



مدل سازی تبخیر و تعرق در کانوبی برای کشت هیدروپونیک بر اساس داده های مدل سازی

محمدهادی موحدنژاد^{۱*}، سید ایمان ساعدی^۲، حسین میرزایی مقدم^۳

۱- استادیار مهندسی مکانیک بیوسیستم، گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود (mhmovahed@shahroodut.ac.ir)

۲- استادیار مهندسی مکانیک بیوسیستم، گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود (isaedi@gmail.com)

۳- استادیار مهندسی مکانیک بیوسیستم، گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود (hosseinsg@yahoo.com)

چکیده

توسعه سامانه های آبیاری هوشمند یکی از راهبردهای مهم برای حفظ شرایط زیستی گیاه با بهبود راندمان آبیاری می باشد. درصد زیادی از آب آبیاری در گیاه صرف تبخیر و تعرق می شود. برای پیش بینی آن روش های متنوعی وجود دارد. در این تحقیق با منطق فازی میزان تبخیر و تعرق با استفاده از سیستم خبره تعیین گردید. در کشت هیدروپونیک موضوع این پژوهش صرفاً نور مصنوعی وجود دارد و جریان هوا نیز قابل چشم پوشی است. لذا، به منظور استفاده از منطق فازی، این سامانه دارای ورودی های دما، رطوبت نسبی محیط کشت و نور و یک خروجی یعنی تبخیر و تعرق بوده است. با توجه به نتایج رشدی گیاه کشت فازی عملکرد مناسبی داشت. بر اساس داده های فازی، شبکه عصبی برای بررسی در پیش بینی تبخیر و تعرق توسعه یافت. دو الگوریتم LM و BR برای این مدل انتخاب گردید. بهترین نتیجه برای الگوریتم BR با سه لایه پنهان با توپولوژی ۸-۱۰-۱۰ و تابع انتقال tansig در سه لایه پنهان و لایه خروجی با خطای و ضریب تعیین به ترتیب ۰/۰۰۰۰۲۲۵ و ۹۹/۹۸٪ تعیین گردید. همچنین در شبکه یک لایه با توجه به سادگی، الگوریتم BR با یک لایه پنهان با تعداد نرون ۸ و تابع انتقال logsig در لایه پنهان و تابع tansig در لایه خروجی بهترین مدل انتخاب شد. خطای و ضریب تعیین این ترکیب به ترتیب ۰/۰۰۰۸۴۶ و ۹۸/۸۴٪ گردید. با توجه آنالیز حساسیت نیز به ترتیب رطوبت و دما مهم ترین پارامتر مؤثر در پیش بینی تبخیر و تعرق می باشد.

کلمات کلیدی: کشت هیدروپونیک، آبیاری هوشمند، منطق فازی، شبکه عصبی، آنالیز حساسیت

*نویسنده مسئول: mhmovahed@shahroodut.ac.ir



مدل‌سازی تبخیر و تعرق در کانوپی برای کشت هیدروپونیک بر اساس داده‌های مدل فازی

مقدمه

اتخاذ روش‌هایی مبتنی بر علم و فناوری برای مدیریت منابع آب، و افزایش بهره‌وری آن در کشاورزی امری ضروری است. یکی از این راهبردها توسعه سامانه‌های آبیاری هوشمند است که بتوانند با حفظ شرایط زیستی گیاه حداقل آب را به آن برسانند [۱۱ و ۲۰]. بیش از ۹۹٪ آب مصرفی گیاه صرف تبخیر و تعرق می‌شود. بنابراین، اختلاف تبخیر و تعرق و آب مورد مصرف گیاه تنها در مقدار آبی است که صرف فتوسنتز و انتقال مواد در داخل گیاه می‌شود و یا در ساختمان اسکلت گیاه به کار رفته است. پس منظور از تعیین تبخیر و تعرق تعیین مقدار آبی است که باید به یک پوشش زراعی داده شود تا در طول رویش صرف تبخیر و تعرق کند و بدون آنکه با تنش آبی مواجه شود رشد خود را تکمیل کرده و بیشینه مقدار محصول را تولید نماید [۱]. در میان روش‌های برآورد تبخیر و تعرق روشی از نظر عملی مطلوب است که اولاً آسان بوده و ثانیاً نتایج حاصل از آن واقعی‌تر باشد [۱].

