

واسنجی معادلات تجربی تبخیر و تعرق روزانه و مقایسه با نتایج شبکه‌های عصبی مصنوعی در شرایط مختلف کمبود داده‌های هواشناسی

امیر احمد دهقانی^{*}، محمد قبائی سوق^۲، حسین شریفان^۳ و نوید دهقانی^۴

!!(E-mail: a.dehghani@gau.ac.ir)

(تاریخ دریافت: ۸۹/۱۰/۶ - تاریخ پذیرش: ۹۰/۳/۴)

چکیده

برآورد صحیح تبخیر و تعرق گیاه مرجع (ET_0) در مدیریت منابع آب و برنامه‌ریزی سیستم‌های آبیاری اهمیت ویژه‌ای دارد. روش فائو پنمن - مانیتث (F-P-M) به عنوان روش استاندارد برای محاسبه ET_0 ، به پارامترهای دما، رطوبت نسبی، ساعات آفتابی و سرعت باد نیاز دارد که در اکثر ایستگاه‌های هواشناسی امکان اندازه‌گیری همه آن‌ها وجود ندارد، لذا در چنین شرایطی نیاز به معادلات تجربی با پارامترهای هواشناسی کمتر می‌باشد. شبکه‌های عصبی نیز می‌توانند برای تخمین پدیده‌هایی مانند ET_0 که متغیرهای آن دارای روابط داخلی غیرخطی و پیچیده‌اند، به کار برده شوند. در این تحقیق، با استفاده از داده‌های روزانه ایستگاه سینوپتیک گرگان هفت مدل شبکه عصبی مصنوعی با ساختارهای مختلف از پارامترهای هواشناسی به عنوان ورودی طراحی گردید. تبخیر و تعرق پتانسیل نیز از پنج معادله تجربی فائو پنمن - مانیتث (F-P-M)، هارگریوز - سامانی (HS)، تورک (T)، پریستلی - تیلور (PT) و مک‌کینک (MK) و شش معادله تخمینی که در آن‌ها پارامترهای رطوبت نسبی و یا تابش خورشیدی معادلات تجربی با استفاده از داده‌های دمایی برآورد گردیدند، محاسبه شد. معادلات تجربی و تخمینی با استفاده از روش استاندارد F-P-M، در دوره آموزش (۸۱-۱۳۷۱) واسنجی و ضرایب آن‌ها تعیین گردید. سپس براساس پارامترهای موردنیاز جهت تخمین ET_0 معادلات تجربی، تخمینی واسنجی شده و مدل‌های شبکه عصبی به سه گروه تقسیم و با استفاده از معیارهای آماری R^2 ، RMSE و MBE در دوره آزمون (سال‌های ۶-۱۳۸۲) در گروه‌های سه‌گانه با هم مقایسه شدند. نتایج نشان داد که مدل‌های شبکه عصبی مصنوعی ایجاد شده در هر سه گروه نسبت به معادلات تجربی از دقت بالاتری برخوردارند: در گروه معادلات ایجاد شده براساس دما و یا رطوبت نسبی مدل ANN 3 و معادله HS با ریشه میانگین مربعات خطا (RMSE) برابر با ۰/۴۲۳ و ۰/۵۵۱ میلی‌متر بر روز، در گروه معادلات ایجاد شده براساس پارامتر تابش خورشیدی مدل ANN 4 و معادله T با RMSE برابر با ۰/۳۷۲ و ۰/۵۱۸ میلی‌متر بر روز و در گروه سوم که پارامترهای آن مشابه با روش F-P-M بودند مدل ANN 6 و معادله $F-P-M_{RHest}$ با آماره RMSE برابر با ۰/۲۰۸ و ۰/۳۱۰ میلی‌متر بر روز از دقت بالاتری برخوردار بودند.

کلمات کلیدی: تبخیر و تعرق پتانسیل، شبکه‌های عصبی مصنوعی، گرگان، معادلات تجربی، واسنجی

۱ - استادیار گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گلستان - ایران (نویسنده مسئول مکاتبه^{*})!!

۲ - دانشجوی کارشناسی ارشد مهندسی منابع آب، گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گلستان - ایران

۳ - استادیار گروه مهندسی آب، گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گلستان - ایران

۴ - دانشجوی کارشناسی ارشد مهندسی آبخیزداری، گروه مهندسی آبخیزداری، دانشکده منابع طبیعی و علوم دریایی، دانشگاه تربیت مدرس، تهران - ایران

مقدمه

فرآیند تبخیر و تعرق یکی از مؤلفه‌های اصلی چرخه هیدرولوژی است که نقش حیاتی در مطالعات کشاورزی و هواشناسی از جمله طراحی سیستم‌های آبیاری و زهکشی، طراحی مخازن و برنامه‌ریزی آبیاری دارد (۱۱). تخمین بیش از حد آب موردنیاز گیاه ضمن هدر دادن آب آبیاری باعث ماندابی شدن اراضی، شستشوی مواد غذایی خاک و آلوده نمودن منابع آب زیرزمینی می‌شود. از سوی دیگر، تخمین کمتر نیز باعث اعمال تنش رطوبتی به گیاه شده و در نتیجه، کاهش محصول را به همراه خواهد داشت (۶). بنابراین، تعیین نسبتاً دقیق نیاز آبی گیاهان قدم اساسی در پروژه‌های آبیاری و زهکشی به‌شمار می‌رود و لازمه آن محاسبه ET_0 سطوح گیاهی مرجع برای منطقه طرح می‌باشد.

تبخیر و تعرق شامل دو مؤلفه می‌باشد که یکی تبخیر آب از سطوح مختلف شامل سطح خاک مرطوب آبیاری شده، سطح آزاد آب و سطح برگ گیاهان است و دیگری تعرق که خروج بخار آب از برگ گیاهان و ورود آن به هواست (علیزاده، ۱۳۸۴). مقدار ET_0 به طور مستقیم به کمک لایسیمتر اندازه‌گیری می‌شود که دارای دقت بالایی است، اما مستلزم صرف هزینه‌های بالا و زمان طولانی است که همیشه امکان‌پذیر نمی‌باشد (۴).

طی دهه‌های گذشته معادلات تجربی مختلفی نظیر تورنت - وایت (Thornth-Waite)، بلانی - کریدل (Blaney-Criddle)، تورک (Tourc)، مک‌کینک (Makkinc)، پرستلی - تیلور (Priestley and Taylor)، هارگریوز - سامانی (Hargreaves-Samani) و فائو پنمن - مانتیث (FAO Penman-Monteith) جهت تخمین ET_0 با استفاده از پارامترهای هواشناسی ارائه شده است (۲۳). متأسفانه، امکان اندازه‌گیری برخی از پارامترهای آب و هوایی مانند تابش خورشیدی و رطوبت نسبی در اکثر ایستگاه‌های هواشناسی وجود ندارد و این شرایط باعث محدودیت استفاده از برخی معادلات تجربی می‌شود. روشهای

استانداردی جهت تخمین تابش خورشیدی و فشار بخار واقعی موردنیاز معادلات تجربی به کمک داده‌های دمایی در نشریه ۵۶ فائو ارائه شده است (۷).

شبکه‌های عصبی مصنوعی که با الهام از سلول عصبی زیستی طراحی شده‌اند برای تخمین پدیده‌هایی که دارای ارتباطات داخلی پیچیده و غیرخطی باشند به‌کار می‌روند. از دیدگاه ریاضی شبکه عصبی به عنوان یک تقریب‌گر است. توانایی آن در تقریب بین الگوهای یک مساله باعث می‌شود تا بتوان مسایل با پیچیدگی زیاد نظیر شناسایی الگو، تفکیک الگو، نگاشت غیرخطی، حافظه انجمنی، خودسازمان‌دهی و کنترل را انجام دهد.

