

ارزیابی تأثیر پیش‌پردازش پارامترهای ورودی به شبکه عصبی مصنوعی (ANNs) با استفاده از روش‌های رگرسیون گام به گام و گاما تست به منظور تخمین سریع‌تر تبخیر و تعرق روزانه

محمد قبائی سوق^۱ - ابوالفضل مساعدي^{۲*} - موسی حسام^۳ - ابوطالب هزارجریبی^۴

تاریخ دریافت: ۱۲/۱۲/۸۸

تاریخ پذیرش: ۳۰/۳/۸۹

چکیده

تبخیر و تعرق (ET_0) یکی از اجزای اصلی چرخه‌ی هیدرولوژیکی است که تعیین صحیح آن در مطالعات بیلان آبی، طراحی سیستم‌های آبیاری و برنامه‌ریزی و مدیریت منابع آب برای دست‌یابی به توسعه‌ی پایدار نقش بهسازایی دارد. تبخیر و تعرق به علت نیاز به فاکتورهای اقلیمی مختلف و اثر مقابله این فاکتورها بر همدیگر یک پدیده‌ی غیرخطی و پیچیده است. یکی از مراحل پیچیده در مدل‌سازی سیستم‌های غیرخطی، پیش‌پردازش پارامترهای ورودی جهت انتخاب ترکیبی مناسب از آن‌ها است. پیش‌پردازش داده‌ها سبب کاهش مراحل سعی و خطأ و شناخت هم‌تلرین پارامترهای مؤثر بر پدیده‌ی مورد نظر جهت مدل‌سازی با استفاده از روش‌های هوشمند می‌گردد. در این تحقیق از دو روش رگرسیون گام‌به‌گام (FS) و گاما تست (GT) برای پیش‌پردازش پارامترهای ورودی به شبکه‌ی عصبی پرسپترون چندلایه (MLP) جهت تخمین ET_0 روزانه‌ی ایستگاه سینوپتیک شیراز استفاده شده است. برای ارزیابی تأثیر پیش‌پردازش پارامترهای ورودی با استفاده از معیارهای مختلف آماری سنجش خطأ به مقایسه‌ی دو مدل ANN-FS و ANN-GT (با پارامترهای پردازش شده) با یکدیگر و همچنین با مدل ANN که هیچ‌گونه پیش‌پردازشی روی پارامترهای ورودی آن انجام نشده است، پرداخته شد. نتایج نشان داد که هر سه مدل از دقت بالایی جهت تخمین ET_0 روزانه برخوردارند و از میان سه مدل فوق، مدل ANN-GT با مقدار ضریب تبیین (R^2) ۰/۹۹۹۵ و ریشه میانگین مربعات خطأ (RMSE) ۰/۴۸۳ نسبت به دو مدل دیگر ANN-FS و ANN به ترتیب با مقادیر R^2 ۰/۹۹۸۴ و ۰/۹۹۹۴ و RMSE برابر با ۰/۰۸۷۴ و ۰/۰۵۴۸ از دقت بالاتری برخوردار است. اگرچه در این تحقیق برتری دقت مدل ANN-GT نسبت به مدل ANN ناچیز است اما توانایی‌های مشخص نمودن ترتیب اهمیت پارامترهای ورودی، تعیین تعداد تقریباً ۸۰۰ داده‌ی معنی‌دار برای آموزش شبکه و یافتن بهترین ترکیب که شامل همه‌ی پارامترهای ورودی به جز دمای حداکثر می‌باشد این آزمون را می‌تواند به عنوان ابزار مفیدی برای پیش‌پردازش پارامترهای ورودی جهت مدل‌سازی سریع‌تر تبخیر و تعرق تبدیل کند.

واژه‌های کلیدی: تبخیر و تعرق پتانسیل، شبکه‌های عصبی مصنوعی، گاما تست، رگرسیون گام‌به‌گام، ایستگاه سینوپتیک شیراز

مقدمه

تعرق است. هم‌چنین طراحی سیستم‌های آبیاری و تعیین بهترین دور آبیاری به تخمین مقدار آب مصرفی گیاه که شامل میزان تبخیر از سطح خاک و تعرق از گیاه است، نیازمند می‌باشد. لذا مساله‌ی تبخیر و تعرق باید به عنوان یکی از عوامل مهم و مؤثر در طراحی شبکه‌های آبیاری و زهکشی مدنظر قرار گیرد (۲). تخمین بیش از حد آب مورد نیاز گیاه ضمن هدر دادن آب آبیاری باعث ماندابی شدن اراضی، شستشوی مواد غذایی خاک و آلوده نمودن منابع آب زیرزمینی می‌شود. ضمن آن که تخمین کمتر نیز باعث اعمال استرس رطوبتی به گیاه شده و در نتیجه کاهش محصول را به همراه خواهد داشت (۹).

انتقال آب بصورت بخار از سطح خاک را تبخیر^۵ و از سطح

تبخیر و تعرق یکی از اجزای اصلی چرخه‌ی هیدرولوژی است که تعیین صحیح آن در علوم آب از قبیل مطالعات توازن هیدرولوژیکی و طراحی و مدیریت سیستم‌های آبیاری از اهمیت بالایی برخوردار است (۱۲). علاوه بر این مقدار تبخیر و تعرق یکی از داده‌های اساسی در طراحی شبکه‌های آبیاری و زهکشی می‌باشد. زیرا طراحی شبکه‌های انتقال اعم از کanal‌های آبرسانی یا زهکشی و نیز سایر قسمت‌های طرح‌های آبی، وابسته به مقدار آب مورد نیاز از طریق پدیده‌ی تبخیر و

۱، ۲، ۳ و ۴ - دانشجوی کارشناسی ارشد، دانشیار و استادیاران گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان
(Email: mosaedi@yahoo.com) - نویسنده مسئول:
*)

شایان نژاد و همکاران (۸) با استفاده از اطلاعات ۵ ساله‌ی اقلیمی و لایسیمتری ایستگاه اکباتان همدان تبخیر و تعرق را به سه روش- رگرسیون فازی، شبکه‌های عصبی مصنوعی و روش فائق پنمن- مانیتیث محاسبه و با داده‌های حاصل از لایسیمتر مقایسه و بیان داشتند که روش رگرسیون فازی با ضریب تبیین ۰/۸۸ و محدود میانگین مربعات خطایی برابر ۰/۷۴ میلیمتر بر روز نتایج بهتری را بدست می‌دهد. کوچک‌زاده و بهمنی (۹) در تحقیقی به ارزیابی عملکرد شبکه‌های عصبی مصنوعی در کاهش پارامترهای مورد نیاز برای برآورد تبخیر و تعرق مرجع در ایستگاه مهرآباد تهران و مقایسه‌ی آن با روش‌های فائق پنمن-مانیتیث، بلانی کریدل، جنسن هیز اصلاح شده، و هارگریوز سامانی پرداختند. آن‌ها بدین منظور به کمک پارامترهای مختلف ۱۱ مدل مختلف ANN طراحی نمودند و با مرجع قرار دادن روش فائق پنمن-مانیتیث از طریق معیارهای آماری خطاب به ارزیابی مدل‌های ایجاد شده پرداختند. بر اساس نتایج بدست آمده دو پارامتر دما و سرعت باد به عنوان مؤثرترین فاکتورها بر دقت برآورد مدل‌های ANN شناسایی شد. زارع ابیانه و همکاران (۴) برای پیش‌بینی تبخیر و تعرق گیاه مرجع در منطقه همدان از شبکه عصبی مصنوعی و سیستم استنتاج عصبی فازی استفاده نمودند. آن‌ها در تحقیق خود با ایجاد ۴ مدل مختلف از ترکیب ۶ پارامتر دماهای حداکثر و حداقل، مقادیر رطوبت نسبی حداقل و حداکثر، سرعت باد و ساعات آفتابی بیان داشتند که از میان مدل‌های بررسی شده، مدل با ترکیب پارامترهای دمای حداقل، دمای حداکثر و ساعات آفتابی روزانه از دقت بالاتری چهارتگاه زارع ابیانه و همکاران (۵) با استفاده از داده‌های لایسیمتری دقت شبکه عصبی MLP را جهت تخمین مقدار تبخیر و تعرق گیاه سیر با استفاده از پارامترهای هواشناسی، مورد ارزیابی قرار دادند. نتایج آن‌ها نشان داد که شبکه‌ی MLP از دقت خوبی برخوردار است و نسبت به پارامتر دمای حداکثر بیشترین حساسیت و حداقل رطوبت نسبی کمترین حساسیت را دارد.

به طور کلی مدل‌سازی داده‌های خروجی با استفاده از مجموعه داده‌های ورودی همواره دارای مقداری خطا خواهد بود که منشأ ایجاد این خطا می‌تواند ناشی از عدم دقت در اندازه‌گیری مقادیر پارامترها، عدم کفايت دانش بشری برای اندازه‌گیری و تشخیص تمام عوامل مؤثر پدیده‌ی مورد نظر و عدم وجود رابطه‌ی هموار^۱ بین مجموعه داده‌های ورودی و خروجی باشد (۱۵).

در شرایطی که هیچ دانشی از معادلاتی که رفتار سیستم را مشخص سازد در دسترس نباشد، گاماتست اساساً به عنوان یک ابزار، می‌تواند برای کمک به ساخت مدلی هموار از رفتار سیستمی آن پدیده بر اساس سری داده‌های اندازه‌گیری شده بکار رود. همچنین این

گیاهان را تعرق^۱ گویند. از نظر فیزیکی این دو فرآیند مشابه هستند، زیرا در هر دو صورت تغییر حالت آب از مایع به بخار و انتقال آن به جو رخ می‌دهد. مجموع این دو تلفات را تبخیر و تعرق^۲ گویند (۶). بر اساس استاندارد فائق، تبخیر و تعرق گیاه مرتع عبارت است از میزان آبی که یک مزرعه پوشیده از گیاه مرتع (نظیر چمن) در یک دوره زمانی مشخص مصرف نماید به طوری که گیاهان این مزرعه در طول دوره رشد با کمبود آب مواجه نشوند (۱۰).

