شده است (Wei et al., 2019; Pekel et al., 2020; Asadollah et al., 2021). همچنین، دو رویکرد کلی یادگیری گروهی در ابتدا روی DTR پیاده‌سازی شده‌اند و از این منظر انتظار می‌رود که ترکیب یادگیری گروهی با این ماشین یادگیری سازگاری بیشتری داشته و به احتمال زیاد منجر به اعتمادپذیری بیشتر نتایج خواهد شد.

رگرسیون درخت تصمیم (DTR)

توصیف گام‌های عملیاتی این روش همراه با ارائه یک پیشینه در مورد پیدایش، توسعه و آخرین دستاوردهای آن در مطالعاتی نظیر (Tso & Yau (2007)، ارائه شده است که جهت اطلاعات بیشتر توصیه می‌شود به آن‌ها مراجعه شود. با این وجود، یک توضیح مختصر راجب چگونگی عملکرد و مراحل این روش در این قسمت آورده شده است: ۱- تعیین نقطه شکست در هر سری از داده‌های ورودی: هر کدام از متغیرهای ورودی باید در نقطه‌ای به دو قسمت مجزا تقسیم بشوند به طوری که میانگین هر قسمت کمترین میزان خطا را با میانگین متغیر خروجی داشته باشد. برای این کار لازم است تا کلیه داده‌ها در هر کدام از متغیرهای ورودی به صورت نزولی مرتب شوند. ۲- تعیین گره ریشه: در این مرحله لازم است تا از بین متغیرهای ورودی، مؤلفه‌ای که بهترین حالت تقسیم‌بندی بوسیله آن ایجاد می‌شود، تعیین شود. در مطالعات رگرسیون که با داده‌های پیوسته سری زمانی مواجه است عموماً این موضوع با استفاده از شاخص کاهش انحراف معیار (-Standard Deviation Reduction SDR) انجام می‌شود:

یادگیری به‌عنوان یادگیرنده ضعیف (Weak Learner Machine- WLM) انتخاب شود. سپس با استفاده از داده‌ها، ماشین یادگیری ضعیف اقدام به شبیه‌سازی می‌کند و خطای پیش‌بینی محاسبه می‌شود. در مرحله بعد، داده‌هایی که توسط WLM نادرست پیش‌بینی شده‌اند، به عنوان داده‌های ورودی برای آموزش مرحله بعدی استفاده می‌شوند. هدف این است که ماشین یادگیری در مرحله دوم خطاهای نادرست مرحله قبل را نداشته باشد. این مراحل تا زمانی که یک مدل قوی با دقت بالا به دست آید، تکرار می‌شوند. در نهایت، از یک رویکرد میانگین‌گیری برای تولید خروجی نهایی استفاده می‌شود.

روش Bagging

در روش (Bagging (Bootstrap Aggregating)، چندین مدل به صورت مجزا برای آموزش مجموعه‌ی داده‌ها به صورت همزمان انتخاب می‌شوند. در واقع، چندین WLM در همان ابتدا فرض می‌شود و هر کدام به صورت مجزا اقدام به شبیه‌سازی می‌کنند. در نهایت نیز مشابه روش Boosting از یک رویکرد میانگین‌گیری برای تخمین نهایی استفاده می‌شود (Guidotti et al., 2018).

مراحل اجرای این الگوریتم بدین شرح است که در گام نخست لازم است تعدادی زیرمجموعه تصادفی و با جایگزینی از مجموعه داده‌های اولیه تولید شود (Bootstrapping). در گام دوم، هر کدام از زیرمجموعه‌های تولید شده با استفاده از ماشین یادگیری ضعیف آموزش داده می‌شود (Training). در گام آخر، پیش‌بینی‌های حاصل از همه مدل‌ها با یکدیگر ترکیب شده و به عنوان پیش‌بینی نهایی ارائه می‌شود. این ترکیب معمولاً با یکی از دو روش میانگین‌گیری حسابی یا رأی اکثریت (Majority voting) انجام می‌شود.

همان‌گونه که در فوق بدان اشاره شد، در یادگیری گروهی لازم است تا در گام نخست یک ماشین یادگیری تعیین شود تا

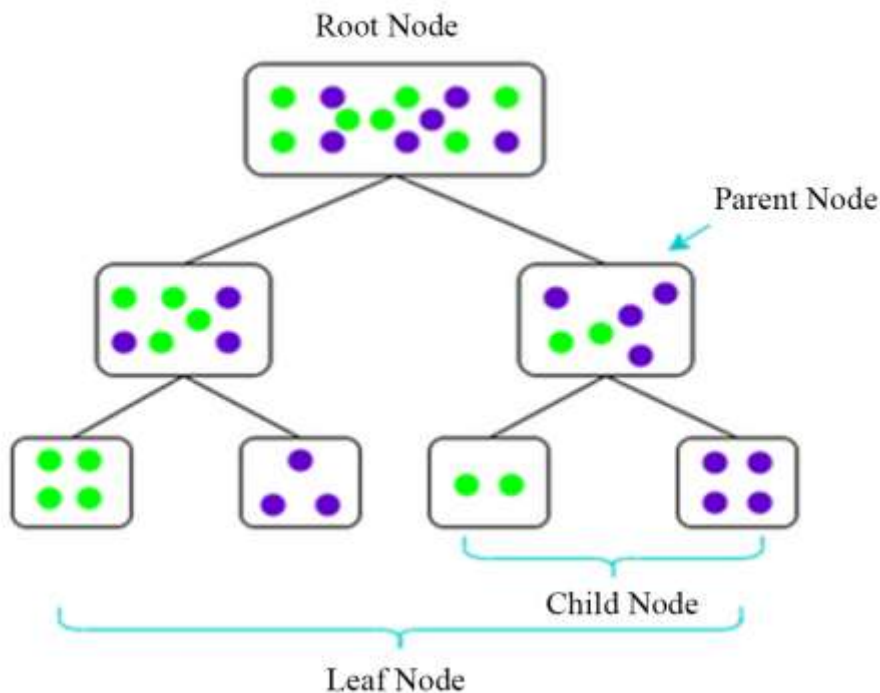
شکست مابقی داده‌ها به دو شاخه تقسیم می‌شوند. در ادامه برای هر شاخه، این فرآیند برای متغیری بعدی (براساس SDR) تکرار می‌شود. در تقسیم‌بندی هر متغیر، معیار مقدار نقطه شکست است و براساس آن خروجی برآورد می‌شود. چنانچه در شاخه یک متغیر، داده‌های متغیر بعدی همه در یک طبقه قرار داشته باشند، فرآیند تقسیم‌بندی متوقف می‌شود. مقدار خروجی در این حالت از روی مقدار میانگین خروجی که در آخرین طبقه قرار گرفته است، محاسبه می‌شود. به گره‌هایی که در نتیجه تقسیم‌بندی آن‌ها دو شاخه ایجاد می‌شود، گره مادر و به گره‌هایی که امکان ایجاد شاخه در آن‌ها وجود ندارد، گره فرزند اطلاق می‌شود. مقدار خروجی نیز در آخرین گره نمایش داده می‌شود که از آن با گره برگ یاد می‌شود.

