



Evaluating Remote Sensing Technique and Machine Learning Algorithms in Estimating Sugarcane Evapotranspiration

Mohammad Alavi¹ | Mohammad Albaji² | Mona Golabi³ | Abd Ali Naseri⁴ | Saeid Homayouni⁵

1. Department of Irrigation and Drainage, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran. E-mail: mohammad-alavi@stu.scu.ac.ir
2. Corresponding Author, Department of Irrigation and Drainage, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran. E-mail: m.albaji@scu.ac.ir
3. Department of Irrigation and Drainage, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran. E-mail: m.golabi@scu.ac.ir
4. Department of Irrigation and Drainage, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran. E-mail: abdalinaseri@scu.ac.ir
5. Centre Eau Terre Environnement, Institut National de la Recherche Scientifique (INRS), 490 Couronne St, Quebec, QC G1K 9A9, Canada. E-mail: saeid.homayouni@inrs.ca

Article Info

Article type:
Research Article

Article history:

Received 17 July 2023
Received in revised form
9 August 2023
Accepted 4 October 2023
Published online 17 January 2024

Keywords:

Decision tree
Experimental models
Gradient boosted regression tree
Spectral indices
Support vector machine

ABSTRACT

Estimating crop evapotranspiration (ET_c) in arid and semi-arid areas can be difficult due to the dynamic nature of this process across both time and space. In addition, obtaining on-site measurements for this variable can be very time-consuming and costly. This study aimed to develop a framework that accurately estimates the sugarcane crop evapotranspiration on a spatio-temporal scale. This was achieved using four machine learning (ML) algorithms (MLR, CART, SVR, and GBRT) combined with remote sensing (RS) data and meteorological variables. Also, to reduce the dependence on several meteorological parameters in conventional ET_c equations, the performance of eight different experimental temperature-based methods and four modified Hargreaves & Samani equations was evaluated compared to the standard FAO-Penman-Monteith method. For this purpose, weather data were collected from Hakim Farabi Sugarcane Agro-Industrial meteorological station for three years (2018-2021). Nine combinations of input variables (RS data and meteorological variables) were designed based on the IGR method and then evaluated by the ML algorithms. The results showed that the highest accuracy of ML algorithms based on R^2 , RMSE, and MAE statistics was obtained in CART (0.99, 0.41, and 0.18) and GBRT algorithms (0.99, 0.65, and 0.26), respectively. Regarding temperature-based methods, Ivanov's equation had the best performance with an R^2 of 0.91, while Baier and Robertson's equation had the weakest performance with an R^2 of 0.78 when estimating ET_c . Overall, the combination of RS and ML algorithms effectively produced more precise and reliable ET_c values on both temporal and spatial scales.

Cite this article: Alavi, M., Albaji, M., Golabi, M., Naseri, A. A., & Homayouni, S. (2024). Evaluating Remote Sensing Technique and Machine Learning Algorithms in Estimating Sugarcane Evapotranspiration. *Journal of Water and Irrigation Management*, 13 (4), 965-982. DOI: <https://doi.org/10.22059/jwim.2023.362473.1090>





ارزیابی تکنیک سنجش از دور و مدل‌های یادگیری ماشین در برآورد تبخیر و تعرق گیاه نیشکر

محمد علوی^۱ | محمد الباجی^۲ | منا گلابی^۳ | عبدعلی ناصری^۴ | سعید همایونی^۵

۱. گروه آبیاری و زهکشی، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران. رایانامه: mohammad-alavi@stu.scu.ac.ir
۲. نویسنده مسئول، گروه آبیاری و زهکشی، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران. رایانامه: m.albaji@scu.ac.ir
۳. گروه آبیاری و زهکشی، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران. رایانامه: m.golabi@scu.ac.ir
۴. گروه آبیاری و زهکشی، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران. رایانامه: abdalinaseri@scu.ac.ir
۵. گروه سنجش از دور محیطی و ژئوماتیک، مرکز آب، زمین و محیط زیست، INRS - کبک، کانادا. رایانامه: saeid.homayouni@inrs.ca

اطلاعات مقاله

چکیده

نوع مقاله: مقاله پژوهشی

تخمین تبخیر و تعرق گیاه در مناطق خشک و نیمه‌خشک چالش برانگیز است زیرا این فرایند در طول زمان و مکان بسیار پویا است. همچنین اندازه‌گیری این متغیر به صورت میدانی کاری بسیار وقت‌گیر و هزینه‌بر است. لذا این پژوهش با هدف ایجاد چارچوبی برای برآورد بهینه تبخیر و تعرق گیاه نیشکر در مقیاس مکانی - زمانی با استفاده از چهار مدل یادگیری ماشین (GBRT، SVR، CART، MLR) در ترکیب با داده‌های سنجش از دور و متغیرهای هواشناسی صورت گرفت. همچنین به منظور کاهش وابستگی به پارامترهای متعدد هواشناسی در روش‌های مرسوم برآورد تبخیر و تعرق، هشت مدل مختلف تجربی مبتنی بر دما و چهار مدل اصلاحی هارگریوز سامانی نسبت به مدل استاندارد فائو- پنمن - مانیتیت ارزیابی شد. بدین منظور داده‌های هواشناسی از ایستگاه هواشناسی کشت و صنعت نیشکر حکیم فارابی در دوره زمانی سه ساله (۱۳۹۷-۱۴۰۰) گردآوری شدند. نه ترکیب مختلف از متغیرهای ورودی (داده‌های سنجش از دور و متغیرهای هواشناسی) بر اساس روش Information Gain Ratio طراحی شدند و سپس توسط الگوریتم‌های یادگیری ماشین ارزیابی شدند. نتایج نشان داد که بیشترین دقت مدل‌های یادگیری ماشین بر اساس آماره‌های R^2 ، RMSE و MAE به ترتیب در مدل‌های CART (۰/۹۹)، GBRT (۰/۴۱ و ۰/۱۸) و (۰/۹۹، ۰/۶۵ و ۰/۲۶) به دست آمد. همچنین از بین روش‌های تجربی مبتنی بر دما، روش ایوانف با R^2 برابر ۰/۹۱ و روش بایر رابرتسون با R^2 برابر ۰/۷۸ به ترتیب بهترین و ضعیف‌ترین عملکرد را ثبت کردند. به‌طور کلی روش سنجش از دور در ترکیب با مدل‌های یادگیری ماشین توانست مقادیر بهتر و دقیق‌تری از تبخیر و تعرق گیاه را در مقیاس زمان و مکان ارائه نماید.

تاریخ دریافت: ۱۴۰۲/۰۴/۲۶

تاریخ بازنگری: ۱۴۰۲/۰۵/۱۸

تاریخ پذیرش: ۱۴۰۲/۰۷/۱۲

تاریخ انتشار: ۱۴۰۲/۱۰/۲۷

کلیدواژه‌ها:

درخت تصمیم

رگرسیون بردار پشتیبان

شاخص‌های طیفی

مدل درخت گرادبان بوستینگ

مدل‌های تجربی

استناد: علوی، محمد؛ الباجی، محمد؛ گلابی، منا؛ ناصری، عبدعلی و همایونی، سعید (۱۴۰۲). ارزیابی تکنیک سنجش از دور و مدل‌های یادگیری ماشین در برآورد تبخیر و تعرق گیاه نیشکر. نشریه مدیریت آب و آبیاری، ۱۳ (۴)، ۹۶۵-۹۸۲. DOI: <https://doi.org/10.22059/jwim.2023.362473.1090>



۱. مقدمه

افزایش تدریجی جمعیت جهان مستلزم افزایش تولیدات کشاورزی است. فعالیت‌های کشاورزی بیش‌ترین سهم آب مصرفی را دارند. از طرفی، رویدادهای مکرر خشکسالی که مناطق وسیعی از کره زمین را تحت تأثیر قرار می‌دهد، مدیریت دقیق‌تر منابع آب در مقیاس جهانی تا محلی را بیش از پیش ضروری می‌سازد (Granata, 2019). لذا برآورد دقیق تبخیر و تعرق گیاه^۱ (ET_c) برای برنامه‌ریزی دقیق آبیاری ضروری است. روش‌های متعددی جهت برآورد مستقیم و غیرمستقیم ET_c ارائه شده است. روش‌های مستقیم مانند لایسیمتر، کوواریانس گردابی و تعادل انرژی نسبت بوون نیازمند صرف وقت، هزینه و دقت بالا می‌باشند. از این‌رو، تمرکز بیش‌تر بر روی روش‌های غیرمستقیم در برآورد ET_c می‌باشد (Ahmadi and Javanbakht, 2020). استفاده از مدل‌های تجربی یکی از روش‌های غیرمستقیم است که عملکرد آن‌ها بسته به شرایط اقلیمی مختلف تغییر می‌کند. این روش‌ها در پنج گروه ترکیبی، دمایی، تشعشعی، رطوبتی و تشت تبخیر طبقه‌بندی می‌شوند (Allen et al., 1998). در تمامی مدل‌های تجربی، ابتدا تبخیر و تعرق گیاه مرجع^۲ (ET_0) برآورد می‌گردد، سپس ضرایب زراعی برای تخمین ET_c هر محصول مورد نظر استفاده می‌شود (Jensen, 1968). در این زمینه Akhavan et al. (2019) و Rodrigue and Braga (2021) عملکرد نه روش مبتنی بر دما را برای تخمین تبخیر و تعرق ارزیابی کردند. با وجود ساده بودن استفاده از مدل‌های تجربی، ماهیت تجربی این روش‌ها باعث شده است که نتایج حاصل شده مختص به یک مکان و شرایط اقلیمی خاص باشد که ممکن است نیاز به کالیبراسیون دوباره محلی داشته باشد. لذا ضروری است که عملکرد مدل‌های تجربی در برآورد ET_0 به صورت محلی در برابر یک مدل معیار، قبل از کاربردهای گسترده در مدیریت‌های آبیاری ارزیابی شود.

معادله فائو-پنمن-مانتیث^۳ (FAO-PM) به عنوان رایج‌ترین مدل مبتنی بر فیزیک و یک مدل استاندارد در توصیف فرایند تبخیر و تعرق در مناطق و اقلیم‌های متنوع پذیرفته شده است، زیرا در دسترس بودن رطوبت، انتقال جرم و انرژی مورد نیاز برای این فرایند را در نظر می‌گیرد (Didari and Ahmadi, 2019). با وجود دقت زیاد این روش، وابستگی به پارامترهای متعدد هواشناسی ضعف این روش محسوب می‌شود. بنابراین استفاده از این معادله در همه زمان‌ها و مکان‌ها میسر نمی‌باشد. لذا در سال‌های اخیر برای رفع این محدودیت‌ها، روش سنجش از دور به عنوان ابزاری مفید جهت برآورد تبخیر و تعرق گیاه در مقیاس‌های بزرگ توسعه داده شده است (Huete 2012; Yebra et al., 2013; Liu et al., 2021).