تحقیقات متعددی در ارتباط با تخمین ET_0 از روی پارامترهای هواشناسی به کمک روشهای هوشمند و معادلات تجربی در نقاط مختلف دنیا انجام گرفته است که از جمله می‌توان به موارد زیر اشاره نمود:

با استفاده از روش عصبی فازی، ET_0 گیاه مرجع چمن را تخمین و خطای آن را برابر $0/48$ میلی‌متر در روز محاسبه شد، درحالی‌که خطای روش F-P-M را برابر $0/56$ میلی‌متر در روز گزارش شده است (۱۸). به منظور برآورد ET_0 در داویس کالیفرنیا، از شبکه عصبی با الگوریتم‌های آموزش مختلف و روش پنمن - مانتیث استفاده شد (۱۵). نتایج آن‌ها نشان داد، شبکه عصبی و روش پنمن مانتیث در مقایسه با داده‌های حاصل از لایسیمتر به ترتیب دارای خطای $0/6$ و $0/97$ میلی‌متر بر روز بودند. برای محاسبه ET_0 از پارامترهای دمای هوا، تابش برون‌زمینی و ساعات آفتابی استفاده و نتایج حاصل رضایت‌بخش توصیف شد (۲۴). جهت تخمین ET_0 از سیستم استنتاج عصبی فازی (ANFIS) استفاده شد (۱۴). در تحقیقی، به جهت تخمین ET_0 از روی داده‌های تشت تبخیر در منطقه صفی‌آباد خوزستان شبکه عصبی مصنوعی به‌کار برده شد و خود ضریب تشت تبخیر را تابعی از پارامترهای دمای حداقل و

لایسیمتر مقایسه شد و به روش رگرسیون فازی، با ضریب تبیین $0/88$ و $RMSE$ برابر $0/74$ میلی متر بر روز نتایج بهتری حاصل گردید (۵). محققین به ارزیابی عملکرد شبکه‌های عصبی مصنوعی در کاهش پارامترهای موردنیاز برای برآورد ET_0 در ایستگاه مهرآباد تهران و مقایسه آن با روشهای F-P-M، بلانی کریدل، جنسن هیز اصلاح شده و هارگریوز سامانی پرداختند (۶). آن‌ها ۱۱ مدل ANN با ساختارهای مختلف از پارامترهای هواشناسی به عنوان ورودی طراحی نمودند. براساس نتایج آن‌ها مدل ANN_3 با چهار پارامتر ورودی (دمای میانگین، رطوبت نسبی، تشعشع خالص و سرعت باد) و مدل ANN_3 با یک پارامتر ورودی (دمای میانگین) بیشترین و کمترین دقت را در برآورد ET_0 داشتند. با استفاده از داده‌های هواشناسی روزانه، مقدار ET_0 را از روشهای ANFIS، ANN و معادلات تجربی F-P-M، HS، T، PT، MK و بلانی کریدل در سه ایستگاه کرمان، یزد و اصفهان محاسبه شد (۱). بر پایه نتایج آن‌ها، معادله بلانی کریدل در هر سه ایستگاه از دقت بالاتری نسبت به سایر معادلات تجربی برخوردار بود. همچنین نتایج مدل‌های ANFIS، ANN نسبت به معادلات تجربی دارای دقت بیشتری بودند.

همان‌طور که ذکر گردید در اکثر ایستگاه‌های هواشناسی تجهیزات موردنیاز جهت اندازه‌گیری پارامترهای معادله F-P-M به عنوان روش استاندارد وجود ندارد، لذا در چنین شرایطی باید از معادلات تجربی دیگر که نیاز به پارامترهای هواشناسی کمتری دارند استفاده شود و یا به کمک روابط تجربی، پارامترهای مورد نیاز این معادلات از روی سایر پارامترهای دسترس برآورد گردد. باتوجه به این که معادلات ET_0 در مناطقی خاص و با شرایط آب و هوایی مربوط به آن محل توسعه داده شده‌اند، لذا لازم است که این معادلات جهت استفاده در مناطق دیگر با استفاده از روشهای استاندارد واسنجی و میزان تأثیر عمل واسنجی در کاهش یا افزایش خطا نیز مورد بررسی قرار گیرد. همچنین باید اثر استفاده از برخی روابط در معادلات تخمینی جهت تخمین پارامترهای تابش خورشیدی و رطوبت نسبی

حداکثر در نظر گرفته شد (۱۹). نتایج نشان داد که مدل ANN نسبت به مدل رایج تشت تبخیر از دقت بالاتری برخوردار است. مقدار ET_0 را با استفاده از لایسیمتر در ۱۱ نقطه جهان با شرایط اقلیمی و آب و هوایی مختلف اندازه‌گیری و نتایج حاصل را با بیش از ۲۰ روش مختلف تجربی مقایسه شد و در تمامی ایستگاه‌ها نتایج F-P-M از دقت بالاتری برخوردار بود (۱۳). مقدار ET_0 به کمک مدل شبکه عصبی محاسبه شد و ضمن تأیید کارایی شبکه‌های عصبی در تخمین این پدیده، نشان دادند شبکه‌های عصبی قادرند با استفاده از داده‌های محدود آب و هوایی نیز این پدیده را با دقت مناسبی برآورد نمایند (۱۲). با طراحی هفت مدل ANN با ساختارهای متفاوت از پارامترهای ورودی به مقایسه این مدل‌ها با ۱۰ مدل تجربی واسنجی شده در منطقه باسک اسپانیا پرداختند (۱۶). بر پایه این تحقیق‌ها، نتایج شبکه عصبی نسبت به مدل‌های تجربی واسنجی شده از دقت بیشتری برخوردار بود و مدل ANN_6 با پارامترهای نظیر دمای حداکثر، دمای حداقل، دمای میانگین، تابش خورشیدی، تابش برون‌زمینی و سرعت باد با $RMSE$ برابر با $0/238$ میلی متر بر روز از میان ۱۷ مدل مورد بررسی، دارای خطای کمتری بود. برای محاسبه ET_0 در منطقه پولیکارو (ایتالیا) از شبکه تابع پایه شعاعی (RBF) و روشهای کریستیانسن (Christiansen)، پنمن و F-P-M استفاده شد (۲۲). وی نشان داد که شبکه تابع پایه شعاعی در مقایسه با نتایج حاصل از لایسیمتر وزنی نسبت به سایر روشها از خطای کمتری برخوردار است. جهت تخمین ET_0 در هفت ایستگاه در ناحیه اطراف خزر از سه پارامتر دمای حداکثر، حداقل و تابش برون‌زمینی به عنوان ورودی در شبکه عصبی استفاده و به مقایسه نتایج آن‌ها مدل تجربی هارگریوز - سامانی پرداخته شد (۱۹). نتایج نشان داد که مدل شبکه عصبی نسبت به مدل هارگریوز از دقت بالاتری برخوردار است. با استفاده از اطلاعات پنج ساله اقلیمی و لایسیمتری ایستگاه اکباتان همدان، ET_0 را به سه روش رگرسیون فازی، شبکه عصبی مصنوعی و F-P-M محاسبه و با داده‌های حاصل از

مواد و روشها

موقعیت منطقه و داده‌های مورد استفاده

برای انجام این تحقیق، از داده‌های روزانه ایستگاه سینوپتیک گرگان در استان گلستان با ارتفاع ۱۳/۳ متر از سطح دریا، مختصات جغرافیایی طول ۵۴ درجه و ۱۶ دقیقه شرقی، عرض ۳۶ درجه و ۵۱ دقیقه شمالی استفاده شده است. داده‌های مورد استفاده شامل دمای حداکثر (T_{max})، دمای حداقل (T_{min})، رطوبت نسبی (RH)، ساعات آفتابی (n) و سرعت باد در ارتفاع ۱۰ متری (U_{10}) به صورت روزانه از ابتدای سال ۱۳۷۱ شمسی تا پایان سال ۱۳۸۶ می‌باشند که از سازمان هواشناسی کشور اخذ گردید. برخی از خصوصیات آماری داده‌های مورد استفاده در طول دوره آماری در جدول (۱) آورده شده است.

