



## "مقاله پژوهشی"

# مقایسه عملکرد مدل‌های GLM، RF و DL در برآورد تبخیر-تعرق گیاه مرجع در ایستگاه سینوپتیک زابل

هادی سیاسر<sup>۱</sup> و تورج هنر<sup>۲</sup>

۱- استادیار دانشکده کشاورزی، دانشگاه پیام نور، تهران، ایران، (نویسنده مسوول: hadisiasar@pnu.ac.ir)

۲- دانشیار، بخش مهندسی آب، دانشگاه شیراز

تاریخ ارسال: ۹۷/۱۲/۱۲ تاریخ پذیرش: ۹۹/۰۳/۰۶

صفحه: ۲۱۰ تا ۲۱۹

### چکیده

تبخیر-تعرق یکی از مهم‌ترین اجزای چرخه هیدرولوژی برای برنامه‌ریزی سیستم‌های آبیاری و ارزیابی اثرات هیدرولوژی تغییر اقلیم است و تعیین صحیح آن برای بسیاری از مطالعات از قبیل توازن هیدرولوژیکی آب، طراحی شبکه‌های آبیاری و زهکشی، شبیه‌سازی میزان محصولات و طراحی و بهینه‌سازی منابع آب از اهمیت بالایی برخوردار است. خاصیت غیرخطی، عدم قطعیت ذاتی و نیاز به اطلاعات متنوع اقلیمی در برآورد تبخیر و تعرق از دلایلی بوده‌اند که باعث شده پژوهشگران از روش‌های مبتنی بر هوش مصنوعی استفاده نمایند. در این تحقیق جهت برآوردی دقیق از مقدار تبخیر-تعرق مرجع روزانه بین سال‌های ۲۰۱۸-۲۰۰۹ در شهرستان زابل در شمال استان سیستان و بلوچستان ابتدا براساس روش استاندارد و متداول فائو-پنمن-مونتیت و داده‌های هواشناسی ایستگاه سینوپتیک زابل مقدار تبخیر-تعرق مرجع ETO محاسبه و سپس با ارائه سناریوهای مختلفی از ترکیب پارامترهای هواشناسی شامل دمای حداکثر، دمای حداقل، دمای میانگین، رطوبت حداکثر، رطوبت حداقل، رطوبت میانگین، بارش، ساعات آفتابی، سرعت باد و تبخیر به‌عنوان ورودی مدل‌های یادگیری عمیق، جنگل تصادفی و مدل خطی تعمیم‌یافته در مقیاس زمانی روزانه سعی در برآورد دقیق‌تری از تبخیر-تعرق مرجع به‌عنوان خروجی مدل شده است. در برآورد تبخیر و تعرق روزانه در مدل‌های مذکور، ۲۵ سناریو از ترکیب داده‌های هواشناسی انتخاب گردید و برای ارزیابی مدل‌ها از روش فائو-پنمن-مانتیت استفاده شد. در بین سناریوهای مورد بررسی، سناریوی M5 (دمای حداکثر، دمای حداقل، دمای میانگین، رطوبت حداکثر، رطوبت حداقل، رطوبت میانگین، سرعت باد و تبخیر از تشت) برای مدل یادگیری عمیق با ریشه میانگین مربعات خطا (۰/۵۱۷) میلی‌متر بر روز و بیشترین ضریب همبستگی (۰/۹۹۶) بهترین عملکرد را در بین مدل‌های فوق داشتند. همچنین مدل یادگیری عمیق دقت و پایداری بیشتری نسبت به دیگر مدل‌ها نشان دادند. بنابراین این تحقیق مدل یادگیری عمیق را برای برآورد تبخیر و تعرق گیاه مرجع در شهر زابل توصیه می‌کند.

واژه‌های کلیدی: تبخیر و تعرق، عدم قطعیت، فائو-پنمن-مانتیت، یادگیری عمیق

### مقدمه

به گیاه شده و به‌دنبال آن، کاهش محصول را به‌دنبال خواهد داشت (۱۸). معمولاً برای اندازه‌گیری مستقیم مقدار تبخیر-تعرق از لایسیمتر استفاده می‌شود. با این حال اندازه‌گیری پرهزینه بوده و نیازمند صرف وقت زیاد است که همیشه امکان‌پذیر نیست. از این رو غالباً روش‌های غیرمستقیم برای برآورد تبخیر-تعرق پتانسیل مورد استفاده قرار می‌گیرد. این روش‌ها شامل طیف وسیعی از مدل‌های ساده تجربی تا روش‌های پیچیده ترکیبی (مانند پنمن-مانتیت) که بر قوانین فیزیکی استوار شده است، تغییر می‌کنند. مطالعات پیشین نشان می‌دهد، که مقدار تخمینی ETO با استفاده از روش فائو-پنمن-مانتیت (PM 56) در اقلیم‌های مختلف به مقادیر اندازه‌گیری شده نزدیک‌تر است (۱).

به‌علت پیچیدگی و عدم دانش کافی در مورد فرایندهای فیزیکی در چرخه هیدرولوژیک از جمله تبخیر-تعرق، ساخت مدل‌های آماری و گسترش آن‌ها برای بیان این فرایندها همیشه مورد توجه مهندسين بوده است. با توجه به مجهول بودن اطلاعات جوی در آینده برای برنامه‌ریزی منابع آب و مدیریت آبیاری در مزرعه نیاز است تا به گونه‌ای تبخیر-تعرق را در دوره‌های زمانی متفاوت پیش‌بینی نمود. اطلاع از

تبخیر-تعرق یکی از مولفه‌های مهم چرخه هیدرولوژی است که تخمین دقیق آن برای مدیریت بهینه منابع آب و برنامه‌ریزی سیستم‌های آبیاری و ارزیابی اثرات هیدرولوژی لازم می‌باشد. تخمین میزان دقیق تبخیر-تعرق گیاه مرجع، ETO نه تنها در برنامه‌ریزی آبیاری و تعیین دوره آبیاری، بلکه در مطالعات مربوط به مدل بیلان آب هر ناحیه از اهمیت فراوانی برخوردار است. افزون بر این، ETO در تامین نیاز آبی گیاهان، برنامه‌ریزی دقیق آبیاری و مطالعات بیلان آب مخازن، ضرورت دارد (۳). برنامه‌ریزی دقیق آبیاری مستلزم داشتن اطلاعات کافی از ETO است. تبخیر-تعرق یکی از مولفه‌های هیدرولوژیکی است که تابعی از عوامل مختلف هواشناسی نظیر دمای هوا، رطوبت نسبی، سرعت باد و تابش خورشیدی است. این مولفه در مطالعات مختلف کشاورزی از جمله طراحی سیستم‌های آبیاری و زهکشی، طراحی مخازن و برنامه‌ریزی آبیاری نقش مهمی ایفا می‌کند (۱۱). تخمین بیش از حد آب مورد نیاز گیاه ضمن هدر دادن آب آبیاری، باعث ماندابی شدن اراضی، شستشوی مواد غذایی و آلوده‌نمودن آب زیرزمینی می‌شود. از سوی دیگر، تخمین کمتر نیز باعث تنش خشکی

پیش‌بینی پارامترهای آب وهوایی صورت گرفته است. برای نمونه لیو و همکاران (۲۴) از یک تکنیک یادگیری عمیق به نام Encoder Auto Stacked جهت پیش‌بینی چهار پارامتر آب و هوایی دما، سرعت باد، فشار سطح متوسط دریاها و دمای نقطه شبنم با استفاده از کلان داده‌های هواشناسی در ۲۴ ساعته آینده پرداختند. نتایج، موفقیت روش‌های مبتنی بر یادگیری عمیق در پیش‌بینی پارامترهای آب و هواشناسی را نشان داد. در تحقیقی دیگر دالتو و همکاران (۷) به پیش‌بینی کوتاه‌مدت وزش باد با استفاده از دو شبکه عصبی عمیق و کم عمق پرداختند.