در پژوهشی جوویک و همکاران (۲۰۱۸) الگوریتمی برای برآورد تبخیر و تعرق مرجع ارائه دادند که از پارامترهای محیطی مثل دمای هوای مینیمم و ماکزیمم ماهانه، ساعات آفتابی، فشار بخار واقعی، رطوبت نسبی مینیمم و ماکزیمم و سرعت باد به عنوان ورودی مدل استفاده نمود. نتایج پژوهش آنها کاربرد عملی این الگوریتم در برنامه ریزی و مدیریت منابع آب را بر اساس پارامترهای مؤثر بر تبخیر و تعرق به اثبات رساند [۱۴]. همچنین در یک تحقیق دیگر ساگی و جاین (۲۰۱۹) به ارائه مدلی مبتنی بر یادگیری عمیق برای برآورد تخمین تبخیر و تعرق مرجع برای ایالت پنجاب هند پرداختند. مدل ارائه شده قادر بود نسبت به چند مدل رایج مثل پنمن مونیتث، RF، GLM و GBM عملکرد بهتری نشان دهد [۲۱]. از جمله پژوهش‌های دیگری که در برآورد تبخیر و تعرق اخیراً توسط محققین مورد توجه قرار گرفته است می‌توان به تقسیم‌بندی داده‌ها به منظور بهبود مدل‌های برآورد تبخیر و تعرق در ایستگاه‌های مشابه [۲۲] و ارزیابی روش‌های شبکه عصبی برای مدل‌سازی تبخیر و تعرق واقعی محصول در زمینه‌ای با و بدون پوشش مالچ [۲۳]، به بارگیری متغیرهای اقلیمی با ورودی محدود در کنار شبکه‌های عصبی مصنوعی و معادلات تجربی برای برآورد تبخیر و تعرق مرجع روزانه [۷] و نیز مدل‌های مبتنی بر یادگیری ماشین [۹، ۱۸، ۱۹] اشاره نمود.

در زمینه اجرای سامانه‌های مختلف آبیاری هوشمند نیز می‌توان به موارد زیر اشاره نمود: در تحقیقی ناواندار و ساتپوت (۲۰۱۹) یک ماژول ارزان قیمت ساده و قابل حمل مبتنی بر IoT برای طراحی یک سامانه آبیاری هوشمند استفاده نمودند. این سامانه دارای قابلیت‌های تعامل با کاربر، برنامه ریزی آبیاری، واحد تصمیم‌گیری آبیاری مبتنی بر شبکه عصبی و پایش از راه دور فرایند بود. نتایج کاربرد این سامانه برای اجرا بر روی مزارع و گلخانه‌ها، امیدبخش بود [۱۶]. همچنین، با هدف صرفه‌جویی در مصرف آب برای کشاورزی، گنزالز و همکاران (۲۰۱۹) از یک سیستم چند عاملی بهره گرفتند. این سیستم مبتنی بر جمع‌آوری و مدیریت اطلاعات از محصول سبب زمینی از طریق شبکه‌های حسگر بی‌سیم برای اجرای یک سیستم آبیاری دقیق بود که قادر بود نواحی را که حاوی محصولات با بیشترین نیاز به آب بود را شناسایی کرده و فرمان آبیاری را به سامانه ارسال نماید. نتایج کاربرد این سامانه افزایش عملکرد محصول و نیز کاهش قابل توجه مصرف آب را نشان می‌داد [۱۲]. در تحقیقی مشابه، ژانگ و همکاران (۲۰۱۸) یک سیستم کنترل آبیاری همراه با صرفه‌جویی در مصرف آب را که مبتنی بر توازن رطوبت بود طراحی نمودند که قادر بود مشکل توزیع غیریکنواخت رطوبت خاک را مرتفع کند. این سامانه مشتمل بر استفاده از اینترنت اشیا در کشاورزی بود که نتایج قابل قبولی در مصرف آب برای اهداف کشاورزی نشان داد [۲۴].