یکی از رایج‌ترین رویکردهای سنجش از دور در برآورد تبخیر و تعرق گیاه، روش تعادل انرژی سطحی است، که در آن گرمای محسوس با استفاده از دمای سطح زمین (حاصل از حسگر مادون قرمز حرارتی ماهواره‌ها) تخمین زده می‌شود. از طرفی اجرای این روش‌ها چالش برانگیز است و مشکلات خاصی را به همراه دارد. به عنوان مثال، خطاهای کوچک در تخمین دمای سطح زمین منجر به خطاهای بزرگ در تخمین گرمای محسوس می‌شود (Yebra et al., 2013). به منظور رفع معایب روش‌های مبتنی بر تعادل انرژی سطحی، روش‌های مبتنی بر شاخص‌های گیاهی با استفاده از داده‌های سنجش از دور برای تخمین ET_c توسعه داده شده است (Mosre and Suárez, 2021). شاخص‌های گیاهی براساس بازتاب طیفی حاوی اطلاعاتی در مورد وضعیت، ترکیبات بیوژئوشیمیایی و ساختار تاج پوششی گیاهان هستند و هم‌چنین می‌توانند اطلاعاتی در مورد چرخه‌های آب و کربن ارائه دهند (Huete, 2012). به عنوان مثال، شاخص گیاهی تفاوت نرمال شده^۴ (NDVI) با استفاده از تفاوت بین مادون قرمز نزدیک (که به شدت توسط گیاهان بازتابش می‌شود) و نور قرمز (که توسط گیاهان جذب می‌شود) می‌تواند نقاط دارای پوشش گیاهی را نمایان سازد. درحالی‌که شاخص تفاوت نرمال شده آب^۵ (NDWI) به محتوای آب برگ

حساس است و می‌تواند محتوای آب تاج و خاک را نشان دهد، بنابراین می‌تواند در تشخیص تنش آبی گیاهان مؤثر باشد (Mosre and Suárez, 2021; Nouraki *et al.*, 2023).

چندین پژوهش پتانسیل ترکیب متغیرهای هواشناسی با داده‌های سنجش از دور برای توسعه مدل‌های تجربی در مقیاس منطقه‌ای را نشان داده است (Mosre and Suárez, 2021; Liu *et al.*, 2021). فرمول‌های رگرسیون تجربی در عین سادگی و بدون نیاز محاسباتی زیاد می‌توانند مقادیر ET_c را برآورد کنند، به طوری که از نظر دقت با مدل‌های پیچیده‌تر قابل مقایسه هستند. با این حال، نیاز به تخمین‌های دقیق‌تر از ET_c در مقیاس‌های زمانی طولانی، پژوهش‌گران را به استفاده از تکنیک‌هایی مانند مدل‌های یادگیری ماشینی سوق داده است.

الگوریتم‌های یادگیری ماشینی هم‌چون رگرسیون خطی چندگانه^۶ (MLR)، شبکه عصبی مصنوعی^۷ (ANN)، درخت تصمیم^۸ (DT)، ماشین بردار پشتیبان^۹ (SVM)، جنگل تصادفی^{۱۰} (RF) و درخت گزاردیان بوستینگ^{۱۱} (GBRT) به پژوهش‌گران اجازه می‌دهد تا از کاوش مکانیسم‌های پیچیده اجتناب کنند و در نهایت نتایج بهینه را به طور مستقیم از طریق متغیرهای مرتبط به دست آورند (Granata, 2019; Mosre and Suárez, 2021). Yamaç and Todorovic (2020) توانایی پیش‌بینی تبخیر و تعرق روزانه گیاه سیب زمینی را با استفاده از سه مدل KNN^{۱۲}، ANN و AdaBoost^{۱۳} در ترکیب با داده‌های هواشناسی در جنوب ایتالیا مورد بررسی قرار دادند. نتایج آن‌ها نشان داد که در شرایط داده‌های هواشناسی محدود (دمای هوا و تابش خورشیدی) مدل KNN می‌تواند ET_c را با دقت قابل قبولی تخمین بزند (Ge *et al.*, 2022) ($R^2=0.97$) از هفت تکنیک یادگیری ماشینی برای برآورد تبخیر و تعرق گیاه گوجه‌فرنگی استفاده کردند. نتایج آن‌ها حاکی از برتری الگوریتم‌های XGBoost^{۱۴} و GBRT نسبت به سایر مدل‌های رگرسیونی بود. Liu *et al.* (2021) دو مدل RFR^{۱۵} و SVR را به عنوان دقیق‌ترین مدل‌های یادگیری ماشینی برای تخمین تبخیر و تعرق با استفاده از NDVI و حداقل داده‌های هواشناسی (دمای هوا و بارش) معرفی کردند. به طور کلی، نوع پوشش گیاهی و شرایط آب‌وهوایی از عوامل مؤثر در برآورد ET_c به روش استفاده از داده‌های سنجش از دور (شاخص‌های پوشش گیاهی) و متغیرهای هواشناسی هستند. بنابراین، انتخاب بهینه شاخص‌های پوشش گیاهی حاصل از تصاویر ماهواره‌ای و متغیرهای هواشناسی در برآورد ET_c بسیار با اهمیت است. از طرفی کاربرد تکنیک‌های یادگیری ماشینی در زمینه تخمین تبخیر و تعرق در حال حاضر محدود است و دانش در مورد این موضوع هنوز جزئی و پراکنده است. لذا هدف اصلی پژوهش حاضر برآورد تبخیر و تعرق گیاه نیشکر در مقیاس نقطه‌ای تا منطقه‌ای با استفاده از روش‌های تجربی و مدل‌های یادگیری ماشینی در ترکیب با داده‌های هواشناسی و سنجش از دور است.

۲. مواد و روش‌ها

۲.۱. منطقه مورد بررسی و داده‌های مورد استفاده

در این پژوهش از داده‌های هواشناسی ایستگاه واقع در کشت و صنعت حکیم فارابی استفاده شد. ایستگاه هواشناسی کشت و صنعت حکیم فارابی در طول جغرافیایی ۴۸ درجه و ۳۶ دقیقه و ۸ ثانیه شمالی و عرض جغرافیایی ۳۰ درجه و ۵۹ دقیقه و ۲۰ ثانیه شرقی در ارتفاع ۱۱ متری از سطح دریا واقع شده است. شکل (۱) موقعیت جغرافیایی منطقه مورد بررسی را نشان می‌دهد. این منطقه دارای اقلیم خشک با تابستان‌های بسیار گرم و زمستان‌های معتدل می‌باشد. فصل ریزش‌های جوی از آبان ماه آغاز می‌شود و گاهی تا اردیبهشت‌ماه ادامه می‌یابد. سردترین و گرم‌ترین ماه در منطقه مورد بررسی به ترتیب در ماه‌های دی و مرداد ثبت شده است. داده‌های هواشناسی شامل حداقل، حداکثر و میانگین دمای هوا، حداقل، حداکثر و میانگین رطوبت نسبی، سرعت باد و ساعات آفتابی در مقیاس روزانه در دوره سه ساله (۱۳۹۷-۱۴۰۰) از ایستگاه هواشناسی مربوطه اخذ گردید.

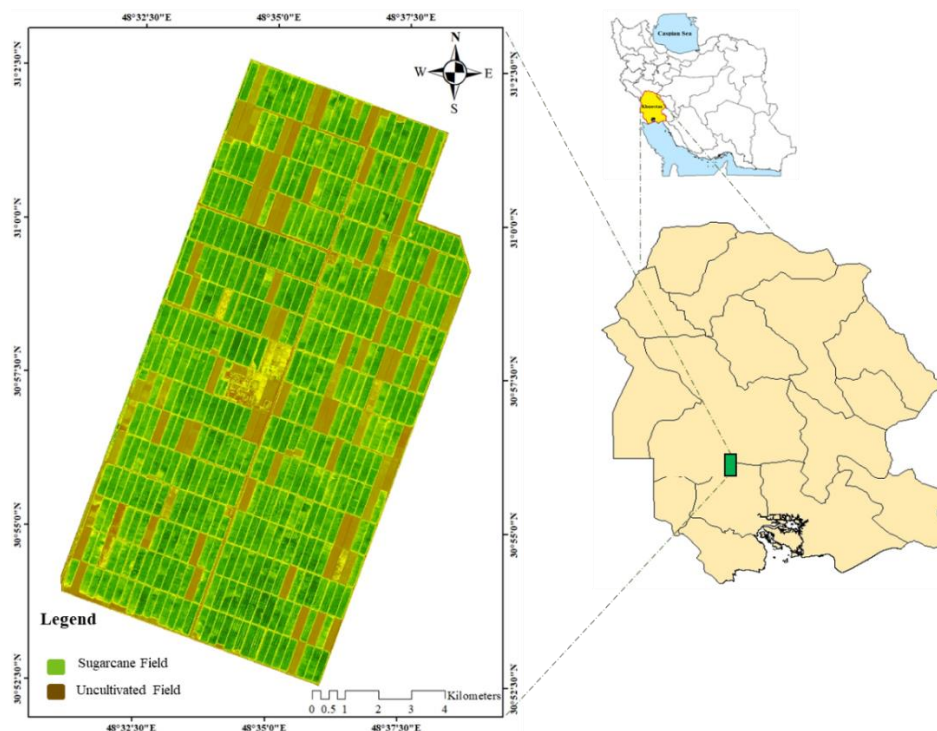


Figure 1. The location of the study area

۲.۲. روش‌های تجربی برآورد تبخیر و تعرق

لایسیمتر دقیق‌ترین روش برآورد میزان تبخیر و تعرق گیاه معرفی شده است. اما استفاده از آن در مقیاس‌های بزرگ دارای محدودیت‌هایی است، چرا که هزینه احداث بالایی دارد و همچنین تنها می‌تواند تبخیر و تعرق گیاه را در یک مکان خاص تعیین کند. در این راستا *Allen et al.* (1998) رابطه فائو-پنمن-مونتیت را به‌عنوان دقیق‌ترین روش برای برآورد نیاز آبی گیاه در نشریه ۵۶ سازمان فائو ارائه نمودند. بنابراین در پژوهش حاضر از این روش به‌عنوان روش استاندارد و دقیق استفاده شد.

$$ET_o = \frac{0.408\Delta(R_n - G) + \gamma\left(\frac{900}{T} + 273\right)(U_2(e_s - e_a))}{\Delta + \gamma(1 + 0.34U_2)} \quad \text{رابطه (۱)}$$

که در آن، ET_o تبخیر و تعرق گیاه مرجع (mm d^{-1})، R_n تابش خالص در سطح پوشش گیاهی ($\text{MJ.m}^{-2}\text{d}^{-1}$)، G شار گرما به داخل خاک ($\text{MJ.m}^{-2}\text{d}^{-1}$)، T متوسط دمای هوا در ارتفاع دو متری از سطح زمین ($^{\circ}\text{C}$)، U_2 سرعت باد در ارتفاع دو متری از سطح زمین (m.s^{-1})، e_a فشار بخار واقعی (KPa)، e_s فشار بخار اشباع هوا (KPa)، $e_s - e_a$ کمبود فشار بخار اشباع (KPa)، Δ شیب منحنی فشار بخار ($\text{KPa } ^{\circ}\text{C}^{-1}$) و γ ضریب رطوبتی ($\text{KPa } ^{\circ}\text{C}^{-1}$) است.

