



ISSN 2251-7480

نشریه حفاظت منابع آب و خاک، سال نهم، شماره سوم، بهار ۱۳۹۹

تحلیل حساسیت داده‌های هواشناسی در برآورد تبخیر و تعرق مرجع با حداقل داده‌های هواشناسی با استفاده از مدل‌های موجک-عصبی-فازی، ANN و ANFIS

احمد رضا کریمی پور^{۱*}، گل‌نوش بنی طالبی^۲^۱ گروه مهندسی عمران، دانشگاه پیام‌نور، شهرکرد، ایران (نویسنده مسئول) ahm.karimipour@gmail.com^۲ دانشجوی دکتری فیزیک و حفاظت خاک، دانشگاه صنعتی اصفهان g.banitalebi@ag.iut.ac.ir

تاریخ پذیرش: ۹۹/۰۲/۲۲

تاریخ دریافت: ۹۸/۰۵/۰۸

چکیده

هدف از مطالعه حاضر برآورد مقدار تبخیر و تعرق (ET_0) در اقلیم نیمه مرطوب معتدل سرد و در یک دوره آماری ۲۲ ساله با بکارگیری مدل موجک-عصبی-فازی با حداقل تعداد پارامترهای ورودی موثر بود. به منظور بررسی کارایی این مدل نتایج با مدل شبکه عصبی و انفیس (Anfis) مقایسه شد. آنالیز حساسیت داده‌های ورودی به سه روش هیل، ضریب تبیین و استات‌سافت انجام شد. آنالیز تحلیل حساسیت نشان داد که دما (T) (دما، مینیمم، ماکزیمم و میانگین)، R_a ، R_s ، سرعت باد در ارتفاع دو متری (U_2) و R_n به عنوان پارامترهای اثرگذار بوده‌اند و ترکیب‌های مختلف این پارامترهای ورودی می‌تواند منجر به برآورد دقیق‌تر ET_0 شود. بر اساس نتایج آنالیز حساسیت، شش ترکیب با پارامترهای مذکور انتخاب شد و دما در تمامی این ترکیب‌ها به عنوان متغیر ورودی به کار برده شد. با کاربرد سه پارامتر ورودی T_{max} ، T_{min} و R_s و موجک sym8 مدل موجک-عصبی-فازی عملکرد بهتری ($MBE=0.03$ و $R^2=0.71$) نسبت به مدل شبکه عصبی ($MBE=0.07$ و $R^2=0.65$) دارد. براساس ضریب تبیین و مقدار خطای محاسبه شده برای شبکه عصبی و انفیس، ترکیب ۷ پارامتر ورودی (R_a ، R_n ، R_s ، U_2 ، T_{mean} ، T_{min} و T_{max}) $ANFIS=0.007$ ، $ANN=MBE=0.003$ ، $MBE=0.007$ ، $R^2=0.99$ و $ANFIS=MBE=0.003$ ، $ANN=MBE=0.003$ ، $R^2=0.99$ ، $MBE=0.003$ ، $R^2=0.98$ را در تخمین میزان ET_0 در مقایسه با روش فائو پنمن مانیتیت داشتند. نتایج همچنین نشان داد که بیشترین مقدار ضریب تبیین و کمترین مقدار خطا در بین موجک‌های مختلف مورد استفاده در مدل موجک-عصبی-فازی به ترتیب برای ترکیب‌های ۷ و ۳ پارامتر ورودی (R_s ، T_{min} ، T_{max}) با مقادیر ضریب تبیین 0.87 و مقدار میانگین خطای انحراف 0.02 برای ترکیب ۷ پارامتری و با مقادیر ضریب تبیین 0.71 و مقدار میانگین خطای انحراف 0.03 برای ترکیب سه پارامتری بدست آمده است. نتایج این مطالعه همچنین نشان داد که براساس آماره‌های خطا ($NRMSE$ ، $RMSE$ ، MAE ، MBE ، EF) و ضریب تبیین، برترین روش‌ها در برآورد مقدار تبخیر و تعرق فصلی، سالانه و ماهانه، روش‌های هاگریوزز ام ۴، تیلور-پریستلی، ایرماک و میر بودند. براساس دو آماره‌ی خطای EF و $NRMSE$ برای چهار روش هاگریوزز ام-۴ ($EF=0.92$ ، $NRMSE=0.11$)، تیلور-پریستلی ($EF=0.88$ ، $NRMSE=0.12$)، ایرماک ($EF=0.67$ ، $NRMSE=0.25$) و میر ($EF=0.73$ ، $NRMSE=0.03$) در بازه زمانی طولانی مدت، از نظر کارایی مدل روش هاگریوزز ($EF=0.92$) و از نظر جذر میانگین مربع خطای نرمال شده، میر ($NRMSE=0.03$) از بقیه روش‌ها بهتر عمل نموده است.

کلید واژه‌ها: انفیس؛ تحلیل حساسیت؛ فائو پنمن مانیتیت؛ موجک-عصبی-فازی

مقدمه

است. روش‌های متعددی برای تخمین تبخیر و تعرق وجود دارد و این روش‌ها به دو گروه مستقیم و غیرمستقیم تقسیم بندی می‌شوند. معمول‌ترین روش مستقیم تعیین مقدار تبخیر و تعرق، استفاده از لایسیمتر می‌باشد. اما استخراج داده از

محدودیت منابع آب، توسعه کشاورزی را تحت تأثیر قرار می‌دهد. بنابراین تعیین مقدار تبخیر و تعرق به منظور محاسبه نیاز آبی گیاهان و استفاده بهینه از منابع آبی حائز اهمیت

مدل را به عنوان متغیر ورودی در نظر گرفته و هدف، ارزیابی تأثیر عدم قطعیت پارامتر ورودی مدل بر عملکرد مدل است از جمله شاخص‌هایی که برای تحلیل حساسیت محلی مورد استفاده قرار می‌گیرد می‌توان به مشتقات جزئی یا تفاضل محدود اشاره نمود (Hill et al., 2006). روش‌های تحلیل حساسیت جامع، هم پارامترهای مدل و هم سایر عوامل ورودی مدل در یک فرآیند شبیه‌سازی را در نظر می‌گیرد از جمله این شاخص‌ها می‌توان به معیارهای همبستگی بین ورودی و خروجی‌های مدل یا مشخصات آماری توزیع‌های خروجی مانند واریانس، اشاره نمود. از آنجایی که محاسبات تحلیلی این شاخص‌ها برای بیشتر مدل‌ها غیرممکن است، شاخص‌های حساسیت با نمونه‌گیری از ورودی‌ها و خروجی‌های برآورد شده، تخمین زده می‌شود. همچنین در روش‌های تحلیل حساسیت یک فاکتور در زمان و همه فاکتورها در زمان با تغییر یک متغیر ورودی یا تمامی متغیرهای ورودی به ترتیب مقدار تغییرات در خروجی مدل بررسی می‌شود. در روش‌های تحلیل حساسیت محلی نیز از تغییر یک فاکتور در زمان و برای روش‌های جامع از هر دو مورد استفاده می‌شود (Pianosi et al., 2016).

Odhiambo و همکاران (۲۰۰۱) روش منطق فازی را برای تخمین تبخیر و تعرق گیاه مرجع به کار برده و نتایج را با روش‌های فائو-پنمن ماتیت و هارگریوز-سامانی مقایسه کردند. نتایج نشان داد روش منطق فازی دارای خطای کم‌تری نسبت به دو روش دیگر می‌باشد. Zanetti و همکاران (۲۰۰۷) با مقایسه نتایج حاصل از برآورد مقدار (ET_0) با استفاده از شبکه عصبی مصنوعی (ANN) و به کارگیری پارامترهای دمای حداکثر و حداقل، تشعشع خورشیدی خارج از اتمسفر و ساعات آفتابی روزانه نشان دادند که فقط با به کارگیری حداقل و حداکثر دما، می‌توان مقادیر (ET_0) را با دقت قابل قبولی تخمین زد. Kumar و همکاران (۲۰۰۸) با اجرای ۳ سناریوی متفاوت از پارامترهای هواشناسی به عنوان ورودی (ANN) شامل دما و

لایسیمتر دشوار و بسیار وقت‌گیر است. در روش‌های غیرمستقیم یا محاسباتی نیز از عوامل مختلف اقلیمی و گیاهی استفاده شده و به کمک روابط مختلف مقدار تبخیر و تعرق مرجع تخمین زده می‌شود. این روابط اغلب تحت شرایط خاص محلی واسنجی شده‌اند و دارای محدودیت‌های برای استفاده در مناطق دیگر هستند. تبخیر و تعرق مرجع یک پدیده غیرخطی است و شبکه عصبی مصنوعی به عنوان یک ابزار مناسب برای مدل‌سازی سامانه‌های غیرخطی شناخته شده است. شبکه‌های عصبی مصنوعی یکی از ابزارهای قدرتمند در مدل‌سازی هستند و برای طبقه‌بندی، خوشه‌بندی و تقریب توابع مورد استفاده قرار می‌گیرند. در سال‌های اخیر از روش‌های شبکه عصبی مصنوعی یا منطق فازی و یا ترکیبی از آن‌ها برای تخمین تبخیر و تعرق استفاده شده است. انتخاب متغیرهای ورودی مناسب در این مدل‌ها می‌تواند نقش قابل توجهی در تخمین دقیق‌تر تبخیر و تعرق داشته باشد. تحلیل حساسیت جزء مراحل اساسی مدل‌سازی است که تعیین‌کننده درجه تغییرپذیری خروجی مدل با تغییر متغیرهای آن است. در دهه‌های اخیر با افزایش مدل‌های شبیه‌سازی و پیچیدگی هر چه بیشتر این مدل‌ها به دلیل افزایش متغیرها، تحلیل حساسیت ابزاری ضروری برای فهم نقش و اهمیت متغیرها در فرآیند مدل‌سازی شده است. به طوری که در آنالیز حساسیت ابتدا ورودی‌های مدل به آرامی تغییر می‌کنند و تغییرات متناظر آن‌ها در خروجی شبکه به صورت درصد و یا مقدار تفاوت کلی ثبت می‌شود (شیرانی، ۱۳۹۶). تقسیم‌بندی‌های مختلفی (کمی و کیفی، یک در زمان و همه در زمان) برای انواع روش‌های تحلیل حساسیت وجود دارد، روش‌های کلی تحلیل حساسیت با توجه به اینکه تغییرات خروجی به وسیله تغییرات مؤلفه‌های ورودی اطراف یک مقدار مرجع، یا در کل فضای ممکن به دست آید، به دو گروه تحلیل حساسیت محلی و جامع تقسیم می‌گردند (Hamraz et al., 2016, Razavi et al., 2015).

در روش‌های تحلیل حساسیت محلی معمولاً پارامترهای

به مدل شبکه عصبی و رگرسیون خطی بهینه‌شده دارد (Adamala et al., 2019). Alves و همکاران (۲۰۱۷) به تخمین تبخیر و تعرق روزانه در منطقه سائوپائولو برزیل با استفاده از شبکه عصبی مصنوعی پرداختند. در این تحقیق از داده‌های ۱۰ ساله رطوبت نسبی روزانه (RH)، شار گرما، سرعت باد در ارتفاع ۲ متری از سطح زمین و تابش خالص خورشیدی استفاده گردید. نتایج نشان داد که تنها با استفاده از دمای هوا به‌عنوان متغیر ورودی به شبکه عصبی مصنوعی می‌توان با دقت بسیار خوبی مقدار تبخیر و تعرق را تخمین زد.

Qasem و همکاران (۲۰۱۹)، به مقایسه مدل‌های ترکیبی شبکه عصبی، موجک- شبکه عصبی، موجک- بردار پشتیبان و بردار پشتیبان در منطقه تبریز و آنتالیا پرداختند. معیارهای آماری RMSE، MAE، R و شاخص نش‌ساتکلیف (NSE) نشان داد که شبکه عصبی با سه پارامتر ورودی دمای حداقل و حداکثر هوا و تشعشع خورشیدی عملکرد بهتری در مقایسه با مدل موجک- شبکه عصبی، موجک- بردار پشتیبان و بردار پشتیبان برای این دو منطقه دارد. همچنین نتایج نشان داد که با کاربرد تعداد بیشتر پارامترهای ورودی (۵ پارامتر) (دمای ماکزیمم و مینیمم، رطوبت نسبی ماکزیمم و می نیمم و تشعشع خورشیدی) دقت مدل موجک- بردار پشتیبان از سایر مدل‌ها بیشتر می‌گردد و به‌طورکلی شبکه عصبی روند منطقی‌تری نسبت به سایر مدل‌ها در برآورد مقدار تبخیر و تعرق در دو منطقه آنتالیا و تبریز دارد.

Valipour (۲۰۱۷)، مقادیر تبخیر و تعرق ۳۱ منطقه از ایران را با استفاده از ۱۸۱ ایستگاه سینوپتیک هواشناسی در شرایط محدود داده‌های هواشناسی با سه ترکیب فرمول‌های بر پایه دما، فرمول‌های بر پایه دما- رطوبت و فرمول‌های بر پایه دما- رطوبت- سرعت باد تخمین زد و نتایج را با روش فائو- پنمن- مانیتث مقایسه کرده و بیان نمود که مهم‌ترین پارامترهای هواشناسی مؤثر در مدل‌سازی تبخیر و تعرق، دما، سرعت باد و رطوبت نسبی هوا هستند. همچنین نتایج نشان داد که فرمول‌های بر پایه دما، دما- رطوبت و دما-

تشعشع (مدل ۱)، باد و رطوبت (مدل ۲) و تعداد ساعات آفتابی و دما (مدل ۳) مقدار (ET_0) را برآورد نمودند و مطالعه آنان مؤید مناسب بودن هر یک از سناریوهای ۱ تا ۳ به ترتیب برای مناطق با اقلیم خشک، مرطوب و خشک-مرطوب بود.

Ghorbani و همکاران (۲۰۱۸) در پژوهش خود مقدار تبخیر و تعرق روزانه را با کمک یک مدل بهینه‌سازی رفتار ذرات کوانتومی- شبکه عصبی مصنوعی (MLP-QPSO) در شمال ایران (تالش) پیش‌بینی نمودند. در این مطالعه، یک الگوریتم بهینه‌سازی رفتار ذرات کوانتومی، درون یک تکنیک پرسپترون چندلایه برای برآورد نرخ تبخیر روزانه تعبیه شد و از داده‌های اندازه‌گیری شده تبخیر و تعرق از سال ۲۰۱۲ تا ۲۰۱۴ ایستگاه هواشناسی تالش واقع در شمال ایران استفاده گردید. در این تحقیق دقت پیش‌بینی مدل MLP-QPSO با مدل هیبریدی MLP-PSO و MLP مورد ارزیابی قرار گرفت و نتایج نشان داد که مدل MLP-QPSO به‌عنوان یک ابزار پیش‌بینی بهینه تبخیر و تعرق روزانه تحت تبخیر عملکرد بهتری نسبت به مدل هیبریدی MLP-PSO و مدل مستقل MLP دارد. Allawi و همکاران (۲۰۱۹) در مطالعه خود به بررسی توانایی شبکه عصبی مصنوعی بر پایه شعاعی (RBF-NN) و روش‌های رگرسیون بردار پشتیبان (SVR) برای تهیه یک مدل پیش‌بینی تبخیر و تعرق در یک منطقه گرمسیری در مالزی پرداختند. نتایج نشان داد که در مقایسه با مقادیر اندازه‌گیری شده تبخیر و تعرق دقت مدل RBF-NN بالاتر از SVR بود.

