

مقاله علمی-پژوهشی

ارزیابی عملکرد روش‌های شبکه عصبی مصنوعی و سیستم استنتاج عصبی-فازی تطبیقی در تخمین تبخیر-تعرق گیاه مرجع در شرایط گلخانه

حدیثه رحیمی‌خوب^{۱*}، تیمور سهرابی^۲، مجتبی دلشاد^۳

تاریخ دریافت: ۱۴۰۰/۱۱/۱۹ تاریخ پذیرش: ۱۴۰۰/۱۲/۲۲

چکیده

برآورد دقیق تبخیر-تعرق گیاه مرجع (ET_0) یکی از عوامل مهم در مدیریت و برنامه‌ریزی آبیاری در بخش کشاورزی است. استفاده از روش استاندارد فائو-پنمن-مانتیت برای تخمین ET_0 مشروط به در دسترس بودن پارامترهای اقلیمی شامل دما، رطوبت، تابش، سرعت باد و همچنین فراهم بودن فرضیات ذکر شده در نشریه فائو ۵۶ است. در بعضی مناطق یا در کشت‌های کنترل شده گلخانه، اغلب دسترسی به تمام پارامترهای اقلیمی و یا برآوردن فرضیات روش فائو-پنمن-مانتیت امکان‌پذیر نیست؛ بنابراین، بهره‌گیری از روش‌هایی که با پارامترهای کمتری بتواند تخمین دقیقی از ET_0 ارائه نماید، ارجح است. پژوهش حاضر با هدف ارزیابی عملکرد دو روش شبکه‌های عصبی مصنوعی (ANNs) و سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) برای برآورد ET_0 در گلخانه تحقیقاتی واقع در دانشکده کشاورزی و منابع طبیعی دانشگاه تهران انجام شد. بر اساس پارامترهای اقلیمی اندازه‌گیری شده در داخل گلخانه، ترکیب‌های مختلفی ایجاد و شاخص‌های ارزیابی برای هر روش و سناریو محاسبه گردیدند. بهترین ساختار شبکه عصبی برای سناریو ۴ (ورودی‌های تابش، دما، رطوبت) با ۷ نورون در لایه میانی و الگوریتم آموزش تنظیم بیزی به دست آمد. طراحی شبکه‌های ANFIS با توابع عضویت‌های مختلف انجام شد. نتایج نشان داد، تفاوت قابل‌ملاحظه‌ای بین دقت مدل‌سازی ET_0 در روش ANFIS تحت سناریوهای مختلف وجود ندارد؛ به عبارت دیگر در این روش، حتی با داده‌های دما و رطوبت نیز می‌توان با دقت بالایی ET_0 در داخل گلخانه را شبیه‌سازی نمود. مقایسه شاخص‌های ارزیابی بین مدل‌های ANFIS و ANNs نشان داد، مدل ANFIS عملکرد بهتری نسبت به روش ANNs دارد. به طوری که شاخص جذر میانگین مربعات خطای نسبی (RRMSE)، برای سناریوهای ۱ تا ۴ در مدل ANFIS به ترتیب برابر با ۱/۴۱، ۰/۸۰، ۰/۰۶ و ۱/۰۱ درصد و در مدل ANNs برابر با ۱۲/۷۰، ۲/۲۳، ۲/۱۲ و ۲/۱۰ درصد بود.

واژه‌های کلیدی: تبخیر-تعرق گیاه مرجع، سیستم استنتاج عصبی-فازی تطبیقی، شبکه‌های عصبی مصنوعی

مقدمه

ET_0 با دو روش مستقیم یا غیرمستقیم تخمین زده می‌شود. در روش‌های مستقیم، ET_0 اغلب با استفاده از انواع لایسیمترها و بر اساس روابط بیلان آب در خاک محاسبه می‌شود. با توجه به هزینه‌های زیاد اجرا و نگهداری لایسیمترها، مدل‌ها و روابط متعددی برای تخمین ET_0 مبتنی بر داده‌های اقلیمی توسعه داده شده‌اند. از پرکاربردترین روش‌های غیرمستقیم برآورد ET_0 می‌توان به روش‌های فائو-پنمن-مانتیت^۵ (Monteith and Unsworth, 1990)، هارگریوز-سامانی^۶ (Priestley and Taylor, 1972) و ایرماک^۸ (Irmak et al., 2003) اشاره نمود.

تبخیر-تعرق گیاه مرجع^۴ (ET_0) یکی از عوامل مهم در برآورد دقیق نیاز آبی محصولات کشاورزی و همچنین برنامه‌ریزی و مدیریت پایدار منابع آب است (Rahimikhoob et al., 2020). به‌طور کلی،

- ۱- دانش آموخته دکتری، گروه مهندسی آبیاری و آبادانی، دانشکده مهندسی و فناوری کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران
- ۲- استاد گروه مهندسی آبیاری و آبادانی، دانشکده مهندسی و فناوری کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران
- ۳- دانشیار گروه علوم باغبانی، دانشکده مهندسی و فناوری کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران

(*- نویسنده مسئول : (Email: h.rahimikhoob@ut.ac.ir

DOR: 20.1001.1.20087942.1401.16.3.4.5

4- Reference evapotranspiration

5- FAO-Penman-Monteith

6- Hargreaves-Samani

7- Priestley-Taylor

8- Irmak

ورودی نیز عملکرد مناسبی دارد. یکی دیگر از روش‌های مدل‌سازی بر پایه هوش مصنوعی، روش ANFIS است. این روش ترکیبی از قواعد منطق فازی و شبکه عصبی مصنوعی است (Jang, 1993). کارایی روش ANFIS در علوم کشاورزی مثل مطالعات منابع آب (Lohani et al., 2012)، پیش‌بینی زمان رسیدن محصولات کشاورزی (Kaur et al., 2021) و تخمین ET_0 (Cobaner, 2011; Adnan, 2021) مورد بررسی قرار گرفته است. به‌عنوان مثال در تحقیقی که توسط Cobaner (2011) انجام شد، دو سیستم فازی-عصبی مبتنی بر روش تقسیم‌بندی شبکه‌ای^۴ و روش خوشه‌بندی^۵ مورد مقایسه قرار گرفت. نتایج این پژوهش نشان داد که روش خوشه‌بندی دقت بیشتر و زمان محاسبات کمتری نسبت به روش تقسیم‌بندی شبکه‌ای دارد. تحقیق دیگری در همدان با هدف تخمین ET_0 با استفاده از داده‌های اقلیمی محدود و روش‌های ماشین بردار پشتیبان^۶ (SVM)، ANFIS و رگرسیون خطی و غیرخطی انجام شد (Tabari et al., 2012). مقایسه شاخص‌های عملکرد نشان داد که روش‌های SVM و ANFIS دقت بیشتری نسبت به روش‌های رگرسیونی دارند. همچنین بهترین ترکیب متغیرهای ورودی (داده‌های اقلیمی) مدل نیز به دست آمد. با توجه به مرور منابع در زمینه کاربرد روش ANFIS در تخمین ET_0 ، اغلب پژوهش‌ها در شرایط مزرعه و فضای باز انجام شده‌اند. درحالی‌که کشت محصولات کشاورزی در شرایط کنترل شده گلخانه به‌خصوص در مناطقی که با بحران کم‌آبی مواجه هستند، ارجحیت دارد؛ بنابراین، لازم است که روش‌های غیرمستقیم برآورد ET_0 در شرایط گلخانه نیز مورد مطالعه قرار گیرد. هدف از این پژوهش ارزیابی دقت روش‌های مبتنی بر هوش مصنوعی (ANFIS و ANNs) در تخمین ET_0 در گلخانه بود.