معادله فائو-پنمن-مونتیت مقدار ET_o را براساس تابش خالص خورشیدی، رطوبت نسبی، سرعت باد و دمای هوا محاسبه می‌کند. از طرفی دیگر، پیچیدگی محاسبات معادله فائو-پنمن-مونتیت و نیاز به تجهیزات گران قیمت برای اندازه‌گیری متغیرهای آن، متخصصان را به سمت استفاده از یک سری روابط تجربی سوق داده است. این معادلات تجربی براساس رابطه بین چند متغیر اساسی که به‌راحتی قابل اندازه‌گیری هستند، با تبخیر و تعرق به‌دست می‌آیند. با توجه به اندازه‌گیری آسان دمای هوا، در این پژوهش از هشت مدل مختلف تجربی مبتنی بر دما و چهار مدل اصلاحی هارگریوز سامانی برای تخمین ET_o استفاده گردید (جدول ۱).

Table 1. Temperature-based methods for estimating ET_0

Model	Equation	Parameter	Source
Ivanov	$ET_0 = 0.00006 (25 + T_{mean})^2 (100 - RH)$	T_{mean} , RH	Ivanov (1954)
Schendel	$ET_0 = 16 \left(\frac{T_{mean}}{RH} \right)$	T_{mean} , RH	Schendel (1967)
Blaney & Criddle	$ET_0 = a + b[p(0.46T_{mean} + 8.13)]$	T_{mean} , RH, RH_{min} , n, N, U	Blaney & Criddle (1950)
Kharrufa	$ET_0 = 0.34pT_{mean}^{1.3}$	T_{mean} , n	Kharrufa (1985)
Ravazzani	$ET_0 = (0.817 + 0.00022z)(0.0023R_a)(TD^{0.5})(T_{mean} + 17.8)$	T_{mean} , T_{max} , T_{min} , z	Ravazzani <i>et al.</i> (2012)
Hargreaves & Samani	$ET_0 = 0.0135 \times K_{rs} \times 0.408R_a \times (T_{mean} + 17.8)(TD)^{0.5}$	T_{mean} , T_{max} , T_{min}	Hargreaves & Samani (1985)
Hargreaves & Samani -1	$ET_0 = 0.0030 \times 0.408R_a \times (T_{mean} + 20)(TD)^{0.4}$	T_{mean} , T_{max} , T_{min}	Droogers & Allen (2002)
Hargreaves & Samani -2	$ET_0 = 0.0025 \times 0.408R_a \times (T_{mean} + 16.8)(TD)^{0.5}$	T_{mean} , T_{max} , T_{min}	Droogers & Allen (2002)
Hargreaves & Samani -3	$ET_0 = 0.0013 \times 0.408R_a \times (T_{mean} + 17)(TD - 0.0123P)^{0.76}$	T_{mean} , T_{max} , T_{min} , P	Droogers & Allen (2002)
Hargreaves & Samani -4	$ET_0 = 0.00193 \times 0.408R_a \times (T_{mean} + 17.8)(TD)^{0.517}$	T_{mean} , T_{max} , T_{min}	Berti <i>et al.</i> (2014)
Baier & Robertson	$ET_0 = 0.157T_{max} + 0.158TD + 0.408R_a - 5.39$	T_{max} , T_{min}	Baier & Robertson (1965)
Trajkovic	$ET_0 = 0.0023R_a \times (T_{mean} + 17.8)(TD)^{0.424}$	T_{mean} , T_{max} , T_{min}	Trajkovic (2007)

در جدول (۱)، ET_0 تبخیر و تعرق گیاه مرجع ($mm\ d^{-1}$)، T_{mean} متوسط دمای هوا ($^{\circ}C$)، RH متوسط رطوبت نسبی (درصد)، a و b ضرایب معادلات تجربی، p ضریب روشنایی مربوط به طول روز در ماه مشخص از سال، P بارش (mm)، z ارتفاع از سطح دریا (m)، R_a تابش برون زمینی ($MJ.m^{-2}.d^{-1}$) و TD اختلاف دمای حداکثر و حداقل ($^{\circ}C$) است. در تمام روش‌هایی که توسط آن‌ها تبخیر و تعرق گیاه مرجع محاسبه می‌شود برای آن که بتوان نتایج حاصله را به سطوح پوشش گیاهی مورد نظر مانند پوشش‌های زراعی، مرتعی و باغی تعمیم داد لازم است مقادیر به دست آمده را در ضریب گیاهی (K_c) ضرب نمود.

$$ET_c = K_c \times ET_0$$

(رابطه ۲)

ضریب گیاهی علاوه بر تبخیر و تعرق مرجع به نوع گیاه، مرحله رشد و شرایط آب‌وهوایی محل بستگی دارد که در این پژوهش بر اساس روش پیشنهادی فائو برای دوره رویش گیاه نیشکر متناسب با شرایط آب‌وهوای منطقه اصلاح شد.

۳.۲. سنجش از دور و شاخص‌های پوشش گیاهی

جهت برآورد تبخیر و تعرق گیاه نیشکر از طریق روش سنجش از دور، از داده‌های ماهواره لندست-۸ در بازه زمانی ۲۱ سپتامبر ۲۰۱۸ تا ۳۱ اکتبر ۲۰۲۱ (۳۰ شهریورماه ۱۳۹۷ تا ۹ آبان‌ماه ۱۴۰۰) استفاده گردید. تعداد ۵۵ تصویر بدون ابر از ماهواره لندست-۸ با دقت تفکیک زمانی ۱۶ روزه و دقت تفکیک مکانی ۳۰ متر در ۳۰ متر، از سایت USGS (<https://glovis.usgs.gov>) دانلود و تصحیحات اتمسفری و رادیومتریک آن‌ها با نرم‌افزار ENVI 5.3.1 انجام شد. در نهایت پس از محاسبه مقادیر بازتابش باندهای طیفی، شاخص‌های گیاهی (NDVI)، شاخص گیاهی تعدیل‌کننده خاک (SAVI)^{۱۶}، شاخص سبزی تفاضل نرمال شده (NDGI)^{۱۷}، و شاخص مقاومت جوی قابل مشاهده (VARI)^{۱۸} محاسبه شدند. شاخص‌های گیاهی مورد نظر به این دلیل انتخاب شدند که پیاده‌سازی آن‌ها آسان است و وضعیت پوشش گیاهی را در بازه‌های زمانی هفتگی، ماهانه و سالانه به درستی نشان می‌دهند (Mosre and Suárez, 2021). NDVI در حقیقت نشان‌دهنده تراکم پوشش گیاهی است که با نسبت تابش جذب شده توسط فتوسنتز مرتبط است و فعالیت کلروفیل گیاهان را منعکس می‌کند و همچنین با تبخیر و تعرق گیاه رابطه قوی دارد. بازه مقادیر NDVI بین منفی یک تا مثبت یک متغیر است. عموماً مقادیر کم‌تر از صفر به‌عنوان نواحی مرطوب و آب در نظر گرفته می‌شوند (Gates *et al.*, 1965). SAVI یک شاخص گیاهی مشتق شده از NDVI است که شامل یک ضریب تصحیح (L) می‌باشد که تغییرات ایجاد شده توسط حضور خاک در سطوح ناهمگن را به حداقل می‌رساند (Huete *et al.*, 1994). NDGI یک شاخص گیاهی است که برای به حداقل رساندن تغییرات بین بازتاب پس‌زمینه سطوح مختلف و به حداکثر رساندن تضاد بین پوشش گیاهی و سایر اجزای زمینه در تخمین فنولوژی گیاهان توسعه یافته است (Yang *et al.*, 2019).

NDWI برخلاف سایر شاخص‌های پوشش گیاهی، بر شناسایی محتوای آب خاک لخت و پوشش گیاهی تمرکز دارد (Gao, 1996). VARI برای تأکید بر پوشش گیاهی در بخش طیف مرئی طراحی شده است، درحالی‌که تفاوت‌های روشنی و اثرات جوی را کاهش می‌دهد (Schneider *et al.*, 2008). شاخص‌های موردبررسی از طریق معادلات زیر محاسبه می‌شوند.

$$NDVI = \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red}} \quad \text{رابطه ۳}$$

$$SAVI = \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red} + L} (1 + L) \quad \text{رابطه ۴}$$

$$NDGI = \frac{\varepsilon \rho_{Green} + (1 - \varepsilon) \rho_{NIR} - \rho_{Red}}{\varepsilon \rho_{Green} + (1 - \varepsilon) \rho_{NIR} + \rho_{Red}} \quad \text{رابطه ۵}$$

$$NDWI = \frac{\rho_{NIR} - \rho_{SWIR1}}{\rho_{NIR} + \rho_{SWIR1}} \quad \text{رابطه ۶}$$

$$VARI = \frac{\rho_{Green} - \rho_{Red}}{\rho_{Green} + \rho_{Red} - \rho_{Blue}} \quad \text{رابطه ۷}$$

که در این روابط، ρ_{Red} ، ρ_{Green} ، ρ_{Blue} ، ρ_{NIR} ، ρ_{SWIR1} انعکاس در باندهای سبز، قرمز، آبی، مادون قرمز نزدیک و مادون قرمز طول موج کوتاه است. L فاکتوری جهت از بین بردن تأثیرات پوشش گیاهی می‌باشد که از صفر برای پوشش گیاهی متراکم، تا یک برای تراکم‌های پایین متغیر است. در این پژوهش از مقدار L برابر با 0.25 استفاده گردید. همچنین ε ضریبی است که به ماهواره بستگی دارد (ماهواره لندست-۸: 0.63).

۲.۴.۲ مدل‌های یادگیری ماشین

۲.۴.۲.۱ انتخاب ویژگی

قبل از شروع فرایند مدل‌سازی در ابتدا لازم است که عوامل مؤثر در برآورد تبخیر و تعرق گیاه تعیین شود. لذا جهت انتخاب مهم‌ترین عوامل مؤثر از بین ۱۷ متغیر ورودی در برآورد تبخیر و تعرق گیاه از روش IGR استفاده شد. مقادیر IGR بالاتر نشان‌دهنده توانایی پیش‌بینی بالاتر آن عامل مؤثر برای مدل‌سازی است. اگر M داده‌های آموزشی با M_i نمونه ورودی باشد، روش IGR برای یک عامل مؤثر خاص A از رابطه (۸) محاسبه می‌شود.

$$IGR(M, A) = \frac{\text{Entropy}(M) - \sum_{i=1}^n \frac{|M_i|}{|M|} \text{Entropy}(M_i)}{-\sum_{i=1}^n \frac{|M_i|}{|M|} \log \frac{|M_i|}{|M|}} \quad \text{رابطه ۸}$$

۲.۴.۲.۲ رگرسیون خطی چندگانه (MLR)

با استفاده از روش MLR می‌توان به‌طور هم‌زمان به تحلیل و بررسی چند متغیر مختلف پرداخت. در این پژوهش به‌منظور وارد کردن متغیرها در رگرسیون خطی چندگانه از روش گام‌به‌گام استفاده شد. در روش گام‌به‌گام تمامی متغیرهای مستقل وارد مدل می‌شوند و اگر نقش معنی‌داری در رگرسیون نداشته باشند از آن حذف می‌گردند (Eshaghi *et al.*, 2010).