$$SDR^1 = SD_t - SD_{tx}^1 \quad (2)$$

where,

$$SD_{tx}^1 = SD_1 \cdot \frac{N_1}{N_t} + SD_2 \cdot \frac{N_2}{N_t}$$

که در آن SD_t : انحراف معیار متغیر خروجی با تعداد N_t داده است و SD_{tx}^1 مقدار انحراف معیار وزن‌دهی شده هر کدام از متغیرهای ورودی به‌ازای هر کدام از دسته‌های آن را توصیف می‌کند. در واقع، یک متغیر ورودی با در نظر گرفتن نقطه‌ی شکست به دو بخش (طبقه) تقسیم می‌شود که طبقه اول دارای N_1 داده با انحراف معیار SD_1 و طبقه دوم دارای N_2 داده با انحراف معیار SD_2 خواهد بود. براساس این شاخص، متغیری به‌عنوان گره ریشه انتخاب می‌شود که مقدار برای آن از بقیه SD^1 متغیرهای ورودی بیشتر باشد. ۳- فرآیند درخت تصمیم از روی تقسیم‌بندی گره ریشه ابتدا آغاز شده و براساس نقطه‌ی



شکل ۴- نمایش مفاهیم اساسی در مدل‌سازی درخت تصمیم (اقتباس شده از Tso & Yau, 2007).
Figure 4- Illustration of key features defined in DTR (modified from Tso & Yau, 2007).

پیااده‌سازی مدل

در این قسمت سعی شده است تا مروری کلی روی گام‌های عملیاتی صورت گرفته در این پژوهش انجام شود و مراحل روش بکار گرفته شده به صورت نمایشی و توصیفی تشریح گردد. در پژوهش حاضر، ابتدا یک مجموعه داده از مؤلفه‌های اقلیمی شامل دمای حداقل و حداکثر روزانه و رطوبت نسبی حداقل و حداکثر روزانه برای منطقه مورد مطالعه جمع‌آوری شد. داده‌های اقلیمی مدنظر از ایستگاه هواشناسی هوشمند واقع در آزمایشگاه هواشناسی دانشگاه بیرجند گردآوری شد. در ادامه، داده‌های اندازه‌گیری شده نیاز آبی زعفران در آزمایشگاه لایسی‌متر (به‌عنوان خروجی) و داده‌های اقلیمی (به‌عنوان ورودی) به مقیاس میانگین ده روزه تبدیل شد. بازه زمانی شبیه‌سازی متناسب با سال دوم کشت زعفران از تاریخ ۷ ابان ۱۳۹۹ لغایت ۱۷ اردی‌بهشت ۱۴۰۰ در نظر گرفته شد (شامل ۱۸۰ روز). برای شبیه‌سازی نیاز آبی زعفران، سری زمانی داده‌های اقلیمی در کنار داده‌های اندازه‌گیری شده نیاز آبی زعفران به مدل DTR داده شد. قبل از پیاده‌سازی مدل درخت تصمیم، اقدامات پیش‌پردازش شامل استانداردسازی، ارزیابی وضعیت پایایی و تحلیل روند، حذف داده‌های پرت و تخمین داده‌ها مفقود روی کلیه اطلاعات متغیرهای ورودی و خروجی صورت پذیرفت و از صحت آن‌ها اطمینان حاصل شد. پس از مدل‌سازی نیاز آبی زعفران توسط مدل DTR عملکرد دو رویکرد Boosting و Bagging به منظور بهبود نتایج شبیه‌سازی مورد ارزیابی قرار گرفت. به منظور کمی کردن کارایی مدل‌سازی گروهی در تخمین نیاز آبی زعفران از آزمون‌های مقایسه‌ای متنوع و متعددی استفاده شد تا تمایزهای موجود به خوبی مشخص شود. این آزمون‌ها شامل شاخص‌های ارزیابی (RMSE)، مقایسه توزیع کرنل و پراکنش داده‌ها (مقایسه وایولین Violin plot)،