موردنیاز معادلات تجربی از روی پارامترهای دمایی مورد ارزیابی قرار گیرد. از طرفی، باتوجه به توانایی شبکه عصبی در مدل‌سازی پدیده‌های پیچیده و غیرخطی، توانایی آن در شرایط مختلف کمبود پارامترهای هواشناسی جهت تخمین ET_0 با معادلات تجربی و تخمینی مقایسه گردد. بنابراین هدف این تحقیق، مدل‌سازی ET_0 روزانه با استفاده از شبکه‌های عصبی مصنوعی و مقایسه با معادلات مختلف تجربی و تخمینی واسنجی شده در شرایط گوناگون کمبود پارامترهای هواشناسی در گروه‌های سه‌گانه تعریف شده در ایستگاه سینوپتیک گرگان می‌باشد.

جدول ۱ - برخی از پارامترهای آماری داده‌های مورد استفاده در طول دوره آماری ۱۳۷۱ الی ۱۳۸۶

پارامتر	دمای حداکثر	دمای حداقل	رطوبت نسبی	ساعات آفتابی	سرعت باد (U_2)
حداکثر	۴۵/۰۰	۲۸/۸۰	۹۸/۴۰	۱۳/۹۰	۸/۶۰
حداقل	۱/۲۰	-۴/۸۰	۲۵/۳۰	۰	۰
میانگین	۲۳/۰۵	۱۲/۸۱	۷۳/۶۳	۶/۱۵	۱/۳۲
انحراف معیار	۸/۶۷	۷/۸۸	۱۰/۴۹	۴/۲۱	۰/۹۸
ضریب تغییرات	۰/۳۸	۰/۶۲	۰/۱۴	۰/۶۸	۰/۷۴
چولگی	-۰/۱۴	-۰/۰۱	-۰/۴۱	-۰/۱۶	۱/۲۲

معادلات برآورد تبخیر و تعرق پتانسیل

محاسبه پارامترهای معادلات ET_0

روش محاسبه پارامترهای موردنیاز معادلات مختلف تبخیر و تعرق پتانسیل ارائه شده در جدول (۲)، براساس معادلات نشریه شماره ۵۶ فائو می‌باشد. در این تحقیق، به‌علت عدم اندازه‌گیری داده‌های تابش خورشیدی، مقادیر آن مطابق با روش

پیشنهاد شده توسط آلن در رابطه (۱) با استفاده از مقادیر ساعات آفتابی اندازه‌گیری شده، محاسبه شده است. در رابطه زیر، ضرایب تجربی a و b به‌ترتیب برابر ۰/۲۵ و ۰/۵۰ توصیه شده‌اند:

$$R_s = \left(a + b \left(\frac{n}{N} \right) \right) R_a \quad (1)$$

جدول ۲ - روابط ریاضی و علائم اختصاری معادلات مختلف تجربی و تخمینی جهت برآورد تبخیر و تعرق پتانسیل گیاه مرجع

گروه	معادله	علامت اختصاری	پارامترهای تخمینی	روابط ریاضی برآورد ET_0
روش استاندارد	فائو پنمن - مانتیث	F-P-M	-	$F - P - M = \frac{0.408 \Delta (R_n - G) + \gamma (900 / (T + 273)) U_2 (e_a - e_d)}{\Delta + \gamma (1 + 0.34 U_2)}$
	هارگریوز - سامانی	HS	-	$HS = 0.0023 \frac{R_a}{\lambda} (T_{mean} + 17.8) \sqrt{T_{max} - T_{min}}$
	پریستلی - تیلور	PT	-	$PT = \frac{a}{\lambda} \frac{\Delta}{\Delta + \gamma} (R_n - G)$
معادلات تجربی	مک کینگ	MK	-	$MK = 0.61 \frac{\Delta}{\Delta + \gamma} \frac{R_s}{\lambda} - 0.12$
	تورک	T	-	$T = a_T 0.013 \frac{T_{mean}}{T_{mean} + 15} + \frac{23.8856 R_s + 50}{\lambda}$ $RH \geq 50 \rightarrow a_T = 1$ $RH < 50 \rightarrow a_T = 1 + \frac{50 - RH}{70}$
معادلات تخمینی	فائو پنمن - مانتیث	F-P-M _{Rsest}	تابش خورشیدی	$R_{sest} = 0.16 R_a \sqrt{T_{max} - T_{min}}$
	تورک	T _{Rsest}	تابش خورشیدی	
	مک کینگ	MK _{Rsest}	تابش خورشیدی	
	پریستلی - تیلور	PT _{Rsest}	تابش خورشیدی	
	فائو پنمن - مانتیث	F-P-M _{RHest}	رطوبت نسبی	$e_a = \frac{RH}{100} \left[\frac{e_s(T_{min}) + e_s(T_{max})}{2} \right]$
	فائو پنمن - مانتیث	F-P-M _{RsRHest}	تابش خورشیدی و رطوبت نسبی	$e_a = 0.611 \exp \frac{17.27 T_{min}}{T_{min} + 237.3}$

پارامترهای به کار رفته در جدول فوق به شرح زیر می‌باشند:

T_{min} حداقل دمای روزانه ($^{\circ}C$)، T_{max} حداکثر دمای روزانه ($^{\circ}C$)، T_{mean} میانگین دمای روزانه ($^{\circ}C$)، N_m ضریب اصلاحی (تابعی از طول جغرافیایی منطقه و ماه مورد نظر)، I شاخص حرارتی سالیانه، n شماره ماه‌های سال، a (تابعی از شاخص حرارتی سالیانه)، λ گرمای نهان تبخیر ($MJkg^{-1}$)، Δ شیب منحنی فشار بخار اشباع ($kPaC^{-1}$)، R_n تابش خالص در سطح پوشش گیاهی ($MJm^{-2} d^{-1}$)، G چگالی شار گرمای خاک ($MJm^{-2} d^{-1}$)، R_s تابش خورشیدی روزانه ($MJm^{-2} d^{-1}$)، R_a تابش برون‌زمینی ($MJm^{-2} d^{-1}$)، ضریب α برابر $1/26$ ، γ ضریب سایکرومتری رطوبتی ($kPaC^{-1}$)، u_2 سرعت باد در ارتفاع دو متری (ms^{-1})، e_s فشار بخار اشباع (kPa)، e_a فشار بخار واقعی (kPa)، e_{sTmin} فشار بخار اشباع در دمای حداقل روزانه (kPa)، e_{sTmax} فشار بخار اشباع در دمای حداکثر روزانه (kPa) و RH متوسط رطوبت نسبی روزانه (%)

عدم اندازه‌گیری داده‌های تابش خورشیدی مقادیر آن از روی داده‌های دمایی محاسبه شده‌اند. همچنین معادلات F-P-M_{RHest} و F-P-M_{RsRHest} اشکال تغییر یافته معادله F-P-M می‌باشند که

در جدول (۲)، معادلات F-P-M_{Rsest}، T_{Rsest}، MK_{Rsest} و PT_{Rsest} به ترتیب شکل‌های تغییر یافته معادلات تجربی F-P-M، T، MK و PT می‌باشند که در معادلات آن‌ها با فرض

می‌تواند یک نگاشت یا تبدیل از فضای چندبعدی به یک فضای چندبعدی دیگر انجام دهد، صورت گرفته است. شبکه‌های عصبی براساس ارتباطات داخلی بسیار گسترده، همانند سیستم عصبی و مغز انسان بنا نهاده شده‌اند که با تعدادی لایه، به وسیله گره‌ها یا نرون‌ها به‌طور کامل به هم متصل می‌شوند. رایج‌ترین نوع ANNs دارای سه یا چند لایه می‌باشد. یک لایه ورودی که از طریق آن اطلاعات به شبکه وارد می‌شود، یک لایه خروجی که برای تولید پاسخ مناسب به ورودی‌های داده شده به شبکه به‌کار می‌رود و یک یا چند لایه میانی که به عنوان مجموعه‌ای از آشکارسازهای روابط درونی بین متغیرهای ورودی و خروجی عمل می‌کنند. شبکه‌های عصبی توانایی خود برای پردازش اطلاعات را از طریق فرایند یادگیری به دست می‌آورند که این فرآیند از طریق تنظیم وزن‌های بین پیوندگاه‌های لایه‌های شبکه در جهت نزدیک نمودن خروجی‌های شبکه به خروجی‌های واقعی انجام می‌گیرد. این نوع شبکه را پرسپترون چند لایه (MLP) می‌نامند (۱۰).

