

مدل سازی فرایند تبخیر-تعرق روزانه با استفاده از مدل های رگرسیونی و هوشمند (مطالعه موردی)

حسین ملک احمدی^{۱*}، احسان میرزانیان^۲، سپیده خسروی^۳ و علی ابراهیم زاده^۴

چکیده

تبخیر-تعرق نقش مهمی در مدیریت منابع آب منطقه‌ای، تغییرات آب‌وهوایی و تولید کشاورزی دارد. در این تحقیق، کارایی برخی از تکنیک‌های داده‌محور، شامل ماشین بردار پشتیبان (SVM)، شبکه‌های عصبی مصنوعی (ANN) و ترکیب آن با تبدیل موجک (WANN)، رگرسیون خطی چندمتغیره (MLR) و درخت تصمیم (Decision Tree) برای پیش‌بینی نرخ تبخیر-تعرق در ایستگاه اسکاتس بلوف در ایالت نبراسکا بررسی شد. برای این منظور، از ۵ پارامتر هواشناسی (دمای کمینه، دمای بیشینه، رطوبت نسبی، سرعت باد و تابش خورشیدی) به‌عنوان ورودی برای مدل‌ها استفاده شد. داده‌های مورد استفاده در این تحقیق اطلاعات هواشناسی روزانه بین سال‌های ۲۰۰۵ و ۲۰۱۳ برای آموزش و آزمون مدل‌ها بود. به‌منظور اجرای هر یک از مدل‌ها ۸ سناریو با توجه به ترکیب پارامترهای ورودی در نظر گرفته شد. برای ارزیابی عملکرد تکنیک‌های مورد مطالعه، از سه شاخص آماری مختلف، یعنی ریشه میانگین مربع خطا (RMSE)، ضریب همبستگی (R) و ضریب نش‌ساتکلیف (NSE) استفاده شد که بدین‌وسیله نتایج مدل‌ها با داده‌های مشاهداتی بررسی شد؛ علاوه بر این، نمودارهای تیلور برای آزمایش شباهت بین داده‌های مشاهده‌شده و پیش‌بینی‌شده استفاده شد. نتایج نشان داد که در ایستگاه اسکاتس بلوف، WANN (هشتمین ترکیب ورودی برای مدل WANN است) با توجه به مقادیر ریشه میانگین مربع خطا (RMSE)، ضریب همبستگی (R) و ضریب نش‌ساتکلیف به ترتیب برابر با ۰/۰۹۷ میلی‌متر در روز، ۰/۹۹۹ و ۰/۹۹۹ عملکرد بهتری در مقایسه با ANN، SVM، MLR و DT داشت. مدل‌های ANN و SVM نیز دقت بسیار خوبی را نشان دادند و مدل‌های DT و MLR با وجود قابل قبول بودن دقت در آن‌ها از سایر مدل‌ها ضعیف‌تر عمل کردند. به‌عنوان یک نتیجه‌گیری، نتایج حاصل از مطالعه فعلی ثابت کرد که WANN روندهای معقولی را برای مدل‌سازی اسکاتس بلوف در ایستگاه اسکاتس بلوف ارائه کرده‌است.

واژه‌های کلیدی: اسکاتس بلوف، درخت تصمیم، رگرسیون خطی چندگانه، ماشین بردار پشتیبان، هیبرید عصبی موجکی.

ارجاع: ملک احمدی ح. میرزانیان ا. خسروی س. و ابراهیم‌زاده ع. ۱۴۰۱. مدل‌سازی فرایند تبخیر-تعرق روزانه با استفاده از مدل‌های رگرسیونی و هوشمند (مطالعه موردی). مجله پژوهش آب ایران. ۴۴: ۴۹-۶۲. DOI: <https://dx.doi.org/10.22034/iwrj.2022.10026.2338>

1- گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران.

2- گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران.

3- گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران.

4- گروه مهندسی عمران، دانشگاه آزاد اسلامی واحد مرند، مرند، ایران.

* نویسنده مسئول: h.malekhamdi@tabrizu.ac.ir

تاریخ پذیرش: ۱۴۰۰/۱۱/۰۲

تاریخ دریافت: ۱۴۰۰/۰۸/۱۱

مقدمه

تبخیر، اولین فرایند انتقال آب در چرخه هیدرولوژیکی است و نقش بسزایی در ارزیابی تعادل آب دارد (لیو و همکاران، ۲۰۰۴). همچنین بزرگ‌ترین جزء اتلاف آب چرخه هیدرولوژیکی را تشکیل می‌دهد. تبخیر را فرایند انتقال آب از اقیانوس‌ها، دریاها و توده‌های خشکی به اتمسفر تعریف می‌کنند. از آن‌جاکه کمبود آب به مسائل جدی تبدیل می‌شود، برآورد دقیق میزان تبخیر بسیار مهم است؛ به‌ویژه در مناطقی که منابع آب محدودی دارند. تخمین زده شده است که ۶۱ درصد بارش‌های جهانی از طریق تبخیر از بین می‌رود (چو و همکاران، ۱۹۸۸). در سطح جهانی، تبخیر-تعرق عامل اصلی کاهش رطوبت خاک در مزارع کشاورزی است. تبخیر یک فرایند پیچیده است که تحت‌تأثیر پارامترهای آب‌وهوایی زیادی قرار دارد و این پارامترها در فرایندهای هیدرولوژیکی دخیل هستند (طبری و همکاران، ۲۰۱۰). برای برآورد شدت تبخیر، روش‌های مستقیم و غیرمستقیم زیادی وجود دارد. روش تشت تبخیر، جزو روش‌های مستقیم است که به‌طور معمول برای برآورد تبخیر دریاچه‌ها و مخازن استفاده می‌شود. در روش‌های غیرمستقیم، شدت تبخیر با استفاده از روش‌های تجربی و استفاده از داده‌های هواشناسی و فرمول مبتنی بر موازنه جرم و بقای انرژی برآورد می‌شود. یکی از روش‌های استاندارد اندازه‌گیری تبخیر، تشت تبخیر کلاس A مرکز هواشناسی آمریکا است؛ اما نصب تشت تبخیر، دارای محدودیت‌های ابزاری و مشکلات عملی شامل خطای ناظر، کدورت آب و مشکلات نگهداری است و به‌همین دلیل از میزان دقت این ابزار می‌کاهد؛ بنابراین با توجه به مشکلات و محدودیت‌های تشت تبخیر، ارائه روش‌هایی برای برآورد میزان تبخیر با استفاده از دیگر متغیرهای هواشناسی ضروری است. از آن‌جایی‌که تبخیر، اساساً در طبیعت یک فرایند غیرخطی است، استفاده از روابط خطی، همراه با خطا خواهد بود؛ بنابراین برای ایجاد رابطه غیرخطی بین تبخیر و متغیرهای هواشناسی، می‌بایست از روش‌های غیرخطی استفاده کرد. تبخیر اولاً، وابسته به عوامل اقلیمی مختلفی است، دوماً، این عوامل بر روی یک‌دیگر تأثیر می‌گذارند. از این‌رو تهیه یک مدل ریاضی برای آن با در نظر گرفتن همه عوامل اقلیمی مؤثر در آن، کاری دشوار بوده و در صورت امکان، با خطاهای قابل‌توجهی روبه‌رو است، یا نیاز

به اطلاعات زیادی دارد که اندازه‌گیری آن‌ها مشکل و زمان‌بر است (چین و همکاران، ۱۹۹۹). امروزه محققان از مدل‌های گوناگونی جهت تخمین تبخیر-تعرق استفاده می‌کنند و تلاش برای انتخاب مدلی با بیشترین دقت، کمترین خطا و درعین‌حال کمترین تعداد پارامتر ورودی صورت می‌پذیرد. این مدل‌ها مشکلات و هزینه‌های روش‌های مستقیم را ندارند و می‌توان به‌منظور پیش‌بینی نیز از آن‌ها استفاده کرد، از جمله این مدل‌ها می‌توان به مدل‌های یادگیری ماشینی اشاره کرد که نه تنها در زمینه تخمین تبخیر-تعرق، بلکه در زمینه‌های دیگر علم هیدرولوژی پتانسیل بالایی را برای مدل‌سازی نشان داده‌اند.

کیسی (۲۰۱۵) به بررسی دقت ماشین بردار پشتیبان حداقل مربعات (LSSVM)، خطوط رگرسیون تطبیقی چندمتغیره (MARS) و مدل درخت ΔM (Tree ΔM) در مدل‌سازی E_p پرداخت. بخش اول مطالعه بر روی آزمایش توانایی مدل‌های LSSVM، MARS و Tree ΔM در تخمین داده‌های E_p ایستگاه‌های مرسین و آنتالیا واقع در منطقه مدیترانه ترکیه با استفاده از روش اعتبارسنجی متقابل متمرکز شد. بخش دوم مطالعه با استفاده از ایستگاه متقابل با وضعیت اقلیمی مشابه بدون داده‌های ورودی محلی مورد بررسی قرار گرفت. نتایج کلی نشان داد که می‌توان از LSSVM در برآورد E_p با استفاده از داده‌های ورودی و خروجی محلی استفاده کرد، درحالی‌که مدل MARS در موارد بدون ورودی و خروجی محلی بهتر از LSSVM عمل می‌کند.