۲.۴.۲.۳ درخت تصمیم CART

درختان تصمیم به‌عنوان یک ابزار قوی و متداول برای حل مسائل طبقه‌بندی و رگرسیون اعمال می‌شوند. که برخلاف

مدل‌های شبکه عصبی به تولید قانون می‌پردازند. درخت CART یک روش رگرسیونی است که توسط Breiman (1984) معرفی شد. الگوریتم CART یک روش سلسله مراتبی یا چند مرحله‌ای است که در آن به صورت بازگشتی مجموعه داده‌ها به روش دودویی به تقسیمات فرعی و کوچک‌تر تقسیم‌بندی می‌شوند. تقسیم‌بندی‌ها تا زمانی که تقسیمات فرعی نهایی نتوانند بیش‌تر از آن تجزیه شوند ادامه می‌یابد. پس از ساخت درخت، عملیات هرس کردن درخت انجام می‌شود.

۲.۴.۴. رگرسیون بردار پشتیبان (SVR)

ماشین بردار پشتیبان یکی از روش‌های یادگیری است که برای مسائل مربوط به طبقه‌بندی (SVM) و رگرسیون (SVR) مورد استفاده قرار می‌گیرد. این روش توسط Boser *et al.* (1992) بر پایه تئوری یادگیری آماری با هدف حداقل‌سازی خطای ساختاری و تولید یک جواب بهینه معرفی شده است. ماشین‌های بردار پشتیبان برای حل مسائل غیرخطی، ابعاد مسئله را از طریق توابع کرنل تغییر می‌دهند. انتخاب کرنل برای ماشین بردار پشتیبان به حجم داده‌های آموزشی و ابعاد بردار ویژگی بستگی دارد. به عبارت دیگر، با یک تبدیل غیرخطی از فضای ورودی به فضایی با ابعاد بیش‌تر (حتی نامتناهی) می‌توان مسائل را به صورت خطی، تفکیک‌پذیر ساخت. در این پژوهش نوع کرنل و مابقی پارامترهای قابل تنظیم مدل SVR در نرم‌افزار پایتون با روش اعتبارسنجی متقابل k -Fold ($k=10$) انجام شد.

۲.۴.۵. مدل درخت گرادیان بوستینگ (GBRT)

GBRT توسط Friedman (2001) به عنوان یک تکنیک یادگیری جمعی با الگوریتم تقویتی معرفی شد. این مدل درختان را در یک زمان می‌سازد، به طوری که هر درخت جدید به تصحیح خطاهای مربوط به درختان آموزشی قبلی کمک می‌کند. به این صورت که پس از ارزیابی درخت اول، وزن مشاهدات با طبقه‌بندی سخت‌تر را افزایش می‌دهد و وزن کم‌تر را به مشاهداتی می‌دهد که طبقه‌بندی آن‌ها راحت‌تر است و در نهایت درخت دوم بر این داده‌های وزنی رشد می‌کند. این روند برای تعداد مشخصی تکرار می‌شود. درخت‌های بعدی در طبقه‌بندی مشاهداتی که به وسیله درختان قبلی به خوبی طبقه‌بندی نشده‌اند کمک‌کننده هستند.

در این پژوهش به منظور مدل‌سازی، مجموعه داده‌ها به ۷۰ درصد داده‌های آموزش و ۳۰ درصد داده‌های آزمایش تقسیم شدند. جهت پیش‌بینی مدل MLR از نرم‌افزار SPSS استفاده شد و مدل‌سازی سایر الگوریتم‌های یادگیری ماشین توسط نرم‌افزار Python صورت گرفت. همچنین از روش IGR به منظور بررسی اهمیت متغیرهای ورودی و طراحی الگوها استفاده شد.

۳. نتایج و بحث

۳.۱. ارزیابی عملکرد مدل‌های مبتنی بر دما جهت برآورد تبخیر و تعرق

برای برآورد هرچه دقیق‌تر تبخیر و تعرق گیاه نیاز به استفاده از ضرایب گیاهی اصلاح‌شده محلی است. شکل (۲) مقادیر K_c اصلاح‌شده گیاه نیشکر را در سال ۱۳۹۹ نشان می‌دهد. میانگین ضریب گیاهی نیشکر در مرحله ابتدایی رشد در مدت زمان انجام پژوهش برابر ۰/۴۱، سپس با افزایش سرعت رشد گیاه و افزایش شاخص سطح برگ و به دنبال آن افزایش تعرق در دوره رشد توسعه ضریب گیاهی افزایش یافته و برابر ۰/۷۸ شد. سپس در مرحله میانی این مقدار به ۱/۴۱ و در مرحله انتهایی به ۰/۸۶ رسید. همان‌طور که در شکل (۲) ملاحظه می‌شود، ضریب گیاهی در مراحل اولیه رشد مقادیر کمی دارد و هر چه به مراحل توسعه و میانی رشد گیاه نزدیک‌تر می‌شود این مقادیر بیش‌تر می‌شوند و در نهایت در مرحله انتهایی رشد، مقادیری کم‌تر از دوره میانی پیدا می‌کنند (Shao *et al.*, 2021).




Figure 2. Curves of sugarcane K_c values during the entire growing stage in 2019

شکل (۳) مقادیر ET_c محاسبه شده براساس روش استاندارد FAO-PM در مقابل روش‌های تخمین تبخیر و تعرق گیاه مبتنی بر دما را نشان می‌دهد. مطابق با شکل (۳) در تبخیر و تعرق‌های بالای ۲۰ میلی‌متر در روز، تخمین‌های برخی روش‌های مبتنی بر دما مقادیر بیش‌برآورد و کم‌برآوردی را نشان می‌دهد. تخمین‌های روش‌های بلانی کریدل، روزانی، خروفا، هارگریوز سامانی-۱، -۲، -۳، ترایکوویچ و بایر رابرتسون نسبت به روش استاندارد کم‌برآورد بودند. بنابراین چنانچه برنامه‌ریزی آبیاری منطقه براساس این روش‌ها تعیین شود، احتمال تنش کم‌آبی در تبخیر و تعرق‌های بالاتر از ۲۰ میلی‌متر در روز وجود خواهد داشت. از طرفی با توجه به شکل (۳)، روش شندل در تبخیر و تعرق‌های بالاتر از ۲۰ میلی‌متر در روز به‌صورت بیش‌برآورد عمل کرده است و در صورت استفاده از این روش در برنامه‌ریزی آبیاری نیز مشکلاتی مانند ایجاد حالت غرقابی و آسیب به گیاهان دور از انتظار نیست. بنابراین روش‌های ذکر شده نمی‌توانند به‌عنوان معیار مناسب در برآورد تبخیر و تعرق گیاه نیشکر در این منطقه معرفی شوند.

به‌منظور بررسی دقیق‌تر میزان دقت مدل‌های مبتنی بر دما در برآورد تبخیر و تعرق از مقادیر شاخص‌های آماری R^2 ، RMSE و MAE استفاده شد که نتایج آن در شکل (۳) نشان داده شده است. نتایج نشان داد که در رتبه نخست روش ایوانف با R^2 ، RMSE و MAE برابر ۰/۹۱، ۱/۳۶ و ۱/۱۶ میلی‌متر بر روز و در انتخاب دوم روش هارگریوز سامانی اصلاح‌شده-۴ با R^2 ، RMSE و MAE برابر ۰/۸۱، ۱/۶۷ و ۱/۴۰ میلی‌متر بر روز برآورد‌های نزدیک‌تری با روش استاندارد داشتند. شایان ذکر است که روش ایوانف تنها با استفاده از دو پارامتر RH و T توانست با دقت بسیار خوبی تبخیر و تعرق گیاه را در منطقه تخمین بزند. همچنین از بین روش‌های تجربی مورد بررسی، ضعیف‌ترین عملکرد در روش بایر رابرتسون با مقادیر R^2 برابر ۰/۷۸، RMSE برابر ۸/۱۰ و MAE برابر ۳/۷۴ میلی‌متر در روز به‌دست آمد.

Akhavan *et al.* (2019) در پژوهشی به‌منظور تخمین تبخیر و تعرق واقعی ذرت برآورد‌های نه روش مبتنی بر دما را با روش استاندارد فائو- پنمن- ماتیت در کرج، ایران مقایسه کردند. آن‌ها از روش‌های بلانی کریدل، شندل، هارگریوز سامانی، هارگریوز سامانی اصلاح‌شده-۱، -۲، -۳، بایر رابرتسون، ترایکوویچ و جنسن- هیز استفاده کردند. نتایج آن‌ها نشان داد که مقادیر RMSE از ۱/۹۷ تا ۵/۸۰ میلی‌متر در روز متغیر است. در پژوهش آن‌ها روش‌های هارگریوز سامانی-۳ و شندل به‌ترتیب بهترین و بدترین عملکرد را ثبت کردند. همچنین Rodrigues and Braga (2021) از نه روش مبتنی بر دما (هارگریوز-سامانی، هارگریوز سامانی اصلاح‌شده-۱، -۲، -۳، -۴، شندل، ترایکوویچ، انکو و ملس) برای تخمین تبخیر و تعرق گیاه مرجع در چهارده مکان مختلف در یک منطقه آب‌وهوایی مدیترانه‌ای با تابستان گرم (آلتجو، پرتغال جنوبی) استفاده کردند. نتایج آن‌ها نشان داد که روش هارگریوز-سامانی اصلاح‌شده، با RMSE ۰/۸۴ - ۰/۷۲ میلی‌متر در روز و R^2 بالاتر از ۰/۷۸ عملکرد قابل‌قبولی داشت.