گروه‌بندی معادلات و مدل‌های مختلف

در این تحقیق، مدل‌های مختلف ANNs، معادلات تجربی و تخمینی را براساس پارامترهای هواشناسی مورد نیاز جهت محاسبه ET_0 در سه گروه تقسیم‌بندی شدند. در گروه اول، مدل‌ها و معادلاتی قرار دارند که ورودی‌های آن‌ها براساس پارامترهای دما و یا رطوبت نسبی استوار است. معادلات این گروه می‌توانند در اکثر ایستگاه‌های تبخیرسنجی و هواشناسی که این داده‌ها برداشت می‌شوند به‌کار روند. گروه دوم، مدل‌ها و معادلاتی را شامل می‌شود که علاوه بر دما و یا رطوبت نسبی نیازمند پارامتر تابش خورشیدی برای محاسبه ET_0 هستند. این گروه معادلات در ایستگاه‌هایی با امکانات بیشتر که پارامترهای تابش خورشیدی یا ساعات آفتابی اندازه‌گیری می‌شوند، به‌کار می‌روند. در گروه سوم، معادلات تخمینی قرار دارند که دارای پارامترهای مشابه با معادله F-P-M می‌باشند با این تفاوت که یک یا هر دو پارامتر تابش خورشیدی و یا رطوبت نسبی براساس پارامترهای دمایی برآورد شده‌اند. معادلات این گروه

در آن با فرض عدم وجود داده‌های رطوبت نسبی و یا تابش خورشیدی، مقادیر آن‌ها از روی داده‌های دمایی محاسبه و در معادله F-P-M جایگزین شده‌اند.

به‌منظور افزایش کارایی و کاهش خطای معادلات برآورد ET_0 ، می‌توان با استفاده از روشهای استاندارد مانند معادله F-P-M و یا از روی داده‌های لایسیمیتری آن‌ها را برای هر منطقه واسنجی نمود (۱۶).

$$ET_0 = a + b ET_{Model} \quad (۲)$$

در این رابطه، ET_0 تبخیر و تعرق استاندارد است که از روش F-P-M محاسبه می‌شود، E_{Model} تبخیر و تعرق محاسبه شده از معادلات تجربی و تخمینی، a و b ضرایب رگرسیون خطی می‌باشند که هرچه b به سمت واحد و a به سمت صفر میل کند و ضریب تبیین به سمت واحد میل کند، نشان‌دهنده دقت بیشتر و خوب بودن مدل است.

انتخاب پارامترهای ورودی مدل‌های ANNs

در این تحقیق، هفت مدل شبکه عصبی مصنوعی با ساختارهای مختلف از پارامترهای هواشناسی به عنوان ورودی تعریف گردید. نحوه انتخاب ترکیب پارامترهای هر مدل براساس ورودی‌های مورد نیاز معادلات تجربی و تخمینی تعریف شده است، به‌طوری‌که هر کدام از شبکه‌های ساخته شده براساس شباهت در پارامترهای ورودی می‌توانند با یک یا چند معادله تجربی و تخمینی مقایسه شوند. در جدول (۳) پارامترهای هواشناسی ورودی مدل‌های مختلف ANNs آورده شده است.

شبکه‌های عصبی مصنوعی

آغاز نظریه شبکه‌های عصبی مصنوعی تقریباً به دهه ۴۰ میلادی برمی‌گردد، زمانی که مک‌کلاچ (McCulloch) روان‌شناس معروف و والتر پیترز (Walter Pitts) ریاضی‌دان در سال ۱۹۴۳ آن را پایه‌گذاری کردند. نخستین کاربرد عملی AANNs توسط روزنبلات (Rosenblatt) در سال ۱۹۵۸، با معرفی شبکه‌های چند لایه پرسپترون انجام شد. پس از آن، مطالعات زیادی روی توانایی شبکه‌های عصبی به عنوان یک ابزار محاسباتی که

دهقانی و همکاران: واسنجی معادلات تجربی تبخیر و تعرق روزانه و مقایسه با نتایج ...

نیازمند داده‌های سرعت باد می‌باشند. گروه‌بندی معادلات و محاسبه ET_0 در جدول (۴) آورده شده است. مدل‌های مختلف براساس پارامترهای هواشناسی موردنیاز جهت

جدول ۳ - پارامترهای هواشناسی ورودی به‌کار رفته در ساختار مدل‌های مختلف ANNs

نام مدل	پارامترهای هواشناسی ورودی
ANN1	$T_{min}, T_{max}, T_{mean}, R_a$
ANN2	$T_{min}, T_{max}, T_{mean}, R_a, R_s$
ANN3	$T_{min}, T_{max}, T_{mean}, R_a, RH$
ANN4	$T_{min}, T_{max}, T_{mean}, R_a, R_s, RH$
ANN5	$T_{min}, T_{max}, T_{mean}, R_a, RH, u_2$
ANN6	$T_{min}, T_{max}, T_{mean}, R_a, R_s, u_2$
ANN7	$T_{min}, T_{max}, T_{mean}, R_a, u_2$

جدول ۴ - تقسیم‌بندی معادلات و مدل‌های مختلف براساس پارامترهای هواشناسی موردنیاز جهت محاسبه ET_0

گروه	مدل	پارامترهای بردار ورودی	پارامترهای هواشناسی مورد نیاز
مدل‌ها و معادلات مبتنی بر پارامترهای دما و یا رطوبت	ANN1	$T_{min}, T_{max}, T_{mean}, R_a$	$T_{min}, T_{max}, T_{mean}$
	$PT_{R_{srest}}$	$T_{min}, T_{max}, T_{mean}$	$T_{min}, T_{max}, T_{mean}$
	$MK_{R_{srest}}$	$T_{min}, T_{max}, T_{mean}$	$T_{min}, T_{max}, T_{mean}$
	HS	$T_{min}, T_{max}, T_{mean}, R_a$	$T_{min}, T_{max}, T_{mean}$
	ANN3	$T_{min}, T_{max}, T_{mean}, RH, R_a$	$T_{min}, T_{max}, T_{mean}, RH$
	$T_{R_{srest}}$	$T_{min}, T_{max}, T_{mean}, RH, R_a$	$T_{min}, T_{max}, T_{mean}, RH$
مدل‌ها و معادلات مبتنی بر پارامتر تابش خورشیدی	ANN2	$T_{min}, T_{max}, T_{mean}, R_s, R_a$	$T_{min}, T_{max}, T_{mean}, R_s$
	PT	$T_{min}, T_{max}, T_{mean}, R_s$	$T_{min}, T_{max}, T_{mean}, R_s$
	MK	$T_{min}, T_{max}, T_{mean}, R_s$	$T_{min}, T_{max}, T_{mean}, R_s$
	ANN4	$T_{min}, T_{max}, T_{mean}, R_s, RH, R_a$	$T_{min}, T_{max}, T_{mean}, R_s, RH$
مدل‌ها و معادلات مبتنی بر پارامترهای روش F-P-M	T	$T_{min}, T_{max}, T_{mean}, R_s, RH$	$T_{min}, T_{max}, T_{mean}, R_s, RH$
	ANN5	$T_{min}, T_{max}, T_{mean}, u_2, RH, R_a$	$T_{min}, T_{max}, T_{mean}, u_2, RH$
	$F-P-M_{R_{srest}}$	$T_{min}, T_{max}, T_{mean}, u_2, RH, R_a$	$T_{min}, T_{max}, T_{mean}, u_2, RH$
	ANN6	$T_{min}, T_{max}, T_{mean}, u_2, R_s, R_a$	$T_{min}, T_{max}, T_{mean}, u_2, R_s$
	$F-P-M_{RH_{srest}}$	$T_{min}, T_{max}, T_{mean}, u_2, R_s, R_a$	$T_{min}, T_{max}, T_{mean}, u_2, R_s$
	ANN7	$T_{min}, T_{max}, T_{mean}, u_2, R_a$	$T_{min}, T_{max}, T_{mean}, u_2$
	$F-P-M_{R_sRH_{srest}}$	$T_{min}, T_{max}, T_{mean}, u_2, R_a$	$T_{min}, T_{max}, T_{mean}, u_2$