وانگ و همکاران (۲۰۱۷)، مدل‌سازی تبخیر را با استفاده از چهار روش مختلف اکتشافی انجام داده‌اند. این مطالعه توانایی‌های مدل ژنتیک فازی (FG)، مدل درخت ΔM (Tree ΔM)، خطوط رگرسیون تطبیقی چندمتغیره (MARS)، رگرسیون بردار پشتیبان حداقل مربعات (LSSVR) و رگرسیون خطی چندگانه (MLR) را در برآورد تبخیر روزانه بررسی کردند. از داده‌های آب‌وهوایی روزانه، دمای هوا، دمای سطح، سرعت باد، رطوبت نسبی و ساعات آفتابی در هشت ایستگاه در حوضه دریاچه دونگ‌تینگ چین برای توسعه و اعتبار مدل استفاده شد. نتایج کلی نشان داد که مدل‌های فوق را می‌توان با موفقیت برای تخمین تبخیر روزانه با استفاده از داده‌های ورودی و خروجی محلی استفاده کرد؛ درحالی‌که LSSVR

مصنوعی-موجک در آب‌وهوای خشک و مرطوب پرداختند و کارایی برخی از تکنیک‌های داده‌محور شامل رگرسیون بردار پشتیبان (SVR) و شبکه عصبی مصنوعی (ANN) و ترکیب آن‌ها با تبدیل موجک برای پیش‌بینی نرخ تبخیر در تبریز (ایران) و ایستگاه‌های آنتالیا (ترکیه) برای ارزیابی عملکرد مورد بررسی قرار گرفت. نتایج نشان داد که در ایستگاه تبریز ANN (سومین ترکیب ورودی که دما و تابش خورشیدی مورد استفاده در بخش پارامترهای ورودی است) با ضریب همبستگی ۰/۹۹ و ضریب نش‌ساتکلیف ۰/۹۷۷ نتایج بهتری در مقایسه با SVR، WSVR و WANN داشته است و موجک نقش مثبتی در مدل‌سازی ایفا نکرده است. در ایستگاه آنتالیا نیز تقریباً همین روند مشاهده شد و مدل ANN (پنجمین ترکیب ورودی که شامل دمای هوا، رطوبت نسبی و تابش خورشیدی به‌عنوان پارامترهای ورودی است) با ضریب همبستگی ۰/۹۶ و ضریب نش‌ساتکلیف ۰/۸۹ نتایج بهتری در مقایسه با سایر مدل‌ها داشت.

پاتل و همکاران (۲۰۲۰)، مدل‌سازی ماهانه تبخیر را با استفاده از روش‌های خطی چندگانه و شبکه عصبی مصنوعی انجام دادند. رویکرد مدل‌سازی شامل ترکیب مختلف شش پارامتر اقلیمی اندازه‌گیری شده شامل حداکثر و حداقل دمای هوا، حداکثر و حداقل رطوبت نسبی، ساعات آفتابی و سرعت باد در دو ایستگاه گنگتوک در ایالت سکام و ایفمال در ایالت مانی‌پور است. تجزیه و تحلیل همبستگی نشان داد که دما، سرعت باد و ساعات آفتابی دارای همبستگی مثبت هستند؛ درحالی‌که رطوبت نسبی با تبخیر تشک همبستگی منفی دارد. نتایج نشان داد که عملکرد مدل‌های شبکه عصبی مصنوعی نسبت به مدل‌های رگرسیون خطی چندگانه برای پیش‌بینی تبخیر ماهانه در منطقه مورد مطالعه کمی بهتر است.

مجهی و همکاران (۲۰۲۱)، به توسعه یک مدل جدید با دقت بیشتر و کاهش پیچیدگی محاسباتی پرداختند. شبکه عصبی مصنوعی پیوند عملکردی (FLANN) به‌عنوان ساختاری برای برآورد تبخیر روزانه تشک در سه منطقه آب‌وهوایی از ایالت چاتیسگار در شرق مرکزی هند انتخاب شد. نوروں منفرد و یک لایه در ساختار آن در مقایسه با سایر شبکه‌های عصبی چندلایه و مدل‌های ترکیبی مبتنی بر نوروں فازی باعث پیچیدگی کمتری شد.

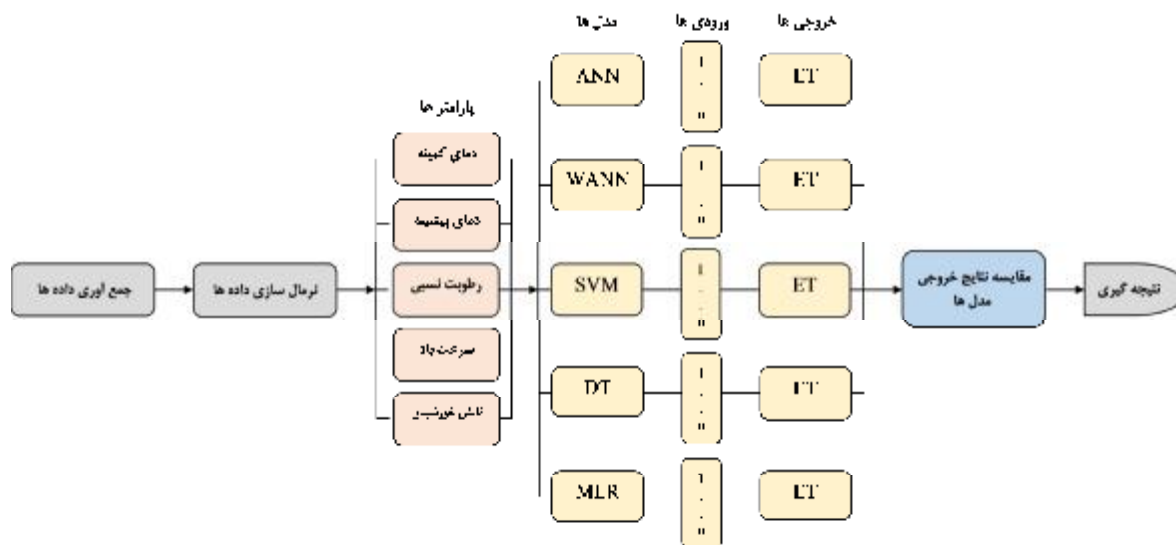
و FG به‌طور کلی بهتر از سایر مدل‌ها بدون ورودی و خروجی محلی عمل کردند. همچنین ساعات آفتابی، دمای سطح و دمای هوا عوامل اصلی تأثیرگذار هستند و افزودن سرعت باد و رطوبت نسبی به ورودی‌های مدل به‌طور قابل‌توجهی عملکرد مدل را بهبود بخشید.

قربانی و همکاران (۲۰۱۸)، یک مدل پیش‌بینی ترکیبی (الگوریتم کرم شب‌تاب چندلایه MLP-FFA) (Perceptron) براساس بهینه‌ساز FFA که در تکنیک MLP تعبیه شده است، توسعه دادند و از نظر مناسب بودن آن برای پیش‌بینی تبخیر روزانه تشک مورد ارزیابی قرار دادند. برای توسعه مدل ترکیبی MLP-FFA، داده‌های تبخیر اندازه‌گیری شده بین سال‌های ۲۰۱۲ تا ۲۰۱۴ برای دو ایستگاه بزرگ هواشناسی (تالش و منجیل) واقع در شمال ایران برای آموزش و آزمون مدل پیش‌بینی استفاده کردند. توانایی مدل ترکیبی MLP-FFA با مدل‌های سنتی MLP و ماشین بردار پشتیبان (SVM) مقایسه شدند. نتایج نشان داد که یک مدل MLP-FFA بهینه از مدل MLP و SVM برای هر دو ایستگاه مورد آزمایش بهتر است که برای تالش ضریب نش‌ساتکلیف ۰/۷۹ به دست آمد و برای منجیل این مقدار برابر با ۰/۹۱ محاسبه شد.