در این تحقیق تلاش شد تا الگوریتمی جهت انتخاب پارامترهای ورودی بهینه معرفی شود. نتایج این تحقیق برتری شبکه عصبی عمیق را نشان داد (۱۷).

ساگی و جین (۳۲)، با بررسی روش‌های آموزش عمیق، مدل خطی تعمیم‌یافته، جنگل تصادفی و درخت گرادبان بوستینگ برای محاسبه تبخیر-تعرق، مناسب بودن این روش‌ها و همچنین یک ترکیب الگویی از متغیرهای دمای حداکثر، دمای حداقل، رطوبت نسبی، سرعت باد و تشعشع خورشیدی و ساعات آفتابی را تأیید کردند.

هدف از انجام این تحقیق، شناسایی پارامترهای تأثیرگذار در محاسبه تبخیر-تعرق مرجع روزانه در شهر زابل و بررسی الگوهای مختلف از ترکیب پارامترهای هواشناسی به‌عنوان ورودی مدل‌های خطی تعمیم‌یافته (Generalized Linear Model, GLM)، جنگل تصادفی (Random Forest, RF) و یادگیری عمیق (Deep Learning) به‌عنوان تکنیک‌های نوین محاسباتی و انتخاب مدل برتر بر اساس الگوی منتخب می‌باشد.

### مواد و روش‌ها

ایستگاه سینوپتیک زابل در شمال استان سیستان و بلوچستان و در مختصات جغرافیایی ۳۰ درجه و ۱۸ دقیقه تا ۳۱ درجه و ۲۰ دقیقه عرض شمالی و ۶۱ درجه و ۱۰ دقیقه تا ۶۱ درجه و ۵۰ دقیقه طول جغرافیایی شرقی واقع شده است. ایستگاه سینوپتیک زابل در دشت سیستان با بارندگی میانگین سالانه ۵۹/۶ میلی‌متر و میزان تبخیرسالیانه ۴۰۰۰-۵۰۰۰ میلی‌متر از شرایط نامساعد محیطی برخوردار بوده و براساس شاخص خشکی دومارتن جزء نواحی فراخشک محسوب می‌شود.

داده‌های مورد استفاده در تحقیق شامل حداکثر، حداقل و میانگین دما، حداکثر، حداقل و میانگین رطوبت نسبی، ساعات آفتابی، سرعت باد، بارش و تبخیر از تشت، به‌صورت روزانه در طول دوره آماری ۲۰۱۸-۲۰۰۹ از ایستگاه هواشناسی سینوپتیک زابل جمع‌آوری شد. جدول (۱) متغیرهای مورد استفاده برای مدل‌سازی تبخیر-تعرق روزانه در طول دوره آماری برای ایستگاه سینوپتیک زابل را نشان می‌دهد.

وضعیت آبی تبخیر تعرق پتانسیل در مقیاس‌های سالانه و ماهانه می‌تواند به تصمیم‌گیری‌ها برای برنامه‌ریزی منابع آب در مزرعه کمک کند (۳).

در زمینه کاربرد روش‌های هوش مصنوعی در برآورد تبخیر-تعرق مرجع تحقیقات متعددی صورت گرفته است (۲۳)، ولی کاربرد روش‌های هوش مصنوعی در برآورد مقادیر تبخیر-تعرق مرجع کمتر مورد توجه قرار گرفته و تحقیقات محدودی در این زمینه موجود است. دیامانتوپولو و همکاران (۸) عملکرد شبکه‌های عصبی مصنوعی را در تخمین تبخیر-تعرق پتانسیل با حداقل داده هواشناسی بررسی نمودند و نتیجه گرفتند با در نظر گرفتن متوسط، ماکزیمم و مینیمم دما، مدل‌های انتخابی شبکه عصبی مصنوعی تخمین‌های روزانه تبخیر-تعرق پتانسیل را در مقایسه با معادله هارگریوز اصلاح شده به‌صورت قابل توجهی بهبود می‌دهند. تیان و همکاران (۳۴) و سیلوا و همکاران (۳۳) نشان دادند که پیش‌بینی هواشناسی با استفاده از روش‌های عددی می‌تواند به‌عنوان راه‌کاری مناسب جهت پیش‌بینی تبخیر-تعرق در آینده مورد استفاده قرار بگیرد. پالم و همکاران (۳۰) پیشنهاد کردند که مجموعه مدل‌ها به تدریج برای بهبود تخمین مدل‌ها مورد استفاده قرار می‌گیرد. مدل‌های خطی تعمیم‌یافته (GLM) عموماً ابزارهایی تحلیلی برای انواع مختلف داده هستند. مدل‌های خطی تعمیم‌یافته شامل طیف گسترده‌ای از مدل‌های آماری نظیر رگرسیون خطی برای پاسخ توزیع شده نرمال، مدل‌های لجستیک برای داده‌های باینری و مدل‌های خطی برای داده‌های شمارشی و همچنین بسیاری از مدل‌های آماری مفید از طریق فرم‌سازی مدل کلی آن می‌شود. بسیاری از محققان گزارش داده‌اند که مدل خطی تعمیم‌یافته (GLM) به‌طور گسترده در مدل‌سازی و پیش‌بینی بارش استفاده شده است (۶).