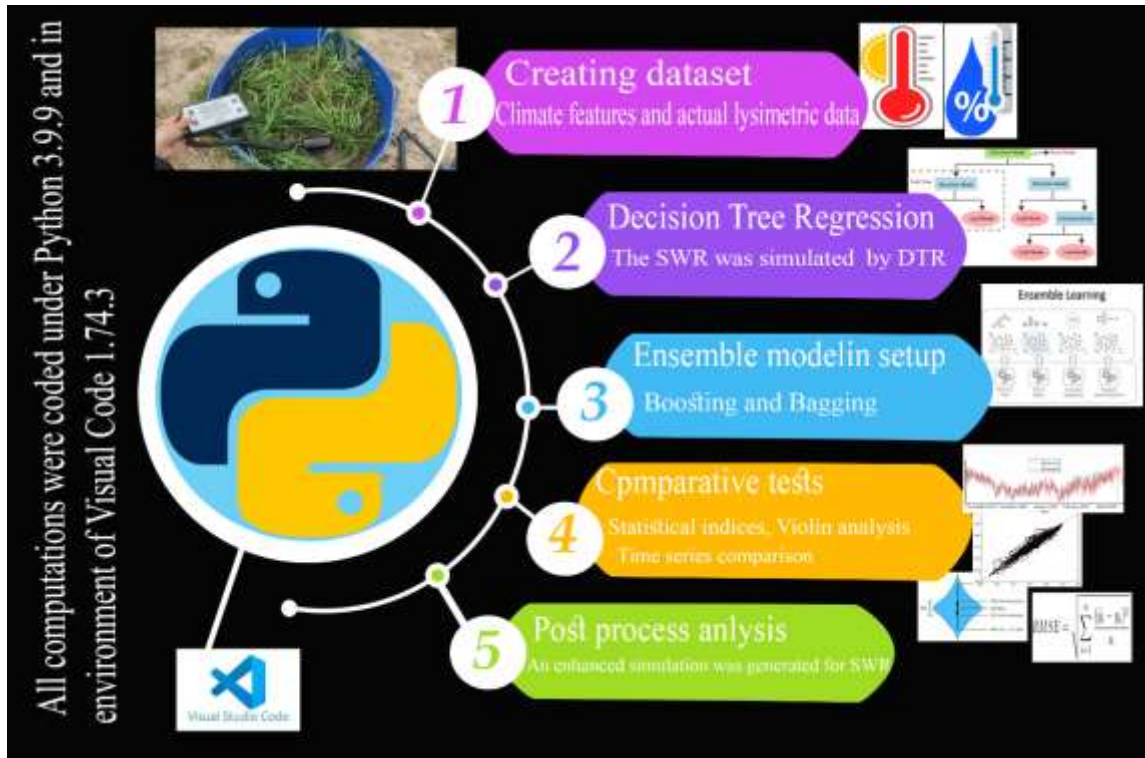
ارزیابی کم/بیش تخمینی، مقایسه سری زمانی و تحلیل بهبود خطا می‌شود. لازم به ذکر است که کلیه گام‌های محاسباتی این پژوهش برپایه زبان Python 3.9.9 و در محیط Visual Studio Code 1.74.3 کدنویسی شد. شکل ۵ یک شمای کلی از گام‌های شرح داده شده را نشان می‌دهد.

نتایج و بحث

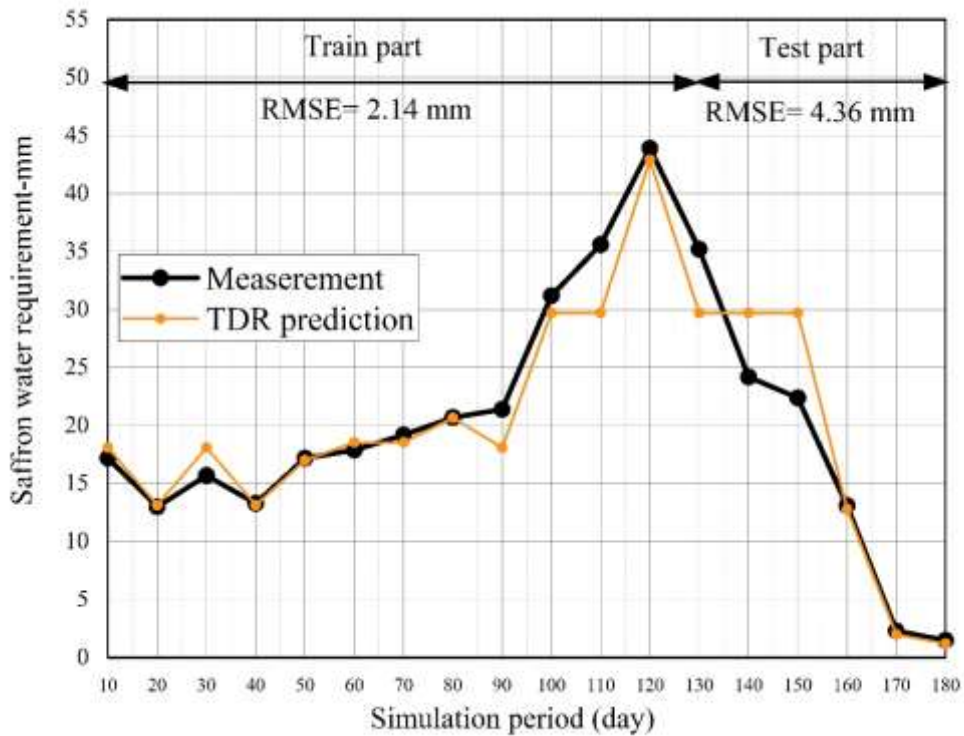
بررسی دقت مدل درخت تصمیم در شبیه‌سازی نیاز آبی زعفران و ارزیابی میزان کارایی مدل‌سازی گروهی در بهبود نتایج در این قسمت به تفکیک ارائه شده است و ضمن تشریح نتایج بدست آمده، مقایسه یافته‌های مطالعات مشابه با نتایج این پژوهش در دستور کار قرار گرفت.

ارزیابی عملکرد مدل درخت تصمیم

نتایج بدست آمده از کاربست مدل درخت تصمیم در این قسمت به نمایش در آمده است. در این پژوهش داده‌های مربوط نیاز آبی و متغیرهای ورودی در ۱۲۰ روز ابتدایی برای دوره آموزش و داده‌ها در ۶۰ روز نهایی دوره کشت برای دوره آزمایش در نظر گرفته شد. در ادامه شکل ۶ یک مقایسه نمایشی از مقدار واقعی سری زمانی نیاز آبی زعفران را در برابر مقادیر شبیه‌سازی شده نشان می‌دهد. شاخص RMSE مندرج شده روی نمودار دقت و کارایی مدل DTR را در شبیه‌سازی نیاز آبی زعفران در سال دوم کشت نشان می‌دهد. مجموع کل نیاز آبی واقعی زعفران برای سال دوم کشت ۳۶۵ میلی‌متر اندازه‌گیری شد در حالی، که مقدار برآورد شده توسط درخت تصمیم ۳۶۲ میلی‌متر در سال است.