Adamala و همکاران (۲۰۱۹) به مقایسه برآورد مقادیر تبخیر و تعرق روزانه توسط شبکه موجک عصبی با روش‌های فائو- پنمن- مانیتث، Turc و هارگریوز در چهار اقلیم نیمه‌خشک، خشک، نیمه مرطوب و مرطوب در هند پرداختند. داده‌های مورد استفاده در این برآورد شامل T_{max} ، T_{min} ، RH_{min} ، RH_{max} و سرعت باد و تشعشع خورشیدی بودند. نتایج آن‌ها نشان داد که در چهار اقلیم مورد مطالعه مدل بهینه‌شده موجک- شبکه عصبی عملکرد بهتری نسبت

مورد استفاده قرارداد. Arca و همکاران (۲۰۰۱) نشان دادند که مدل شبکه عصبی حاصله از ترکیب پارامترهای سرعت باد و کمبود فشار بخار نتایج بهتری را نسبت به روش هارگریوز نشان می‌دهد و مقدار ریشه میانگین مربعات خطا، در روش شبکه عصبی مصنوعی و روش هارگریوز به ترتیب ۰/۲۷ و ۰/۴۳ میلی‌متر در روز می‌باشد. Keskin و Terzi (۲۰۱۰)، مقادیر روزانه تبخیر و تعرق از تشت را با چهار روش تجربی و همچنین روش شبکه عصبی مصنوعی مورد مقایسه قراردادند و پیشنهاد دادند که روش‌های تجربی باید قبل از استفاده کالیبره شوند و روش شبکه عصبی مصنوعی نتایج دقیق‌تری از تبخیر و تعرق نسبت به روش‌های دیگر ارائه می‌دهد.

با توجه به اهمیت پیش‌بینی تبخیر-تعرق مرجع در برنامه‌ریزی کوتاه‌مدت آبیاری و عدم دسترسی به کلیه داده‌های هواشناسی مورد نیاز، شناسایی و تعیین پارامترهای اثرگذار برای تخمین دقیق تبخیر و تعرق حائز اهمیت است. در این راستا هدف از مطالعه حاضر برآورد مقدار تبخیر و تعرق مرجع در اقلیم نیمه مرطوب معتدل سرد با حداقل داده‌های هواشناسی با استفاده از شبکه عصبی مصنوعی (ANN) و انفیس (ANFIS) و مدل موجک عصبی-فازی (FWNN) و مقایسه آن‌ها تا رسیدن به حداقل مقدار خطا هست.

مواد و روش‌ها

استان چهارمحال و بختیاری با مساحت ۱۶۵۳۲ کیلومتر مربع بین ۳۱ درجه و ۹ دقیقه تا ۳۲ درجه و ۴۸ دقیقه عرض شمالی و نیز ۴۹ درجه و ۲۸ دقیقه تا ۵۱ درجه و ۲۵ دقیقه طول شرقی قرار دارد. این استان در بخش مرکزی کوه‌های زاگرس واقع شده است. شهرهای مورد مطالعه در این تحقیق شامل شهرکرد، بروجن، فارسان و فرخشهر می‌باشند و داده‌های مورد استفاده در این مطالعه از ایستگاه‌های سینوپتیک سازمان هواشناسی شهرکرد، بروجن، فارسان و فرخشهر گردآوری شده که مشخصات این ایستگاه‌ها در

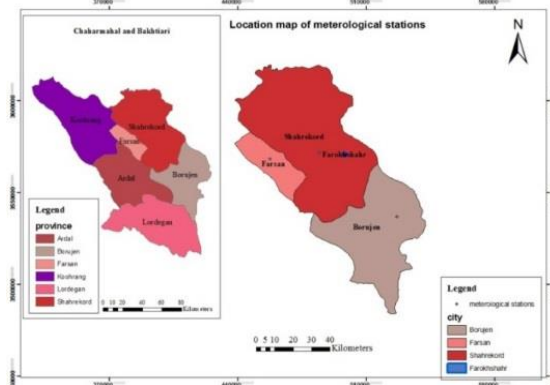
رطوبت-سرعت باد با دقت بالایی مقادیر تبخیر و تعرق را تخمین می‌زنند. Adamala (۲۰۱۹) مقدار تبخیر و تعرق را به صورت غیرخطی با استفاده از شبکه‌های عصبی مصنوعی برآورد نمود. در این مطالعه عملکرد مدل‌های شبکه عصبی مصنوعی در تخمین دقیق مقدار تبخیر و تعرق برای ۱۵ منطقه در هند با استفاده از ۶ متغیر هواشناسی به عنوان ورودی مورد بررسی قرار گرفت. همچنین عملکرد مدل‌های شبکه عصبی مصنوعی در تخمین مقدار تبخیر و تعرق در مقایسه با مدل‌های رگرسیون خطی چند متغیره مورد مقایسه قرار گرفت و نتایج نشان داد که مدل‌های شبکه عصبی مصنوعی عملکرد بهتری در همه مناطق نسبت به مدل‌های رگرسیون خطی چند متغیره دارند.

Trajkovic و Kolakovic (۲۰۰۹) با استفاده از حداقل و حداقل پارامترهای هواشناسی، مقدار (ET₀) ماهانه را برآورد نمودند و نتایج به دست آمده را با روش‌های هارگریوز اصلاح شده و تورک و روش (ANN) مقایسه کردند. نتایج نشان داد که برآورد مقدار تبخیر و تعرق با داده‌های ورودی محدود، به نتایج حاصل از برآورد این پارامتر با داده‌های کامل ارجحیت دارد. در این مطالعه حداقل داده‌های مورد نیاز برای برآورد مقدار (ET₀) در اقلیم مرطوب را مینیمم و ماکزیمم دمای روزانه و سرعت باد منطقه ذکر نمودند.

Goyal و همکاران (۲۰۱۴) توانایی تکنیک‌های شبکه عصبی مصنوعی، منطق فازی و سیستم استنتاج فازی عصبی تطبیقی و حداقل مربعات رگرسیون بردار پشتیبان (LS-SVR) را جهت تعیین دقت تخمین تبخیر و تعرق برای حوضه آبریز کارسو در هند با اقلیم آب و هوایی گرمسیری را مورد بررسی قراردادند. روش تجربی هارگریوز-سامانی (Hargreaves-Samani)، و همچنین روش استفانز استوارت (SS or Stephens-Stewart)، برای مقایسه با تکنیک‌های ذکر شده نیز مورد توجه قرار گرفت. نتایج نشان داد که رویکردهای منطق فازی و (LS-SVR) را می‌توان در مدل‌سازی و تخمین تبخیر و تعرق به طور موفقیت‌آمیز

می‌توانند مورد استفاده قرار گیرند. ابتدا مقایسه‌ای بین معادلات تجربی مورد استفاده در برآورد تبخیر و تعرق با مقدار اندازه‌گیری شده با معادله فائو-پنمن-مانتیت انجام شد. این معادلات شامل هارگریوز ام ۴ (-Hargreaves-M4)، تراجکویک (Trajkovic)، تیلور-پریستلی (-Taylor Priestley)، ایرماک ۱ و ۲ (IRMAK 1,2)، میر (Meyer) و ترک اصلاح شده (Modified Turc) بودند (جدول ۲ الف-د). براساس آماره‌های خطا (MBE, EF, NRMSE, RMSE, MAE) و ضریب تبیین، برترین روش‌ها در برآورد مقدار تبخیر و تعرق فصلی، سالانه و ماهانه، روش‌های هارگریوز ام ۴، تیلور-پریستلی، ایرماک و میر بودند. پارامترهای مورد استفاده در این معادلات تجربی شامل دمای هوا ($T, ^\circ\text{C}$), تابش برون زمینی (R_n), متوسط سرعت باد در ارتفاع ۲ متری از سطح زمین (U_2), تابش خالص در سطح پوشش گیاهی (R_s) و ($MJm^{-2}d^{-1}$) و تشعشع خورشیدی رسیده به زمین (موج کوتاه) ($MJm^{-2}d^{-1}$) بودند. بر این اساس از داده‌های هواشناسی مذکور و در ایستگاه‌های هواشناسی شهرکرد، بروجن، فارسان و فرخشهر در طی یک بازه زمانی ۲۲ ساله (۱۳۷۴-۱۳۹۶) بعنوان پارامترهای مورد استفاده در این مطالعه استفاده شد. میانگین پارامترهای آماری متغیرهای مذکور و همچنین مقدار تبخیر و تعرق محاسبه شده با استفاده از معادله فائو-پنمن-مانتیت (ET_0) در جدول ۳ آورده شده است.

جدول ۱ آورده شده است. داده‌های مورد استفاده تنها برگرفته از اطلاعات ایستگاه‌های هواشناسی منطقه بوده که فاقد داده‌های لایسیمیتری می‌باشد. اقلیم منطقه مورد مطالعه، نیمه مرطوب معتدل سرد می‌باشد و موقعیت محدوده مورد مطالعه در شکل ۱ نمایش داده شده است.



شکل ۱. موقعیت محدوده مورد مطالعه و ایستگاه‌های هواشناسی

جدول ۱. مشخصات ایستگاه‌های سینوپتیک هواشناسی

ایستگاه	عرض جغرافیایی	طول جغرافیایی	ارتفاع (m)
شهرکرد	$32^{\circ}17'$	$50^{\circ}50'$	۲۰۵۰
بروجن	$31^{\circ}58'$	$51^{\circ}17'$	۲۲۶۰
فارسان	$32^{\circ}15'$	$50^{\circ}33'$	۲۰۵۹
فرخشهر	$32^{\circ}17'$	$50^{\circ}55'$	۲۰۸۵

به منظور انتخاب داده‌های هواشناسی مورد استفاده در مطالعه حاضر، از آن‌جایی که پارامترهای هواشناسی بسیاری

جدول ۲. الف عملکرد آماری معادله‌های تجربی انتخابی جهت تخمین تبخیر و تعرق سالانه در مقایسه با روش فائو-پنمن-مانتیت در بازه زمانی مورد مطالعه (۱۳۷۴-۱۳۹۶)

آماره خطا					روش‌ها
RMSE	MAE	NRMSE	MBE	EF	
۰/۱۸	۰/۱۶	۰/۱۱	-۰/۱۶	۰/۹۲	Hargreaves-M4
۰/۴۹	۰/۴۴	۰/۰۳	۰/۰۳	۰/۷۳	Meyer
۰/۱۹	۰/۱۷	۰/۱۲	-۰/۱۷	۰/۹۱	Trajkovic
۰/۵۶	۰/۴۴	۰/۳۳	-۰/۴۴	۰/۶۲	Modified-turc
۰/۲۴	۰/۲۱	۰/۱۲	۰/۰۵	۰/۸۸	Taylor-Priestley
۰/۳۴	۰/۲۵	۰/۲۵	-۰/۲۱	۰/۶۷	IRMAK 1
۰/۵۴	۰/۳۹	۰/۴۵	-۰/۳۰	۰/۵۷	IRMAK 2

جدول ۲. ب عملکرد آماری معادله‌های تجربی انتخابی جهت تخمین تبخیر و تعرق فصلی در مقایسه با روش فائو-پنمن-مانتیت در بازه زمانی مورد مطالعه (۱۳۷۴-۱۳۹۶).

فصلی					روش
بهار	تابستان	پاییز	زمستان	آماره خطا	
۰/۹۱	۰/۹۴	۰/۹۹	۰/۸۴	EF	Hargreaves-M4
-۰/۲۷	-۰/۱۳	-۰/۰۵	-۰/۱۸	MBE	
۰/۱۱	۰/۱۰	۰/۰۳	۰/۲۱	NRMSE	
۰/۲۷	۰/۱۳	۰/۰۶	۰/۱۸	MAE	
۰/۲۷	۰/۱۳	۰/۰۶	۰/۱۹	RMSE	
۰/۷۵	-۰/۲۵	۰/۷۷	۰/۶۸	EF	Meyer
-۰/۶۱	۰/۵۷	۰/۳۵	-۰/۱۹	MBE	
۰/۲۵	۰/۵۷	۰/۱۷	۰/۴۱	NRMSE	
۰/۶۱	۰/۵۷	۰/۳۵	۰/۲۳	MAE	
۰/۶۴	۰/۵۸	۰/۳۹	۰/۲۸	RMSE	
۰/۹۰	۰/۹۲	۰/۹۹	۰/۸۴	EF	Trajkovic
۰/۱۲۴	۰/۱۲	۰/۰۴	۰/۲۱	MBE	
۰/۹۳	۰/۹۷	۰/۹۷	۰/۸۹	NRMSE	
۰/۲۸	۰/۱۴	۰/۰۶	۰/۱۸	MAE	
۰/۲۸	۰/۱۴	۰/۰۷	۰/۲	RMSE	
۰/۸۴	۰/۶۸	۰/۸۹	-۲/۸۴	EF	Modified-turc
-۰/۳۶	-۰/۲۷	-۰/۱۸	-۰/۹۶	MBE	
۰/۱۵	۰/۲۹	۰/۱۰۹	۰/۷۴	NRMSE	
۰/۳۶	۰/۲۷	۰/۱۹	۰/۹۶	MAE	
۰/۳۶	۰/۲۹	۰/۲۷	۰/۹۸	RMSE	

ادامه‌ی جدول ۲. ب عملکرد آماری معادله‌های تجربی انتخابی جهت تخمین تبخیر و تعرق فصلی در مقایسه با روش فائو-پنمن-مانتیت در بازه زمانی مورد مطالعه (۱۳۷۴-۱۳۹۶).