آماره‌های ارزیابی

نتایج و بحث

روش F-P-M به عنوان تنها روش استاندارد برای محاسبه ET₀ گیاه مرجع از روی داده‌های اقلیمی و همچنین برای ارزیابی سایر روشها از سوی کمیسیون بین‌المللی آبیاری و زهکشی (ICID) و سازمان خواروبار جهانی (FAO) در سال ۱۹۹۰ پیشنهاد شده است (۸). در این تحقیق، به علت عدم وجود داده‌های لایسیمتری در ایستگاه مورد تحقیق، مقادیر ET₀ روزانه محاسبه شده از مدل‌ها و معادلات مختلف (E_{Modeli}) با مقادیر واقعی F-P-M به عنوان روش مرجع از طریق معیارهای آماری RMSE، MBE و R² مقایسه می‌گردند. جهت مقایسه مدل‌ها با هم، آماره ریشه متوسط مجذور خطا (RMSE) و ضریب تبیین (R²)، از اولویت برخوردارند. برای درک میزان درصد خطای مدل‌ها، آماره‌های میانگین و انحراف معیار نسبت E_{Model} به F-P-M نیز در جدول‌های مقایسه آورده شده است.

$$MBE = \frac{\sum_{i=1}^n (E_{Modeli} - E_{FPMi})}{n} \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (E_{Modeli} - E_{FPMi})^2}{n}} \quad (4)$$

همچنین برای سنجش میزان تأثیر عمل واسنجی با محاسبه مقادیر میانگین مربعات خطا برای معادلات ET₀ با عمل واسنجی ETO Calibrated RMSE و بدون عمل واسنجی ETO not Calibrated RMSE در دوره ۱۳۸۲ الی ۱۳۸۶ از رابطه زیر استفاده شده است:

$$RaRMSE = 1 - \frac{RMSE_{ET_0 \text{ Calibrated}}}{RMSE_{ET_0 \text{ not Calibrated}}} \quad (5)$$

در این رابطه، مقادیر مثبت RaRMSE نشان‌دهنده بهبود عملکرد و افزایش کارایی معادلات ET₀ در اثر عمل واسنجی است و مقادیر منفی نشان‌دهنده آن است که عمل واسنجی سبب کاهش کارایی و افزایش خطا شده است (۱۶).

نتایج واسنجی معادلات ET₀ در دوره ۱۳۷۱ الی ۱۳۸۱

با استفاده از آمار پارامترهای هواشناسی مقادیر ET₀ از معادلات مختلف تجربی و تخمینی در دوره ۱۳۷۱ الی ۱۳۸۱ محاسبه و با مرجع قرار دادن روش F-P-M معادلات تجربی و تخمینی با استفاده از رابطه (۲) واسنجی و ضرایب رگرسیون خطی محاسبه گردید که این ضرایب برای معادلات مختلف ET₀ در جدول (۵) آمده است.

با محاسبه مقادیر RMSE برای معادلات ET₀ بدون عمل واسنجی و با عمل واسنجی در دوره ۱۳۸۲ الی ۱۳۸۶، درصد میزان تأثیر عمل واسنجی بر کارایی عملکرد معادلات تبخیر و تعرق پتانسیل محاسبه شده است (شکل ۱). نتایج نشان داد که به‌طور کلی انجام عمل واسنجی سبب بهبود کارایی اکثر معادلات تجربی و تخمینی شده است، به‌طوری‌که معادلات T و T_{Rsest} به‌ترتیب با مقادیر ۷۲/۵۸ و ۶۷/۲۷ درصد بیشترین افزایش کارایی داشتند و معادلات PT_{Rsest} و PT به‌ترتیب با مقادیر ۱/۶۲- و ۴/۵۵- درصد، عمل واسنجی سبب کاهش کارایی در آن‌ها گردید (شکل ۱). همچنین عمل واسنجی سبب افزایش ناچیزی به مقدار ۰/۵۳ درصد افزایش عملکرد (کاهش خطا) در معادله F-P-M_{Rsest} شده است.

نتایج حاصل از آزمون مدل‌های مختلف ANNs


برای آموزش و آزمون مدل‌های مختلف ANNs ایجاد شده با تقسیم مجموعه داده‌های روزانه در دوره (۱۳۷۱ الی ۱۳۸۶) به دو دسته آموزش (۱۳۷۱ الی ۱۳۸۱) مجموعاً تعداد ۴۰۱۸ الگو و آزمون (۱۳۸۲ الی ۱۳۸۶) مجموعاً تعداد ۱۸۲۵ الگو با استفاده از شبکه عصبی پرسپترون چند لایه با الگوریتم پس‌انتشار خطا با توجه به مدل‌های مختلف در شبکه‌های تعریف شده از چهار تا هفت نرون در لایه ورودی و یک نرون در لایه خروجی استفاده شد. محققان مختلفی در بسیاری از کارهای تجربی و تئوری خود نشان دادند که استفاده از یک لایه پنهان برای تخمین هر نوع تابع پیچیده غیرخطی کفایت می‌کند (۱۷). مهم‌ترین دلیل درستی این نظریه را در عدم ارتباط مستقیم

افزودن نرون‌های اضافی تا زمانی ادامه داشت که افزایش نرون‌های بیشتر تأثیری در بهبود خطا نداشته باشند. بدین‌منظور از دو تا ۲۰ نرون در لایه پنهان استفاده گردید. جدول (۶) ساختار مدل و نتایج حاصل از به‌کارگیری مدل‌های مختلف ANNs را برای دوره آزمون نشان می‌دهد.