شکل ۵- توصیف نمایشی گام‌های عملیاتی استفاده شده در مطالعه حاضر
Figure 5- Illustrative description of work flow implemented in current study.

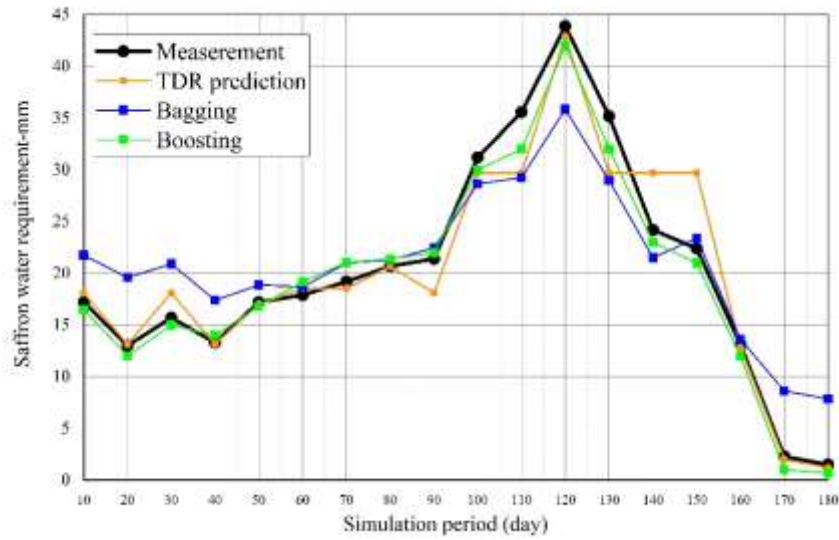


شکل ۶- نمایش سری زمانی نیاز آبی زعفران اندازه‌گیری شده و شبیه‌سازی شده در سال دوم کشت
Figure 6- Time series comparison of actual and simulated water requirement of the second growing year.

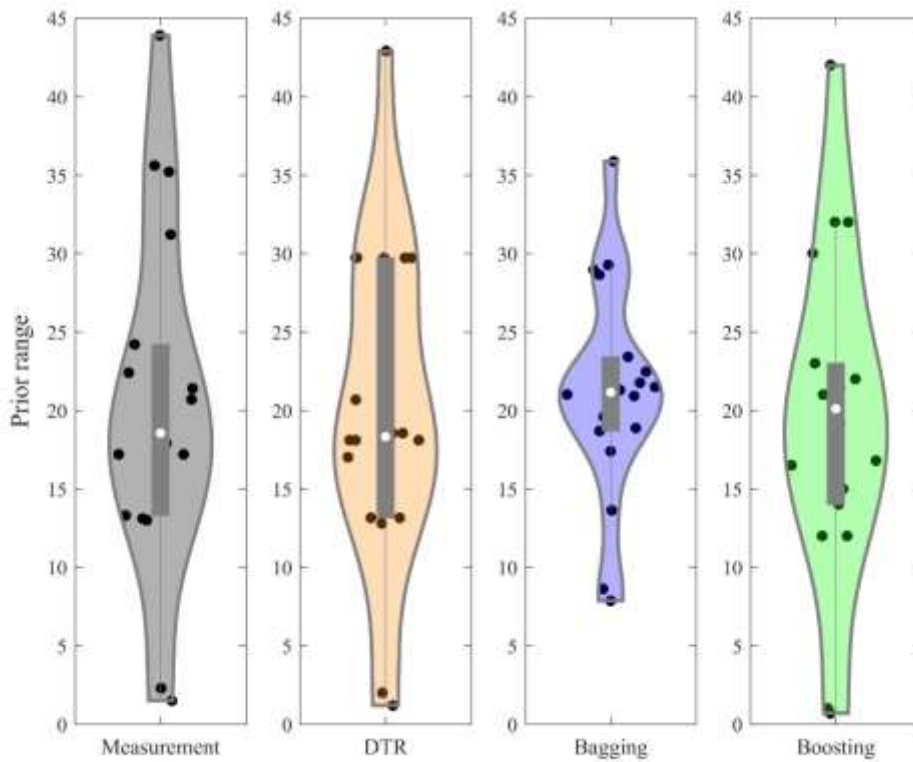
در این قسمت توانمندی روش‌های Bagging و Boosting در بهبود نتایج مدل درخت تصمیم ارائه شده است. به‌عنوان اولین آزمون مقایسه‌ای، به مقایسه سری زمانی نیاز آبی پرداخته شد. شکل ۷ مقایسه نمایشی نیاز آبی اندازه‌گیری شده، شبیه‌سازی شده توسط مدل درخت تصمیم و خروجی یادگیری گروهی ماشین را نشان می‌دهد. براساس نتایج بدست آمده کاملاً مشخص است که کاربست مدل Boosting موجب ارتقای نتایج شده و در نهایت شبیه‌سازی بهتری را ارائه می‌کند. مقدار شاخص RMSE برای روش Boosting و مقدار شاخص RMSE به ترتیب معادل ۰/۰۷ و ۰/۴۵ میلی‌متر برآورد گردید. یکی از بهترین آزمون‌های مقایسه‌ای در مدل‌سازی‌های پیوسته سری زمانی، مقایسه توزیع پراکنش داده‌ها است. نمودار واپولین یکی از ابزارهای نمایش پراکنش و توصیف وضعیت آماری داده‌ها است. این نمودار ترکیبی از وضعیت پراکنش داده‌ها و نمودار جعبه‌ای (Box plot) است که در ادامه از آن جهت مقایسه ماهیت و کیفیت مقادیر شبیه‌سازی شده در مقابل مقادیر اندازه‌گیری شده استفاده شد. عملکرد بهتر روش Boosting نسبت به روش Bagging کاملاً در این نمودار مشخص است. مقایسه کیفیت تخمین در مقادیر نهایی نیاز آبی شبیه‌سازی شده در سه خروجی مدل تصمیم، روش Boosting و Bagging انجام شد و به‌صورت نمایشی در شکل (۹) به نمایش گذاشته شده است. بر اساس نتایج بدست آمده کیفیت خروجی بدست آمده از روش Boosting بسیار به مقادیر اندازه‌گیری شده نزدیک‌تر است. فاصله بین بیشترین و کمترین تخمین با یک نشان‌گر آبی عمودی مشخص شده است که ثابت می‌کند خطای تخمین در خروجی بدست آمده از یادگیری گروهی Boosting بسیار کمتر از درخت تصمیم و روش Bagging است. این موضوع به‌خوبی اثر مدل‌سازی گروهی را در بهبود نتایج هوش مصنوعی در زمینه تخمین نیاز آبی زعفران نشان می‌دهد.