در سال‌های اخیر پیشرفت‌های زیادی در حوزه یادگیری عمیق صورت گرفته که سبب ایجاد روش‌های گوناگونی در این حوزه گشته است. شبکه باور عمیق یکی از قدرتمندترین الگوریتم‌های یادگیری عمیق (DL) است که در سال ۲۰۰۶ توسط هینتون ارائه شده است. DL یک نگرش جدید به ایده شبکه‌های عصبی می‌باشد. در واقع DL مجموعه الگوریتم‌هایی است که در تلاش‌اند تا مفاهیم انتزاعی و پیچیده را در سطوح و لایه‌های مختلف مدل کنند (۲، ۱۳، ۲۲). ایده اصلی شبکه‌های مبتنی بر یادگیری عمیق، نزدیک شدن هر چه بیشتر یادگیری ماشین به یکی از اهداف اصلی‌اش که همان هوش مصنوعی است، می‌باشد. در نگاه اول دو شبکه باور عمیق و پرسپترون چند لایه<sup>۳</sup> از لحاظ ساختار شبکه یکسان به نظر می‌آیند. این در حالی است که شبکه‌های باور عمیق از چند لایه ماشین بولتزمن محدود شده (RBM) ساخته شده‌اند (۲۲). در واقع یک ماشین بولتزمن نوع خاصی از میدان‌های تصادفی مارکوف هستند که از شبکه‌های متقارن با واحدهای تصادفی باینری تشکیل شده‌اند (۲۲). در این بین تحقیقات بسیار کمی با استفاده از یادگیری‌های عمیق جهت

1- Generalized Linear Models (GLM)  
3- Multi Layer Perceptron

2- Deep Learning  
4- Restricted Boltzmann Machine

جدول ۱- پارامترهای آماری مورد استفاده در مدلسازی تبخیر و تعرق پتانسیل روزانه در ایستگاه سینوپتیک زابل  
Table 1. The statistical mean of the parameters used in modeling mobility and daily potential of Zabol station

ارتفاع از سطح دریا (متر)	ساعات آفتابی (ساعت)	سرعت باد (متر بر ثانیه)	رطوبت نسبی (درصد)	دما (درجه سانتی‌گراد)	پارامتر آماری
۴۸۹/۲۰	۹/۱۱	۱۳/۳۱	۲۹/۸۵	۲۳/۴۵	میانگین
	۹/۷۰	۱۳	۳۷/۵۰	۲۳/۸۰	میانه
	۷/۸۲	۳۸/۹۲	۲۲۸/۵۵	۱۰۲/۴۵	واریانس
	-۱/۵۴	-۰/۱۹	-۰/۶۴	-۲/۳۴	چولگی
	۲/۲۸	-۰/۹۸	-۰/۴۲	-۱/۲۲	کشیدگی

جدول ۲- سناریوهای در نظر گرفته شده جهت ساختار شبکه

Table 2. Designed scenarios for network structure

تعداد متغیر	پارامترهای ورودی شبکه	سناریو
۱۰	دمای حداکثر، دمای حداقل، دمای میانگین، رطوبت حداکثر، رطوبت حداقل، رطوبت میانگین، بارش، ساعات آفتابی، سرعت باد، تبخیر از تشت	۱
۹	دمای حداکثر، دمای حداقل، دمای میانگین، رطوبت حداکثر، رطوبت حداقل، رطوبت میانگین، بارش، ساعات آفتابی، سرعت باد، تبخیر از تشت	۲
۹	دمای حداکثر، دمای حداقل، دمای میانگین، رطوبت حداکثر، رطوبت حداقل، رطوبت میانگین، ساعات آفتابی، سرعت باد، تبخیر از تشت	۳
۸	دمای حداکثر، دمای حداقل، دمای میانگین، رطوبت حداکثر، رطوبت حداقل، رطوبت میانگین، ساعات آفتابی، تبخیر از تشت	۴
۸	دمای حداکثر، دمای حداقل، دمای میانگین، رطوبت حداکثر، رطوبت حداقل، رطوبت میانگین، سرعت باد، تبخیر از تشت	۵
۷	دمای حداکثر، دمای حداقل، دمای میانگین، رطوبت حداکثر، رطوبت حداقل، رطوبت میانگین، سرعت باد، تبخیر از تشت	۶
۶	دمای حداکثر، دمای حداقل، دمای میانگین، رطوبت میانگین، سرعت باد، تبخیر از تشت	۷
۵	دمای حداکثر، دمای میانگین، رطوبت میانگین، سرعت باد، تبخیر از تشت	۸
۴	دمای میانگین، رطوبت میانگین، سرعت باد، تبخیر از تشت	۹
۴	دمای حداکثر، رطوبت میانگین، سرعت باد، تبخیر از تشت	۱۰
۳	دمای حداکثر، رطوبت میانگین، تبخیر از تشت	۱۱
۳	دمای حداکثر، سرعت باد، تبخیر از تشت	۱۲
۲	دمای حداکثر، سرعت باد	۱۳
۱	دمای حداکثر	۱۴
۱	سرعت باد	۱۵
۱	تبخیر از تشت	۱۶
۲	دمای حداکثر-دمای حداقل	۱۷
۱	رطوبت میانگین	۱۸
۲	دمای حداکثر، تبخیر از تشت	۱۹
۲	دمای حداکثر، رطوبت میانگین	۲۰
۲	دمای حداکثر، رطوبت حداکثر	۲۱
۲	دمای میانگین، سرعت باد	۲۲
۲	دمای حداکثر، سرعت باد	۲۳
۱	ساعات آفتابی	۲۴
۱	دمای حداقل	۲۵

### مدل‌های خطی تعمیم یافته (GLM)

مدل‌های خطی تعمیم یافته برای مواقعی که مشاهدات به طور نرمال توزیع نیافته‌اند و زمانی که سایر روش‌های مدل رگرسیون مناسب نمی‌باشند، ابداع شدند. این مدل، در بین روش‌های مدل‌سازی دارای عملکرد خوبی است (۳۱). بسیاری از محققین از این روش در مدل‌سازی و پیش‌بینی‌های بارش استفاده کرده‌اند (۲۸،۶).

### جنگل تصادفی (RF)

مدل جنگل تصادفی در حال حاضر جزء بهترین الگوریتم‌های یادگیری است و برای بسیاری از مجموعه داده‌ها، دسته‌بندی را با سرعت بالایی انجام می‌دهد و بر خلاف مدل‌های کلاسیکی چون رگرسیون، که تنها بر پایه یک مدل تکیه دارند با استفاده از صدها و هزاران درخت از اطلاعات بیشتری در داده‌ها استفاده می‌کند تا بتوان استنباط بهتری از متغیرها داشت (۲۹). این روش یک تکنیک مدل ناپارامتری و متعلق به خانواده روش‌های دسته‌جمعی است. این الگوریتم از جمله دسته‌بندی‌هایی است که متد Bagging را به کار می‌گیرد (۵). در این روش تعداد زیادی درخت تصمیم

ایجاد گردیده، سپس تمام درختان با هم برای پیش‌بینی ترکیب می‌گردند (۵).

### یادگیری عمیق (DL)

شبکه باور عمیق یکی از قدرتمندترین الگوریتم‌های یادگیری عمیق (DL) است. این شبکه‌ها با ترکیب چندین تبدیل غیرخطی شکل می‌گیرند که هدف آن‌ها دستیابی به فضای بیشتر و در نهایت بازنمایی سودمند از داده‌های موجود است (۴). هر چه تعداد لایه‌ها در شبکه عصبی بیشتر شود، مسئله بهینه‌سازی پیچیده‌تر می‌شود. (شکل ۱) (۲۲).

