

مقاله علمی-پژوهشی

توسعه مدل شبکه عصبی برآورد تبخیر-تعرق واقعی گیاه در یک سامانه کشت هیدروپونیک

محمد هادی موحدنژاد^{۱*}، سید ایمان ساعدی^۲

تاریخ دریافت: ۱۳۹۸/۱۲/۲۲ تاریخ پذیرش: ۱۳۹۹/۳/۹

چکیده

توسعه سامانه‌های آبیاری هوشمند با هدف تأمین به‌هنگام و به میزان موردنیاز آب گیاه یک راهبرد مهم برای افزایش کمیت و کیفیت محصولات کشاورزی با حداقل مصرف آب می‌باشد. از طرفی تعیین میزان آب مورد نیاز گیاه تا حد زیادی به برآورد دقیق تبخیر-تعرق در پوشش گیاهی وابسته است. در این تحقیق از مدل شبکه عصبی برای برآورد تبخیر-تعرق در یک سیستم کشت دوار هیدروپونیک کاهو در فضای بسته استفاده شد. مدت زمان کشت ۳۰ روز و بازه‌های زمانی داده‌برداری ۱۰ دقیقه بود. تبخیر-تعرق واقعی گیاه کاهو در سیستم کشت هیدروپونیک مذکور در راستای طراحی سامانه آبیاری به کمک مدل منطق فازی برآورد گردید و با توجه به نتایج مطلوب حاصل از ارزیابی محصول کاشته شده و آب مصرفی، کارایی آن به اثبات رسید. لذا از آن به‌عنوان معیاری برای اعتبارسنجی مدل شبکه عصبی این پژوهش استفاده شد. تعداد داده‌ها برای مدل شبکه عصبی حدود ۴۵۰۰ بوده که به‌طور تصادفی به سه قسمت، ۷۰ درصد (آموزش)، ۱۵ درصد (ارزیابی) و ۱۵ درصد (آزمون) تقسیم گردید. به‌منظور یافتن مناسب‌ترین معماری شبکه عصبی، ساختارهای مختلفی ارزیابی شد. بهترین نتیجه در الگوریتم BR با سه لایه پنهان و توپولوژی ۱۰-۱۰-۸ و نیز تابع انتقال tansig در تمامی لایه‌ها، به دست آمد. برای این ساختار، خطا مطلق و ضریب تعیین به ترتیب ۰/۴۳ و ۹۹/۹۸ درصد تعیین گردید. همچنین در شبکه یک‌لایه با توجه به سادگی، الگوریتم BR با یک لایه پنهان با تعداد ۸ نرون و تابع انتقال logsig در لایه پنهان و تابع tansig در لایه خروجی به‌عنوان بهترین مدل انتخاب شد. خطا مطلق و ضریب تعیین این ترکیب به ترتیب ۰/۷۹ و ۹۸/۸۴ درصد به دست آمد. با توجه آنالیز حساسیت، رطوبت و دما به ترتیب به‌عنوان مهم‌ترین پارامترهای مؤثر در پیش‌بینی تبخیر-تعرق حاصل شدند.

واژه‌های کلیدی: تبخیر-تعرق، شبکه عصبی، کاهو، کشت هیدروپونیک، منطق فازی

مقدمه

است که اولاً آسان بوده و ثانیاً نتایج حاصل از آن واقعی‌تر باشد (علیزاده، ۱۳۹۰). از میان راهبردهای مختلف، روش پنمن مونتیت فائو به‌عنوان تنها مدل استاندارد برای تخمین تبخیر-تعرق مرجع توصیه شده است. همچنین روش‌های برآورد تبخیر-تعرق توسط هوش مصنوعی و از جمله منطق فازی و شبکه عصبی نیز در این زمینه مورد توجه محققین بوده است (Cobaner, 2011; Kişi and Öztürk, 2007; Shiri et al., 2013). در پژوهشی الگوریتمی برای برآورد تبخیر-تعرق مرجع ارائه شد که مبتنی بر پارامترهای محیطی نظیر دمای هوای مینیمم و ماکزیمم ماهانه، ساعات آفتابی، فشار بخار واقعی، رطوبت نسبی مینیمم و ماکزیمم و سرعت باد به‌عنوان ورودی مدل بود. نتایج کاربرد عملی این الگوریتم در برنامه‌ریزی و مدیریت منابع آب بر اساس پارامترهای مؤثر بر تبخیر-تعرق به اثبات رسید (Jovic et al., 2018). از جمله پژوهش‌های دیگری که در برآورد تبخیر-تعرق اخیراً توسط محققین مورد توجه قرار گرفته است، می‌توان به ارزیابی روش‌های شبکه

اتخاذ روش‌هایی مبتنی بر فناوری برای مدیریت منابع آب و افزایش بهره‌وری آن در کشاورزی امری ضروری است. یکی از این راهبردها توسعه سامانه‌های آبیاری است که بتواند با حفظ شرایط زیستی گیاه حداقل آب را به آن برسانند (Evans et al., 2006; Reuter and Everett, 2000). بیش از ۹۹ درصد آب مصرفی گیاه صرف تبخیر-تعرق می‌شود. بنابراین، منظور از تعیین تبخیر-تعرق تعیین مقدار آبی است که باید به یک پوشش زراعی داده شود تا در طول رویش صرف تبخیر-تعرق کند و بدون آنکه با تنش آبی مواجه شود رشد خود را تکمیل کرده و بیشینه مقدار محصول را تولید نماید (علیزاده، ۱۳۹۰). در برآورد تبخیر-تعرق روشی از نظر عملی مطلوب

۱- استادیار گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود، ایران
۲- استادیار گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود، ایران
(* نویسنده مسئول: Email: mhmovahed@shahroodut.ac.ir)

در مطالعه‌ای دیگر، تبخیر-تعرق روزانه گیاه مرجع به روش هوش مصنوعی و روش‌های تجربی در مقایسه با اندازه‌گیری‌های لایسیمتری در اقلیم نیمه‌خشک سرد همدان شبیه‌سازی شد. نشان داده شد که روش‌های هوش مصنوعی بهتر از روش‌های کلاسیک قادر به تخمین رفتار سیستم در همه مراحل عملکرد چه مرحله افزایش تبخیر-تعرق و چه مرحله کاهش تبخیر-تعرق می‌باشند. بر اساس نتایج، میزان R^2 برای آموزش شبکه به ۰.۹۵ رسید (بیات ورکشی و همکاران، ۱۳۸۸). در نهایت، میزان تبخیر-تعرق روزانه با شبکه عصبی در یک پژوهش دیگر مدل گردید. بر اساس نتایج به‌دست‌آمده از ارزیابی شبکه عصبی، میزان $RSME$ و R^2 به ترتیب ۰.۹۶ و 0.4 mm/day (Abudu et al., 2010).