فصلی					روش
بهار	بهار	بهار	بهار	بهار	
۰/۸۸	۰/۷۴	۰/۹۳	۰/۹۵	EF	Taylor-Priestley
۰/۳۱	۰/۲۱	-۰/۲۲	-۰/۰۸	MBE	
۰/۱۳	۰/۱۶	۰/۱۱	۰/۰۸	NRMSE	
۰/۳۱	۰/۲۱	۰/۲۲	۰/۰۸	MAE	
۰/۳۲	۰/۲۶	۰/۲۲	۰/۱۱	RMSE	
۰/۸۳	-۰/۱۲	۰/۹۸	۰/۹۷	EF	IRMAK1
-۰/۳۳	-۰/۵۲	۰/۰۹	-۰/۰۸	MBE	
۰/۲۰	۰/۶۹	۰/۰۵۲	۰/۰۷	NRMSE	
۰/۳۳	۰/۵۲	۰/۰۹	۰/۰۸	MAE	

تحلیل حساسیت داده‌های هواشناسی در برآورد تبخیر و تعرق مرجع / ۵۳

RMSE	۰/۰۸	۰/۱۱	۰/۵۵	۰/۳۷
EF	۰/۹۳	۰/۹۸	-۲/۲۴	۰/۶۹
MBE	۰/۱۳	۰/۰۲	-۰/۹۱	-۰/۴۳
NRMSE	۰/۱۲	۰/۰۶۸	۱/۲۹	۰/۳۲
MAE	۰/۱۴	۰/۱۱	۰/۹۱	۰/۴۳
RMSE	۰/۱۴	۰/۱۲	۰/۹۳	۰/۵۰

جدول ۲. عملکرد آماری معادله‌های تجربی انتخابی جهت تخمین تبخیر و تعرق ماهیانه در مقایسه با روش فائو-پنمن-ماتیت در بازه زمانی مورد مطالعه (۱۳۷۴-۱۳۹۶)

ماه	NRMSE						MBE							
	Hargreaves-M4	Trajkovic	Mod-turc	Meyer	Taylor-Priestley	IRMAK 2	IRMAK 1	Hargreaves-M4	Trajkovic	Mod-turc	Meyer	Taylor-Priestley	IRMAK 2	IRMAK 1
فروردین	۰/۰۵۰	۰/۰۵۳	۰/۰۶۰	۰/۱۱۰	۰/۰۲۳	۰/۰۱۹	۰/۰۱۸	۰/۰۳۰۷	-۰/۳۱۴	-۰/۴۷۴	-۰/۷۰۵	۰/۱۸۷	-۰/۱۱۳	-۰/۱۴۱
اردیبهشت	۰/۰۱۶	۰/۰۱۷	۰/۰۲۰	۰/۰۹۰	۰/۰۲۴	۰/۰۴۲	۰/۰۲۴	-۰/۲۶۲	-۰/۲۷۵	-۰/۳۱۷	-۰/۷۷۹	۰/۳۴۰	-۰/۴۱۴	-۰/۳۱۲
خرداد	۰/۰۱۳	۰/۰۱۵	۰/۰۱۳	۰/۰۱۳	۰/۰۲۹	۰/۱۳۰	۰/۰۶۷	-۰/۲۴۲	-۰/۲۵۶	-۰/۲۸۱	-۰/۳۵۴	۰/۳۹۳	-۰/۷۵۶	-۰/۵۴۳
تیر	۰/۰۰۴	۰/۰۰۵	۰/۰۲۹	۰/۰۲۲	۰/۰۲۴	۰/۳۰۰	۰/۱۳۰	-۰/۱۲۲	-۰/۱۳۸	-۰/۳۹۷	۰/۴۸۱	۰/۳۵۰	-۱/۱۴۱	-۰/۷۳۸
مرداد	۰/۰۰۶	۰/۰۰۸	۰/۰۰۹	۰/۰۴۳	۰/۰۱۱	۰/۱۲۰	۰/۰۴۶	-۰/۱۳۹	-۰/۱۵۳	-۰/۲۸۴	۰/۵۳۶	۰/۲۸۹	-۰/۹۳۳	-۰/۵۴۶
شهریور	۰/۰۰۵	۰/۰۰۶	۳/۷۰e-۳	۰/۰۶۸	۵/۵۰e-۷	۰/۱۵۰	۰/۰۲۸	-۰/۱۳۰	-۰/۱۴۲	-۰/۱۳۷	۰/۷۰۰	-۰/۰۰۱	-۰/۶۲۲	-۰/۲۷۴
مهر	۰/۰۰۲	۰/۰۰۳	۸/۰۰e-۵	۰/۰۳۱	۰/۰۱۳	۰/۰۰۶	۰/۰۰۲	-۰/۰۷۹	-۰/۰۸۸	۰/۰۱۵	۰/۵۸۹	-۰/۲۰۲	۰/۱۳۸	۰/۰۹۱
آبان	۰/۰۰۳	۰/۰۰۳	۰/۰۰۴	۰/۰۱۰	۰/۰۲۲	۰/۰۰۱	۰/۰۰۸	-۰/۰۸۰	-۰/۰۸۵	-۰/۰۹۹	۰/۲۸۰	-۰/۲۵۸	۰/۰۶۱	۰/۱۵۱
آذر	۳/۶e-۵	۱/۲۰e-۵	۰/۱۱۰	۰/۰۰۶	۰/۰۳۳	۰/۰۰۷	۰/۰۰۰۷	۰/۰۰۸	۰/۰۰۴	-۰/۴۵۵	۰/۱۹۵	-۰/۱۸۶	۰/۱۳۷	۰/۰۴۸
دی	۰/۰۰۲	۰/۰۰۳	۰/۶۴۰	۰/۰۰۰۴	۰/۰۲۶	۰/۰۱۳	۰/۰۰۶	-۰/۰۵۹	-۰/۰۶۱	-۰/۹۹۵	۰/۰۵۵	-۰/۱۶۵	۰/۱۳۸	-۰/۱۰۶
بهمن	۰/۰۱۶	۰/۰۱۷	۰/۵۲۰	۰/۰۰۷	۰/۰۰۵	۰/۰۱۱	۰/۰۰۴	-۰/۱۸۰	-۰/۱۸۴	-۱/۱۷۲	-۰/۱۹۹	-۰/۰۹۳	۰/۱۵۶	-۰/۰۹۲
اسفند	۰/۰۲۷	۰/۰۲۸	۰/۱۷۶	۰/۰۲۳	۳/۸۰e-۶	۰/۰۰۴	۰/۰۰۲۷	-۰/۲۸۶	-۰/۲۹۲	-۰/۷۱۰	-۰/۴۳۹	-۰/۰۰۳	۰/۱۱۲	-۰/۰۳۰

جدول ۳. عملکرد آماری معادله‌های تجربی انتخابی جهت تخمین تبخیر و تعرق ماهیانه در مقایسه با روش فائو-پنمن-ماتیت در بازه زمانی مورد مطالعه (۱۹۹۵-۲۰۱۷)

ماه	RMSE						EF							
	Hargreaves-M4	Trajkovic	Mod-turc	Meyer	Taylor-Priestley	IRMAK 2	IRMAK 1	Hargreaves-M4	Trajkovic	Mod-turc	Meyer	Taylor-Priestley	IRMAK 2	IRMAK 1
فروردین	۰/۰۹۴	۰/۰۹۹	۰/۲۲۴	۰/۴۹۶	۰/۰۳۵	۰/۰۱۳	۰/۰۰۲	-۰/۶۲	-۰/۶۶	-۲/۴۱	-۲/۵۵	-۰/۰۵	۰/۲۶	۰/۵۲
اردیبهشت	۰/۰۰۷	۰/۰۰۷۵	۰/۱	۰/۶۰۷	۰/۱۱۶	۰/۱۷۲	۰/۰۹۷	۰/۶۳	۰/۶۳	۰/۰۵	۰/۵۸	۰/۷۶	۰/۶۲	۰/۷۱
خرداد	۰/۰۵۸	۰/۰۶۶	۰/۰۷۹	۰/۱۲۵	۰/۱۵۴	۰/۵۷۱	۰/۲۹۵	-۰/۵۱	۰/۵۳	۰/۳۷	-۰/۹۵	۰/۳۶	۰/۴۴	-۰/۰۶
تیر	۰/۰۱۵	۰/۰۱۹	۰/۱۵۸	۰/۲۳۱	۰/۱۲۲	۱/۳۰۵	۰/۵۲۹	-۱/۰۰	-۱/۰۰	۰/۰۳	-۱	-۰/۱۰	-۳/۲۸	-۲/۰۶
مرداد	۰/۰۱۹	۰/۰۲۴	۰/۰۸۱	۰/۲۸۷	۰/۰۸۴	۰/۹۲۷	۰/۲۹۸	۰/۹۹	۰/۹۹	۰/۹۹	۰/۹۸	۰/۹۹	۰/۹۷	۰/۹۸
شهریور	۰/۰۱۷	۰/۰۲	۰/۰۱۹	۰/۴۹۱	۱/۹۵e-۶	۰/۳۸۷	۰/۰۷۵	۰/۵۵	۰/۵۵	۰/۲۷	۰/۳۵	۰/۵۸	۰/۲۴	۰/۴۹
مهر	۰/۰۰۶	۰/۰۰۸	۰/۰۰۰۲۳	۰/۳۴۶	۰/۰۴۱	۰/۰۱۹	۰/۰۰۸	۰/۵۶	۰/۵۵	۰/۲۳	۰/۵۰	۰/۴۴	۰/۴۶	۰/۵۶
آبان	۰/۰۰۶	۰/۰۰۷	۰/۰۱	۰/۰۷۹	۰/۰۶۷	۰/۰۰۴	۰/۰۲۳	۰/۶۱	۰/۶۱	-۰/۱۲	۰/۶۴	۰/۵۲	۰/۵۲	۰/۵۹
آذر	۵/۷۳e-۵	۱/۹۰e-۵	۰/۲۰۷	۰/۰۳۸	۰/۰۳۴	۰/۰۱۹	۰/۰۰۲	۰/۲۴	۰/۲۴	-۱/۹۲	۰/۳۸	-۰/۰۹	۰/۰۳	۰/۰۶
دی	۰/۰۰۳	۰/۰۰۴	۰/۹۹	۰/۰۰۳	۰/۰۲۷	۰/۰۱۹	۰/۰۱۱	۰/۴۸	۰/۴۸	-۳/۰۰	۰/۷۱	۰/۲۵	۰/۳۱	۰/۲۳
بهمن	۰/۰۳۲	۰/۰۳۴	۱/۳۷۴	۰/۰۴	۰/۰۰۹	۰/۰۲۴	۰/۰۰۹	۰/۸۴	۰/۸۴	۰/۳۲	۰/۹۵	۰/۷۹	۰/۸۳	۰/۸۴
اسفند	۰/۰۸۲	۰/۰۸۵	۰/۵۰۴	۰/۱۹۳	۱/۹۰e-۵	۰/۰۱۳	۰/۰۰۱	۰/۵۸	۰/۵۷	-۲/۰۳	۰/۷۹	۰/۶۵	۰/۵۲	۰/۶۰

جدول ۳. میانگین پارامترهای آماری داده‌های هواشناسی و تبخیر و تعرق تخمین زده شده توسط معادله فائو-پنمن-مانتیت (ET₀) در ایستگاه‌های هواشناسی شهرکرد، بروجن، فارسان و فرخشهر در طی سال‌های ۱۳۹۶-۱۳۷۴.

دمای مینیمم (°C)	دمای ماکزیمم (°C)	دمای میانگین (°C)	تابش برون زمینی، Ra (mm d ⁻¹)	سرعت باد در ارتفاع ۲متری در سطح زمین (m s ⁻¹)	تابش خالص در سطح پوشش گیاهی R _n (MJm ⁻² d ⁻¹)	پنمن-مانتیت (ET ₀) (mm d ⁻¹)
۳۲/۴۰	-۱۰/۴۰	-۲۰/۷۰	۱۸/۳۰	۰/۰۰	۲/۸۲	۰/۲۳
۳۳/۸۰	۳۹/۰۰	۳۰/۹۰	۴۱/۴۳	۱۵/۷۱	۱۸/۱۸	۹/۶۱
۳/۴۹	۲۰/۳۶	۱۱/۹۲	۳۰/۹۶	۴/۷۵	۹/۵۵	۳/۶۹
۸/۰۰	۱۰/۱۱	۸/۷۵	۸/۳۶	۳/۸۹	۴/۴۲	۲/۱۳

محاسبه شده و مقدار حساسیت مدل نسبت به متغیر ورودی محاسبه می‌شود. هر چه مقدار حساسیت برای یک متغیر ورودی بیشتر باشد، اهمیت آن در مدل‌سازی بیشتر بوده و تاثیر بیشتری بر خروجی و یا متغیر هدف دارد. در روش استات‌سافت مقدار حساسیت برای هر ویژگی ورودی، از تقسیم نمودن خطای شبکه در غیاب ویژگی ورودی مورد نظر بر خطای شبکه در حضور همه متغیرهای ورودی بدست می‌آید. بدین معنی که ابتدا مدل با تمامی متغیرها ایجاد و پس از رسیدن به بهترین عملکرد با کمترین خطا، مقدار شاخص خطا (*MSE*) محاسبه شده و در نظر گرفته می‌شود. سپس یک متغیر ورودی معین حذف شده و مدل دوباره با سایر ویژگی‌های ورودی ایجاد می‌شود. پس از رسیدن به مناسب‌ترین ساختار و عملکرد در مدل، مقدار شاخص خطا (*MSE*) در این حالت نیز تعیین می‌شود. از نسبت شاخص خطا در حالت دوم (حذف یک ویژگی ورودی) به حالت اول (حضور تمام ورودی‌ها)، مقدار حساسیت خروجی نسبت به متغیر ورودی مورد نظر محاسبه می‌شود. در روش تغییر در ضریب تبیین برای بررسی عملکرد شبکه، از شاخص ضریب تبیین استفاده می‌شود. مزیت روش تغییر در ضریب تبیین آن است که به راحتی قابل محاسبه می‌باشد و نسبت به روش هیل خیلی ساده‌تر است. هرچه مقدار اهمیت محاسبه شده برای متغیر

از آنجایی که از بین تمامی پارامترهای ذکر شده در بالا برخی از پارامترها می‌تواند تاثیر بیشتری بر مقدار تبخیر و تعرق داشته باشد و همچنین به منظور صرفه‌جویی در وقت و هزینه و همچنین بدلیل عدم دسترسی به تمامی داده‌های هواشناسی برای برآورد پارامتر تبخیر و تعرق، مدل‌سازی شبکه عصبی مصنوعی و (*ANFIS*) و موجک-عصبی-فازی با ترکیبات مختلف داده‌های ورودی هواشناسی موثری که در بالا به آن‌ها اشاره شد، بر (*ET₀*) انجام شد و نتایج آن با نتایج حاصل از برآورد تبخیر و تعرق معادله استاندارد فائو-پنمن-مانتیت به منظور دستیابی و انتخاب بهترین مدل مقایسه شد.


آنالیز حساسیت

به منظور بررسی دقیق‌تر پارامترهای اثرگذار در برآورد مقدار دقیق‌تر تبخیر و تعرق مرجع با استفاده از شبکه عصبی مصنوعی، (*ANFIS*) و موجک-عصبی-فازی آنالیز حساسیت با سه روش هیل (*Hill*) (با آنالیز تجزیه به مولفه-های اصلی (*PCA*)^۱ و بدون تبدیل داده‌ها)، تغییر در ضریب تبیین (*R-Square, R²*) و استات‌سافت (*Statsoft*) انجام شد.

در روش هیل، هر یک از متغیرها یا ویژگی‌های ورودی مقداری تغییر داده می‌شوند و تاثیر آن‌ها بر خروجی مدل

¹ Principle Component Analysis

شده متناظر (ET_0)، به عنوان خروجی مدل شبکه عصبی مصنوعی در نظر گرفته شد. انتخاب تعداد نرون در لایه پنهان بر مبنای آموزش شبکه با تعداد نرون‌های مختلف تا رسیدن به کمترین مقدار خطا انجام شد. بر این اساس مدل-سازی و تغییر الگوریتم‌های آموزش با تعداد ۳۰ نرون در لایه پنهان الگوریتم آموزشی لوببرگ-مارکوات تا رسیدن به کمترین مقدار خطا و بیشترین ضریب تبیین، انجام شد.