اثر متقابل فاکتورهای کلیماتولوژی از قبیل دما، رطوبت نسبی، سرعت باد، تشعشع، نوع و مرحله رشد گیاه و عوامل دیگر سبب شده است تا تبخیر و تعرق به صورت پدیده‌ای غیرخطی و پیچیده بیان شود (۹). به خاطر دشواری و پیچیدگی فرآیند مذکور از سوی محققان معادلات تجربی مختلفی شامل: پنمن ۱۹۴۸^۳، تورنتو-ایت ۱۹۴۸^۴، بلانی کریدل ۱۹۵۰^۵، تورک ۱۹۶۱^۶، هارگریوز-سامانی ۱۹۸۵^۷، جنسن هیز ۱۹۶۳^۸، پنمن-مانیتیث ۱۹۶۵^۹ و فائق پنمن-مانیتیث ۱۹۹۸^{۱۰} ارائه شده است (۶).

پیچیدگی فرآیند تبخیر و تعرق و کثرت اطلاعات مورد نیاز برای محاسبه‌ی آن از یک سو و مشکلات موجود بر سر راه اندازه‌گیری این داده‌ها که غالباً موجب فقدان آن‌ها می‌گردد از طرف دیگر، ضرورت استفاده از شبکه‌های عصبی مصنوعی را در برآورد تبخیر و تعرق آشکار می‌سازد (۹). در طی سالیان اخیر تحقیقات متعددی در ارتباط با تخمین تبخیر و تعرق از روی داده‌های هواشناسی با استفاده از روش‌های هوشمند در نقاط مختلف دنیا انجام گرفته است. ادھیامبو و همکاران (۲۰۰۱)، کومار و همکاران (۲۰۰۲)، سیلوا (۲۰۰۲) و تراجکویچ و همکاران (۲۰۰۳) از داده‌های هواشناسی بکسانی در تحقیقات خود استفاده نمودند و طی تحقیقات خود نشان دادند که نتایج حاصل از تخمین تبخیر و تعرق با استفاده از شبکه‌های عصبی مصنوعی دارای دقت بالاتری نسبت به روش‌های رایج تبخیر و تعرق می‌باشند (۲۴). سادهر و همکاران (۲۶) برای محاسبه‌ی تبخیر و تعرق از داده‌های ساده شده مانند دمای هوا، تابش بروون زمینی و ساعات آفتابی استفاده نموده و نتایج حاصل را رضایت‌بخش توصیف نمودند. کیسی و اوژتورک (۱۷) جهت تخمین مقدار تبخیر و تعرق به روش فائق پنمن-مانیتیث از سیستم استنتاج عصبی فازی (ANFIS) استفاده نمودند.

1- Transpiration

2- Evapotranspiration

3- Penman

4- Thornth-Waite

5- Blaney-Criddle

6- Hargreaves-Samani

7- Jensen-Haise

8- Penman-Monteith

9- FAO Penman-Monteith

هفتگی در شهر مشهد را با استفاده از دو تکنیک گاماتست و تحلیل مؤلفه‌های اصلی برآورد نمودند و سپس با استفاده از شبکه عصبی مصنوعی به مدل‌سازی این پدیده پرداختند. آن‌ها در این تحقیق با استفاده از دو روش فوق توانستند تعداد ۱۳ متغیر اولیه‌ی تأثیرگذار بر تولید زباله‌های هفتگی در مشهد را به ترتیب به ۵ و ۷ متغیر برای ورود به شبکه‌ی عصبی پرسپترون کاهش دهند. در پایان بیان داشتند که مدل حاصل از گاماتست و شبکه عصبی از دقت بیشتری برای مدل‌سازی تولید زباله‌های هفتگی برخوردار است. نوری و همکاران (۲۱) با استفاده از گاماتست غلظت مونواکسید کربن روزانه در ایستگاه قلهک تهران را به کمک شبکه‌ی عصبی مصنوعی و سیستم استنتاج فازی عصبی مدل‌سازی نمودند. آن‌ها با استفاده از دو تکنیک گاماتست و رگرسیون گامبه‌گام توانستند تعداد ۱۲ متغیر اولیه‌ی تأثیرگذار بر غلظت مونواکسید کربن روزانه را به ترتیب به ۹ و ۷ متغیر برای ورود به شبکه‌های عصبی مصنوعی و سیستم استنتاج فازی عصبی کاهش دهند. در پایان بیان داشتند که مدل حاصل از رگرسیون گامبه‌گام و شبکه عصبی از دقت بیشتری برای مدل‌سازی غلظت مونواکسید کربن روزانه برخوردار است. احمدی و همکاران (۱۱) روش‌های متعدد گزینش پارامترهای ورودی مانند (گاماتست، نظریه‌ی آنتروپی، AIC^{۱۰} و BIC^{۱۱}) بر انتخاب پارامترهای مؤثر بر تابش خورشیدی در حوضه آبریز بروانگلستان را مورد بررسی قراردادند. آن‌ها ضمن مقایسه‌ی روش‌های مختلف بیان داشتند که قابلیت انتخاب بهترین ترکیب از ورودی‌ها، گاماتست را نسبت به سایر روش‌ها متمایز می‌سازد. هرچند این تکنیک تعداد داده‌های مورد نیاز برای مدل‌سازی را بطور قابل ملاحظه‌ای کم برآورد می‌نماید که در این زمینه نظریه‌ی آنتروپی دارای قابلیت بهتری است.

پیش‌پردازش پارامترهای ورودی جهت انتخاب ترکیب مناسب از میان آن‌ها یکی از فرایندهای پیچیده در مدل‌سازی سیستم‌های غیرخطی است. علیرغم وجود مقالات فراوان برای مدل‌سازی پدیده‌ی تبخیر و تعرق با استفاده از روش‌های هوشمند، همچنان در این باره چند سؤال اساسی وجود دارد از جمله: کدام یک از داده‌های ورودی به مدل از اهمیت بیشتری برخوردار است؟ چه ترکیبی از داده‌های ورودی باید به مدل معروفی شود؟ چه تعداد داده برای مدل‌سازی این پدیده مورد نیاز است؟ بررسی منابع نشان می‌دهد که در اکثر مراجع برای مدل‌سازی تبخیر و تعرق با استفاده از روش‌های هوشمند، بدون بکارگیری روش‌های پیش‌پردازش پارامترهای ورودی، با استفاده از روش سعی و خطأ، از میان ترکیبات محدود بررسی شده بهترین ترکیب انتخاب می‌شود. بنابراین فقدان یک روش قاعده‌مند برای یافتن بهترین ترکیب از میان پارامترهای مختلف ورودی احساس می‌

آزمون می‌تواند تا اندازه‌ای برای تخمین آن بخش از واریانس داده‌های خروجی که از روی داده‌های ورودی با ایجاد یک مدل هموار نمی‌تواند محاسبه شوند، به کار رود (۱۲). این آزمون نخستین بار توسط کانسکر^۱ و کمی بعد استفانسون^۲ و همکاران در سال ۱۹۹۷ به صورت خلاصه معرفی شد و در سال‌های بعد توسط چوزانوا^۳ و همکاران، ۱۹۹۸، الیویرا^۴، ۱۹۹۹، تسو^۵، دورانت^۶، تسو و همکاران، ۲۰۰۱، جونس^۷ و همکاران (۲۰۰۲) با جزئیات بیشتر مورد بررسی و استفاده قرار گرفت. ایوانس (۲۰۰۱) و ایوانس و جونس (۲۰۰۲) ضمن استفاده از این آزمون به اثبات آن از طریق روابط ریاضی پرداختند (۲۵). طی سالیان اخیر تحقیقاتی در ارتباط با استفاده از گاماتست بویه کاربرد آن در تبخیر و تعرق منتشر شده‌است. ریمسان^۸ و همکاران (۲۵) با استفاده از گاماتست عوامل مؤثر بر تابش خورشیدی را در حوضه آبریز بروانگلستان تعیین نمودند. آن‌ها با استفاده از آمار پارامترهای روزانه هواشناسی شامل: دما، باران، سرعت باد و تابش بروان زمینی و ایجاد مدل‌های مختلف از ترکیب پارامترهای فوق بهترین مدل را مدل تشخیص دادند که دارای تمام پارامترهای فوق باشد و سپس با استفاده از دو مدل رگرسیون و شبکه‌ی عصبی به مدل‌سازی تابش خورشیدی پرداختند که نتایج حاکی از دقت بیشتر مدل رگرسیونی ایجاد شده بود.

مقدمنا و همکاران (۱۹) برای مدل‌سازی تبخیر روزانه منطقه‌ی چاهنیمه، واقع در استان سیستان و بلوچستان از شبکه‌های عصبی مصنوعی و سیستم استنتاج عصبی فازی استفاده نمودند. آن‌ها در تحقیق خود از چهار پارامتر هواشناسی شامل: دمای هوای کمبود فشار بخار اشباع، رطوبت نسبی و سرعت باد در ارتفاع دو متري نموده و با استفاده از گاماتست بهترین ترکیب که شامل پارامترهای کمبود فشار بخار اشباع، رطوبت نسبی و سرعت باد در ارتفاع دو متري می‌باشد را بدست آوردند. همچنین با استفاده از آزمون M تست تعداد داده‌های مورد نیاز برای مدل‌سازی تبخیر را بدست آورند و در پایان بیان داشتند که نتایج حاصل از شبکه‌ی عصبی برای پیش‌بینی تبخیر نسبت به مدل‌های تجربی و سیستم استنتاج فازی عصبی از دقت بالاتری برخوردارند.