در گلخانه‌های هیدروپونیک کشت مترامک و سایه انداز تقریباً کامل است، از این رو، آب مورد نیاز بیشتر به تعرق وابستگی پیدا می‌کند. برای برآورد نیاز آبی گیاهان در شرایط گلخانه باید روش‌های مورد استفاده در شرایط باز اصلاح شده و یا با توجه به عوامل مؤثر بر تبخیر-تعرق در شرایط گلخانه‌ای روش‌های جدیدی ایجاد شوند. عوامل محیطی مهم و اثرگذار بر تبخیر-تعرق گیاهان گلخانه‌ای عبارتند از: نور، دما، رطوبت نسبی هوا، تهویه. به همین دلیل از طریق تخمین بر اساس داده‌های اقلیمی می‌توان آب مورد نیاز را در فواصل کوتاه تعیین کرد (انتصاری و همکاران، ۱۳۸۶). تحقیقات در زمینه تخمین این پارامتر در کشت در فضای بسته، جامع و کامل نیست. به همین دلیل در برآورد تبخیر-تعرق عدم قطعیت زیادی وجود داشته و استفاده از هوش مصنوعی و مدل‌های مختلف امکان برآورد دقیق‌تر تبخیر-تعرق واقعی را میسر می‌سازد. در پژوهشی، جوادی کیا و همکاران یک سامانه هوشمند آبیاری مبتنی بر منطق فازی برای کشت گلخانه‌ای توسعه داده و آن را با روش On/Off مقایسه کردند (Javadi Kia et al., 2009). همچنین، در دو پژوهش مشابه دیگر، کنترل‌گرهای فازی باهدف کاهش مصرف آب در کشت گلخانه‌ای توسعه داده شدند، با این تفاوت که در تحقیق اول ورودی‌ها شامل دمای محیط گلخانه و رطوبت خاک بود، در حالی که مدت زمان آبیاری به‌عنوان خروجی آن مدنظر قرار گرفت (Ed-Dahhak et al., 2013). اما در پژوهش دوم ورودی‌ها شامل میزان رطوبت خاک و خطای رطوبت خاک و خروجی آن تفاوت سطح آب بود (Ji et al., 2012). این دو سامانه هر دو در عین سادگی این قابلیت را داشتند که به شکلی مؤثر در محیط گلخانه مورد استفاده قرار گرفته و سهم بسزایی در کاهش مصرف آب ایفا نماید. در پژوهشی کاربردی، یک سامانه کنترل خودکار برای تهیه و اعمال زمان واقعی محلول غذایی در کشت هیدروپونیک گوجه‌فرنگی توسعه داده شد. میزان تعرق تجمعی مهم‌ترین عامل در تصمیم‌گیری کودآبیاری و شروع به کار پمپ مربوطه بود. تعیین چرخه کودآبیاری بر اساس ظرفیت نگهداری آب در بستر شنی که از روی ویژگی‌های فیزیکی آن و حجم منطقه توسعه ریشه

عصبی برای مدل‌سازی تبخیر-تعرق واقعی محصول در زمین‌های با و بدون پوشش مالچ (Tang et al., 2018)، به‌کارگیری متغیرهای اقلیمی با ورودی محدود در کنار شبکه‌های عصبی مصنوعی و معادلات تجربی برای برآورد تبخیر-تعرق مرجع روزانه مبتنی بر یادگیری ماشین (Patil and Deka, 2016; Reis et al., 2019; Dou and Yang, 2018) اشاره نمود. همچنین در تحقیقی دیگر مدلی مبتنی بر یادگیری عمیق برای برآورد تخمین تبخیر-تعرق مرجع برای ایالت پنجا ب هند ارائه شد که قادر بود نسبت به چند مدل رایج مثل پنمن مونتیت، RF، GLM و GBM عملکرد بهتری نشان دهد (Saggi and Jain, 2019). همچنین، در یک مطالعه صورت گرفته، به منظور پیش‌بینی تبخیر-تعرق روزانه با استفاده از شبکه عصبی مدلی ارائه شد. در این مدل، ورودی شبکه شامل دمای حداقل، دمای حداکثر، دمای متوسط، رطوبت نسبی، ساعات آفتابی، سرعت باد و تابش برون زمینی بود. کارایی این مدل با الگوریتم LM با تابع $tansig$ با یک لایه پنهان و ۸ نرون با دقت ۹۹.۹۴ درصد و خطای ۰.۰۵۴۷۵ به اثبات رسید (قبائی سوق و همکاران، ۱۳۸۹). علاوه بر این، قابلیت سیستم استنتاج عصبی-فازی تطبیقی در بهبود تخمین میزان تبخیر-تعرق روزانه گیاه مرجع (ET_0) نیز راهبردی بود که در یک پژوهش مشابه بررسی گردید. حاصل تحقیق بیانگر دقت بالای مدل‌های عصبی-فازی با مقادیر $RSME$ بین ۰.۲۷۶ تا ۰.۴۳۷ میلی‌متر در تخمین میزان تبخیر-تعرق و نیاز آبی روزانه گیاه مرجع بود. مدل‌های شبکه عصبی مصنوعی با مقادیر $RSME$ به میزان ۰.۲۹۸ تا ۱۲.۵ میلی‌متر نیز عملکرد بهتری نسبت به معادله‌های تجربی نشان دادند (کریمی و همکاران، ۱۳۹۲). در مطالعه‌ای دیگر از دو مدل ترکیبی شامل تلفیق شبکه عصبی-ژنتیک و شبکه عصبی-فازی در کنار شبکه عصبی مصنوعی جهت پیش‌بینی نیاز آبی گیاه سیر استفاده گردید. نتایج مدل‌سازی تبخیر-تعرق گیاه سیر نشان از برتری روش تلفیقی شبکه عصبی-ژنتیک در مقایسه با دو روش شبکه عصبی و شبکه عصبی-فازی داشت. الگوریتم ژنتیک در ترکیب با شبکه عصبی توانست خطای آزمون شبکه را نسبت به شبکه عصبی-فازی به میزان ۲۴ درصد کاهش دهد (زارع ایبانه و همکاران، ۱۳۹۰). همچنین محققین با به‌کارگیری منطق فازی و شبکه عصبی مصنوعی تبخیر و تعرق بالقوه گیاه مرجع را برآورد نمودند. با توجه به $RMSE$ معادل ۰.۸۷ و R^2 برابر با ۰.۹۳ روش ترکیبی عصبی-فازی کارایی مناسبی در تخمین تبخیر-تعرق به همراه داشت (پیرمردیان و ابول‌پور، ۱۳۸۹).

- 1- Random forests
- 2- Generalized Linear Model
- 3- Gradient Boosting Machine
- 4- Levenberg Marquardt

(On/Off) به‌عنوان شاهد بوده است. مدت‌زمان کشت برای هر روش آبیاری مذکور ۳۰ روز و بازه‌های زمانی داده‌برداری ۱۰ دقیقه بود. در روش غیر فازی آبیاری (پمپاژ آب به سینی زیرین) زمانی انجام می‌شود که سطح آب در این سینی از حد از پیش تعیین‌شده توسط حسگرها کمتر شود و عملاً دسترسی گیاهان به آب از بین رفت. اما مبنای روش آبیاری فازی برآورد تبخیر-تعرق واقعی با استفاده از روش منطق فازی و بهره‌گیری از نظر فرد خبره بود. سه پارامتر یعنی دما، رطوبت نسبی و وضعیت لامپ (روشن و خاموش) (که توسط حسگرهای واقع بر محیط رشد گیاه خوانده می‌شدند) به‌عنوان ورودی مدل فازی مدنظر بودند که پس از تحلیل در واحد پردازش مرکزی سامانه و برآورد تبخیر-تعرق (به‌عنوان خروجی مدل) دستورات لازم به عملگرها صادر شد (شکل ۱ ب). تعیین خروجی (تبخیر-تعرق) بر اساس توابع عضویت هر ورودی، روابط بین ورودی‌ها و تعداد پنجاه قاعده اگر - آنگاه فازی صورت پذیرفت که با توجه به سطح زیر کشت سامانه تبدیل به واحد حجم گردید (ساعدی و همکاران، ۱۳۹۷). هر مقدار تبخیر-تعرق اصولاً منجر به صدور دستور آبیاری نمی‌شود. از این‌رو، مقادیر برآورد شده فازی تبخیر-تعرق در بازه‌های زمانی ده‌دقیقه‌ای باهم جمع شدند تا به یک حد بحرانی رسید. در این زمان فرمان آبیاری برای پر کردن سینی زیرین صادر گردید. حد بحرانی مذکور معادل است با از دست رفتن حجم آب سهل‌الوصول گیاه^۱ که این پارامتر با توجه به روابط آب و خاک و گیاه که مبتنی بر حداکثر تخلیه مجاز برای کاهو و ظرفیت زراعی بستر بوده محاسبه گردید (علیزاده، ۱۳۹۰؛ ساعدی و همکاران، ۱۳۹۷).

