

A novel method based on Landsat 8 and MODIS satellite images to estimate monthly reference evapotranspiration in arid and semi-arid climates

Hamed Talebi¹ , Saeed Samadianfard^{2*} , Khalil Valizadeh Kamran³ 

¹ Ph.D. Student, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran

² Associate Professor, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran

³ Professor, Department of Remote Sensing and GIS, University of Tabriz, Tabriz, Iran

Abstract

Introduction

Accurate estimation of reference evapotranspiration (ET_0) is essential in water management in the agricultural sector, especially for arid and semi-arid climates. ET_0 plays a vital role in the water and energy cycle and is an essential link between ecological and hydrological processes. Therefore, accurately estimating ET_0 is a major issue for understanding the water cycle in continuous soil-plant-atmosphere systems. The traditional ET_0 estimation methods are mainly based on physical principles, such as Priestley-Taylor, Hargreaves, and Samani, which have many limitations in accurate ET_0 estimation in cases of minimum meteorological parameters (such as radiation solar, wind speed, and air temperature). Numerous studies have focused on ET_0 estimation using terrestrial data. However, in the case of a lack of meteorological stations, the conventional methods of estimating ET_0 using ground data will be inefficient, so remote sensing (RS) provides the possibility to fill such a gap, in such conditions, satellite images are the most effective for evaluating ET_0 in large areas. Because satellite images have a suitable spatial and temporal resolution, the time series of satellite images can be used to estimate ET_0 . The successful estimation of ET_0 from satellite images paved the way for its prediction using artificial intelligence models. The primary satellite imagery sources can be obtained from Landsat, Moderate Resolution Imaging Spectroradiometer (MODIS), and Global Land Surface Satellite (GLASS). Remote sensing data provides the possibility of recording more information through satellite images. Remote sensing methods can be used to extract vegetation information and different types of radiation, which help estimate ET_0 .

Materials and Methods

In the current research, two different agro-climatic locations including Ahvaz and Tabriz stations were selected. According to De Martonne classification method, Ahvaz was classified as dry climate and Tabriz as semi-arid climate. In this research, random forest (RF) and multi-layer perceptron (MLP) algorithms have been used to estimate monthly ET_0 in Ahvaz and Tabriz stations. The input parameters were selected from Landsat 8 and MODIS satellite images in the time period of 2014 to 2021. The utilized parameters were the monthly average, Landsat Land Surface Temperature (LST_{Land}), MODIS Land Surface Temperature (LST_{MOD}), Landsat Satellite Normalized Difference Vegetation Index ($NDVI_{Land}$) and MODIS Normalized Difference Vegetation Index ($NDVI_{MOD}$). To evaluate the accuracy of the input parameters and models, the estimated monthly ET_0 was evaluated with the monthly ET_0 of the FAO-Penman-Monteth equation.

Results and Discussion

The input parameters for implemented models were Landsat land surface temperature (LST_{Land}), MODIS land surface temperature (LST_{MOD}), Landsat Satellite Normalized Difference Vegetation Index ($NDVI_{Land}$), and MODIS Normalized Difference Vegetation Index ($NDVI_{MOD}$). Six possible scenarios were defined to estimate monthly ET_0 . The first two scenarios were considered as a single parameter (scenarios 1 and 2) and other scenarios were evaluated with two input parameters. Scenarios 3 and 4 were evaluated based on the parameters of the Landsat satellite and MODIS sensor, respectively. In scenarios 5 and 6, monthly ET_0 was estimated with Landsat and MODIS NDVI and Landsat and MODIS LST, respectively, to determine the effect of NDVI and LST values on ET_0 estimation. According to the obtained results, for the MLP and RF models in Ahvaz station,

the value of R^2 ranges from 0.440 to 0.972 and 0.271 to 0.983, respectively. In Ahvaz station, the lowest and highest RMSE is $0.279 \text{ mm}\cdot\text{month}^{-1}$ (RF-5 model) and $1.396 \text{ mm}\cdot\text{month}^{-1}$ (RF-4 model), respectively. Additionally, in this station, the highest and lowest values of NS are 0.962 (RF-5 model) and 0.042 (RF-4 model), respectively. According to the obtained results, in estimating the monthly ET_0 , the best performance is related to MLP-6 ($R^2=0.972$, $RMSE=0.348$, and $NS=0.940$) and RF-4 ($R^2=0.983$, $RMSE=0.279$, and $NS=0.962$). The highest and lowest values of R^2 in Tabriz station were 0.988 and 0.186, respectively. Moreover, MLP-4 and RF-5 models in this station have the lowest and highest RMSE, respectively. The results showed that in Tabriz station, the best performances were related to MLP-4 ($R^2=0.988$, $RMSE=0.299$, and $NS=0.935$) and RF-4 ($R^2=0.979$, $RMSE=0.302$, and $NS=0.933$). In addition, in this station, the RF-5 model has the weakest performance among all models with $R^2=0.186$, $RMSE=1.169$, and $NS=0.012$.

Conclusion

The results showed that 1) the accuracy of monthly ET_0 estimation in Ahvaz (arid climate) and Tabriz stations (semi-arid climate) with scenario 4 including LST_{MOD} and $NDVI_{MOD}$ was better than other investigated scenarios; 2) in estimating monthly ET_0 using a single input parameter including LST_{Land} (scenario 1) and LST_{MOD} (scenario 2), in both Ahvaz and Tabriz stations, scenario 2 had better performance with both MLP and RF models; 3) estimation of monthly ET_0 in Ahvaz and Tabriz stations has performed best with RF-4 and MLP-4 models, respectively, with LST_{MOD} and $NDVI_{MOD}$ input parameters (scenario 4); 4) in the comparison of scenario 5 ($NDVI_{Land}$, $NDVI_{MOD}$) and scenario 6 (LST_{Land} , LST_{MOD}) in both RF and MLP models, scenario 6 has the best performance in estimating monthly ET_0 ; and 5) in the comparison of monthly ET_0 estimation in both arid and semi-arid climates, the best performance with a high correlation coefficient was obtained with the MLP model in semi-arid climates.

Keywords: Landsat, Land surface temperature, MODIS, Multilayer perceptron, Random forest

Article Type: Research Article

*Corresponding Author, E-mail: s.samadian@tabrizu.ac.ir

Citation: Talebi, H., Samadianfard, S., & Kamran, K.V. (2023). A novel method based on Landsat 8 and MODIS satellite images to estimate monthly reference evapotranspiration in arid and semi-arid climates. *Water and Soil Management and Modeling*, 3(3),180-195.

DOI: 10.22098/mmws.2023.12048.1198

DOR: 20.1001.1.27832546.1402.3.3.12.4

Received: 04 January 2023, Received in revised form: 15 January 2023, Accepted: 15 January 2023, Published online: 15 January 2023

Water and Soil Management and Modeling, Year 2023, Vol. 3, No. 3, pp. 180-195

Publisher: University of Mohaghegh Ardabili

© Author(s)





روش جدید مبتنی بر تصاویر ماهواره لندست ۸ و سنجنده مادیس برای تخمین تبخیر و تعرق مرجع ماهانه در دو اقلیم خشک و نیمه‌خشک

حامد طالبی^۱، سعید صمدیان فرد^{۲*}، خلیل ولیزاده کامران^۳

^۱ دانشجوی دکتری، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران

^۲ دانشیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران

^۳ استاد، گروه سنجش از دور، دانشکده برنامه‌ریزی و علوم محیطی، دانشگاه تبریز، تبریز، ایران

چکیده

مدیریت آب کشاورزی و برنامه‌ریزی آبیاری به برآورد دقیق تبخیر و تعرق مرجع (ET_0) وابسته هستند. با استفاده از تصاویر ماهواره‌ای می‌توان در مناطق فاقد ایستگاه هواشناسی، کمبود اطلاعات آب و هوایی را جبران کرد. بنابراین، در این مطالعه، الگوریتم‌های جنگل تصادفی (RF) و پرسپترون چندلایه (MLP) برای برآورد تبخیر و تعرق مرجع ماهانه در ایستگاه‌های اهواز (اقلیم خشک) و تبریز (اقلیم نیمه‌خشک) با استفاده از پارامترهای استخراج شده از تصاویر ماهواره لندست ۸ و سنجنده مادیس اجرا شده است. لازم به ذکر است که پایگاه داده بر اساس داده‌های تصاویر ماهواره‌ای جمع‌آوری شده از سال ۱۳۹۲ تا ۱۴۰۰ ایجاد شد. همچنین برای توسعه مدل‌های مذکور، از داده‌های سال‌های ۱۳۹۲-۱۳۹۸ (۷۵ درصد) برای آموزش مدل و داده‌های باقی‌مانده (۲۵ درصد) برای آزمایش مدل استفاده شد. علاوه بر این، متغیرهای ورودی، شامل دمای سطح زمین لندست (LST_{Land})، دمای سطح زمین مادیس (LST_{MOD})، شاخص نرمال شده تفاوت پوشش گیاهی ماهواره لندست ($NDVI_{Land}$) و شاخص نرمال شده تفاوت پوشش گیاهی سنجنده مادیس ($NDVI_{MOD}$) برای تخمین ET_0 ماهانه استفاده شد. همچنین، سه شاخص عملکرد ضریب تعیین (R^2)، ریشه میانگین مربعات خطا (RMSE) و ضریب نش-ساتکلیف (NS) به منظور تعیین توانایی مدل‌های اجرا شده مورد استفاده قرار گرفت. نتایج نشان داد که دقت برآورد تبخیر و تعرق مرجع ماهانه در ایستگاه اهواز و تبریز با سناریوی ۴ شامل پارامترهای ورودی LST_{MOD} و $NDVI_{MOD}$ بهتر از سایر سناریوهای مورد بررسی است. همچنین برآورد تبخیر و تعرق مرجع ماهانه در ایستگاه اهواز و تبریز به ترتیب با مدل $RF-4$ ($NS=0.962$ و $RMSE=0.279$ ، $R^2=0.983$) و $RF-4$ ($NS=0.988$ ، $RMSE=0.299$ و $R^2=0.935$) بهترین عملکرد را داشته است. در نهایت چنین نتیجه‌گیری شد که کاربرد داده‌های حاصل از تصاویر سنجنده مادیس نسبت به ماهواره لندست ۸ در برآورد تبخیر و تعرق مرجع ماهانه دقیق‌تر است.