مواد و روش‌ها

این تحقیق در گلخانه پژوهشی دانشکده کشاورزی و منابع طبیعی دانشگاه تهران واقع در کرج با عرض جغرافیایی ۳۵ درجه و ۴۸ دقیقه شمالی، طول جغرافیایی ۵۰ درجه و ۵۷ دقیقه شرقی و با ارتفاع ۱۲۹۲/۹ متر از سطح دریا انجام شد. ابعاد سالن گلخانه مورد مطالعه ۸×۲۰ مترمربع، از نوع چنددهانه‌ای با دیواره‌های شیشه‌ای و پوشش سقف از جنس پلی کریبات بود. به‌منظور تعدیل درجه حرارت محیط، گلخانه مجهز به سیستم پد و فن خودکار و حرارت مرکزی است. پارامترهای هواشناسی، شامل حداکثر و حداقل دمای روزانه، حداکثر و حداقل رطوبت نسبی و تابش طول‌موج کوتاه رسیده به داخل گلخانه به‌صورت روزانه برداشت گردید. سنجش متغیر دما و

در این میان، روش فائو-پنمن-مانتیت به‌عنوان روشی استاندارد برای تخمین ET_0 شناخته شده است (Allen et al., 1998). در این روش، ET_0 با استفاده از داده‌های اقلیمی شامل حداکثر و حداقل دما، متوسط سرعت باد، متوسط رطوبت نسبی و تابش تخمین زده می‌شود. بنابراین برای استفاده از روش فائو-پنمن-مانتیت، دسترسی به تمام داده‌های اقلیمی ذکر شده ضرورت دارد. البته می‌بایست در نظر داشت که برخی از ایستگاه‌های هواشناسی، تجهیزات و در نتیجه داده‌های کافی و قابل اطمینانی برای کاربرد روش فائو-پنمن-مانتیت ندارند. علاوه بر این، اگر کاشت محصولات کشاورزی به جای مزرعه در محیط کنترل شده گلخانه انجام گیرد، فراهم نمودن دستگاه‌های اندازه‌گیری متغیرهای اقلیمی به‌خصوص دستگاه تابش‌سنج بسیار هزینه‌بر است. در نتیجه، کاربرد روش‌هایی که قادر به تخمین ET_0 با داده‌های اقلیمی کمتری باشند، ارجحیت دارد.

در سال‌های اخیر، تکنولوژی هوش مصنوعی^۱ (AI) به‌طور گسترده‌ای در مطالعات کشاورزی از جمله مدیریت منابع آب (Allawi et al., 2018)، کشاورزی دقیق (Costa et al., 2021)، مدیریت علف هرز (Partel et al., 2019) و پیش‌بینی عملکرد محصول (Kouadio et al., 2018) مورد استفاده قرار گرفته است. مزیت اصلی کاربرد روش‌های هوشمند، مدل‌سازی فرآیندهای پیچیده و غیرخطی با حداقل داده‌های ورودی و دقت قابل قبول است (Abiodun et al., 2018). از پرکاربردترین روش‌های مدل‌سازی هوشمند می‌توان به روش شبکه‌های عصبی مصنوعی^۲ (ANNs) و سیستم استنتاج عصبی-فازی تطبیقی^۳ (ANFIS) اشاره نمود. ساختار روش ANNs الهام گرفته از سیستم عصبی مغز انسان است. در این روش ارتباط بین متغیرهای مستقل و وابسته بدون نیاز به دانستن قواعد فیزیکی و ریاضی توصیف می‌شود (Abiodun et al., 2018). از این روش برای تخمین ET_0 در مناطق مختلف دنیا استفاده شده است. به‌طور مثال، در شمال کشور یونان دقت روش‌های تجربی شامل پرستلی-تیلور، مکینک، هارگریوز-سامانی و انتقال جرم با روش ANNs در برآورد ET_0 مورد مقایسه قرار گرفت (Antonopoulos and Antonopoulos, 2017). ساختار شبکه عصبی به‌صورت ۱-۶-۴ یا به‌عبارت دیگر با ۴، ۶ و ۱ نورون به ترتیب در لایه‌های ورودی، میانی و خروجی طراحی شد. نتایج نشان داد، روش ANNs عملکرد بهتری نسبت به سایر روش‌ها دارد. پژوهش دیگری با هدف ارزیابی عملکرد روش ANNs در برآورد ET_0 با استفاده از حداقل داده‌های اقلیمی انجام شد (Jain et al., 2008). تعداد شش ترکیب متفاوت از داده‌های اقلیمی (دما، رطوبت، تابش) ایجاد و شبکه بر اساس آن‌ها طراحی شد. نتایج نشان داد، روش ANNs حتی با حداقل داده‌های

4- Grid partitioning

5- Clustering

6- Support vector machines

1- Artificial intelligence

2- Artificial neural networks

3- Adaptive neuro-fuzzy inference system

به صورت تجمعی در ۲۴ ساعت اندازه‌گیری شد. میانگین میزان تابش طول موج کوتاه ثبت شده برابر با ۲۰/۹ مگا ژول در مترمربع بر روز بود. خاک مورد استفاده در این تحقیق، بافت لوم که در این منطقه بخش عمده‌ای از خاک بستر گلخانه‌ها را تشکیل می‌دهد، انتخاب شد. نتایج آنالیز خصوصیات فیزیکی و شیمیایی خاک در جدول ۱ ارائه شده است.

رطوبت با استفاده از سنسور دیجیتال مدل HTC-1 (Xuzhou Sanhe Automatic Control Equipment Co., Ltd, Jiangsu, China) و متغیر تابش توسط دستگاه تابش سنج مدل TES-1333R (Electronic Corp, Taipei, Taiwan TES Electrical) انجام شد. اندازه‌گیری پارامترهای هواشناسی در گلخانه در ماه‌های خرداد تا اواسط مرداد سال ۱۳۹۷ به مدت ۷۳ روز انجام گرفت. میانگین دما و رطوبت نسبی در طول دوره به ترتیب برابر با ۳۳/۴ درجه سانتی‌گراد و ۳۱/۳ درصد بود. تابش طول موج کوتاه توسط دستگاه تابش سنج

جدول ۱- خصوصیات فیزیکی و شیمیایی خاک

ذرات تشکیل دهنده خاک	ظرفیت زراعی	نقطه پژمردگی	جرم مخصوص ظاهری	شوری عصاره اشباع	اسیدیته
رس (%)	شن (%)	(درصد وزنی)	(گرم بر سانتی‌متر مکعب)	(دسی زیمنس بر متر)	(pH)
۲۰	۳۴	۴۶	۲۱/۲۴	۱۰/۳۶	۱/۳۳
					۱/۴۶
					۸/۱

R برابر با صفر در نظر گرفته شده‌اند. ET_0 روزانه از میانگین مقادیر به دست آمده از رابطه بیلان آب خاک برای هر میکرولاسیسمتر محاسبه شد.

محاسبه ET_0 توسط میکرولاسیسمتر

در این تحقیق برای تعیین میزان ET_0 از سه عدد میکرولاسیسمتر وزنی استفاده شد. میکرولاسیسمترها از جنس پلاستیک فشرده با قطر و ارتفاع ۲۱ سانتی‌متر تهیه گردید. در کف میکرولاسیسمترها، شن درشت به ضخامت ۱/۵ سانتی‌متر برای تسهیل زهکشی ریخته شد. سپس میکرولاسیسمترها با خاک مناسب زراعی پر و به منظور یکسان‌سازی توزین شدند. وزن میکرولاسیسمترها در حدود ۵/۵ کیلوگرم با احتساب وزن خاک خشک و شن تثبیت شد. برای تعیین تغییرات روزانه ET_0 از میکرولاسیسمتر چمن استفاده شد. اندازه‌گیری‌های مربوط به محاسبه ET_0 شامل اندازه‌گیری متغیرهای رابطه بیلان آب، پس از آنکه ارتفاع چمن به ۱۲ سانتی‌متر رسید، آغاز گردید. در طول دوره، ارتفاع چمن همواره بین ۱۰ تا ۱۵ سانتی‌متر ثابت نگه داشته شد. برای جلوگیری از ایجاد تنش آبی، آبیاری به صورت روزانه انجام می‌گرفت. میزان آب زهکش شده از هر میکرولاسیسمتر نیز در هر ۲۴ ساعت جمع‌آوری و اندازه‌گیری شد. تغییرات ذخیره رطوبتی خاک (ΔS)، از طریق توزین روزانه میکرولاسیسمترها توسط ترازوی دیجیتال با دقت ± 1 گرم به دست آمد. سپس از رابطه بیلان آب خاک، ET_0 گیاه چمن تخمین زده شد (Zelege and Wade, 2012):

$$ET_0 = I + P + U - R - D - \Delta S \quad (1)$$

در رابطه فوق، ET_0 تبخیر- تعرق مرجع، I عمق آب آبیاری، P میزان بارندگی، U^1 جریان کاپیلاری از اعماق به سمت ریشه، R رواناب سطحی، D نفوذ عمقی و ΔS تغییرات ذخیره رطوبتی خاک هستند. در این رابطه تمام مقادیر بر حسب حجم آب در واحد سطح بیان می‌شوند. در محیط کشت کنترل شده گلخانه، پارامترهای U ، P و