نورانی و همکاران (۲۰۱۹)، تکنیک‌های مختلف هوش مصنوعی (AI) شامل شبکه عصبی (FFNN)، سیستم استنباط فازی تطبیقی عصبی (ANFIS)، رگرسیون بردار پشتیبانی (SVR)، مدل‌های تجربی شامل هارگریوز، هارگریوز-سامانی (HS)، هارگریوز-سامانی اصلاح‌شده (MHS)، مکینک (MK)، ریچی (RT) و رگرسیون چندخطی معمولی (MLR)، برای مدل‌سازی تبخیر-تعرق مرجع (ET). در چهارده ایستگاه از چندین منطقه آب‌وهوایی در ترکیه، قبرس، عراق، ایران و لیبی استفاده کردند و از ۱۲ پارامتر داده‌های آب‌وهوایی ماهانه جمع‌آوری شده به‌عنوان پارامترهای ورودی مدل‌ها استفاده کردند. نتایج نشان داد مدل‌های مبتنی بر هوش مصنوعی از نظر عملکرد از مدل‌های دیگر برتر هستند. همچنین می‌توان با مدل‌سازی گروهی به بهبود مدل‌سازی تبخیر تعرق مرجع دست یافت. مدل‌سازی مجموعه مبتنی بر هوش مصنوعی بر مدل‌سازی گروه تجربی ارجحیت داشت. قاسم و همکاران (۲۰۱۹)، به بررسی مدل‌سازی تبخیر ماهانه با استفاده از رگرسیون بردار-موجک و شبکه عصبی

از روش‌های ساده تا پیچیده و هیبریدی (عصبی موجکی) در منطقه اسکاتس بلوف نبراسکا پرداخته می‌شود و تأثیر هیبرید موجکی عصبی بر افزایش دقت مدل‌سازی تبخیر-تعرق با سایر پارامترهای هواشناسی و تفاوت دقت آن با مدل‌های ساده‌تر بررسی می‌شود. شکل ۱ فلوچارت روند انجام تحقیق را نشان می‌دهد.

نتایج برآوردی به‌دست‌آمده با مدل FLANN، با نتایج به‌دست‌آمده از شبکه‌های عصبی مصنوعی چندلایه (MLANN) و دو روش تجربی با استفاده از داده‌های خام یکسان و ویژگی‌های مربوط به آن مقایسه شدند. نتایج نشان دادند که برآوردهای تبخیر تشتکی که با مدل پیشنهادی FLANN به‌دست آمده، باعث بهبود شده است. در این مطالعه به مدل‌سازی تبخیر-تعرق روزانه با استفاده



شکل ۱- شمای کلی روند انجام تحقیق

بارش‌ها در بهار رخ می‌دهد، توزیع نوسانات قابل‌توجهی را در طول سال تقویم نشان می‌دهد. ET_r سالانه از حدود ۱۴۰۰ میلی‌متر در قسمت جنوب‌شرقی تا ۱۵۲۰ میلی‌متر در جنوب مرکزی و ۱۷۰۰ میلی‌متر در قسمت غربی ایالت متغیر است (ایرماک و همکاران، ۲۰۱۲). آب‌وهوا در اسکاتس بلوف نیمه‌خشک است، با رطوبت نسبی متوسط درازمدت (۱۹۸۲-۲۰۱۶) حدود ۶۰ درصد، دمای بالا و پایین روزانه به‌ترتیب ۱۷ و ۱ درجه سانتی‌گراد و سالانه انباشت بارش و ET مرجع (محاسبه‌شده برای یونجه محصول مرجع)، به‌ترتیب تقریباً ۲۹۷ میلی‌متر و ۱۶۵۶ میلی‌متر است (یونتس و همکاران، ۲۰۱۸). در این تحقیق از داده‌های ایستگاه هیدرومتری اسکاتس بلوف برای مدل‌سازی تبخیر استفاده شده است. مشخصات آماری پارامترهای مذکور در جدول ۱ ارائه شده است و سری زمانی داده‌ها در شکل ۲ نمایش داده شده است.


مواد و روش‌ها

منطقه مورد مطالعه

این پژوهش در بخش غربی ایالت نبراسکا، در دشت‌های بزرگ ایالات متحده، منطقه اسکاتس بلوف (۴۱ درجه، ۵۲ دقیقه و ۲ ثانیه شمالی و ۱۰۳ درجه، ۳۹ دقیقه و ۳۹ ثانیه غربی) انجام شده است. ارتفاع متوسط این شهر از سطح آب‌های آزاد برابر با ۱۱۸۶ متر و مساحت این منطقه برابر با ۱۷/۳ کیلومتر مربع است. نبراسکا با بیش از ۳/۴ میلیون هکتار زمین آبی و حدود ۵ میلیون هکتار علفزار طبیعی یکی از ایالت‌های کشاورزی پیش‌رو در ایالات متحده است. میانگین بارندگی سالانه (۱ ژانویه تا ۳۱ دسامبر) در سطح کشور حدود ۵۵۰ میلی‌متر است. میانگین فصل رشد بلندمدت (۱ مه تا ۳۰ سپتامبر) در سراسر ایالات متحده ۳۶۰ میلی‌متر است. حداکثر میانگین بلندمدت بارندگی فصل رشد در قسمت جنوب‌شرقی ایالت و حداقل آن در لبه غربی رخ می‌دهد. درحالی‌که بیشتر

جدول ۱- مشخصات آماری داده‌های مطالعاتی

مشخصات آماری	دمای کمینه (°C)	دمای بیشینه (°C)	رطوبت نسبی (%)	سرعت باد (m/s)	تابش خورشید (mj/m ² /day)	تبخیر-تعرق (mm/day)
تعداد داده‌ها	۳۲۸۶	۳۲۸۶	۳۲۸۶	۳۲۸۶	۳۲۸۶	۳۲۸۶
کمینه	-۳۳/۸۳	-۲۱/۰۰	۱۷/۷۹	۰/۸۷	۰/۲۸	۰
بیشینه	۲۳/۲۹	۴۰/۵۴	۹۹/۹۶	۱۲/۰۶	۳۲/۱۴	۱۴/۵۰
میانه	۰/۷۲	۱۸/۱۲	۵۷/۴۶	۲/۷۸	۱۵/۲۱	۴/۲۹
میانگین	۱/۱۶	۱۷/۷۱	۵۸/۴۴	۳/۱۰	۱۵/۶۷	۴/۵۹
واریانس	۱۰۴/۶۹	۱۳۷/۹۵	۲۷۸/۴۴	۱/۸۴	۶۲/۲۵	۸/۳۱
انحراف معیار	۱۰/۲۳	۱۱/۷۵	۱۶/۶۹	۱/۳۶	۷/۸۹	۲/۸۸
چولگی	-۰/۲۲	-۰/۲۶	۰/۲۰	۱/۶۸	۰/۱۲	۰/۳۶



شکل ۱- نمودار سری زمانی تبخیر-تعرق

تصادفی است و نشان‌دهنده اثرات باقی‌مانده بر y متغیرهایی است که به‌صراحت در مدل گنجانده نشده است. برای مدل‌های رگرسیونی ساده، e_i را می‌توان یک متغیر غیرهمبسته با میانگین صفر فرض کرد.

درخت تصمیم (DT)

روش درخت تصمیم یک روش سلسله‌مراتبی یا چندمرحله‌ای است که در آن به‌صورت بازگشتی مجموعه داده‌ها به روش دودویی به تقسیمات فرعی و کوچک‌تر تقسیم‌بندی می‌شوند؛ تا زمانی که تقسیمات فرعی نهایی نتوانند بیشتر از آن تجزیه شوند (طالبی، ۱۳۹۲). درختان تصمیم مجموعه‌ای از داده‌های معلوم را می‌گیرند و یک درخت تصمیم را از آن استنتاج می‌کنند. سپس درخت می‌تواند به‌صورت مجموعه قوانینی برای پیش‌بینی ویژگی‌های معلوم استفاده شود. مجموعه داده‌های اولیه که درخت به‌وسیله آن‌ها ایجاد می‌شود، به‌عنوان داده‌های آموزشی شناخته می‌شوند. درخت تصمیم از بالا به پایین ترسیم می‌شود. در بالا ویژگی اول و مقدارش قرار می‌گیرد

رگرسیون خطی چندگانه (MLR)

رگرسیون خطی چندگانه یک تکنیک آماری است که از چندین متغیر توضیحی برای پیش‌بینی نتیجه یک متغیر پاسخ استفاده می‌کند (زونمات‌کرمانی، ۲۰۱۲). هدف از روش رگرسیون خطی چندگانه مدل‌سازی رابطه بین متغیرهای توضیحی و پاسخ است. روش‌های آماری، مانند مدل‌های رگرسیونی، مناسب‌ترین ابزار برای بررسی ارتباط بین اندازه نمونه‌های کوچک متغیرهای وابسته و مستقل هستند (رازی و آتاپیلی، ۲۰۰۵). از تکنیک‌های رگرسیون خطی چندگانه برای مدل‌سازی داده‌های تبخیر براساس پارامترهای اقلیمی محلی دما، رطوبت نسبی و سرعت باد (المدیج، ۲۰۱۲) استفاده می‌شود. برای مدل رگرسیون خطی چندگانه، متغیر وابسته y تابعی از k متغیرهای مستقل $x_1, x_2, x_3, \dots, x_k$ است. مدل به‌صورت معادله (۱) بیان شده است:

$$y_i = b_0 + b_1x_{1i} + \dots + b_kx_{ki} + e_i \quad (1)$$

در معادله (۱)، b_0, b_1, \dots, b_k ثابت‌های مناسب هستند. $x_{1i}, x_{2i}, \dots, x_{ki}$ مقادیر مشاهداتی هر متغیر است. e_i خطای

تابع Kernel: تابع وزنی است که در تکنیک‌های پیش‌بینی غیرپارامتریک استفاده می‌شود.