واژه‌های کلیدی: پرسپترون چندلایه، جنگل تصادفی، دمای سطح زمین، لندست، مادیس

نوع مقاله: پژوهشی

*مسئول مکاتبات، پست الکترونیکی: s.samadian@tabrizu.ac.ir

استناد: طالبی، حامد، صمدیان فرد، سعید، و ولیزاده کامران، خلیل (۱۴۰۲). روش جدید مبتنی بر تصاویر ماهواره لندست ۸ و سنجنده مادیس برای تخمین تبخیر و تعرق مرجع ماهانه در دو اقلیم خشک و نیمه‌خشک. *مدل‌سازی و مدیریت آب و خاک*، ۳(۳)، ۱۸۰-۱۹۵.

DOI: 10.22098/mmws.2023.12048.1198

DOR: 20.1001.1.27832546.1402.3.3.12.4

تاریخ دریافت: ۱۴۰۱/۱۰/۱۴، تاریخ بازنگری: ۱۴۰۱/۱۰/۲۵، تاریخ پذیرش: ۱۴۰۱/۱۰/۲۵، تاریخ انتشار: ۱۴۰۱/۱۰/۲۵

مدل‌سازی و مدیریت آب و خاک، سال ۱۴۰۲، دوره ۳، شماره ۳، شماره صفحه ۱۸۰ تا ۱۹۵

ناشر: دانشگاه محقق اردبیلی

© نویسندگان



۱- مقدمه

برآورد دقیق تبخیر و تعرق مرجع (ET₀) در مدیریت آب در بخش کشاورزی به‌ویژه برای اقلیم‌های خشک و نیمه‌خشک، ضروری است. تبخیر و تعرق مرجع نقش حیاتی در چرخه آب و انرژی ایفا می‌کند و یک پیوند مهم بین فرآیندهای اکولوژیکی و هیدرولوژیکی است (Sattari et al., 2021). بنابراین، چگونگی برآورد دقیق تبخیر و تعرق مرجع یک مسئله اصلی برای درک چرخه آب در سیستم‌های پیوسته خاک-گیاه-اتمسفر است. روش‌های تخمین سنتی تبخیر و تعرق مرجع عمدتاً روش‌هایی بر اساس اصول فیزیکی هستند، مانند پرستلی-تیلور^۱ (Priestley and Taylor, 1972)، هارگریوز و سامانی^۲ (Hargreaves and Samani, 1985) و فائو-پنمن-مانتیث^۳ (FAO-PM) (Allen et al., 1998) که دارای محدودیت‌های زیادی در برآورد دقیق تبخیر و تعرق مرجع در مواردی که فاقد پارامترهای هواشناسی (مانند تابش خورشیدی، سرعت باد و دمای هوا) هستند (Wu et al., 2021).

Tafi et al. (2021) روش‌های تجربی تخمین تبخیر و تعرق مرجع شامل روش‌های مبتنی بر دما، تابش و انتقال جرم و نیز پنج مدل مختلف روش والیانتراس از طریق مقایسه با روش فائو-پنمن-مانتیث به‌عنوان روش مرجع، ارزیابی کردند. نتایج نشان داد که از میان روش‌های تجربی مبتنی بر دما، روش هارگریوز-سامانی در شش ایستگاه، روش تراچکویک در دو ایستگاه و نیز روش بلانی-کریدل در یک ایستگاه بهترین عملکرد را داشتند. از بین روش‌های تجربی مبتنی بر تابش، روش جنسن-هیز در هفت ایستگاه و روش آبتیو در سه ایستگاه بهترین عملکرد را ارائه دادند. نتایج حاکی از تخمین کم‌تر تبخیر و تعرق گیاه مرجع توسط هر سه روش تجربی مبتنی بر انتقال جرم نسبت به روش مرجع فائو-پنمن-مانتیث بود. تکنیک‌های هوش مصنوعی^۴ (AI) مبتنی بر یادگیری ماشین^۵ (ML) با موفقیت در برآورد فرآیندهای پیچیده و غیرخطی در علوم طبیعی، به‌ویژه هیدرولوژی استفاده شده است (Koch et al., 2019). بنابراین، روش‌هایی مانند ML و یادگیری عمیق^۶ (DL) در تخمین و پیش‌بینی تبخیر و تعرق مرجع محبوبیت پیدا کرده‌اند. Tabari et al. (2013) برای تخمین تبخیر و تعرق مرجع در اقلیم

نیمه‌خشک از شبکه پرسپترون چندلایه^۸ (MLP) استفاده کردند. نتایج آن‌ها نشان داد که مدل MLP با استفاده از تمام پارامترهای هواشناسی بهترین عملکرد را در بین سایر مدل‌ها داشته است. Antonopoulos et al. (2017) برای برآورد تبخیر و تعرق مرجع با داده‌های هواشناسی روزانه از MLP و روش‌های تجربی پرستلی-تیلور، مکینک، هارگریوز و انتقال جرم استفاده کردند. نتایج آن‌ها نشان داد که مدل MLP تبخیر و تعرق مرجع را با دقت بهتری نسبت به مدل‌های تجربی با ریشه میانگین مربعات خطا^۹ (RMSE) از ۰/۵۷۴ تا ۱/۳۳ میلی‌متر در روز و ضریب تعیین^{۱۰} (R²) از ۰/۹۵۵ تا ۰/۹۸۶ برآورد می‌کنند. Huang et al. (2019) روش جنگل تصادفی^۱ (RF) و رگرسیون بردار پشتیبان^۲ (SVR) را در تخمین مقادیر تبخیر و تعرق مرجع روزانه در پنج منطقه مرطوب چین با داده‌های محدود و کامل بررسی کردند. نتایج نشان داد که با کمبود داده، روش‌های SVR و RF نتایج رضایت‌بخشی ارائه می‌دهند. تعداد زیادی از مطالعات در جهت تخمین تبخیر و تعرق مرجع با استفاده از داده‌های زمینی متمرکز شده‌اند (Panahi et al., 2016, Samadianfard and Panahi, 2019). با این حال، در مناطقی که فاقد ایستگاه‌های هواشناسی باشند، اطلاعات سنجش از دور امکان‌پذیر کردن چنین کمبودی را فراهم می‌کند. در چنین شرایطی، تصاویر ماهواره‌ای مؤثرترین و مقرون به‌صرفه‌ترین روش برای ارزیابی تبخیر و تعرق مرجع در مناطق وسیع هستند (Fawzy et al., 2021).

با توجه به این‌که تصاویر ماهواره‌ای از تفکیک مکانی و زمانی مناسبی برخوردار هستند، بنابراین در جهت تخمین تبخیر و تعرق مرجع می‌توان از سری زمانی تصاویر ماهواره‌ای استفاده کرد (Hadadi et al., 2022). تخمین موفقیت‌آمیز تبخیر و تعرق مرجع از تصاویر ماهواره‌ای، راه را برای پیش‌بینی آن با استفاده از مدل‌های هوش مصنوعی باز کرد (Talebi et al., 2023). منابع اصلی تصاویر ماهواره‌ای را می‌توان از لندست^۳، طیف رادیومتری تصویربرداری با وضوح متوسط^۴ (MODIS) و ماهواره جهانی سطح زمین^۵ (GLASS) به‌دست آورد. داده‌های سنجش از دور امکان ثبت اطلاعات بیش‌تر توسط تصاویر ماهواره‌ای را فراهم

⁸ Multilayer perceptron

⁹ Root mean squared error

¹ Coefficient of determination 0

¹ Random forest 1

¹ Support Vector Regression 2

¹ Landsat 3

¹ Moderate Resolution Imaging Spectroradiometer

¹ Global Land Surface Satellite 5

¹ Reference evapotranspiration

² Priestley-Taylor

³ Hargreaves and Samani

⁴ FAO-56 Penman-Monteith

⁵ Artificial intelligence

⁶ Machine learning

⁷ Deep learning

شامل شبکه عصبی مصنوعی^۸ (ANN) و درخت مدل M5 برای تخمین مقادیر تبخیر و تعرق مرجع در نظر گرفته‌اند و نتایج را با تبخیر و تعرق مرجع به‌دست آمده از معادله FAO-PM مقایسه کردند. به‌طور کلی، نتایج نشان داد که هر دو مدل می‌توانند به درستی تبخیر و تعرق مرجع را با استفاده از داده‌های LST به‌دست آمده از مادیس تخمین بزنند. با این حال، برآورد تبخیر و تعرق مرجع با استفاده از الگوریتم‌های یادگیری ماشین و پارامترهای سنجش از دور در مراحل اولیه است، بنابراین ترکیب پارامترهای سنجش از دور حاصل شده از تصاویر ماهواره‌ای متنوع و استفاده از الگوریتم‌های پیشرفته هوش مصنوعی می‌تواند نتایج تحقیقات را بهبود بخشد. علاوه بر این، نتایج سنجش از دور در تخمین تبخیر و تعرق مرجع در اقلیم‌های مختلف و مقایسه آن‌ها یک شکاف تحقیقاتی قابل توجه است. هدف از این تحقیق، برآورد تبخیر و تعرق مرجع ماهانه در دو اقلیم مختلف با استفاده از پارامترهای به‌دست آمده از ماهواره لندست و سنجنده مادیس و مقایسه دقت برآورد آن‌هاست. همچنین بررسی دقت الگوریتم‌های یادگیری ماشین با ترکیب ورودی‌های پارامترهای ماهواره‌های لندست و مادیس در برآورد تبخیر و تعرق مرجع ماهانه مورد ارزیابی قرار می‌گیرد.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

با افزایش کمبود آب، به‌ویژه در اقلیم‌های خشک و نیمه‌خشک، بهره‌برداری ایمن از منابع آبی برای توسعه پایدار در این اقلیم‌ها بسیار مهم است. به این منظور، در پژوهش حاضر دو موقعیت مختلف زراعی اقلیمی شامل ایستگاه‌های اهواز و تبریز انتخاب شدند. مشخصات اقلیمی و مشخصات مکانی دو ایستگاه مذکور در جدول ۱ و نقشه‌های موقعیت ایستگاه‌های مورد مطالعه در شکل ۱ نشان داده شده‌اند. بر اساس روش دومارتن اصلاح شده، اهواز جزء اقلیم خشک (Valipour, 2016) و تبریز جزء اقلیم نیمه‌خشک (Eslamian et al., 2011) طبقه‌بندی شدند.