در گلخانه‌های هیدروپونیک کشت متراکم و سایه‌انداز 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 و تعرق در شرایط گلخانه‌ای روش‌های جدیدی ایجاد شوند. عوامل محیطی مهم و اثرگذار بر تبخیر و تعرق گیاهان گلخانه‌ای عبارت‌اند 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 [۴]. تحقیقات در زمینه تخمین این پارامتر در کشت در فضای بسته، جامع و کامل نیست. به همین دلیل در برآورد تبخیر و تعرق عدم قطعیت زیادی وجود داشته و استفاده از هوش مصنوعی و مدل‌های مختلف امکان برآورد دقیق‌تر تبخیر و تعرق واقعی را میسر می‌سازد. در پژوهشی، جوادی کیا و همکاران در زمینه سامانه‌های آبیاری هوشمند در کشت گلخانه‌ای، یک سامانه هوشمند آبیاری مبتنی بر منطق فازی برای کشت گلخانه‌ای توسعه داده و آن را با روش On/Off مقایسه کردند. کنترلر فازی دارای یک ورودی یعنی تفاوت بین مقادیر مطلوب و واقعی رطوبت خاک، و یک خروجی یعنی وضعیت دریچه آبیاری بود که بیانگر مقدار آبی بود که می‌بایست به طور پیوسته به خاک افزوده شود تا با حداقل نوسانات به رطوبتی نزدیک به مقدار واقعی برسد. در روش On/Off دریچه آبیاری هنگامی باز می‌شد که رطوبت مطلوب خاک بیشتر از رطوبت اندازه‌گیری شده باشد. نتایج ارزیابی نشان داد که سامانه فازی باعث مصرف کمتر انرژی شده و با جلوگیری از ایجاد تنش آبی باعث مصرف کمتر آب در عملیات آبیاری نیز می‌شود [۱۵]. در زمینه روش‌های آبیاری هوشمند در گلخانه می‌توان به دو پژوهش مشابه دیگر نیز اشاره کرد نخست پژوهش الدهاک و همکاران و دوم پژوهش جی و همکاران. در هر دو پژوهش کنترلرهای فازی با هدف 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 به عنوان خروجی آن مدنظر قرار گرفت [۱۰]. اما در پژوهش دوم ورودی‌ها شامل میزان رطوبت خاک و خطای رطوبت خاک و خروجی آن تفاوت سطح آب بود [۱۳]. 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 بسزائی در کاهش مصرف آب ایفا نماید. در پژوهشی کاربردی نتو و همکاران یک سامانه کنترل خودکار برای تهیه و اعمال زمان واقعی محلول غذایی در کشت هیدروپونیک گوجه فرنگی توسعه دادند. میزان تعرق جمعی مهم‌ترین عامل در تصمیم‌گیری آبیاری 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 مشخص می‌شد، صورت گرفت. بر این اساس، بیشینه تخلیه ۲۵٪ آب از بستر ریشه برای جلوگیری از تنش آبی محصول انتخاب گردید. در نتیجه، مدت هر چرخه کودآبیاری برابر با ۱۰۰ ثانیه انتخاب شد. این سامانه قادر بود بسامد سیکل‌های کودآبیاری را تنظیم کرده، غلظت محلول غذایی تهیه شده را کنترل کند و مشکلات زیست‌محیطی مرتبط با دفع پساب و مسائل اقتصادی دخیل در کودها و منابع آبی را مدیریت [۱۷].

در تحقیقی نیز برای پیش‌بینی تبخیر و تعرق روزانه از شبکه عصبی استفاده گردید. ورودی شبکه شامل دمای حداقل، دمای حداکثر، دمای متوسط، رطوبت نسبی، ساعات آفتابی، سرعت باد و تابش برون زمینی می‌باشد. در این تحقیق از الگوریتم LM با تابع tansig با یک لایه پنهان و ۸ نرون با دقت ۹۹/۹۴٪ با خطای ۰/۰۵۴۷۵ به دست آمد [۶]. هدف از این پژوهش ارائه یک مدل هوش مصنوعی مبتنی بر شبکه‌های عصبی مصنوعی به منظور توسعه یک سامانه آبیاری هوشمند مبتنی بر نیاز آبی گیاه برای یک سامانه کشت هیدروپونیک دوار در فضای بسته می‌باشد. مدل شبکه عصبی مدنظر با توجه به نتایج مطلوب کشت و نیز به کمک داده‌های ورودی مناسب برداشت شده در حین کشت ارزیابی خواهد شد.

مواد و روش‌ها

دو نظام آبیاری برای این سامانه مدنظر بوده است که شامل روش مبتنی بر منطق فازی و روش On/Off می‌باشد. در روش کشت On/Off (غیر فازی) دستور آبیاری تابع حسگر سطح آب مخزن زیرین است در حالیکه در روش کشت فازی دستور آبیاری زمانی صادر می‌شود که مقدار تبخیر و تعرق واقعی گیاه (که از طریق منطق فازی برآورد می‌گردد و در بازه‌های زمانی یکسان با هم جمع می‌شوند) به

حد بحرانی خود برسد. از آنجا که هر میزان تبخیر و تعرق به طریقی موجب کاهش رطوبت بستر ریشه می گردد، لذا حد بحرانی تبخیر و تعرق تجمعی معادل با از دست رفتن مقدار آب سهل الوصول در نظر گرفته شده است.