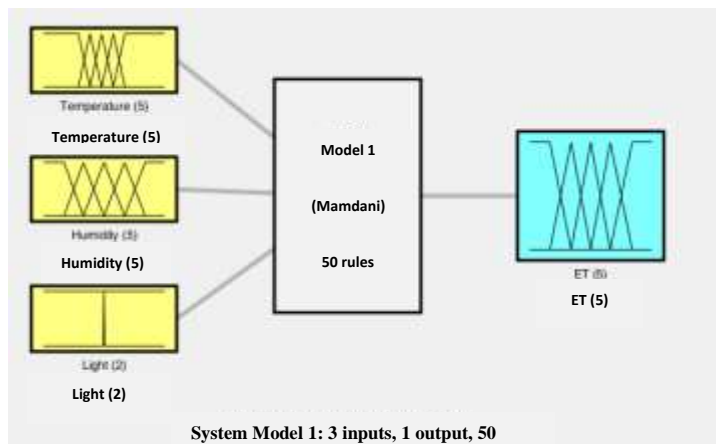
ارزیابی دو راهبرد آبیاری فازی و غیرفازی (On/Off) مذکور با کشت گیاه کاهو در سامانه مذکور و به مدت سی روز برای هر راهبرد، صورت گرفت. نتایج مقایسه این دو روش آبیاری نشان داد که مدل فازی عملکرد بهتری داشته است. بر اساس نتایج، پارامترهای رشدی گیاه و نیز عملکرد و اجزاء عملکرد در کنار میزان آب مصرفی در کشت فازی نسبت به کشت On/Off به شکل معنی‌داری بهتر بود (ساعدی و همکاران، ۱۳۹۷). به‌بیان‌دیگر، مدل فازی به شکل مطلوبی قادر بود تبخیر-تعرق واقعی گیاه را برآورد کند. از این‌رو، با توجه به داده‌های برداشت‌شده ورودی و خروجی مدل فازی و مطلوب بودن نتایج رشدی، در این پژوهش نتایج حاصل از مدل فازی به‌عنوان مقادیر اندازه‌گیری شده تبخیر-تعرق واقعی لحاظ گردید و از آن برای ارزیابی شبکه عصبی (به‌عنوان مقادیر پیش‌بینی‌شده) استفاده گردید.

مشخص می‌شد، صورت گرفت. بر این اساس، بیشینه تخلیه ۲۵ درصد آب از بستر ریشه برای جلوگیری از تنش آبی محصول انتخاب گردید (Neto et al., 2014). در تحقیقی که روی پارامترهای تبخیر-تعرق در شرایط گلخانه‌ای کاهو انجام گرفت با استفاده از روش رگرسیونی درجه‌دو مدلی برای تبخیر-تعرق ارائه گردید. پارامتر مورد‌استفاده در این مدل دما بوده و رطوبت در نظر گرفته نشد. ضریب تعیین این مدل ۰/۶۳ با خطای میانگین ۱۴/۵ درصد به دست آمد (Ciolkosz et al., 1998). در پژوهشی دیگر، میزان تبخیر-تعرق خیار گلخانه‌ای با روش‌های رگرسیون و شبکه عصبی مدل گردید. بر اساس نتایج، میزان RSME برای مدل رگرسیون و شبکه عصبی به ترتیب ۱/۰۶ و ۰/۲۶۷ به دست آمد که نشان از عملکرد مناسب شبکه عصبی می‌باشد (مؤذن‌زاده، ۱۳۹۴). در پژوهشی از روش پنمن موتیث برای تخمین تبخیر-تعرق گیاه کاهو در کشت هیدروپونیک استفاده گردید. نتایج نشان داد این روش با دقت ۷۰ درصد توانست تبخیر-تعرق را پیش‌بینی کند (Mathieu and Albright, 2002). درنهایت، در مطالعه‌ای مشابه، مدل اصلاح شده پنمن موتیث با معادلات تجربی و مدل رگرسیونی برای شرایط گلخانه برای تولید گل ژربرا مقایسه گردید. ضریب تعیین این مدل ۹۳/۵ درصد گردید، که نشان‌دهنده کارایی این روش بود (Mascarini et al., 2001).


با توجه به مطالب مذکور و عدم وجود تحقیقات کافی در مورد مدل‌سازی تبخیر-تعرق در شرایط کشت هیدروپونیک در فضای بسته و پایین بودن دقت تخمین تبخیر-تعرق، ضرورت این تحقیق نمایان گردید. لذا هدف از تحقیق حاضر، ارائه یک مدل هوش مصنوعی مبتنی بر شبکه‌های عصبی مصنوعی برای برآورد تبخیر-تعرق واقعی گیاه در شرایط کشت هیدروپونیک دوار در داخل اتاق می‌باشد. ارزیابی این مدل به کمک داده‌های ورودی برداشت‌شده و مبتنی بر برآورد مناسب تبخیر-تعرق واقعی گیاه (به روش منطق فازی) که منجر به نتایج مطلوب کشت‌شده، می‌باشد.

مواد و روش‌ها

در سامانه کشت هیدروپونیک دوار مورد بحث که موضوع پژوهش قبلی نویسنده بوده (ساعدی و همکاران، ۱۳۹۷) کیسه‌های کشت محتوی مخلوط پرلیت و کوکوپیت به‌عنوان بستر کشت در محیط یک استوانه دوار استفاده شد. واحد نوردهی نیز متشکل بود از یک رشته ۱۷ متری از لامپ‌های LED نواری سفید که در اطراف یک لوله گالوانیزه به قطر ۱۰ سانتیمتر پیچیده شد که در مجموع ۱۵۰ وات توان نیاز داشت. آبیاری گیاهان از طریق پمپاژ آب به سینی زیرین صورت می‌گیرد و گیاهان دوران‌کننده به ترتیب وارد سینی زیرین شده و آب و مواد غذایی را دریافت می‌کرد. (شکل ۱ الف). دو راهبرد آبیاری برای این سامانه مدنظر بود که شامل روش مبتنی بر منطق فازی (برآورد تبخیر-تعرق واقعی به کمک منطق فازی) و روش غیرفازی



(ب)



(الف)

شکل ۱- الف) دستگاه کشت هیدروپونیک دوار مورد مطالعه، ب) کلیت مدل فازی برآورد تبخیر-تعرق

شامل دو تابع تانژانت هایپربولیک سیگموئید (tansig) (رابطه ۲) و سیگموئید لگاریتمی (logsig) (رابطه ۳) بودند (Demuth and Beale, 2009).