روش شبکه‌های عصبی مصنوعی

روش ANNs از سیستم عصبی مغز انسان الهام گرفته و به عبارتی یک سامانه پردازش داده است که هدف آن حل مسائل پیچیده و غیرخطی می‌باشد (Abiodun et al., 2018). کوچک‌ترین واحدهای پردازش اطلاعات در ANNs، نورون^۲ نام دارد. نورون‌های مصنوعی اغلب با انجام عملیات ساده مانند تجمیع سیگنال‌های ورودی و اعمال عملگرهای ریاضی، خروجی را با توجه به نوع توابع فعال‌سازی تولید می‌کنند. ساده‌ترین مدل نورون که شامل ویژگی‌های اصلی (پیوستگی، قابلیت یادگیری، پردازش موازی) یک شبکه عصبی بیولوژیکی است، اولین بار توسط McCulloch and Pitts (1943) پیشنهاد شد و هنوز هم پرکاربردترین مدل در معماری‌های مختلف شبکه‌های عصبی مصنوعی است. در این مدل هر نورون از یک شبکه، مطابق با شکل (۱) طراحی می‌شود. داده‌ها و اطلاعات ورودی به مدل که با مجموعه $\{x_1, x_2, x_3, \dots, x_n\}$ نشان داده می‌شوند، در یک فاکتور وزنی $\{w_1, w_2, w_3, \dots, w_n\}$ ضرب شده و سپس با مقدار ثابتی تحت عنوان خطا^۳ جمع می‌گردد. مقدار به دست آمده (u)، به عنوان ورودی به تابع محرک^۴ (g) وارد و سپس خروجی (y) محاسبه می‌شود. توابع محرک در واقع توابعی هستند که مقدار خروجی شبکه را به ازای مجموع ورودی‌های وزن‌دار در هر گره تولید می‌کنند. از پرکاربردترین توابع محرک می‌توان به تابع تانژانت

2- Neuron
3- Bias
4- Activation function

1- Upward capillary rise

لایه خروجی نتایج شبیه‌سازی را نشان می‌دهد. در لایه میانی نیز، فرآیند پردازش داده‌ها انجام می‌شود. ساختارهای متعددی برای طراحی ANNs وجود دارد که بر اساس نحوه اتصال نورون‌ها و تشکیل لایه‌ها در دو شاخه اصلی شامل شبکه‌های پیش‌خور^۹ (FF) و شبکه‌های پس‌خور^{۱۰} (FB) تقسیم‌بندی می‌شوند. در شبکه‌های FB خروجی نورون‌ها به‌عنوان ورودی بازگشتی به نورون لایه‌های قبل اعمال می‌شود. این نوع از شبکه‌ها قابلیت پردازش اطلاعات در سامانه‌های پویا و هم‌چنین مدل‌سازی فرآیندهای دینامیکی را دارند (Bhat and McAvoy, 1990). در شبکه‌های FF بین خروجی هر گره و ورودی گره بعدی ارتباطی یک‌طرفه وجود دارد؛ به عبارت دیگر گره‌ها از یکدیگر تأثیر نمی‌پذیرند. از انواع شبکه‌های FF می‌توان به شبکه عصبی پرستپترون تک لایه^{۱۱} (SLP) و شبکه عصبی پرستپترون چندلایه^{۱۲} (MLP) اشاره نمود. تفاوت شبکه‌های FF و FB به‌صورت شماتیک در شکل (۲) نشان داده شده است.


در شبکه‌های عصبی از نوع MLP، آموزش بر اساس الگوریتم پس انتشار خطا^{۱۳} (BP) صورت می‌گیرد. در این روش، خطای شبیه‌سازی (اختلاف خروجی مدل و خروجی مطلوب) به مدل بازگشت داده و در لایه‌های شبکه توزیع می‌شود. سپس تا زمانی که خطای مدل-سازی به حداقل مقدار ممکن برسد، بردار وزن‌ها (w_i) اصلاح می‌گردد.

سیستم استنتاج فازی-عصبی تطبیقی

سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) که ادغامی از سیستم‌های فازی (مبتنی بر قواعد منطقی) و ANNs است، از جمله روش‌های هوشمند برای تحلیل پدیده‌های غیرخطی و غیرقطعی می‌باشد (Jang, 1993).

این سیستم از نوع شبکه‌های چندلایه بوده و بر اساس الگوریتم BP سعی در به حداقل رساندن خطای شبیه‌سازی دارد. سیستم‌های فازی بر اساس نوع عملکرد و خروجی آن‌ها در دو گروه سیستم استنتاج ممدانی^{۱۴} (Mamdani and Assilian, 1975) و سوگنو^{۱۵} (Takagi and Sugeno, 1985) طبقه‌بندی می‌شوند. سیستم سوگنو نسبت به ممدانی به دلیل روند محاسباتی سریع و کارآمد، کاربرد بیشتری دارد (Gonzalez del Cerro et al., 2021).

سیگموئید، هاپربولیک تانژانت، خطی و لوگ سیگموئید اشاره نمود.



شکل ۱- ساختار یک نورون مصنوعی

بیان ریاضی عملکرد یک نورون توسط روابط ۲ و ۳ نشان داده می‌شود.

$$u = \sum_{i=1}^n x_i w_i + b \quad (2)$$


$$y = g(u) \quad (3)$$

یکی از مهم‌ترین ویژگی‌های ANNs توانایی آن‌ها در یادگیری بر اساس اطلاعات از پیش داده‌شده به مدل است. فرآیند آموزش و یادگیری یک ANN با تنظیم پارامترهای شبکه به نحوی انجام می‌شود که خروجی مدل به خروجی مطلوب همگرا گردد. به‌طورکلی، روش‌های یادگیری ANNs عبارت‌اند از: یادگیری با نظارت^۱، یادگیری بدون نظارت^۲ و یادگیری تقویت‌شده^۳. در روش یادگیری با نظارت، داده‌های ورودی و هم‌چنین خروجی متناظر با آن، از قبل مشخص بوده و هدف تعیین ارتباط بین آن‌ها است. درحالی‌که در روش یادگیری بدون نظارت، داده‌های خروجی از پیش به مدل معرفی نمی‌شوند. در این روش هدف شبکه، خوشه‌بندی اطلاعات ورودی است. در روش یادگیری تقویت‌شده، یک سامانه به‌صورت خودکار^۴ یا مستقل از طریق تعامل با محیط و در نتیجه کسب تجربه، سعی در بیشینه نمودن پاداش‌ها^۵ دارد (Sutton and Barto, 1998). یادگیری تقویت‌شده یک نگاهت از موقعیت به عمل است؛ به عبارت دیگر، بیان‌کننده آن است که در هر موقعیتی چه تدابیری می‌بایست اتخاذ گردد تا هدف سامانه مرتفع گردد (Abiodun et al., 2018).