لایه‌های نهانی با خروجی‌های شبکه ارتباط دادند. بنابراین در این تحقیق، به‌منظور طراحی بهینه ساختار شبکه عصبی، با استفاده از یک لایه میانی و توابع تحریک مختلف تانژانت سیگموئید و لوگ سیگموئید آموزش شبکه‌ها از تعداد نرون‌های متفاوتی استفاده شده و تعداد بهینه آن‌ها برای حداقل نمودن خطا تعیین گردیده است. روند کار با تعداد نرون‌های کم آغاز و

جدول ۵ - پارامترهای رگرسیون خطی برای واسنجی معادلات ET_۰ دوره ۱۳۷۱ الی ۱۳۸۱

مدل	شیب	ضریب ثابت	ضریب تبیین	خطای استاندارد (S.E)
HS	۰/۹۱۶	-۰/۲۳۶	۰/۸۹۹	۰/۵۵۹
PT	۰/۸۹۰	-۰/۱۷۶	۰/۹۳۳	۰/۴۵۶
MK	۱/۱۵۴	-۰/۰۲۶	۰/۹۰۳	۰/۵۴۸
T	۲/۴۴۷	-۰/۱۴۶	۰/۹۲۰	۰/۴۹۹
F-P-M _{Rsest}	۱/۰۵۳	-۰/۱۰۰	۰/۹۵۶	۰/۳۷۱
E _{TRsest}	۲/۷۰۲	-۰/۳۷۷	۰/۸۸۰	۰/۶۰۱
MK _{Rsest}	۱/۳۱۷	-۰/۳۳۸	۰/۸۷۷	۰/۶۱۹
PT _{Rsest}	۰/۹۵۷	۰/۰۳۵	۰/۸۷۹	۰/۶۱۲
F-P-M _{RRHest}	۱/۰۷۷	-۰/۰۸۴	۰/۹۸۳	۰/۲۲۹
F-P-M _{RsRRHest}	۱/۱۳۲	-۰/۱۷۸	۰/۹۲۷	۰/۴۷۳



شکل ۱ - درصد مقدار تأثیر عمل واسنجی بر عملکرد معادلات ET_۰ در دوره ۱۳۸۲-۸۶

جدول ۶ - نتایج آزمون و ساختار مدل‌های مختلف ANNs در دوره ۱۳۸۲ الی ۱۳۸۶

E _{model} /F-P-M		R ²	RMSE	MBE	تابع محرک	ساختار مدل*	مدل
انحراف معیار	میانگین						
۰/۱۶۳	۰/۹۵۷	۰/۹۳۵	۰/۴۸۶	-۰/۱۵۲	تانزانته سیگموئید	۱-۵-۴	ANN1
۰/۱۳۵	۰/۹۵۲	۰/۹۶۳	۰/۴۰۸	-۰/۱۹۱	تانزانته سیگموئید	۱-۶-۵	ANN2
۰/۱۴۴	۰/۹۵۲	۰/۹۴۸	۰/۴۲۳	-۰/۱۱۵	لوگ سیگموئید	۱-۳-۵	ANN3
۰/۱۱۸	۰/۹۴۵	۰/۹۷۲	۰/۳۷۲	-۰/۱۹۵	لوگ سیگموئید	۱-۴-۶	ANN4
۰/۱۰۱	۱/۰۱۰	۰/۹۷۱	۰/۳۳۴	۰/۰۶۴	تانزانته سیگموئید	۱-۹-۶	ANN5
۰/۰۸۷	۱/۰۱۷	۰/۹۸۷	۰/۲۰۸	۰/۰۲۸	تانزانته سیگموئید	۱-۱۰-۶	ANN6
۰/۱۴۸	۱/۰۴۰	۰/۹۵۳	۰/۴۳۹	۰/۱۳۲	تانزانته سیگموئید	۱-۱۳-۵	ANN7

* - پارامترهای ورودی، تعداد نرون، پارامتر خروجی

خورشیدی آن‌ها با برخی روابط تجربی از روی داده‌های دمایی محاسبه شده‌اند. در این گروه، بهترین مدل ANN6 می‌باشد که دارای RMSE برابر با ۰/۲۳۸ میلی‌متر بر روز است. همچنین معادله F-P-M_{RHest} با RMSE برابر با ۰/۳۱۰ میلی‌متر بر روز دارای دقت بیشتری بود. به‌منظور مقایسه بهتر نتایج، مقادیر محاسبه شده توسط بهترین مدل ANNs و بهترین معادله برآورد ET_o در هر گروه در مقابل مقادیر مشاهده شده حول خط ۱:۱ در شکل (۲) ترسیم شده است.

نتیجه‌گیری

نتایج حاصل از واسنجی معادلات تجربی و تخمینی به‌جز در معادلات PT و PT_{Rsest} تا حدود زیادی سبب افزایش کارایی و کاهش خطای معادلات برآورد ET_o گردید، هرچند این افزایش عملکرد در معادلات مختلف متفاوت به‌دست آمد. این مطلب مؤید آن است که با توجه به آن‌که معادلات مختلف در شرایط آب و هوایی خاصی توسعه یافتند، لذا برای دست‌یابی به نتایج مطلوب باید با استفاده از روشهای استاندارد برای هر منطقه واسنجی و آن‌گاه مورد استفاده قرار گیرند.

مدل‌های مختلف شبکه عصبی در هر سه گروه تعریف شده نسبت به معادلات مختلف تجربی و تخمینی واسنجی شده از دقت بالاتری برخوردارند و به‌طورکلی، با افزایش پارامترهای ورودی در این شبکه‌ها دقت مدل‌ها جهت تخمین ET_o افزایش می‌یابد.

نتایج حاصل از مقایسه مدل‌های مختلف ANNs و معادلات برآورد ET_o در گروه‌های سه‌گانه

نتایج عملکرد مدل‌های ANNs و معادلات ET_o با آماره‌های مختلف خطا در گروه‌های سه‌گانه در جدول (۷) ارائه شده است. نتایج حاصل از آن نشان می‌دهد که در هر گروه، مدل‌های مختلف ANNs نسبت به معادلات مختلف تجربی و تخمینی واسنجی شده از دقت بالاتری برخوردارند. به‌طورکلی، با افزایش پارامترهای ورودی دقت مدل‌ها و معادلات جهت تخمین ET_o افزایش می‌یابد.

در گروه اول که مبتنی بر پارامترهای دما و یا رطوبت نسبی‌اند، بهترین مدل برای تخمین ET_o مدل ANN3 می‌باشد که دارای RMSE برابر با ۰/۴۲۳ میلی‌متر بر روز است. همچنین در این گروه، معادله واسنجی شده HS با RMSE برابر با ۰/۵۵۱ میلی‌متر بر روز تخمین بهتری از ET_o نسبت به سایر معادلات این گروه به‌دست می‌دهد.

در گروه دوم که معادلات و مدل‌های آن نیازمند داده‌های تابش خورشیدی می‌باشند، مدل ANN4 با کم‌ترین RMSE به میزان ۰/۳۷۲ میلی‌متر بر روز از دقت بالاتری برخوردار است. ضمن آن‌که مدل T واسنجی شده با مقدار RMSE برابر با ۰/۴۰۸ میلی‌متر نتایج بهتری از ET_o ارائه می‌کند.