در مدل فازی برآورد تبخیر و تعرق سه عامل کلیدی یعنی دمای محیط، رطوبت نسبی محیط و نور مصنوعی منظور گردید. کشت هیدروپونیک موضوع این پژوهش صرفاً نور مصنوعی وجود دارد و جریان هوا نیز قابل چشم پوشی است. لذا، به منظور استفاده از منطق فازی، این سامانه دارای ورودی‌های دما، رطوبت نسبی محیط کشت و نور، و یک خروجی یعنی تبخیر و تعرق بوده است.

ارزیابی‌های کشت انجام شده در دو وضعیت فازی و On/Off با توجه به کشت کاهو در این دستگاه نشان داد که مدل فازی عملکرد بهتری در رشد گیاه 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 [۵]. به بیان دیگر، مدل فازی به شکل مطلوبی قادر بود تبخیر و تعرق واقعی گیاه را برآورد کند. از این رو، با توجه به داده‌های برداشت شده ورودی و خروجی مدل فازی و مطلوب بودن نتایج رشدی، در این پژوهش نتایج حاصل از مدل فازی به عنوان مقادیر اندازه‌گیری شده تبخیر و تعرق لحاظ گردید و از آن برای ارزیابی شبکه عصبی (به عنوان مقادیر پیش‌بینی شده) استفاده گردید.

برای مدل‌سازی تبخیر و تعرق با استفاده از شبکه عصبی از نرم‌افزار MATLAB استفاده شد. داده‌ها در ابتدا در یک ماتریس وارد شده و سپس به شبکه فراخوانده شد. سپس داده‌ها در دو مجموعه ورودی و خروجی تقسیم گردید. ورودی‌ها شامل زمان، دما (محیط یا کانوپی)، رطوبت (محیط یا کانوپی) و روشنایی (وجود یا عدم وجود روشنایی) بوده و داده خروجی نیز شامل میزان تبخیر و تعرق بود. داده‌های هر دسته به طور تصادفی به سه قسمت، ۷۰٪، ۱۵٪ و ۱۵٪ تقسیم گردید. قسمت اول برای یادگیری، 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 [۸].

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

شبکه مورد استفاده شبکه چند لایه‌ی پرسپترون (MLP) با الگوریتم پس انتشار پیشخور (FFBP) می‌باشد. برای آموزش داده‌ها در فضای نرم‌افزار برنامه‌ای نوشته شد. 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، لونیگ-مارکواریت (LM)، تنظیم بیزین (BR)، بود. توابع آستانه مورد استفاده در مدل‌سازی دو تابع تانژانت هایپربولیک سیگموئید (tansig) (رابطه ۲) و سیگموئید لگاریتمی (logsig) (رابطه ۳) بودند [۸].

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

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

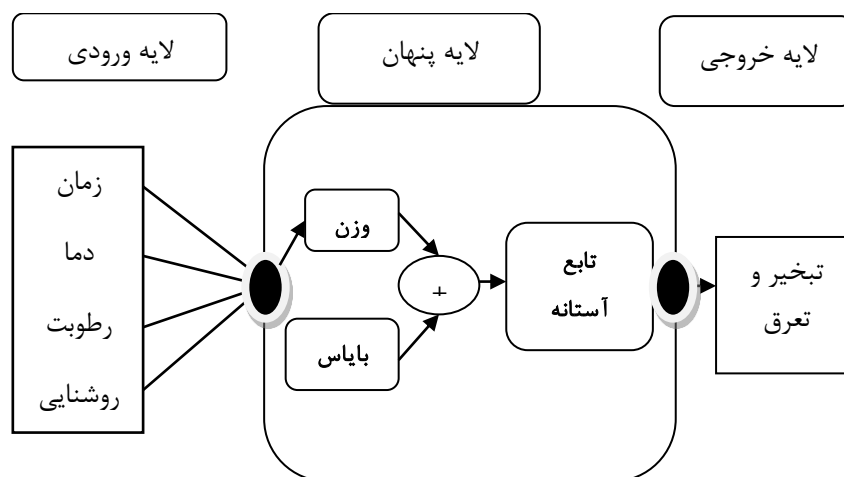
لایه‌های پنهان به صورت تک لایه‌ای بررسی شد. تعداد نورن نیز از ۲ تا ۱۰ نورن مورد بررسی قرار گرفت. سپس با برنامه نوشته شده سه المان تعداد نورن، الگوریتم آموزش، تابع آستانه بررسی شده و برای تمام ترکیب‌های ایجاد شده بر اساس چهار المان خطا و بقیه پارامترهای ارزیابی تعیین می‌گردد. بر اساس کمترین میانگین مربعات خطا (MSE) (رابطه ۳) بهترین مدل برای هر دسته به دست آمد. پارامترهای ارزیابی دیگر شامل ضریب همبستگی ۱ (r) (رابطه ۵)، ضریب تعیین R^2 (رابطه ۶). [۲، ۳ و ۸].