۲-۲- روش تحقیق

در این تحقیق به‌منظور برآورد تبخیر و تعرق مرجع ماهانه در دو ایستگاه اهواز و تبریز، از الگوریتم‌های جنگل تصادفی (RF) و پرسپترون چندلایه (MLP) استفاده شده است. پارامترهای ورودی از تصاویر ماهواره لندست ۸ و سنجنده مادیس در بازه زمانی ۱۳۹۲ تا ۱۴۰۰ انتخاب شدند. پارامترهای مورد استفاده شامل میانگین

می‌کند. در واقع می‌توان از روش سنجش از دور برای استخراج اطلاعات پوشش گیاهی و همچنین انواع مختلف تابش استفاده کرد که برای تخمین تبخیر و تعرق مرجع مفید هستند (Chia et al., 2020).

Kim et al. (2020) با استفاده از روش‌های یادگیری ماشینی (ML) با محصولات تصاویر ماهواره‌ای سنجنده مادیس و داده‌های هواشناسی اقدام به بازیابی تبخیر و تعرق مرجع کردند. روش استاندارد فائو-پنمن-مونتیت برای محاسبه تبخیر و تعرق مرجع به‌عنوان روش مبنای مد نظر قرار گرفته است. برای بازیابی تبخیر و تعرق مرجع روزانه از چندین متغیر ورودی استفاده شده است: شاخص گیاهی تفاوت نرمال شده (NDVI)، شاخص سطح برگ^۱ (LAI) و کسری از تابش فعال فتوسنتزی^۲ (FPAR) از سنجنده مادیس و دمای هوا، دمای سطح زمین، دمای خاک، رطوبت نسبی و سرعت باد که از ایستگاه‌های هواشناسی به‌دست آمده است. نتایج نشان داد که مدل تبخیر و تعرق مرجع مبتنی بر ML دارای جذر میانگین مربعات خطا (RMSE) ۱/۰۳۸ میلی‌متر در روز و ضریب تعیین ($R^2 = ۰/۸۷۰$) بود. آن‌ها نشان دادند که رطوبت نسبی و دمای سطح زمین تأثیرگذارترین متغیرها برای مدل تبخیر و تعرق مرجع مبتنی بر ML هستند. Zhang et al. (2018) به بررسی روش تخمین تبخیر و تعرق مرجع براساس داده‌های سنجش از دور پرداختند. در این روش، داده‌های سنجش از دور با الگوریتم‌های یادگیری ماشین ترکیب می‌شوند تا مدلی برای تخمین مکانی تبخیر و تعرق مرجع ایجاد کنند. در مطالعه مذکور، سه الگوریتم ماشین بردار پشتیبان^۳ (SVM)، شبکه عصبی پس‌انتشار^۴ (BP) و سیستم استنتاج فازی عصبی تطبیقی^۵ (ANFIS) مورد آزمایش قرار گرفتند. نتایج نشان داد که روش‌های یادگیری ماشین توانایی خوبی در تخمین تبخیر و تعرق مرجع دارد. همچنین، دمای سطح زمین را می‌توان برای تخمین دقیق تبخیر و تعرق مرجع با ضرایب تعیین بالا ($R^2 = ۰/۸۹۷ - ۰/۹۱۵$) استفاده کرد.

Alipour et al. (2014) در تحقیقی به‌منظور برآورد تبخیر و تعرق مرجع از دمای سطح زمین^۶ (LST) سنجنده مادیس استفاده کردند. آن‌ها داده‌های LST را به‌عنوان ورودی دو مدل داده محور

¹ Normalized Difference Vegetation Index

² Leaf area index

³ Fraction of photosynthetically active radiation

⁴ Support vector machine

⁵ Back-propagation neural network

⁶ Adaptive neuro fuzzy inference system

⁷ Land surface temperature

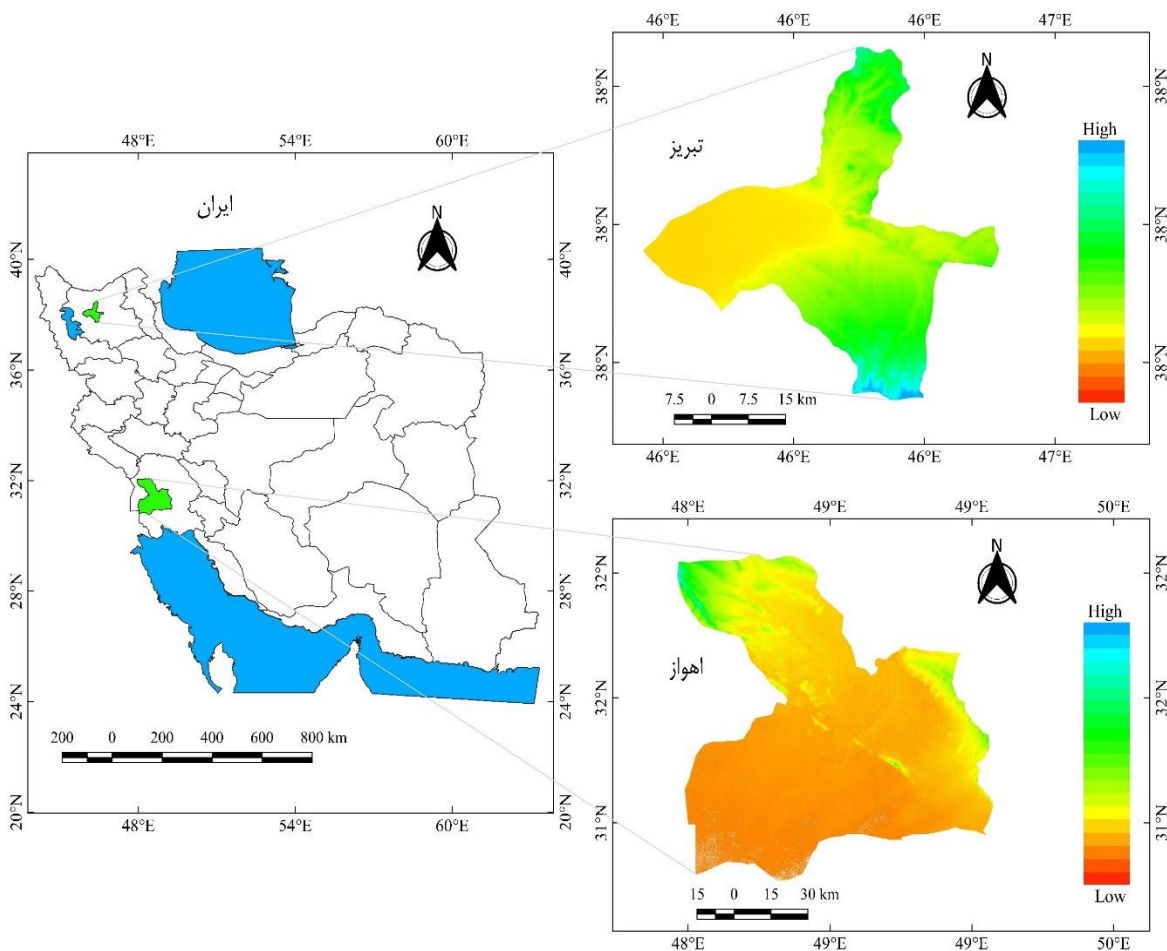
⁸ Artificial neural network

برای ارزیابی دقت پارامترهای ورودی و مدل‌ها، تبخیر و تعرق مرجع ماهانه برآورد شده با تبخیر و تعرق مرجع ماهانه معادله فائو-پنمن-مانتیث مورد ارزیابی قرار گرفت. در این پژوهش، مقایسه دقت مدل‌ها با استفاده از نمودار تیلور در زبان برنامه‌نویسی R استفاده شد. ساختار مراحل مختلف مورد مطالعه در شکل (۲) نشان داده شده است.

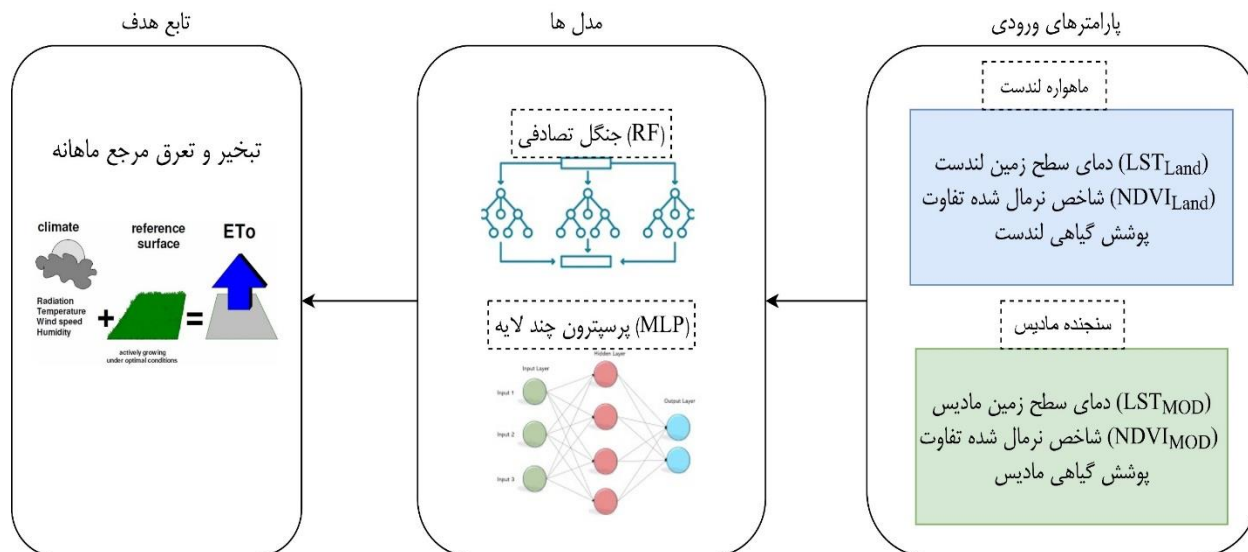
ماهانه، دمای سطح زمین لندست (LST_{Land})، دمای سطح زمین مادیس (LST_{MOD})، شاخص نرمال شده تفاوت پوشش گیاهی ماهواره لندست ($NDVI_{Land}$) و شاخص نرمال شده تفاوت پوشش گیاهی سنجنده مادیس ($NDVI_{MOD}$) است. مجموعه داده مورد استفاده برای ساخت مدل شامل ۹۶ داده (۱۳۹۲-۱۴۰۰) است که ۷۵ درصد داده‌ها (۱۳۹۲-۱۳۹۸) برای مرحله آموزش و ۲۵ درصد داده‌ها (۱۳۹۹-۱۴۰۰) برای مرحله آزمایش تقسیم‌بندی شده‌اند.