شکل ۲. ساختار یک شبکه عصبی مصنوعی

موجک - عصبی - فازی

شبکه‌های موجک-عصبی-فازی ترکیبی از سیستمی مبتنی بر شبکه‌های عصبی مصنوعی و فازی-عصبی و موجک می‌باشند به طوریکه این شبکه‌ها با استفاده از قابلیت یادگیری شبکه‌های عصبی مصنوعی، رابطه ورودی-خروجی که از تئوری موجک تبعیت می‌کند را به دست آورده و با استفاده از استدلال منطقی فازی نتایج را ارائه می‌کند. در این شبکه‌ها سیگنال‌های ورودی و خروجی مطابق با یکی از توابع موجک مادر شکسته شده و خصوصیات پارامترها به صورت ضرائب جزئی‌تر به شبکه‌های فازی-عصبی معرفی می‌گردد. سپس این پارامترها در مدل‌های فازی-عصبی مطابق با الگوریتم آموزشی شبکه‌های عصبی مانند الگوریتم کاهش شیب نزولی آموزش دیده و نتایج به صورت فازی ارائه می‌گردد. بعد از ارائه ضرایب پیش‌بینی شده در مدل‌های فازی-

ورودی مورد نظر بیشتر باشد، اهمیت آن متغیر در خروجی مدل بیشتر است و تاثیر چشمگیرتری بر متغیر هدف دارد. در این مطالعه قبل از ایجاد و آموزش شبکه عصبی، با شناسایی و حذف ورودی‌های با اهمیت کمتر، شبکه عصبی کارآمدتری طراحی گردید. زیرا حذف ورودی‌های غیر ضروری، ابعاد شبکه را کاهش داده و در نتیجه میزان پیچیدگی شبکه و زمان آموزش آن نیز کاهش می‌دهد. در نهایت توانایی مدل شبکه عصبی و ($ANFIS$) و موجک-عصبی-فازی به منظور برآورد مقادیر تبخیر و تعرق روزانه با استفاده از تعداد محدود پارامترهای ورودی حاصل از نتایج آنالیز حساسیت مورد بررسی، به منظور دستیابی به نتیجه و تخمین دقیق‌تر مورد ارزیابی قرار گرفت.

شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی جهت مدل‌سازی به انواع مختلف تقسیم‌بندی می‌شوند که در این تحقیق از شبکه عصبی پرسپترون چند لایه (MLP) استفاده شده است. در شکل ۲ نمونه‌ای از ساختار شبکه عصبی چند لایه نمایش داده شده است. اکثر شبکه‌های عصبی یک لایه مخفی دارند. سیستم شبکه عصبی می‌تواند با آموزش و با روش تکرارشونده، وزن‌ها را به گونه‌ای تنظیم کند که شبکه توان باز تولید جفت‌های ورودی و خروجی را داشته باشد. تعداد نورون‌ها در لایه ورودی با تعداد پارامترهای ورودی برابر است و تعداد نورون‌ها در لایه خروجی با تعداد پارامترهای مجهول برابر می‌باشد (Hornik et al., 1989). ۷۰ درصد داده‌های ورودی برای آموزش و ۳۰ درصد آن‌ها جهت آزمون و صحت سنجی استفاده شد.

برای آموزش شبکه عصبی مصنوعی پرسپترون چند لایه از الگوریتم پس انتشار خطا، استفاده گردید. در این تحقیق پارامترهای هواشناسی موثر (T_{max} , T_{min} , T_{mean} , R_s , R_n و U_2) (بر طبق آنالیز حساسیت و هم بستگی بین متغیرهای هواشناسی با ET_0) تحت سناریوهای مختلف به عنوان ورودی مدل شبکه عصبی مصنوعی و مقادیر محاسبه

لایه دوم بعنوان یک تابع عضویت عمل نموده و از این لایه به عنوان لایه فازی سازی نام برده می شود. در لایه سوم هر گره بیانگر یک قانون فازی است. عملگر "و" (*And*) به منظور محاسبه سیگنال‌های خروجی استفاده می شود. لایه چهارم متغیرهای x_1, x_2, \dots, x_n را بعنوان سیگنال‌های ورودی که در برگزیده ام شبکه عصبی-موجک بوده و هر شبکه نتیجه یک قانون فازی است را در بر می گیرد. در لایه پنجم سیگنال‌های خروجی لایه سوم در سیگنال‌های خروجی لایه چهارم ضرب می شوند. در لایه ششم دو نرون به ترتیب بعنوان عملگر جمع سیگنال‌های خروجی لایه پنجم و سوم عمل می کنند. در لایه هفتم نرون خروجی فاکتوری را محاسبه می کند که بیانگر سهم هر یک از شبکه عصبی-موجک در خروجی نهایی شبکه موجک-عصبی-فازی است.


اساس کار شبکه‌های موجک-عصبی-فازی بر پایه شناخت خصوصیات جزئی هر سیگنال ورودی می باشد. زمانی که تعداد داده‌ها به اندازه کافی موجود باشد این مدل‌ها قادرند انواع مختلفی از الگوها را شبیه‌سازی نمایند. مدل موجک-عصبی-فازی بر اساس توابع مختلف موجکی و همچنین الگوریتم‌های مختلف، آموزش می بیند در این تحقیق از الگوریتم آموزشی لورنبرگ مارکوات در مدل در شبکه‌های عصبی موجکی و الگوریتم پس انتشار خطا فازی-عصبی موجکی استفاده شده است و تابع موجک مادر دابشیز در سطح سه، به عنوان تابع اساسی موجکی به کار رفته است.

مدل استنتاج تطبیقی فازی-عصبی (ANFIS)

سیستم (ANFIS) نوعی شبکه تطبیقی چند لایه، متشکل از عناصر اصلی و توابع سیستم‌های منطق فازی است که توسط یانگ (۱۹۹۳) بسط داده شد. این مدل همانند مدل فازی از دانش تجربی بهره گرفته و نیز همانند مدل شبکه عصبی می تواند آموزش ببیند. در مجموع سیستم (ANFIS) متشکل از ساختاری ۵ لایه با تعدادی متغیر ورودی است

عصبی، مطابق با عملیات معکوس موجکی سیگنال‌های اصلی پیش‌بینی شده (خروجی‌ها) تولید می گردد.

از سیستم‌های فازی (Takagi-Sugeno-Kang) TSK به منظور توصیف مدل شبکه موجک-عصبی-فازی استفاده می شود. در یک مدل فازی (TSK) فاصله دامنه هر متغیر ورودی به تعدادی ناحیه فازی تقسیم‌بندی می شود و هر ناحیه نشان‌دهنده‌ی یک تابع عضویت در بخش قوانین اگر-سپس (*if-then*) از قوانین فازی است. یک مقدار ثابت و یا یک تابع خطی می تواند در قسمت انتهای شرط گذاشته شده (*then*) به کار رود. در اکثر مدل‌های فازی، یک تابع تخمین‌گر شامل مجموعه‌ای از مقادیر ورودی و یک عبارت ثابت است. این سیستم‌ها قابلیت تنظیم نداشته و برای همگرا شدن به زمان نیاز دارند. به هنگام مدل‌سازی فرآیندهای غیر خطی پیچیده، در نظر گرفتن بخشی از این سیستم‌های فازی بیشتر آشکار می شود. به این منظور از ترکیب شبکه عصبی همراه با مدل‌های فازی TSK استفاده شد، این امر می تواند منجر به دقت بالاتر و استفاده کمتری از قوانین در مقایسه با سایر مدل‌های فازی گردد. برای درک بهتر، ساختار مدل موجک-عصبی-فازی با یک خروجی در این جا ارائه شده است (شکل ۳).



شکل ۳. ساختار پیشنهادی شبکه موجک-عصبی-فازی

این ساختار شامل ۷ لایه است لایه اول سیگنال‌های ورودی را به لایه دوم منتقل می کند. گره‌های موجود در

ارزیابی مدل‌ها

در این مطالعه روش استاندارد اندازه‌گیری مقدار تبخیر و تعرق، معادله فائو-پنمن-مانتیت می‌باشد و عملکرد و کارایی شبکه عصبی مصنوعی و (ANFIS) و موجک-عصبی-فازی در برآورد مقدار تبخیر و تعرق در مقایسه با معادله فائو-پنمن-مانتیت مورد ارزیابی قرار گرفت.

مدل فائو-پنمن-مانتیت

این معادله به عنوان معتبرترین روش جهت تخمین تبخیر و تعرق مرجع می‌باشد و مقدار آن از رابطه زیر محاسبه می‌گردد:

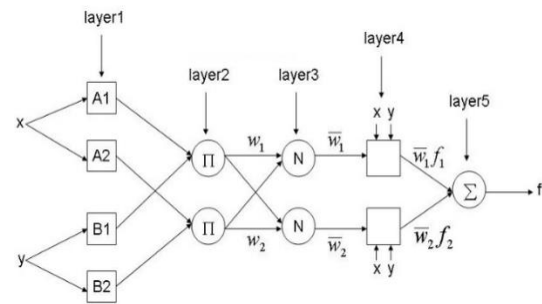
$$ET_0 = \frac{0.408 \times \Delta (R_n - G) + \gamma [900 / (T + 273)] U_2 (e_a - e_d)}{\Delta + \gamma (1 + 0.34 U_2)}$$

در این معادله (ET_0) مقدار تبخیر و تعرق گیاه مرجع (R_n)، ($mm\ d^{-1}$)، تابش خالص در سطح پوشش گیاهی ($MJm^{-2}d^{-1}$)، متوسط دمای هوا در ارتفاع ۲ متری از سطح زمین ($^{\circ}C$)، (U_2): سرعت باد در ارتفاع ۲ متری از سطح زمین (m/s): $e_a - e_d$: کمبود فشار بخار در ارتفاع ۲ متری از سطح زمین (kPa)، (Δ): شیب منحنی فشار بخار ($kPa\ ^{\circ}C^{-1}$)، γ : ضریب رطوبتی ($kPa\ ^{\circ}C^{-1}$) و (G): شار گرما به داخل خاک ($MJm^{-2}d^{-1}$)، (R_a): تابش برون زمینی ($mm\ d^{-1}$) و (R_s): تشعشع خورشیدی رسیده به زمین (موج کوتاه) ($MJm^{-2}d^{-1}$) می‌باشد. در این پژوهش از این معادله به عنوان شاخصی برای مقایسه با معادله‌های تجربی و مدل‌های برآورد تبخیر و تعرق استفاده شد.

پارامترهای خطا

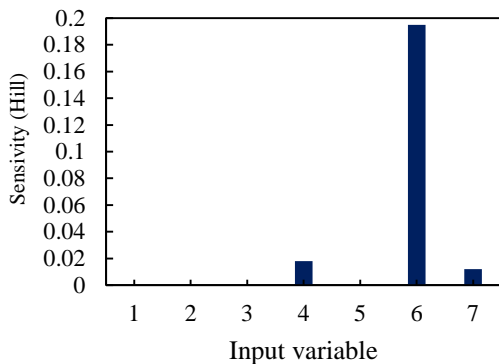
به منظور ارزیابی دقت روش‌های تجربی انتخابی برای تعیین پارامترهای مناسب در برآورد تبخیر و تعرق از معیارهای آماری ریشه میانگین مربع خطا ($RMSE$)، جذر میانگین مربع خطای نرمال شده ($NRMSE$)، میانگین خطای انحراف (MBE)، میانگین قدرمطلق خطا (MAE)، فاکتور کارایی مدل (EF) و R^2 استفاده شد. همچنین به منظور

که هر ورودی دو یا چند تابع عضویت دارد. در شکل ۴ نمایشی از معماری شبکه (ANFIS) با دو ورودی، یک خروجی و دو قانون آمده است. در لایه‌ی اول (لایه ورودی) میزان تعلق هر ورودی به بازه‌های مختلف فازی توسط کاربر مشخص می‌شود. با ضرب مقادیر ورودی به هر گره در یکدیگر، وزن قانون‌ها در لایه دوم به دست می‌آید. در لایه سوم وزن (w_i) محاسبه می‌شود. لایه چهارم لایه قوانین نسبی (w_i) است که از اجرای عملیات بر روی سیگنال‌های ورودی به این لایه حاصل می‌شود. لایه‌ی آخر خروجی شبکه است (f) که هدف آن حداقل نمودن اختلاف خروجی شبکه و خروجی واقعی است (Kisi et al., 2006). روش آموزش اصلی در این سیستم، روش پس انتشار خطا است که در ترکیب با کمترین مربعات خطا، روش ترکیبی هیبرید به دست می‌آید. در هر دور آموزش، هنگام حرکت رو به جلو، خروجی‌های گره‌ها به صورت عادی تا لایه چهارم محاسبه می‌شوند و سپس پارامترهای نتیجه به روش کمترین مجموع مربعات خطا محاسبه می‌شوند. در ادامه پس از محاسبه‌ی خطا، در بازگشت با استفاده از الگوریتم شیب نزولی خطا، مقدار خطا به سمت ورودی‌ها پخش و پارامترها تصحیح می‌شوند (Riahi-Modavar et al., 2008). در (ANFIS) قوانین ثابت می‌باشند و آنچه بهینه‌سازی می‌شود، شکل توابع عضویت است. ساختار مناسب (ANFIS) متناسب با داده‌های ورودی، نوع توابع عضویت ورودی و خروجی، قوانین و تعداد تابع عضویت انتخاب می‌شود.




شکل ۴. معماری شبکه (ANFIS) با دو ورودی، یک خروجی و دو قانون

که حاکی از اهمیت بیشتر آن در مدل سازی و تاثیر آن بر متغیر خروجی یا هدف دارد. این در حالی است که میزان حساسیت دو متغیر R_s و R_a کمتر از متغیر R_n بوده و از لحاظ اهمیت در جایگاه پایین تری قرار می گیرند. سایر متغیرهای ورودی مورد بررسی نیز تاثیری بر متغیر هدف یا خروجی نداشته و میزان حساسیت آن ها با توجه به شکل صفر بدست آمده است.



شکل ۵. الف آنالیز حساسیت به روش هیل بدون تبدیل داده ها، در این جا متغیر ورودی یک بیانگر دمای مینیمم، متغیر دوم: دمای ماکزیمم، متغیر سوم: دمای میانگین، متغیر چهارم: تابش برون زمینی (R_s)، متغیر پنجم: سرعت باد در ارتفاع ۲ متری از سطح زمین، متغیر ششم: تابش خالص در سطح پوشش گیاهی (R_n) و متغیر هفتم تشعشع خورشیدی رسیده به زمین (R_e) است.



شکل ۵. ب آنالیز حساسیت به روش هیل با استفاده از آنالیز تجزیه به مولفه های اصلی (PCA)، در این جا متغیر ورودی یک بیانگر دمای مینیمم، متغیر دوم: دمای ماکزیمم، متغیر سوم: دمای میانگین، متغیر چهارم: تابش برون زمینی (R_s)، متغیر پنجم: سرعت باد در ارتفاع ۲ متری از سطح زمین، متغیر ششم: تابش خالص در سطح پوشش گیاهی (R_n) و متغیر هفتم تشعشع خورشیدی رسیده به زمین (R_e) است.