به‌طورکلی ANNs، از سه لایه به نام‌های لایه ورودی^۶، میانی^۷ و خروجی^۸ تشکیل شده است. لایه ورودی شامل داده‌ها و اطلاعاتی است که سیستم برای حل مسئله از آن‌ها استفاده می‌کند، درحالی‌که

- 9- Feed-forward neural network
- 10- Feed-back neural network
- 11- Single-layer perceptron
- 12- Multi-layer perceptron
- 13- Back propagation
- 14- Mamdani's system
- 15- Sugeno's system

- 1- Supervised learning
- 2- Unsupervised learning
- 3- Reinforcement learning
- 4- Autonomous
- 5- Rewards
- 6- Input layer
- 7- Hidden layer
- 8- Output layer



شکل ۲- شبکه عصبی مصنوعی از نوع پیشخور (سمت چپ) و پسخور (سمت راست)



شکل ۳- ساختار مدل ANFIS

حداقل مربعات خطا^۴ می‌باشد، انجام می‌گیرد. هدف از کاربرد الگوریتم گرادیان نزولی و حداقل مربعات به ترتیب تخمین پارامترهای تعیین کننده شکل تابع عضویت (پارامترهای اولیه^۵) و پارامترهای تابع خروجی (پارامترهای نتیجه^۶) است (Jang et al., 1997). در این پژوهش، فرآیند مدل‌سازی با استفاده از نرم‌افزار MATLAB انجام شد. در شبیه‌سازی ET_o با روش ANNs، دو الگوریتم آموزش لونیگ-مارکواریت^۷ (trainlm) و تنظیم بیزی^۸ (trainbr) مورد استفاده قرار گرفتند. داده‌های ورودی شامل دمای میانگین، رطوبت نسبی و تابش بودند. چهار سناریوی مختلف از ترکیب این متغیرها به عنوان پارامترهای ورودی در نظر گرفته شد (جدول ۲).

به منظور ایجاد یک سیستم فازی، می‌بایست متغیرهای زبانی (فازی) جایگزین متغیرهای عددی شوند. در این سیستم‌ها، روابط بین متغیرهای فازی بر اساس قوانین فازی (اگر - آنگاه) توصیف می‌گردد. اگر فرض شود که x و y ورودی‌ها و f خروجی مدل هستند، قوانین در سیستم فازی از نوع سوگنو به صورت زیر بیان می‌شوند (Sayed et al., 2003):

$$\text{If } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ then } f = p_1x + q_1y + r_1 \quad (4)$$

$$\text{If } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ then } f = p_2x + q_2y + r_2 \quad (5)$$

در روابط ۴ و ۵، A_1, A_2, B_1, B_2 به ترتیب توابع عضویت برای ورودی‌های x و y هستند. همچنین ضرایب $p_1, p_2, q_1, q_2, r_1, r_2$ پارامترهای تابع خروجی می‌باشند. ساختار یک مدل ANFIS در شکل (۳) نشان داده شده است. همان‌طور که مشاهده می‌شود، مدل ANFIS متشکل از پنج لایه است. مراحل مدل‌سازی در این لایه‌ها شامل ورود داده، عملیات فازی سازی^۱، استنتاج قوانین، نرمال سازی و فازی زدایی^۲ است. آموزش شبکه در مدل ANFIS بر اساس الگوریتم بهینه‌سازی هیبرید که در واقع ترکیبی از الگوریتم گرادیان نزولی^۳ و

- 4- Least squares
- 5- Premise parameters
- 6- Consequent parameters
- 7- Levenberg-Marquardt
- 8- Bayesian regularization

- 1- Fuzzification
- 2- Defuzzification
- 3- Gradient descent

جدول ۲- ترکیب پارامترهای ورودی به مدل‌ها

شماره سناریو	پارامترهای ورودی
۱	میانگین دما، رطوبت نسبی
۲	میانگین دما، تابش
۳	رطوبت نسبی، تابش
۴	میانگین دما، رطوبت نسبی، تابش

شبیه‌سازی شده، \bar{P} میانگین مقادیر شبیه‌سازی شده، O_i مقادیر مشاهده شده و \bar{O} میانگین مقادیر مشاهده شده است. شاخص R^2 بیان‌کننده میزان پراکندگی متغیر وابسته نسبت به خط رگرسیون است. اگر هدف مقایسه روند تغییرات پارامتر پیش‌بینی شده با اندازه‌گیری شده باشد، مقادیر زیاد این شاخص بیان‌کننده تطابق کامل روش محاسباتی با شرایط واقعی است. شاخص MBE با مقایسه اختلاف بین مقادیر پیش‌بینی شده توسط مدل و مقادیر واقعی، بیش برآورد یا کم برآورد بودن هر روش را با همان واحد و مقیاس متغیر مورد بررسی نشان می‌دهد. حد پایین هر دو شاخص MBE صفر است که بیان‌کننده سازگاری کامل بین مقادیر پیش‌بینی شده و واقعی است. شاخص RRMSE نسبت شاخص RMSE به میانگین مقادیر مشاهده شده است که به صورت درصد بیان می‌شود. مقادیر RRMSE کمتر از ۱۰ درصد نشان‌دهنده عملکرد عالی مدل، بین ۱۰ تا ۲۰ درصد عملکرد خوب، بین ۲۰ تا ۳۰ درصد عملکرد متوسط و بالای ۳۰ درصد بیانگر عملکرد ضعیف مدل است. شاخص NSE به منظور ارزیابی کارایی مدل‌ها استفاده شد. دامنه تغییرات این شاخص بین منفی بی‌نهایت تا یک است. هر چه شاخص NSE به عدد یک نزدیک‌تر باشد، مدل از قدرت شبیه‌سازی بیشتری برخوردار است.

علاوه بر شاخص‌های آماری، رابطه خطی بین مقادیر اندازه‌گیری و شبیه‌سازی شده توسط آزمون F-Fisher و آنالیز واریانس (ANOVA) به صورت آماری با استفاده از نرم‌افزار SPSS مورد ارزیابی قرار گرفت. فرض صفر در آزمون F، برابر با صفر بودن ضرایب معادله رگرسیون است. به عبارت دیگر، فرض می‌شود هیچ رابطه خطی بین متغیر مستقل و وابسته وجود نداشته باشد؛ بنابراین، اگر مقادیر p-value کمتر از سطح معناداری ۰/۰۵ به دست آید، فرض صفر رد خواهد شد.

نتایج و بحث

مقادیر ET_0 محاسبه شده از روش مستقیم مبنای مقایسه و سنجش دقت روش‌های ANFIS و ANNs قرار گرفت. میانگین ET_0 اندازه‌گیری شده توسط میکرولاسیمترها در طول دوره برابر با ۷/۹۵ میلی‌متر بر روز بود. در روش شبکه عصبی تعداد نورون‌ها در لایه میانی بین یک تا ۵ نورون برای هر الگوریتم آموزشی تغییر داده شد و سپس معیارهای ارزیابی محاسبه شدند. لازم به ذکر است که تعداد کم نورون در لایه میانی منجر به خطای کم برآزش^۲ یا کم آموزش^۳ و در مقابل، تعداد زیاد نورون باعث خطای بیش برآزش^۴ یا بیش آموزش^۵ می‌شود. توصیه شده است که تعداد نورون‌ها در لایه

طراحی شبکه با یک لایه میانی انجام و تعداد بهینه نورون‌ها در این لایه به روش سعی و خطا تعیین شد. توابع محرک از نوع logsig و tansig برای لایه میانی و تابع purelin برای لایه خروجی در نظر گرفته شدند. به منظور تعیین مجموعه‌های آموزش و ارزیابی شبکه، ابتدا داده‌ها با استفاده از تابع dividerand به صورت تصادفی انتخاب شدند. سپس ۷۰، ۱۵ و ۱۵ درصد داده‌ها به ترتیب برای آموزش، اعتبارسنجی و ارزیابی شبکه مورداستفاده قرار گرفتند. لازم به ذکر است که عملیات پیش و پس پردازش (نرمال‌سازی) داده‌ها با استفاده از تابع mapminmax انجام شد.

طراحی شبکه‌های ANFIS بر اساس مدل پنج لایه سوگنو انجام شد. همانند روش ANNs داده‌های ورودی در این سیستم نیز شامل ترکیبی از متغیرهای دما، رطوبت و تابش بودند. به صورت تصادفی ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد برای ارزیابی مدل انتخاب شدند. توابع عضویت مختلف از جمله تابع گوسی (gaussmf)، مثلثی (trimf)، ذوزنقه‌ای (trapmf)، زنگوله‌ای (gbellmf) و همچنین تعداد ۲ تابع عضویت برای هر پارامتر ورودی در نظر گرفته شد.