نوری و همکاران (۲۰) عوامل مؤثر بر میزان تولید زباله‌های

1- Koncar

2- Stefánsson

3- Chuzhanova

4- Oliveira

5- Tsui

6- Durrant

7- Jones

8- Remesan

9- Brue

شبکه‌های عصبی مصنوعی

آغاز نظریه‌ی شبکه‌های عصبی مصنوعی تقریباً به دهه‌ی ۴۰ میلادی بر می‌گردد، زمانی که مک‌کلاچ^۱ روانشناس معروف و والریت^۲ ریاضی‌دان در سال ۱۹۴۳ آن را پایه‌گذاری نمودند(۱۸). از دیدگاه ریاضی یک شبکه عصبی به عنوان یک تقریب‌گر است و توانایی آن در تقریب بین الگوهای یک مساله باعث می‌شود تا بتوان مسائل با پیچیدگی زیاد از قبیل شناسایی الگو^۳، تفکیک الگو^۴، نگاشت غیرخطی^۵، حافظه‌ی انجمانی^۶، خودسازمان‌دهی^۷ و کنترل را انجام دهد. اگر چه ایده‌ی شبکه عصبی مک‌کلاچ و پیتز بیشتر از ۶۰ سال پیش ارائه شد ولی نخستین کاربرد عملی شبکه‌های عصبی مصنوعی توسط روزبلاط^۸ با معرفی شبکه‌های پرسپترون چند لایه^۹ (MLP) انجام شد. بطور کلی ساختار شبکه‌ی عصبی MLP از سه لایه‌ی ورودی، پنهانی و خروجی تشکیل شده که برای معماری شبکه در هر لایه‌ی تعدادی نرون در نظر گرفته می‌شود. تعداد نرون‌های موجود در لایه‌های ورودی و خروجی با توجه به ماهیت مسئله‌ی مورد بررسی مشخص می‌شود، حال آن که تعداد نرون‌های موجود در لایه‌های پنهانی و همچنین تعداد این لایه‌ها با سعی و خطأ در جهت کاهش مقدار خطأ توسط طراح مشخص می‌گردد(۱۹).

در این تحقیق برای مدل‌سازی ET₀ با استفاده از شبکه‌ی MLP، از یک لایه‌ی پنهان با تعداد نرون‌های متفاوت و توابع محرك کران‌دار تابع سیگموید و از میان روش‌های مختلف آموزش به روش پسانشار خطأ با الگوریتم لوبنبرگ-مارکوارت، به دلیل همگرایی سریع‌تر در آموزش شبکه استفاده شده‌است. علت انتخاب یک لایه‌ی پنهان این است که چون لایه‌های میانی در ارتباط مستقیم با خروجی نیستند، بنابراین تغییرات این لایه‌ها تأثیر چندانی در تعديل وزن‌ها ایجاد نمی‌کنند (۲۰). اساس روش پسانشار خطأ بر پایه قانون یادگیری اصلاح خطأ می‌باشد که از دو مسیر اصلی رفت و برگشت تشکیل می‌شود. در مسیر رفت، بردار ورودی به شبکه اعمال شده و تأثیراتش از طریق لایه‌های میانی به لایه خروجی انتشار می‌یابد و بردار خروجی پاسخ واقعی شبکه را تولید می‌نماید.

شود که این تحقیق به دنبال معرفی روشهای جهت تعیین بهترین ترکیب از میان پارامترهای مختلف ورودی در برآورد تبخیر و تعرق است. همچنین اهداف دیگر این تحقیق ارزیابی تأثیر دو روش پیش‌پردازش پارامترهای ورودی (رگرسیون گامبه‌گام و گاماتست) برای انتخاب بهترین ترکیب، مشخص نمودن ترتیب داده‌های پارامترهای ورودی مؤثر بر تبخیر و تعرق و تعیین تعداد داده‌های معنی‌دار برای ایجاد یک مدل هموار برای مدل‌سازی تبخیر و تعرق با استفاده از شبکه عصبی MLP می‌باشد.

مواد و روش‌ها

در این تحقیق برای انجام رگرسیون گامبه‌گام از نرم‌افزار آماری R نسخه‌ی ۲/۹ استفاده شد. این نرم‌افزار یک نرم‌افزار رایگان با کتابخانه‌ی گستردگی و قدرت گرافیکی بالا در مقایسه با دیگر نرم‌افزارهای آماری نظیر SAS، Minitab و SPSS است که توسط رایبرت^{۱۰} و رز^{۱۱} از بنیان‌گذاران هسته‌ی اولیه‌ی R در دانشگاه نیوزلند برنامه‌نویسی شد (۲۷). همچنین برای انجام گاماتست از نرم‌افزار وین گاما^{۱۲} نسخه‌ی ۱/۹۸ که توسط جمیع از محققان گروه کامپیوتر دانشگاه کاردیف^{۱۳} برای مدل‌سازی سیستم‌های غیرخطی طراحی گردیده است، استفاده شد (۱۴). برای مدل‌سازی شبکه‌های عصبی مصنوعی نیز از نرم‌افزار Matlab نسخه‌ی ۷/۲ استفاده شده است. این نرم‌افزار امکان طراحی، ساخت، یادگیری و ارزیابی شبکه‌های عصبی مصنوعی را در اختیار می‌دهد و در برگیرنده‌ی شبکه‌های متفاوت با قوانین یادگیری مختلف می‌باشد.

موقعیت منطقه و داده‌های مورد استفاده

برای انجام این تحقیق از داده‌های ایستگاه سینوپتیک شیراز واقع در استان فارس با مختصات جغرافیایی طول ۵۲ درجه و ۳۲ دقیقه شرقی، عرض ۲۹ درجه و ۳۶ دقیقه شمالی، ارتفاع ۱۴۸۴ متر از سطح دریا و متوسط بارندگی سالانه ۳۴۶ میلی‌متر استفاده شده‌است. داده‌های مورد استفاده شامل: دمای حداکثر (T_{max})، دمای حداقل (T_{min})، رطوبت نسبی (RH)، ساعت آفتابی (R_s) و سرعت باد در ارتفاع دو متری (U₂) به صورت روزانه از ابتدای سال ۱۹۹۲ میلادی تا پایان سال ۲۰۰۷ میلادی می‌باشند که از سازمان هواشناسی کشور اخذ گردید. خصوصیات آماری داده‌های مورد استفاده در طول دوره آماری در جدول ۱ ارائه شده‌است.

5- McCulloch

6- Walter Pitts

7- Pattern recognition

8- Pattern classification

9- Nonlinear mapping

10- Associative memory

11- Self organization

12- Rosenblatt

13- Multi layer perceptron

1- Robert Gentlman

2- Ross Ihaka

3- Win Gamma

4- Cardiff

جدول ۱- برخی از پارامترهای آماری داده‌های ایستگاه سینوپتیک شیراز در طول دوره آماری ۱۹۹۲-۲۰۰۷

پارامتر خصوصیت آماری	حداکثر °C	دماهی حداکثر °C									
حداکثر	۴۳/۲	۲۸/۶	۳۵/۶	۹۸/۵	۱۶/۲	۸/۳	۴۱/۱				
حداکل	۱/۴	-۹/۶	-۳/۷	۱۱	۰	.	۲۰/۱				
میانگین	۲۶/۱	۱۱/۲	۱۸/۶	۳۹/۳	۹/۳	۲	۳۱/۷				
انحراف میانگین	۹/۶۰	۷/۸۰	۸/۵۴	۱۸/۵۲	۳/۱۱	۱/۱۶	۷/۵۱				
ضریب تغیرات	۰/۳۶۸	۰/۶۹۸	۰/۴۵۹	۰/۴۷۲	۰/۳۳۵	۰/۵۶۹	۰/۲۳۷				
چوگی	-۰/۱۸۷	-۰/۰۸	-۰/۰۴	-۰/۹۴۹	-۱/۵۳	۰/۸۵۶	-۰/۲۱۱				

زمان بررسی می‌کنند. این روش‌ها عموماً به روش‌های نوع گامبه‌گام^۱ معروف هستند. روش‌های گامبه‌گام را می‌توان در سه دسته کلی گزینش پیش‌رونده (FS)، حذف پس‌رونده^۲ و رگرسیون گامبه‌گام که ترکیبی از روش‌های پیشین است تقسیم نمود (۳). محققان مختلفی: چن^۳ و همکاران^۴، اکسی اوگلو^۵ و همکاران^۶، وانگ^۷ و همکاران^۸، خان^۹ و همکاران^{۱۰} از روش گزینش پیش‌رونده به عنوان یک ابزار برای پیش‌بینی و مدل‌سازی پدیده‌ها استفاده نمودند (۲۱). در روش رگرسیون گامبه‌گام پیش‌رونده که براساس مدل EPM56 (۲۱) در این مطالعه سطح معنی‌داری α برابر ۰/۰۵ انتخاب می‌کنند، که در این مطالعه سطح معنی‌داری α برابر ۰/۰۵ انتخاب شده است. این روش با این فرض شروع می‌شود که هیچ متغیر مستقلی در مدل حضور ندارد و فقط عرض از مبدأ وجود دارد. اولین متغیر مستقل که برای ورود به معادله انتخاب می‌شود آن است که بزرگ‌ترین همبستگی ساده را با متغیر وابسته Y دارد. سپس یک متغیر مستقل برای ورود به مدل برگزیده می‌شود. به بیان دیگر مدل رگرسیون ساده را برای هریک از پارامترهای مستقل، برآش داده و برای هر مدل رگرسیون ساده آماری مقدار آماره‌ی F را محاسبه می‌کنند. آن متغیر مستقلی که دارای مقدار F بزرگ‌تری است، برای افزودن به مدل انتخاب می‌شود. چنان‌چه F مربوط به این متغیر مستقل انتخاب شده از $F_{a,n-2}$ (۱) بزرگ‌تر باشد، آن کاه متغیر مستقل مربوطه به مدل افزوده می‌شود، در غیر این صورت افزودن این متغیر مستقل به مدل چندان مفید نخواهد بود. سرانجام مجموعه‌ای که با افزودن پارامتر مستقل دیگر در سطح α افزایش

معادله فائو پنمن-ماتیت (E_{PM56})

روش موسوم به فائو پنمن-ماتیت تکامل یافته‌ی روش ترکیبی پنمن-ماتیت ۱۹۶۵ است که توسط آلن و همکاران (۱۲) برای محاسبه‌ی تبخیر و تعرق در نشریه‌ی شماره ۵۶ سازمان فائو با نام E_{PM56} به صورت رابطه‌ی ۱ ارائه شده است. این روش با درجه اعتماد بالای در دامنه وسیعی از مناطق و اقلیمه‌ها برآورد صحیحی از تبخیر و تعرق گیاه مرجع ارائه می‌کند و از سوی سازمان خوار و بار جهانی (FAO) به عنوان تنها روش استاندارد برای محاسبه تبخیر و تعرق گیاه مرجع از روی داده‌های اقلیمی و همچنین برای ارزیابی سایر روش‌ها پیشنهاد شده است (۱۶). با استفاده از این روش می‌توان را به صورت ماهانه، ۱۰ روزه و روزانه محاسبه کرد.

$$E_{PM56} = \frac{0.408 \Delta (R_n - G) + \gamma (890 / (T_{mean} + 273)) U_2 (e_s - e_a)}{\Delta + \gamma (1 + 0.34 U_2)} \quad (1)$$

در رابطه‌ی ۱ تبخیر و تعرق گیاه مرجع E_{PM56} ، Δ شب منحنی فشار بخار اشباع ($mm\ day^{-1}$)، R_n (kPa C⁻¹)، G چگالی شار تاش خالص در سطح پوشش گیاهی (MJ m⁻² d⁻¹)، γ ضریب سایکرومتری رطوبتی گرمای خاک (MJ m⁻² d⁻¹)، T_{mean} میانگین دمای روزانه (°C)، U_2 سرعت باد در ارتفاع دو متری (m s⁻¹)، e_s فشار بخار اشباع (kPa)_a، e_a فشار بخار واقعی (kPa) است.