ارزیابی شبکه عصبی مصنوعی، انفیس و موجک - عصبی - فازی، تجزیه و تحلیل مدل ها از میانگین مربع خطا (MSE) میانگین خطای انحراف (MBE) و R^2 استفاده شد. روابط مذکور به ترتیب به صورت زیر می باشند:

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

$$NRMSE = \frac{RMSE}{X_{max} - X_{min}} \quad (3)$$

$$MBE = \frac{\sum_{i=1}^n (P_i - Q_i)}{n} \quad (4)$$

$$MAE = \frac{\sum_{i=1}^n |P_i - Q_i|}{n} \quad (5)$$


$$EF = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (6)$$

در این روابط: P_i : تخییر و تعرق تخمین زده شده توسط مدل های مختلف، O_i : تخییر و تعرق تخمین زده شده واقعی (معادله فائو - پنمن - مانیتث)، X_{min} و X_{max} به ترتیب ماکزیمم و مینیمم اعداد مورد استفاده و n تعداد داده ها می باشد. هرچه $RMSE$ ، MAE و $NRMSE$ به صفر نزدیک تر و مقادیر R^2 به ۱ نزدیک تر باشد، عملکرد شبیه سازی مدل بهتر است. همچنین مقدار EF از منفی بینهایت برای بدترین برآورد تا یک برای تطابق کامل تغییر کرده و کفایت و کارایی مدل را نشان می دهد.

نتایج و بحث

تحلیل حساسیت

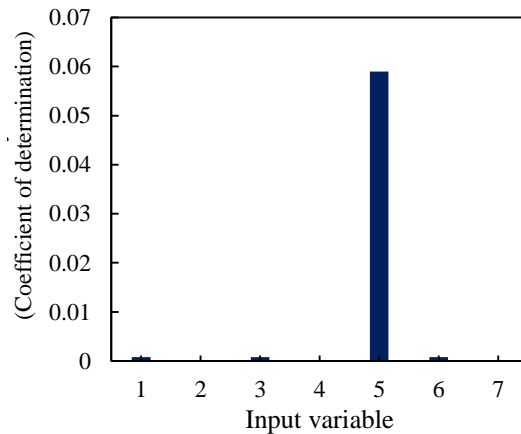
نتایج آنالیز حساسیت پارامترهای هواشناسی مورد استفاده، با استفاده از روش هیل بدون تبدیل داده ها و به کمک تجزیه به مولفه های اصلی در شکل ۵ الف و ب آورده شده است. نتایج شکل ۵- الف نشان می دهد که در بین هفت پارامتر ورودی مورد بررسی، تشعشع خالص خورشیدی (R_n) دارای حساسیت بیشتری نسبت به سایر متغیرهای ورودی بوده،



شکل ۵. ب نتایج بررسی میزان آنالیز حساسیت متغیرهای ورودی به روش هیل با استفاده از آنالیز تجزیه به مولفه‌های اصلی (PCA) را نشان می‌دهد. در این روش به ترتیب متغیرهای ورودی تابش برون زمینی (R_a)، تشعشع خورشیدی رسیده به زمین (R_s) و تابش خالص در سطح پوشش گیاهی (R_n) اثر گذارترین متغیرهای ورودی بر پارامتر خروجی یعنی میزان تبخیر و تعرق بوده‌اند.

شکل ۶. ب آنالیز حساسیت با روش استات‌سافت؛ در این جا متغیر ورودی یک بیانگر دمای مینیمم، متغیر دوم: دمای ماکزیمم، متغیر سوم: دمای میانگین، متغیر چهارم: تابش برون زمینی (R_a)، متغیر پنجم: سرعت باد در ارتفاع ۲ متری از سطح زمین، متغیر ششم: تابش خالص در سطح پوشش گیاهی (R_n) و متغیر هفتم تشعشع خورشیدی رسیده به زمین (R_s) است.

بررسی میزان حساسیت متغیرهای ورودی با استفاده از روش تغییر در ضریب تبیین در شکل ۶ الف آورده شده است. نتایج آنالیز حساسیت با استفاده از این روش نشان داد که در بین متغیرهای ورودی، تنها متغیر سرعت باد در ارتفاع دو متری از سطح زمین بر متغیر خروجی (متغیر هدف) اثرگذار بوده است. نتایج آنالیز حساسیت با روش استات‌سافت (شکل ۶-ب) نیز حاکی از آن است که مقدار ضریب حساسیت برای متغیرهای دمای ماکزیمم، R_n ، R_a ، R_s ، T_{mean} ، U_2 بالاتر از یک بوده و این متغیرها بیشترین تاثیر را در عملکرد مدل و خروجی آن دارند.



شکل ۶ الف آنالیز حساسیت متغیرهای ورودی با استفاده از روش ضریب تبیین؛ در این جا متغیر ورودی یک بیانگر دمای مینیمم، متغیر دوم: دمای ماکزیمم، متغیر سوم: دمای میانگین، متغیر چهارم: تابش برون زمینی (R_a)، متغیر پنجم: سرعت باد در ارتفاع ۲ متری از سطح زمین، متغیر ششم: تابش خالص در سطح پوشش گیاهی (R_n) و متغیر هفتم تشعشع خورشیدی رسیده به زمین (R_s) است.



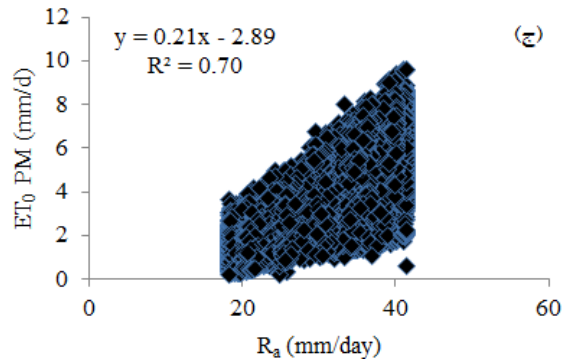



مقادیر آماره‌ی خطا (RMSE) و ضریب تبیین روش‌های مختلف آنالیز حساسیت در جدول ۴ آورده شده است. نتایج بدست آمده حاکی از دقت بالای این روش‌ها می‌باشد. مقایسه بین نتایج حاصل از آنالیز حساسیت انجام شده با سه روش ارائه شده حاکی از آن است که بررسی اهمیت پارامترهای ورودی با استفاده از دو روش استات‌سافت و هیل نشان دهنده اهمیت سه پارامتر ورودی R_a ، R_n و R_s می‌باشد. روش ضریب تبیین دارای عملکرد متفاوتی بوده و تنها پارامتر U_2 را به عنوان حساس‌ترین و موثرترین پارامتر ورودی بر مقدار تبخیر و تعرق عنوان می‌کند.


جدول ۴. مقادیر آماره خطای RMSE و R^2 برای روش‌های

مختلف آنالیز حساسیت		
R^2	RMSE	نام روش
۰/۹۹۹۸	۰/۰۲۰۹	روش هیل بدون تبدیل داده‌ها
۰/۹۱۹۷	۰/۸۳۹	روش هیل با استفاده از آنالیز تجزیه به مولفه‌های اصلی (PCA)
۰/۹۹۹۹	۰/۰۰۹	روش ضریب تبیین
۰/۹۰۲۵	۱/۰۴	روش استات‌سافت

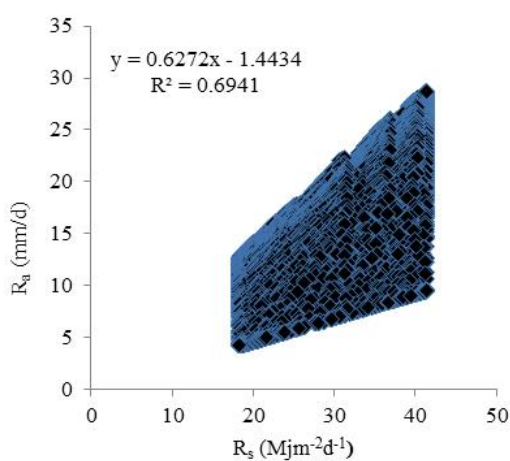



نسبتاً خوبی برقرار است ($R^2=0/60$). بنابراین به نظر می‌رسد که در صورت استفاده از پارامترهای دما، R_a ، R_n و R_s به عنوان پارامترهای ورودی مدل، مقدار ET_0 تخمین زده شده از دقت خوبی برخوردار است. کارایی مدل را می‌توان با همبستگی بین متغیر R_s با سایر متغیرهای موثر بر تبخیر و تعرق (طبق آنالیز حساسیت) را نیز مورد بررسی قرار داد (شکل ۷).


به منظور بررسی رابطه بین هر یک از متغیرهای ورودی با مقدار تبخیر و تعرق مرجع همبستگی آن‌ها نیز مورد بررسی قرار گرفت. شکل ۷ (الف-ر) همبستگی بین پارامترهای هواشناسی را با ET_0 نشان می‌دهد. روند تغییرات پارامترهای دمای میانگین، R_n ، R_s و R_a با ET_0 خطی بوده ($0/70 < R^2 < 0/78$) و ضرایب معادله خط آن‌ها به ترتیب برابر با $0/77$ ، $0/78$ ، $0/71$ و $0/70$ می‌باشد. هر چند که بین ET_0 با دمای مینیمم و ماکزیمم نیز همبستگی





شکل ۷. همبستگی پارامترهای هواشناسی با مقادیر تبخیر و تعرق (فانو- پنمن- مانیتث) $(ET_0 PM)$ بر حسب میلی‌متر بر روز. (الف): دمای مینیمم-تبخیر و تعرق، (ب): دمای میانگین-تبخیر و تعرق، (ج): تابش برون زمینی-تبخیر و تعرق، (د): تابش خالص در سطح پوشش گیاهی -تبخیر و تعرق، (ه): تشعشع خورشیدی-تبخیر و تعرق، (و): سرعت باد در ارتفاع ۲ متری-تبخیر و تعرق و (ز): دمای ماکزیمم-تبخیر و تعرق





ادامه شکل ۷. همبستگی بین پارامترهای مختلف هواشناسی

دمای مینیمم، ماکزیمم و دمای میانگین تا رسیدن به کمترین میزان خطا انجام شد. در مراحل بعدی مدل سازی با تعداد پارامتر ورودی کمتر یعنی مدل سازی با ۳ و ۴ پارامتر ورودی تا رسیدن به کمترین مقدار خطا با تغییر نوع الگوریتم های آموزشی، تعداد لایه پنهان، تعداد نرون های لایه پنهان و تابع انتقال تا رسیدن به کمترین میزان خطا (MSE) انجام شد. مقادیر ضریب تبیین و میانگین مربعات خطا برای هر مجموعه ترکیبی از داده های مورد استفاده برای دو مدل شبکه عصبی و انفیس در جدول ۶ آورده شده است. نتایج مدل سازی انجام شده با شبکه عصبی حاکی از آن است که دامنه ی تغییرات میانگین مربعات خطا بین ۰/۰۰۰۸ تا ۰/۵۳ بوده و کمترین مقادیر آن به ترتیب مربوط با ۷ پارامتر ورودی هواشناسی و ۴ پارامتر ورودی هواشناسی U_2, R_a, T_{max} و T_{mean} می باشد. در حالی که برای انفیس دامنه تغییرات این ویژگی بین ۰/۰۰۴۷ تا ۰/۵۵ بوده و مجدداً مشابه با شبکه عصبی بیشترین مقدار ضریب تبیین و کمترین مقدار خطا به ترتیب مربوط به ۷ پارامتر ورودی هواشناسی و ۴ پارامتر ورودی هواشناسی U_2, R_a, T_{mean} و T_{max} می باشد. بنابراین می توان به جای استفاده از تمامی پارامترهای ورودی (۷ پارامتر) از ۴ پارامتر ورودی U_2, R_a, T_{max} و T_{mean} برای برآورد دقیق مقدار تبخیر و تعرق استفاده نمود. به نظر می رسد بین نتایج شبکه عصبی و انفیس تفاوتی وجود ندارد و می توان برای برآورد مقدار تبخیر و تعرق از آن ها استفاده نمود.

همان طور که در شکل ۷ نشان داده شده است، پارامترهای R_n, R_s, R_a و T در درجه دوم پارامتر سرعت باد در ارتفاع ۲ متری از سطح زمین بیشترین تاثیر را بر روی تخمین مقدار تبخیر و تعرق دارند. براساس نتایج حاصل از همبستگی بین تمامی متغیرهای ورودی با تبخیر و تعرق محاسبه شده با معادله فائو-پنمن-ماتیت (شکل ۷) و همچنین براساس نتایج آنالیز تحلیل حساسیت تمامی متغیرهای ورودی مورد استفاده در معادلات تجربی مورد مقایسه با معادله فائو-پنمن ماتیت که پیش از این به آن ها اشاره شده بود، مدل سازی موجک-عصبی-فازی، شبکه عصبی مصنوعی و ($ANFIS$) با ترکیب های مختلف پارامترهای ورودی ذکر شده انجام شد. ترکیب های انتخاب شده در جدول ۵ ارائه شده است.

جدول ۵. نام و تعداد پارامترهای ورودی مورد استفاده در مدل سازی

تعداد	نام
۱	۷ پارامتر ورودی $T_{max}, T_{min}, R_n, R_s, R_a, U_2$ و T_{mean}
۲	۴ پارامتر ورودی T_{max} و T_{min}, R_n, R_s
۳	۴ پارامتر ورودی R_n, R_s, R_a, T_{mean}
۴	۴ پارامتر ورودی $T_{max}, T_{min}, R_a, U_2$
۵	۳ پارامتر ورودی T_{max} و T_{min}, R_s
۶	۳ پارامتر ورودی T_{max} و R_a, R_s

ابتدا مدل سازی با تمامی هفت پارامتر ورودی یعنی سرعت باد در ارتفاع ۲ متری از سطح زمین، R_n, R_s, R_a

عصبی داشته است (R^2 بالاتر). برای نمونه برخی از نمودارهای پراکنش مقادیر متغیر هدف (داده‌های تبخیر و تعرق اندازه‌گیری شده) و مقادیر متغیر خروجی حاصل از شبکه موجک-عصبی-فازی برای برخی از موجک‌های مورد استفاده در مدل‌سازی در شکل ۸ آورده شده است. براساس آماره MBE، کمترین خطا با روش شبکه عصبی متعلق به ۷ پارامتر ورودی است (۰/۰۰۳). بررسی مقادیر MBE بدست آمده در بین ترکیب‌های مختلف مدل‌سازی شده با شبکه عصبی حاکی از آن است که بین مقادیر این آماره خطا برای تمامی ترکیب‌های سه و چهار پارامتری به استثناء ترکیب R_a ، U_2 ، T_{mean} و T_{max} تفاوتی با یکدیگر وجود ندارد. برای ترکیب‌های ۷ و ۴ پارامتر ورودی R_a ، U_2 ، T_{mean} و T_{max} ، در بین موجک‌های مختلف کمترین مقدار MBE برای موجک *coif1* بدست آمده است.