به همین دلیل یکی از روش‌های آموزش این شبکه‌ها با استفاده از الگوریتم‌های پیش‌آموزشی بدون ناظر و لایه‌ای حریصانه انجام می‌گیرد (۴،۲۴). در این روش ابتدا هر لایه به صورت مجزا آموزش داده می‌شود و در نهایت روی کل شبکه تنظیم دقیق و یکپارچه انجام می‌گیرد. همچنین علاوه بر تفاوت‌های ساختاری، دو شبکه باور عمیق و پرسپترون چند لایه از لحاظ شیوه آموزشی نیز کاملاً متفاوت می‌باشند. مدل‌هایی نظیر پرسپترون چند لایه، آموزش با کمک شیوهی انتشار رو به عقب صورت می‌گیرد در صورتی که

1- Regression

2- Nonlinear


3- Deep Learning

4- Greedy Layer-wise Unsupervised Pre-training Algorithms

5- Backward Propagation Machine

بولتزمن محدود شده را ایفا می‌کند و آموزش دومین ماشین بولتزمن محدود شده با استفاده از خروجی ماشین بولتزمن اول صورت می‌گیرد. این روند تا آموزش تک تک لایه‌های مدل تداوم می‌یابد (۱۶).

استفاده از همین متد آموزشی در شبکه‌های باور عمیق، سبب ایجاد خطای گرادیان محوشونده<sup>۱</sup> می‌شود (۴،۱۲). شیوه آموزش در شبکه‌های باور عمیق به این صورت است که ابتدا اولین ماشین بولتزمن محدود شده آموزش می‌بیند، سپس لایه‌ی پنهان<sup>۲</sup> آن، نقش لایه قابل مشاهده‌ی دومین ماشین



شکل ۱- ساختار شبکه‌ی باور عمیق (۲۲)  
Figure 1. The structure of the deep belief network (22)

نتایج پارامترهای آماری مدل‌های پیشنهادی برای انتخاب بهترین الگو در جدول (۳) ارائه شده است. ارزیابی کلی نتایج حاصل از مدل‌های خطی تعمیم‌یافته، جنگل تصادفی و یادگیری عمیق و همچنین شاخص‌های آماری محاسبه‌شده، نشان‌دهنده توانایی این مدل‌های هوشمند در شبیه‌سازی میزان تبخیر-تعرق روزانه منطقه مورد مطالعه است. بررسی مقایسه مدل‌های خطی تعمیم‌یافته، جنگل تصادفی و یادگیری عمیق نشان می‌دهد که می‌توان یک الگوی مشخصی برای ایستگاه سینوپتیک زابل را با دقت مناسب برای برآورد تبخیر-تعرق پتانسیل روزانه معرفی نمود و باید برای هر مدل، الگوی برتر را معرفی کرد. مهمترین چالش‌های یک مدل یادگیری ماشین، انتخاب بهترین الگوریتم ممکن، انتخاب متغیرهای نشانگر مناسب و در دسترس بودن مجموعه داده‌های ورودی است (۱۴).

پس از طراحی اجزای مختلف مدل‌های فوق، خروجی این مدل‌ها دریافت شد و با شاخص‌های آماری ذکر شده مورد ارزیابی قرار گرفت. نتایج هر یک از مدل‌ها در جدول (۳) دیده می‌شود. با تعیین بهترین مدل مناسب، ترکیب متغیرهای متفاوت در مدل خطی تعمیم‌یافته بررسی شد و الگوهای M1 و M3 با بالاترین ضریب همبستگی R=0.95 و کمترین خطا RMSE=1.712، به‌عنوان بهترین الگوها انتخاب شدند (جدول ۳).

در مدل جنگل تصادفی با الگوهای مختلف، بهترین ترکیب، الگوی M10 با متغیرهای دمای حداکثر، رطوبت میانگین، سرعت باد و تبخیر از تشت بود که با بیشترین ضریب همبستگی R=0.981 و کمترین خطای RMSE=1.073 به‌عنوان بهترین الگو در این مدل برگزیده شد. همچنین در رتبه‌های بعدی به‌ترتیب الگوهای M8، M3 و M1 در حد قابل قبول بودند. مهمترین پارامترها به‌ترتیب شامل دمای

#### ارزیابی روش‌های مورد استفاده

به‌منظور مقایسه مدل‌های مختلف از شاخص‌های آماری ضریب همبستگی (r) برای تعیین همبستگی بین مقادیر پیش‌بینی‌شده و اندازه‌گیری‌شده، میانگین قدرمطلق خطا (MAE) برای نشان‌دادن میزان هم‌خوانی میان مجموعه داده‌های مقادیر مشاهده‌ای و مدل‌سازی‌شده و از RMSE برای مقایسه مقادیر اندازه‌گیری‌شده با مقادیر پیش‌بینی‌شده از استفاده شد (۳۳).

$$r = \frac{\sum_{i=1}^N O_i P_i}{\sqrt{\sum_{i=1}^N O_i^2 \sum_{i=1}^N P_i^2}} \quad (2)$$

$$MAE = \frac{\sum_{i=1}^N (|O_i - P_i|)}{N} \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (O_i - P_i)^2}{n}} \quad (4)$$

در این روابط؛  $O_i$ : تبخیر و تعرق به روش فائو-پنمن-مانیت؛  $P_i$ : تبخیر و تعرق محاسبه‌شده به هر روش؛  $R$ : ضریب همبستگی که هر چه این شاخص به یک نزدیکتر باشد نشان‌دهنده همبستگی بالای مدل می‌باشد و  $MAE$  و  $RMSE$  به‌ترتیب میانگین قدرمطلق خطا و ریشه میانگین مربعات خطا که هرچه این شاخص به صفر نزدیکتر باشد نشان‌دهنده انحراف کمتر و دقت بالاتر مدل می‌باشد.

#### نتایج و بحث

با محاسبه مقادیر تبخیر-تعرق مرجع با روش فائو-پنمن-مانیت و در نظر گرفتن این مقادیر به‌عنوان مقادیر هدف در آموزش، شبکه مدل‌های خطی تعمیم‌یافته، جنگل تصادفی و یادگیری عمیق ایجاد و عملکرد آنها بررسی شد.

خورشیدی خالص، سرعت باد، دمای میانگین و رطوبت نسبی میانگین، و همچنین الگوی تشعشع خورشیدی خالص، رطوبت نسبی میانگین و دمای میانگین نتایج بهتر از سایر روش‌ها ارائه داد.

فنگ و همکاران (۹) برای منطقه‌ای خشک در چین نشان داد که روش جنگل تصادفی و روش شبکه‌های عصبی رگرسیونی تعمیم‌یافته (Generalized Regression Neural Networks, GRNN)، نتایج مناسبی در تخمین تبخیر-تعرق روزانه داشتند و نتایج روش جنگل تصادفی اندکی مناسب‌تر بود.

میانگین، دمای حداکثر، سرعت باد، دمای میانگین و تبخیر از تشت بودند.