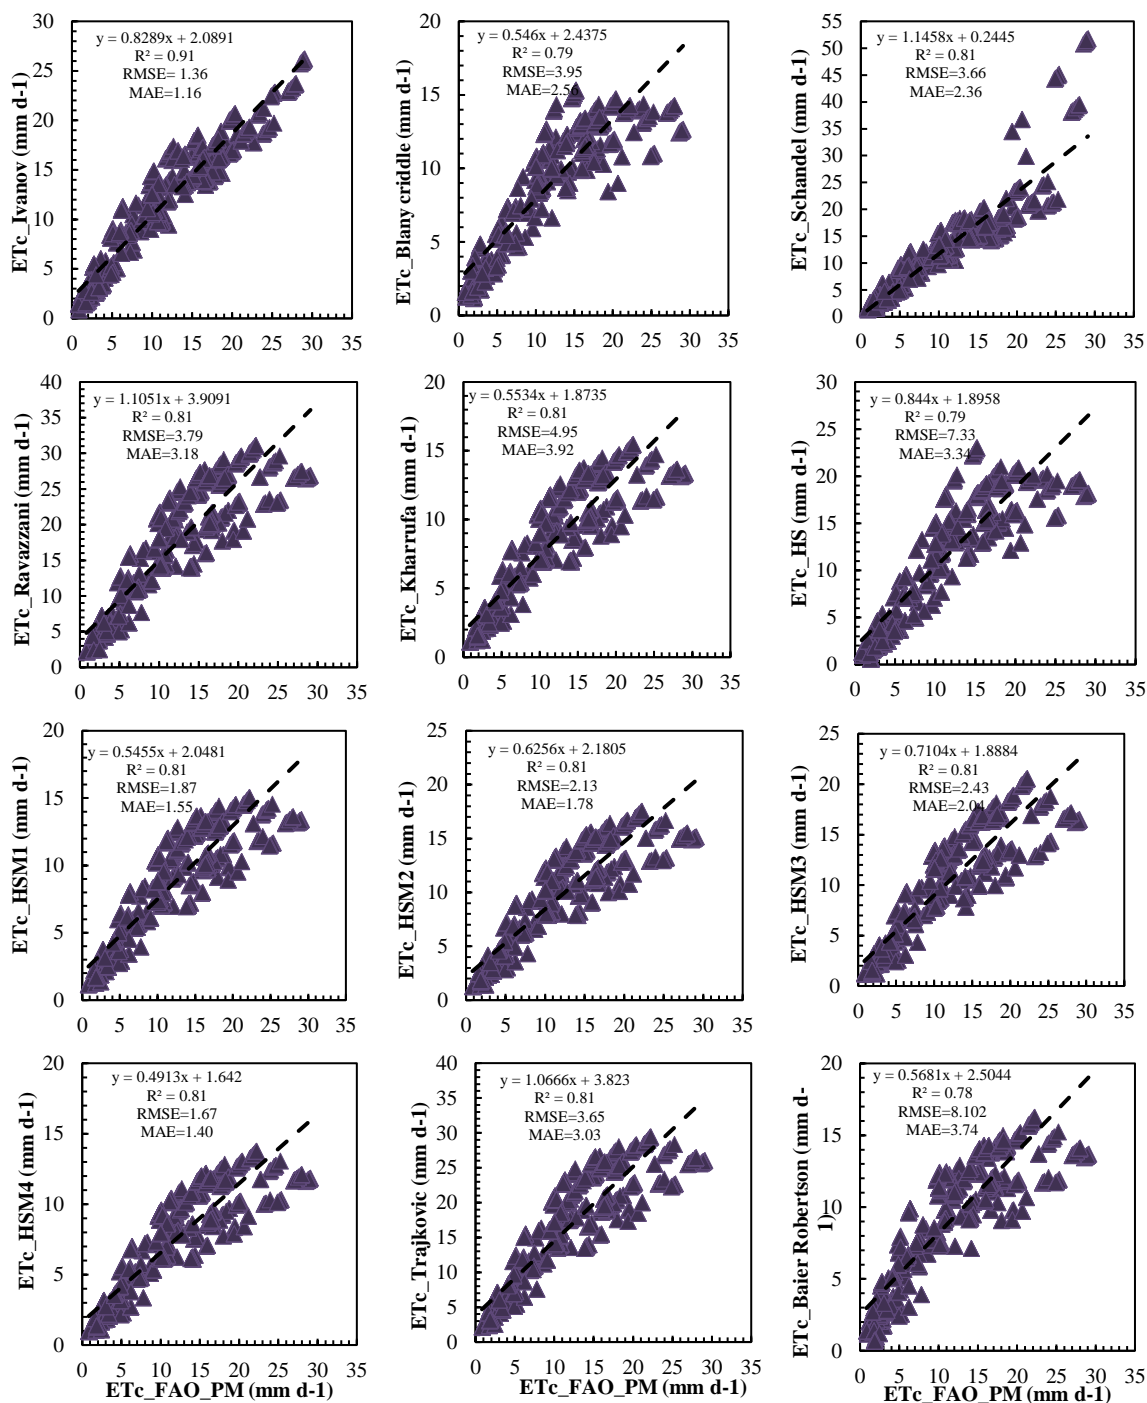


Figure 3. Comparison of estimated ET_c based on the standard method with the temperature-based methods

به‌طور کلی براساس نتایج پژوهش حاضر، روش ایوانف به‌دلیل ارائه دقیق‌ترین برآوردها و به‌کارگیری حداقل داده ورودی به‌عنوان بهترین روش در تخمین تبخیر و تعرق گیاه انتخاب شد و در نهایت با استفاده از نرم‌افزار MATLAB ضرایب این روش براساس الگوریتم لونیبرگ-مارکوارت متناسب با منطقه کالیبره شد (رابطه ۹).

$$ET_o = 0.000063 (22.83 + T_{mean})^2 (100 - RH) \quad \text{(رابطه ۹)}$$

۲.۳. تعیین اهمیت متغیرهای ورودی در مدل‌های یادگیری ماشین

در پژوهش حاضر از روش IGR به منظور بررسی روابط بین متغیرهای هواشناسی و داده‌های سنجش از دور طیفی-حرارتی بر ET_c استفاده شد. نتایج مقادیر IGR برای ۱۷ متغیر ورودی در شکل (۴) ارائه شده است. همان‌طور که در شکل (۴) مشاهده می‌شود، تمامی متغیرهای هواشناسی مورد بررسی (R_s ، U ، T ، n و RH) نسبت به داده‌های سنجش از دور طیفی-حرارتی (به جز LST) اهمیت بالاتری در تخمین تبخیر و تعرق گیاه دارند. به طوری که متغیر R_s با بیشترین مقدار IGR (۰/۴۳) به عنوان مؤثرترین متغیر برای تعیین تبخیر و تعرق گیاه معرفی شد. همچنین در رتبه‌های بعدی متغیرهای U ، T ، n و RH با مقدار IGR به ترتیب ۰/۳۷، ۰/۳۷، ۰/۳۶ و ۰/۳۵ قرار داشتند. Liu *et al.* (2021) از تحلیل همبستگی برای بررسی تأثیر پارامترهای هواشناسی بر تبخیر و تعرق گیاه استفاده کردند. آن‌ها دریافتند که میانگین دمای هوا بیشترین همبستگی را با تبخیر و تعرق گیاه داشته است.

از بین داده‌های سنجش از دور طیفی-حرارتی بالاترین اهمیت در تخمین ET_c توسط متغیرهای LST ، NIR ، $SAVI$ و $NDVI$ با مقدار IGR به ترتیب برابر با ۰/۳۸، ۰/۲۳، ۰/۱۹ و ۰/۱۷ به دست آمد. در حالی که کم‌اهمیت‌ترین متغیرها در تخمین ET_c ، باندهای مرئی (RGB) و مادون قرمز کوتاه (SWIR1 و SWIR2) بودند (شکل ۴). بر اساس پژوهش‌های Liu *et al.* (2021)، Mosre and Suárez (2021) و Nouraki *et al.* (2021)، شاخص‌های طیفی-حرارتی به شدت با پویایی پوشش گیاهی و محتوای آب موجود در خاک و محصول مرتبط هستند که با نتایج پژوهش حاضر مطابقت دارد. پس از تعیین متغیرهای مؤثر در تخمین تبخیر و تعرق گیاه با استفاده از روش IGR، تعداد نه مدل طراحی شدند (جدول ۲). طراحی مدل‌ها با حذف متغیرهای با اهمیت کم‌تر در مدل‌های بعدی صورت گرفت، به طوری که در مدل آخر تنها از دو فاکتور R_s و LST (با داشتن بالاترین مقادیر IGR) استفاده شد.

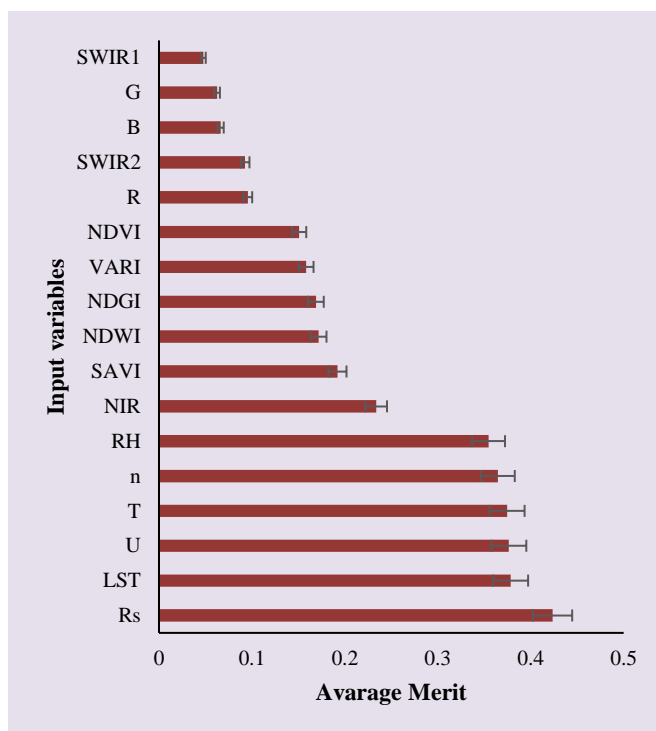


Figure 4. Importance of variables in estimating ET_c using the IGR method

* Spectral bands (R, G, B, NIR, SWIR1, SWIR2 and LST), Spectral indices (NDVI, SAVI, NDWI, NDGI, VARI), and Meteorological data (RH, T, R_s , U and n).

Table 2. Defined scenarios in the study

Model	Input variable
1	Rs, LST, U, T, n, RH, NIR, SAVI, NDWI, NDGI, VARI, NDVI, R, SWIR2, B, G, SWIR1
2	Rs, LST, U, T, n, RH, NIR, SAVI, NDWI, NDGI, VARI, NDVI, R, SWIR2, B, G
3	Rs, LST, U, T, n, RH, NIR, SAVI, NDWI, NDGI, VARI, NDVI, R, SWIR2
4	Rs, LST, U, T, n, RH, NIR, SAVI, NDWI, NDGI, VARI, NDVI
5	Rs, LST, U, T, n, RH, NIR, SAVI, NDWI, NDGI
6	Rs, LST, U, T, n, RH, NIR, SAVI
7	Rs, LST, U, T, n, RH, NIR
8	Rs, LST, U, T, n, RH
9	Rs, LST

* Spectral bands (R, G, B, NIR, SWIR1, SWIR2 and LST), Spectral indices (NDVI, SAVI, NDWI, NDGI, VARI), and Meteorological data (RH, T, Rs, U and n).