رگرسیون گامبه‌گام

زمانی که تعداد عوامل ورودی مؤثر (N) بر پدیده‌ای کم باشند، می‌توان با بررسی تمام ترکیبات ممکن و مقایسه‌ی خطای در مدل‌های مختلف رگرسیونی، بهترین مدل رگرسیونی برای پیش‌بینی آن پدیده را بدست آورد. اما وقتی که تعداد پارامترهای ورودی افزایش می‌یابد ارزیابی کلیه‌ی رگرسیون‌های ممکن به حجم محاسبات زیادی نیاز دارد. بنابراین روش‌های مختلفی ایجاد شده است که صرفاً تعداد کمی از مدل‌های رگرسیون دارای زیر مجموعه‌ای از متغیرها را در یک

1- Stepwise

2- Forward selection

3- Backward elimination

4- Chen

5- Eksiyoglu

6- Wang

7- Khan

$$\gamma_M(k) = \frac{1}{2M} \sum_{i=1}^M \left| y_{N(i,k)} - y_i \right|^2 \quad 1 \leq k \leq p \quad (5)$$

با ایجاد رابطه‌ی رگرسیون خطی بین P مجموعه‌ی $(\gamma_M(k), \delta_M(k))$ ، مقدار آماره گاما برابر عرض از مبدأ خط رگرسیون ایجاد شده است که معادله‌ی این خط در رابطه‌ی ۶ آورده شده است.

$$\gamma = A\delta + \Gamma \quad (6)$$

از روی خط رگرسیون بیان شده در رابطه‌ی ۶ و نمودار پراکنش گاماتست در شکل ۱ می‌توان اطلاعات مفیدی بدست آورد: نخست آن که عرض از مبدأ خط مذکور نشان دهنده‌ی مقدار گاماتست است که بیانگر آن بخش از واریانس داده‌های خروجی است که نمی‌تواند بوسیله‌ی مدل برآورد گردد. دوم آن که شیب خط رگرسیون نشان دهنده‌ی پیچیدگی مدلی است که از روی مجموعه‌ی داده‌های ورودی و خروجی ساخته می‌شود و این شیب هرچه تندتر باشد نشان دهنده‌ی پیچیدگی بیشتر مدل است. یکی دیگر از معیارهای مهم که با استفاده از این آزمون می‌توان بدست آورد معیار بدون بعد V_{ratio} است که دارای مقادیری بین بازه ۰ و ۱ است و هرچه این مقدار به صفر نزدیک‌تر باشد نمایانگر دقیق‌تر مدل برای یافتن خروجی‌های مطلوب از ورودی‌هاست. در واقع اگر مقدار V_{ratio} از عدد یک کم شود مقدار ضریب تبیین را نشان می‌دهد (۲۵).

اگر فرض شود N پارامتر ورودی بر وقوع پدیده‌ای مؤثر باشند تعداد $1 - N^2$ ترکیب معنی‌دار از پارامترهای ورودی بوجود می‌آید که برای مدل سازی این پدیده با استفاده از ANNs بررسی تک‌تک ترکیبات ایجاد شده برای یافتن بهترین ترکیب کاری بسیار وقت‌گیر و خسته‌کننده است. بنابراین هنگامی که عوامل مؤثر بر پدیده‌ای بطور قابل ملاحظه‌ای زیاد باشد با استفاده از گاماتست می‌توان ترتیب میزان اهمیت پارامترهای ورودی و بهترین ترکیب از میان تمام M ترکیب‌های ممکن را بدست آورد. همچنین با استفاده از آزمون M تست می‌توان تعداد داده‌های ورودی که مقدار گاما را به حالت پایدار برای ایجاد مدل هموار می‌رساند، تعیین نمود (۱۹).

معیارهای آماری سنجش مقدار خط

در این تحقیق به علت عدم وجود داده‌های لایسیمتری در ایستگاه مورد مطالعه، به منظور سنجش میزان کارایی و عملکرد مدل‌های مختلف، مقادیر تبخیر و تعرق روزانه‌ی محاسبه شده از مدل‌های مختلف (E_{Modeli}) با مقادیر برآورده توسط روش فاو پنمن-مانیت (EPM56) به عنوان روش مرجع، از طریق معیارهای آماری ضریب تبیین (R^2)، ریشه میانگین مربعات خط (RMSE) و MBE مقایسه می‌گردد.

معنی‌داری در آماره‌ی F آن ایجاد نشود، به عنوان بهترین ترکیب ورودی برای مدل‌سازی انتخاب می‌گردد (۱).

آزمون گاماتست

گاماتست یک ابزار مدل‌سازی غیرخطی است که به کمک آن می‌توان ترکیب مناسب از پارامترهای ورودی برای مدل‌سازی داده‌های خروجی و ایجاد یک مدل هموار را بررسی نمود. همچنین یک ابزار توسعه یافته برای تخمین میانگین مربعات خطی حاصل از مدل‌سازی پدیده‌های مختلف با استفاده از مجموعه داده‌های مشاهداتی از آن پدیده است. با فرض آن که مجموعه‌ای از داده‌های ورودی x_i و خروجی y_i مشاهده شده از پدیده‌ای به صورت رابطه‌ی ۲ در اختیار باشد.

$$\{(x_i, y_i), 1 \leq i \leq M\} \quad (2)$$

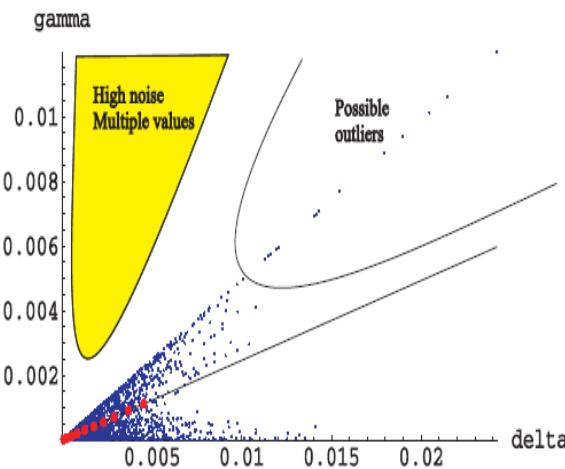
در صورتی که با توجه به مجموعه ورودی x_i ، خروجی y_i بدست آید و M نشان دهنده‌ی تعداد سری مجموعه مشاهده شده از پدیده‌ی مورد بررسی باشد، آن‌گاه گاماتست با فرض عدم قطعیت و پذیرش مقدار خطای در بدست آوردن خروجی از روی ورودی بخاطر پیچیدگی و غیرخطی بودن پدیده‌های مدل‌سازی این خطای را به صورت رابطه‌ی ۳ بین مجموعه داده‌های ورودی و خروجی باتابع f نشان می‌دهد.

$$y = f(x_1, x_2, \dots, x_m) + r \quad (3)$$

که در آن f نمایانگرتابع همواری است که برای مدل‌سازی داده‌ها استفاده می‌شود و r نشان دهنده‌ی متغیر تصادفی است که برای نمایش خطای بکار می‌رود. با فرض آن که میانگین توزیعی که r از آن پیروی می‌کند برابر صفر است (هر مقدار ثابت دیگر را نیز می‌توان برای میانگین تابع f در نظر گرفت) و فرض دیگر آن که واریانس خطای کران‌دار است، مدل فوق به مدلی با مشتقهای جزئی درجه اول محدود می‌شود و گاماتست نشان دهنده‌ی آن بخش از واریانس داده‌های خروجی است که نمی‌تواند توسط مدل هموار محاسبه گردد.

گاماتست بر اساس $N[i, k]$ می‌باشد که در آن p بیانگر نزدیک‌ترین همسایگی است. مقادیر این آزمون برای مجموعه داده‌های ورودی و خروجی بر اساس روابط ۴ و ۵ بدست می‌آید که $| \dots |$ فاصله‌ی اقلیدسی است.

$$\delta_M(k) = \frac{1}{M} \sum_{i=1}^M \left| x_{N(i,k)} - x_i \right|^2 \quad 1 \leq k \leq p \quad (4)$$



شکل ۱ - نمودار پراکنش گاماتست

روش‌های رگرسیون گامبه‌گام و گاماتست، سه مدل مختلف جهت انتخاب بهترین ترکیب از میان پارامترهای ورودی، تعیین شد. اولین مدل که با استفاده از رگرسیون گامبه‌گام بدست آمد ANN-FS نام دارد. مدل دوم که بر پایه‌ی پارامترهای مؤثر بدست آمده از گاماتست ساخته شد ANN-GT نام دارد. مدل سوم که بدون انجام هیچ‌گونه پیش‌پردازشی بر روی پارامترهای ورودی، همه‌ی آن‌ها را شامل می‌شود مدل ANN نام دارد. با تعیین پارامترهای مؤثر و ترکیب بهینه در هر روش، به کمک شبکه‌ی عصبی MLP به مدل‌سازی ET₀، اقدام و سپس با معیارهای مختلف آماری سنجش مقدار خطأ، به ارزیابی مدل‌های ایجاد شده جهت تخمین تبخیر و تعرق روزانه پرداخته شد.