شبکه عصبی مصنوعی (ANN)

یک شبکه عصبی مصنوعی را می‌توان به‌عنوان گروهی از واحدهای پردازش ساده که به‌عنوان پردازنده پراکنده موازی عمل می‌کند، توصیف کرد. این واحدهای پردازشی که نورون نامیده می‌شوند، دانش تجربی را برای محاسبات بعدی ذخیره می‌کنند. در شبکه‌های عصبی، یادگیری از طریق تجربیات صورت می‌گیرد. نمونه‌ها و دانش به‌دست‌آمده در وزن‌های ارتباطی بین نورون‌ها ذخیره می‌شود که از سیستم عصبی بیولوژیکی مشابه مغز تقلید می‌کند (دموت و بیل، ۲۰۰۵). لایه ورودی اجازه می‌دهد تا داده‌ها در شبکه باشند و به لایه‌های متوالی ارائه می‌شوند تا به‌تدریج آن را پردازش کنند و نتیجه‌ای را در لایه خروجی به‌دست آورند. نورون‌های لایه ورودی از طریق وزن w_{ji} به لایه‌های واسطه و شبکه‌های عصبی در سطح واسطه از طریق وزن‌ها w_{ki} به لایه‌های سطح خروجی یا لایه نهایی متصل می‌شوند. نمادهای z و k به ترتیب نشان‌دهنده نورون‌ها در لایه‌های ورودی، مخفی و خروجی هستند. آمیختگی ورودی با وزن خاص و بایاس net_j به نورون j در لایه مخفی می‌تواند به شکل معادله (۲) بیان شود (بیشاپ، ۱۹۹۵).

$$net_j = \sum_{i=1}^p (w_{ji}x_i + b_j) \quad (2)$$

که در معادله (۲)، x_i و b_j به ترتیب مقادیر ورودی نرون i ام در لایه ورودی و بایاس j ام نرون مخفی هستند. معادله (۳) یک تابع انتقال یا فعال‌ساز در لایه مخفی برای کار بر روی ارزش شبکه net_j در جهت تولید خروجی از نورون پنهان است. خروجی را می‌توان براساس معادله (۳) زیر استخراج کرد (بیشاپ، ۱۹۹۵).

$$y_j = f(net_j) = f_h \left(\sum_{i=1}^p (w_{ji}x_i + b_j) \right) \quad (3)$$

در معادله (۳) که y_j خروجی نرون مخفی j است. ورودی وزنی خالص به نورون خروجی را می‌توان با معادله (۴) منتقل کرد (بیشاپ، ۱۹۹۵).

$$net_k = \sum_{j=1}^q f_0(y_j)w_{kj} + b_k \quad (4)$$

و از آن به بعد شاخه یا منجر به یک ویژگی یا نتیجه می‌شود (یوسفی و همکاران، ۱۳۹۳). یک درخت تصمیم معمولاً از چهار بخش ریشه، شاخه، گره‌ها و برگ‌ها تشکیل شده است. گره اول در درخت تصمیم به‌عنوان ریشه درخت در نظر گرفته می‌شود. هر گره مربوط به یک خصوصیت معین است و شاخه‌ها به‌معنای بازه‌ای از مقادیر هستند. این بازه‌های مقادیر باید بخش‌های مختلف مجموعه مقادیر معلوم را برای خصوصیت‌ها به‌دست دهند. عمل انشعاب توسط یکی از متغیرهای پیش‌بینی‌کننده انجام می‌پذیرد (آلبرگ و همکاران، ۲۰۱۲).

ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبانی، به‌عنوان یک تکنیک یادگیری ماشین تحت نظارت با طراحی هوشمند، اولین بار توسط بوسر، گیون و وپنیک در سال ۱۹۹۲ معرفی شد (جاکولا، ۲۰۰۶). ماشین بردار پشتیبان با استفاده از یک الگوریتم یادگیری با تکیه بر تئوری یادگیری آماری و نظریه بهینه‌سازی، کامپیوتر را قادر می‌سازد تا یاد بگیرد که چگونه کارهای طبقه‌بندی و رگرسیون را اجرا کند، دقت پیش‌بینی را افزایش دهد و همچنین از ایرادات اضافی جلوگیری کند (کریستیانینی و لکوف، ۲۰۰۲؛ گو و همکاران، ۲۰۰۵). ماشین بردار پشتیبان (SVM) از جمله روش‌های نسبتاً جدیدی است که در سال‌های اخیر کارایی خوبی نسبت به روش‌های قدیمی‌تر برای دسته‌بندی و رگرسیون از جمله شبکه‌های عصبی پرسپترون چندلایه نشان داده‌است. از برتری‌های مدل ماشین بردار پشتیبان نسبت به سایر روش‌ها آن است که با داده‌های آموزشی کمتر و متغیرهای کمتری کار می‌کند؛ اما نسبت به تغییر متغیرها بسته به داده‌های آموزشی حساس است. یک ماشین یادگیری (f) یک ورودی (x) را می‌گیرد و آن را با استفاده از وزن‌های α به یک خروجی تبدیل می‌کند. متغیرهای مهم در ماشین‌های بردار پشتیبان عبارت‌اند از: متغیر c : این متغیر تنظیم حواشی و اندازه متغیرهای دورافتادگی را کنترل می‌کند.

متغیر گاما: در یک ماشین بردار پشتیبان مقدار گاما در تابع تقلیل غیرحساس بایستی انتخاب شود. اپسیلون بر انعطاف پاسخ‌های به‌دست‌آمده از ماشین‌های بردار پشتیبان تأثیر دارد و بردارهای پشتیبان و به‌دنبال آن پیچیدگی و توانایی تعمیم‌پذیری شبکه مؤثر است.

است که در محاسبات نقش بسیار مهمی ایفا می‌کند. دسته دوم جزئیات نام دارد که دارای فرکانس بالاست و بیانگر تغییرات محدوده در داده‌ها است. فرایند تجزیه سیگنال شامل یک یا چند مرحله است که در تجزیه چندمرحله‌ای، موج پس از اولین مرحله تفکیک با تجزیه مجدد قسمت تقریبی، تجزیه موج ادامه می‌یابد (نورانی و همکاران، ۲۰۱۴). امروزه توانایی تجزیه داده‌ها با استفاده از موجک در روش‌های مدل‌سازی هوشمند مانند شبکه عصبی به صورت متعدد استفاده می‌شود که نتایج بسیار جالب و قابل‌توجهی در دقت این مدل‌ها دارد. در روش هیبرید موجکی عصبی از مقادیر تخمین و جزئیات به‌دست‌آمده از موجک برای آموزش دادن شبکه عصبی به‌جای استفاده مستقیم از داده‌ها استفاده می‌شود.

پارامترهای ارزیابی

برای محاسبه دقت مدل‌های مورد مطالعه از ۳ معادله ارزیابی که شامل، ریشه میانگین مربع خطاها، (RMSE) ضریب همبستگی (R) و ضریب نش‌سانکلیف (NSE) استفاده شده است. معادله توابع ارزیابی به صورت زیر است.

$$R = \frac{\sum_{i=1}^N (ET_{o,i} - \overline{ET}_o)(ET_{p,i} - \overline{ET}_p)}{\sqrt{\sum_{i=1}^N (ET_{o,i} - \overline{ET}_o)^2 \cdot \sum_{i=1}^N (ET_{p,i} - \overline{ET}_p)^2}} \quad (۸)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (ET_{p,i} - ET_{o,i})^2} \quad (۹)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (ET_{o,i} - ET_{p,i})^2}{\sum_{i=1}^N (ET_{o,i} - \overline{ET}_o)^2} \quad (۱۰)$$

که در معادلات (۸) الی (۱۰) مقدار $ET_{o,i}$ مقدار مشاهداتی، $ET_{p,i}$ مقدار محاسباتی، N تعداد داده‌ها، \overline{ET}_o میانگین مقادیر مشاهداتی و \overline{ET}_p میانگین مقادیر محاسباتی است. علاوه بر پارامترهای ارزیابی نام برده در معادلات (۸)، (۹) و (۱۰) از دیاگرام تیلور نیز درجهت نمایش دقت و صحت مدل‌ها استفاده شده است (تیلور، ۲۰۰۱). درواقع تیلور با ارائه دیاگرامی توانست برخی از مقادیر ارزیابی را به تصویر بکشد و دقت هر مدل در این دیاگرام را با یک نقطه تعیین کند که امکان مقایسه مدل‌ها را نیز در یک دیاگرام می‌دهد.