معیارهای ارزیابی

به منظور مقایسه و ارزیابی دقت روش‌های ANNs و ANFIS در برآورد ET_0 ، از معیارهای جذر میانگین مربعات خطای نسبی (RRMSE)، ضریب تعیین (R^2)، انحراف میانگین خطا (MBE) و ضریب نش-ساتکلیف^۱ (NS) استفاده شد:

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}} \right)^2 \quad (6)$$

$$MBE = \frac{\sum_{i=1}^n (P_i - O_i)}{N} \quad (7)$$

$$RRMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{N}} \times \frac{1}{\bar{O}} \quad (8)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (9)$$

در معادلات فوق N بیانگر تعداد داده‌ها، P_i مقادیر

2- Under fitting
3- Under training
4- Over fitting
5- Over training

1- Nash-Sutcliffe

با توجه به جدول (۳)، بهترین ساختار برای سناریو ۱، ساختار ANN(2-5-1) یا به عبارتی تعداد ۲ پارامتر ورودی، ۵ نورون در لایه میانی و ۱ نورون در لایه خروجی به دست آمد. این سناریو متشکل از دو پارامتر دما و رطوبت نسبی به‌عنوان داده‌های ورودی می‌باشد. همان‌طور که ملاحظه می‌گردد، با وجود ۵ نورون در لایه میانی برای سناریو ۱، عملکرد و دقت شبیه‌سازی مدل در مقایسه با سناریوهای ۲ و ۳ بسیار کمتر است. با توجه به شاخص‌های محاسبه‌شده در جدول ۳، شبیه‌سازی ET_o توسط سناریوهای ۲ و ۳ به ترتیب با ساختارهای ANN(2-2-1) و ANN(2-3-1) با دقت بسیار بیشتری انجام شده است. می‌توان نتیجه گرفت، پارامتر تابش رسیده به درون گلخانه یکی از مهم‌ترین پارامترهای ورودی به مدل است. به‌گونه‌ای که در نظر گرفتن این پارامتر به‌عنوان یکی از ورودی‌ها، منجر به ساده‌تر شدن ساختار شبکه (کاهش تعداد نورون‌ها در لایه میانی) می‌گردد. در پژوهشی، به اهمیت و حساسیت زیاد پارامتر تابش رسیده به درون گلخانه برای برآورد دقیق ET_o توسط معادلات دیگر نیز اشاره شده است (Rahimikhoob et al. 2021).

میانمی بیش‌تر از ۲ برابر داده‌های ورودی نباشد (Kumar et al., 2011)؛ بنابراین برای سناریوهای ۱، ۲ و ۳ حداکثر تعداد ۵ نورون و برای سناریو ۴ حداکثر ۷ نورون در نظر گرفته شد. به‌طورکلی به تعداد ۸۸ بار مدل ANNs اجرا شد و بهترین ساختار برای هر نوع الگوریتم آموزشی و نوع تابع محرک در لایه میانی استخراج شد. نتایج به‌دست‌آمده از محاسبه معیارهای ارزیابی برای هر سناریو در جدول (۳) آورده شده است.

مطابق با جدول (۳)، بهترین نوع الگوریتم آموزش شبکه و تابع محرک در لایه میانی برای تمامی سناریوها، الگوریتم تنظیم بیزی و تابع تانژانت سیگموئید بود. برتری الگوریتم آموزش تنظیم بیزی نسبت به الگوریتم لونبرگ-مارکواریت در پژوهش‌های دیگر با اهداف متفاوت نیز گزارش شده است (He, 2014; Movahednejad and Saedi, 2020). با این حال به‌طورقطع نمی‌توان نتیجه گرفت که در تمامی مطالعات، الگوریتم تنظیم بیزی از عملکرد نسبی بهتری برخوردار است؛ زیرا عوامل متعددی از جمله تعداد پارامترهای ورودی و ساختار شبکه بر عملکرد الگوریتم مورداستفاده اثر می‌گذارد. این موضوع برای نوع تابع محرک در لایه میانی نیز صادق است.

جدول ۳- نتایج معیارهای ارزیابی برای مدل ANNs در هر سناریو (بهترین ساختار برای هر سناریو bold شده است)

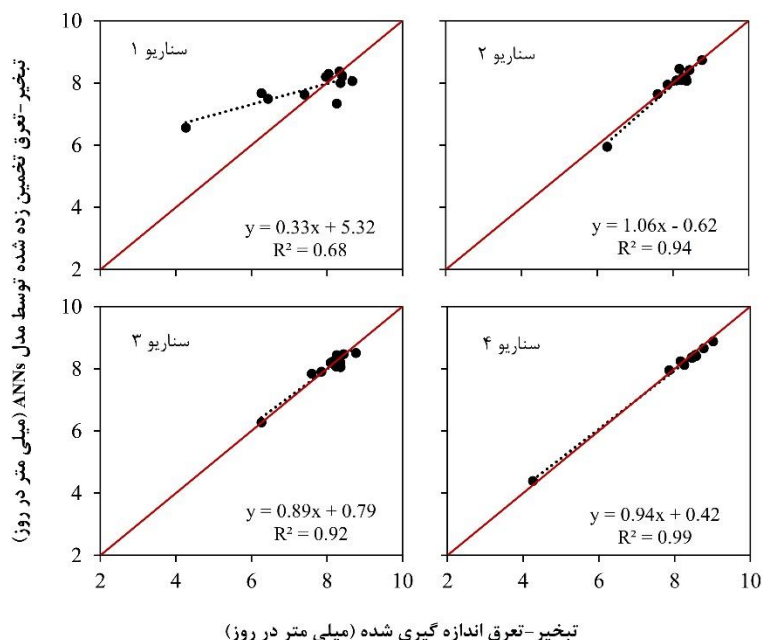
شماره سناریو	نوع الگوریتم	تابع لایه میانی	تعداد نورون	MBE (mm day ⁻¹)	R ²	RRMSE (%)	NSE
۱	trainlm	logsig	۵	۰/۴۹	۰/۵۰	۱۴/۹۳	۰/۲۲
	trainlm	tansig	۳	۰/۴۰	۰/۳۸	۶/۴۴	۰/۳۲
	trainbr	logsig	۴	۰/۷۸	۰/۵۵	۱۳/۴۵	۰/۳۹
	trainbr	tansig	۵	۰/۶۸	۰/۶۸	۱۲/۷۰	۰/۴۴
۲	trainlm	logsig	۲	۰/۰۲	۰/۹۲	۳/۳۲	۰/۹۱
	trainlm	tansig	۳	-۰/۰۳	۰/۹۳	۲/۰۴	۰/۹۱
	trainbr	logsig	۵	۰/۱۲	۰/۹۴	۴/۶۳	۰/۹۲
	trainbr	tansig	۲	-۰/۰۶	۰/۹۴	۲/۲۳	۰/۹۱
۳	trainlm	logsig	۲	۰/۰۸	۰/۹۰	۳/۹۲	۰/۸۸
	trainlm	tansig	۲	۰/۱۵	۰/۹۰	۴/۴۰	۰/۸۶
	trainbr	logsig	۳	-۰/۰۵	۰/۹۱	۲/۴۳	۰/۹۰
	trainbr	tansig	۳	-۰/۰۱	۰/۹۲	۲/۱۲	۰/۹۲
۴	trainlm	logsig	۳	۰/۱۴	۰/۹۳	۸/۱۳	۰/۷۶
	trainlm	tansig	۳	۰/۱۲	۰/۹۵	۸/۰۳	۰/۸۷
	trainbr	logsig	۷	۰/۰۶	۰/۹۹	۶/۹۰	۰/۷۹
	trainbr	tansig	۷	۰/۰۲	۰/۹۹	۲/۱۰	۰/۹۱

مؤثر بر دقت مدل ANNs عنوان شده‌اند (Jain et al., 2008). نمودار پراکنش مقادیر ET_o اندازه‌گیری شده در مقابل مقادیر تخمین زده‌شده توسط مدل ANNs برای بهترین ساختار مربوط به هر سناریو در شکل (۴) نشان داده شده است. همان‌طور که مشاهده می‌شود، سناریو ۴ با ضریب R² برابر با ۰/۹۹ بهترین سناریو برای

با مقایسه شاخص‌های ارزیابی می‌توان نتیجه گرفت، دقت شبیه‌سازی ET_o در سناریو ۲ نسبت به سناریو ۳ بیشتر است؛ بنابراین، حتی بدون اندازه‌گیری رطوبت و تنها با در اختیار داشتن پارامترهای تابش و دما درون گلخانه می‌توان ET_o را با دقت بالایی تخمین زد. در پژوهشی مشابه نیز پارامترهای تابش و دما به‌عنوان پارامترهای

اقليمی در نظر گرفته شوند، بیشتر می‌شود (Antonopoulos and Antonopoulos, 2017; Yamaç and Todorovic, 2020).