نتایج و بحث

نتایج آزمون رگرسیون گامبه‌گام پیش‌پردازش

بر اساس نتایج این آزمون در مرحله‌ی نخست تابش‌برون‌زمینی مهم‌ترین پارامتری است که برای ورود به مدل انتخاب می‌شود. زیرا مطابق با نتایج جدول ۲ که در آن مقادیر ضریب همبستگی ساده (دو به دو) پارامترهای هواشناسی آمده‌است، پارامتر تابش‌برون‌زمینی دارای بیشترین مقدار ضریب همبستگی با تبخیر و تعرق به مقدار ۸۸/۳۹ درصد می‌باشد. بنابراین وقتی به مدل اضافه می‌شود مقدار ضریب تبیین را به ۷۸/۱۲ درصد می‌رساند. در گام بعدی پارامتر دمای حداکثر با بیشترین مقدار F نسبت به سایر پارامترهای مستقل باقی‌مانده، به مدل اضافه می‌شود که باعث افزایش این ضریب به عدد ۸۷/۸۳ درصد می‌شود. سپس از میان مجموعه پارامترهای باقی‌مانده پارامتری که می‌تواند با بیشترین مقدار F و معنی‌داری در سطح α

$$MBE = \frac{\sum_{i=1}^n (E_{Modeli} - E_{PM56i})}{n} \quad (7)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (E_{Modeli} - E_{PM56i})^2}{n}} \quad (8)$$

جاکوویدز معتقد است که معیارهای آماری MBE و RMSE به تنها‌ی برای انتخاب بهترین مدل ET₀ کافی نمی‌باشند. بنابراین برای ارزیابی دقیق مدل‌ها و مقایسه نسبی نتایج با مقادیر محاسبه شده از روش EPM56 از آزمون زیر که توسط جاکوویدز پیشنهاد گردیده است، نیز استفاده شد. بنابراین، علاوه بر دو معیار MBE و RMSE که عموماً برای مقایسه مدل‌های تبخیر و تعرق استفاده می‌شوند، از معیار دیگری به نام t که ترکیبی از دو معیار ذکر شده است، برای مقایسه‌ی بیشتر نیز استفاده شده است (۷).

$$t = \sqrt{\frac{(n-1)(MBE)^2}{(RMSE^2 - MBE^2)}} \quad (9)$$

در رابطه‌ی t، MBE معیار جاکوویدز و n تعداد مشاهدات می‌باشد و مقادیر کمتر معیار جاکوویدز نشانگر کارایی بالاتر مدل در مدل‌سازی است.

مدلهای مختلف پیش‌پردازش پارامترهای ورودی
در این تحقیق با پیش‌پردازش پارامترهای ورودی توسط

می‌نمایند. این فرآیند برای تمام متغیرها به ترتیب انجام می‌گردد و هر بار مقدار آماره‌ی گاماتست محاسبه می‌شود. در این فرآیند با حذف پارامتر تأثیرگذار مقدار آماره‌ی GT افزایش می‌یابد و با حذف پارامتری که از اهمیت کمتری برخوردار است مقدار این آماره کاهش می‌یابد. نتایج این آزمون برای تبخیر و تعرق روزانه در جدول ۴ آورده شده است. نتایج جدول ۴ بیانگر آن است که با حذف پارامتر سرعت باد، آماره‌ی گاما دارای بیشترین مقدار می‌گردد. بنابراین با توجه به این آزمون سرعت باد مؤثرترین پارامتر بر $_{\text{ET}}$ در ایستگاه سینوپتیک شیراز می‌باشد و پارامترهای تابش بروزنمینی، ساعات آفتابی، رطوبت نسبی، دمای متوسط، دمای حداقل و دمای حداکثر به ترتیب در مرتبه‌های بعدی اهمیت قرار دارند. هم‌چنین با رسم نمودار منحنی‌های جانب برای ترکیبی که همه‌ی پارامترها در آن دخالت دارند و ۷ ترکیب دیگر ذکر شده در جدول ۴، که در آن‌ها در هر مرحله یکی از پارامترهای ورودی به دلخواه حذف گردیده است، می‌توان به ترتیب اهمیت پارامترهای ورودی دست یافته. نتایج حاصل از منحنی‌های جانب مقادیر گاما برای ۸ ترکیب یاد شده در شکل ۲ ارائه شده است. مطابق منحنی‌های جانب رسم شده در این شکل با حذف پارامتر سرعت باد منحنی جانب این ترکیب در فاصله‌ی بالاتری نسبت به سایر جانبها قرار می‌گیرد. بنابراین از تأثیرگذاری بیشتری نسبت به سایر پارامترها برخوردار است.

تعیین بهترین ترکیب

انتخاب ترکیب مناسب از پارامترهای ورودی یکی از مهم‌ترین مراحل ساخت و طراحی هرگونه مدل سازی ریاضی و هوشمند است. اگر فرض شود N پارامتر ورودی بر وقوع پدیده‌ای مؤثر باشند -1^{N-1} ترکیب معنی‌دار از پارامترهای ورودی بوجود می‌آید.

برابر $0/0/0$ به مدل اضافه شود، سرعت باد است که ضریب تبیین مدل را به $94/3$ درصد ارتقاء می‌دهد و به همین ترتیب پارامترهایی که در گام‌های بعدی می‌توانند در سطح α باعث ایجاد معناداری در مقدار آماره‌ی F شوند، پارامترهای ساعات آفتابی، دمای متوسط و رطوبت نسبی می‌باشند و در نهایت اضافه نمودن پارامتر دمای حداقل نمی‌تواند در سطح $0/0/0$ سبب ایجاد معنی‌داری در مقدار آماره‌ی F شود. بنابراین براساس نتایج جدول ۳، مدل حاصل از روش رگرسیون گام به گام به روش پیشرو از تمام پارامترهای ورودی به جز پارامتر دمای حداقل برای مدل سازی تبخیر و تعرق استفاده می‌نماید. نتایج گام به گام مدل‌های ایجاد شده در هر مرحله به همراه مقادیر p -value، آماره‌ی F و مقدار ضریب تبیین برای این آزمون در جدول ۳ ارائه شده‌است.

نتایج گاماتست

با استفاده از روش گاماتست برای پیش‌پردازش پارامترها می‌توان ترتیب میزان اهمیت پارامترهای ورودی، بهترین ترکیب از میان تمام ترکیب‌های ممکن و تعداد داده‌های مورد نیاز برای ایجاد یک مدل هموار جهت ورود به شبکه‌ی عصبی مصنوعی را بدست آورد.

اهمیت پارامترهای ورودی

در این مطالعه ترکیبات مختلف ورودی مورد آزمون قرار گرفته‌اند تا تاثیر هر پارامتر بر مقدار تبخیر و تعرق سنجیده شود. برای مشخص نمودن ترتیب اهمیت پارامترهای ورودی ابتدا آزمون GT را برای ترکیبی که همه‌ی پارامترهای ورودی در آن دخالت دارند انجام داده و سپس در گام بعدی یکی از پارامترها را به دلخواه از مجموعه‌ی اولیه حذف و این بار گاماتست را در این مطالعه با ۶ پارامتر باقی‌مانده محاسبه می‌نمایند و سپس در گام بعدی متغیر حذف شده را به مجموعه‌ی پارامترهای اصلی اضافه نموده و پارامتر دیگری را حذف

جدول ۲- مقادیر ضریب همبستگی ساده (دو به دو) پارامترهای هواشناسی

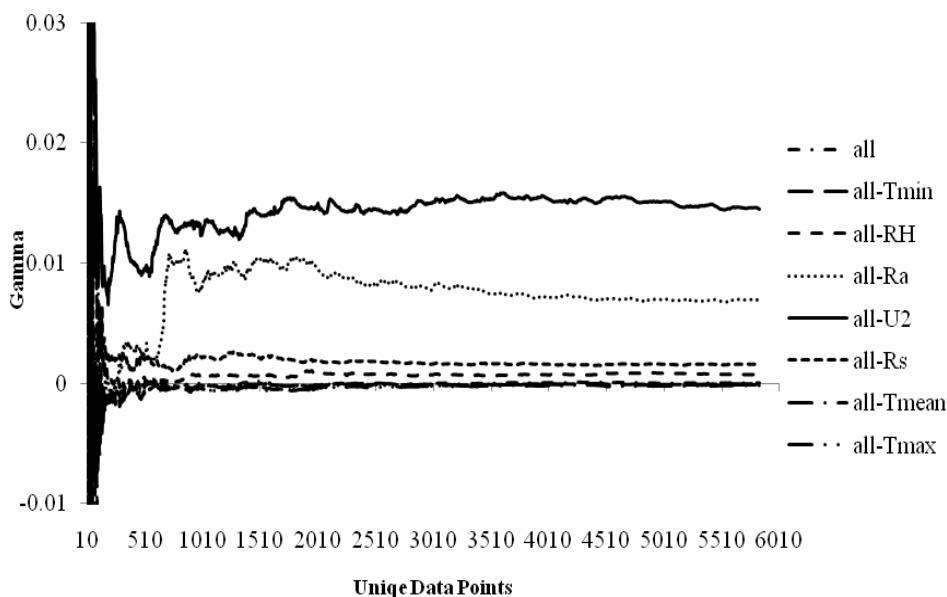
پارامتر	دمای حداکثر	دمای حداقل	دمای متوسط	رطوبت نسبی	ساعات آفتابی	سرعت باد	تابش بروزنمینی	تعزیر و تعرق
تبخیر و تعرق	۰/۸۶۹	۰/۸۵۱	۰/۸۷۶	-۰/۶۴۱	۰/۶۱۴	۰/۵۲۴	۰/۸۸۴	۱
تابش بروزنمینی	۰/۷۵۰	۰/۷۵۸	۰/۷۵۲	-۰/۵۹۱	۰/۴۵۱	۰/۳۶۶	۱	۱
سرعت باد	۰/۲۰۱	۰/۲۸۷	۰/۴۴۴	-۰/۲۲۲	۰/۱۰۸	۱	۱	۱
ساعات آفتابی	۰/۵۹۹	۰/۵۱۷	۰/۳۹۶	-۰/۷۶۱	۰/۱۰۸	۰/۴۵۱	۰/۳۶۶	۱
رطوبت نسبی	۰/۸۱۱	-۰/۷۵۴	-۰/۶۵۵	-۰/۶۴۱	-۰/۶۱۴	۰/۵۲۴	۰/۸۸۴	۱
دمای متوسط	۰/۹۸۶	۰/۹۷۸	۰/۹۷۸	-۰/۵۹۱	-۰/۴۵۱	۰/۳۶۶	۱	۱
دمای حداقل	۰/۹۲۹	۰/۹۲۹	۰/۹۲۹	-۰/۷۶۱	-۰/۷۶۱	۰/۴۵۱	۰/۳۶۶	۱
دمای حداکثر	۰/۹۲۹	۰/۹۲۹	۰/۹۲۹	-۰/۶۱۴	-۰/۶۱۴	۰/۵۲۴	۰/۸۸۴	۱