۳.۳. ارزیابی عملکرد مدل‌های یادگیری ماشین

جدول‌های (۳) تا (۵) ارزیابی آماری الگوریتم‌های مختلف یادگیری ماشین تحت مدل‌های طراحی شده را نشان می‌دهد. همان‌طور که مشاهده می‌شود، مدل‌های یادگیری ماشین قابلیت بالایی در تخمین ET_c دارند. هر چند براساس شاخص‌های آماری محاسبه شده برخی از روش‌ها قابلیت پیش‌بینی بالاتری از خود نشان دادند.

Table 3. Comparison of the R^2 values in four different machine learning algorithms for the nine proposed models

Model	Train				Test			
	MLR	CART	SVR	GBRT	MLR	CART	SVR	GBRT
1	0.90	0.99	0.99	0.99	0.88	0.92	0.93	0.94
2	0.90	0.99	0.99	0.99	0.88	0.91	0.92	0.94
3	0.90	0.92	0.98	0.92	0.88	0.90	0.92	0.93
4	0.90	0.99	0.98	0.99	0.88	0.93	0.93	0.93
5	0.90	0.99	0.97	0.99	0.88	0.93	0.92	0.94
6	0.90	0.99	0.96	0.99	0.88	0.94	0.92	0.93
7	0.88	0.99	0.94	0.98	0.86	0.88	0.92	0.90
8	0.86	0.98	0.92	0.97	0.84	0.89	0.92	0.88
9	0.64	0.90	0.74	0.96	0.56	0.87	0.68	0.87

Table 4. Comparison of the RMSE values in four different machine learning algorithms for the nine proposed models

Model	Train				Test			
	MLR	CART	SVR	GBRT	MLR	CART	SVR	GBRT
1	3.25	0.48	0.73	0.73	3.30	1.92	1.58	1.79
2	3.25	0.48	0.76	0.75	3.30	2.07	1.59	1.71
3	3.25	2	0.83	0.72	3.30	2.26	1.62	1.83
4	2.20	0.52	0.93	0.74	2.43	1.81	1.55	1.88
5	2.21	0.54	1.12	0.65	2.43	1.84	1.52	1.70
6	2.34	0.41	1.33	0.72	2.51	1.76	1.56	1.80
7	2.5	0.70	1.69	0.87	2.64	2.44	2.04	2.17
8	2.63	0.94	1.95	1.21	2.78	2.38	1.99	2.48
9	4.27	2.45	3.63	3.31	4.72	2.61	4.04	2.57

Table 5. Comparison of the MAE values in four different machine learning algorithms for the nine proposed models

Model	Train				Test			
	MLR	CART	SVR	GBRT	MLR	CART	SVR	GBRT
1	2.68	0.17	0.45	0.29	2.66	0.99	0.90	1.06
2	2.68	0.17	0.46	0.30	2.66	1.01	0.99	1.06
3	2.68	1.46	0.49	0.27	2.66	1.23	0.97	1.08
4	1.67	0.18	0.54	0.28	1.76	0.93	0.96	0.99
5	1.67	0.19	0.62	0.26	1.77	0.92	0.97	1
6	1.79	0.18	0.73	0.29	1.85	0.88	0.93	1.1
7	1.84	0.26	0.92	0.36	1.90	1	1.09	1.25
8	1.90	0.42	1.08	0.43	1.99	1.17	1.10	1.25
9	3.23	2.24	2.81	2.70	3.52	1.56	2.91	1.35

الگوریتم MLR ضعیف‌ترین عملکرد برآورد ET_c را در بین سایر الگوریتم‌های یادگیری ماشین داشت (جدول‌های ۳ تا ۵). علاوه بر این، کاهش متغیرهای ورودی در مدل‌های سلسه مراتبی منجر به کاهش دقت برآورد ET_c شد، به طوری که در مدل ۹- کم‌ترین دقت برآورد ET_c مشاهده شد ($R^2=0/64$). طی رگرسیون گام‌به‌گام با حذف G، B و SWIR1 در مدل ۳- نسبت به مدل ۱- تغییری در شاخص‌های آماری مشاهده نشد ($R^2=0/90$ ، $RMSE=3/25$ و $MAE=2/68$ میلی‌متر در روز). بیش‌ترین دقت MLR در تخمین ET_c در مدل ۴- که در آن از SAVI، NDWI، NDGI، VARI، NIR، n، RH، T، U، LST و Rs به‌عنوان ورودی مدل استفاده شد، مشاهده گردید ($R^2=0/90$ ، $RMSE=2/20$ و $MAE=1/67$ میلی‌متر در روز). مطابق با نتایج به‌نظر می‌رسد که کاربرد باندهای مرئی (RGB) و مادون قرمز طول موج کوتاه (SWIR1 و SWIR2) در مدل‌سازی MLR منجر به کاهش دقت در تخمین ET_c می‌شود. بنابراین، بهترین رابطه رگرسیونی خطی چندانگانه بین ET_c و متغیرهای ورودی به‌صورت رابطه (۱۰) به‌دست آمد:

$$ET_c = -11.181 + 0.249T + 1.482U + 16.104SAVI - 0.079RH - 34.832NDGI + 0.159Rs + 7.249NDWI + 21.775NDVI \quad \text{رابطه (۱۰)}$$

براساس رابطه رگرسیونی گام‌به‌گام (معادله ۱۰) متغیرهای SAVI، NDGI، VARI، NIR، n و LST اثر معنی‌داری در پیش‌بینی ET_c نداشتند ($P < 0/05$) و از رابطه نهایی حذف شدند. از طرفی با توجه به ضریب استاندارد شده بتا، متغیر NDGI ($\beta = 0/728$) مؤثرترین متغیر در تخمین ET_c در مدل چهارم شناخته شد و به‌دنبال آن متغیرهای NDVI، U، SAVI، T، RH، NDWI و Rs با ضریب استاندارد شده بتا به‌ترتیب ۵۱۲، ۴۱۷، ۳۰۴، ۲۶۶، ۱۴۴، ۱۴۱ و ۱۳۲ در رتبه‌های بعدی قرار گرفتند. در حقیقت، این ضرایب انطباق مطلوب مقادیر مشاهداتی و مقادیر پیش‌بینی‌شده توسط الگوریتم MLR را بیان می‌کنند. هم‌چنین مدل MLR در بهترین حالت خود (مدل ۴-) عملکرد نسبتاً مناسبی را در مرحله آزمایش ثبت کرد ($R^2=0/88$ ، $RMSE=2/43$ و $MAE=1/76$ میلی‌متر در روز). شکل (۵)، نمودار پراکنش مقادیر پیش‌بینی‌شده توسط مدل برتر الگوریتم MLR (مدل ۴-) و مقادیر استاندارد را نشان می‌دهد. همان‌طور که مشاهده می‌شود الگوریتم MLR در تبخیر و تعرق‌های بین پنج تا ۱۰ میلی‌متر در روز بیش برآورد و در تبخیر و تعرق‌های بالاتر از ۲۰ میلی‌متر در روز کم‌برآورد عمل کرده است. همسو با یافته‌های پژوهش حاضر، Mosre and Suárez (2021) گزارش کردند که الگوریتم MLR می‌تواند تخمین‌های قابل‌اعتماد و دقیقی از ET_c روزانه و ماهانه را با ترکیب داده‌های سنجش از دور (NDWI و NDGI) و پارامترهای هواشناسی (شار تشعشع خالص، شارگرمای خاک و بارندگی) تولید کند ($R^2=0/82$). درحالی‌که کم‌ترین دقت پیش‌بینی در صورت استفاده از پارامترهای هواشناسی به‌تنهایی مشاهده شد.

ET_c برای نه مدل پیشنهادی متشکل از متغیرهای هواشناسی و داده‌های سنجش از دور طیفی - حرارتی توسط الگوریتم CART تخمین زده شد و نتایج عملکرد آن براساس شاخص‌های اعتبارسنجی در جدول‌های (۳) تا (۵) ارائه شده است. مطابق با نتایج، ضعیف‌ترین پیش‌بینی توسط الگوریتم CART در مدل ۹- که در آن از Rs و LST استفاده گردید، مشاهده شد ($R^2=0/90$ ، $RMSE=2/45$ و $MAE=2/24$ میلی‌متر در روز). هم‌چنین بیش‌ترین دقت الگوریتم CART در تخمین ET_c در مدل ۶- که در آن از SAVI، NIR، RH، n، T، U، LST و Rs به‌عنوان ورودی مدل استفاده شد، مشاهده گردید ($R^2=0/99$ ، $RMSE=0/41$ و $MAE=0/18$ میلی‌متر در روز). همان‌طور که در جدول (۴) مشاهده می‌شود مقادیر RMSE در مرحله آموزش با حذف متغیرهای SAVI و NIR در مدل‌های (۷) و (۸) در مقایسه با مدل ۶- به‌ترتیب ۷۱ و ۱۲۹ درصد افزایش یافت. بنابراین براساس پیش‌بینی الگوریتم CART از بین داده‌های سنجش از دور طیفی - حرارتی، متغیرهای SAVI و NIR در کنار متغیرهای هواشناسی نقش تعیین‌کننده‌ای در تخمین ET_c دارند. هم‌چنین حذف باندهای طیفی (SWIR1، SWIR2، B، G و R) در مدل ۵- نسبت به مدل ۱- اثر قابل‌توجهی در تخمین

ET_c نداشت. این نتیجه اهمیت شاخص‌های طیفی پوشش گیاهی نسبت به باندهای طیفی (به جز NIR) در تخمین ET_c را برجسته می‌کند که با نتایج Braga *et al.* (2021) مطابقت دارد. شکل (۵)، نمودار پراکنش مقادیر استاندارد و تخمینی با استفاده از الگوریتم CART را نسبت به نیمساز ربع اول نشان می‌دهد. بیش‌تر مقادیر در اطراف خط نیمساز پراکنده شده‌اند که نشان از نزدیک‌بودن مقادیر استاندارد و تخمینی دارد. با توجه به شکل (۴)، پراکندگی داده‌ها در تبخیر و تعرق - های پایین (بین پنج تا ۱۵ میلی‌متر در روز) زیاد بوده است. هم‌چنین کم‌ترین پراکندگی در برآوردهای الگوریتم CART در محدوده‌ی بین ۱۵ تا ۲۰ میلی‌متر در روز مشاهده شد.

Granata (2019) برای مدل‌سازی ET_c در اقلیم‌های نیمه‌گرمسیری مرطوب در فلوریدا مرکزی از رگرسیون درخت تصمیم، رگرسیون جنگل تصادفی و رگرسیون برداری پشتیبان استفاده کرد. الگوریتم درخت تصمیم با کاربرد متغیرهای تابش خالص خورشیدی، شار حرارتی محسوس، محتوای رطوبت خاک، سرعت باد، میانگین رطوبت نسبی و میانگین دما توانست دقیق‌ترین برآورد ET_c را برای این منطقه داشته باشد.