شکل‌های ۹ و ۱۰ به ترتیب نشان‌دهنده نمودارهای پراکندگی مقادیر تبخیر و تعرق روزانه محاسبه شده با معادله فائو-پنمن-مانتیث ($ET_0 PM$) و مقادیر برآورد شده از مدل‌های شبکه عصبی ($ET_0 ANN$) و انفیس ($ET_0 ANFIS$) با حداقل تعداد پارامتر هواشناسی با ساختارهای مختلف ذکر شده را نشان می‌دهد. نتایج شبکه عصبی می‌تواند به شدت تحت تاثیر تعداد پارامترهای ورودی باشد که این مطلب خود بر روی مقدار خطا و دقت شبکه اثرگذار است (Laaboudi و Antopoulos and Antopoulos, 2017). با توجه به شکل‌های ۹ و ۱۰، ترکیب همه پارامترهای ورودی منجر به عملکرد بهتر مدل در برآورد مقدار تبخیر و تعرق می‌شود. بیشترین مقدار ضریب همبستگی بدست آمده مربوط به ساختارهای ۷ و ۴ پارامتر ورودی (T_{max} و T_{mean} ، U_2 ، R_a) بوده ($R^2=0/99$) و این نتیجه با نتایج Benzaghta و همکاران (۲۰۱۲)؛ Sammen (۲۰۱۳) و Antopoulos (۲۰۱۷) مطابقت دارد (Antopoulos and Antopoulos, 2017; Benzaghta et al., 2012 and Sammen, 2013).

نتایج مدل‌سازی با استفاده از شبکه عصبی و موجک-عصبی-فازی و انفیس برای ۶ ترکیب ورودی پارامترهای مختلف (جدول ۵) نیز هم‌چنین در جدول ۶ آورده شده است. نتایج مدل‌سازی با شبکه عصبی و انفیس نشان می‌دهد که کاربرد تمامی ۶ ترکیب مختلف پارامترهای ورودی منجر به نتایجی با دقت بالا (R^2 بالا، MBE و MSE پایین) می‌شود. نتایج هم‌چنین نشان داد که بیشترین مقدار ضریب تبیین و کمترین مقدار خطا در بین موجک‌های مختلف مورد استفاده در مدل موجک-عصبی-فازی به ترتیب برای ترکیب‌های ۷ و ۳ پارامتر ورودی (T_{max} ، T_{min} ، R_s) بدست آمده است.

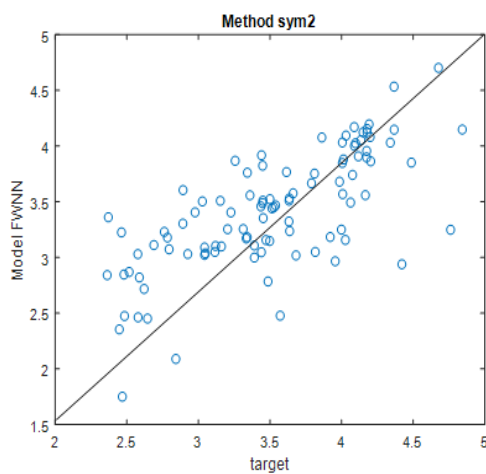
در بین تمامی موجک‌های مختلف مورد بررسی در مدل‌سازی با مدل موجک-عصبی-فازی بیشترین مقدار ضریب تبیین برای ۷ پارامتر ورودی مربوط به موجک‌های *coif1*، *coif3*، *sym4*، *db8* و *db10* با دامنه تغییرات ۰/۸۴ تا ۰/۸۷ می‌باشد. در ارتباط با کاربرد ۴ پارامتر ورودی با ترکیب R_s ، R_n ، T_{min} ، T_{max} ، R_n ، R_s و R_a ، بیشترین مقدار ضریب تبیین به ترتیب مربوط به موجک‌های مادر (*sym10*) و (*coif1*) بوده و برای ترکیب T_{max} ، T_{min} ، R_a ، U_2 مربوط به دو موجک (*coif1*) و (*coif5*) است. نتایج مدل‌سازی با ۳ پارامتر ورودی و ترکیب‌های T_{max} ، T_{min} ، R_s و T_{max} ، R_a ، R_s نشان داد که موجک (*sym8*) دارای عملکرد بالاتری (ضریب تبیین بالاتر و مقدار خطای کمتر) نسبت به سایر موجک‌های مورد استفاده در مدل‌سازی است. براساس آماره‌های ضریب تبیین و آماره‌های خطا، مقایسه نتایج مدل‌سازی بدست آمده با استفاده از شبکه عصبی و موجک-عصبی-فازی نشان می‌دهد که تفاوتی بین نتایج این دو مدل‌سازی برای ترکیب پارامترهای ورودی با ۴ پارامتر ورودی با ترکیب‌های R_s ، R_n ، T_{min} ، T_{max} و در موجک *sym10* وجود ندارد. به نظر می‌رسد که با استفاده از سه پارامتر ورودی دمای ماکزیمم و مینیمم و تشعشع خورشیدی رسیده به زمین، عملکرد مدل موجک-عصبی-فازی با موجک *sym8* عملکرد بهتری نسبت به شبکه

پارامترهای ضروری برای تخمین دقیق تبخیر و تعرق با استفاده از شبکه عصبی پارامترهای مربوط به دما و تشعشع هستند (Jain et al., 2008). مقایسه مقادیر (R^2) و (MSE) بین نتایج مدل شبکه عصبی با ۳ و ۴ پارامتر ورودی (جدول ۵) حاکی از آن است که مدل‌هایی با ۴ پارامتر ورودی دارای مقدار (R^2) بالاتر و خطای پایین‌تری (MSE و MBE) در مقایسه با مدل‌های سه هستند. نتایج مدل‌سازی هستند. نتایج مدل‌سازی با انقیس همچنین نشان داد که استفاده از


کاربرد تعداد پارامتر ورودی کمتر (۳ پارامتر ورودی) و یا تغییر نوع پارامترهای هواشناسی مورد استفاده در این ترکیب یا ترکیب‌های مختلف دیگر مقدار ضریب تبیین را کاهش می‌دهد. در بررسی تمامی ساختارهای متفاوت شبکه عصبی با ترکیبات مختلف متغیرهای ورودی، نتایج حاکی از آن است که دما بعنوان یکی از متغیرهای هواشناسی در تمامی این مدل‌ها به عنوان متغیر ورودی به کار رفته است. جین و همکاران (۲۰۰۸) بیان نمودند که مهمترین

جدول ۶. خروجی مدل‌های شبکه عصبی، انقیس و موجک-عصبی-فازی برای پارامترهای ورودی مختلف

مدل	تعداد پارامتر ورودی																	
	3 parameters (T_{max} , R_a , R_s)			3 parameters (T_{max} , T_{min} , R_s)			4 parameters (T_{mean} , R_a , R_s , R_e)			4 parameters (T_{max} , T_{min} , R_a , R_s)			4 parameters (T_{max} , T_{min} , R_a , U_2)			7 parameters		
	R^2	MSE	MBE	R^2	MSE	MBE	R^2	MSE	MBE	R^2	MSE	MBE	R^2	MSE	MBE	R^2	MSE	MBE
ANN	۰/۷۰	۰/۱۱	۰/۰۳	۰/۶۵	۰/۰۸	۰/۰۲۸	۰/۷۰	۰/۱۲	۰/۰۳۵	۰/۷۴	۰/۰۷	۰/۰۲۶	۰/۹۳	۰/۴۸	۰/۰۶۹	۰/۹۹	۰/۰۰۰۸	۰/۰۰۳
ANFIS	۰/۹۴	۰/۵۳۲	۰/۰۷	۰/۹۳۷	۰/۵۵۳	۰/۰۷	۰/۹۴	۰/۵۳۳	۰/۰۷۳	۰/۹۴	۰/۵۲۹	۰/۰۷۳	۰/۹۸	۰/۲۷	۰/۰۵۲	۰/۹۹	۰/۰۰۴۷	۰/۰۰۷
coif1	۰/۴۶۵	۰/۲۰۶	۰/۰۵	۰/۴۷۲	۰/۲۰۳	۰/۰۴۵	۰/۶۱۳	۰/۲۰۰	۰/۰۴۵	۰/۴۸۲	۰/۲۲۴	۰/۰۴۷	۰/۶۲۹	۰/۱۴	۰/۰۳۷	۰/۸۶۲	۰/۰۵۳	۰/۰۰۷۳
coif3	۰/۵۱۷	۰/۲۲۰	۰/۰۴	۰/۶۵۲	۰/۱۳۷	۰/۰۳۷	۰/۲۴۵	۰/۳۹۹	۰/۰۶۳	۰/۱۴۶	۰/۴۳۱	۰/۰۶۶	۰/۲۹۷	۰/۴۵	۰/۰۶۷	۰/۸۶۶	۰/۰۵۱	۰/۰۲۲
coif5	۰/۳۸۲	۰/۲۴۲	۰/۰۵	۰/۳۶۸	۰/۲۳۵	۰/۰۴۸	۰/۴۸۷	۰/۱۹۷	۰/۰۴۴	۰/۰۳۷	۰/۶۲۴	۰/۰۷۹	۰/۶۰۵	۰/۲۱	۰/۰۴۶	۰/۷۲۱	۰/۱۳۴	۰/۰۳۶
db1	۰/۴۸۸	۰/۲۳۷	۰/۰۵	۰/۲۵۴	۰/۴۳۱	۰/۰۶۵	۰/۴۵۹	۰/۲۶۵	۰/۰۵۱	۰/۰۸۵	۰/۴۵۹	۰/۰۶۸	۰/۲۸۲	۰/۲۹	۰/۰۵۴	۰/۷۳۰	۰/۱۰۳	۰/۰۳۲
db2	۰/۴۱۸	۰/۲۲۸	۰/۰۴۸	۰/۶۱	۰/۴۶۵	۰/۰۶۸	۰/۵۷۲	۰/۱۸۰	۰/۰۴۲	۰/۲۸۷	۰/۳۷۸	۰/۰۶۱	۰/۵۳۶	۰/۱۸	۰/۰۴۲	۰/۷۲۵	۰/۱۰۹	۰/۰۳۳
db4	۰/۰۰۵	۰/۹۳۸	۰/۰۹۶	۰/۳۱۴	۰/۳۴۰	۰/۰۵۸	۰/۵۱۸	۰/۱۸۷	۰/۰۴۳	۰/۶۰۵	۱/۰۵	۰/۱۰۲	۰/۳۷۱	۰/۲۸	۰/۰۵۳	۰/۷۹۵	۰/۰۸۳	۰/۰۲۹
db8	۰/۳۶۹	۰/۲۹۴	۰/۰۵۴	۰/۰۹۱	۰/۶۶۳	۰/۰۸۲	۰/۱۳۹	۰/۴۵۶	۰/۰۶۷	۰/۱۱۶	۰/۵۱۸	۰/۰۷۲	۰/۳۷۸	۰/۲۵	۰/۰۵	۰/۸۴۴	۰/۰۷۵	۰/۰۲۷
db10	۰/۳۷۰	۰/۳۳۹	۰/۰۴۹	۰/۶۲۱	۰/۱۴۹	۰/۰۳۸	۰/۳۷۴	۰/۴۵۹	۰/۰۶۷	۰/۰۸۱	۱/۵۵	۰/۱۲۴	۰/۴۳۲	۰/۲۴	۰/۰۴۹	۰/۸۴۴	۰/۰۶۳	۰/۰۲۵
dmey	۰/۰۸۰	۰/۳۹۲	۰/۰۶۳	۰/۵۴۴	۰/۲۰۳	۰/۰۴۵	۰/۱۸۲	۰/۳۳۹	۰/۰۵۸	۰/۱۳۹	۰/۳۸۹	۰/۰۶۲	۰/۵۳۴	۰/۱۸	۰/۰۴۲	۰/۸۳۲	۰/۰۶۳	۰/۰۲۵
sym2	۰/۵۱۱	۰/۲۰۵	۰/۰۴۵	۰/۳۷۳	۰/۲۴۷	۰/۰۴۹	۰/۵۳۶	۰/۲۱۷	۰/۰۴۶	۰/۳۸۵	۰/۲۴۵	۰/۰۴۹	۰/۴۶۲	۰/۲۸	۰/۰۵۳	۰/۸۰۲	۰/۰۰۷	۰/۰۳۳
sym4	۰/۳۳۲	۰/۳۰۳	۰/۰۵۵	۰/۵۳۲	۰/۱۸۳	۰/۰۴۲	۰/۳۴۲	۰/۲۴۷	۰/۰۴۹	۰/۱۳۸	۰/۳۸۳	۰/۰۶۱	۰/۴۷۴	۰/۲۲	۰/۰۴۷	۰/۸۴۶	۰/۰۵۹	۰/۰۲۴
sym8	۰/۶۶۳	۰/۱۴۳	۰/۰۳۸	۰/۷۰۹	۰/۱۱۶	۰/۰۳۴	۰/۱۳۹	۰/۳۸۳	۰/۰۶۲	۰/۰۹۱	۰/۴۲۶	۰/۰۶۵	۰/۴۷۷	۰/۳۲	۰/۰۵۷	۰/۷۵۹	۰/۱۱۲	۰/۰۳۳
sym10	۰/۳۲۹	۰/۲۴۵	۰/۰۴۹	۰/۲۳۳	۰/۲۹۸	۰/۰۵۴	۰/۰۹۱	۰/۴۲۶	۰/۰۶۵	۰/۷۴۳	۰/۱۱۲	۰/۰۳۳	۰/۴۰۳	۰/۲۲	۰/۰۴۷	۰/۶۵۸	۰/۲۷۰	۰/۰۵۲

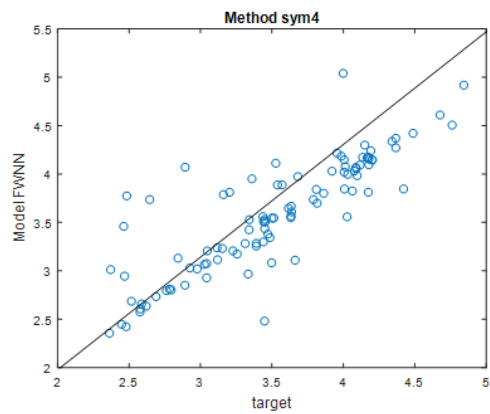


(T_{max} , R_a , R_s) 3 parameters

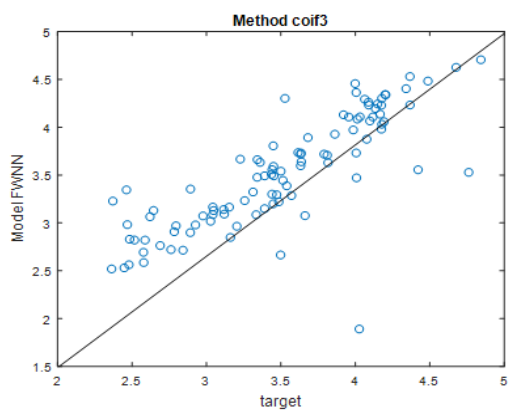


(T_{max} , R_a , R_s) 3 parameters

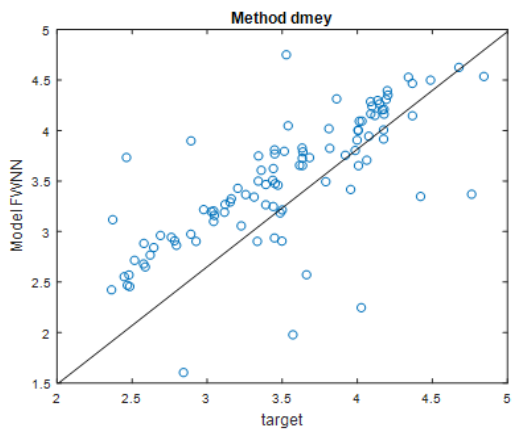
شکل ۸. نمودار پراکنندگی مقادیر داده‌های مشاهداتی در مقابل مقادیر پیش‌بینی شده برای برخی از موجک‌های مختلف