گراناتا (۱۴) با بررسی الگوریتم‌های مختلف یادگیری ماشین شامل الگوریتم‌های درخت تصمیم M5P، روش دسته‌بندی (bagging)، روش جنگل تصادفی و روش رگرسیون بردار پشتیبانی (Support Vector Regression, SVR) و همچنین الگوهای مختلف متغیرهای هواشناسی و مقایسه آنها با روش فائو-پنمن-مانتیت در منطقه ای با اقلیم مرطوب، استفاده از روش جنگل تصادفی را برای برآورد تبخیر-تعرق رضایت‌بخش دانست. این مدل برای الگوهای ساده‌تر با متغیرهای هواشناسی اندک مانند الگوی شامل تشعشع

جدول ۳- نتایج آنالیز مدل‌های انتخابی در ایستگاه مورد مطالعه

Table 3. Results of analysis of selected models at the studied station

سناریو	Generalized Linear Model			Deep Learning			Random Forest		
	RMSE	Absolute Error	Squared Correlation	RMSE	Absolute Error	Squared Correlation	RMSE	Absolute Error	Squared Correlation
M1	۱/۷۱۲	۱/۳۴۲	-۰/۹۵	۰/۵۵۷	-۰/۴۲۲	-۰/۹۹۶	۱/۱۸۷	-۰/۸۳۹	-۰/۹۷۱
M2	۱/۷۵۱	۱/۳۶	-۰/۹۴۸	۰/۶۳۴	-۰/۴۶۲	-۰/۹۹۴	۱/۲۹۲	-۰/۹۲۳	-۰/۹۷۲
M3	۱/۷۱۲	۱/۳۴۲	-۰/۹۵	۰/۵۵۷	-۰/۴۲۲	-۰/۹۹۶	۱/۱۸۷	-۰/۸۳۹	-۰/۹۷۷
M4	۲/۲۷۴	۱/۶۴۴	-۰/۹۱۲	۲/۰۰۳	۱/۳۲۶	-۰/۹۳۲	۲/۰۷۵	۱/۳۹۲	-۰/۹۳۷
M5	۱/۷۱۵	۱/۳۴۵	-۰/۹۵	۰/۵۱۷	-۰/۳۹۹	-۰/۹۹۶	۱/۱۹۵	-۰/۸۴۵	-۰/۹۷۶
M6	۱/۷۹۴	۱/۴۰۲	-۰/۹۴۵	۰/۵۸	-۰/۴۰۲	-۰/۹۹۴	۱/۲۵۹	-۰/۸۸۴	-۰/۹۷۴
M7	۱/۷۹۴	۱/۴۰۱	-۰/۹۴۵	۰/۶۲۸	-۰/۴۶۳	-۰/۹۹۴	۱/۲۴۹	-۰/۸۷۴	-۰/۹۷۴
M8	۱/۸۱۵	۱/۴۱۴	-۰/۹۴۴	۰/۵۹۹	-۰/۴۴۴	-۰/۹۹۴	۱/۰۸۲	-۰/۸۰	-۰/۹۸۱
M9	۱/۹۷۷	۱/۵۰۸	-۰/۹۳۳	۰/۸۹۱	-۰/۶۰۷	-۰/۹۸۷	۱/۱۲۴	-۰/۸۲۷	-۰/۹۷۹
M10	۱/۸۰۳	۱/۴۰۵	-۰/۹۴۵	۰/۶۰۵	-۰/۴۶۷	-۰/۹۹۴	۱/۰۷۳	-۰/۸۰	-۰/۹۸۱
M11	۲/۴۴۶	۱/۸۱۱	-۰/۸۹۸	۲/۲۱۵	۱/۴۷۷	-۰/۹۱۸	۲/۲۶۷	۱/۵۹۴	-۰/۹۱۲
M12	۱/۹۸۷	۱/۵۸۹	-۰/۹۳۳	۱/۲۸۲	۱/۰۰۹	-۰/۹۷۳	۱/۴۴۹	۱/۱۰۶	-۰/۹۶۵
M13	۲/۲۱۲	۱/۸۳۱	-۰/۹۱۷	۱/۳۴۷	۱/۰۴	-۰/۹۶۹	۱/۴۴۶	۱/۱۱۳	-۰/۹۶۴
M14	۳/۷۳۵	۲/۹۹۳	-۰/۷۶۳	۳/۴۸۶	۲/۶۵۶	-۰/۷۹۴	۳/۵۲۲	۲/۶۷	-۰/۷۸۸
M15	۵/۴۱۸	۴/۳۰۲	-۰/۵۰۱	۵/۳۸۲	۴/۲۱۳	-۰/۵۰۶	۵/۴۰۸	۴/۲۹	-۰/۵۰۳
M16	۳/۲	۲/۴۱۴	-۰/۸۲۵	۳/۰۹۸	۲/۲۹۸	-۰/۸۳۷	۳/۱۲۵	۲/۳۳	-۰/۸۳۳
M17	۳/۱۸۳	۲/۵۳۲	-۰/۸۲۵	۲/۶۲۹	۱/۹۱۷	-۰/۸۸۴	۲/۶۷۱	۱/۹۴	-۰/۸۷۹
M18	۵/۰۹	۳/۹۴۵	-۰/۵۵۹	۴/۱۰۸	۳/۱۳۱	-۰/۷۱۶	۳/۹۲۷	۲/۹۷	-۰/۷۳۷
M19	۲/۵۷۱	۱/۹۱۲	-۰/۸۸۸	۲/۴۶۱	۱/۷۴۲	-۰/۸۹۷	۲/۵۰۵	۱/۸۲	-۰/۸۹۳
M20	۳/۳۷۶	۲/۶۷۷	-۰/۸۰۶	۲/۷۴	۲/۰۳۳	-۰/۸۷۵	۲/۷۳۷	۱/۹۶	-۰/۸۷۲
M21	۳/۰۷۴	۲/۴۱۸	-۰/۸۳۹	۲/۵۵۳	۱/۸۲۶	-۰/۸۸۹	۲/۶۰۳	۱/۸۵	-۰/۸۸۴
M22	۲/۴	۱/۹۵۶	-۰/۹۰۲	۱/۶۰۴	۱/۳۲۶	-۰/۹۵۶	۱/۶۴۷	۱/۲۷	-۰/۹۵۴
M23	۲/۲۱۲	۱/۸۳۱	-۰/۹۱۷	۱/۳۴۷	۱/۰۴	-۰/۹۶۹	۱/۴۴۶	۱/۱۱	-۰/۹۶۴
M24	۶/۴۶۵	۵/۵۶۴	-۰/۲۸۹	۵/۶۸۱	۴/۵۴	-۰/۴۵۳	۵/۶۴۴	۴/۴۵	-۰/۴۵۶
M25	۳/۲۲۲	۲/۶۱۲	-۰/۸۱۲	۲/۸۵۷	۲/۰۶۵	-۰/۸۶۲	۲/۹۰۱	۲/۱۱	-۰/۸۵۶