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

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

$$R^2 = \frac{\sum_1^n (y - \bar{y})^2 - \sum_1^n (y - \hat{y})^2}{\sum_1^n (y - \bar{y})^2} \quad (6)$$

بهترین نتایج برای هر دسته‌ی آزمایشی برای الگوریتم‌های منتخب و دو تابع آستانه در دو ترکیب تعداد لایه و تعداد نورون در جدولی ارائه شد. همچنین در برنامه نوشته شده R^2 داده‌های خروجی پیش‌بینی شده توسط شبکه نسبت به داده‌های خروجی واقعی نیز به دست می‌آید. این اطلاعات نیز برای حالات بهینه ارائه گردید.



شکل ۱ ساختار شبکه عصبی

نتایج و بحث

ارزیابی‌های کشت انجام شده در دو وضعیت فازی و On/Off با توجه به کشت کاهو در این دستگاه نشان داد که مدل فازی عملکرد بهتری در رشد گیاه 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 [۵].

با توجه به نتایج جداول بهینه‌سازی شبکه عصبی نتایج الگوریتم آموزش BR بهتر از LM جواب 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 ۱۰-۱۰-۸ و تابع انتقال tansig در سه لایه پنهان و لایه خروجی با خطای و ضریب تعیین به ترتیب ۰/۰۰۰۰۲۲۵ و ۹۹/۹۸٪ تعیین گردید. برای الگوریتم LM نتایج برای سه لایه پنهان با توپولوژی ۱۰-۱۰-۲ و تابع انتقال tansig-tansig-logsig و تابع tansig برای لایه خروجی با خطای و ضریب تعیین ۰/۰۰۰۰۵۶۳ و ۹۹/۲۳٪ انتخاب گردید (جدول ۱).

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

الگوریتم	تابع لایه اول	تابع لایه دوم	تابع لایه سوم	تابع خروجی	لایه اول	لایه دوم	لایه سوم	MSE	r	R ²
trainlm	tansig	tansig	logsig	tansig	2	10	10	0.000563	0.99616	0.992331
trainlm	tansig	logsig	Logsig	tansig	4	6	8	0.000575	0.99608	0.992171
trainlm	tansig	tansig	Logsig	tansig	10	6	6	0.000582	0.996032	0.992076
trainlm	tansig	tansig	Tansig	tansig	10	10	6	0.000585	0.996015	0.992041
trainlm	tansig	logsig	Tansig	tansig	10	10	8	0.000586	0.996011	0.992022
trainbr	tansig	tansig	Tansig	tansig	8	10	10	2.55E-05	0.999827	0.999653
trainbr	tansig	logsig	Tansig	tansig	10	6	8	3.86E-05	0.999738	0.999475
trainbr	tansig	tansig	Tansig	tansig	6	8	4	6.90E-05	0.999531	0.999061
trainbr	tansig	tansig	Tansig	tansig	4	10	6	9.67E-05	0.999341	0.998683
trainbr	tansig	tansig	tansig	tansig	6	6	10	9.83E-05	0.999331	0.998661

اگر سادگی شبکه مد نظر باشد، بهینه ترین شبکه مربوط به الگوریتم BR با یک لایه پنهان با تعداد نرون ۸ و تابع انتقال نیز در لایه پنهان logsig و لایه خروجی tansig شد. خطای و ضریب تعیین این ترکیب به ترتیب ۰/۰۰۰۸۴۶ و ۹۸/۸۴٪ شد. البته در الگوریتم LM نیز تفاوت چندانی نبوده و خطای و ضریب تعیین این ترکیب به ترتیب ۰/۰۰۱۱ و ۹۸/۵۰٪ بوده، که تفاوت چندانی ندارد. در کل میزان اختلاف حدود ۱/۵٪ شد. توپولوژی این الگوریتم با تعداد نرون ۱۰ و تابع tansig به دست آمد (جدول ۲). در برای مدل سازی تبخیر و تعرق روزانه سوق و همکاران از الگوریتم LM با تابع tansig با یک لایه پنهان و ۸ نرون استفاده کردند. دقت مدل ۹۹/۹۴٪ با خطای ۰/۰۵۴۷۵ نیز به دست آمد [۶].