جدول ۳- نتایج آزمون رگرسیون گام به گام پیش‌روندۀ

پارامترهای ورودی مدل	F	آماره F	ضریب تبیین
تابش بروز زمینی	۲۰.۸۱۹/۳۳***	۷۸/۱۲	.
تابش بروز زمینی، دمای حداکثر	۴۶۴۹/۳۹***	۸۷/۸۳	.
تابش بروز زمینی، دمای حداکثر، سرعت باد	۶۶۲۰/۳۱***	۹۴/۳۰	.
تابش بروز زمینی، دمای حداکثر، سرعت باد، ساعات آفتابی	۲۰.۱۰/۱.۶***	۹۵/۷۶	.
تابش بروز زمینی، دمای حداکثر، سرعت باد، ساعات آفتابی، دمای متوسط	۵۱۴/۶۵***	۹۶/۱۰	.
تابش بروز زمینی، دمای حداکثر، سرعت باد، ساعات آفتابی، دمای متوسط، رطوبت نسبی *** معنی داری در سطح $\alpha / 0.05$	۶۰/۷۶***	۹۶/۱۴	.

جدول ۴- نتایج مقادیر آماره‌ی گاما برای ترکیب پارامترهای مختلف ورودی

مقادیر گاما	ترکیب پارامترهای ورودی	مقادیر گاما	ترکیب پارامترهای ورودی
-./۰۱۴۵۴	T _{min} , T _{max} , T _{mean} , R _a , R _s , RH, U ₂	-./۰۰۰۱۵	T _{min} , T _{max} , T _{mean} , R _a , R _s , RH
-./۰۰۰۱۳	T _{min} , T _{max} , T _{mean} , R _a , RH, U ₂	./۰۰۱۵۹	T _{min} , T _{max} , R _a , R _s , RH, U ₂
./۰۰۰۱۱	T _{min} , T _{max} , T _{mean} , R _s , RH, U ₂	./۰۰۰۶۸۹	T _{min} , T _{mean} , R _a , R _s , RH, U ₂
-./۰۰۰۰۲	T _{min} , T _{max} , T _{mean} , R _a , R _s , U ₂	./۰۰۰۷۳	T _{max} , T _{mean} , R _a , R _s , RH, U ₂



شکل ۲- منحنی‌های مجانب مقادیر گاما در حالت حذف هریک از پارامترها ورودی

جدول ۵- نتایج مقادیر آماره‌های گاما، گرادیانت، خطای استاندارد و V_{ratio} برای هفت ترکیب منتخب

پارامتر	All	All-T _{mean}	All-T _{max,mean}	All-T _{min,mean}	All-T _{max,min}	All-T _{min}	All-T _{max}
مقادیر گاما	-./۰۰۰۰۱۵	-./۰۰۰۰۱۴	./۰۰۰۰۵۳	./۰۰۰۰۳۹	./۰۰۰۰۰۶	-./۰۰۰۰۰۲	./۰۰۰۰۰۱
گرادیانت	./۰۰۰۰۹	./۰۰۰۳۳۷	./۰۰۰۴۰۹	./۰۰۰۴۲۲	./۰۰۰۴۱۴	./۰۰۰۳۴۴	./۰۰۰۳۵۵
خطای استاندارد	./۰۰۰۰۳۹	./۰۰۰۰۴۸	./۰۰۰۰۰۷۷	./۰۰۰۰۰۷۴	./۰۰۰۰۰۵۸	./۰۰۰۰۰۴۴	./۰۰۰۰۰۵۶
V _{ratio}	./۰۰۰۰۶۳	./۰۰۰۰۵۴	./۰۰۰۲۱۱	./۰۰۰۱۵۷	./۰۰۰۰۲۲	./۰۰۰۰۰۹	./۰۰۰۰۰۴

برای مثال در این تحقیق با در نظر گرفتن هفت پارامتر ورودی مؤثر بر ET_0 تعداد ۱۲۷ ترکیب مختلف ایجاد می‌شود که برای مدل-

روزانه و چگونگی تغییرات خطای استاندارد و مقدار آماره‌ی گاما با افزایش تعداد داده‌ها را نشان داد. با توجه به شکل ۳ می‌توان مشاهده نمود که منحنی‌های مجانب آماره‌های گاما و خطای استاندارد تقریباً در اطراف نقطه‌ی 800 به حالت پایدار می‌رسد که با افزایش تعداد داده‌ها مجانب‌های گاما و خطای استاندارد تغییرات چندانی به خود نمی‌بینند. بنابراین تعداد داده‌های معنی‌دار برای آموزش شبکه‌های عصبی مصنوعی 800 مجموعه انتخاب می‌شود.

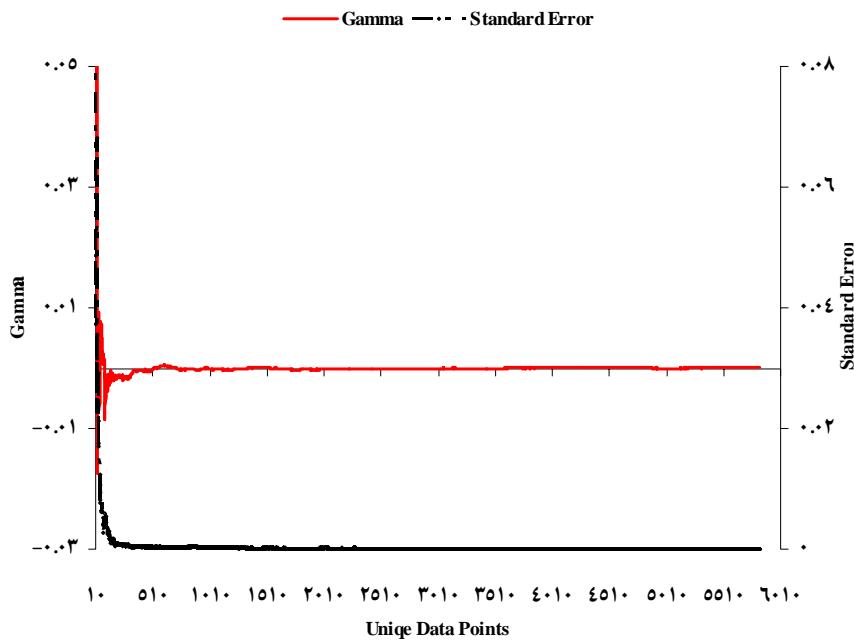
نتایج پیش‌پردازش پارامترهای ورودی در مدل‌های مختلف
بر اساس نتایج پارامترهای مؤثر بدست آمده از روش‌های رگرسیون گامبه‌گام و گاماتست بهترین ترکیب از میان پارامترهای MLP، ورودی برای سه مدل مختلف برای ورود به شبکه‌ی عصبی عصبی مخصوص گردید که نتایج آن برای مدل‌های مختلف در جدول ۶ آمده است. مطابق با نتایج این جدول مدل ANN-FS برای مدل‌سازی ET₀ از ترکیب تمام پارامترهای ورودی به جزء دمای حداقل استفاده می‌نماید. بر پایه‌ی بهترین ترکیب بدست آمده از گاماتست، مدل ANN-GT نیز از ترکیب تمام پارامترهای ورودی به جزء دمای حداقل استفاده و مدل ANN سوم نیز بدون انجام هیچ‌گونه پیش‌پردازشی بر روی پارامترهای ورودی، از ترکیب همه‌ی آن‌ها استفاده می‌کند.

سازی این پدیده با استفاده از ANNs بررسی تک‌تک ترکیبات ایجاد شده برای یافتن بهترین ترکیب کاری بسیار وقت‌گیر و خسته‌کننده است. بنابراین با استفاده از آن آزمون با بررسی ۱۲۷ ترکیب ممکن ایجاد شده نتایج حاصل از آن برای هفت ترکیب منتخب که دارای کمترین مقدار گاما هستند در جدول ۵ آورده شده است. براساس نتایج جدول ۵ و شکل ۲ ترکیبی که شامل همه‌ی پارامترهای گاما نسبت به سایر جز دمای حداقل باشد با کمترین مقدار آماره‌ی گاما نسبت به سایر ترکیب‌ها و پائین‌ترین منحنی مجانب که دارای منحنی مجانب تقریباً همواری است، به عنوان بهترین ترکیب ورودی انتخاب می‌شود.

تعیین تعداد داده‌های مورد نیاز با استفاده از آزمون M تست

یکی از چالش‌های اصلی در مدل‌سازی پدیده‌ها، ارزیابی اطلاعات موجود و کفایت داده‌ها است. به بیان دیگر چه تعداد الگو از مجموعه الگوهای ورودی باید برای مدل‌سازی استفاده شود؟ اگر چه به طور کلی با افزودن اطلاعات بیشتر عملکرد مدل در مرحله‌ی کالیبراسیون بهبود می‌باید ولی باید به این نکته توجه داشت که افزودن اطلاعات بیشتر به چه میزان می‌تواند عملکرد مدل را بهبود ببخشد؟ (۲۳).