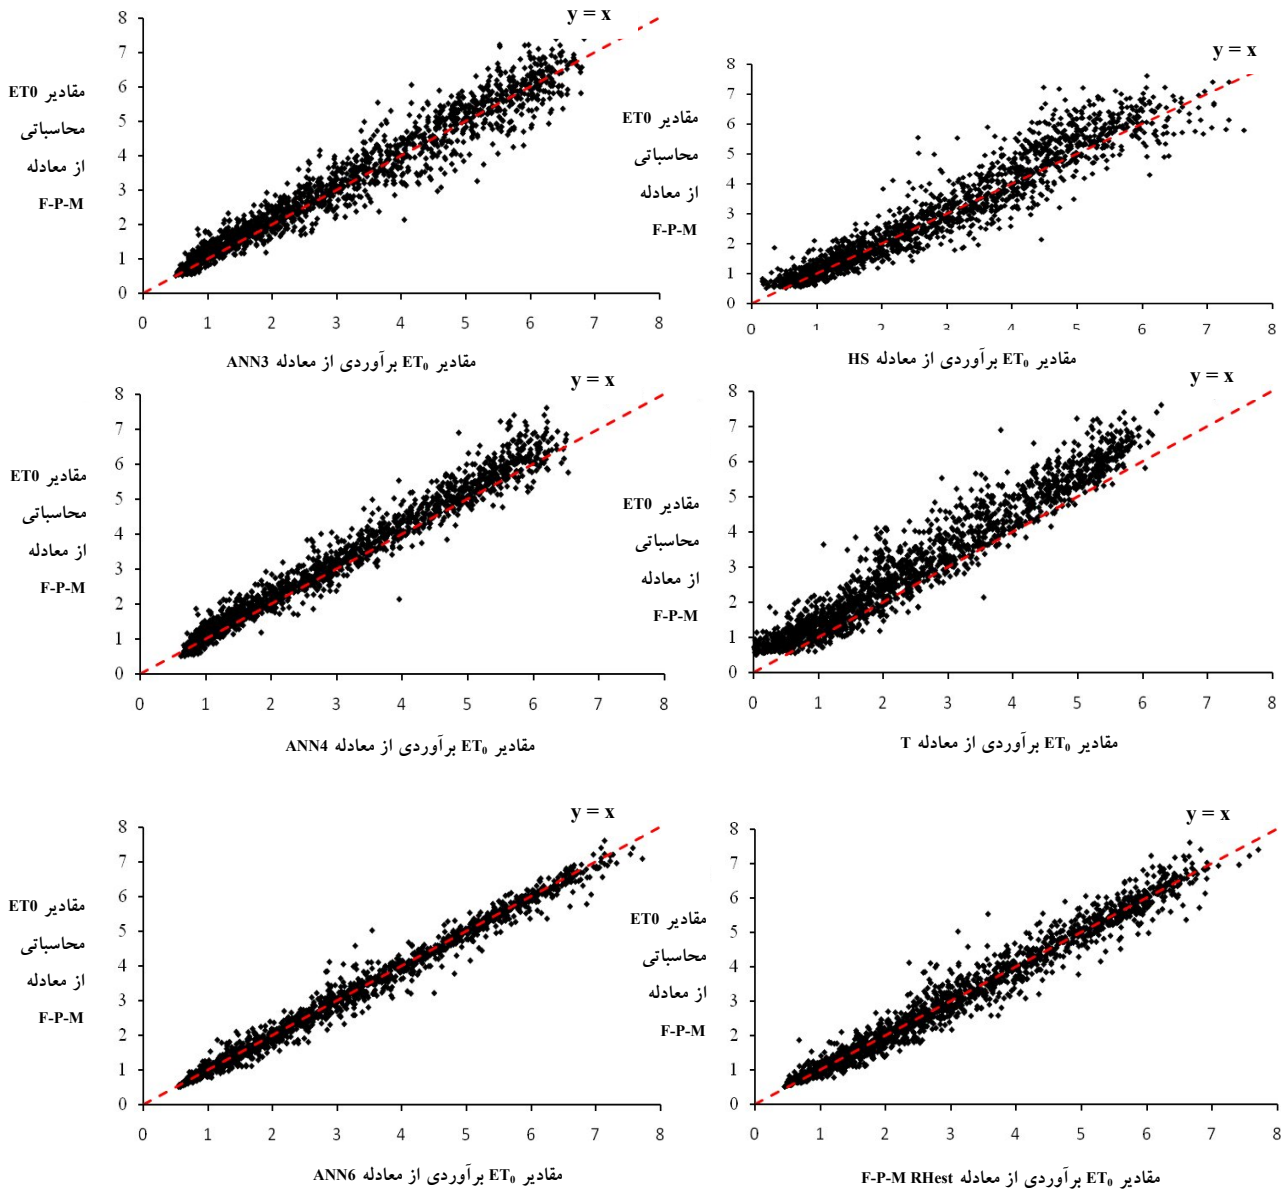
گروه سوم دربردارنده معادلاتی است که نیازمند پارامتر سرعت باد می‌باشند. معادلات این گروه مشابه معادله F-P-M هستند با این تفاوت که پارامترهای رطوبت نسبی و تابش

جدول ۷ - نتایج عملکرد مدل‌های ANNs و معادلات ET_o با آماره‌های مختلف خطا در گروه‌های سه‌گانه در دوره ۱۳۸۲ الی ۱۳۸۶

گروه	مدل	MBE	RMSE	R ²	E _{model} /F-P-M	
					میانگین	انحراف معیار
مدل‌ها و معادلات مبتنی بر پارامترهای دما یا رطوبت	ANN3	-۰/۱۱۵	۰/۴۲۳	۰/۹۴۸	۰/۹۵۲	۰/۱۴۴
	ANN1	-۰/۱۵۲	۰/۴۸۶	۰/۹۳۵	۰/۹۵۷	۰/۱۶۳
	HS	-۰/۱۴۲	۰/۵۵۱	۰/۹۱۵	۰/۹۶۵	۰/۱۹۹
	MK _{Rsest}	-۰/۲۱۷	۰/۵۸۱	۰/۹۱۵	۰/۹۶۲	۰/۲۵۹
	T _{Rsest}	-۰/۱۴۸	۰/۵۹۹	۰/۹۰۰	۰/۹۶۲	۰/۲۲۸
	PT _{Rsest}	۰/۱۵۱	۰/۶۶۶	۰/۸۷۴	۱/۱۳۶	۰/۲۸۸
مدل‌ها و معادلات مبتنی بر پارامتر تابش خورشیدی	ANN4	-۰/۱۹۵	۰/۳۷۲	۰/۹۷۲	۰/۹۴۵	۰/۱۱۸
	ANN2	-۰/۱۹۱	۰/۴۰۸	۰/۹۶۳	۰/۹۵۲	۰/۱۳۵
	T	-۰/۲۱۴	۰/۵۱۸	۰/۹۳۹	۰/۹۵۰	۰/۱۸۱
	MK	-۰/۲۱۷	۰/۵۸۱	۰/۹۱۵	۰/۹۶۲	۰/۲۵۹
	PT	-۰/۵۲۶	۰/۶۹۹	۰/۹۳۴	۰/۷۷۹	۰/۲۲۵
	ANN6	۰/۰۲۸	۰/۲۰۸	۰/۹۸۷	۱/۰۱۷	۰/۰۸۷
مدل‌ها و معادلات مشقت شده از F-P-M	F-P-M _{RRHest}	-۰/۰۰۸	۰/۳۱۰	۰/۹۷۱	۱/۰۰۶	۰/۱۲۰
	ANN5	۰/۰۶۴	۰/۳۳۴	۰/۹۷۱	۱/۰۱۰	۰/۱۰۱
	ANN7	۰/۱۳۲	۰/۴۳۹	۰/۹۵۳	۱/۰۴۰	۰/۱۴۸
	F-P-M _{Rsest}	۰/۰۴۹	۰/۳۶۶	۰/۹۶۱	۱/۰۱۹	۰/۱۱۷
	F-P-M _{RRsRHest}	۰/۰۴۵	۰/۵۲۱	۰/۹۲۰	۱/۰۳۰	۰/۱۸۷

نتایج معادلات تجربی و تخمینی واسنجی شده، در شرایط مختلف کمبود پارامترهای سرعت باد، تابش خورشیدی و رطوبت نسبی قابل تعمیم به مناطق هم‌اقلیم که دارای شرایط آب و هوایی مشابه با ایستگاه مورد مطالعه هستند می‌باشند. به عنوان مثال، در ایستگاه‌های تبخیرسنجی که معمولاً داده‌های دما و رطوبت اندازه‌گیری می‌شود (معادلات گروه ۱) یا ایستگاه‌هایی با تجهیزات بیشتر که تابش خورشیدی یا ساعات آفتابی اندازه‌گیری می‌شود (معادلات گروه ۲) به‌کار رود.

در مناطق مرطوب و سواحل دریاها معادلات تجربی و تخمینی گروه اول به‌علت آن‌که از پارامتر تابش برون‌زمینی به جای تابش خورشیدی استفاده می‌کند، نسبت به گروه دوم که مبتنی بر تابش خورشیدی می‌باشند دارای دقت کمتری است. علت آن می‌تواند اثر رطوبت و پوشش ابری این مناطق بر مقدار تابش خورشیدی باشد که باعث می‌شود معادلات گروه اول مقادیر ET_o را تا حدودی بیشتر از مقدار واقعی برآورد نمایند. اگرچه این تحقیق در یک ایستگاه انجام شده است ولی



شکل ۲- نتایج بهترین مدل‌های ANNs و بهترین معادلات تجربی و تخمینی روی خط ۱:۱ در گروه‌های سه‌گانه

منابع مورد استفاده

موردی: منطقه مشهد). آب و خاک (علوم کشاورزی و صنایع غذایی) ۲۳(۱): ۲۳۸-۲۲۹.