تخمین ET_0 در گلخانه است. ساختار بهینه برای این سناریو برابر با ANN(3-7-1) به دست آمد. تحقیقات متعددی نیز نشان داده‌اند که دقت مدل‌سازی ET_0 با روش ANNs زمانی که تمام متغیرهای



شکل ۴- نمودار پراکنش مقادیر ET_0 اندازه‌گیری شده در مقابل مقادیر تخمین زده‌شده توسط مدل ANNs

جدول ۴- نتایج معیارهای ارزیابی برای مدل ANFIS در هر سناریو

شماره سناریو	نوع تابع عضویت	تعداد تابع عضویت	MBE	R^2	RRMSE	NSE
۱	trapmf	۲	-/۰.۱	۰/۹۷	۱/۴۱	۰/۹۷
۲	gbellmf	۲	-/۰.۱	۰/۹۸	۰/۸۰	۰/۹۹
۳	gbellmf	۲	-/۰.۱	۰/۹۸	۱/۰۶	۰/۹۸
۴	gbellmf	۲	-/۰.۱	۰/۹۹	۱/۰۱	۰/۹۹

محسوب شده و نیاز به آموزش با داده‌های محلی^۱ دارد. با این حال مدل‌سازی توسط ANNs در مقایسه با روش‌های ساده‌تر مثل روش‌های رگرسیونی و تجربی، عملکرد و دقت بهتری دارند (Tabari et al., 2012; Shiri et al., 2014).

همان‌طور که ملاحظه می‌شود، بهترین نوع تابع عضویت برای سناریو ۱، تابع دوزنقه‌ای و برای سناریوهای ۲ تا ۴، تابع زنگوله‌ای بود. در پژوهشی مشابه که با هدف ارزیابی مدل ANFIS برای شبیه‌سازی تبخیر-تعرق گیاه سیر در ایران انجام شد، تابع زنگوله‌ای بهترین نوع تابع عضویت با در نظر گرفتن تعداد ۲ تابع برای هر

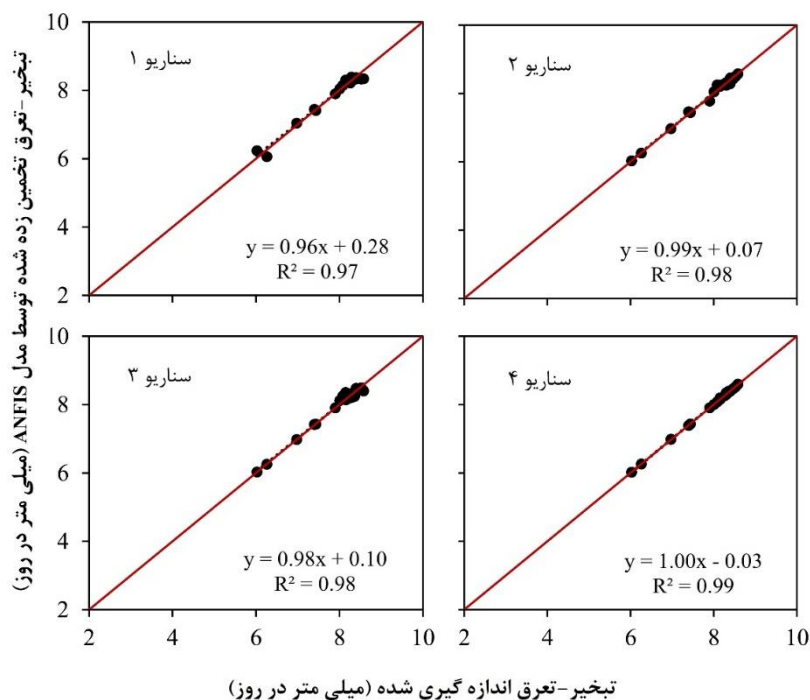
مدل ANFIS با در نظر گرفتن ۴ نوع مختلف و تعداد ۲ تابع عضویت اجرا شد. سپس شاخص‌های ارزیابی برای مدل ANFIS در مقایسه با داده‌های میکروولایسیمتر برای هر سناریو به دست آمد. نتایج مربوط به بهترین ساختار برای هر سناریو در جدول ۴ آورده شده است.

در مدل‌سازی با استفاده از روش ANNs می‌بایست در نظر داشت که این مدل‌ها مثل یک جعبه سیاه عمل کرده و هیچ‌گونه اطلاعاتی در مورد فرآیندهای فیزیکی مسئله ارائه نمی‌کنند. درحالی‌که روش‌هایی مانند روش پنمن-مانتیت، مبنای تئوری و فیزیکی داشته و فرآیند شبیه‌سازی و ارتباط بین متغیرها در یک چارچوب ریاضی بیان می‌شود. به همین دلیل روش ANNs در واقع جزو روش‌های تجربی

1- Local training

ندارد؛ به عبارت دیگر در این روش، حتی با داده‌های دما و رطوبت نیز می‌توان با دقت بالایی ET_0 در داخل گلخانه را شبیه‌سازی نمود.

ورودی، تعیین شد (Abyaneh et al., 2011). از مقایسه شاخص‌های ارزیابی در جدول ۵ می‌توان نتیجه گرفت که تفاوت چشم‌گیری بین دقت مدل‌سازی در روش ANFIS تحت سناریوهای مختلف وجود



شکل ۵- نمودار پراکنش مقادیر ET_0 اندازه‌گیری شده در مقابل مقادیر تخمین زده شده توسط مدل ANFIS

جدول ۵- نتایج آنالیز واریانس و آزمون F برای ارزیابی رابطه رگرسیون بین مقادیر اندازه‌گیری شده و محاسباتی توسط مدل‌های ANN و ANFIS

روش	شماره سناریو	پارامتر	ضرایب	ANOVA	
				F	p-value
ANN	۱	شیب	۰/۳۳	۱۹/۱۰	۰/۰۱
		عرض از مبدأ	۵/۳۲		۰/۰۲
	۲	شیب	۱/۰۶	۱۵۶/۳۷	۰/۰۳
		عرض از مبدأ	-۰/۶۲		۰/۰۰
	۳	شیب	۰/۸۹	۱۱۶/۳۳	۰/۰۰
		عرض از مبدأ	۰/۷۹		۰/۰۴
	۴	شیب	۰/۹۴	۲۳۳۹/۹۲	۰/۰۰
		عرض از مبدأ	۰/۴۲		۰/۰۱
ANFIS	۱	شیب	۰/۹۶	۷۳۴/۲۲	۰/۰۰
		عرض از مبدأ	۰/۲۸		۰/۰۴
	۲	شیب	۰/۹۹	۲۳۲۷/۵۶	۰/۰۰
		عرض از مبدأ	۰/۰۷		۰/۰۴
	۳	شیب	۰/۹۸	۱۳۰۵/۴۶	۰/۰۰
		عرض از مبدأ	۰/۱۰		۰/۰۳
	۴	شیب	۱/۰۰	۳۶۵۴۷/۲۸	۰/۰۰
		عرض از مبدأ	-۰/۰۳		۰/۰۰

ANFIS برابر با ۰/۰۱ میلی‌متر در روز، ۰/۹۷، ۱/۴۱ درصد و ۰/۹۷ به دست آمد؛ بنابراین، در شرایط عدم دسترسی به داده‌های تابش درون گلخانه، می‌توان ET_0 را با استفاده از روش ANFIS با دقت بسیار زیادی تخمین زد. با این حال، کاربرد روش‌های هوشمند برای شبیه‌سازی ET_0 و اظهار نظر قطعی در مورد عملکرد آن‌ها منوط به انجام تحقیقات بیشتر در مناطق و شرایط مختلف است.