جدول ۱- مشخصات ایستگاه‌های مورد مطالعه
Table 1- Characteristics of the studied stations

ایستگاه	عرض جغرافیایی	طول جغرافیایی	ارتفاع (متر)	اقلیم
اهواز	31.3442°	48.7442°	22.5	خشک
تبریز	38.1219°	46.2422°	1361	نیمه خشک



شکل ۱- موقعیت و رقوم ارتفاعی ایستگاه‌های مورد مطالعه
Figure 1- The location and altitude of the studied stations



شکل ۲- نمودار جریان‌ی روش برآورد تبخیر و تعرق مرجع در منطقه مورد مطالعه
Figure 2 -Flowchart of the model to estimate ET_0 in the study sites

اکولوژیکی و تحقیقات تغییرات آب و هوایی مهم است. دمایی که هنگام لمس سطح زمین احساس می‌شود یا دمای پوست زمین به‌عنوان دمای سطح زمین نامیده می‌شود. بسیاری از زمینه‌های تحقیقاتی، مانند تغییرات آب و هوایی جهانی، چرخه‌های هیدرولوژیکی، کشاورزی و کاربری پوشش زمین، به‌شدت به LST متکی هستند (Kumar et al., 2022). NDVI معیاری است که سبزی و سلامت پوشش گیاهی را در هر پیکسل در یک تصویر ماهواره‌ای اندازه‌گیری می‌کند (Kumar et al., 2020). NDVI یکی از پرکاربردترین شاخص‌های پوشش گیاهی در سنجش از دور است. مقدار NDVI از +۱ تا -۱ متغیر است. مقادیر مثبت و منفی به تمایز بین مناطق پوشش گیاهی و غیررویشی کمک می‌کند (Taloor et al., 2021).

۲-۴- معرفی ماهواره لندست ۸ و سنجنده مادیس

لندست ۸ یکی از ماهواره‌های سری لندست ناسا (سازمان ملی هوانوردی و فضایی) است که در ۱۱ فوریه ۲۰۱۳ به فضا پرتاب شد. این ماهواره ۱۶ روز دوره چرخه تکرار دارد. در پایگاه اطلاعاتی سازمان زمین‌شناسی ایالات متحده (USGS) داده‌های لندست ۸ به‌صورت رایگان در دسترس است. این ماهواره دارای دو سنسور است: تصویرگر زمین عملیاتی^۱ (OLI) و سنسور حرارتی مادون قرمز^۲ (TIRS) (Dehghani et al., 2022). سنسور OLI در

مطالعات نشان داده که روش FAO-PM به‌عنوان دقیق‌ترین روش محاسباتی در شرایط مختلف آب و هوایی است (Djaman et al., 2015). بنابراین این روش برای تخمین تبخیر و تعرق مرجع در در همه اقلیم‌ها توصیه شده است (Allen et al., 1998). در این پژوهش، روش استاندارد FAO-PM برای محاسبه تبخیر و تعرق مرجع ماهانه به‌عنوان روش مبنا مطابق رابطه (۱) مرد نظر قرار گرفته است (رابطه ۱) (Allen et al., 1998).

$$ET_0 = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T_{min} + 273} U_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34U_2)} \quad (1)$$

در این رابطه، ET_0 تبخیر و تعرق گیاه مرجع (mm day^{-1})، Δ شیب منحنی فشار بخار اشباع ($\text{kPa } ^\circ\text{C}^{-1}$)، R_n تابش خالص خورشیدی ($\text{MJ m}^{-2} \text{d}^{-1}$)، G چگالی شار حرارتی خاک ($\text{MJ m}^{-2} \text{d}^{-1}$)، γ ثابت سایکرومتری ($\text{kPa } ^\circ\text{C}^{-1}$)، T_{min} متوسط دمای هوا ($^\circ\text{C}$)، U_2 متوسط سرعت باد در ارتفاع دو متری از سطح زمین (ms^{-1})، e_s فشار بخار اشباع (kPa) و e_a نیز فشار بخار واقعی (kPa) هستند.

۲-۳- پارامترهای تصاویر ماهواره‌ای

در این پژوهش به‌منظور برآورد تبخیر و تعرق مرجع ماهانه از دمای سطح زمین (LST) و شاخص نرمال شده تفاوت پوشش گیاهی (NDVI) به‌دست آمده از ماهواره لندست ۸ و سنجنده مادیس استفاده شده است. فرآیند تبادل انرژی و آب بین سطح زمین و اتمسفر تحت تأثیر LST است. LST برای کاربردهای مختلفی از جمله مدل‌سازی هیدرولوژیکی، مدل‌سازی سطح زمین، مطالعات

¹ United States Geological Survey

² Operational land imager

³ Thermal infrared sensor

انسان است و می‌تواند برای ذخیره و یادآوری داده‌ها، طبقه‌بندی الگوها، انجام نقشه‌برداری کلی از الگوی ورودی به الگوی خروجی و گروه‌بندی الگوهای مشابه استفاده شود. شبکه‌های عصبی مصنوعی دو نوع فرآیند یادگیری را دنبال می‌کنند: نظارت شده و بدون نظارت. در یادگیری نظارت شده، شبکه با مقایسه خروجی پیش‌بینی شده با خروجی شناخته شده، دانش را به دست می‌آورد. در یادگیری بدون نظارت، شبکه برای مقایسه و یادگیری به دانش خروجی مربوطه نیاز ندارد و از طریق دوره‌های مکرر، الگوریتم یادگیری نقاط قوت اتصال را تنظیم می‌کند (Raju et al., 2006). پرسپترون چندلایه (MLP) رایج‌ترین نوع ANN برای یادگیری نظارت شده است و به طور گسترده برای مدل‌سازی فرآیندهای غیرخطی پیچیده در منابع آب و مسائل هیدرولوژی استفاده می‌شود (Talaee et al., 2012). این مطالعه به ارزیابی کاربرد شبکه‌های عصبی MLP برای تخمین تبخیر و تعرق مرجع ماهانه می‌پردازد. یک شبکه MLP پیشخور شامل یک لایه ورودی، یک لایه خروجی و یک یا چند لایه پنهان بین آن‌هاست. اتصالات بین لایه ورودی و لایه میانی یا پنهان حاوی وزنه‌هایی هستند که معمولاً از طریق آموزش سیستم تعیین می‌شوند. لایه پنهان ورودی‌های وزنی را جمع می‌کند و از تابع فعال‌سازی برای ایجاد یک مقدار خروجی استفاده می‌کند (Caudill and Butler, 1992). از نظر ریاضی، MLP را می‌توان به صورت رابطه ۲ نشان داد (Talebi et al., 2023):

$$y = f\left(\sum_{i=1}^n w_i p_i + b\right) \quad (2)$$

که در آن، w_i نشان‌دهنده بردار وزن، p_i بردار ورودی ($i = 1, 2, \dots, n$)، b بایاس، f تابع فعال‌سازی و y خروجی است. بایاس میزان اختلاف بین خروجی واقعی و خروجی تخمین شده توسط مدل را مشخص می‌کند. لازم به ذکر است که در محاسبات انجام یافته، برای لایه‌های ورودی، پنهان و خروجی، یک لایه در نظر گرفته شده و تابع سیگموئید برای ایجاد مقادیر خروجی مورد استفاده قرار گرفته است. همچنین، محاسبات مربوط به روش شبکه عصبی مصنوعی با استفاده از نرم‌افزار ریپدماینر انجام گرفته است.

۲-۷- توابع عملکرد

مقادیر خطای بین روش‌های محاسباتی توسط پارامترهای آماری جذر میانگین مربعات (RMSE)، ضریب تعیین (R^2) و ضریب نش^۴

مجموع دارای ۹ باند و هر باند با وضوح فضایی ۳۰ متر است (به جز باند پانکروماتیک-وضوح فضایی ۱۵ متر) و سنسور TIR دارای دو باند مادون قرمز موج بلند حرارتی با وضوح فضایی ۱۰۰ متر است (Sutariya et al., 2022). دستگاه طیف‌سنج تصویربرداری با وضوح متوسط (MODIS) یک حس‌گر ماهواره‌ای است که توسط سازمان ملی هوانوردی و فضایی (ناسا) برای نظارت بر محیط‌زیست زمین بر روی ماهواره‌های ترا (پرتاب شده در سال ۱۹۹۹) و آکوا^۲ (پرتاب شده در سال ۲۰۰۲) کار می‌کند. ترا تقریباً در ساعت ۱۰:۳۰ صبح به وقت محلی از شمال به جنوب از خط استوا می‌گذرد و آکوا تقریباً در ساعت ۱:۳۰ بعدازظهر به وقت محلی، از استوا از جنوب به شمال عبور می‌کند (Pagano and Durham, 1993). باندهای متعدد حس‌گر مادیس قادر به تفکیک فضایی ۲۵۰ متر، ۵۰۰ متر و یک کیلومتر هستند. دسترسی به طیف گسترده‌ای از محصولات سنجنش از راه دور پرکاربرد، مانند مادیس و لندست ۸، به راحتی از طریق برنامه کاربردی گوگل ارث انجین (GEE)^۳ امکان‌پذیر است (Moore and Hansen, 2011). در این پژوهش از تصاویر تصحیح شده ماهواره لندست ۸ و سنجنده مادیس از طریق سامانه GEE استفاده شد. جدول ۲ نشان‌دهنده اطلاعات مربوط به نام سنجنده، متغیر، ماهواره و وضوح مکانی و زمانی LST و NDVI مورد استفاده در این پژوهش است.

۲-۵- جنگل تصادفی

الگوریتم جنگل تصادفی (RF)، اولین بار توسط بریمن پیشنهاد شده (Breiman, 2001) که یک الگوریتم یادگیری ماشین مبتنی بر درخت تصمیم است. این الگوریتم به دلیل سادگی و قابلیت استفاده، هم برای دسته‌بندی و هم رگرسیون مورد استفاده قرار می‌گیرد. در RF، درخت‌های تصمیم در زیرمجموعه‌های مختلف داده‌های آموزشی برازش داده می‌شوند. مزیت الگوریتم RF در مقایسه با سایر الگوریتم‌ها این است که اهمیت هر یک از متغیرهای ورودی را تخمین می‌زند. در الگوریتم RF بسیاری از متغیرهای ورودی که ممکن است به پیش‌بینی کمک کنند، می‌توانند استفاده شوند (Chen et al., 2017).