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

الگوریتم	تابع لایه اول	تابع لایه خروجی	لایه اول	MSE	r	R ²
trainlm	tansig	tansig	10	0.0011	0.992488	0.985029
trainlm	logsig	tansig	8	0.001286	0.991205	0.982488
trainlm	logsig	tansig	6	0.001313	0.991029	0.982126
trainlm	tansig	tansig	8	0.001351	0.990767	0.981615
trainlm	logsig	tansig	10	0.00136	0.990713	0.981483
trainbr	logsig	tansig	8	0.000846	0.994227	0.988486
trainbr	logsig	tansig	10	0.000849	0.994208	0.988438
trainbr	tansig	tansig	10	0.000877	0.99402	0.988066
trainbr	tansig	tansig	8	0.001003	0.993173	0.986349
trainbr	tansig	tansig	6	0.00106	0.992771	0.985567

برای دو لایه پنهان نتایج مطابق با جدول زیر به دست آمد. مانند نتایج قبلی الگوریتم BR نتیجه بهتری داشت. لایه پنهان با توپولوژی ۸-۱۰ و تابع انتقال tansig-logsig در دو لایه پنهان و تابع tansig برای لایه خروجی با خطای و ضریب تعیین به ترتیب ۰/۰۰۰۱۴۸ و ۹۹/۷۹٪ تعیین گردید (جدول ۳).

جدول ۳: برای 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
trainlm	tansig	logsig	tansig	10	10	0.00062	0.995773	0.991561
trainlm	tansig	tansig	tansig	10	10	0.000662	0.995483	0.990984
trainlm	tansig	logsig	tansig	8	8	0.000666	0.995464	0.990935
trainlm	tansig	logsig	tansig	10	8	0.000669	0.995437	0.990894
trainlm	logsig	tansig	tansig	6	6	0.000671	0.995428	0.990872
trainbr	tansig	logsig	tansig	10	8	0.000148	0.998992	0.997985
trainbr	tansig	logsig	tansig	10	10	0.00051	0.996535	0.993053
trainbr	tansig	logsig	tansig	10	6	0.00059	0.995976	0.991964
trainbr	logsig	tansig	tansig	8	8	0.000591	0.995975	0.99196
trainbr	tansig	tansig	tansig	10	10	0.000601	0.995902	0.991818

آنالیز حساسیت

با توجه به جدول شماره ۵ بالاترین حساسیت مربوط به میزان رطوبت می باشد. میزان خطا در حذف رطوبت نسبت به مدل پیش بینی با تمام پارامترها حدود ۱۵ برابر گردیده که معادل کاهش دقت تا ۱۸٪ می باشد. همچنین در رتبه بعدی از نظر حساسیت دما قرار دارد. میزان خطا در حذف دما از پارامترهای مدل سازی نسبت به مدل اصلی حدود ۴ برابر گردیده که معادل کاهش دقت تا حدود ۴٪ می باشد. با توجه به معادلات تجربی تبخیر و تعرق این آنالیز حساسیت مورد تأیید می باشد. همچنین صحت مدل شبکه عصبی نیز نشان داده می شود (جدول ۴).

جدول ۴: تعیین حساسیت های پارامترهای ورودی بر میزان تبخیر و تعرق (۱)

الگوریتم	تابع انتقال	تعداد نرون لایه اول	خروجی	MSE	r	R2	
trainbr	tansig	2	رطوبت	0.025241	7.943712	0.810273	
			دما	0.007306	4.273704	0.948977	
			نور	0.002255	2.374234	0.98455	
			زمان	0.00182	2.133172	0.987537	
			کل ورودی	0.00178	2.109654	0.987826	
			رطوبت	0.017593	6.631915	0.872085	
		6	دما	0.005382	3.667963	0.962732	
			نور	0.001279	1.787876	0.99127	
			زمان	0.001188	1.723102	0.991886	
			کل ورودی	0.001119	1.672906	0.992354	
			8	رطوبت	0.017322	6.580668	0.874198
				دما	0.005628	3.751032	0.960949
نور	0.001086	1.647891		0.992582			
زمان	0.001052	1.622075		0.992817			
کل ورودی	0.000894	1.494992	0.993898				

نتیجه گیری

ارزیابی‌های کشت انجام شده در دو وضعیت فازی و On/Off با توجه به کشت کاهو در این دستگاه نشان داد که مدل فازی عملکرد بهتری در رشد گیاه داشته است. 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 خطای و ضریب تعیین به ترتیب ۰/۰۰۰۰۲۲۵ و ۹۹/۹۸٪ تعیین گردید. اگر سادگی شبکه مد نظر باشد، بهینه‌ترین شبکه مربوط به الگوریتم BR با یک لایه پنهان با تعداد نرون ۸ و تابع انتقال نیز در لایه پنهان logsig و لایه خروجی tansig شد. خطای و ضریب تعیین این ترکیب به ترتیب ۰/۰۰۰۰۸۴۶ و ۹۸/۸۴٪ شد. مانند نتایج قبلی الگوریتم BR نتیجه بهتری داشت. لایه پنهان با توپولوژی ۱۰-۸ و تابع انتقال tansig-logsig در دو لایه پنهان و تابع tansig برای لایه خروجی با خطای و ضریب تعیین به ترتیب ۰/۰۰۰۰۱۴۸ و ۹۹/۷۹٪ تعیین گردید