دیگرام پراکنش یا منحنی پراکنده‌گی مقادیر برآورده شده در برابر مقادیر مشاهداتی بر اساس سناریوی M3 در شکل (۲) آورده شده است. همان‌طور که نتایج نشان دادند همبستگی بالایی بین تبخیر و تعرق برآورده شده از این مدل‌ها و روش فائو-پنمن-مانتیت وجود دارد و می‌توان از این مدل محاسباتی برای برآورد تبخیر و تعرق روزانه در زمانی که داده‌های محدودتری در دسترس می‌باشند، استفاده نمود. نکته دیگر در بحث مدل‌سازی با مدل‌های مذکور، بحث زمان مورد نیاز برای محاسبات شبیه‌سازی در مدل‌های یاد شده است. به‌طوری که این زمان‌ها مثلاً در مدل‌های GLM، RF و DL به‌ترتیب ۲ دقیقه و ۷ ثانیه، ۱۳ ثانیه و ۳ دقیقه و ۲۶ ثانیه بود که زمان اجرای مدل یادگیری عمیق از همه مدل‌های

جابلون و سالی (۲۰) مقدار تبخیر-تعرق محاسباتی را با استفاده از دو مجموعه محدود و کامل از داده‌های هواشناسی در تونس مقایسه کردند و تفاوت بین نتایج آنها برای مناطق مورد مطالعه اندک بود. فریرا و همکاران (۱۰) نشان دادند که در زمان محدودیت داده‌های ورودی برای مدل‌های شبکه عصبی مصنوعی و SVM می‌توان از روش استفاده از داده‌های روزهای قبل (previous days strategy) و نیز روش کلاسترینگ (clustering) بهره‌گیری نمود.

در مدل یادگیری عمیق الگوی الگوی M5 با کمترین میانگین مربعات خطا (۰/۵۱۷) و خطای مطلق ۰/۳۹۹ و بیشترین ضریب همبستگی ۰/۹۹۶ به‌عنوان بهترین الگوی در مدل‌های مذکور در منطقه مورد مطالعه انتخاب شد. نمودار

است که می‌توان علت را تأثیرگذاری بیشتر تغییر اقلیم بر ماه‌های گرم سال نسبت به ماه‌های فصل سرد سال دانست. بنابراین مدیریت کارآمد منابع آب در اولویت‌بندی و برنامه‌ریزی دقیق در طرح‌های مدیریتی منابع آب، مطالعات کشاورزی، طراحی شبکه‌های آبیاری و زهکشی و سازه‌های آبی به‌ویژه با توجه به ماهیت خشک و نیمه‌خشک منطقه ضروری به نظر می‌رسد.

بنابراین، درمجموع پارامتر دما به‌عنوان مهمترین پارامتر موثر برای هر سه مدل بررسی‌شده به‌دست آمد. بنابراین افزایش دقت و صحت داده‌های دما، می‌تواند به افزایش دقت مدل‌های استفاده‌شده کمک کند. لو و همکاران (۲۵) با مطالعه پارامترهای مختلف هواشناسی در تخمین تبخیر-تعرق توسط مدل‌های شبکه عصبی مصنوعی نتایج مشابهی مبنی بر اهمیت صحت داده‌های دما بر دقت نتایج پیش‌بینی‌شده را گزارش کردند. از طرف دیگر، مدل‌هایی که بر اساس دما هستند، به‌علت اندازه‌گیری این پارامتر در بیشتر ایستگاه‌های هواشناسی، مدل‌هایی با اهمیت و مقبولیت بیشتر به‌شمار می‌آیند (۲۶،۲۷). تراوره و همکاران (۳۵)، گزارش دادند که مدل شبکه عصبی مصنوعی بر پایه دما می‌تواند عملکرد بهتری نسبت به روش تجربی هارگریوز داشته باشد. همچنین نتایج پژوهش حقیقت‌جو و آخوند علی (۱۵) نشان داد که روش‌های مبتنی بر دمای هوا، تبخیر-تعرق دشت سیستان را بهتر برآورد می‌کند. بررسی نتایج مدل‌ها در ایستگاه مورد مطالعه نشان داد که مدل یادگیری عمیق به‌عنوان بهترین مدل در بین مدل‌های انتخابی می‌باشد و همچنین سناریوی M5 در مدل یادگیری عمیق با بالاترین ضریب همبستگی (۰/۹۹۶) و کمترین میانگین مربعات خطا (۰/۵۱۷) به‌عنوان سناریوی برتر انتخاب شد. بنابراین این تحقیق مدل یادگیری عمیق را برای برآورد تبخیر و تعرق در منطقه زابل پیشنهاد می‌نماید. از نتایج پژوهش حاضر می‌توان جهت برنامه‌ریزی منابع آبی و برنامه‌ریزی شبکه‌های آبیاری و زهکشی و استفاده بهینه آب در منطقه مورد مطالعه استفاده نمود.


پیشنهادی کمتر بودند و این موضوع به‌لحاظ صرفه‌جویی در زمان محاسبات برای کاربر بسیار مهم است که مطالعات کسکین و همکاران (۲۱) نیز گواه بر این موضوع می‌باشد.

### تحلیل حساسیت

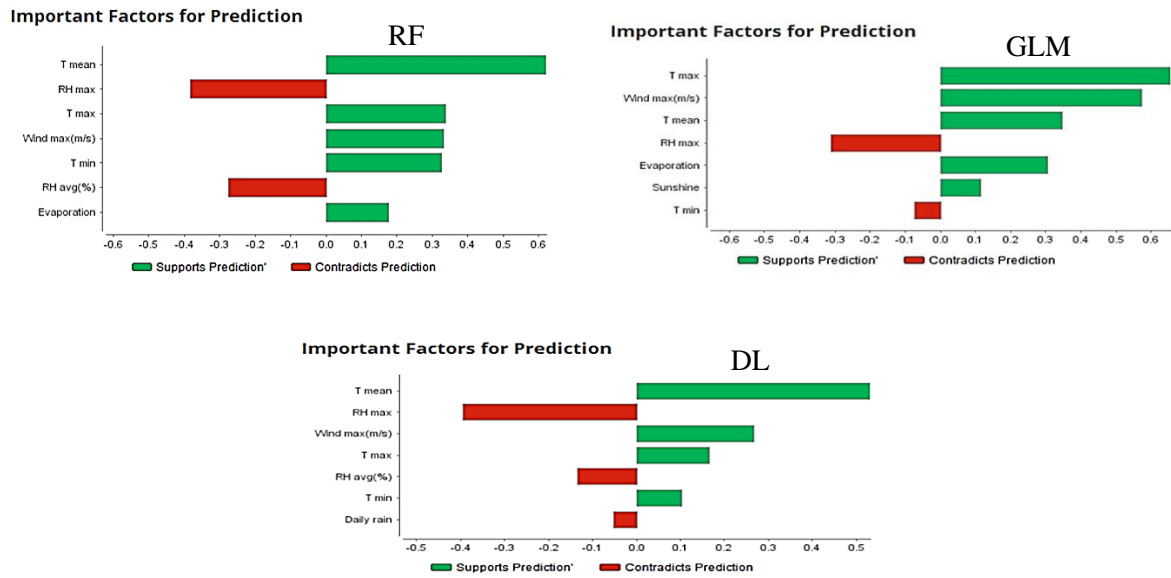
هدف از تحلیل حساسیت در این پژوهش شناسایی و تعیین درجه اهمیت هر یک از پارامترها در سری داده‌های ورودی بر عملکرد دینامیکی سیستم است. به‌منظور آنالیز حساسیت در هر سری داده ورودی یک پارامتر حذف و مدل با همان داده‌های سری آموزش، تست، اجرا و مقادیر ضریب همبستگی و خطا تعیین گردید. با حذف هر پارامتر هرچه خطای مدل افزایش بیشتری نشان دهد بیان‌گر تأثیر بیشتر آن پارامتر بر فرایند شبیه‌سازی می‌باشد.