۲-۶- پرسپترون چندلایه

شبکه عصبی مصنوعی (ANN) یک سیستم پردازش اطلاعات توزیع شده موازی است که شبیه شبکه‌های عصبی بیولوژیکی مغز

¹ Terra

² Aqua

³ Google Earth Engine

⁴ Nash-Sutcliffe efficiency

$$NS = 1 - \left[\frac{\sum_{i=1}^n x_i - y_i^2}{\sum_{i=1}^n (x_i - y_i)^2} \right] \quad (5)$$

در روابط فوق، n تعداد داده‌های مشاهده شده، y_i مقادیر تخمینی، x_i مقادیر مشاهده شده و \bar{x}_i میانگین مقادیر مشاهده شده هستند.

(NS) و با استفاده از رابطه‌های ۳ تا ۵ مورد بررسی قرار گرفت (Shrestha et al., 2010).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2} \quad (3)$$

$$R^2 = \frac{\sum (y_i - x_i)^2}{\sum (x_i - \bar{x}_i)^2} \quad (4)$$

جدول ۲- اطلاعات داده‌های سنجنش از دور
Table 2- Remote sensing data information

پارامتر	اختصار	ماهواره	سنجنده	وضوح مکانی	وضوح زمانی
دمای سطح زمین لندست	LST _{Land}	لندست ۸	OLI / TIRS	100 متر	16 روز
شاخص نرمال شده تفاوت پوشش گیاهی لندست	NDVI _{Land}	لندست ۸	OLI / TIRS	30 متر	16 روز
دمای سطح زمین مادیس	LST _{MOD}	آکوا	مادیس	1 کیلومتر	8 روز
شاخص نرمال شده تفاوت پوشش گیاهی مادیس	NDVI _{MOD}	آکوا	مادیس	250 متر	16 روز

۳- نتایج و بحث

مادیس برای تخمین تبخیر و تعرق مرجع ماهانه در دو ایستگاه اهواز (اقلیم خشک) و تبریز (اقلیم نیمه‌خشک) مورد استفاده قرار گرفته و دقت آن‌ها ارزیابی شد. جدول ۳ معیارهای آماری حداکثر، حداقل، میانگین و انحراف معیار را برای مجموعه داده‌ها در اقلیم‌های اهواز و تبریز است.

در پژوهش حاضر، مدل‌های RF و MLP با ترکیب ورودی‌های مختلف دمای سطح زمین ماهواره لندست ۸، دمای سطح زمین سنجنده مادیس، شاخص نرمال شده تفاوت پوشش گیاهی ماهواره لندست ۸ و شاخص نرمال شده تفاوت پوشش گیاهی سنجنده

جدول ۳- ویژگی‌های آماری داده‌های مورد استفاده
Table 3- Statistical characteristics of the data used

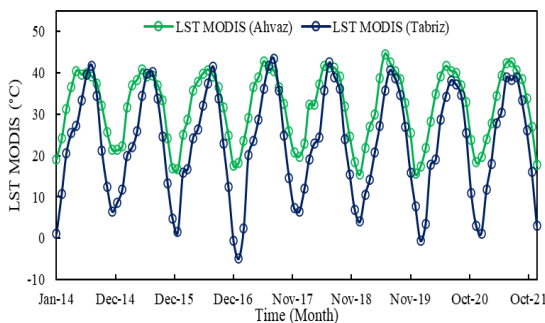
ایستگاه	پارامتر	واحد	حداکثر	حداقل	میانگین	انحراف معیار
اهواز	LST _{Land}	درجه سانتی‌گراد	47.86	-0.37	30.15	12.52
	LST _{MOD}	درجه سانتی‌گراد	44.57	15.46	31.76	8.41
	NDVI _{Land}	-	0.57	0.08	0.36	0.13
	NDVI _{MOD}	-	0.6	0.16	0.39	0.11
	ET ₀	میلی‌متر در ماه	5.68	1.06	3.44	1.42
تبریز	LST _{Land}	درجه سانتی‌گراد	52.29	-28.36	15.86	20.21
	LST _{MOD}	درجه سانتی‌گراد	43.46	-4.94	22.81	12.87
	NDVI _{Land}	-	0.69	0	0.28	0.17
	NDVI _{MOD}	-	0.68	0	0.35	0.16
	ET ₀	میلی‌متر در ماه	3.90	0.36	1.92	1.18

مورد بررسی است. باتوجه به شکل ۳، LST لندست و مادیس در ایستگاه اهواز بیش‌تر از ایستگاه تبریز است (شکل ۳). همچنین روند تغییرات LST مادیس نسبت به لندست دارای تغییرات ناگهانی کم‌تری است (شکل ۳ ب). باتوجه به شکل ۳ ج و د، در ماه‌هایی از

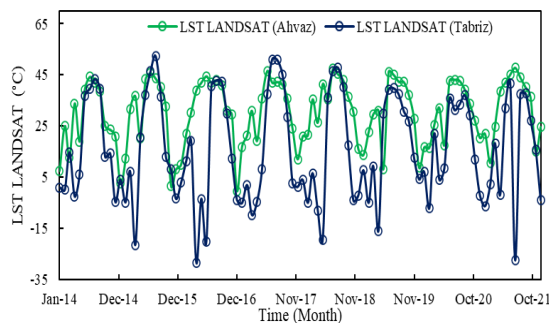
شکل ۳ نشان‌دهنده نمودار دمای سطح زمین ماهواره لندست ۸، دمای سطح زمین سنجنده مادیس، شاخص نرمال شده تفاوت پوشش گیاهی ماهواره لندست ۸ و شاخص نرمال شده تفاوت پوشش گیاهی سنجنده مادیس به‌صورت ماهانه برای سال‌های

حساسیت زیاد ماهواره لندست نسبت به سنجنده مادیس باشد. با توجه به شکل ۳ روند تغییرات تبخیر و تعرق مرجع ماهانه در هر دو ایستگاه یکسان بوده و میزان تبخیر و تعرق مرجع در ایستگاه اهواز بیش تر از ایستگاه تبریز است.

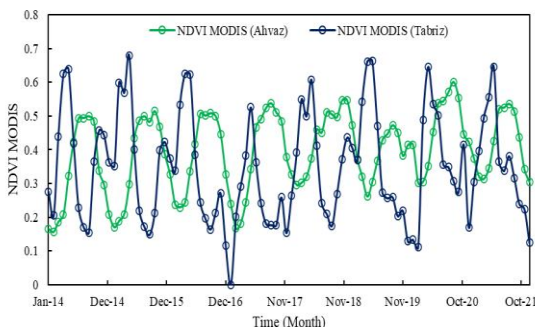
سال که در منطقه مورد مطالعه کشت وجود داشته، میزان NDVI افزایش و در ماه‌های که زمین آیش بوده میزان این پارامتر کاهش یافته است. تغییرات ناگهانی NDVI لندست، نسبت به مادیس بیشتر است که علت آن می‌تواند به دلیل مقیاس مکانی بهتر و



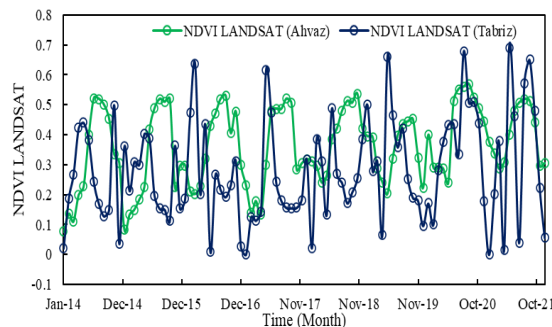
(ب)



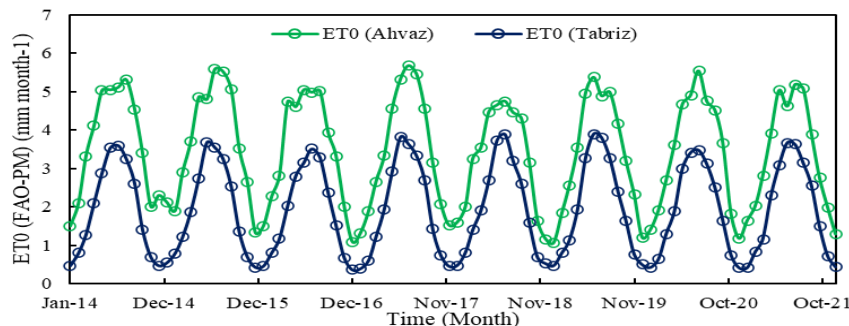
(الف)



(د)



(ج)



(ی)

شکل ۳- مقایسه پارامترهای ورودی برای دو ایستگاه اهواز و تبریز (الف) دمای سطح زمین لندست، (ب) دمای سطح زمین مادیس، (ج) شاخص نرمال شده تفاوت پوشش گیاهی لندست، (د) شاخص نرمال شده تفاوت پوشش گیاهی مادیس و (ی) تبخیر و تعرق مرجع ماهانه

Figure 3- Comparison of input parameters for two stations of Ahvaz and Tabriz a) Landsat land surface temperature, b) MODIS land surface temperature, c) Landsat normalized vegetation difference index, d) MODIS normalized vegetation difference index, and e) Monthly Reference evapotranspiration

ماهواره لندست ($NDVI_{Land}$) و شاخص نرمال شده تفاوت پوشش گیاهی سنجنده مادیس ($NDVI_{MOD}$). طبق جدول ۴، شش سناریوی ممکن برای تخمین تبخیر و تعرق مرجع ماهانه تعریف

جدول ۴ پارامترهای ورودی برای هر مدل را نشان می‌دهد که عبارتند از: دمای سطح زمین لندست (LST_{Land})، دمای سطح زمین مادیس (LST_{MOD})، شاخص نرمال شده تفاوت پوشش گیاهی

تعرق مرجع ماهانه به‌ترتیب با NDVI لندست و مادیس و LST لندست و مادیس برآورد شد تا تاثیر NDVI و LST در برآورد تبخیر و تعرق مرجع مشخص شود.