$$Y_i = \frac{2}{(1 + e^{-2X_i})} - 1 \quad (2)$$

$$Y_i = \frac{1}{(1 + e^{-X_i})} \quad (3)$$

X_i = داده‌های ورودی، Y_i = داده خروجی تابع

لایه‌های پنهان به صورت تک لایه‌ای، دولایه‌ای و سه لایه‌ای بررسی شدند. تعداد نورن نیز از ۲ تا ۱۰ نورن مورد بررسی قرار گرفت. سپس با برنامه نوشته شده، چهار المان شامل تعداد لایه‌های پنهان، تعداد نورن، الگوریتم آموزش و تابع آستانه بررسی شده و برای تمام ترکیب‌های ایجاد شده بر اساس چهار المان، خطا و بقیه پارامترهای ارزیابی تعیین گردید. بر اساس کمترین میانگین مربعات خطا (MSE) (رابطه ۴) بهترین مدل برای هر دسته به دست آمد. پارامترهای ارزیابی دیگر شامل ضریب همبستگی r^2 (رابطه ۵) و ضریب تعیین R^2 (رابطه ۶) (MAE) (Demuth and Beale, 2009) در نظر گرفته شدند.

$$MSE = \frac{\sum_1^n (y - \hat{y})^2}{n} \quad (4)$$

$$R = \sqrt{\frac{\sum_1^n (y - \bar{y})^2 - \sum_1^n (y - \hat{y})^2}{\sum_1^n (y - \bar{y})^2}} \quad (5)$$

2- Correlation Coefficient

3- Coefficient of Determination

4- Absolute Mean Error

برای مدل‌سازی تبخیر-تعرق با استفاده از شبکه عصبی در این پژوهش از نرم‌افزار MATLAB استفاده شد. داده‌ها در ابتدا در یک ماتریس وارد شده، سپس به شبکه فراخوانده شدند و در نهایت در دو مجموعه ورودی و خروجی تقسیم گردیدند. ورودی‌ها شامل زمان، دما، رطوبت نسبی و وضعیت روشنایی (خاموش یا روشن بودن لامپ) بوده و خروجی نیز شامل میزان تبخیر-تعرق (در بازه زمانی ده دقیقه) بود. حجم کل داده برای ۳۰ روز داده‌برداری، حدود ۴۵۰۰ داده شد. داده‌های به طور تصادفی به سه قسمت، ۷۰، ۱۵ و ۱۵ درصد تقسیم گردید. قسمت اول برای یادگیری، و قسمت دوم و سوم نیز برای ارزیابی و آزمون مدل تعیین گردید. در ادامه داده‌ها برای شبکه نرمال‌سازی شد. معادلات نرمال‌سازی، تمام داده‌ها را بین منفی یک و یک قرار می‌دهد (Demuth and Beale, 2009).

$$Normalize(x) = \frac{(x - \min(x))}{(\max(x) - \min(x))} * 2 - 1 \quad (1)$$

X = داده‌های آزمایش، $Normalize(x)$ = داده‌های تبدیل‌شده

بین بازه [۱] و [-۱]

شبکه مورد استفاده از نوع چندلایه‌ی پرسپترون (MLP) با الگوریتم پس انتشار پیشخور (FFBP) بود. برای آموزش داده‌ها در فضای نرم‌افزار، برنامه‌ای نوشته شد. همچنین، برای بهینه‌سازی مدل، چهار المان بررسی گردید. این المان‌ها شامل الگوریتم یادگیری، تابع آستانه، تعداد لایه‌های پنهان و تعداد نورن‌های لایه‌های پنهان بودند. الگوریتم‌های یادگیری شامل دو الگوریتم لوبنبرگ-مارکوارت (LM) و تنظیم بی‌زین^۱ (BR)، بود. توابع آستانه مورد استفاده در مدل‌سازی

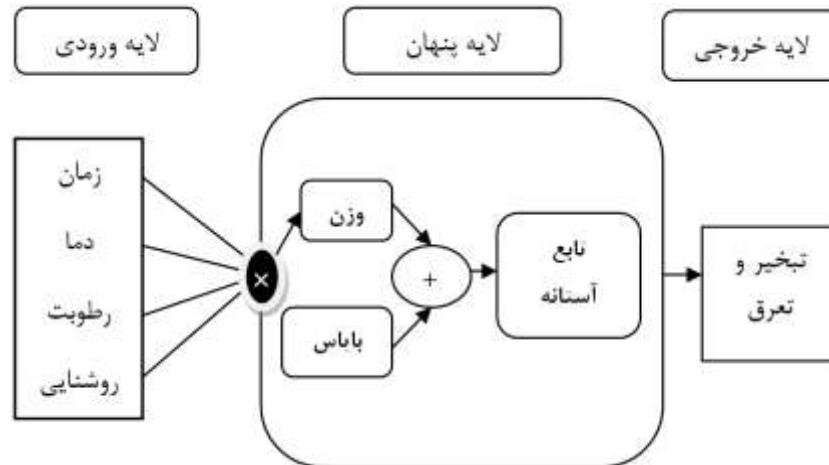
1- Bayesian Regularization

پیش بینی شده توسط شبکه نسبت به داده‌های خروجی واقعی نیز به دست می‌آید. این اطلاعات نیز برای حالات بهینه ارائه گردید. در شکل ۲ ساختار شبکه عصبی مورد استفاده در این پژوهش نشان داده شده است.

$$MAE = \frac{1}{n} \sum_1^n |y - \hat{y}| \quad (6)$$

y=داده واقعی، \bar{y} = میانگین داده‌های خروجی، \hat{y} = داده برآورد شده‌ی مدل

بهترین نتایج برای هر دسته‌ی آزمایشی برای الگوریتم‌های منتخب و دو تابع آستانه در دو ترکیب تعداد لایه و تعداد نورن در جدولی ارائه شد. همچنین در برنامه نوشته شده، R^2 داده‌های خروجی



شکل ۲- ساختار شبکه عصبی مورد استفاده در این پژوهش

خطای مطلق و ضریب تعیین به ترتیب ۰/۴۳ و ۹۹/۹۸ درصد تعیین گردید. برای الگوریتم LM نتایج برای سه لایه پنهان با توپولوژی ۱۰-۱-۲ و تابع انتقال tansig-tansig-logsig و تابع tansig برای لایه خروجی با خطا و ضریب تعیین ۰/۳۰ و ۹۹/۲۳ درصد انتخاب گردید (جدول ۱).

همچنین در تحقیقی مشابه از دقت بالای مدل عصبی فازی در برآورد تبخیر-تعرق اشاره گردید (کریمی و همکاران، ۱۳۹۲). همچنین، در تحقیقی محققین نشان دادند که الگوریتم ژنتیک در ترکیب با شبکه عصبی می‌تواند خطای آزمون شبکه را نسبت به شبکه عصبی-فازی به میزان ۲۴ درصد کاهش دهد (زراع ابیانه و همکاران، ۱۳۹۰). همچنین دیگر محققین نیز با به دست آوردن ضریب تعیین ۰/۹۵ از بهبود روش شبکه عصبی نسبت به روش‌های کلاسیک برآورد تبخیر-تعرق خبر دادند (بیات ورکشی و همکاران، ۱۳۸۸). با توجه به دقت پایین مدل‌های رگرسیونی در تحقیقات انجام شده مانند تحقیقی که روی کاهو در شرایط گلخانه‌ای که دقت آن‌ها زیر ۷۰ درصد تعیین شد (Ciolkosz et al., 1998, Mathieu and Albright, 2002). با توجه به نتایج، مدل‌های شبکه عصبی کارایی بسیار مناسبی برای برآورد تبخیر-تعرق از خود نشان داد.