مشابه معادله قبل خروجی نرون kام در لایه خروجی با معادله (۵) محاسبه می‌شود (بیشاپ، ۱۹۹۵).

$$\text{net}_k = f(\text{net}_k) = f_0 \left(\sum_{j=1}^q w_{kj} f_h \sum_{i=1}^p (w_{ji} x_i + b_j) + b_k \right) \quad (۵)$$

برای کالیبراسیون مدل، وزن ANN به صورت تکرار تنظیم می‌شود. در این مطالعه، الگوریتم انتشار روبه‌جلو لوبنبرگ مارکوارت (LM) معماری پرسپترون چند لایه پیشرو (MLP) را آموزش داد.

شبکه عصبی موجکی (WANN)

تبدیل موجک یکی از پرکاربردترین تبدیلات ریاضی در حوزه پردازش است. تبدیلات موجک به دو نوع پیوسته و گسسته تقسیم می‌شوند. تبدیل موجک پیوسته یک سیگنال $x(t)$ به صورت معادله (۶) تعریف می‌شود:

$$CWT_f^\psi(s, \tau) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} f(t) \psi \left(\frac{t - \tau}{s} \right) dt \quad (۶)$$

در معادله فوق، ψ تابع موجک، s ($s < 1$) پارامتر مقیاس یا اتساع، τ پارامتر انتقال زمان، t زمان و علامت * نشان‌دهنده مزدوج مختلط است. مدل CWT، سیگنال را به وسیله تعداد بی‌شمار و نامحدودی از پارامترهای مقیاس و انتقال تجزیه می‌کند. در این مدل پارامترهای مقیاس و انتقال به صورت پیوسته تغییر می‌کنند؛ از این رو محاسبه ضرایب موجک برای همه مقیاس‌های ممکن، علاوه بر تولید حجم زیادی از اطلاعات، نیاز به کوششی قابل‌ملاحظه دارد؛ اما می‌توان با استفاده از زیرنمونه‌هایی از CWT ویژگی‌های کلیدی تبدیل را حفظ کرد. این ایده منجر به ابداع تبدیل گسسته موجک (DWT) شده است (هیل و والنات، ۱۹۸۹). شکل گسسته تابع موجک به صورت معادله (۷) است:

$$\Psi_{j,k}(t) = \frac{1}{\sqrt{|s_0^j|}} \psi \left(\frac{t - k\tau_0 s_0^j}{s_0^j} \right) \quad (۷)$$

که در آن، $\Psi_{j,k}$ تابع موجک به‌ازای مقادیر معین k و j (اعداد صحیح)، t زمان، S_0 ($S_0 < 1$) ثابت گام اتساع، τ_0 ثابت انتقال زمان بوده و وابسته به S_0 هستند. با اعمال تبدیل گسسته، داده‌های اولیه موجکی شده و به دو دسته تقسیم می‌شوند. دسته اول که تقریب نامیده می‌شود، دارای فرکانس کم بوده و نشان‌دهنده روند کلی داده‌های موجود

نتایج و بحث

در این مطالعه، به مدل‌سازی تبخیر-تعرق به‌وسیله پنج مدل در منطقه اسکاتس بلوف در ایالت نبراسکا در آمریکا پرداخته شده است. این مدل‌ها شامل شبکه عصبی مصنوعی (ANN)، هیبرید شبکه عصبی و موجکی (WANN)، ماشین بردار پشتیبان (SVM)، درخت تصمیم (DT) و رگرسیون چندگانه خطی (MLR) هستند. همچنین، از پنج پارامتر هواشناسی (دمای کمینه، دمای بیشینه، رطوبت نسبی، سرعت باد و تابش خورشید) برای مدل‌سازی تبخیر-تعرق با استفاده از ۸ سناریو پرداخته شد که مشخصات سناریوها در جدول ۲ ارائه شده است. داده‌های مورد بررسی در مقیاس روزانه از سال ۲۰۰۵ تا ۲۰۱۴ است. برای ارزیابی نتایج مدل‌های استفاده‌شده در تحقیق از سه پارامتر ارزیابی R، RMSE و NSE استفاده شد. در شروع روند مدل‌سازی، ۸۰ درصد ابتدایی داده‌ها برای بخش آموزش و ۲۰ درصد انتهایی برای بخش آزمون در نظر گرفته شد. با توجه به جدول ۳ و مقایسه نتایج مدل‌های مختلف به‌ازای بهترین سناریو (سناریو ۸) حاکی از آن است که مدل هیبرید عصبی موجکی (WANN8) با بیشترین ضریب همبستگی (R) برابر با ۰/۹۹، کمترین ریشه میانگین مربعات خطا (RMSE) برابر با ۰/۰۹۷ و ضریب نش‌سائکلیف (NSE) برابر با ۰/۹۹ در مرحله آزمون عملکرد بهتری را نسبت به سایر مدل‌ها در تخمین تبخیر-تعرق از خود نشان داده است. در نتایج سایر مدل‌ها ANN، SVM، DT و MLR بهترین سناریو با توجه به جدول ۳، در بین سایر سناریوها، سناریوی ۸ انتخاب شد که نشان می‌دهد وجود تمام پارامترها در مدل‌سازی و پیش‌بینی تبخیر-تعرق حائز اهمیت است.

جدول ۲- الگوهای مختلف ورودی مدل‌ها

شماره الگو	ساختار ورودی	خروجی
۱	T_{min}, T_{max}	ET
۲	T_{min}, T_{max}, RH	ET
۳	T_{min}, T_{max}, W	ET
۴	T_{min}, T_{max}, R_s	ET
۵	T_{min}, T_{max}, RH, W	ET
۶	$T_{min}, T_{max}, RH, R_s$	ET
۷	T_{min}, T_{max}, W, R_s	ET
۸	$T_{min}, T_{max}, RH, W, R_s$	ET