شده است. دو سناریوی اول به‌صورت تک پارامتر (سناریوهای ۱ و ۲) و سناریوهای بعدی با دو پارامتر ورودی در نظر گرفته شد. سناریوهای ۳ و ۴ به‌ترتیب بر اساس پارامترهای ماهواره لندست و سنجنده مادیس در نظر گرفته شد. در سناریوهای ۵ و ۶، تبخیر و

جدول ۴- ترکیب ورودی‌های مدل مورد مطالعه
Table 4- Composition of the inputs of the studied model

مدل	پارامترهای ورودی
1	LST _{Land}
2	LST _{MOD}
3	LST _{Land} , NDVI _{Land}
4	LST _{MOD} , NDVI _{MOD}
5	NDVI _{Land} , NDVI _{MOD}
6	LST _{Land} , LST _{MOD}

الگوریتم‌های MLP و RF را با استفاده از پارامترهای ورودی در دو ایستگاه اهواز و تبریز را در طول دوره مورد بررسی نشان می‌دهند. طبق شکل ۴، توزیع نقاط اطراف خط بهترین تناسب (۱:۱) در ایستگاه اهواز نسبت به ایستگاه تبریز در بیش‌تر مدل‌ها مناسب و متقارن است. طبق نتایج، در ایستگاه اهواز کم‌ترین همبستگی با مدل MLP-5 حاصل شده است، هم‌چنین همبستگی سه مدل MLP-2، MLP-4 و MLP-6 با هم برابر بوده و بیش‌ترین مقدار را دارند (شکل ۴-الف). در ایستگاه تبریز نیز، بیش‌ترین و کم‌ترین R^2 با مدل MLP به‌ترتیب MLP-4 و MLP-5 است. مقدار ضریب تعیین با مدل MLP در ایستگاه تبریز نسبت به ایستگاه اهواز در همه سناریوها، به‌جز سناریوی ۴ کم‌تر است. در مقایسه پراکندگی نقاط اطراف خط بهترین تناسب (۱:۱) در هر دو ایستگاه با مدل MLP، در ایستگاه اهواز توزیع نقاط تقارن مناسبی دارد (شکل ۴ الف-ب).

مدل RF در همه سناریوها در ایستگاه اهواز عملکرد بهتری نسبت به ایستگاه تبریز دارد. در ایستگاه‌های اهواز و تبریز بیش‌ترین و کم‌ترین R^2 با مدل RF به‌ترتیب RF-4 و RF-5 است. بنابراین سناریوی ۴ با ورودی‌های NDVI و LST سنجنده مادیس بهتر از سایر سناریوهاست. هم‌چنین سناریوی ۵ با ورودی NDVI مادیس و لندست کم‌ترین ضریب تعیین را در بین همه سناریوها دارد. (Yurtseven and Serengil (2021) به بررسی دقت مدل‌های پرسپترون چندلایه (MLP)، ماشین بردار پشتیبان (SVM)، جنگل تصادفی (RF) و رگرسیون خطی چندگانه (MLR) برای تخمین تبخیر و تعرق مرجع در منطقه نیمه‌خشک آناتولی ترکیه پرداختند. طبق نتایج آن‌ها، مدل MLP و SVM در مناطق

نتایج معیار ارزیابی برای دو مدل MLP و RF در مرحله آزمایش برای دو ایستگاه اهواز (اقلیم خشک) و تبریز (اقلیم نیمه‌خشک) در جدول ۵ آورده شده است. طبق نتایج به‌دست آمده، برای مدل MLP و RF در ایستگاه اهواز، مقدار R^2 به‌ترتیب از ۰/۳۴۰ تا ۰/۹۷۲ و ۰/۲۷۱ تا ۰/۹۸۳ متغیر است. در ایستگاه اهواز کم‌ترین و بیش‌ترین RMSE به‌ترتیب ۰/۲۷۹ (مدل RF-5) و ۱/۳۹۶ (مدل RF-4) میلی‌متر در ماه است. هم‌چنین در این ایستگاه بیش‌ترین و کم‌ترین مقدار NS به‌ترتیب ۰/۹۶۲ (مدل RF-5) و ۰/۰۴۲ (مدل RF-4) است. طبق نتایج حاصله، در برآورد تبخیر و تعرق مرجع ماهانه بهترین عملکرد با مدل‌های MLP و RF به‌ترتیب MLP-6 ($R^2=0/972$, $RMSE=0/348$, $NS=0/940$) و RF-4 ($R^2=0/983$, $RMSE=0/279$, $NS=0/962$) به‌دست آمده است. طبق نتایج جدول ۵ بیش‌ترین و کم‌ترین مقدار R^2 در ایستگاه تبریز، به‌ترتیب برابر با ۰/۹۸۸ و ۰/۱۸۶ است. هم‌چنین در این ایستگاه مدل MLP-4 و RF-5 به‌ترتیب کم‌ترین و بیش‌ترین ضریب تعیین NS به‌ترتیب NS=0.935 (MLP-4) و NS=0.012 (RF-5) است. نتایج نشان داد که در ایستگاه تبریز بهترین عملکرد با مدل MLP و RF به‌ترتیب MLP-4 ($R^2=0/988$, $RMSE=0/299$) و RF-4 ($R^2=0/979$, $RMSE=0/302$) و NS=0/935 است. هم‌چنین، در این ایستگاه مدل RF-5 ضعیف‌ترین عملکرد را در بین همه مدل‌ها با $R^2=0/186$, $RMSE=1/169$ و $NS=0/012$ دارد.

شکل ۴ نمودارهای پراکندگی مقادیر تبخیر و تعرق مرجع (P-M) و مقادیر تخمینی تبخیر و تعرق مرجع ماهانه به‌دست آمده از

ترکیب داده‌های ورودی مختلف به این نتیجه رسیدند که مدل RF به‌عنوان روشی بهتر در برآورد تبخیر و تعرق مرجع برای اقلیم‌های خشک است.

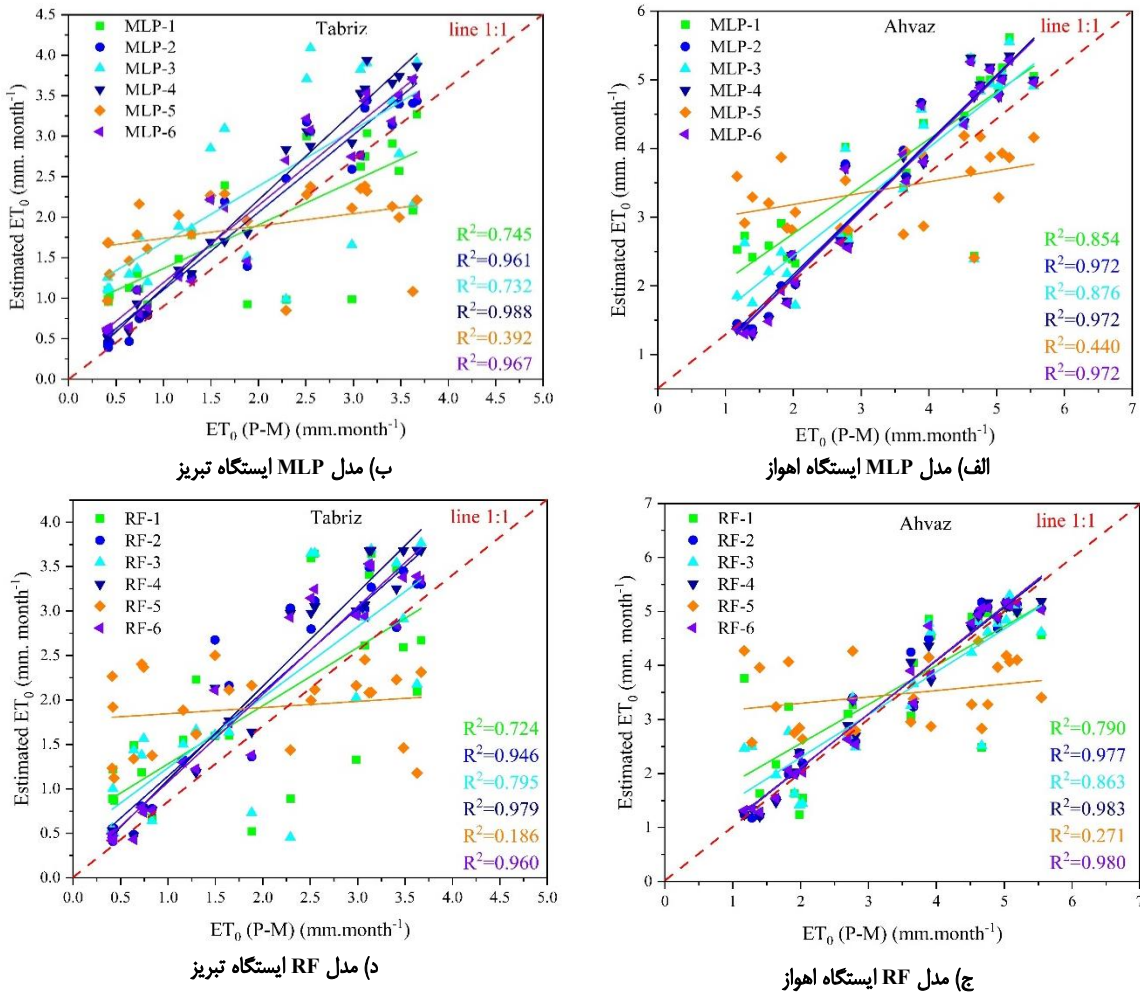
نیمه‌خشک بهتر از سایر مدل‌ها عمل کردند. همچنین، Wu et al. (2020) با استفاده از داده‌های ایستگاه هواشناسی به بررسی دقت برآورد تبخیر و تعرق مرجع در اقلیم خشک با مدل RF با استفاده از

جدول ۵- نتایج آماری برای ایستگاه اهواز و تبریز بر اساس مدل MLP و RF
Table 5- Statistical results for Ahvaz and Tabriz stations based on MLP and RF models

NS	RMSE	R ²	NS	RMSE	R ²	مدل
ایستگاه تبریز (اقلیم نیمه‌خشک)			ایستگاه اهواز (اقلیم خشک)			
0.552	0.782	0.745	0.673	0.816	0.854	MLP-1
0.919	0.332	0.961	0.936	0.360	0.972	MLP-2
0.367	0.930	0.732	0.757	0.703	0.876	MLP-3
0.935	0.299	0.988	0.939	0.352	0.972	MLP-4
0.153	1.076	0.392	0.189	1.284	0.440	MLP-5
0.918	0.335	0.967	0.940	0.348	0.972	MLP-6
0.491	0.834	0.724	0.593	0.910	0.790	RF-1
0.886	0.395	0.946	0.948	0.327	0.977	RF-2
0.588	0.750	0.795	0.742	0.752	0.863	RF-3
0.933	0.302	0.979	0.962	0.279	0.983	RF-4
0.012	1.169	0.186	0.042	1.396	0.271	RF-5
0.914	0.344	0.960	0.953	0.310	0.980	RF-6