با توجه آنالیز حساسیت نیز به ترتیب رطوبت و دما مهم‌ترین پارامتر مؤثر در پیش‌بینی تبخیر و تعرق می‌باشد. میزان خطا در حذف رطوبت نسبت به مدل پیش‌بینی با تمام پارامترها حدود ۱۵ برابر گردیده که معادل کاهش دقت تا ۱۸٪ می‌باشد. همچنین در رتبه بعدی از نظر حساسیت دما قرار دارد. میزان خطا در حذف دما از پارامترهای مدل‌سازی نسبت به مدل اصلی حدود ۴ برابر گردیده که معادل کاهش دقت تا حدود ۴٪ می‌باشد.

مراجع

۱. علیزاده، ا. (۱۳۹۰). رابطه آب و خاک. انتشارات دانشگاه امام رضا.
۲. امیری چایجان ر.، خوش تقاضا م.ه.، منتظرغ.، مینایی س. (۱۳۸۶). تخمین رطوبت لایه‌های شلتوک در انتهای مرحله خشک شدن به کمک شبکه‌های عصبی مصنوعی. مجله علوم کشاورزی ایران. ۱۳(۱): ۱۱۳-۱۲۳.
۳. امیری چایجان ر.، خوش تقاضا م.ه.، منتظرغ.، مینایی س. و علیزاده م.ر. (۱۳۸۸). تخمین ضریب تبدیل شلتوک با استفاده از شبکه‌های عصبی مصنوعی در خشک کردن بستر سیال. مجله علوم و فنون کشاورزی و منابع طبیعی، ۴۸: ۲۸۵-۲۹۸.
۴. انتصاری، م. حیدری، ن. خیرابی، ج. علائی، م. فرشی، ع. ا. وزیری، ژ. (۱۳۸۶). کارایی مصرف آب در کشت گلخانه‌ای. کمیته ملی آبیاری و زهکشی ایران.
۵. ساعدی، ا. علیمردانی، ر. موسی زاده، ح. صالحی، ر. (۱۳۹۷). طراحی و پیاده سازی دستگاه کشت هیدروپونیک دوار خورشیدی مجهز به سامانه هوشمند آبیاری. ماشین‌های کشاورزی. ۸(۲): ۲۷۹-۲۹۴.
۶. قبائی سوق، م. مساعدی ا. حسام، م. هزارجریبی، ا. (۱۳۸۹). با استفاده از (ANNs) ارزیابی تأثیر پیش‌پردازش پارامترهای ورودی به شبکه عصبی مصنوعی روش‌های رگرسیون گام به‌گام و گاما تست به منظور تخمین سریع‌تر تبخیر و تعرق روزانه. نشریه آب و خاک. ۲۴(۳): ۶۲۴-۶۱۰.
7. Antonopoulos, Vassilis Z., and Athanasios V. Antonopoulos. (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.
8. Demuth H. and Beale M. (2009). Neural Network Toolbox For Use with MATLAB. The MathWorks, Inc.
9. Dou, Xianming, and Yongguo Yang. (2018). Evapotranspiration estimation using four different machine learning approaches in different terrestrial ecosystems', Computers and Electronics in Agriculture, 148: 95-106.