بررسی نتایج بدست آمده از سایر پژوهش‌های مربوطه در خصوص کارایی مدل DTR حاکی از آن است که هم‌خوانی خوبی بین نتایج بدست آمده وجود دارد. به‌عنوان مثال، در پژوهشی، (Khan et al. (2012)، به دقت و کارایی بالاتر درخت تصمیم در مقایسه با شبکه عصبی و رگرسیون بردار پشتیبان در شبیه‌سازی نیاز آبی اشاره شده است. در یک پژوهش نسبتاً جدید، (Perea et al. (2019)، که از ترکیب الگوریتم ژینتیک و درخت تصمیم جهت تخمین نیاز آبی محصولات ذرت، گوجه و برنج در شمال غرب اسپانیا استفاده شده بود، عملکرد خوب این ماشین یادگیری گزارش شده است. علاوه‌بر این، به‌وفور مطالعاتی وجود دارند که در آن‌ها به عملکرد بهتر مدل DTR در مقایسه با سایر ماشین‌های یادگیری اشاره شده است. در مطالعه‌ای اذعان شده است، (Asadollah et al. (2021)، که عملکرد مدل درخت تصمیم در مقایسه با مدل رگرسیون بردار پشتیبان در حوزه شبیه‌سازی محتوای کیفی جریان رودخانه بسیار بهتر و بالاتر بوده است. شاید بتوان گفت که یکی از علت‌های کاربرد زیاد درخت تصمیم در مطالعات هوش مصنوعی، عدم پیچیدگی این ماشین یادگیری بوده. چراکه عملاً در این روش فرآیند بهینه‌سازی یا آموزش ماشین یادگیری به‌گونه‌ای که در سایر مدل‌ها متعارف است، وجود ندارد و کاربر بیشتر با یک فرآیند تقسیم‌بندی مبتنی بر گزاره‌های ریاضی مواجه است. عملاً در فرآیند شبیه‌سازی درخت تصمیم فرآیند خاصی برای تخمین وزن‌ها (مشابه آنچه در شبکه عصبی است) و یا انتخاب و تخمین پارامترهای تأثیرگذار در توابع کرنل (مشابه آنچه در ماشین بردار پشتیبان است)، وجود ندارد و خروجی نهایی صرفاً براساس تقسیم‌بندی ورودی‌ها مشخص می‌شود (Gibert et al., 2018).

ارزیابی عملکرد مدل‌سازی گروهی




شکل ۷- مقایسه سری زمانی نیاز آبی زعفران در مقابل خروجی درخت تصمیم و یادگیری گروهی
 Figure 7- Time series comparison of actual water requirement versus ensemble modelling outputs.



شکل ۸- تحلیل وایولین جهت مقایسه توزیع، آماره‌های توصیفی و تراکم داده‌های واقعی و شبیه‌سازی شده توسط درخت تصمیم و یادگیری گروهی

Figure 8- Violin plot analysis to depict distribution, descriptive statistics, and density of actual water requirement along with DTR and ensemble modeling.



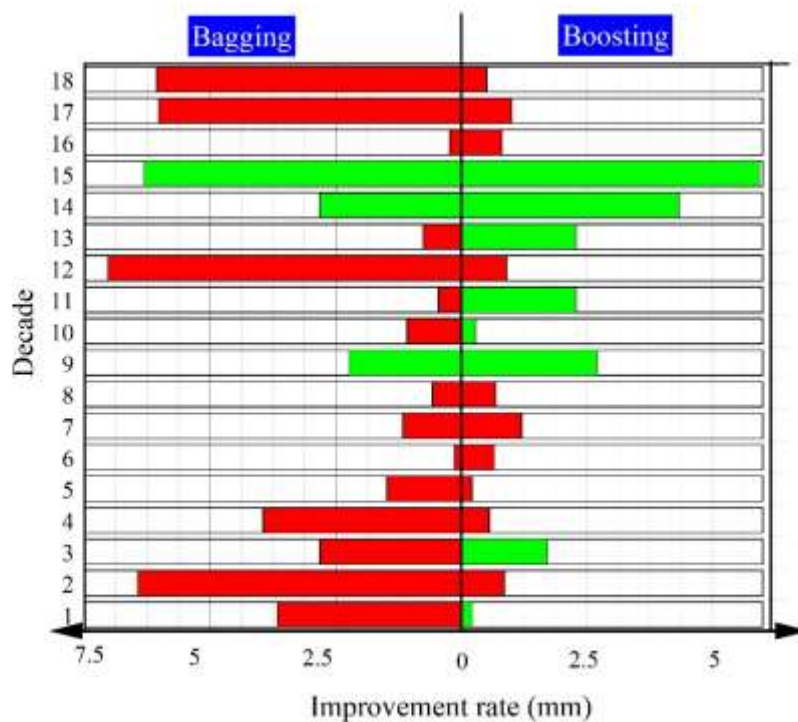
شکل ۹- نتایج تحلیل کم/بیش تخمینی خروجی مدل درخت تصمیم در مقایسه با خروجی یادگیری گروهی
Figure 9- Over/underestimation analysis of DTR prediction versus outputs of ensemble modelling.