۴. علیزاده ا. و کمالی غ غ (۱۳۸۶) نیاز آبی گیاهان در ایران. چاپ اول. مؤسسه چاپ و انتشارات آستان قدس رضوی. ۲۲۸ ص.

۵. شایان‌نژاد م، ساداتی‌نژاد ج. و فهمی ه (۱۳۸۶) تعیین تبخیر و تعرق بالقوه با استفاده رگرسیون فازی. تحقیقات منابع آب ایران ۳: ۱۹-۹.

۱. احمدزاده قره‌گویز ک، میرلطیفی م. و محمدی ک (۱۳۸۹) مقایسه سیستم‌های هوش مصنوعی (ANN و ANIS) در تخمین میزان تبخیر و تعرق گیاه.

۲. مرجع در مناطق بسیار خشک ایران. آب و خاک ۲۴(۴): ۶۸۹-۶۷۹.

۳. علیزاده ا. و خلیلی ن (۱۳۸۸) تعیین ضریب معادله انگستروم و توسعه یک مدل رگرسیونی برآورد تابش کل خورشیدی (مطالعه

۶. کوچک‌زاده م. و بهمنی ع (۱۳۸۴) ارزیابی عملکرد شبکه‌های عصبی مصنوعی در کاهش پارامترهای موردنیاز، جهت برآورد تبخیر و تعرق مرجع. علوم کشاورزی ۱۱: ۹۶-۸۷.
۷. محمدی م، نوری م. و لیاقت ع م (۱۳۸۸) ارزیابی روش فائوپنمن - مانتیث برای تخمین تبخیر و تعرق مرجع با استفاده از داده‌های محدود آب و هوایی. اولین کنفرانس بین‌المللی منابع آب، دانشگاه صنعتی شاهرود، ایران.
۸. موسوی بایگی م، عرفانیان م. و سرمد م (۱۳۸۸) استفاده از حداقل داده‌های هواشناسی برای برآورد تبخیر و تعرق گیاه مرجع و ارائه ضریب اصلاحی (مورد: استان خراسان رضوی). آب و خاک (علوم و صنایع کشاورزی) ۲۳(۱): ۹۹-۹۱.
9. Allen RG, Pereira LS, Raes D and Smith M (1998) Crop evapotranspiration: Guidelines for computing crop water requirements. FAO Irrigation and Drainage Paper No. 56, Rome, Italy.
10. Fausset LV (1994) Fundamentals of Neural Networks: Architectures, Algorithms and Applications. Prentice Hall, Upper Saddle River, NJ. 462 P.
11. Gundekar HG, Khodke UM and Sarkar S (2008) Evaluation of pan coefficient for reference crop evapotranspiration for semi-arid region. Irrigation Science 26: 169-175.
12. Jain SK, Nayak PC and Sudheer KP (2008) Models for estimating evapotranspiration using artificial neural networks and their physical interpretation. Hydrological Processes 22(13): 2225-2234.
13. Jensen ME, Burman RD and Allen RG (1990) Evapotranspiration and irrigation water requirements. ASCE Manuals and Reports on Engineering Practices. No. 70. American Society of Civil Engineers, NY.
14. Kisi O (2007) The potential of different ANN techniques in evapotranspiration modelling. Hydrological Processes 22(14): 2449-2460.
15. Kumar M, Raghuwanshi NS, Singh R, Wallender WW, and Pruitt WO (2002) Estimating evapotranspiration using artificial neural network. Irrigation Drainage Engineering 128(4): 224-233.
16. Landeras G, Ortiz Barredo A and Lopez JJ (2008) Comparison of artificial neural network models and empirical and semi-empirical equations for daily reference evapotranspiration estimation in the Basque Country (Northern Spain). Agricultural Water Management 95: 553-565.
17. Noori R, Karbassi A and Sabahi MS (2009) Evaluation of PCA and gamma test techniques on AAN operation for weekly solid waste prediction. Environmental Management 91: 767-771.
18. Odhiambo LO, Yoder RE, Yoder DC and Hines JW (2001) Optimization of fuzzy evaporation model through neural training with input-output examples. Transactions of the ASABE 44(6): 1625-1633.
19. Rahimikhoob A (2008) Artificial neural network estimation of reference evapotranspiration from pan evaporation in a semi-arid environment. Irrigation Science 27: 35-39.
20. Rahimikhoob A (2010) Estimation of evapotranspiration based on only air temperature data using artificial neural networks for a subtropical climate in Iran. Theor. Appl. Climatol., 101: 83-91.
21. Sudheer KP, Gosain AK and Ramasastri KS (2003) Estimating actual evapotranspiration from limited climatic data using neural computing technique. Irrigation Drain. Engineering ASCE 129(3): 214-218.
22. Trajkovic S (2009) Comparison of radial basis function networks and empirical equations for converting from pan evaporation to reference evapotranspiration, Hydrological Processes 23(6): 874-880.
23. Tabari H (2009) Evaluation of reference crop evapotranspiration equations in various climates. Water Resource Management 24(10): 2311-2337.
24. Zanetti SS, Sousa EF, Oliveira VPS, Almeida FT and Bernard S (2007) Estimating evapotranspiration using artificial neural network and minimum climatologically data. Irrigation Drain. Engineering 133(2): 83-89.

Calibration of Empirical Equations to Estimate the Daily Reference Evapotranspiration and Comparison with ANNs Models under the Lack of Meteorological Data

A. A. Dehghani ^{1*}, M. Ghabaei Sough ², H. Sharifan ¹ and N. Dehghani ³

(E-mail: a.dehghani@gau.ac.ir)

Abstract

Accurate estimation of reference evapotranspiration plays a key role in water resources management and irrigation scheduling. The FAO Penman-Monteith (F-P-M) is a reference method for calculation of evapotranspiration that needs temperature, humidity, wind speed and solar radiation. In many stations, it is not an easy task to measure the whole weather variables. Thus, in this situation, one must use some of the equations that require less climatic data. ANNs are an effective tools to model nonlinear phenomena with an interaction relationship. In this study, Seven ANNs with different input combinations have been implemented and compared with ten locally calibrated empirical and semi-empirical ET_0 equations (with estimated solar radiation and humidity parameters as inputs) in Gorgan synoptic station. The comparisons have been based on the basis of statistical error techniques, using F-P-M daily ET_0 values as a reference. ANNs have obtained better results than the locally calibrated ET_0 equations in the three groups: temperature and/or relative humidity based methods ANN 3 model and HS equation with RMSE equal to 0.422 and 0.551 mm d⁻¹, respectively; solar radiation-based methods ANN 4 model and T equation with RMSE equal to 0.372 and 0.518 mm d⁻¹, respectively and methods based on similar requirements to those of PM56 except for the estimation of solar radiation and/or relative humidity ANN 6 and F-P-M_{RHest} equation with RMSE equal to 0.208 and 0.310 mm d⁻¹, respectively.

Keywords: Artificial neural networks, Calibration, Empirical and semi empirical equation, Evapotranspiration, Gorgan province

1 - Assistant Professor, Department of Water Engineering, Gorgan University of Agricultural Sciences and Natural Resources, Golestan - Iran (**Corresponding Author ***)

2 - M.Sc. Student, Department of Water Engineering, Gorgan University of Agricultural Sciences and Natural Resources, Golestan - Iran

3 - M.Sc. Student, Department of Watershed Management Engineering, College of Natural Resources & Marine Sciences, Tarbiat Modarres University, Tehran - Iran