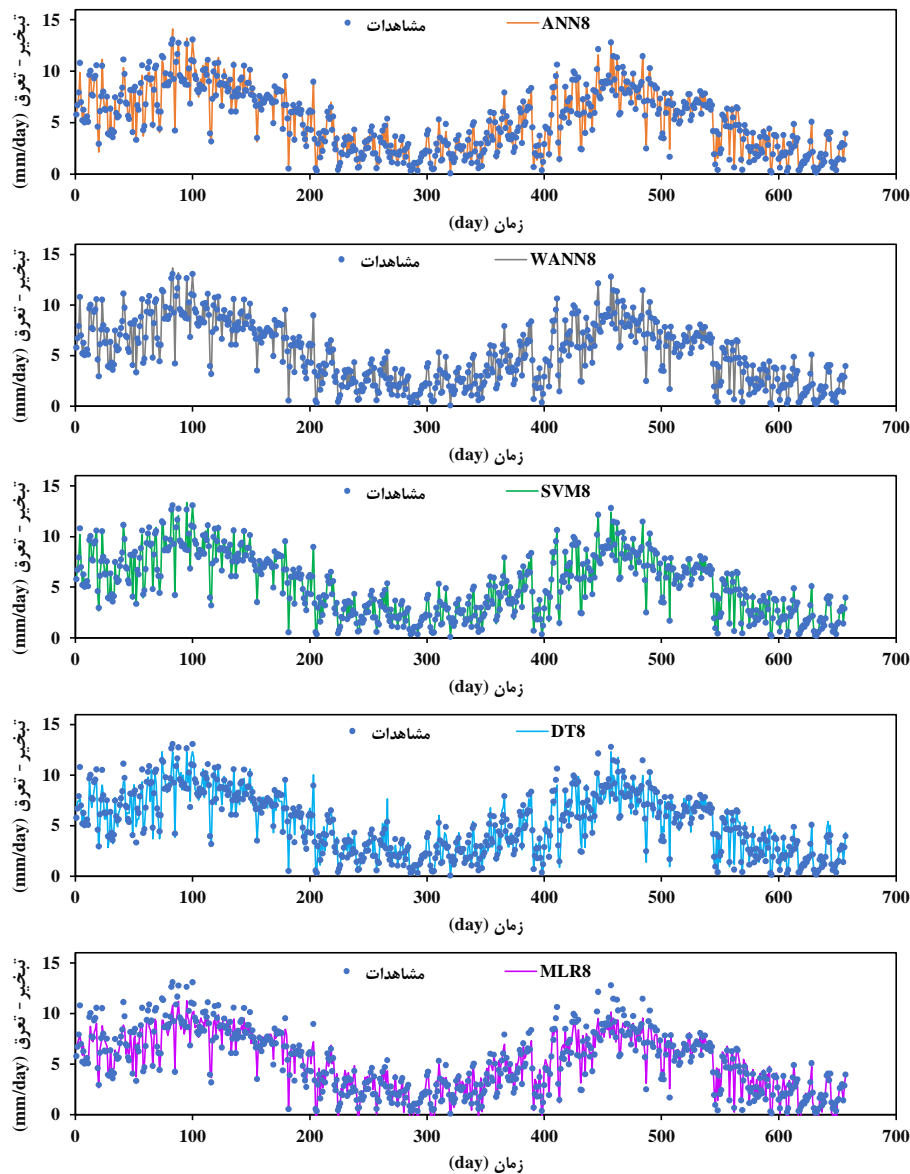
جدول ۳- شاخص‌های عملکرد بخش آزمون

مدل	ضریب همبستگی	ریشه میانگین مربع خطاها	نش سائکلیف
ANN1	۰/۸۴۷	۱/۶۲۸	۰/۷۱۳
ANN2	۰/۹۳۱	۱/۱۱۰	۰/۸۶۷
ANN3	۰/۹۴۱	۱/۰۳۵	۰/۸۸۴
ANN4	۰/۹۲۹	۱/۱۳۷	۰/۸۶۰
ANN5	۰/۹۷۰	۰/۷۳۹	۰/۹۴۱
ANN6	۰/۹۶۰	۰/۸۴۸	۰/۹۲۲
ANN7	۰/۹۸۱	۰/۶۰۰	۰/۹۶۱
ANN8	۰/۹۹۶	۰/۲۵۷	۰/۹۹۳
WANN1	۰/۸۵۴	۱/۶۰۱	۰/۷۲۳
WANN2	۰/۹۴۱	۱/۰۶۰	۰/۸۷۸
WANN3	۰/۹۵۲	۰/۹۳۵	۰/۹۰۵
WANN4	۰/۹۴۵	۱/۰۱۱	۰/۸۸۹
WANN5	۰/۹۷۹	۰/۶۲۶	۰/۹۵۸
WANN6	۰/۹۶۹	۰/۷۵۷	۰/۹۳۸
WANN7	۰/۹۸۶	۰/۵۱۵	۰/۹۷۱
WANN8	۰/۹۹۹	۰/۰۹۷	۰/۹۹۹
SVM1	۰/۸۵۷	۱/۵۸۱	۰/۷۲۹
SVM2	۰/۹۳۵	۱/۰۸۱	۰/۸۷۳
SVM3	۰/۹۴۱	۱/۰۳۴	۰/۸۸۴
SVM4	۰/۹۳۰	۱/۱۲۴	۰/۸۶۳
SVM5	۰/۹۷۳	۰/۶۹۹	۰/۹۴۷
SVM6	۰/۹۶۴	۰/۸۱۳	۰/۹۲۹
SVM7	۰/۹۸۵	۰/۵۳۶	۰/۹۶۹
SVM8	۰/۹۹۹	۰/۱۴۴	۰/۹۹۸
DT1	۰/۸۴۷	۱/۶۲۸	۰/۷۱۳
DT2	۰/۹۰۹	۱/۲۶۹	۰/۸۲۶
DT3	۰/۹۱۱	۱/۲۶۲	۰/۸۲۷
DT4	۰/۹۱۶	۱/۲۲۹	۰/۸۳۶
DT5	۰/۹۴۷	۰/۹۷۸	۰/۸۹۷
DT6	۰/۹۴۶	۰/۹۹۱	۰/۸۹۴
DT7	۰/۹۵۲	۰/۹۳۷	۰/۹۰۵
DT8	۰/۹۸۱	۰/۶۰۰	۰/۹۶۱
MLR1	۰/۸۳۸	۱/۳۰۰	۰/۶۹۶
MLR2	۰/۹۰۵	۱/۱۳۰	۰/۸۱۸
MLR3	۰/۸۹۵	۱/۱۲۶	۰/۷۹۳
MLR4	۰/۹۲۲	۱/۰۲۰	۰/۸۴۴
MLR5	۰/۹۲۷	۱/۰۰۲	۰/۸۵۶
MLR6	۰/۹۵۲	۰/۸۶۷	۰/۹۰۵
MLR7	۰/۹۶۰	۰/۷۶۲	۰/۹۱۷
MLR8	۰/۹۷۲	۰/۶۶۹	۰/۹۴۳

در جدول ۳، شاخص‌های آماری عملکرد مدل‌های مورد استفاده در تحقیق حاضر به‌ازای سناریوهای مختلف گزارش شده است.

قابل توجه در سایر مدل‌ها این است که در محاسبه مقادیر بیشینه و کمینه دقت کافی را نداشته و خطای بیشتری نسبت به مدل منتخب داشته‌است.

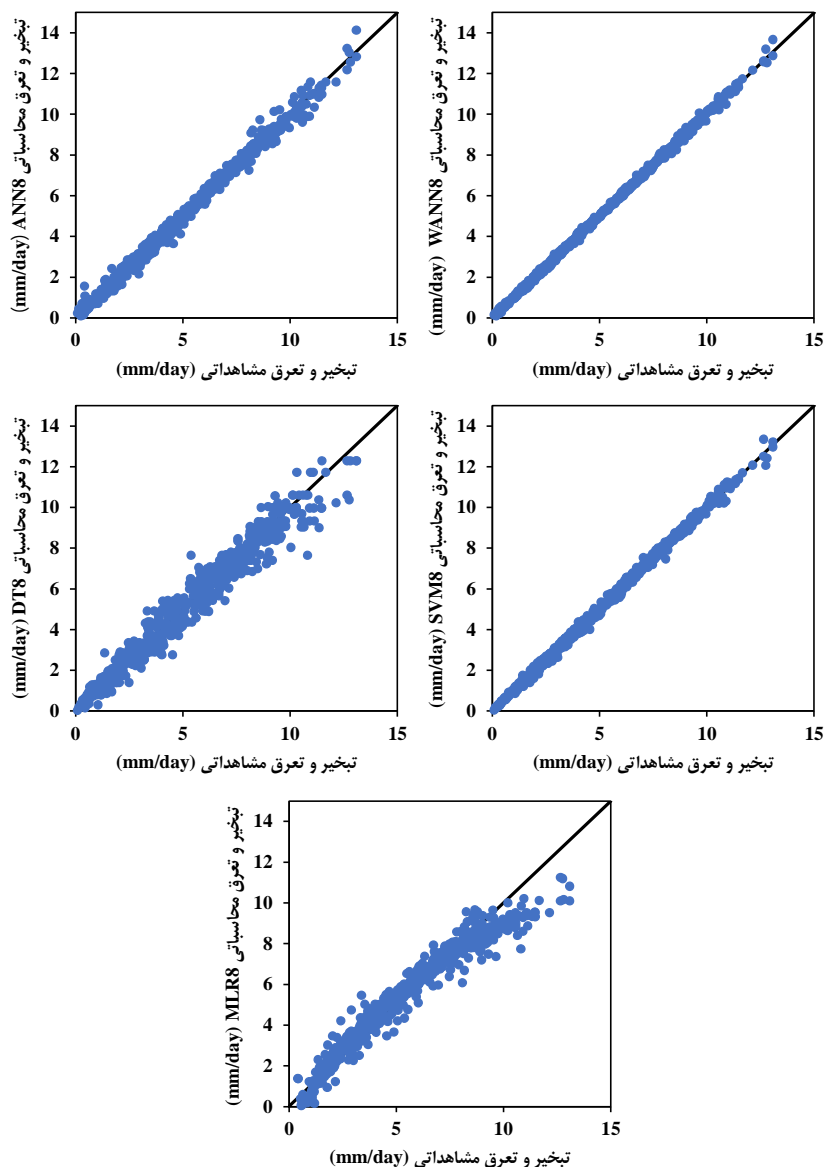
در شکل ۳، نمودار سری زمانی برای سناریوی منتخب در تمامی مدل‌ها مشاهده می‌شود که در مدل هیبرید موجکی عصبی (WANN8) بهترین دقت را داشته و نکته



شکل ۳- نمودار سری زمانی داده‌های مشاهداتی و محاسباتی برای قسمت آزمون

است و پس از آن مدل ماشین بردار پشتیبان (SVM8) نتایج بسیار مطلوبی را داشته‌است. سایر مدل‌ها نیز با وجود داشتن نتایج قابل قبول، دقتی پایین‌تر نسبت به مدل‌های ذکر شده داشته‌اند.