(T_{\max} , T_{\min} , R_s) 3 parameters




(T_{\max} , T_{\min} , R_s) 3 parameters




(T_{\max} , T_{\min} , R_s) 3 parameters



(T_{\max} , T_{\min} , R_s) 3 parameters


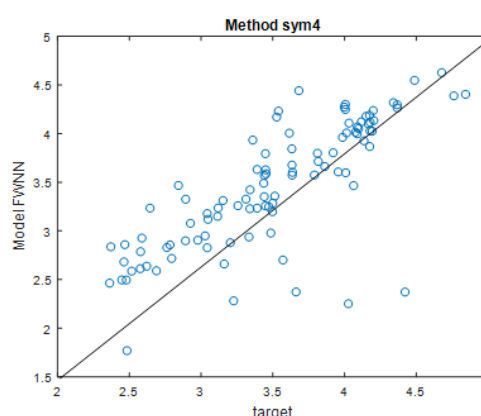


(T_{\max} , R_a , R_s , R_n) 4 parameters



(T_{\max} , R_a , R_s , R_n) 4 parameters

ادامه‌ی شکل ۸. نمودار پراکندگی مقادیر داده‌های مشاهداتی در مقابل مقادیر پیش‌بینی شده برای برخی از موجک‌های مختلف

(T_{max}, T_{min}, R_n, R_s) 4 parameters(T_{max}, T_{min}, R_n, R_s) 4 parameters

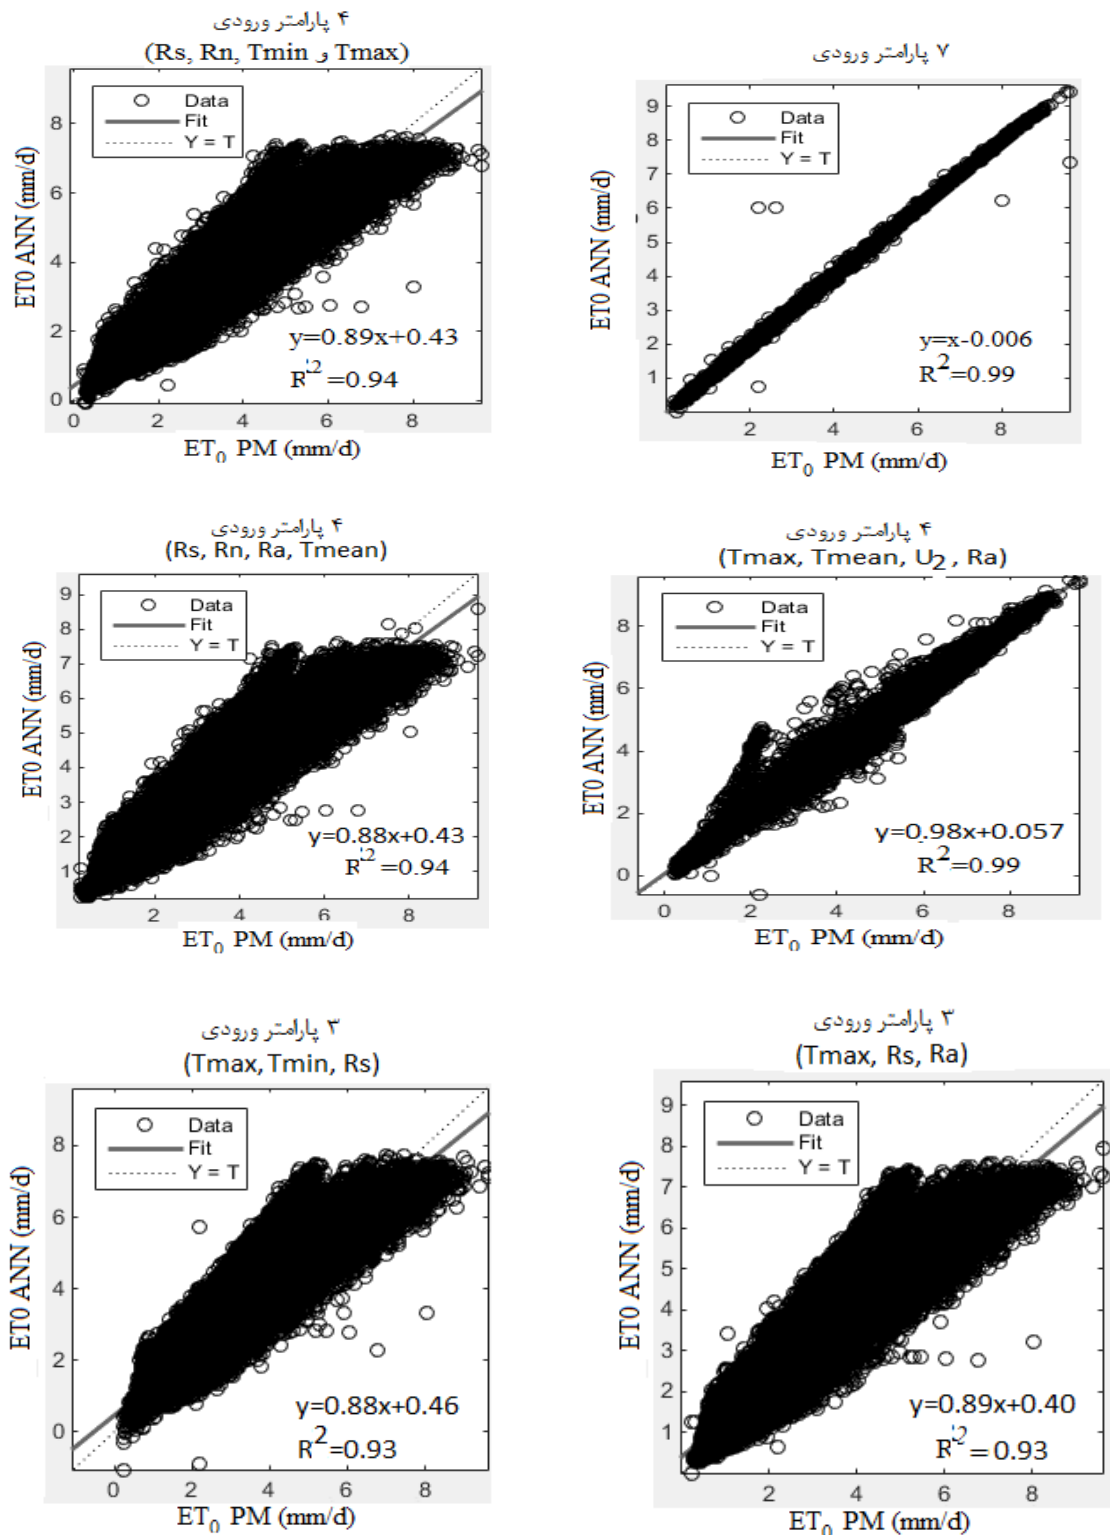
ادامه‌ی شکل ۸. نمودار پراکندگی مقادیر مشاهداتی در مقابل مقادیر پیش‌بینی شده برای برخی از موجک‌های مختلف

مطابقت دارد (Antopoulos and Antopoulos, 2017; Benzaghta *et al.*, 2012 and Sammen, 2013).

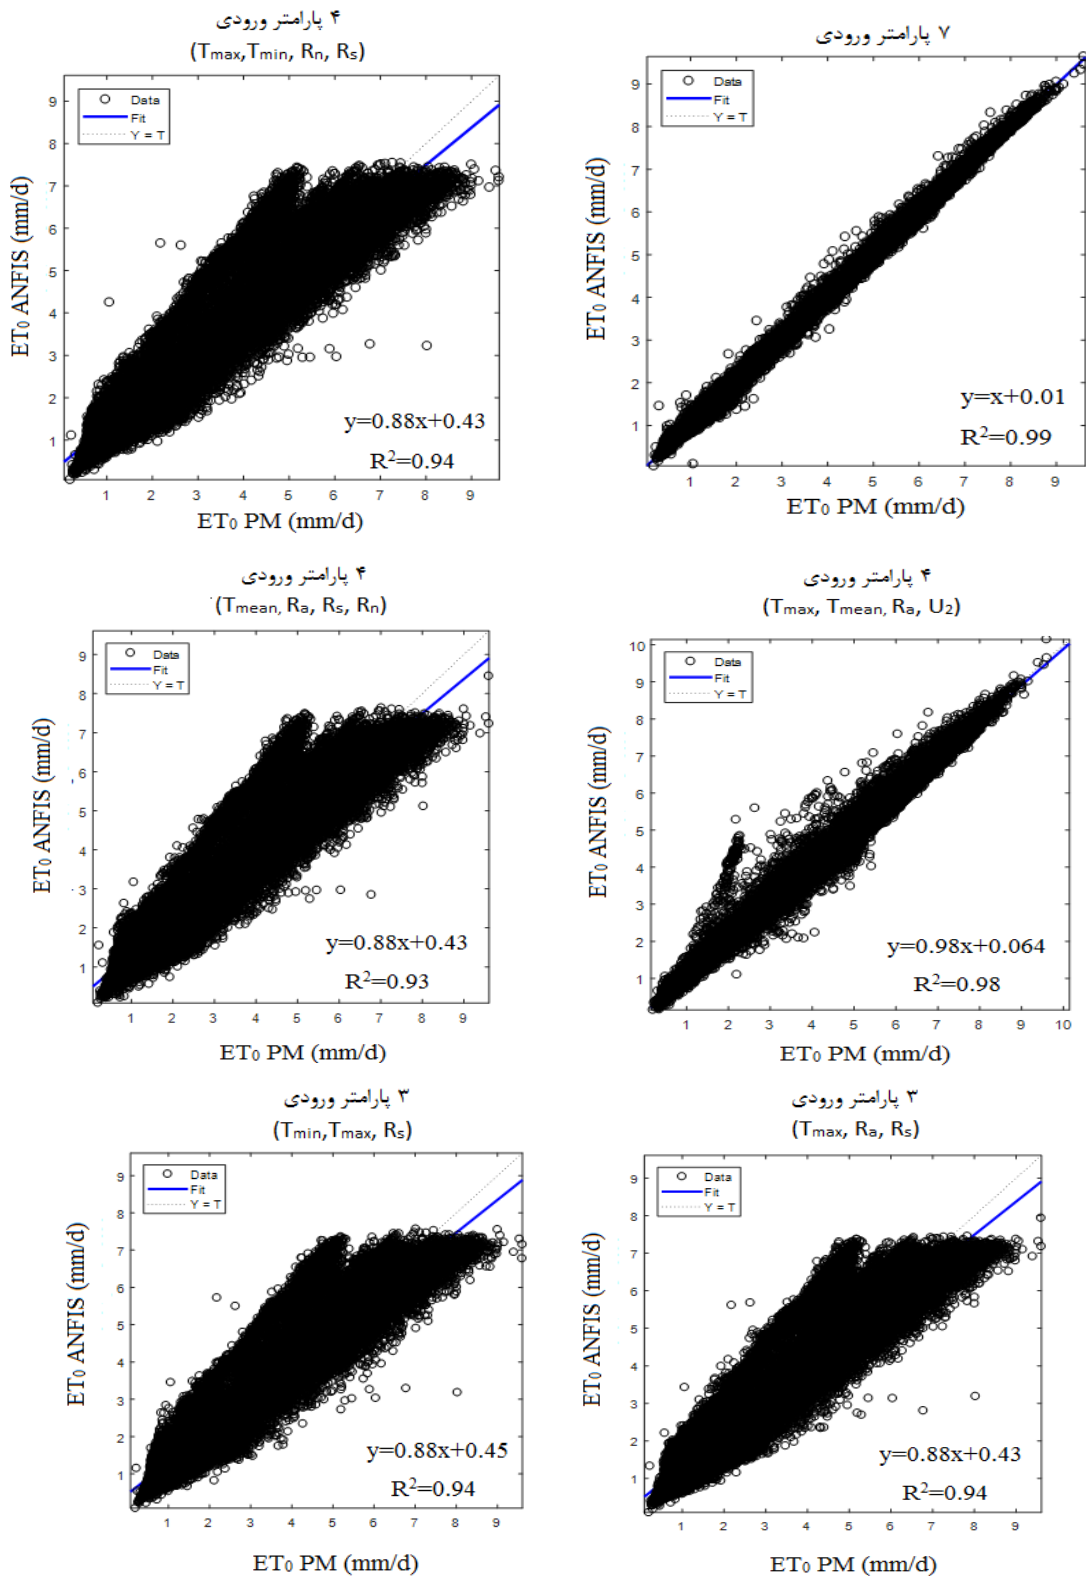
کاربرد تعداد پارامتر ورودی کمتر (۳ پارامتر ورودی) و یا تغییر نوع پارامترهای هواشناسی مورد استفاده در این ترکیب یا ترکیب‌های مختلف دیگر مقدار ضریب تبیین را کاهش می‌دهد. در بررسی تمامی ساختارهای متفاوت شبکه عصبی با ترکیبات مختلف متغیرهای ورودی، نتایج حاکی از آن است که دما بعنوان یکی از متغیرهای هواشناسی در تمامی این مدل‌ها به عنوان متغیر ورودی به کار رفته است. جین و همکاران (۲۰۰۸) بیان نمودند که مهمترین پارامترهای ضروری برای تخمین دقیق تبخیر و تعرق با استفاده از شبکه عصبی پارامترهای مربوط به دما و تشعشع هستند (Jain *et al.*, 2008). مقایسه مقادیر (MSE) و (R^2) بین نتایج مدل شبکه عصبی با ۳ و ۴ پارامتر ورودی (جدول ۵) حاکی از آن است که مدلی با ۴ پارامتر ورودی دارای مقدار (R^2) بالاتر و خطای پایین‌تری (MSE و MBE) در مقایسه با مدل‌های سه پارامتری هستند. نتایج مدل‌سازی با انفیس همچنین نشان داد که استفاده از ۴ پارامتر ورودی $(T_{max}$ و T_{mean} , U_2 , R_a) منجر به برآورد دقیق مقدار ET_0 شده (شکل ۱۰، $R^2=0/98$) و مشابه با شبکه عصبی، ترکیب همه پارامترهای ورودی منجر به عملکرد بهتر مدل انفیس در برآورد مقدار تبخیر و تعرق می‌شود..