علاوه بر آن با استفاده از نمودار M تست می‌توان تعداد داده‌های معنی‌دار برای ایجاد یک مدل هموار برای پیش‌بینی تبخر و تعرق



شکل ۳ – نمودار آزمون M تست مقادیر گاما و خطای استاندارد برای مدل برگزیده در گاماتست

جدول ۶- مدل‌های برگزیده و پارامترهای ورودی در هر مدل

نام مدل	ترکیب پارامترهای ورودی
ANN-FS	$T_{\max}, T_{\text{mean}}, R_a, R_s, RH, U_2$
ANN-GT	$T_{\min}, T_{\text{mean}}, R_a, R_s, RH, U_2$
ANN	$T_{\min}, T_{\max}, T_{\text{mean}}, R_a, R_s, RH, U_2$

ANN با معیارهای آماری مختلف سنجش خطأ در جدول ۷ آورده شده است. براساس نتایج این جدول هر سه مدل از دقت بالایی جهت تخمین ET روزانه برخوردارند و از میان آن‌ها، مدل ANN-GT با مقدار ضریب تبیین ($R^2 = 0.9995$)، آماره جاکوییدز ($t = 6/192$) و ریشه میانگین مربعات خطأ (RMSE) 0.0483 برابر با 0.9984 و دو مدل دیگر میانگین مربعات خطأ (RMSE) 0.0483 و 0.0488 برابر با 0.9984 و 0.9987 هستند.

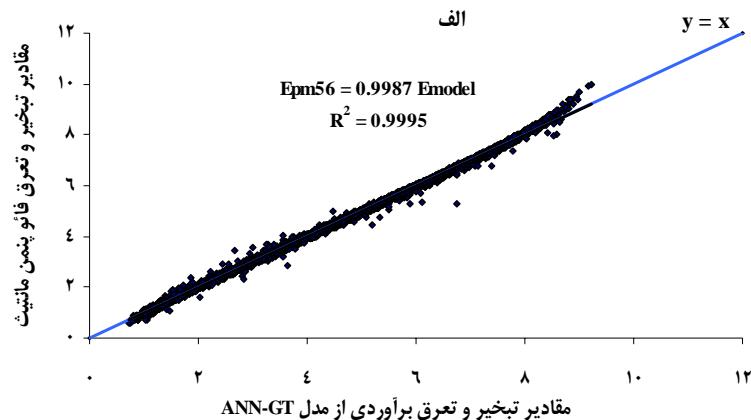
همچنین نتایج حاصل از سه مدل برای مقادیر فاکتور پمن ماننتیث به عنوان داده‌های واقعی و مقادیر بدست آمده از شبیه‌سازی توسط شبکه‌ی MLP، روی خط برآذش یافته و خط درجه 45 در شکل ۴ نشان‌داده شده است. براساس نتایج این شکل ضریب شیب خط بدون عرض از مبدأ برای هریک از سه مدل ANN-GT، ANN-FS و ANN-GT برابر با 0.9988 ، 0.9987 و 0.9997 هستند. همچنین می‌باشد که تقریباً هر سه مدل دارای شبیه مساوی و برابر با شیب خط 45 درجه می‌باشند.

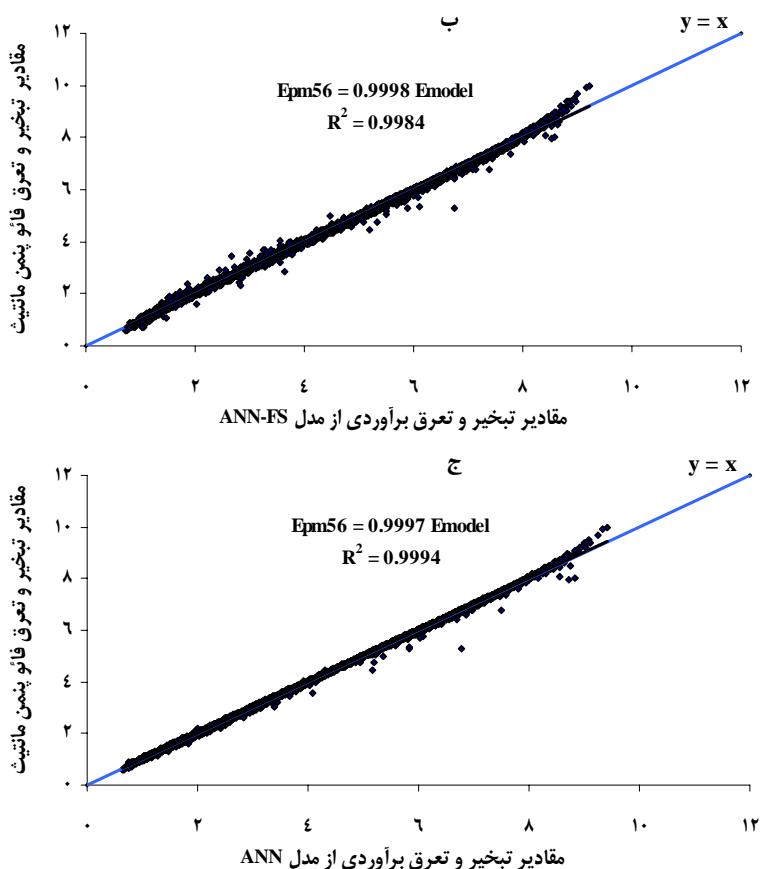
نتایج شبکه‌های عصبی مصنوعی برای داده‌های آزمون

مطابق نتایج حاصل از پیش‌پردازش پارامترهای ورودی در جدول ۶ برای آموزش هریک از سه مدل تعریف شده با استفاده از شبکه‌ی عصبی MLP، در لایه‌ی ورودی از ترکیب پارامترهای هواشناسی مختلف استفاده شد. بدین منظور از 5832 رکورد ثبت شده این استنگاه در سال‌های 1992 الی 2007 با توجه به آزمون M تست تعداد 800 رکورد برای آموزش و تعداد 5033 رکورد باقیمانده برای آزمون شبکه‌های عصبی استفاده شده است. برای این کار در لایه‌ی پنهان از یک لایه‌ی مخفی با تعداد نرون‌های متفاوتی استفاده شده و تعداد بهینه‌ی آن‌ها برای حداقل نمودن خطأ تعیین گردیده است. روند کار با تعداد نرون‌های کم آغاز و افزودن نرون‌های اضافی تا زمانی ادامه داشت که افزایش نرون‌های بیشتر تأثیری در بهبود خطأ نداشته باشند. بدین منظور از 2 تا 20 نرون استفاده گردید. همچنین در لایه‌ی پنهان از توابع محرک تائزانت سیگموئید، لوگ سیگموئید با روش پسانشوار خطأ و الگوریتم آموزشی لونبرگ-مارکوارت مورد استفاده قرار گرفت. تعداد نرون‌های لایه‌ی پنهان، توابع محرک به همراه نتایج حاصل از مقایسه‌ی سه مدل ANN-FS، ANN-GT و ANN-GT.

جدول ۷- مقایسه‌ی سه مدل ANN-FS، ANN-GT و ANN با معیارهای آماری مختلف سنجش خطأ

مدل	ساختار	تابع محرك	R^2	RMSE	MBE	t
ANN-FS	۶-۵-۱	لوگ سیگموئید	0.9984	0.0483	-0.0084	$6/149$
ANN-GT	۶-۸-۱	تائزانت سیگموئید	0.9995	0.0482	-0.0042	$6/192$
ANN	۷-۸-۱	تائزانت سیگموئید	0.9994	0.0478	-0.0052	$6/768$





شکل ۴- نتایج مدل‌های (الف) ANN-GT، (ب) ANN-FS و (ج) ANN روی خط ۱:۱ (۴۵ درجه) جهت تخمین $_{\text{ET}}$ (میلیمتر بر روز) در ایستگاه سینوپتیک شیراز

این واقعیت می‌تواند ناشی از همبستگی بالا بین پارامترهای دمای حداقل و دمای حداکثر با دمای میانگین باشد که باعث ایجاد هم‌خطی و نقض استقلال پارامترهای ورودی مدل می‌شود. بنابراین مدل بهینه در این دو روش به خوبی توانسته است با حذف یکی از این پارامترها مانع ایجاد هم‌خطی شود.

همان‌طور که در بخش پایانی مقدمه ذکر شد، اهداف این تحقیق پاسخ به چند سوال اساسی در ارتباط با مدل‌سازی تبخیر و تعرق با استفاده از شبکه‌ی عصبی از جمله: کدام یک از داده‌های ورودی به مدل از اهمیت بیشتری برخوردار است؟ چه ترکیبی از پارامترهای ورودی باید به مدل وارد شود؟ چه تعداد داده برای مدل‌سازی تبخیر و تعرق با توجه به مجموعه‌ی ورودی مورد نیاز است؟ تعریف شده بود که در این تحقیق روش‌های FS و GT برای پاسخ به سوالات فوق و رائمه‌ی یک روش قاعده‌مند برای کاوش مراحل سعی و خطا بکار گرفته شد. نتایج بکارگیری روش‌های پیش‌پردازش فوق نشان داد که روش FS با مشخص نمودن اهمیت نسبی پیوستن پارامترها به مدل در هرگام و تعیین مدل بهینه‌ی نهایی در سطح معنی‌داری ۰/۰۵ در پاسخ به دو پرسش از پرسش‌های مطرح شده می‌تواند به عنوان

نتیجه‌گیری کلی

انتخاب ترکیب مناسب از پارامترهای ورودی یکی از مهم‌ترین مراحل ساخت و طراحی هرگونه مدل‌سازی ریاضی و هوشمند است. در این تحقیق از روش رگرسیون گام‌به‌گام و یک ابزار جدید به نام گاماتست برای پیش‌پردازش پارامترهای ورودی و انتخاب ترکیب بهینه از پارامترهای ورودی جهت شبیه‌سازی تبخیر و تعرق روزانه به کمک شبکه‌ی عصبی MLP استفاده شد. آن‌گاه با مرتع قراردادن روش فاصله‌نمای ماننیش، عملکرد مدل‌های مختلف جهت تخمین تبخیر روزانه مورد ارزیابی و بررسی قرار گرفت. نتایج ارزیابی سه مدل نشان داد که هر سه مدل از دقت بالایی برای شبیه‌سازی تبخیر و تعرق روزانه برخوردارند. ضمن آن که برتری مدل ANN-GT نسبت به مدل ANN و نیز برتری مدل‌های ANN-GT و مدل ANN نسبت به مدل ANN-FS چندان محسوس نبی‌باشد.