برای آنالیز حساسیت پارامترهای ورودی مدل با استفاده از شبکه عصبی به صورت گام به گام، هر یک از پارامترهای ورودی حذف گردید و سپس مدل اجرا شد. این اجرا برای چهار پارامتر ورودی انجام گرفت. شاخص‌های آماری مورد استفاده در مورد دقت شامل میانگین مربعات خطا، خطای مدل (رابطه ۷) و ضریب تعیین بود. برای تعیین میزان حساسیت، هر کدام از پارامترهای ورودی در صورت حذف، اگر خطای بیشتری داشته باشد، همبستگی بیشتری با پارامتر خروجی دارد (Pal and Deswal, 2009).

$$Error = \frac{\sqrt{MSE}}{2} * 100 \quad (7)$$

نتایج و بحث

مدل‌سازی با شبکه عصبی

با توجه به نتایج جداول بهینه‌سازی شبکه عصبی الگوریتم، آموزش BR نسبت به LM عملکرد بهتری را نشان داد. همچنین با افزایش تعداد لایه پنهان دقت شبکه بالاتر رفت. البته با افزایش تعداد لایه پیچیدگی شبکه نیز افزایش می‌یابد. بهترین شبکه در الگوریتم BR با سه لایه پنهان با توپولوژی ۱۰-۱-۸ و تابع انتقال tansig در سه لایه پنهان و لایه خروجی با

جدول ۱- پنج حالت بهینه برای سه لایه پنهان الگوریتم آموزش LM و BR

الگوریتم	تابع لایه اول	تابع لایه دوم	تابع لایه سوم	تابع لایه خروجی	لایه اول	لایه دوم	لایه سوم	MSE	r	R ²	MAE
trainlm	tansig	tansig	logsig	tansig	۲	۱۰	۱۰	۰٫۰۰۰۵۶۳	۰٫۹۹۶۱۶	۰٫۹۹۲۳۳۱	۰٫۰۰۴۳۶
trainlm	tansig	logsig	Logsig	tansig	۴	۶	۸	۰٫۰۰۰۵۷۵	۰٫۹۹۶۰۸	۰٫۹۹۲۱۷۱	۰٫۰۰۵۰
trainlm	tansig	tansig	Logsig	tansig	۱۰	۶	۶	۰٫۰۰۵۸۲	۰٫۹۹۶۰۳۲	۰٫۹۹۲۰۷۶	۰٫۰۰۴۸
trainlm	tansig	tansig	Tansig	tansig	۱۰	۱۰	۶	۰٫۰۰۰۵۸۵	۰٫۹۹۶۰۱۵	۰٫۹۹۲۰۴۱	۰٫۰۰۵۲
trainlm	tansig	logsig	Tansig	tansig	۱۰	۱۰	۸	۰٫۰۰۰۵۸۶	۰٫۹۹۶۰۱۱	۰٫۹۹۲۰۲۲	۰٫۰۰۵۲
trainbr	tansig	tansig	Tansig	tansig	۸	۱۰	۱۰	۰٫۰۰۰۰۲۵۵	۰٫۹۹۹۸۲۷	۰٫۹۹۹۶۵۳	۰٫۰۰۳۰
trainbr	tansig	logsig	Tansig	tansig	۱۰	۶	۸	۰٫۰۰۰۰۳۸۶	۰٫۹۹۹۷۳۸	۰٫۹۹۹۴۷۵	۰٫۰۰۳۵
trainbr	tansig	tansig	Tansig	tansig	۶	۸	۴	۰٫۰۰۰۰۶۹	۰٫۹۹۹۵۳۱	۰٫۹۹۹۰۶۱	۰٫۰۰۵۱
trainbr	tansig	tansig	Tansig	tansig	۴	۱۰	۶	۰٫۰۰۰۰۹۶۷	۰٫۹۹۹۳۴۱	۰٫۹۹۹۶۸۳	۰٫۰۰۵۴
trainbr	tansig	tansig	tansig	tansig	۶	۶	۱۰	۰٫۰۰۰۰۹۸۳	۰٫۹۹۹۳۳۱	۰٫۹۹۸۶۶۱	۰٫۰۰۵۵

تابع tansig با یک لایه پنهان و ۸ نرون استفاده شد. دقت مدل ۹۹٫۹۴ درصد با خطای ۰٫۰۵۴۷۵ به دست آمد (قبایی سوق و همکاران، ۱۳۸۹). در پژوهشی دیگر نیز میزان R² برای روش ترکیبی عصبی-فازی ۰٫۹۳ به دست آمد که نشان‌دهنده تخمین مناسب آن بود (پیرمردیان و ابول پور، ۱۳۸۹). با وجود سادگی مدل، دقت و قدرت ارزیابی آن نسبت به مدل‌های رگرسیونی بسیار بالاتر بود (Ciolkosz et. al., 1998, Mathieu and Albright, 2002). توجه به این نکته در کل مدل شبکه عصبی جایگزین مناسبی برای پیش‌بینی تبخیر-تعرق نسبت به مدل‌های کلاسیک می‌باشد.

اگر سادگی شبکه مدنظر باشد، بهینه‌ترین شبکه مربوط به الگوریتم BR با یک لایه پنهان حاوی ۸ نرون و تابع انتقال logsig و tansig به ترتیب در لایه پنهان و لایه خروجی خواهد بود. خطا مطلق و ضریب تعیین این ترکیب به ترتیب ۱٫۷۹ و ۹۸٫۸۴ درصد به دست آمد. البته در الگوریتم LM نیز تفاوت چندانی مشاهده نشد و خطا و ضریب تعیین این ترکیب به ترتیب ۱٫۲۷ و ۹۸٫۵۰ درصد گردید. در کل میزان اختلاف حدود ۱٫۵ درصد بود. توپولوژی این الگوریتم با تعداد نرون ۱۰ و تابع tansig به دست آمد (جدول ۲). در تحقیقی در زمینه مدل سازی تبخیر-تعرق روزانه، از الگوریتم LM با

جدول ۲- پنج حالت بهینه برای یک لایه پنهان الگوریتم آموزش LM و BR

الگوریتم	تابع لایه اول	تابع لایه خروجی	لایه اول	MSE	r	R ²	MAE
trainlm	tansig	tansig	۱۰	۰٫۰۰۱۱	۰٫۹۹۲۴۸۸	۰٫۹۸۵۰۲۹	۰٫۰۱۷۹
trainlm	logsig	tansig	۸	۰٫۰۰۱۲۸۶	۰٫۹۹۱۲۰۵	۰٫۹۸۲۴۸۸	۰٫۰۲۰۱
trainlm	logsig	tansig	۶	۰٫۰۰۱۳۱۳	۰٫۹۹۱۰۲۹	۰٫۹۸۲۱۲۶	۰٫۰۲۰۳
trainlm	tansig	tansig	۸	۰٫۰۰۱۳۵۱	۰٫۹۹۰۷۶۷	۰٫۹۸۱۶۱۵	۰٫۰۲۰۸
trainlm	logsig	tansig	۱۰	۰٫۰۰۱۳۶	۰٫۹۹۰۷۱۶	۰٫۹۸۱۴۸۳	۰٫۰۲۱۵
trainbr	logsig	tansig	۸	۰٫۰۰۰۸۴۶	۰٫۹۹۴۲۲۷	۰٫۹۸۸۴۸۶	۰٫۰۱۲۷
trainbr	logsig	tansig	۱۰	۰٫۰۰۰۸۴۹	۰٫۹۹۴۲۰۸	۰٫۹۸۸۴۳۸	۰٫۰۱۱۰
trainbr	tansig	tansig	۱۰	۰٫۰۰۰۸۷۷	۰٫۹۹۴۰۲	۰٫۹۸۸۰۶۶	۰٫۰۱۲۵
trainbr	tansig	tansig	۸	۰٫۰۰۱۰۰۳	۰٫۹۹۳۱۳۷	۰٫۹۸۶۳۴۹	۰٫۰۱۴۷
trainbr	tansig	tansig	۶	۰٫۰۰۱۰۰۶	۰٫۹۹۲۷۷۱	۰٫۹۸۵۵۶۷	۰٫۰۱۶۷