همچنین در شکل ۴، نمودارهای پراکندگی مشاهده می‌شود که برای بهترین سناریو (سناریوی ۸) برای ۵ مدل مورد بررسی ترسیم شده‌است. به‌وضوح مشاهده می‌شود که نمودار هیبرید موجکی عصبی (WANN8) بهترین نتیجه با کمترین پراکندگی را حول خط $(y=x)$ داشته



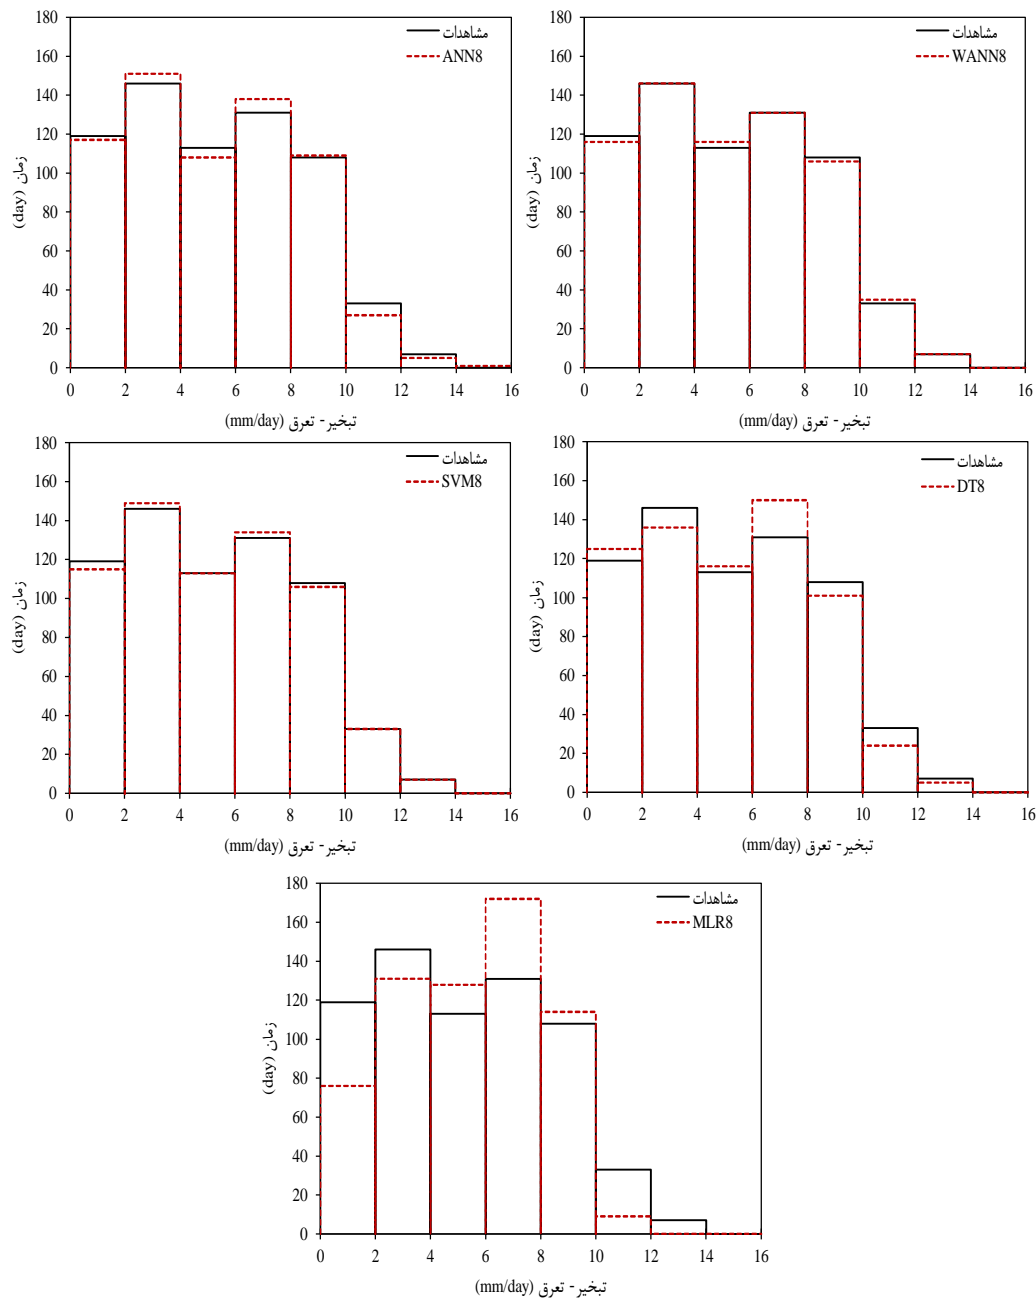
شکل ۴- نمودارهای پراکنش داده‌های محاسباتی-مشاهداتی برای قسمت آزمون

نمودار اصلاح‌شده و کامل‌تری از نمودار جعبه‌ای است. در این نمودار علاوه بر بیشینه، کمینه، چارک‌های اول، سوم و میانه، وضعیت پراکنش داده‌ها حول بیشینه، کمینه و میانه را نیز نمایش می‌دهد. در شکل ۶، وضعیت پراکنش داده‌ها نسبت به مقادیر بیشینه، کمینه و میانه برای مقادیر مشاهداتی و مدل‌ها ترسیم شده است. در شکل ۶ پراکنش داده‌های تبخیر-تعرق بیشتر حول چارک اول و سپس چارک سوم است. نزدیک‌ترین نمودار ویولونی به داده‌های مشاهداتی هیبرید موجکی عصبی و رگرسیون خطی بیشترین تفاوت را در پراکنش داده‌ها داشته است. شکل ۷


شکل ۵ نیز هیستوگرام احتمال وقوع تبخیر-تعرق در بازه‌های مختلف و وضعیت توزیع آن را نشان می‌دهد که در اینجا نیز با توجه به مدل‌ها و تخمین آن‌ها در وضعیت توزیع و احتمال وقوع تبخیر در مقایسه با میزان مشاهداتی به وضوح دقت بالای شبکه عصبی موجکی (WANN8) قابل مشاهده است که در همه مدل‌ها بازه ۶ تا ۸ میلی‌متر بر روز بیشترین خطا را نسبت به داده‌های مشاهداتی داشته است. بیشترین خطا مربوط به رگرسیون چندگانه خطی و کم‌ترین خطا مربوط به هیبرید عصبی موجکی است. همچنین شکل ۶ نمودار ویولونی را نشان می‌دهد که

بهترین نتیجه را داشته است. هر مدل در شکل ۷ با دایره رنگی مشخص شده است. مدل هیبرید عصبی موجکی (نقطه آبی) کمترین فاصله را با مقادیر مشاهداتی (نقطه سیاه) داشته که نشان دهنده بالاترین دقت است و مدل رگرسیون چندگانه خطی (نقطه بنفش) بیشترین فاصله را با مقادیر مشاهداتی داشته که نشان دهنده کمترین دقت است.


نمودار دیاگرام تیلور را برای بهترین مدل‌ها نمایش می‌دهد که در این شکل فاصله شعاعی هر نقطه از داده‌های مشاهداتی (نقطه سیاه‌رنگ) نشان دهنده مقدار ریشه میانگین مربع خطاها (RMSE) است (تیلور، ۲۰۰۱). برای ارزیابی دیاگرام تیلور، هرچقدر میزان ضریب همبستگی (R) به ۱ و ریشه میانگین مربع خطاها (RMSE) کمتر باشد، مدل دقت بالاتری خواهد داشت که مدل هیبریدی موجکی عصبی (WANN8) در این نمودار



شکل ۵- نمودار هیستوگرام داده‌های محاسباتی-مشاهداتی قسمت آزمون



شکل ۶- نمودار ویولونی مدل‌های استفاده‌شده و داده‌های مشاهداتی برای قسمت آزمون



شکل ۷- دیاگرام تیلور مدل‌های مورد استفاده برای قسمت آزمون

مقادیر ضریب همبستگی، میانگین مربع خطاها و ضریب نش-ساتکلیف داشته‌اند.