نتایج پیش‌پردازش پارامترهای ورودی روش‌های FS و GT جهت مدل‌سازی نشان داد که افزودن پارامترهای دمای حداقل و دمای حداکثر در بهبود عملکرد مدل شبیه‌سازی تأثیر چندانی ندارند و

بنابراین به نظر می‌رسد ارائه و بکارگیری الگوهای نو و تکنیک‌های پیشرفته جهت پیش‌پردازش پارامترهای ورودی می‌تواند موجب کاهش مراحل سعی و خطأ در یافتن ترکیب مناسب ورودی و ایجاد تحول در مدل‌سازی پدیده‌ها با استفاده از روش‌های هوشمند گردد.

روشی مؤثر بکار رود. ضمن آن که آزمون گاما تست به عنوان یک الگوی نو ضمن پاسخ به دو پرسش قبلی با توانایی تعیین تعداد الگوهای لازم برای آموزش شبکه جهت ایجاد یک مدل هموار با استفاده از آزمون M تست (در این تحقیق 800 الگوی ورودی) می‌تواند به عنوان یک روش کارآمد برای پیش‌پردازش پارامترهای ورودی جهت مدل‌سازی تبخیر و تعرق با استفاده از شبکه MLP بکارگرفته شود.

منابع

- بازرگان لاری ع. ۱۳۸۴. رگرسیون خطی کاربردی. چاپ اول. انتشارات مرکز نشر دانشگاه شیراز، ۳۲۹ ص.
- جهانبخش اصل س.، موحددانش ع. و مولوی ا. ۱۳۸۰. تحلیل مدل‌های برآورد تبخیر و تعرق برای ایستگاه هواشناسی تبریز. مجله دانش کشاورزی ۱۱ : ۵۱-۶۶.
- رضایی ع. و سلطانی ا. ۱۳۸۲. مقدمه‌ای بر تحلیل رگرسیون کاربردی. دانشگاه صنعتی اصفهان، مرکز نشر، ۲۹۴ ص
- زارع ابیانه ح، بیات ورکشی م، معروفی ص. و امیری چایخان ر. ۱۳۸۹. ارزیابی سیستم‌های هوشمند عصبی در کاهش پارامترهای تخمین تبخیر و تعرق گیاه مرجع. مجله آب و خاک (علوم و صنایع کشاورزی)، ۲۴ (۲) : ۲۹۷-۳۰۵.
- زارع ابیانه ح، قاسمی ع، بیات ورکشی م. و معروفی ص. ۱۳۸۸. ارزیابی دقت شبکه عصبی مصنوعی در پیش‌بینی تبخیر و تعرق گیاه سیر با استفاده از داده‌های لایسیمتری در منطقه همدان. مجله آب و خاک (علوم و صنایع کشاورزی)، ۲۳ (۳) : ۱۷۶-۱۸۵.
- علیزاده ا. و کمالی غ. ۱۳۸۷. نیاز آبی گیاهان در ایران. چاپ اول. موسسه‌ی چاپ و انتشارات آستان قدس رضوی. ۲۲۸ ص.
- سبزی پرور ع. ا، تفضلی ف، زارع ابیانه ح، باززاد ح، موسوی بایگی م، غفوری م، محسنی موحد، ا. و مریانجی، ز. ۱۳۸۷. مقایسه چند مدل برآورد تبخیر و تعرق گیاه مرجع در یک اقلیم سرد نیمه‌خشک، به منظور استفاده بهینه از مدل‌های تابش. مجله آب و خاک (علوم و صنایع کشاورزی)، ۲۲ (۲) : ۳۲۷-۳۴۰.
- شایان نژاد م، ساداتی نژاد ج. و فهمی ه. ۱۳۸۶. تعیین تبخیر و تعرق بالقوه با استفاده رگرسیون فازی. مجله تحقیقات منابع آب ایران، ۱۹: ۳-۹.
- کوچکزاده م. و بهمنی ع. ۱۳۸۴. ارزیابی عملکرد شبکه‌های عصبی مصنوعی در کاهش پارامترهای مورد نیاز، جهت برآورد تبخیر و تعرق مرجع. مجله علوم کشاورزی، ۱۱ : ۸۷-۹۶.
- موسوی بایگی م، عرفانیان م. و سردم م. ۱۳۸۸. استفاده از حداقل داده‌های هواشناسی برای برآورد تبخیر و تعرق گیاه مرجع و ارائه‌ی ضریب اصلاحی (مطالعه موردی: استان خراسان رضوی). مجله آب و خاک (علوم و صنایع کشاورزی)، ۲۳ (۱) : ۹۱-۹۹.
- 11- Ahmadi A., Han D., Karamouz M., and Remesan R. 2009. Input data selection for solar radiation estimation. *Hydrological Processes*, 23: 2754-2764.
- 12- Allen, R.G., Pereira, L.S., Raes, D., and Smith, M., 1998. Crop evapotranspiration. Guidelines for computing crop water requirements. FAO Irrigation and Drainage, Paper no. 56. FAO, Rome.
- 13- Jones A.J., Evans D., Margetts S., and Durrant P. 2002 .The Gamma Test. Chapter IX in Heuristic and Optimization for Knowledge Discovery. Edited by Ruhul Sarker, Hussein Abbass and Charles Newton. Idea Group Publishing, Hershey, PA. 27 pp.
- 14- Jones A.J., Margetts S., and Durrant P. 2000. The win Gamma User Guide. Department of computer science, university of Wales, 77pp. accessible at: <http://users.cs.cf.ac.uk/.../Gamma%20Software/winGamma.htm/>
- 15- Jones A.J., Tsui A., and Oliveira A.G. 2002. Neural models of arbitrary chaotic systems. construction and the role of time delayed feedback in control and synchronization, Complexity Int;09.
- 16- Kumar M., Bandyopadhyay A., Raghuwanshi N. S., and Singh R. 2008. Comparative study of conventional and artificial neural network-based ET₀ estimation models. *Irrigation Sciences* 26:531-545.
- 17- Kisi O., and Ozturk, O. 2007. Adaptive neuro-fuzzy computing technique for evapotranspiration estimation. *J. Irrig. Drain. Eng., ASCE* 133 (4), 368-379.
- 18- McCulloch W.S., and Pitts W.A. 1943. Logical calculus of the ideas immanent in nervous activity. *Bull Math Biophys* ,5:115-33.

- 19- Moghaddamnia A., Ghafari Gousheh M., Piri J., Amin S., and Han D. 2009. Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques. *Advances in Water Resources*. 32 : 88–97.
- 20- Noori R., Karbassi A., and Sabahi M.S .2009. Evaluation of PCA and gamma test techniques on AAN opration for weekly solid waste prediction, *Journal of Enviromental Management*.91: 767-771
- 21- Noori R., Hoshayaripour GH., Ashrafi KH., and Najdar Araabi B. 2009. Uncertainty analysis of developed ANN and ANFIS models in prediction of carbon monoxide daily concentration, *Atmospheric Environment*, 44:476-482.
- 22- Odhiambo L.O., Yoder R. E., Yoder D. C., and Hines J.W. 2001. Optimization of fuzzy evaporation model through neural training with input-output examples. *Trans, ASAE*, 44(6):1625-1633.
- 23- Peterson A.T., and Cohoon K.P. 1999. Sensitivity of distributional prediction algorithms to geographic data completeness. *Ecological Modelling* 117: 159–164.
- 24- Rahimi Khoob A. 2008. Artificial neural network estimation of reference evapotranspiration from pan evaporation in a semi-arid environment. *Irrigation Sciences* 27:35–39
- 25- Remesan R., Shamim M.A., and Han D. 2008. Model data selection using gamma test for daily solar radiation estimation. *Hydrological Processes* 22: 4301–4309.
- 26- Sudheer K.P., Gosain A.K., and Ramasastri K.S. 2003. Estimating actual evapotranspiration from limited climatic data using neural computing technique. *J. Irrigation. Drainage. Engineering*, 129: 214–218.
- 27- Venables W.N., Smith D.M., and the R Development Core Team. 2009. An Introduction to R. ISBN 3-900051-12-7, 100pp. accessible at: <http://www.R-project.org/>.



Evaluation Effect of Input Parameters Preprocessing in Artificial Neural Networks (Anns) by Using Stepwise Regression and Gamma Test Techniques for Fast Estimation of Daily Evapotranspiration

M. Ghabaei Sough¹ - A. Mosaedi^{2*} - M. Hesam³ - A. Hezarjaribi³

Abstract

Process of evapotranspiration (ET_o) is a major component of the hydrologic cycle that its accurate estimation plays an important role to achieve sustainable development in water balance, irrigation system design and planning and management of water resources. Being a function of different metrological parameters and their interactions, evapotranspiration is a complex, nonlinear phenomenon. Preprocessing input parameters to select appropriate combinations is complex when modeling nonlinear systems. Using these methods reduce steps by trial and error by recognizing most important parameters for modeling by intelligent methods. In this study, two methods of stepwise regression (FS) and gamma test (GT) were used for preprocessing input parameters in multi layer perceptron neural network (MLP) to estimate daily estimation of ET_o at Shiraz synoptic station. To evaluate the effect of Input parameters preprocessing in artificial neural networks using different statistical error criteria, ANN-FS and ANN-GT both with pre-processed parameters were compared against each other and also with ANN model without pre-processed parameters. The results showed that all three models have a high degree of accuracy to estimate daily ET_o . ANN-GT model represented a determination coefficient (R^2) of 0.9995 and the root mean square error (RMSE) of 0.0483. For ANN-FS and ANN models R^2 values were 0.9984 and 0.9994 respectively and RMSE_s were 0.0874 and 0.0548 respectively. Although the accuracy of ANN-GT model was slightly greater than ANN, but the ability of determination of importance of input parameters, education and recognition of the best combination of input parameters with 800 data in this study, makes this model a useful tool for fast preprocessing input parameters to model evapotranspiration.

Keywords: Potential evapotranspiration, Artificial neural networks, Gamma test, Stepwise regression, Shiraz synoptic station

1,2,3,4- MSc. Student, Associate prof., and Assistant professors, Dept. of Water Eng. Gorgan University of Agricultural Sciences and Natural Resources, Respectively
(* - Corresponding author Email: mosaedi@yahoo.com)