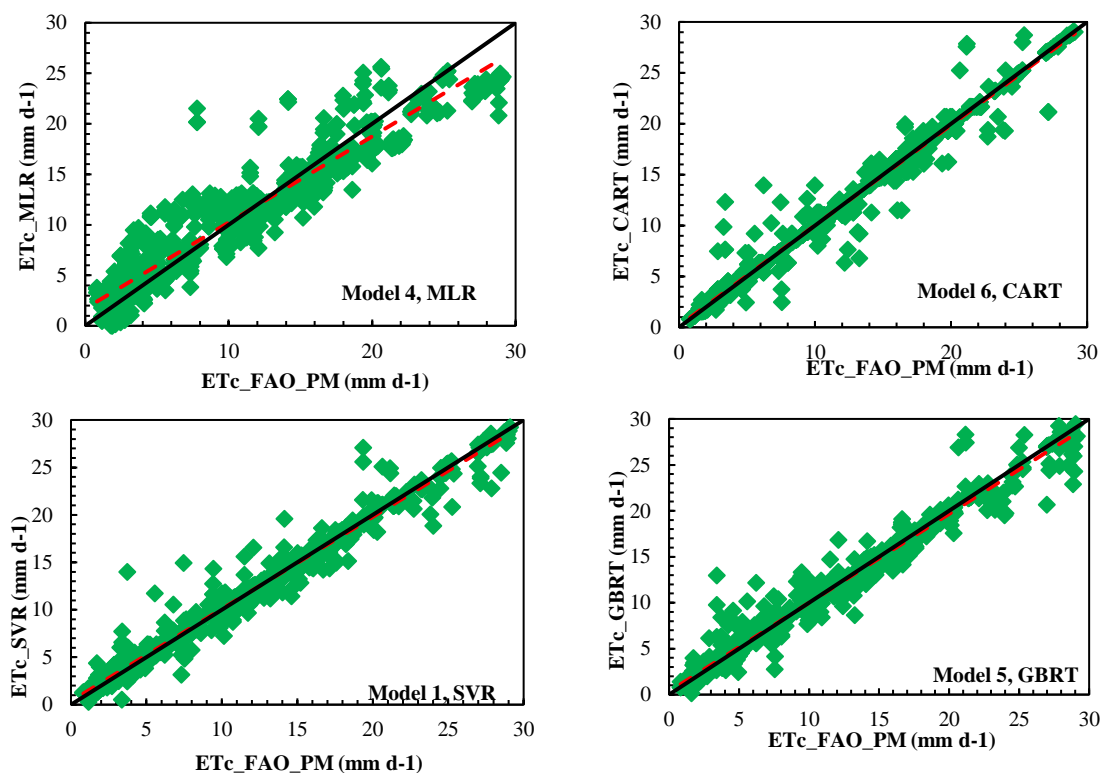


Figure 5. Comparison of estimated ET_c with machine learning models (best estimates)

نتایج حاصل از اجرای الگوریتم SVR توسط تابع کرنل پایه شعاعی برای داده‌های آموزش و آزمایش در نه‌الگوی ورودی، در جدول‌های (۳) تا (۵) ارائه شده است. همان‌طور که مشاهده می‌شود الگوریتم SVR توانسته است مقادیر ET_c را به کمک متغیرهای هواشناسی و داده‌های سنجش از دور طیفی - حرارتی در تمامی مدل‌های پیشنهادی در حد قابل قبولی تخمین بزند. الگوریتم SVR با داشتن تمامی متغیرهای هواشناسی و داده‌های سنجش از دور طیفی - حرارتی (مدل-۱) بهترین عملکرد را در تعیین ET_c در مرحله آموزش ($R^2=0.99$ ، $RMSE=0.73$ و $MAE=0.45$ میلی‌متر در روز) و آزمایش ($R^2=0.95$ ، $RMSE=1.58$ و $MAE=0.90$ میلی‌متر در روز) داشت.

هم‌چنین نتایج نشان داد که با حذف متغیرهای ورودی، دقت الگوریتم SVR کاهش می‌یابد (جدول‌های ۳ تا ۵). به طوری که ضعیف‌ترین پیش‌بینی SVR در مدل-۹ که در آن تنها از متغیرهای Rs و LST استفاده گردید، مشاهده شد ($R^2=0/74$ ، $RMSE=3/63$ و $MAE=2/81$ میلی‌متر در روز). شکل (۵)، نمودار پراکنش مقادیر پیش‌بینی شده توسط مدل برتر الگوریتم SVR (مدل-۱) و مقادیر استاندارد را نشان می‌دهد. همان‌طور که مشاهده می‌شود این مدل توانسته است تغییرات ET_c را به‌طور مناسبی پیش‌بینی کند. براساس نمودار پراکنش مشاهده می‌شود که عملکرد مدل در محدوده مقادیر حداکثر (۲۲ تا ۳۰ میلی‌متر در روز) کم‌برآورد بوده است (شکل ۵). Liu et al. (2021) تبخیر و تعرق را در آمریکای جنوبی با ترکیب تصاویر مودیس و داده‌های هواشناسی با استفاده از الگوریتم‌های SVR و RFR تخمین زدند. نتایج آن‌ها نشان داد که هر دو الگوریتم عملکرد قابل‌قبولی در تخمین تبخیر و تعرق دارند. هم‌چنین NDVI، دما و پارامترهای بارش به‌طور قابل‌توجهی بر برآورد تبخیر و تعرق تأثیرگذار بودند.

نتایج برآوردهای حاصل از الگوریتم GBRT در جدول‌های (۳) تا (۵) نشان داده شده است. همان‌طور که مشاهده می‌شود مدل-۵ با حذف برخی متغیرهای سنجش از دوری (VARI، NDVI، SWIR2، B، G و R) در ترکیب با متغیرهای هواشناسی بهترین عملکرد را نسبت به سایر مدل‌های پیشنهادی در مرحله آموزش ($R^2=0/99$ ، $RMSE=0/65$ و $MAE=0/26$ میلی‌متر در روز) و آزمایش ($R^2=0/94$ ، $RMSE=1/70$ و $MAE=1$ میلی‌متر در روز) داشته است. هم‌چنین نتایج نشان داد که از مدل-۵ به بعد دقت برآورد ET_c با استفاده از الگوریتم GBRT کاهش یافته است؛ که اهمیت داده‌های سنجش از دور و اطلاعات هواشناسی در ساختار این الگوریتم را نشان می‌دهد. بنابراین ضعیف‌ترین عملکرد این الگوریتم در مدل-۹ در مرحله آموزش ($R^2=0/96$ ، $RMSE=3/31$ و $MAE=2/70$ میلی‌متر در روز) و آزمایش ($R^2=0/87$ ، $RMSE=2/57$ و $MAE=1/35$ میلی‌متر در روز) مشاهده شد.

شکل (۵)، نمودار پراکنش مقادیر استاندارد و تخمینی با استفاده از الگوریتم GBRT را نسبت به نیمساز ربع اول نشان می‌دهد. بیش‌تر مقادیر در اطراف خط نیمساز پراکنده شده‌اند که نشان از نزدیک بودن مقادیر استاندارد و تخمینی است. با این حال، الگوریتم GBRT در محدوده حداقل و حداکثر تبخیر و تعرق گیاه عملکرد ضعیف‌تری داشت. Ge et al. (2022) با استفاده از هفت مدل رگرسیون رایج (رگرسیون خطی (LR)، SVR، رگرسیون همسایگان (KNN)، RFR، رگرسیون AdaBoost، رگرسیون کیسه‌ای (BR)، XGBoost و GBRT) تبخیر و تعرق گیاه گوجه‌فرنگی گلخانه‌ای را شبیه‌سازی کردند. نتایج آن‌ها نشان داد که از بین مدل‌های رگرسیونی، XGBoost و GBRT بالاترین دقت را با انتخاب متغیرهای ورودی R_n ، RH ، RH_{min} ، T_{max} و T_{min} داشتند.

۳.۴. ارزیابی و مقایسه عملکرد مدل‌های یادگیری ماشین و مدل‌های تجربی

به‌منظور مقایسه عملکرد الگوریتم‌های یادگیری ماشین، جواب بهینه هر یک از الگوریتم‌های مورد بررسی تحت مدل‌های ورودی مختلف در جدول (۶) آورده شده است. براساس نتایج آماری هر چهار مدل یادگیری ماشین عملکرد قابل‌قبولی را در پیش‌بینی تبخیر و تعرق گیاه نیشکر داشته‌اند (جدول ۶). مطابق با جدول (۶)، کم‌ترین دقت در پیش‌بینی تبخیر و تعرق گیاه نیشکر در الگوریتم MLR مشاهده شد. از بین سه الگوریتم SVR، CART و GBRT، الگوریتم SVR دقت کم‌تری را نشان داد، در حالی که الگوریتم‌های CART و GBRT با ورودی‌های مختلف تقریباً نتایج مشابهی داشتند. با این حال، الگوریتم CART به دلیل تعداد ورودی و هاپیر پارامترهای قابل تنظیم کم‌تر نسبت به الگوریتم GBRT، به‌عنوان بهترین الگوریتم در برآورد تبخیر و تعرق گیاه نیشکر انتخاب شد. هم‌چنین مقایسه نتایج مدل‌های یادگیری ماشین و مدل بهینه تجربی (روش ایوانف) نشان از برتری عملکرد مدل‌های یادگیری ماشین (به‌جز MLR) داشت. بنابراین این نتایج

بیان کننده توانایی و پتانسیل بالای شاخص‌های پوشش گیاهی حاصل از داده‌های سنجش از دور در ترکیب با داده‌های هواشناسی در برآورد ET_c از نظر مکانی و زمانی می‌باشد. شایان ذکر است که مدل‌های یادگیری ماشین برخلاف مدل‌های فیزیکی نیازی به معادلات غیرخطی و بعضاً پیچیده ندارند، اما ضرورت کاربرد بهینه آن‌ها درک صحیح از فرایندها و تأثیرات داده‌های ورودی بر خروجی مدل است، در غیر این صورت نمی‌توان انتظار نتایج مطلوبی را در شرایط مختلف داشت.