است. در این نمودار میزان بهبود قدرمطلق خطا برای هر دهه و به تفکیک روش‌های Bagging و Boosting مشخص شده است (رنگ سبز نشان دهنده‌ی کاهش و قرمز افزایش قدرمطلق خطا را نشان می‌دهد). براساس این نمودار میزان بهبود قدرمطلق خطای روش درخت تصمیم بعد از استفاده از مدل‌سازی گروهی Boosting بادر نظر گرفتن کل بازه شبیه‌سازی، $۱۲/۳۴$ میلی‌متر بوده است ($۱۹/۶۸$ میلی‌متر بهبود و $۷/۳۴$ میلی‌متر افزایش خطا). این نتایج به‌طور مشابه برای روش Bagging نیز قابل درک است با این تفاوت که در این روش مقدار افزایش خطا بسیار بیشتر از بهبود خطا بوده است.

به‌منظور مقایسه بهتر، میزان خطای تخمین اتفاق افتاده در خروجی بدست آمده از مدل درخت تصمیم و نتایج مدل‌سازی گروهی به تفکیک هر دوره در جدول ۱ درج شده است. براساس نتایج بدست آمده مشخص می‌شود که یادگیری گروهی بر پایه روش Boosting توانسته است تخمین نهایی را تا حد بسیار زیادی بهبود بخشد. به‌طوری‌که کاربرد این روش باعث شده است تا میزان کل قدر مطلق خطا (ردیف آخر) در DTR از ۳۶ میلی‌متر به $۲۳/۶۵$ میلی‌متر کاهش پیدا کند ($۳۴/۳$ درصد بهبود در میزان قدرمطلق خطای تخمین).
شکل ۱۰ به گونه‌ای دیگر این تفسیر را به نمایش گذاشته

جدول ۱- مقدار قدر مطلق خطای بدست آمده در مدل درخت تصمیم و مدل‌سازی گروهی (میلی‌متر)
 Table 1- Absolute error derived by DTR and ensemble modeling (mm)

(دهه) Decade	DTR	Bagging	Boosting
1	0.90	4.56	0.70
2	0.15	6.59	1.00
3	2.40	5.22	0.70
4	0.15	4.09	0.70
5	0.19	1.67	0.40
6	0.65	0.79	1.30
7	0.65	1.81	1.85
8	0.02	0.59	0.70
9	3.30	1.06	0.60
10	1.48	2.56	1.20
11	5.88	6.34	3.60
12	1.00	8.03	1.90
13	5.48	6.24	3.20
14	5.52	2.71	1.20
15	7.32	1.01	1.40
16	0.30	0.53	1.10
17	0.30	6.32	1.30
18	0.30	6.36	0.80
(میانگین) Average	2.00	3.69	1.31
(مقدار کل) Total	35.99	66.49	23.65



شکل ۱۰- مقایسه نرخ بهبود خطای تخمین در روش‌های یادگیری گروهی در دوره‌های مختلف رشد زعفران
 Figure 10- Rate of improvement comparison of different techniques of ensemble modelling.

نتیجه گیری

این پژوهش با هدف کاربست مدل سازی گروهی جهت بهبود شبیه سازی نیاز آبی زعفران انجام شد و در آن سعی شد ضمن معرفی تقسیم بندی های موجود، به پرکاربردترین روش ها پرداخته شود و با ارائه نتایج کاربردی یک راهنمایی مناسب جهت پیاده سازی و انتخاب درست ارائه کند. بدین ترتیب، در گام نخست داده های واقعی نیاز آبی زعفران در آزمایشگاه لایسی متری دانشگاه بیرجند اندازه گیری و جمع آوری شد. در ادامه، به دلیل کاربرد گسترده هوش مصنوعی در زمینه مدل سازی و نیاز فراینده به بررسی ابعاد این علم در موضوع مورد بحث، از رگرسیون درخت تصمیم استفاده شد تا با استفاده از چهار متغیر اقلیمی (به عنوان ورودی) مقدار نیاز آبی شبیه سازی شود. پس از بررسی عملکرد درخت تصمیم، به منظور ارزیابی عملکرد روش های یادگیری گروهی، کارایی دو روش Boosting و Bagging در زمینه بهبود دقت شبیه سازی مورد کنکاش قرار گرفت. نتایج بدست آمده حاکی از آن بود که توانمندی بسیار خوبی در زمینه تجهیز ماشین های یادگیری به مدل سازی گروهی وجود دارد تا از این طریق، دقت و عملکرد هوش مصنوعی در شبیه سازی نیاز آبی زعفران ارتقا یابد. نتایج این پژوهش نشان داد که کاربست یادگیری نظارتی Boosting در کنار ماشین یادگیری درخت تصمیم می تواند بیش از ۳۴ درصد خطای تخمین را کاهش دهد.

مهم ترین محدودیت ها، دست آوردها و زمینه های مطالعاتی احتمالی برای تحقیقات آینده که این پژوهش بدان ها رسیده است در ادامه تشریح شده است: در مطالعه حاضر (با توجه به هدف اصلی) به ابعاد مختلف کارایی ماشین یادگیری درخت تصمیم و عوامل تأثیرگذار در شبیه سازی نیاز آبی زعفران پرداخته نشد (حداکثر عمق معادل چهار و از هرس کردن اجتناب

جمع بندی نتایج فوق نشان می دهد که کاربست یادگیری گروهی Boosting به طور قابل توجهی دقت و عملکرد مدل درخت تصمیم در شبیه سازی نیاز آبی زعفران را ارتقا داده است. به نظر می رسد علت این موضوع ریشه در سازوکار نظارتی نهفته در روش Boosting دارد. در این روش، یادگیری گروهی به صورت متناوب به گونه ای انجام می شود که هر کدام از مدل های یادگیرنده ی ضعیف مرتکب خطای قبلی نمی شود و به این یادگیری بانظارت در روش Bagging زیاد مورد توجه قرار نگرفته است (Zounemat-Kermani et al., 2021).