نتیجه‌گیری

در پژوهش حاضر، عملکرد روش‌های مبتنی بر هوش مصنوعی شامل ANFIS و ANNs برای برآورد ET_0 در شرایط گلخانه مورد ارزیابی قرار گرفتند. ترکیب‌های مختلفی از پارامترهای اقلیمی به‌عنوان داده‌های ورودی به مدل در نظر گرفته شدند. مقادیر ET_0 اندازه‌گیری شده توسط میکرولاسیمتر مبنای مقایسه دقت شبیه‌سازی قرار گرفت. به‌منظور یافتن بهترین ساختار شبکه در روش ANNs، تعداد نورون‌ها در لایه میانی برای سناریوهای با ۲ و ۳ ورودی به ترتیب بین ۱ تا ۵ و ۱ تا ۷ نورون تغییر داده شد. همچنین، الگوریتم‌های لوبنبرگ-مارکوارت و تنظیم بیزی برای آموزش شبکه در نظر گرفته شدند. با توجه به نتایج حاصل از شاخص‌های ارزیابی، بهترین معماری شبکه برای الگوریتم آموزش تنظیم بیزی با تابع محرک تانژانت-سیگموئید و ساختار ANN(3-7-1) به دست آمد. علاوه بر این، روش ANNs عملکرد مطلوبی در شرایط مدل‌سازی با ۲ پارامتر ورودی به شرط اینکه یکی از داده‌های ورودی به مدل تابش رسیده به داخل گلخانه باشد، نشان داد. مدل ANFIS با در نظر گرفتن ۴ نوع مختلف و تعداد ۲ تابع عضویت اجرا و شاخص‌های ارزیابی مدل برای هر سناریو محاسبه شدند. بهترین نوع تابع عضویت برای سناریوهایی که پارامتر تابش به‌عنوان یکی از ورودی‌ها در نظر گرفته شده بود، تابع زنگوله‌ای به دست آمد. به‌طور کلی، تفاوت معناداری بین دقت مدل‌سازی در روش ANFIS تحت سناریوهای مختلف وجود نداشت. همچنین نتایج نشان داد، مدل ANFIS عملکرد بهتری نسبت به روش ANNs حتی با داده‌های ورودی محدودتر دارد.

تشکر و قدردانی

این تحقیق در قالب طرح پژوهشی (شماره ۱۳۰۷۳/۹۶۰) با حمایت مالی صندوق حمایت از پژوهشگران و فناوران کشور اجرا گردیده است و نویسندگان از مساعدت‌های آنان تقدیر می‌نمایند.

منابع

Abiodun, O., Jantan, A., Omolara, A., Dada, K., Mohamed, N. and Arshad, H. 2018. State-of-the-art

به‌طور کلی روش ANFIS در تمام سناریوها دارای خطای بیش برآورد ($MBE > 0$) است. نمودار پراکنش مقادیر ET_0 اندازه‌گیری شده توسط میکرولاسیمتر با مقادیر شبیه‌سازی شده توسط مدل ANFIS، در شکل (۵) نشان داده شده است.

همان‌طور که مشاهده می‌شود، شیب خط رگرسیون در سناریو ۴ برابر با ۱ بوده که بیانگر توانایی بسیار زیاد مدل ANFIS در شبیه‌سازی ET_0 با داده‌های دما، رطوبت و تابش است. نتایج آزمون F و آنالیز واریانس برای مدل‌های ANN و ANFIS در جدول ۵ آورده شده است. با توجه به جدول ۵، مقادیر p-value به‌دست‌آمده برای هر دو پارامتر شیب و عرض از مبدأ معادلات رگرسیون در سطح آماری $p < 0/05$ معنادار است. همچنین، فرض صفر با توجه به مقادیر p-value به‌دست‌آمده از آزمون F (کم‌تر از سطح معناداری ۰/۰۵) رد می‌شود. پس می‌توان نتیجه گرفت که در هر دو روش، روابط رگرسیون به‌دست‌آمده به‌خوبی تغییرات متغیر وابسته را شبیه‌سازی می‌کنند.

به‌طور کلی، با مقایسه نتایج به‌دست‌آمده از شبیه‌سازی ET_0 توسط مدل‌های ANFIS و ANNs می‌توان نتیجه گرفت که مدل ANFIS عملکرد بهتری نسبت به روش ANNs دارد. به‌طوری‌که شاخص RRMSE برای سناریوهای ۱ تا ۴ در مدل ANFIS به ترتیب برابر با ۱/۴۱، ۰/۸۰، ۱/۰۶ و ۱/۰۱ درصد و در مدل ANNs برابر با ۱۲/۷۰، ۲/۲۳، ۲/۱۲ و ۲/۱۰ درصد به دست آمد. برتری روش ANFIS نسبت به ANNs برای برآورد ET_0 ، در تحقیقات دیگر نیز گزارش شده است (Cobaner et al., 2011; Dou and Yang, 2018). به‌طور کلی، روش ANFIS تلفیقی از قابلیت یادگیری مدل ANNs و ویژگی‌های سیستم استنتاج فازی (FIS)، از جمله در نظر گرفتن عدم قطعیت موجود در داده‌ها است. در نتیجه دقت شبیه‌سازی در روش ANFIS نسبت به ANNs بیشتر است. مدل‌سازی با ANFIS همانند روش ANNs مبتنی بر داده است؛ بنابراین، می‌توان از این روش بدون دانستن روابط پایه و فیزیک مسئله در شبیه‌سازی‌ها استفاده نمود. به‌طور کلی مزیت مدل‌های غیر پارامتریک مثل ANFIS و ANNs نسبت به دیگر روش‌های تجربی، قابلیت مدل‌سازی پدیده‌های غیرخطی و توابع چند متغیره با دقت مطلوب است (Wang et al., 2017).

از یافته‌های مهم این پژوهش، می‌توان به عملکرد مطلوب روش ANFIS نسبت به ANNs در شرایطی که پارامترهای اقلیمی محدود هستند، اشاره نمود. به‌طوری‌که شاخص‌های ارزیابی شامل MBE، R² و RRMSE برای سناریو ۱ در روش ANNs به ترتیب برابر با ۰/۶۸ میلی‌متر در روز، ۰/۶۸، ۱۲/۷۰ درصد و ۰/۴۴ و در روش