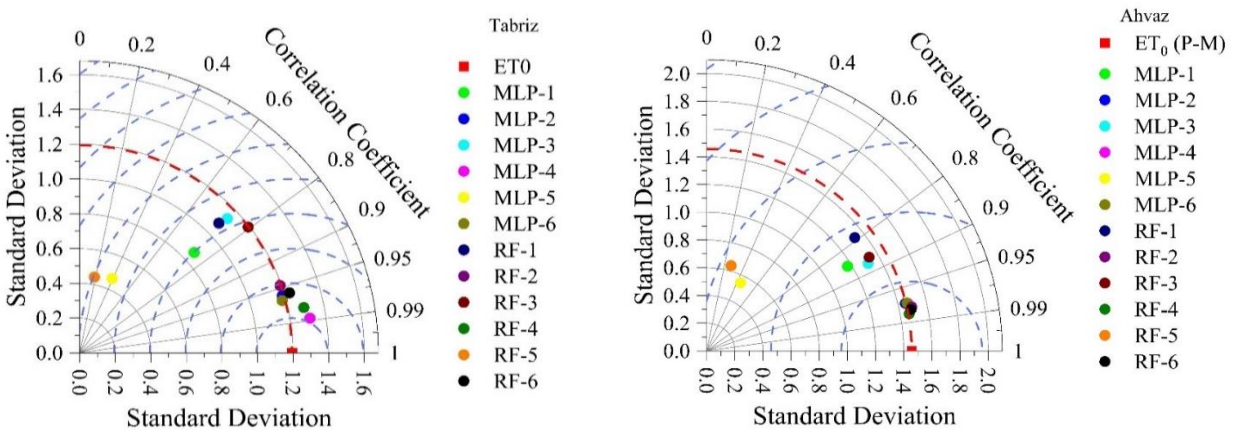
انطباقی بهتر تصاویر سنجنده مادیس با لندست ۸ در برآورد تبخیر و تعرق مرجع ماهانه احتمالاً به این دلیل است که، تصاویر لندست ۸ پیکسل‌های کوچک‌تری نسبت به سنجنده مادیس دارند و این باعث می‌شود که تصاویر ماهواره لندست از روند رشد گیاه نسبت به سنجنده مادیس تأثیر بیشتری بگیرد، این در حالی است که تبخیر و تعرق مرجع حاصله از معادله P-M با فرض گیاه مرجع (یونجه یا چمن) با آب کافی (بدون تنش) و بدون در نظر گرفتن دوره رشد گیاه مرجع، تبخیر و تعرق مرجع را حساب می‌کند. بنابراین تصاویر سنجنده مادیس نسبت به تصاویر ماهواره لندست کم‌تر تحت تأثیر روند رشد گیاه قرار گرفته و نتایج بهتری را ثبت کرده است. در پژوهشی (Nouri et al., 2017) به بررسی دقت تخمین تبخیر و تعرق واقعی با استفاده از الگوریتم تعادل انرژی سطح زمین (SEBAL) در تصاویر لندست و مادیس پرداختند. طبق نتایج آن‌ها، سنجنده مادیس نسبت به لندست ۸ با دقت بالا تبخیر و تعرق را محاسبه کرده است؛ به طوری که $RMSE=1/0.04$ و $MBE=0/0.033$ (میانگین انحراف خطا) به دست آمده که با نتایج این تحقیق همسو است.

نمودار تیلور برای بررسی عملکرد هر دو مدل MLP و RF در هر دو ایستگاه اهواز و تبریز مورد استفاده قرار گرفت (شکل ۵ الف-ب). مربع قرمز در محور X نمودار تیلور نشان‌دهنده تبخیر و تعرق مرجع ماهانه P-M است. به طور کلی مدل‌های نزدیک به مربع قرمز بهتر در نظر گرفته می‌شوند. در ایستگاه اهواز و تبریز به ترتیب مدل RF-4 و MLP-4 با ورودی‌های NDVI و LST مادیس، بهترین عملکرد را در برآورد تبخیر و تعرق مرجع دارد. همچنین در هر دو ایستگاه مدل‌های MLP-5 و RF-5 با ورودی‌های NDVI مادیس و لندست ضعیف‌ترین عملکرد را دارند. در مقایسه ترکیب LST و NDVI ماهواره لندست (سناریوی ۳) و سنجنده مادیس (سناریوی ۴) مشاهده شد که نتایج حاصله با ورودی‌های ماهواره مادیس در هر دو ایستگاه نتایج قابل قبول‌تری را ثبت کردند. همچنین با مقایسه بین LST لندست (سناریوی ۱) و مادیس (سناریوی ۲) نتیجه‌گیری شد که در هر دو مدل RF و MLP در هر دو ایستگاه نتایج به دست آمده از سناریوی ۲ بهتر از سناریوی ۱ است. در نتیجه برآورد تبخیر و تعرق مرجع ماهانه با پارامترهای ورودی سنجنده مادیس بهتر از ماهواره لندست ۸ است.



شکل ۴- نمودارهای پراکندگی مقادیر مشاهده شده و برآورد شده ET₀ ماهانه با مدل MLP و RF در ایستگاه‌های اهواز و تبریز (الف) مدل MLP ایستگاه اهواز، (ب) مدل MLP ایستگاه تبریز، (ج) مدل RF ایستگاه اهواز و (د) مدل RF ایستگاه تبریز

Figure 4 - Scatter plots of the observed and estimated ET₀ monthly values with MLP and RF models in Ahvaz and Tabriz station a) MLP model of Ahvaz station, b) MLP model of Tabriz station, c) RF model of Ahvaz station, and d) RF model of Tabriz station



شکل ۵- نمودار تیلور بر اساس دو مدل MLP و RF در ایستگاه اهواز و تبریز

Figure 5- Taylor diagram based on two MLP and RF models at Ahvaz and Tabriz stations

۴- نتیجه‌گیری

هر دو ایستگاه اهواز و تبریز با هر دو مدل MLP و RF سناریوی ۲ عملکرد بهتری داشت.

- برآورد تبخیر و تعرق مرجع ماهانه در ایستگاه اهواز و تبریز به ترتیب با مدل RF-4 و MLP-4 با پارامترهای ورودی LST_{MOD} و NDVI_{MOD} (سناریوی ۴) بهترین عملکرد را داشته است.

- در مقایسه سناریوی ۵ (NDVI_{Land}, NDVI_{MOD}) و سناریوی ۶ (LST_{Land}, LST_{MOD}) در هر دو مدل RF و MLP، سناریوی ۶ بهترین عملکرد را در برآورد تبخیر و تعرق مرجع ماهانه داشته است.

- در مقایسه برآورد تبخیر و تعرق مرجع ماهانه در هر دو اقلیم خشک و نیمه‌خشک، بهترین عملکرد با ضریب تعیین بالا با مدل MLP در اقلیم نیمه‌خشک حاصل شد.

- با توجه به نتایج به‌دست آمده، برآورد تبخیر و تعرق مرجع ماهانه با استفاده از دمای سطح زمین و شاخص نرمال شده تفاوت پوشش گیاهی به‌دست آمده از سنجنده مادیس نسبت به تصاویر ماهواره لندست ۸ دقت مناسبی در اقلیم خشک و نیمه‌خشک داشته است و در اقلیم‌های مشابه می‌تواند مورد استفاده قرار بگیرد.

برآورد تبخیر و تعرق مرجع (ET₀)، در فعالیت‌های کشاورزی بسیار مهم است. از طریق داده‌های ماهواره‌ای اکنون می‌توان به بینش‌های جدیدی در زمینه کشاورزی دست یافت. در این پژوهش، تخمین تبخیر و تعرق مرجع ماهانه برای زمین‌های زراعی اهواز (اقلیم خشک) و تبریز (اقلیم نیمه خشک) بر اساس مدل‌های RF و MLP، با استفاده از تصاویر ماهواره‌ای لندست و سنجنده مادیس ارائه شدند. پارامترهای مورد استفاده شامل دمای سطح زمین لندست (LST_{Land})، دمای سطح زمین مادیس (LST_{MOD})، شاخص نرمال شده تفاوت پوشش گیاهی ماهواره لندست (NDVI_{Land}) و شاخص نرمال شده تفاوت پوشش گیاهی سنجنده مادیس (NDVI_{MOD}) هستند. نتایج نشان داد که:

- دقت برآورد تبخیر و تعرق مرجع ماهانه در ایستگاه اهواز (اقلیم خشک) و تبریز (اقلیم نیمه خشک) با سناریوی ۴ شامل پارامترهای ورودی LST_{MOD} و NDVI_{MOD} بهتر از سایر سناریوهای مورد بررسی است.

- در برآورد تبخیر و تعرق مرجع ماهانه با استفاده از تک پارامتر ورودی شامل LST_{Land} (سناریوی ۱) و LST_{MOD} (سناریوی ۲)، در

منابع

صمدیان فرد، سعید، و پناهی، سولماز (۱۳۹۷). برآورد تبخیر-تعرق مرجع روزانه با استفاده از روش‌های داده کاوی رگرسیون بردار پشتیبان و مدل درختی M5. پژوهشنامه مدیریت حوزه آبخیز، ۹(۱۸)، ۹-۱۵۷. doi:10.29252/jwmr.9.18.157

طافی، شکور، پیغان، خشایار، باقری خانقاهی، مرضیه، صالحی‌پور باورصاد، تارا، و سلطانی محمدی، امیر (۱۴۰۰). ارزیابی چهارده روش تخمین تبخیر و تعرق گیاه مرجع (مطالعه موردی: استان مازندران). آبیاری و زهکشی ایران، ۱۵(۳)، ۵۱۰-۵۲۰. doi:20.1001.1.20087942.1400.15.3.3.7

پناهی، سهیلا، کرباسی، مسعود، و نیکبخت، جعفر (۱۳۹۵). پیش‌بینی تبخیر و تعرق مرجع با استفاده از شبکه‌های عصبی مصنوعی SVM، RBF و MLP. محیط زیست و مهندسی آب، ۲(۱)، ۶۳-۵۱.