با این وجود، هستند مطالعاتی که در آن دقت و عملکرد مدل Bagging بهتر از مدل Boosting گزارش شده است (Chen et al., 2019; Salam & Islam, 2020). پاسخی احتمالی که می توان برای این یافته های بیان کرد این است که روش Bagging اقدام به باز تولید نمونه های بسیار زیادی از مجموعه اولیه داده ها می کند و این موضوع همگنی موجود در مجموعه داده های ورودی را کاهش خواهد داد. فلذا، زمانی که عملکرد ماشین یادگیری پایه در دو قسمت آموزش و آزمایش ضمن متمایز بودن، مطلوب نیز نباشد (Overfitting)، انتظار می رود که عملکرد روش Bagging در مقایسه با Boosting بهتر باشد (به دلیل تولید نمونه های اولیه زیاد، احتمال رسیدن به یک جواب مناسب وجود دارد). این در حالی است که، استفاده از یادگیری گروهی نظارتی (نظیر Boosting) زمانی موفق خواهد بود که صرفاً میزان خطای شبیه سازی در خروجی ماشین یادگیری پایه وجود داشته باشد (عملکرد مدل حداقل در دوره آموزش مطلوب است). فلذا از این منظر، انتخاب روش مناسب یادگیری گروهی نیازمند این است که در ابتدا ضمن پایش داده های مجموعه های ورودی، خروجی ماشین یادگیری پایه مورد بررسی قرار گیرد.

گروهی معطوف شد. در حال حاضر، کاربرد مدل‌سازی گروهی ترکیبی و به‌طور خاص میانگین‌گیری نیز در بیشتر مطالعات مرتبط گزارش شده است. از این رو شایسته است در مطالعات آینده به کاربرد این دسته از مدل‌سازی گروهی نیز توجه شود.

تقدیر و تشکر

حمایت مالی

این مقاله مستخرج از نتایج طرح پژوهشی اجرا شده به شماره قرارداد ۱۵۱۲۳۰ از محل اعتبارات پژوهشکده زعفران دانشگاه تربیت مدرس می‌باشد.

شد). شایسته است که در مطالعات آینده به تأثیر اقداماتی نظیر تعیین مقدار بهینه حداکثر عمق، تعداد برگ‌ها و فرآیند هرس کردن توجه ویژه‌ای شود.

اندازه‌گیری داده‌های نیاز آبی زعفران باید به‌صورت مستمر انجام شده و استفاده از آن‌ها نیازمند داده‌های سالانه فصل زراعی است. پژوهش حاضر از داده‌های تأیید شده سال دوم کشت که در دسترس بود استفاده کرد. از این‌رو توصیه می‌شود در پژوهش‌های آینده داده‌ها با مقیاس زمانی گسترده‌تری استفاده گردد.

در فرآیند مدل‌سازی گروهی، هدف این پژوهش متناسب با ضرورت و اهمیت هوش مصنوعی به روش‌های یادگیری

منابع

- Ardabili, S., Mosavi, A., & Várkonyi-Kóczy, A.R. (2020). Advances in machine learning modeling reviewing hybrid and ensemble methods. In *Engineering for Sustainable Future: Selected papers of the 18th International Conference on Global Research and Education Inter-Academia-2019* 18 (pp. 215-227). Springer International Publishing. doi.org/10.1007/978-3-030-36841-8_21.
- Asadollah, S.B.H.S., Sharafati, A., Motta, D., & Yaseen, Z.M. (2021). River water quality index prediction and uncertainty analysis: A comparative study of machine learning models. *Journal of Environmental Chemical Engineering*, 9(1), 104599. doi.org/10.1016/j.jece.2020.104599.
- Ashrafzadeh, M.R., Naghipour, A.A., Haidarian, M., & Khorozyan, I. (2019). Modeling the response of an endangered flagship predator to climate change in Iran. *Mammal Research*, 64, 39-51. doi.org/10.1007/s13364-018-0384-y.
- Başakın, E.E., Ekmekcioğlu, Ö., Stoy, P.C., & Özger, M. (2023). Estimation of daily reference evapotranspiration by hybrid singular spectrum analysis-based stochastic gradient boosting. *MethodsX*, 102163. doi.org/10.1016/j.mex.2023.102163.
- Breiman, L. (2001). *Random forests*. *Machine learning*, 45, 5-32. doi.org/10.1023/A:1010933404324.
- Chapagain, R., Remenyi, T.A., Harris, R.M., Mohammed, C.L., Huth, N., Wallach, D., & Ojeda, J.J. (2022). Decomposing crop model uncertainty: A systematic review. *Field Crops Research*, 279, 108448. doi.org/10.1016/j.fcr.2022.108448.
- Chen, W., Hong, H., Li, S., Shahabi, H., Wang, Y., Wang, X., & Ahmad, B.B. (2019). Flood susceptibility modelling using novel hybrid approach of reduced-error pruning trees with bagging and random subspace ensembles. *Journal of Hydrology*, 575, 864-873. doi.org/10.1016/j.jhydro.2019.05.089.
- Dertimanis, V.K., Chatzi, E.N., Azam, S.E., & Papadimitriou, C. (2019). Input-state-parameter estimation of structural systems from limited output information. *Mechanical Systems*. doi.org/10.1016/j.ymsp.2019.02.040.