نتایج نشان داد در مدل خطی تعمیم‌یافته (GLM) مهمترین پارامترهای هواشناسی به‌ترتیب دمای ماکزیمم، سرعت باد، دمای میانگین، تبخیراز تشت و تابش تشت است و در مدل جنگل تصادفی (RF) پارامترهای تأثیرگذار به‌ترتیب دمای میانگین، دمای ماکزیمم، سرعت باد، دمای حداقل و تبخیر از تشت و در نهایت در مدل یادگیری عمیق (DL) مهمترین پارامترها به‌ترتیب میانگین دما، سرعت باد، دمای حداکثر و دمای حداقل انتخاب شدند.

تحلیل نتایج به‌دست‌آمده از تحلیل رگرسیونی با بررسی فصلی مقدار تبخیر-تعرق مرجع مشخص گردید که بیشترین افزایش میزان تبخیر و تعرق در فصول تابستان و بهار اتفاق افتاده و کمترین آن نیز در پاییز و زمستان در مدل‌های یادگیری عمیق، جنگل تصادفی و مدل خطی تعمیم‌یافته بوده است. روند تغییرات تبخیر و تعرق در فصول تابستان و پاییز کاهش و در فصل بهار و زمستان افزایشی بوده است. همچنین بیشترین مقادیر تبخیر و تعرق به‌ترتیب در فصول تابستان، بهار، پاییز و زمستان با مقادیر ۶۸۴/۳، ۴۷۸/۱۲، ۲۶۳/۷۰ و ۱۷۰/۸۵ میلی‌متر رخ داده است جدول (۴). همچنین می‌توان نتیجه گرفت که روند افزایشی تبخیر-تعرق مرجع معمول افزایش درجه حرارت به تعداد ساعت آفتابی از یک طرف و کاهش رطوبت نسبی هوا به‌علت کاهش بارندگی



شکل ۲- مقادیر پیش‌بینی شده و مشاهده شده تبخیر و تعرق با استفاده از مدل‌های مختلف  
Figure 2. Simulated and observed values of evapotranspiration using different models




شکل ۳- نتایج آنالیز حساسیت مدل‌های مختلف مورد مطالعه  
Figure 3. Sensitivity analysis of the various models studied

جدول ۳- نتایج آنالیز فصلی مدل‌های انتخابی در ایستگاه مورد مطالعه

Table 3. Results of seasonal analysis of selected models at the station under study

سناریو	Generalized Linear Model			Deep Learning			Random Forest		
فصول	RMSE	Absolute Error	Squred Correlation	RMSE	Absolute Error	Squred Correlation	RMSE	Absolute Error	Squred Correlation
پاییز	۲۳/۱۶۷	۱۷/۷۳۸	۹۹/۰	۶/۹۰۴	۵/۸۷۲	۹۹۵/۰	۳۱/۳۲	۳۱/۵۴	۹۹۹/۰
زمستان	۲۷/۵۹	۲۳/۵۵۳	-۰/۹۶۱	۱۰/۸۷۲	۹/۱۹۱	-۰/۹۹۵	۱۱/۲۹۳	۱۲/۸۹۳	-۰/۹۹۶
بهار	۳۶/۳۱۹	۳۲/۰۰۱	-۰/۹۹۳	۸/۲۰۳	۶/۶۱۸	-۰/۹۹۷	۱۰/۹۹۹	۱۱/۷۹۸	-۰/۹۹۷
تابستان	۳۶/۸۶۳	۳۱/۶۳۵	۹۶۷/۰	۷/۹۲۱	۶/۶۳۵	۹۹۷/۰	۱۰/۳۹۶	۹/۷۹۸	۹۹۵/۰



شکل ۴- مقادیر پیش‌بینی شده و مشاهده شده تبخیر و تعرق فصلی با استفاده از مدل‌های مختلف  
Figure 4. Predicted and observed values of seasonal evapotranspiration using different models



## منابع

1. Allen, R.G., J.L. Jensen, J.L. Wright and R.D. Burman. 1989. Operational estimate of evapotranspiration. *Agronomy Journal*, 81: 650-662.
2. Arel, I., D.C. Rose and T.P. Karnowski. 2010. Deep machine learning-a new frontier in artificial intelligenceresearch [research frontier]. *IEEE Computational Intelligence Magazine*, 5(4):13-18.
3. Babamiri, O., Y. Dinpashoh and E. Asadi. 2014. Calibration and evaluation of seven radiation- based reference crop evapotranspiration method at Urmia lake basin. *Water and Soil Science*, 23: 143-158 (In Persian).
4. Bengio Y. 2009. Learning Deep Architectures for Artificial Intelligence. *Foundations and Trends in Machine Learning*, 2(1): 1-127.
5. Breiman, L. 2001. Application and analysis of random forests and machine learning. *Journal of Water Management*, 15(1): 5-32.
6. Chandler, R.E. and H.S. Wheeler. 2002. Analysis of rainfall variability using generalized linear models: a case study from the west of Ireland. *Water Resources Research*, 38(10): 10-1.
7. Dalto, M., J. Matuško and M. Vašak. 2015. Deep neural networks for ultra-short-term wind forecasting. In 2015 IEEE International Conference on Industrial Technology (ICIT). IEEE, 1657-1663.
8. Diamantopoulou, M.J., P.E. Georgiou and D.M. Papamichial. 2010. Performance evaluation of artificial neural networks in estimating reference evapotranspiration with minimal meteorological data. *Global nest Journal*, 13.1 (2011): 18-27.
9. Feng, Y., N. Cui, D. Gong, Q. Zhang and L. Zhao. 2017. Evaluation of random forests and generalized regression neural networks for daily reference evapotranspiration modelling. *Agricultural Water Management*, 193: 163-173.
10. Ferreira, L.B., F.F. da Cunha, R.A. de Oliveira and E.I. Fernandes Filho. 2019. Estimation of reference evapotranspiration in Brazil with limited meteorological data using ANN and SVM-a new approach. *Journal of Hydrology*, 572: 556-570.
11. Ghahreman, N. and A. Gharekhani. 2012. Evaluation stochastic time series models in pan evaporation estimating (case study Shiraz station). *Journal of Water Research in Agriculture*, 25(1): 75-81 (In Persian).
12. Glorot, X. and Y. Bengio. 2010. Understanding the difficulty of training deep feedforward neural networks. *Proceedings of Machine Learning Research*, 9: 249-256.
13. Goodfellow, I., Y. Bengio and A. Courville. 2016. Deep learning. 802 pp. [www.deeplearningbook.org](http://www.deeplearningbook.org).
14. Granata, F. 2019. Evapotranspiration evaluation models based on machine learning algorithms-A comparative study. *Agricultural Water Management*, 217: 303-315.
15. Haghghatjou, P. and A.M. AkhondAli. 2008. Computation of evapotranspiration of Sistan plain based on solar data. *Second National Conference on Management of Irrigation and Drainage Networks*. Ahvaz, Iran. (In Persian).
16. Hinton, G.E., S. Osindero and Y.W. The. 2006. A fast learning algorithm for deep belief nets. *Neural Computation*, 18(7): 1527-1554.
17. Hu, Q., R. Zhang and Y. Zhou. 2016. Transfer learning for short-term wind speed prediction with deep neural networks. *Renewable Energy*, 85: 83-95.
18. Hulme, M.Z., C. Zhao and T. Jiang. 1994. Recent and future climate change in East Asia. *International Journal of Climatology*, 14: 637-658.
19. Jabloun, M. and A. Sahli. 2008. Evaluation of FAO-56 methodology for estimating reference evapotranspiration using limited climatic data: application to Tunisia. *Agricultural Water Management*, 95: 707-715.
20. Jain, S., P. Nayak and K. Sudheer. 2008. Models for estimating evapotranspiration using artificial neural networks, and their physical interpretation. *Hydrological Processes: An International Journal*, 22(13): 2225-2234.
21. Keskin, M.E., O. Terzi, E.D. Taylan and D.K. Ücukyaman. 2009. Meteorological drought analysis using data-driven models for the lakes district, Turkey. *Hydrological Sciences Journal*, 54(6): 1114-1124.
22. Keyvanrad, M.A. and M.M. Homayounpour. 2015. Deep Belief Network Training Improvement Using EliteSamples Minimizing Free Energy. *International Journal of Pattern Recognition and Artificial Intelligence*, 29(5): 155-166.
23. Kişi, Ö. 2009. Modeling monthly evaporation using two different neural computing techniques. *Irrigation Science*, 27(5): 417-430.
24. Liu, J.N. 2014. Deep Neural Network Based Feature Representation for Weather Forecasting. In *Proceedings on the International Conference on Artificial Intelligence (ICAI)*. The Steering Committee of the World Congress in Computer Science, Computer Engineering and Applied Computing (World Comp).