برآورد تبخیر-تعرق بررسی شد که میزان خطای شبکه عصبی مورد استفاده نزدیک به ۰٫۷۴ کاهش یافت (مؤذن‌زاده، ۱۳۹۴). در تحقیقی دیگر، مقدار R² = ۰٫۹۶ برای مدل شبکه عصبی به منظور پیش‌بینی تبخیر تعرق روزانه به دست آمد. این مسئله نشانگر تأیید عملکرد شبکه عصبی می‌باشد (Abudu et al., 2010).

برای دولایه پنهان نتایج مطابق با جدول ۳ به دست آمد. همانند نتایج قبلی، الگوریتم BR نتیجه بهتری داشت. لایه پنهان با توپولوژی ۱۰-۸ و تابع انتقال tansig-logsig در دولایه پنهان و تابع tansig برای لایه خروجی با خطا مطلق و ضریب تعیین به ترتیب ۰٫۵۹ و ۹۹٫۷۹ درصد تعیین گردید (جدول ۳). همچنین، در پژوهشی عملکرد مناسب شبکه عصبی نسبت به روش رگرسیون در

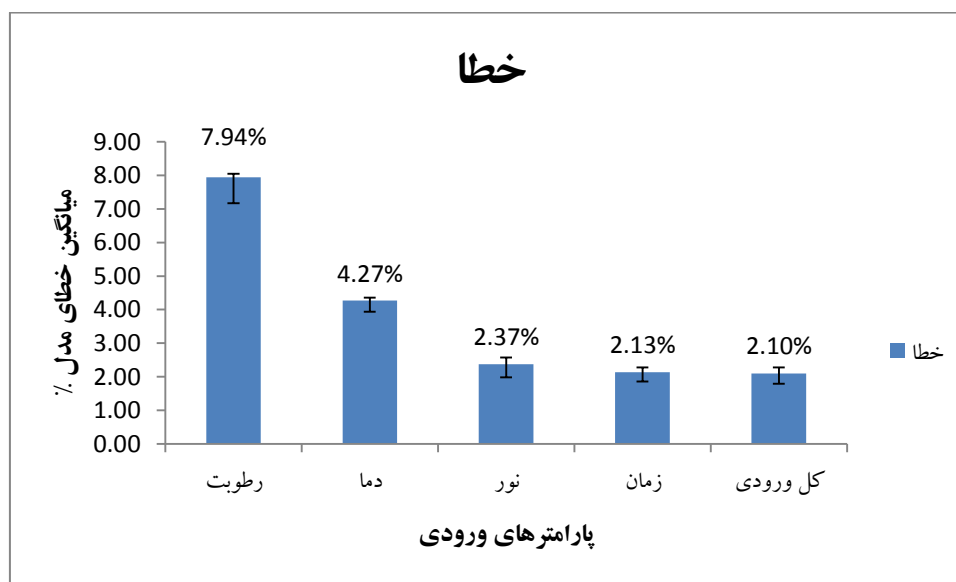
جدول ۳- پنج حالت بهینه برای دو لایه پنهان الگوریتم آموزش LM و BR

الگوریتم	تابع لایه اول	تابع لایه دوم	تابع لایه خروجی	لایه اول	لایه دوم	MSE	r	R ²	MAE
trainlm	tansig	logsig	tansig	۱۰	۱۰	۰/۰۰۰۶۲	۰/۹۹۵۷۶۳	۰/۹۹۱۵۶۱	۰/۰۰۵۶
trainlm	tansig	tansig	tansig	۱۰	۱۰	۰/۰۰۰۶۶۲	۰/۹۹۵۴۸۳	۰/۹۹۰۹۸۴	۰/۰۰۷۸
trainlm	tansig	logsig	tansig	۸	۸	۰/۰۰۰۶۶۶	۰/۹۹۵۴۶۴	۰/۹۹۰۹۳۵	۰/۰۰۸۲
trainlm	tansig	logsig	tansig	۱۰	۸	۰/۰۰۰۶۶۹	۰/۹۹۵۴۳۷	۰/۹۹۰۸۹۴	۰/۰۰۸۲
trainlm	logsig	tansig	tansig	۶	۶	۰/۰۰۰۶۷۱	۰/۹۹۵۴۲۸	۰/۹۹۰۸۷۲	۰/۰۰۸۳
trainbr	tansig	logsig	tansig	۱۰	۸	۰/۰۰۰۱۴۸	۰/۹۹۸۹۹۲	۰/۹۹۷۹۸۵	۰/۰۰۵۹
trainbr	tansig	logsig	tansig	۱۰	۱۰	۰/۰۰۰۵۱	۰/۹۹۶۵۳۵	۰/۹۹۳۰۵۳	۰/۰۰۵۴
trainbr	tansig	logsig	tansig	۱۰	۶	۰/۰۰۰۵۹	۰/۹۹۵۹۷۶	۰/۹۹۱۹۶۴	۰/۰۰۵۲
trainbr	logsig	tansig	tansig	۸	۸	۰/۰۰۰۵۹۱	۰/۹۹۵۹۷۵	۰/۹۹۱۹۶	۰/۰۰۵۸
trainbr	tansig	tansig	tansig	۱۰	۱۰	۰/۰۰۰۶۰۱	۰/۹۹۵۹۰۲	۰/۹۹۱۸۱۸	۰/۰۰۴۴

آنالیز حساسیت

به منظور تعیین مؤثرترین عامل در تبخیر-تعرق محصول کاهو در کشت هیدروپونیک مورد بحث، یک آنالیز حساسیت نیز صورت پذیرفت، که نتایج آن در شکل ۳ و جدول ۴ بیان گردیده است. بر اساس شکل ۳ خطای مدل برای هر پارامتر ورودی بر اساس میانگین خطای توپولوژی‌های مختلف برآورد گردید. با توجه به نتایج بالاترین حساسیت مربوط به میزان رطوبت و در رتبه بعدی دما گردید. میزان خطای میانگین در حذف رطوبت برابر با ۷/۹۴ درصد بوده که نسبت به خطای مدل با تمام پارامترها با خطای میانگین ۲/۱ درصد ۴ برابر

گردید. همچنین در رتبه بعدی از نظر حساسیت دما قرار داشت. میزان خطای میانگین در حذف دما برابر با ۴/۲۷ درصد بوده که نسبت به مدل اصلی با میزان ۲/۱ درصد حدود ۲ برابر گردید. با توجه به معادلات تجربی تبخیر-تعرق این آنالیز حساسیت مورد تأیید می‌باشد (Bormann, 2011). با توجه به خطای میانگین دو پارامتر نور و زمان و تفاوت اندک آن با مدل کلی می‌توان نتیجه گرفت که تأثیری روی برآورد تبخیر و تعرق نداشت. در نهایت می‌توان نتیجه گرفت که مدل شبکه عصبی با دو پارامتر ورودی دما و رطوبت در شرایط گلخانه‌ای نیز کارایی خود خواهد داشت.