Table 6. The best performance for the machine learning models

Algorithm	Optimal Model	Train			Test		
		R ²	RMSE	MAE	R ²	RMSE	MAE
MLR	Model-4	0.90	2.20	1.67	0.88	2.43	1.76
CART	Model-6	0.99	0.41	0.18	0.94	1.76	0.88
SVR	Model-1	0.99	0.73	0.45	0.93	1.58	0.90
GBRT	Model-5	0.99	0.65	0.26	0.94	1.70	1

۴. نتیجه‌گیری

در این پژوهش به منظور غلبه بر مشکلاتی مانند پیچیدگی، هزینه بالا و زمان بر بودن اندازه‌گیری‌های مستقیم ET_c ، از دو رویکرد استفاده شد. در رویکرد اول از چهار مدل یادگیری ماشین مختلف (MLR، CART، SVR، GBRT) در ترکیب با داده‌های حاصل از تصاویر ماهواره لندست-۸ و پارامترهای هواشناسی و در رویکرد دوم از هشت مدل مختلف تجربی مبتنی بر دما و چهار مدل اصلاحی هارگریوز سامانی، برای برآورد تبخیر و تعرق استفاده گردید. سپس عملکرد آن‌ها با روش استاندارد فائو-پنمن مانیتث مقایسه شد. نتایج نشان داد که از میان روش‌های تجربی مبتنی بر دما، معادلات کالیبره شده ایوانف و اصلاح شده هارگریوز سامانی-۴ بهترین عملکرد را در تخمین تبخیر و تعرق گیاه نیشکر داشتند. ارزیابی کلی نتایج حاصل از هر چهار الگوریتم یادگیری ماشین، نشان از توانایی آن‌ها در پیش‌بینی مناسب ET_c در منطقه مورد بررسی داشت. الگوریتم CART با ترکیب داده‌های سنجش از دور (NIR، LST و SAVI) و پارامترهای هواشناسی (R_s و U ، T_a ، RH) بیش‌ترین دقت را در تخمین تبخیر و تعرق گیاه نیشکر داشت. سپس دیگر مدل‌های یادگیری ماشین بر اساس مقادیر R^2 ، RMSE و MAE به ترتیب کاهشی به صورت $GBRT > SVR > MLR$ رتبه‌بندی شدند. به‌طور کلی هر دو رویکرد (روش‌های تجربی مبتنی بر دما (ایوانف، اصلاح شده هارگریوز سامانی-۴) و الگوریتم‌های یادگیری ماشین (CART و GBRT)) در برآورد تبخیر و تعرق گیاه نیشکر عملکرد قابل قبولی داشتند. با این حال، این که کدام یک از آن‌ها می‌باید انتخاب شود، می‌تواند بسته به نظر کارشناس و دسترسی به داده‌های اقلیمی تعیین گردد. از طرفی دسترسی رایگان به تصاویر ماهواره لندست-۸ و همچنین اندازه‌گیری آسان متغیر دمای هوا، امکان جمع‌آوری داده‌ها در مقیاس مکانی-زمانی در هر دو رویکرد پیشنهادی را فراهم می‌کند که می‌تواند منجر به افزایش کارایی مصرف آب در مقیاس‌های بزرگ شود. برای تأیید هر چه بیشتر نتایج این پژوهش، پیشنهاد می‌شود در بررسی‌های آینده ارتباط بین ET_c و داده‌های سنجش از دور در شرایط تنش آبی و مدیریت مختلف مزرعه بررسی شود.

۵. پی‌نوشت‌ها

1. Crop evapotranspiration
2. Reference evapotranspiration
3. Food and agricultural organization penman-monterith
4. Normalized difference vegetation index
5. Normalized difference water index

6. Multiple linear regression
7. Artificial neural network
8. Decision tree
9. Support vector machine
10. Random forest
11. Gradient boosted regression tree
12. K-nearest neighbors
13. Adaptive boosting
14. Extreme gradient boosting
15. Random forest regression
16. Soil adjusted vegetation index
17. Normalized difference greenness index
18. Visual atmospheric resistance index

۶. تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد.

۷. منابع

- Ahmadi, S. H., & Javanbakht, Z. (2020). Assessing the physical and empirical reference evapotranspiration (ET_o) models and time series analyses of the influencing weather variables on ET_o in a semi-arid area. *Journal of Environmental Management*, 276, 111278.
- Akhavan, S., Kanani, E., & Dehghanisani, H. (2019). Assessment of different reference evapotranspiration models to estimate the actual evapotranspiration of corn (*Zea mays* L.) in a semiarid region (case study, Karaj, Iran). *Theoretical and Applied Climatology*, 137, 1403-1419.
- Allen, R.G., Pereira, L.S., Raes, D., & Smith, M. (1998). *Crop Evapotranspiration. Guidelines for Computing Crop Water Requirements*. Irrigation and Drainage Paper No. 56, FAO, Rome, Italy, 300 pp.
- Baier, W., & Robertson, G. W. (1965). Estimation of latent evaporation from simple weather observations. *Canadian Journal of Plant Science*, 45, 276-284.
- Berti, A., Tardivo, G., Chiaudani, A., Rech, F., & Borin, M. (2014). Assessing reference evapotranspiration by the Hargreaves method in north-eastern Italy. *Agricultural Water Management*, 140, 20-25.
- Blaney, H.F., & Criddle, W.D. (1950). *Determining water requirements in irrigated areas from climatological and irrigation data*. Soil conservation service technical paper 96; Soil conservation service. US Department of Agriculture, Washington.
- Boser, B.E., Guyon, I.M., & Vapnik, V.N. (1992). *A training algorithm for optimal margin classifiers*. In D. Haussler, editor, 5th Annual ACM Workshop on COLT, pages 144-152, Pittsburgh, PA.
- Braga, P., Crusiol, L. G. T., Nanni, M. R., Caranhato, A. L. H., Fuhrmann, M. B., Nepomuceno, A. L., Neumaier, N., Farias, J.R.B., Koltun, A., Goncalves, L.S.A., & Mertz Henning, L. M. (2021). Vegetation indices and NIR-SWIR spectral bands as a phenotyping tool for water status determination in soybean. *Precision Agriculture*, 22, 249-266.
- Breiman, L., Friedman, J., Olshen, R., & Stone, C. (1984). *Classification and regression trees*. Monterey, CA: Wadsworth & Brooks. In: Cole Advanced Books and Software.
- Didari, S., & Ahmadi, S.H. (2019). Calibration and evaluation of the FAO56-PenmanMonteith, FAO24-radiation, and Priestly-Taylor reference evapotranspiration models using the spatially measured solar radiation across a large arid and semi-arid area in southern Iran. *Theoretical and Applied Climatology*, 136 (1-2), 441-455.
- Droogers, P., & Allen, R.G. (2002). Estimating reference evapotranspiration under inaccurate data conditions. *Irrigation and Drainage Systems*, 16, 33-45.
- Eshaghi, A., Motamedvaziri, B., & Feiznia, S. (2010). Landslides Hazard Zonation Using Logistic Regression Method (Case Study: Safaroud Watershed). *Territory*, 24(6), 67-77.

- Friedman, J. H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of statistics*, 29(5), 1189-1232.
- Gao, B.C. (1996). NDWI-A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sens. Environment*, 58, 257-266.
- Gates, D.M., Keegan, H. J., Schleter, J. C., & Weidner, V. R. (1965). Spectral properties of plants. *Applied optics*, 4(1), 11-20.
- Ge, J., Zhao, L., Yu, Z., Liu, H., Zhang, L., Gong, X., & Sun, H. (2022). Prediction of greenhouse tomato crop evapotranspiration using XGBoost machine learning model. *Plants*, 11(15), 1923.
- Granata, F. (2019). Evapotranspiration evaluation models based on machine learning algorithms-A comparative study. *Agricultural Water Management*, 217, 303-315.
- Hargreaves, G.H., & Samani, Z.A. (1985). Reference crop evapotranspiration from temperature. *Applied Engineering in Agriculture*, 1, 96-99.
- Huete, A., Justice, C., & Liu, H. (1994). Development of vegetation and soil indices for MODIS-EOS. *Remote Sensing. Environment*, 49, 224-234.
- Huete, A.R. (2012). Vegetation Indices, Remote Sensing and Forest Monitoring. *Geography Compass*, 6, 513-532.
- Ivanov, N. N. (1954). *About potential evapotranspiration estimation*. Izv VGO, 86, 189-196.
- Jensen, M.E. (1968). In: In: Kozlowski, T.T. (Ed.), *Water Consumption by Agricultural Plants*. Water Deficits and Plant Growth, vol. 2. Academic Press, New York, pp. 1-22.
- Kharrufa, N. (1985). Simplified equation for evapotranspiration in arid regions. *Beiträge Hydrol*, 5, 39-47.
- Liu, Y., Yue, Q., Wang, Q., Yu, J., Zheng, Y., Yao, X., & Xu, S. (2021). A Framework for Actual Evapotranspiration Assessment and Projection Based on Meteorological, Vegetation and Hydrological Remote Sensing Products. *Remote Sensing*, 13(18), 3643.
- Mosre, J., & Suárez, F. (2021). Actual evapotranspiration estimates in arid cold regions using machine learning algorithms with in situ and remote sensing data. *Water*, 13(6), 870.
- Nouraki, A., Akhavan, S., Rezaei, Y., & Fuentes, S. (2021). Assessment of sunflower water stress using infrared thermometry and computer vision analysis. *Water Supply*, 21(3), 1228-1242.
- Nouraki, A., Golabi, M., Albaji, M., Naseri, A., & Homayouni, S. (2023). Spatial-temporal modeling of soil moisture using optical and thermal remote sensing data and machine learning algorithms. *Iranian Journal of Soil and Water Research*, 54(4), 637-653. (In Persian).
- Ravazzani, G., Corbari, C., Morella, S., Gianoli, P., & Mancini, M. (2012). Modified Hargreaves-Samani equation for the assessment of reference evapotranspiration in Alpine River Basins. *Journal of Irrigation and Drainage Engineering*, ASCE 138 (7), 592-599.
- Rodrigues, G. C., & Braga, R. P. (2021). Estimation of reference evapotranspiration during the irrigation season using nine temperature-based methods in a hot-summer Mediterranean climate. *Agriculture*, 11(2), 124.
- Schendel, U. (1967). *Vegetationswasserverbrauch und-wasserbedarf*. Habilitation; Kiel, p 137.
- Schneider, P., Roberts, D.A., & Kyriakidis, P.C. (2008). A VARI-based relative greenness from MODIS data for computing the Fire Potential Index. *Remote Sensing of Environment*, 112, 1151-1167.
- Shao, G., Han, W., Zhang, H., Liu, S., Wang, Y., Zhang, L., & Cui, X. (2021). Mapping maize crop coefficient Kc using random forest algorithm based on leaf area index and UAV-based multispectral vegetation indices. *Agricultural Water Management*, 252, 106906.
- Thornthwaite, C.W. (1948). An approach toward a rational classification of climate. *Geographical review*, 38, 55-94.
- Trajkovic, S. (2007). Hargreaves versus penman-Monteith under humid conditions. *Journal of Irrigation and Drainage Engineering*, ASCE 133(1), 38-42.
- Yamaç, S. S., & Todorovic, M. (2020). Estimation of daily potato crop evapotranspiration using three different machine learning algorithms and four scenarios of available meteorological data. *Agricultural Water Management*, 228, 105875.
- Yang, W., Kobayashi, H., Wang, C., Shen, M., Chen, J., Matsushita, B., Tang, Y., Kim, Y., Bret-Harte, M.S., Zona, D., Oechel, W., & Kondoh, A. (2019). A Semi-Analytical Snow-Free Vegetation Index for Improving Estimation of Plant Phenology in Tundra and Grassland Ecosystems. *Remote Sensing of Environment*, 228, 31-44.
- Yebra, M., Van Dijk, A., Leuning, R., Huete, A., & Guerschman, J.P. (2013). Evaluation of Optical Remote Sensing to Estimate Actual Evapotranspiration and Canopy Conductance. *Remote Sensing of Environment*, 129, 250-261.