25. Luo, Y., S. Traore, X. Lyu, W. Wang, Y. Wang, Y. Xie, X. Jiao and G. Fipps. 2015. Medium range daily reference evapotranspiration forecasting by using ANN and public weather forecasts. *Water Resources Management*, 29(10): 3863-3876.
26. Mattar, M.A., A.A. Alazba, B. Alblewi, B. Gharabaghi and M.A. Yassin. 2016. Evaluating and calibrating reference evapotranspiration models using water balance under hyper-arid environment. *Water Resources Management*, 30: 3745-3767.
27. Mendicino, G. and A. Senatore. 2013. Regionalization of the Hargreaves coefficient for the assessment of distributed reference evapotranspiration in Southern Italy. *Journal of Irrigation and Drainage Engineering*, 139: 349-362.
28. Nykodym, T., T. Kraljevic, N. Hussami, A. Rao and A. Wang. 2016. Generalized linear modeling with h2o. Published by H2O. ai Inc.
29. O'Brien, R. and H. Ishwaran. 2019. A random forests quantile classifier for class imbalanced data. *Pattern recognition*, 90: 232-249.
30. Palmer, T., F. Doblas-Reyes, R. Hagedorn and A. Weisheimer. 2005. Probabilistic prediction of climate using multi-model ensembles: from basics to applications. *Philosophical Transactions of the Royal Society B: Biological Sciences* 360(1463): 1991-1998.
31. Pregibon, D. and T.J. Hastie. 2017. Generalized linear models. In *Statistical Models in S*; Momirovic, K., Mildner, V., Eds. Routledge: London, UK, 195-247.
32. Saggi, M.K. and S. Jain. 2019. Reference evapotranspiration estimation and modeling of the Punjab Northern India using deep learning. *Computers and Electronics in Agriculture*, 156: 387-398.
33. Silva, D., F. Meza and E. Varas. 2010. Estimating reference evapotranspiration (ETO) using numerical weather forecast data in central Chile. *Journal Hydrol*, 382(14): 64-71.
34. Tian, D. and C.G. Martinez. 2012. Forecasting reference evapotranspiration using retro-spective forecast analogs in the South-eastern United States. *Journal Hydrometeorol*, 1(3): 1874-1892.
35. Traore, S., Y.M. Wang and T. Kerh. 2010. Artificial neural network for modeling reference evapotranspiration complex process in Sudano-Sahelian zone. *Water Resources Management*, 97(5): 707-714.

## Comparison of Performance of GLM, RF and DL Models in Estimation of Reference Evapotranspiration in Zabol Synoptic Station

Hadi Siasar<sup>1</sup> and Tooraj Honar<sup>2</sup>

1- Assistant Professor, Faculty of Agriculture, Payame Noor University, Tehran, Iran  
(Corresponding author: Hadisiasar@pnu.ac.ir)

2- Associate Professor, Department of Water Science and Engineering, Faculty of Agriculture, Shiraz University, Shiraz, Iran

Received: March 3, 2019      Accepted: May 26, 2020

### Abstract

Evapotranspiration is one of the most important components of the hydrology cycle for planning irrigation systems and assessing the impacts of climate change hydrology and correct determination is important for many studies such as hydrological balance of water, design of irrigation networks, simulation of crop yields, design, optimization of water resources, nonlinearity, inherent uncertainty, and the need for diverse climatic information in estimating evapotranspiration have been the reasons why researchers have used artificial intelligence-based approaches. In this study, to estimate accurately the daily reference evapotranspiration between 2009-2018 in Zabol city, north of Sistan and Baluchestan province, first was used a standard FAO-Penman-Montith method and Zabol synoptic station meteorological data- the ETo reference transpiration is calculated and then presented by various scenarios of meteorological parameters including: maximum, minimum and mean temperature, maximum, minimum and mean humidity, precipitation, sunshine, wind speed and evaporation as inputs for deep learning models, Random forest and generalized linear model were attempted on a daily time scale More accurately. In estimating daily evapotranspiration in these models, 25 scenarios were selected from meteorological data combination and FAO-Penman-Monteith method was used to evaluate the models. Among the investigated scenarios, the M5 scenario (maximum, minimum and mean temperature, maximum, minimum and mean humidity, wind speed, pan evaporation) for deep learning model with minimum error (0.517) and highest correlation coefficient (0.517). 0.996 had the best performance among the above models. The deep learning model showed more accuracy and stability than other models. Hence, this study is recommended a deep learning model for estimating reference plant evapotranspiration in Sistan plain.

**Keywords:** Deep Learning, Evapotranspiration, FAO-Penman-Monteith, Uncertainty