شکل ۳- آنالیز حساسیت برای پارامترهای ورودی مدل

جدول ۴- نتایج آنالیز حساسیت پارامترهای ورودی بر میزان تبخیر-تعرق

الگوریتم	تابع انتقال	تعداد نرون لایه اول	خروجی	MSE	Error%	R2
trainbr	tansig	۲	رطوبت	۰/۰۲۵۲۴۱	۷۹۴۳۷۱۲	۰/۸۱۰۲۷۳
			دما	۰/۰۰۷۳۰۶	۴۲۲۷۳۰۴	۰/۹۴۸۹۷۷
			نور	۰/۰۰۲۲۵۵	۲۳۷۴۲۳۴	۰/۹۸۴۵۵
			زمان	۰/۰۰۱۸۲	۲۱۳۳۱۷۲	۰/۹۸۷۵۳۷
		۶	کل ورودی	۰/۰۰۱۷۸	۲۱۰۹۶۵۴	۰/۹۸۷۸۲۶
			رطوبت	۰/۰۱۷۵۹۳	۶۶۳۱۹۱۵	۰/۸۷۲۰۸۵
			دما	۰/۰۰۵۳۸۲	۳۶۶۷۹۶۳	۰/۹۶۲۷۳۲
			نور	۰/۰۰۱۲۷۹	۱۷۸۷۸۷۶	۰/۹۹۱۲۷
۸	زمان	۰/۰۰۱۱۸۸	۱۷۲۳۱۰۲	۰/۹۹۱۸۸۶		
	کل ورودی	۰/۰۰۱۱۱۹	۱۶۷۲۹۰۶	۰/۹۹۲۳۵۴		
	رطوبت	۰/۰۱۷۳۲۲	۶۵۸۰۶۶۸	۰/۸۷۴۱۹۸		
	دما	۰/۰۰۵۶۲۸	۳۷۵۱۰۳۲	۰/۹۶۰۶۴۹		
۸	۸	نور	۰/۰۰۱۰۸۶	۱۶۴۷۸۹۱	۰/۹۹۲۵۸۲	
		زمان	۰/۰۰۱۰۵۲	۱۶۲۲۰۷۵	۰/۹۹۲۸۱۷	
			کل ورودی	۰/۰۰۰۸۹۴	۱۶۴۹۴۹۲	۰/۹۹۳۸۹۸

نتیجه گیری

مدل فازی برآورد تبخیر-تعرق در یک واحد آبیاری هوشمند مربوط به یک سامانه کشت هیدروپونیک عملکرد مطلوبی نشان داد (هم به لحاظ عملکرد و شرایط رشدی گیاه و هم به لحاظ مصرف آب) و لذا توانایی آن در برآورد تبخیر-تعرق واقعی محصول، به عنوان معیاری برای توسعه مدل های شبکه عصبی مصنوعی در این پژوهش مدنظر قرار گرفت. بهترین شبکه در الگوریتم BR با سه لایه پنهان با توپولوژی ۱۰-۱۰-۸ و تابع انتقال tansig در سه لایه پنهان و لایه خروجی با خطا و ضریب تعیین به ترتیب ۰/۴۳ و ۹۹/۹۸ درصد تعیین گردید. اگر سادگی شبکه مدنظر باشد، بهینه ترین شبکه مربوط به الگوریتم BR خواهد بود که دارای یک لایه پنهان حاوی ۸ نرون و تابع انتقال logsig و tansig به ترتیب در لایه پنهان و لایه خروجی باشد. خطا و ضریب تعیین این ترکیب به ترتیب ۰/۷۹ و درصد ۹۸/۸۴ درصد به دست آمد. مانند نتایج قبلی، الگوریتم BR در حالت دولایه پنهان، نتیجه بهتری به همراه داشت. لایه پنهان با توپولوژی ۱۰-۸ و تابع انتقال tansig-logsig در دولایه پنهان و تابع tansig برای لایه خروجی با خطا و ضریب تعیین به ترتیب ۰/۵۹ و ۹۹/۷۹ درصد به دست آمد.

با توجه آنالیز حساسیت به ترتیب رطوبت و دما مهم ترین پارامتر مؤثر در پیش بینی تبخیر-تعرق بود. میزان خطا میانگین برای رطوبت و دما به ترتیب برابر با ۷/۹۴ و ۴/۲۷ درصد بوده که نسبت به خطای مدل با تمام پارامترها با ۲ برابر شد. با توجه به خطای میانگین دو پارامتر نور و زمان و تفاوت اندک آن مدل کلی می توان نتیجه گرفت که تأثیری روی برآورد تبخیر و تعرق نداشت. در نهایت مدل شبکه

عصبی قابلیت برآورد تبخیر-تعرق با دو پارامتر ورودی دما و رطوبت در شرایط گلخانه ای دارد.

منابع

- انتصاری، م.، حیدری، ن.، خیرابی، ج.، علائی، م.، فرشی، ع. ا.، و وزیری، ژ. ۱۳۸۶. کارایی مصرف آب در کشت گلخانه ای. کمیته ملی آبیاری و زهکشی ایران.
- بیات ورکشی، م.، زارع ایبانه، ح.، معروفی، ص.، سبزی پرور، ع. ا.، و سلطانی، ف. ۱۳۸۸. شبیه سازی تبخیر-تعرق روزانه گیاه مرجع به روش هوش مصنوعی و روش های تجربی در مقایسه با اندازه گیری های لای سی متری در اقلیم نیمه خشک سرد همدان. ۱۶(۴): ۷۹-۱۰۰
- پیرمردیان، ن.، و ابول پور، ن. ۱۳۸۹. تخمین تبخیر-تعرق بالقوه گیاه مرجع با استفاده از منطق فازی و شبکه عصبی مصنوعی. مجله علوم زیستی واحد لاهیجان، ۴(۳): ۲۱-۳۴
- زارع ایبانه، ح.، بیات ورکشی، م.، و معروفی، ص. ۱۳۹۰. محاسبه تبخیر-تعرق واقعی گیاه سیر به روش مدل سازی چندگانه تحت شرایط کاشت لایسیمتر. مجله پژوهش های حفاظت آب و خاک ۱۸(۲): ۱۴۱-۱۵۸.
- ساعدی، ا.، علیمردانی، ر.، موسی زاده، ح.، و صالحی، ر. ۱۳۹۷. طراحی و پیاده سازی دستگاه کشت هیدروپونیک دوار خورشیدی مجهز به سامانه هوشمند آبیاری. ماشین های کشاورزی. ۸(۲): ۲۷۹-۲۹۴