- Freund, Y., Schapire, R., & Abe, N. (1999). A short introduction to boosting. *Journal of the Japanese Society for Artificial Intelligence*, 14(771-780), 1612. <http://www.yorku.ca/gisweb/eats4400/boost.pdf>.
- Gibert, K., Izquierdo, J., Sánchez-Marrè, M., Hamilton, S.H., Rodríguez-Roda, I., & Holmes, G. (2018). Which method to use? An assessment of data mining methods in Environmental Data Science. *Environmental Modelling & Software*, 110, 3-27. doi.org/10.1016/j.envsoft.2018.09.021.
- Guidotti, R., Monreale, A., Ruggieri, S., Turini, F., Giannotti, F., & Pedreschi, D. (2018). A survey of methods for explaining black box models. *ACM Computing Surveys (CSUR)*, 51(5), 1-42. doi.org/10.1145/3236009.
- Günther, D., Marke, T., Essery, R., & Strasser, U. (2019). Uncertainties in snowpack simulations—Assessing the impact of model structure, parameter choice, and forcing data error on point-scale energy balance snow model performance. *Water Resources Research*, 55(4), 2779-2800. doi.org/10.1029/2018WR023403.
- Jafarzadeh, A., Khashei-Siuki, A., & Pourreza-Bilondi, M. (2022). Performance assessment of model averaging techniques to reduce structural uncertainty of groundwater modeling. *Water Resources Management*, 36(1), 353-377. doi.org/10.1007/s11269-021-03031-x.
- Jafarzadeh, A., Pourreza-Bilondi, M., Akbarpour, A., Khashei-Siuki, A., & Samadi, S. (2021). Application of multi-model ensemble averaging techniques for groundwater simulation: synthetic and real-world case studies. *Journal of Hydroinformatics*, 23(6), 1271-1289. doi.org/10.2166/hydro.2021.058.
- Jamei, M., Karimi, B., Ali, M., Alinazari, F., Karbasi, M., Maroufpoor, E., & Chu, X. (2023). A comprehensive investigation of wetting distribution pattern on sloping lands under drip irrigation: A new gradient boosting multi-filtering-based deep learning approach. *Journal of Hydrology*, 129402. doi.org/10.1016/j.jhydrol.2023.129402.
- Joshi, R.C., Ryu, D., Lane, P.N., & Sheridan, G.J. (2023). Seasonal forecast of soil moisture over Mediterranean-climate forest catchments using a machine learning approach. *Journal of Hydrology*, 619, 129307. doi.org/10.1016/j.jhydrol.2023.129307.
- Khan, M., Islam, M.Z., & Hafeez, M. (2012). Evaluating the performance of several data mining methods for predicting irrigation water requirement. In *The 10th Australasian Data Mining Conference: AusDM 2012* (pp. 199-208). Australian Computer Society Inc. <https://researchoutput.csu.edu.au/en/publication/s/evaluating-the-performance-of-several-data-mining-methods-for-pre>.
- Khashei-Siuki, A., Shahidi, A., Behdani, M.A., Hjiabadi, F., & Shirzadi, F. (2020). Determination of single and dual crop coefficients of saffron (*Crocus sativus* L.) in the first year of cultivation. *Journal of Saffron Research*. (In press). doi.org/10.22077/jsr.2020.3825.1143.
- Mirzaei, S., Vafakhah, M., Pradhan, B., & Alavi, S.J. (2021). Flood susceptibility assessment using extreme gradient boosting (EGB), Iran. *Earth Science Informatics*, 14, 51-67. doi.org/10.1007/s12145-020-00530-0.
- Nazeri Tahroudi, M., & Ramezani, Y. (2021). Joint frequency analysis of rainfall and precipitation concentration index (PCI) at Birjand and Tabas meteorological stations, South Khorasan Province, Iran. *Water Harvesting Research*, 4(2), 133-144. doi.org/10.22077/jwhr.2022.5009.1052.
- Nisbet, R., Elder, J., & Miner, G.D. (2009). *Handbook of statistical analysis and data mining applications*. Academic press. 705-718. <https://www.elsevier.com/books/handbook-of->

- statistical-analysis-and-data-mining-applications/nisbet/978-0-12-374765-5.
- Nourali, M., Ghahraman, B., Pourreza-Bilondi, M., & Davary, K. (2016). Effect of formal and informal likelihood functions on uncertainty assessment in a single event rainfall-runoff model. *Journal of Hydrology*, *540*, 549-564. doi.org/10.1016/j.jhydrol.2016.06.022.
- Pekel, E. (2020). Estimation of soil moisture using decision tree regression. *Theoretical and Applied Climatology*, *139*(3-4), 1111-1119. doi.org/10.1007/s00704-019-03048-8.
- Perea, R.G., Poyato, E.C., Montesinos, P., & Díaz, J.R. (2019). Prediction of irrigation event occurrence at farm level using optimal decision trees. *Computers and Electronics in Agriculture*, *157*, 173-180. doi.org/10.1016/j.compag.2018.12.043.
- Rezaei, F., Ghorbani, R., & Mahjouri, N. (2022). Improving daily and monthly river discharge forecasts using geostatistical ensemble modeling. *Water Resources Management*, *36*(13), 5063-5089. doi.org/10.1007/s11269-022-03292-0.
- Sajedi-Hosseini, F., Malekian, A., Choubin, B., Rahmati, O., Cipullo, S., Coulon, F., & Pradhan, B. (2018). A novel machine learning-based approach for the risk assessment of nitrate groundwater contamination. *Science of the Total Environment*, *644*, 954-962.
- Salam, R., & Islam, A.R.M.T. (2020). Potential of RT, Bagging, and RS ensemble learning algorithms for reference evapotranspiration prediction using climatic data-limited humid region in Bangladesh. *Journal of Hydrology*, *590*, 125241. doi.org/10.1016/j.jhydrol.2020.125241.
- Sarigöl, M., & Katipoğlu, O.M. (2023). Estimation of monthly evaporation values using gradient boosting machines and mode decomposition techniques in the Southeast Anatolia Project (GAP) area in Turkey. *Acta Geophysica*, 1-18. doi.org/10.1007/s11600-023-01067-8.
- Tso, G.K., & Yau, K.K. (2007). Predicting electricity energy consumption: A comparison of regression analysis, decision tree, and neural networks. *Energy*, *32*(9), 1761-1768. doi.org/10.1016/j.energy.2006.11.010.
- Wei, L., Huang, C., Wang, Z., Wang, Z., Zhou, X., & Cao, L. (2019). Monitoring of urban black-odor water based on Nemerow index and gradient boosting decision tree regression using UAV-borne hyperspectral imagery. *Remote Sensing*, *11*(20), 2402. doi.org/10.3390/rs11202402.
- Zhou, X., Liu, H., Pourpanah, F., Zeng, T., & Wang, X. (2022). A survey on epistemic (model) uncertainty in supervised learning: Recent advances and applications. *Neurocomputing*, *489*, 449-465. doi.org/10.1016/j.neucom.2021.10.119.
- Zounemat-Kermani, M., Batelaan, O., Fadaee, M., & Hinkelmann, R. (2021). Ensemble machine learning paradigms in hydrology: A review. *Journal of Hydrology*, *598*, 126266. doi.org/10.1016/j.jhydrol.2021.126266.