۴ پارامتر ورودی U_2 , R_a , T_{mean} و T_{max} منجر به برآورد دقیق مقدار ET_0 شده (شکل ۱۰، $R^2=0/98$) و مشابه با شبکه عصبی، ترکیب همه پارامترهای ورودی منجر به عملکرد بهتر مدل انفیس در برآورد مقدار تبخیر و تعرق می‌شود.

شکل‌های ۹ و ۱۰ به ترتیب نشان‌دهنده‌ی نمودارهای پراکندگی مقادیر تبخیر و تعرق روزانه محاسبه شده با معادله فائو-پنمن-مانتیث ($ET_0 PM$) و مقادیر برآورد شده از مدل‌های شبکه عصبی ($ET_0 ANN$) و انفیس ($ET_0 ANFIS$) با حداقل تعداد پارامتر هواشناسی با ساختارهای مختلف ذکر شده را نشان می‌دهد. نتایج شبکه عصبی می‌تواند به شدت تحت تاثیر تعداد پارامترهای ورودی باشد که این مطلب خود بر روی مقدار خطا و دقت شبکه اثرگذار است (Antopoulos and Antopoulos., 2017) و (Laaboudi *et al.*, 2012). با توجه به شکل‌های ۹ و ۱۰، ترکیب همه پارامترهای ورودی منجر به عملکرد بهتر مدل در برآورد مقدار تبخیر و تعرق می‌شود. بیشترین مقدار ضریب همبستگی بدست آمده مربوط به ساختارهای با ۷ و ۴ پارامتر ورودی (T_{max} , T_{mean} , U_2 , R_a) بوده (شکل ۱۰، $R^2=0/99$) و این نتیجه با نتایج Benzaghta و همکاران (۲۰۱۲)؛ Sammen (۲۰۱۳) و Antopoulos (۲۰۱۷)



شکل ۹. نمودار پراکندگی داده‌های تبخیر و تعرق (فائو-پنمن-ماتیت) در بازه زمانی مورد مطالعه در مقابل نتایج حاصل از شبکه عصبی



شکل ۱۰. نمودار پراکندگی داده‌های تبخیر و تعرق (فائو-پنمن-مانتیث) در بازه زمانی مورد مطالعه در مقابل نتایج حاصل از ANFIS

بحث و نتیجه‌گیری

میان دیگر ساختارها در نظر گرفته شدند. مقایسه آماره-های خطای مدل‌های شبکه عصبی نشان داد که مدل‌های با ۴ پارامتر ورودی دارای دقت بالاتری نسبت به مدل‌های با ۳ پارامتر ورودی هستند. همچنین انواع ترکیبات و سناریوهای پارامترهای هواشناسی نشان داد که استفاده از سناریوی با چهار پارامتر ورودی (U_2, R_a, T_{mean}) و T_{max} تخمین بسیار دقیقی از مقدار تبخیر و تعرق ($R^2=0/93, MBE=0/07$) نسبت به روش فائو-پنمن-مانتیت ارائه می‌کند.

۴- نتایج مدل‌سازی با شبکه عصبی و انفیس نشان می‌دهد که برای مدل‌سازی با شبکه انفیس کاربرد تمامی ترکیب‌های مختلف پارامترهای ورودی منجر به نتایجی با دقت بالا (R^2 بالا $0/99-0/94$) و خطای کم (MBE $0/07-0/007$) و MSE ($0/005-0/055$) می‌شود.

۵- با کاربرد سه پارامتر ورودی T_{min}, T_{max} و R_s و موجک $sym8$ مدل موجک-عصبی-فازی عملکرد بهتری نسبت به مدل شبکه عصبی دارد. نتایج همچنین نشان داد که بیشترین مقدار ضریب تبیین و کمترین مقدار خطا در بین موجک‌های مختلف مورد استفاده در مدل موجک-عصبی-فازی به ترتیب برای ترکیب‌های ۷ و ۳ پارامتر ورودی (T_{max}, T_{min}, R_s) با مقادیر ضریب تبیین $0/87$ و مقدار میانگین خطای انحراف $0/02$ برای ترکیب ۷ پارامتری و با مقادیر ضریب تبیین $0/71$ و مقدار میانگین خطای انحراف $0/03$ بدست آمده است.

۶- در بین موجک‌های مورد استفاده در مدل‌سازی موجک-عصبی-فازی دو موجک ($coif$) و (sym) عملکرد بهتری در برآورد دقیق‌تر مقدار تبخیر و تعرق داشته‌اند.

۱- براساس آماره‌های خطا و ضریب تبیین، برترین روش‌ها در برآورد مقدار تبخیر و تعرق فصلی، سالانه و ماهانه، روش‌های هاگریورز ام ۴، تیلور-پریستلی، ایرماک و میر بودند و در بازه زمانی طولانی مدت روش هاگریورز ام-۴ بهتر عمل نموده است.

۲- آنالیز حساسیت انجام شده براساس سه روش هیل، استات سافت و ضریب تبیین بر روی پارامترهای هواشناسی نشان داد که چهار پارامتر R_n, R_a, R_s و دما بیشترین اهمیت و اثرگذاری را بر میزان تبخیر و تعرق در ناحیه مورد مطالعه با اقلیم نیمه مرطوب معتدل سرد دارند. نتایج آنالیز حساسیت روش ضریب تبیین نیز نشان داد که تنها سرعت باد در ارتفاع ۲ متری از سطح زمین بیشترین تاثیر را بر میزان تبخیر و تعرق دارد. از U_2 آنجایی که از نظر کارایی، روش هاگریورز-ام ۴ و از نظر میانگین مربعات خطا میر از بقیه روش‌ها بهتر عمل نموده است، براساس آنالیزهای حساسیت صورت گرفته، پارامترهای حساس در تعیین مقدار تبخیر و تعرق مرجع (ET_0) در دو روش برتر مذکور به ترتیب ارزش T, R_a و U_2 می‌باشند.

۳- تبخیر و تعرق، فرآیندی پیچیده و غیرخطی است، لذا استفاده از روش‌هایی که بتوانند این پیچیدگی را مدل‌سازی نمایند، الزامی به نظر می‌رسد و در این راستا استفاده از مدل‌های شبکه عصبی راهکار به صرفه و مناسبی می‌باشد. در میان ساختارهای مختلف شبکه عصبی، ساختارهای $7-1-20$ و $4-1-20$ (۴ پارامتر ورودی، یک لایه پنهان و ۲۰ نرون در لایه پنهان) به عنوان بهترین ساختارهای شبکه عصبی با دقت کافی از

فهرست منابع

شیرانی، ح. ۱۳۹۶. شبکه‌های عصبی مصنوعی با قابلیت کاربرد در کشاورزی و علوم طبیعی. انتشارات دانشگاه ولیعصر رفسنجان. ۳۲۰ صفحه.

Adamala, S. 2019. Nonlinear Evapotranspiration Modeling Using Artificial Neural Networks. In Advanced Evapotranspiration Methods and Applications. IntechOpen. pp: 1-24.

- Adamala, S. Raghuwanshi, N.S. Mishra, A. and Singh, R. 2019. Generalized wavelet neural networks for evapotranspiration modeling in India. *ISH Journal of Hydraulic Engineering*. 25(2): 119-131.
- Allawi, M.F. Binti Othman, F. Afan, H.A. Ahmed, A.N. Hossain, M. Fai, C.M. and El-Shafie, A. 2019. Reservoir Evaporation Prediction Modeling Based on Artificial Intelligence Methods. *Water*. 11(6). 1226.
- Alves, W.B. Rolim, G.D.S. and Aparecido, L.E.D.O. 2017. Reference evapotranspiration forecasting by artificial neural networks. *Engenharia Agrícola*. 37 (6): 1116-1125.
- Arca, B. Beniscasa, F. and Vincenzi, M. 2001. Evaluation of neural network techniques for estimating evapotranspiration. *Evolving Solution with Neural Networks*. 62-97.
- Benzaghta, M.A. Mohammed, T. A. Ghazali, A.H. and Soom, M.A. M. 2012. Prediction of evaporation in tropical climate using artificial neural network and climate-based models. *Scientific Research and Essays*. 7(36): 3133-3148.
- Ghorbani, A.M. Kazempour, R. Chau, K.W. Shamshirband, S. 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.
- Goyal, M. K., Bharti, B., Quilty, J., Adamowski, J., and Pandey, A. 2014. Modeling of daily pan evaporation in sub-tropical climates using ANN, LS-SVR, Fuzzy Logic, and ANFIS. *Expert systems with applications*, 41(11): 5267-5276.
- Hamraz, B.S. Akbarpour, A. and Pour Reza bilandi, M. 2016. Sensitivity analysis in groundwater model. *Aquifer and aqueduct Journal*. 1(1): 50-60.
- Hill, M.C. and Tiedeman, C.R. 2006. *Effective groundwater model calibration: with analysis of data, sensitivities, predictions, and uncertainty*. John Wiley and Sons.
- Hornik, K. Stinchcombe, M. and White, H. 1989. Multilayer feed forward networks are universal approximations. *Neural Network*. 2: 359-366.
- Jain, S.K. Nayak, P.C. and Sudheer, K. P. 2008. Models for estimating evapotranspiration using artificial neural networks and their physical interpretation. *Hydrology Process*. 22: 2225-2234.
- Kisi, O. 2006. Daily pan evaporation modeling using a neuro-fuzzy computing technique. *Journal of Hydrology*. 329 (3-4): 636-646.
- Kumar, M. Bandyopadhyay, A. Raghuwanshi, N.S. and Singh, R. 2008. Comparative study of conventional and artificial neural network-based ET0 estimation models. *Irrigation Science*. 26(6): 531.
- Laaboudi, A., Mouhouche, B. and Draoui, B. 2012. Neural network approach to reference evapotranspiration modeling from limited climatic data in arid regions. *International journal of biometeorology*, 56(5): 831-841.
- Odhiambo, L.O. Yoder, R.E. and Yoder, D.C. 2001. Estimation of reference crop evapotranspiration using fuzzy state models. *Transactions of the ASAE*. 44(3): 543-550.
- Pianosi, F. Beven, K. Freer, J. Hall, J.W. Rougier, J. Stephenson, D.B. and Wagener, T. 2016. Sensitivity analysis of environmental models: A systematic review with practical workflow. *Environmental Modeling and Software*. 79: 214-232.
- Qasem, S.N. Samadianfard, S. Kheshtgar, S. Jarhan, S. Kisi, O. Shamshirband, S. 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.
- Razavi, S. and Gupta, H.V. 2015. What do we mean by sensitivity analysis? The need for comprehensive characterization of "global" sensitivity in Earth and Environmental systems models. *Water Resources Research*. 51(5): 3070-3092.
- Riahi-modavar, H. and Ayoubzadeh, S.A. 2008. Estimation of Longitudinal Dispersion Coefficient Using Comparative Neuro-Fuzzy Inference System. *Water and Wastewater Journal*. 67: 34-46.
- SAMMEN, S.S. 2013. Forecasting of evaporation from Hemren reservoir by using artificial neural networks. *Diyala Journal of Engineering Sciences*. 6(4): 38-53.
- Terzi, O. and Keskin, M.E. 2010. Comparison of artificial neural networks and empirical equations to estimate daily pan evaporation. *Irrigation and drainage*. 59(2): 215-225.
- Trajkovic, S. and Kolakovic, S. 2009. Estimating reference evapotranspiration using limited weather data. *Journal of irrigation and drainage engineering*. 135(4): 443-449.
- Valipour, M. 2017. Analysis of potential evapotranspiration using limited weather data. *Applied Water Science*. 7(1): 187-197
- Zanetti, S.S. Sousa, E.F. Oliveira, V.P. Almeida, F. T. and Bernardo, S. 2007. Estimating evapotranspiration using artificial neural network and minimum climatological data. *Journal of Irrigation and Drainage Engineering*. 133(2): 83-89.



ISSN 2251-7480

Sensitivity analysis of meteorological data in estimating reference evapotranspiration with the minimum data using wavelet-neuro-fuzzy, ANN and ANFIS models

Ahmadreza Karimipour^{1*}, Golnoosh Banitalebi²

^{1*} Instructor, Dept of Civil Engineering, Payam Noor University, Shahrekord (Corresponding Author),

*Corresponding author email: ahm.karimipour@gmail.com

² Ph.D. student, Isfahan University of Technology. g.banitalebi@ag.iut.ac.ir

Received: 30-07-2019

Accepted: 11-05-2020

Abstract

The aim of this study was to estimate the ET_0 in a moderately cold semi-humid climate in a 22-year statistical period by applying a wavelet-neuro-fuzzy model with a minimum number of input parameters. The results were compared with the ANN and ANFIS models to evaluate the performance of the wavelet-neuro-fuzzy model. The sensitivity analysis of the input parameters was done in three ways: the Hill method, coefficient of determination, and StatSoft methods. Sensitivity analysis showed that temperature (T) (minimum, maximum and average of daily air temperature), R_s , R_a , mean daily wind speed at 2 meters (U_2) and R_n (net radiation) were an effective parameter, and different combinations of these input parameters can lead to more accurate estimate of ET_0 . Based on the results of the sensitivity analysis, six combinations with these parameters were selected, and temperature in all of these compounds was used as an input variable. Using three input parameters; T_{min} , T_{max} , and R_s and *sym8* wavelet, the wavelet-neural-fuzzy model had a better performance than the neural network model. The results also showed that the estimated ET_0 value with three inputs parameters of maximum and minimum temperature and solar radiation using the fuzzy-neural-wavelet model was more accurate than the neural network. Based on the coefficient of determination and the amount of calculated error for the artificial neural network and the Anfis, use of the combination of 7 input parameters (R_a , R_n , R_s , U_2 , T_{mean} , T_{min} , and T_{max}) ($MBE_{ANN}=0.003$, $MBE_{Anfis}=0.007$, $R2_{ANN}=0.99$, $R2_{Anfis}=0.99$) and four meteorological input parameters (R_a , U_2 , T_{mean} , and T_{max}) ($MBE_{ANN}=0.07$, $MBE_{Anfis}=0.05$, $R2_{ANN}=0.93$, $R2_{Anfis}=0.98$) led to more accurate estimates of ET_0 in comparison to the FAO Penman-Monteith method. The results also showed that the highest amount of coefficient of determination and the lowest error value among the different wavelets used in the fuzzy-neuro -wavelet model was for the seven ($R2=0.87$, $MBE=0.02$) and three input parameters (T_{max} , T_{min} , R_s) ($R2=0.71$, $MBE=0.03$), respectively. The results also indicated that, concerning the error criteria (EF, RMSE, NRMSE, MBE and MAE) and the coefficient of determination, the best model for estimation of ET_0 was Hargraverz-M4, Tylor-Priestly, Meyer, and IRMAK. Based on the EF and NRMSE, four methods including Hargraverz-M4 (EF=0.92, NRMSE=0.11), Tylor-Priestly (EF=0.88, NRMSE=0.12), Meyer (EF=0.73, NRMSE=0.03) and IRMAK1 (EF=0.67, NRMSE=0.25) in long-time period, in according to EF, Hargraverz-M4 (0.92) and in relation to NRMSE, Meyer had the better performance than the other methods.

Keywords: ANFIS, Sensitivity analysis, FAO-Penman-Monteith, Fuzzy- neuro -wavelet model