10. Ed-Dahhak, A, M Guerbaoui, Y ElAfou, M Outanoute, A Lachhab, L Belkoura, and B Bouchikhi. (2013). 'Implementation of fuzzy controller to reduce water irrigation in greenhouse using LabView', *International Journal of Engineering and Advanced Technology Studies*, 1: 12-22.
11. Evans, R., R.E. Sneed, and D.K. Cassel. (2006). Irrigation scheduling to improve water and energy use efficiencies (North Carolina Cooperative extension Service).
12. González-Briones, Alfonso, Yeray Mezquita, José A. Castellanos-Garzón, Javier Prieto, and Juan M. Corchado. (2019). 'Intelligent multi-agent system for water reduction in automotive irrigation processes', *Procedia Computer Science*, 151: 971-76.
13. Ji, Ronghua, Lijun Qi, and Zicheng Huo. (2012). 'Design of fuzzy control algorithm for precious irrigation system in greenhouse', *Computer and Computing Technologies in Agriculture V*: 278-83.
14. Jovic, Srdjan, Blagoje Nedeljkovic, Zoran Golubovic, and Nikola Kostic. (2018). 'Evolutionary algorithm for reference evapotranspiration analysis', *Computers and Electronics in Agriculture*, 150: 1-4.
15. Kia, P Javadi, A Tabatabaee Far, Mahmood Omid, Reza Alimardani, and Leila Naderloo. (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.
16. Nawandar, Neha K., and Vishal R. Satpute. (2019). 'IoT based low cost and intelligent module for smart irrigation system', *Computers and Electronics in Agriculture*, 162: 979-90.
17. Neto, Antonio José Steidle, Sérgio Zolnier, and Daniela de Carvalho Lopes. (2014). 'Development and evaluation of an automated system for fertigation control in soilless tomato production', *Computers and electronics in agriculture*, 103: 17-25.
18. Patil, Amit Prakash, and Paresh Chandra Deka. (2016). 'An extreme learning machine approach for modeling evapotranspiration using extrinsic inputs', *Computers and Electronics in Agriculture*, 121: 385-92.
19. Reis, Matheus Mendes, Ariovaldo José da Silva, Jurandir Zullo Junior, Leonardo David Tuffi Santos, Alcinei Místico Azevedo, and Érika Manuela Gonçalves Lopes. (2019). 'Empirical and learning machine approaches to estimating reference evapotranspiration based on temperature data', *Computers and Electronics in Agriculture*, 165: 104937.
20. Reuter, D.C. , and R.S. Everett. (2000). 'Control theory and applications: Neural-fuzzy controller for lawn irrigation.'
21. Saggi, Mandeep Kaur, and Sushma Jain. (2019). 'Reference evapotranspiration estimation and modeling of the Punjab Northern India using deep learning', *Computers and Electronics in Agriculture*, 156: 387-98.
22. Shiri, Jalal, Pau Marti, Sepideh Karimi, and Gorka Landeras. (2019). 'Data splitting strategies for improving data driven models for reference evapotranspiration estimation among similar stations', *Computers and Electronics in Agriculture*, 162: 70-81.
23. Tang, Dahua, Yu Feng, Daozhi Gong, Weiping Hao, and Ningbo Cui. (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.
24. Zhang, S., M. Wang, W. Shi, and W. Zheng. (2018). 'Construction of intelligent water saving irrigation control system based on water balance', *IFAC-PapersOnLine*, 51: 466-71.



Modeling canopy evapotranspiration in hydroponic cultivation based on fuzzy model data

Mohamad Hadi Movahednejad^{1*}, Seyed Iman Saedi², Hossein Mirzaee Moghadam³

1. Assistant Professor of Biosystems Engineering, Water and Soil Department, Faculty of Agriculture, Shahrood University of Technology
2. Assistant Professor of Biosystems Engineering, Water and Soil Department, Faculty of Agriculture, Shahrood University of Technology
3. Assistant Professor of Biosystems Engineering, Water and Soil Department, Faculty of Agriculture, Shahrood University of Technology

Abstract

Development of smart irrigation systems is one of the most important strategies for maintaining plant life conditions by improving irrigation efficiency. A large percentage of irrigation water in the plant is used for evapotranspiration. There are various ways to predict it. In this study, evapotranspiration was determined by fuzzy logic using expert system. In the hydroponic cultivation the subject of this study is merely artificial light and the airflow can be neglected. Therefore, in order to use fuzzy logic, this system has temperature inputs, relative humidity of the medium and light, and an output evapotranspiration. According to the results of the fuzzy plant growth, yield was good. Based on the fuzzy data, the neural network was developed to investigate the prediction of evapotranspiration. Two LM and BR algorithms were selected for this model. The best result for BR algorithm with three hidden layers with topology 8-10-10 and tansig transfer function in three hidden layers and output layer with error and coefficient of determination were 0.0000255 and 99.98%, respectively. Also in the simplicity of a single layer network, the BR algorithm with a hidden layer with neuron number 8 and the logsig transfer function in the hidden layer and the tansig function in the output layer were selected as the best model. The error and coefficient of determination of this compound were 0.000846 and 98.84%, respectively. According to the sensitivity analysis, humidity and temperature are the most important parameters in predicting evapotranspiration, respectively.

Key words: Hydroponic culture, Intelligent irrigation, Fuzzy logic, Neural network, Sensitivity analysis

*Corresponding author

E-mail: mhmovahed@yahoo.com