- Evans, R., Sneed, R.E. and Cassel, D.K. 2006. Irrigation scheduling to improve water and energy use efficiencies (North Carolina Cooperative extension Service).
- Ji, R. Qi, L. and Huo, Z. 2012. 'Design of fuzzy control algorithm for precious irrigation system in greenhouse', *Computer and Computing Technologies in Agriculture*. V: 278-83.
- Jovic, S. Nedeljkovic, B. Golubovic, Z. and Kostic, N. 2018. Evolutionary algorithm for reference evapotranspiration analysis. *Computers and Electronics in Agriculture*. 150: 1-4.
- Javadi Kia, P., Tabatabaee Far, A., Omid, M., Alimardani, R. and Naderloo, L. 2009. 'Intelligent control based fuzzy logic for automation of greenhouse irrigation system and evaluation in relation to conventional systems', *World Applied Sciences Journal*. 6: 16-23.
- Mathieu, J.J. and Albright, L.D. 2002. Evaluation of Crop Evapotranspiration Rates for Use in Fault Detection in Hydroponic Systems. ASAE Annual Meeting. The American Society of Agricultural and Biological Engineers. www.asabe.org.
- Mascarini, L., Delfino, O.S. and Vilella, F. 2001. Evapotranspiration Of Two Gerbera Jamesonii Cultivars In Hydroponics: Adjustment Of Models For Greenhouses. *Acta Hort.* 554, 261-270
- Kişi, Ö. and Öztürk, Ö. 2007. Adaptive neurofuzzy computing technique for evapotranspiration estimation. *Journal of Irrigation and Drainage Engineering*. 133: 368-379.
- Neto, A.J.S. Zolnier, S. and Lopes, D.C. 2014. Development and evaluation of an automated system for fertigation control in soilless tomato production. *Computers and electronics in agriculture*. 103: 17-25.
- Pal, M. and Deswal, S. 2009. M5 model tree based modeling of reference evapotranspiration. *Hydrological Processes*. 23(10): 1437-1443.
- Patil, A.P. and Deka, P.C. 2016. 'An extreme learning machine approach for modeling evapotranspiration using extrinsic inputs', *Computers and Electronics in Agriculture*. 121: 385-92.
- Reis, M.M., Silva, A.J.S., Junior, J.Z., Santos, L.D.T., Azevedo, A.M. and Lopes, É.M.G. 2019. 'Empirical and learning machine approaches to estimating reference evapotranspiration based on temperature data', *Computers and Electronics in Agriculture*. 165: 104937.
- Reuter, D.C. and Everett, R.S. 2000. 'Control theory and applications: Neural-fuzzy controller for lawn
- علیزاده، ا. ۱۳۹۰. رابطه آب و خاک. انتشارات دانشگاه امام رضا.
- قبائی سوق، م.، مساعدی ا. حسام، م.، و هزارجریبی، ا. ۱۳۸۹. ارزیابی تأثیر پیش‌پردازش پارامترهای ورودی به شبکه عصبی مصنوعی (ANNs) با استفاده از روش‌های رگرسیون گام‌به‌گام و گاما تست به‌منظور تخمین سریع‌تر تبخیر و تعرق روزانه. نشریه آب و خاک. ۲۴(۳): ۶۲۴-۶۱۰.
- کریمی، س.، شبیری، ج.، و ناظمی، ا.ح. ۱۳۹۲. تخمین تبخیر-تعرق روزانه گیاه مرجع با استفاده از دستگاه‌های هوش مصنوعی (ANN و ANFIS) و معادله‌های تجربی. نشریه دانش آب و خاک ۲(۲۳): ۱۳۹-۱۵۸.
- مؤذن‌زاده، ز. ۱۳۹۴. اندازه‌گیری و مدل‌سازی تبخیر-تعرق خیار در شرایط درون گلخانه. نشریه آب و خاک. ۲۹(۵): ۱۲۴۷-۱۲۶۱.
- Abudu, S., Bawazir A.S., and King J.P. 2010. Infilling Missing Daily Evapotranspiration Data Using Neural Networks. *Journal of Irrigation and Drainage Engineering*, 136(5): 317-325.
- Antonopoulos, V.Z. and Antonopoulos, A.V. 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.
- Bormann, H. 2011. Sensitivity Analysis Of 18 Different Potential Evapotranspiration Models To Observed Climatic Change At German Climate Stations. *Climatic Change* 104:729-753.
- Ciolkosz, D.E., Albright, L.D. and Both, A.J. 1998. Characterizing Evapotranspiration In A Greenhouse Lettuce Crop. *Acta Hort.* 456, 255-262.
- Cobaner, M. 2011. Evapotranspiration estimation by two different neuro-fuzzy inference systems. *Journal of Hydrology*. 398: 292-302.
- Demuth, H. and Beale, M. 2009. *Neural Network Toolbox For Use with MATLAB*. The MathWorks. Inc.
- 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.
- Ed-Dahhak, A., Guerbaoui, M., ElAfou, Y., Outanoute, M., Lachhab, A., Belkoura, L., and Bouchikhi, B. 2013. Implementation of fuzzy controller to reduce water irrigation in greenhouse using LabView, *International Journal of Engineering and Advanced Technology Studies*. 1: 12-22.

cross-station assessment of neuro-fuzzy models for estimating daily reference evapotranspiration. *Journal of hydrology*. 480: 46-57.

Tang, D., Feng, Y., Gong, D., Hao, W., and Cui, N. 2018. 'Evaluation of artificial intelligence models for actual crop evapotranspiration modeling in mulched and non-mulched maize croplands', *Computers and Electronics in Agriculture*. 152: 375-84.

irrigation'.

Saggi, M.K. and Jain, S. 2019. 'Reference evapotranspiration estimation and modeling of the Punjab Northern India using deep learning', *Computers and Electronics in Agriculture*. 156: 387-98.

Shiri, J., Nazemi, A.H., Sadraddini, A.A., Landaras, G., Kisi, O., Fard, A.F., and Marti, P. 2013. *Global*

Development of an ANN Model for the Prediction of Plant Actual Evapotranspiration under a Hydroponic Growing System

M.H. Movahednejad^{1*}, S.I. Saedi²

Received: Mar.12, 2020

Accepted: May.29, 2020

Abstract

The development of intelligent irrigation systems with the aim of providing the plant with water in a timely and adequate manner is an important strategy to increase the quantity and quality of agricultural products with minimal water consumption. On the other hand, determining the amount of water required by the plant largely depends on an accurate estimate of evapotranspiration in vegetation. In this study, neural network model was used to estimate the evapotranspiration in a lettuce hydroponic rotary culture system. The actual evapotranspiration of lettuce in the hydroponic cultivation system was estimated in order to design the irrigation system with the help of fuzzy logic model. Cultivation time was 30 days and data sampling time from temperature and humidity sensor was 10 minutes. According to the desired results obtained from the evaluation of the planted crop and water consumption, the efficiency of fuzzy model was proved. Therefore, it was used as a criterion for validating the neural network model of this study. The data volume for the neural network model was about 4500, which was randomly divided into three parts, 70% (training), 15% (evaluation) and 15% (test). Different ANN structures were evaluated to find the most suitable neural network architecture. The best result was achieved with BR algorithm with three hidden layers in an 8-10-10 topology and tansig transfer function in three hidden layers and output layer. For this architecture, the absolute error and coefficient of determination were 0.43 and 99.98%, respectively. Furthermore, considering a simple single layer network (one hidden layer), the BR algorithm with 8 neurons and logsig and tansig transfer functions for the hidden and output layers, were selected as the best model. The error and coefficient of determination of this structure were 0.79 and 98.84%, respectively. According to the sensitivity analysis, humidity and temperature were the most important parameters in predicting evapotranspiration, respectively.

Keywords: Evapotranspiration, Neural Network, Lettuce, Hydroponic Culture, Fuzzy Logic

1- Assistant Professor, Department of Water and Soil, Faculty of Agriculture, Shahrood University of Technology, Iran
2- Assistant Professor, Department of Water and Soil, Faculty of Agriculture, Shahrood University of Technology, Iran
(*- Corresponding Author Email: mhmovahed@shahroodut.ac.ir)