دهقانی، تهمینه، احمدپری، هدیه، و امینی، عطا (۱۴۰۲). ارزیابی تغییرات کاربری اراضی با استفاده از تصاویر ماهواره‌ای چند طیفی و شبکه عصبی مصنوعی. مدل‌سازی و مدیریت آب و خاک، ۳(۲)، ۱۸-۳۵. doi:10.22098/mmws.2022.11279.1114

References

- Alipour, A., Yarahmadi, J., & Mahdavi, M. (2014). Comparative study of M5 model tree and artificial neural network in estimating reference evapotranspiration using MODIS products. *Journal of Climatology*, 11(42), 16-50. doi:10.1155/2014/839205
- Allen, R.G., Pereira, L.S., Raes, D., & Smith, M. (1998). Crop evapotranspiration-Guidelines for computing crop water requirements- FAO Irrigation and Drainage paper 56. Fao, Rome, 300(9).
- Antonopoulos, V.Z., & Antonopoulos, A.V. (2017). Daily reference evapotranspiration estimates by artificial neural networks technique and empirical equations using limited input climate variables. *Computers and Electronics in Agriculture*, 132, 86-96. doi:10.1016/j.compag.2016.11.011
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32. doi:10.1023/A:1010933404324
- Caudill, M., & Butler, C. (1992). *Understanding neural networks; Computer Explorations*. MIT press.
- Chen, G., Long, T., Xiong, J., & Bai, Y. (2017). Multiple random forests modelling for urban water consumption forecasting. *Water Resources Management*, 31(15), 4715-4729.

- doi:10.1007/s11269-017-1774-7
- Chia, M. Y., Huang, Y. F., Koo, C.H., & Fung, K.F. (2020). Recent advances in evapotranspiration estimation using artificial intelligence approaches with a focus on hybridization techniques—a review. *Agronomy*, 10(1), 101. doi:10.3390/agronomy10010101
- Dehghani, T., Ahmadpari, H., & Amini, A. (2022). Assessment of land use changes using multispectral satellite images and artificial neural network. *Water and Soil Management and Modelling*, 3(2), 18-35. doi:10.22098/mmws.2022.11279.1114 [In Persian]
- Djaman, K., Balde, A.B., Sow, A., Muller, B., Irmak, S., N'Diaye, M.K., & Saito, K. (2015). Evaluation of sixteen reference evapotranspiration methods under sahelian conditions in the Senegal River Valley. *Journal of Hydrology: regional studies*, 60(1), 139-159. doi:10.1016/j.ejrh.2015.02.002
- Eslamian, S., Khordadi, M.J., & Abedi-Koupai, J. (2011). Effects of variations in climatic parameters on evapotranspiration in the arid and semi-arid regions. *Global and Planetary Change*, 78(3-4), 188-194. doi:10.1016/j.gloplacha.2011.07.001
- Fawzy, H. E.D., Sakr, A., El-Enany, M., & Moghazy, H.M. (2021). Spatiotemporal assessment of actual evapotranspiration using satellite remote sensing technique in the Nile Delta, Egypt. *Alexandria Engineering Journal*, 60(1), 1421-1432. doi:10.1016/j.aej.2020.11.001
- Hadadi, F., Moazenzadeh, R., & Mohammadi, B. (2022). Estimation of actual evapotranspiration: A novel hybrid method based on remote sensing and artificial intelligence. *Journal of Hydrology*, 609, 127774. doi:10.1016/j.jhydrol.2022.127774
- Hargreaves, G.H., & Samani, Z.A. (1985). Reference crop evapotranspiration from temperature. *Applied Engineering in Agriculture*, 1(2), 96-99. doi: 10.13031/2013.26773
- Huang, G., Wu, L., Ma, X., Zhang, W., Fan, J., Yu, X., Zhou, H. (2019). Evaluation of CatBoost method for prediction of reference evapotranspiration in humid regions. *Journal of Hydrology*, 574, 1029-1041. doi:10.1016/j.jhydrol.2019.04.085
- Kim, N., Kim, K., Lee, S., Cho, J., & Lee, Y. (2020). Retrieval of daily reference evapotranspiration for croplands in South Korea using machine learning with satellite images and numerical weather prediction data. *Remote Sensing*, 12(21), 364. doi:10.3390/rs12213642
- Koch, J., Berger, H., Henriksen, H. J., & Sonnenborg, T.O. (2019). Modelling of the shallow water table at high spatial resolution using random forests. *Hydrology and Earth System Sciences*, 23(11), 4603-4619. doi:10.5194/hess-23-4603-2019
- Kumar, B.P., Babu, K.R., Anusha, B., & Rajasekhar, M. (2022). Geo-environmental Monitoring and Assessment of Land Degradation and Desertification in the Semi-arid regions using Landsat 8 OLI/TIRS, LST, and NDVI approach. *Environmental Challenges*, 8, 100578. doi:10.1016/j.envc.2022.100578
- Kumar, B.P., Babu, K.R., Ramachandra, M., Krupavathi, C., Swamy, B. N., Sreenivasulu, Y., & Rajasekhar, M. (2020). Data on identification of desertified regions in Anantapur district, Southern India by NDVI approach using remote sensing and GIS. *Data in Brief*, 30, 105560. doi:10.1016/j.dib.2020.105560
- Moore, R., & Hansen, M. (2011). Google Earth Engine: a new cloud-computing platform for global-scale earth observation data and analysis. AGU Fall Meeting Abstracts.
- Nouri, H., Faramarzi, M., Sobhani, B., & Sadeghi, S. (2017). Estimation of evapotranspiration based on surface energy balance algorithm for land (SEBAL) using Landsat 8 and MODIS images. *Applied Ecology and Environmental Research*, 15(4), 1971-1982. doi: 10.15666/aeer/1504_19711982
- Pagano, T.S., & Durham, R.M. (1993). Moderate resolution imaging spectroradiometer (MODIS). *Sensor Systems for the Early Earth Observing System Platforms*, 31(15). doi: 10.1117/12.152835
- Panahi, S., Karbasi, M., & Nikbakht, J. (2016). Forecasting of Reference Evapotranspiration using MLP, RBF, and SVM Neural Networks. *Environment and Water Engineering*, 2(1), 51-63. [In Persian]
- Priestley, C.H.B., & Taylor, R.J. (1972). On the assessment of surface heat flux and evaporation using large-scale parameters. *Monthly Weather Review*, 100(2), 81-92. doi:10.1175/1520-0493(1972)100<0081:OTAOSH>2.3.CO;2
- Raju, K.S., Kumar, D.N., & Duckstein, L. (2006). Artificial neural networks and multicriterion analysis for sustainable irrigation planning. *Computers & Operations Research*, 33(4), 1138-1153. doi:10.1016/j.cor.2004.09.010
- Samadianfard, S., & Panahi, S. (2019). Estimating daily reference evapotranspiration using data mining methods of support vector regression and M5 model tree. *Journal of Watershed Management Research*, 9(18), 157-167. doi:10.29252/jwmmr.9.18.157 [In Persian]
- Sattari, M.T., Apaydin, H., Band, S.S., Mosavi, A., &

- Prasad, R. (2021). Comparative analysis of kernel-based versus ANN and deep learning methods in monthly reference evapotranspiration estimation. *Hydrology and Earth System Sciences*, 25(2), 603-618. doi:10.5194/hess-25-603-2021
- Shrestha, N., Geerts, S., Raes, D., Horemans, S., Soentjens, S., Maupas, F., & Clouet, P. (2010). Yield response of sugar beets to water stress under Western European conditions. *Agricultural Water Management*, 97(2), 346-350. doi:10.1016/j.agwat.2009.10.005
- Sutariya, S., Ankur, H., & Tiwari, M. (2022). Development of Modeler for Automated Mapping of Land Surface Temperature Using GIS and LANDSAT-8 Satellite Imagery. *International Journal of Environment and Geoinformatics*, 9(2), 54-59. doi:10.30897/ijegeo.820
- Tabari, H., & Hosseinzadeh Talaei, P. (2013). Multilayer perceptron for reference evapotranspiration estimation in a semiarid region. *Neural Computing and Applications*, 23(2), 341-348. doi:10.1007/s00521-012-0904-7
- Tafi, S., Peyghan, K., Bagheri Khaneghahi, M., Salehipour Bavarsad, T., & Soltani Mohamadi, A. (2021). Evaluation of fourteen methods of estimation reference evapotranspiration (Case study: Mazandaran Province). *Iranian Journal of Irrigation & Drainage*, 3(15), 510-520 (in Persian). dor:20.1001.1.20087942.1400.15.3.3.7
- Talaei, P.H., Heydari, M., Fathi, P., Marofi, S., & Tabari, H. (2012). Numerical model and computational intelligence approaches for estimating flow through rockfill dam. *Journal of Hydrologic Engineering*, 17(4), 528-536. doi:10.1061/(ASCE)HE.1943-5584.0000446
- Talebi, H., Samadianfard, S., & Kamran, K.V. (2023). Investigating the roles of different extracted parameters from satellite images in improving the accuracy of daily reference evapotranspiration estimation. *Applied Water Science*, 13(2), 1-11. doi:10.1007/s13201-022-01862-6
- Taloor, A.K., Kothyari, G.C., Manhas, D.S., Bisht, H., Mehta, P., Sharma, M., Mahajan, S., Roy, S., Singh, A.K., & Ali, S. (2021). Spatio-temporal changes in the Machoi glacier Zaskar Himalaya India using geospatial technology. *Quaternary Science Advances*, 4, 100031. doi:10.1016/j.qsa.2021.100031
- Valipour, M. (2016). How much meteorological information is necessary to achieve reliable accuracy for rainfall estimations?. *Agriculture*, 6(4), 53. doi:10.3390/agriculture6040053
- Wu, L., Peng, Y., Fan, J., Wang, Y., & Huang, G. (2021). A novel kernel extreme learning machine model coupled with K-means clustering and firefly algorithm for estimating monthly reference evapotranspiration in parallel computation. *Agricultural Water Management*, 245, 106624. doi:10.1016/j.agwat.2020.106624
- Wu, M., Feng, Q., Wen, X., Deo, R.C., Yin, Z., Yang, L., & Sheng, D. (2020). Random forest predictive model development with uncertainty analysis capability for the estimation of evapotranspiration in an arid oasis region. *Hydrology Research*, 51(4), 648-665. doi:10.2166/nh.2020.012
- Yurtseven, I., & Serengil, Y. (2021). Comparison of different empirical methods and data-driven models for estimating reference evapotranspiration in semi-arid Central Anatolian Region of Turkey. *Arabian Journal of Geosciences*, 14(19), 1-28. doi:10.1007/s12517-021-08150-8
- Zhang, Z., Gong, Y., & Wang, Z. (2018). Accessible remote sensing data based reference evapotranspiration estimation modelling. *Agricultural Water Management*, 210, 59-69. doi:10.1016/j.agwat.2018.07.039