- Irmak, S., Irmak, A., Allen, R.G. and Jones, J.W. 2003. Solar and net radiation-based equations to estimate reference evapotranspiration in humid climates. *Journal of Irrigation and Drainage Engineering*. 129: 336–347.
- Jang, J. 1993. ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*. 23 (3): 665–685.
- Jain, S.K., Nayak, P.C. and Sudheer, K.P. 2008. Models for estimating evapotranspiration using artificial neural networks, and their physical interpretation. *Hydrological Processes*. 22 (13): 2225–2234.
- Kaur, S., Randhawa, S. and Malhi, A., 2021. An efficient ANFIS based pre-harvest ripeness estimation technique for fruits. *Multimedia Tools and Applications*. 80(13): 19459-19489.
- Kouadio, L., Deo, R., Byrareddy, V., Adamowski, J., Mushtaq, S. and Phuong Nguyen, V., 2018. Artificial intelligence approach for the prediction of Robusta coffee yield using soil fertility properties. *Computers and Electronics in Agriculture*. 155: 324-338.
- Kumar, M., Raghuvanshi, N.S. and Singh, R. 2011. Artificial neural networks approach in evapotranspiration modelling: a review. *Irrigation Science*. 29 (1): 11–25.
- Lohani, A., Kumar, R. and Singh, R. 2012. Hydrological time series modeling: A comparison between adaptive neuro-fuzzy, neural network and autoregressive techniques. *Journal of Hydrology*. 442-443.
- McCulloch, W. and Pitts, W. 1943. A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*. 5(4): 115-133.
- Mamdani, E. 1975. Advances in the linguistic synthesis of fuzzy controllers. *International Journal of Man-Machine Studies*. 8(6): 669-678.
- Monteith, J.L. and Unsworth, M.H. 1990. *Principles of Environmental Physics* (Second ed.). Edward Arnold.
- Movahednejad M.H., Saedi S.I. 2020. Development of an ANN Model for the Prediction of Plant Actual Evapotranspiration under a Hydroponic Growing System. *Iranian Journal of Irrigation and Drainage*. 4(14): 1164-1174.
- Partel, V., Charan Kakarla, S. and Ampatzidis, Y., 2019. Development and evaluation of a low-cost and smart technology for precision weed management utilizing artificial intelligence. *Computers and Electronics in Agriculture*. 157: 339-350.
- Priestley, C. and Taylor R. J. 1972. On the assessment of surface heat flux and evaporation using large-scale parameters. *The Monthly Weather Review*. 100: 81–92
- Rahimkhoob, H., Sohrabi, T. and Delshad, M. 2020. Assessment of reference evapotranspiration estimation methods in controlled greenhouse conditions. *Irrigation Science*. 38: 389–400 <https://doi.org/10.1007/s00271-020-00680-5>
- in artificial neural network applications: A survey. *Heliyon*. 4(11): 00938.
- Abyaneh, H., Nia, A., Varkeshi, M., Marofi, S. and Kisi, O. 2011. Performance Evaluation of ANN and ANFIS Models for Estimating Garlic Crop Evapotranspiration. *Journal of Irrigation and Drainage Engineering*. 137(5): 280-286.
- Adnan, R., Mostafa, R., Islam, A., Kisi, O., Kuriqi, A. and Heddam, S. 2021. Estimating reference evapotranspiration using hybrid adaptive fuzzy inferencing coupled with heuristic algorithms. *Computers and Electronics in Agriculture*. 191:106541.
- Allawi, M., Jaafar, O., Ehteram, M., Mohamad Hamzah, F. and El-Shafie, A. 2018. Synchronizing Artificial Intelligence Models for Operating the Dam and Reservoir System. *Water Resources Management*. 32(10): 3373-3389.
- 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 56, Food and Agriculture Organization of the United Nations, Rome.
- Antonopoulos, V. and Antonopoulos, A. 2017. Daily reference evapotranspiration estimates by artificial neural networks technique and empirical equations using limited input climate variables. *Computers and Electronics in Agriculture*. 132: 86-96.
- Bhat, N. and McAvoy, T., 1990. Use of neural nets for dynamic modeling and control of chemical process systems. *Computers & Chemical Engineering*. 14(4-5): 573-582.
- Cobaner, M. 2011. Evapotranspiration estimation by two different neuro-fuzzy inference systems. *Journal of Hydrology*. 398 (3–4): 292–302.
- Costa, L., Kunwar, S., Ampatzidis, Y. and Albrecht, U. 2021. Determining leaf nutrient concentrations in citrus trees using UAV imagery and machine learning. *Precision Agric.* <https://doi.org/10.1007/s11119-021-09864-1>
- Dou, X. and Yang, Y. 2018. Evapotranspiration estimation using four different machine learning approaches in different terrestrial ecosystems. *Computers and Electronics in Agriculture*. 148: 95-106.
- Gonzalez del Cerro, R., Subathra, M., Manoj Kumar, N., Verrastro, S. and Thomas George, S. 2021. Modelling the daily reference evapotranspiration in semi-arid region of South India: A case study comparing ANFIS and empirical models. *Information Processing in Agriculture*. 8(1): 173-184.
- Hargreaves, G.H. and Samani Z.A, 1985 Reference crop evapotranspiration from temperature. *Applied Engineering in Agriculture*. 1(2):96–99.
- He, Z. 2014. Artificial neural network model of forecasting relative humidity in different humid and arid areas of China. *Computer Modelling and New Technologies*. 18(6): 225-232

- models for reference evapotranspiration modeling using limited climatic data in a semi-arid highland environment. *Journal of Hydrology*. 444-445: 78-89.
- Takagi, T., Sugeno, M., 1985. Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man, and Cybernetics*. 15 (1): 116-132.
- Wang, L., Kisi, O., Zounemat-Kermani, M. and Li, H. 2017. Pan evaporation modeling using six different heuristic computing methods in different climates of China. *Journal of Hydrology*. (Amst) 544: 407-427.
- Yamaç, S. and Todorovic, M., 2020. Estimation of daily potato crop evapotranspiration using three different machine learning algorithms and four scenarios of available meteorological data. *Agricultural Water Management*. 228: 105875.
- Zeleeke, K. and Wade, L. 2012. Evapotranspiration Estimation using Soil Water Balance, Weather and Crop Data. In A. Irmak (Ed.), *Evapotranspiration. Remote Sensing and Modeling*. (1 ed). 41-58.
- Rahimikhoob, H., Sohrabi, T. and Delshad, M. 2021. Sensitivity Analysis of Reference Crop Evapotranspiration Estimation Methods to Meteorological Factors in Greenhouse Conditions. *Iranian Journal of Irrigation and Drainage*. 15(2): 307-315.
- Sayed, T., Tavakolie, A. and Razavi, A. 2003. Comparison of adaptive network based fuzzy inference systems and B-spline neuro-fuzzy mode choice models. *Water Resources Research*. 17 (2): 123-130.
- Shiri, J., Nazemi, A., Sadraddini, A., Landaras, G., Kisi, O., Fakheri Fard, A. and Marti, P. 2014. Comparison of heuristic and empirical approaches for estimating reference evapotranspiration from limited inputs in Iran. 108: 230-241.
- Sutton, R. and Barto, A. 1998. *Reinforcement Learning: An Introduction (Adaptive computation and machine learning)*. MIT Press.
- Tabari, H., Kisi, O., Ezani, A. and Hosseinzadeh Talaei, P. 2012. SVM, ANFIS, regression and climate based

Performance Evaluation of Artificial Neural Networks and Adaptive Neuro-Fuzzy Inference System in Estimating Reference Evapotranspiration under Greenhouse Conditions

H. Rahimikhoob^{1*}, T. Sohrabi², M. Delshad³

Received: Feb.08, 2022

Accepted: Mar.13, 2022

Abstract

One of the essential factors for agricultural irrigation management and planning is an accurate estimation of reference evapotranspiration (ET_o). The application of the standard model (FAO-Penman-Monteith) to estimate ET_o is restricted due to the availability of climatic variables including temperature, humidity, radiation, wind speed as well as the availability of the mentioned hypotheses in FAO 56. Accessibility to all climatic parameters or satisfaction of the FAO-Penman-Monteith assumptions is often not possible in some areas or in controlled environments (greenhouses). Therefore, using methods that can provide an accurate estimate of ET_o with fewer input parameters is preferable. The aim of the present study was to evaluate the performance of two methods of artificial neural networks (ANNs) and adaptive neuro-fuzzy inference system (ANFIS) for estimating ET_o in the research greenhouse of the College of Agriculture and Natural Resources of the University of Tehran, located in Karaj, Iran. Based on the measured climatic parameters inside the greenhouse, different combinations were created and evaluation indicators were calculated for each method and scenario. The best neural network structure was obtained for Scenario 4 (radiation, temperature, humidity) with 7 neurons in the hidden layer and the Bayesian Regularization training algorithm. ANFIS model was designed with different membership functions. The results showed that there was no significant difference between the performance of the ANFIS method under different scenarios. In other words, even with temperature and humidity data, ET_o can be simulated with high accuracy by the ANFIS method. A comparison of evaluation indicators between ANFIS and ANNs models showed that ANFIS performed better than ANNs method. The calculated relative root mean square error (RRMSE) for scenarios 1 to 4 in the ANNs model was equal to 12.70, 2.23, 2.12, and 2.10% however it was equal to 1.41, 0.80, 1.06, and 1.01% in ANFIS model.

Keywords: Adaptive neuro-fuzzy inference system, Artificial neural networks, Reference evapotranspiration

1- Ph.D, Department of Irrigation and Reclamation Engineering, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran

2- Professor, Department of Irrigation and Reclamation Engineering, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran

3- Associate Professor, Department of Horticultural Sciences, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran

(* Corresponding author Email: h.rahimikhoob@ut.ac.ir)