نتیجه‌گیری

از آنجایی‌که تبخیر-تعرق در مدیریت منابع آب و معادله بیلان همیشه حائز اهمیت بوده، تخمین دقیق آن همواره مورد توجه محققان مختلف قرار گرفته است. در تحقیق حاضر رویکرد مدل‌های رگرسیون خطی چندمتغیره، درخت تصمیم، شبکه عصبی مصنوعی، ماشین بردار پشتیبان و شبکه عصبی موجکی به‌منظور مدل‌سازی تبخیر تعرق روزانه در شهر اسکاتس‌بلوف در ایالت نبراسکا

پاتیل و دکا (۲۰۱۵) به مدل‌سازی تبخیر-تعرق توسط مدل شبکه عصبی و موجکی در منطقه بیابان بزرگ هند پرداختند که نتایج به‌دست‌آمده در آن تحقیق، به برتری مدل عصبی موجکی اشاره کرده‌است؛ همچنین در ایران نیز گنجی‌خرمدل و حسینی (۱۳۹۸) به مدل‌سازی تبخیر-تعرق توسط مدل عصبی موجکی در منطقه شهرکرد پرداختند که نتیجه آن به برتری مدل موجکی عصبی نسبت به سایر مدل‌ها اشاره کرده‌است و با تحقیق حاضر تطابق دارند. سایر مدل‌های استفاده‌شده نیز (شبکه عصبی مصنوعی، ماشین بردار پشتیبان، رگرسیون خطی چندمتغیره و درخت تصمیم) دقت قابل‌قبولی با توجه به

4. Alberg D. Last M. and Kandel A. 2012. Knowledge discovery in data streams with regression tree methods. WIREs Data Mining Know Discover. 2: 69-78.
5. Almedeij J. 2012. Modeling pan evaporation for Kuwait by multiple linear regression. The Scientific World Journal. 574742.
6. Bishop C. M. 1995. Neural networks for pattern recognition. Oxford University Press. 482 p.
7. Chow V. T. Maidment D. R. and Mays L. W. 1988. Applied hydrology. New York, NY: McGraw-Hill.
8. Cristianini N. and Lkopf B. 2002. Support vector machines and Kernel methods: the new generation of learning machines. AI Mag. 23: 31-41.
9. Demuth H. and Beale M. 2005. Neural Network Toolbox: For Use with Matlab. The MathWorks Inc., Natick, USA.
10. Ghorbani M. A. Kazempour R. Chau K. W. Shamshirband Sh. and Taherei Ghazvinei P. 2018. Forecasting pan evaporation with an integrated artificial neural network quantum-behaved particle swarm optimization model: a case study in Talesh. Northern Iran. Engineering Applications of Computational Fluid Mechanics. 12(1): 724-737.
11. Guo Q. Kelly M. and Graham C. H. 2005. Support vector machines for predicting distribution of Sudden Oak Death in California. Ecol. Model. 182: 75-90.
12. Heil C. E. and Walnut D. F. 1989. Continuous and discrete wavelet transforms. SIAM review. 31(4): 628-666.
13. Irmak S. Kabenge I. E. Skaggs K. and Mutiibwa D. 2012. Trend and magnitude of changes in climate variables and reference evapotranspiration over 116-yr period in the Platte River Basin. central Nebraska-USA, Journal of Hydrology. 420(421): 228-244.
14. Jain S. K. das A. and Srivastva D. k. 1999. Application of ANN for reservoir inflow prediction and operation. Journal of Water Resources Planning and Management. 125(5): 263-271.
15. Jakkula V. 2006. Tutorial on Support Vector Machine (svm). 37 School of EECS, Washington State University.
16. Kisi O. 2015. Pan evaporation modeling using least square support vector machine, multivariate adaptive regression splines and M5 model tree. Journal of Hydrology. 528: 312-320.
17. Liu B. Xu M. Henderson M. and Gong W. 2004. A spatial analysis of pan evaporation trends in China, 1955-2000. Journal of Geophysical Research. 109: D15102.
18. Majhi B. Naidu D. 2021. Pan evaporation modeling in different agroclimatic zones

در آمریکا بررسی شد. از آنجایی که پارامترهای ورودی متفاوتی برای محاسبه تبخیر-تعرق استفاده شد، ۸ سناریوی مختلف مورد بررسی قرار گرفت و در بین ۸ سناریوی بررسی شده، سناریوی ۸ با پارامترهای ورودی دمای کمینه، دمای بیشینه، رطوبت نسبی، سرعت باد و تابش خورشیدی به عنوان سناریوی ورودی برتر و رویکرد مدل هیبریدی عصبی موجک به عنوان رویکرد مدل سازی بهینه بررسی و انتخاب شد. مدل مذکور با شاخص های ارزیابی R ، $RMSE$ و NSE به ترتیب برابر با $0/97$ ، $0/99$ و $0/99$ نتایج رضایت بخشی را نشان داده است. مدل شبکه عصبی مصنوعی قدرتمند است و توانایی تولید مدل های غیرخطی را نیز داراست؛ اما به دلیل نایستاب بودن داده های تبخیر-تعرق روزانه برای افزایش دقت به پیش پردازش داده ها توسط تبدیل موجک پرداخته شد که در نتیجه آن ویژگی های چندمقیاسی داده ها در فرکانس های بالا و پایین تجزیه و باعث افزایش دقت مدل شبکه عصبی شده است. نتایج به دست آمده در این مطالعه می تواند در تخمین تبخیر-تعرق در برنامه های مدیریت منابع آب و تخمین آن در ایستگاه های هواشناسی مورد استفاده قرار گیرد. با توجه به دقت مطلوب مدل هیبرید موجکی عصبی در زمینه مدل سازی تبخیر-تعرق پیشنهاد می شود در مطالعات آتی از این مدل در تحقیقات و پروژه ها استفاده شود. سایر مدل ها (ANN ، DT ، MLT و SVM) نیز نتایج مطلوبی داشته و استفاده از آن ها قابل قبول است.

منابع

۱. طالبی ع. و اکبری ز. ۱۳۹۲. بررسی کارایی مدل درختان تصمیم گیری در برآورد رسوبات معلق رودخانه ای (مطالعه موردی: حوضه سد ایلام). مجله علوم و فنون کشاورزی و منابع طبیعی. علوم آب و خاک. ۱۷(۶۳): ۱۰۹-۱۲۱.
۲. گنجی خرم دل ن. و حسینی م. ر. ۱۳۹۸. تخمین تبخیر و تعرق مرجع روزانه به کمک مدل شبکه عصبی مصنوعی و مدل ترکیبی شبکه عصبی-موجک. علوم آب و خاک (علوم و فنون کشاورزی و منابع طبیعی). ۲۳(۲): ۲۱۵-۲۲۶.
۳. یوسف م. طالبی ع. و پورشرعیاتی ر. ۱۳۹۳. کاربرد هوش مصنوعی در علوم آب و خاک، یزد، دانشگاه یزد. ۵۱۶ ص.

29. Zounemat-Kermani M. 2012. Hourly predictive Levenberg-Marquardt ANN and multi-linear regression models for predicting of dew point temperature. *Meteorol. Atmos. Phys.* 117(3-4): 181-192.
19. Nourani V. Elkiran G. Abdullahi J. 2019. Multi-station artificial intelligence-based ensemble modeling of reference evapotranspiration using pan evaporation measurements. *Journal of Hydrology.* 577 p.
20. Nourani V. Hosseini Baghanam A. Adamowski and Kisi O. 2014. Applications of hybrid wavelet- Artificial Intelligence models in hydrology: A review. *Journal of Hydrology.* 514(3): 358-377.
21. Patil A. and Deka P. 2015. Performance evaluation of hybrid Wavelet-ANN and Wavelet-ANFIS models for estimating evapotranspiration in arid regions of India. *Neural Computing and Applications.* 28. 10.1007/s00521-015-2055-0.
22. Patle G. T. Chettri M. and Jhajharia D. 2020. Monthly pan evaporation modelling using multiple linear regression and artificial neural network techniques. *Water Supply.* 20(3): 800-808.
23. Qasem S. N. Samadianfard S. Kheshtgar S. Jarhan S. Kisi O. Shamshirband SH. and Chau K. W. 2019. Modeling monthly pan evaporation using wavelet support vector regression and wavelet artificial neural networks in arid and humid climates. *Engineering Applications of Computational Fluid Mechanics.* 13(1): 177-187.
24. Razi M. A. and Athappilly K. 2005. A comparative predictive analysis of neural networks (NNs), nonlinear regression and classification and regression tree (CART) models. *Expert Systems with Applications.* 29: 65-74.
25. Tabari H. Marofi S. and Sabziparvar A. A. 2010. Estimation of daily pan evaporation using artificial neural network and multivariate non-linear regression. *Irrigation Science.* 28: 399-406.
26. Taylor K. E. 2001. Summarizing multiple aspects of model performance in a single diagram. *J. Geophys. Res.* 106(D7): 7183-7192.
27. Wang L. Niu Z. Kisi O. Li C. and Yu D. 2017. Pan evaporation modeling using four different heuristic approaches. *Computers and Electronics in Agriculture.* 140: 203-213.
28. Yonts C. D. Haghverdi A. Reichert D. L. and Irmak S. 2018. Deficit irrigation and surface residue cover effects on dry bean yield, in-season soil water content and irrigation water use efficiency in western Nebraska high plains. *Agricultural Water Management.* 199: 138-147.