

ارزیابی دقت شبکه عصبی مصنوعی در پیش‌بینی تبخیر- تعرق گیاه سیر بر اساس داده‌های لایسیمتری در منطقه همدان

حمید زارع ایبانه^{۱*} - عادل قاسمی^۲ - مریم بیات ورکشی^۳ - صفر معروفی^۴

تاریخ دریافت: ۸۸/۱/۳۰

تاریخ پذیرش: ۸۸/۶/۸

چکیده

تبخیر تعرق به عنوان یکی از مولفه‌های اصلی در کشاورزی، نقش قابل توجهی در مدیریت منابع آب دارا می باشد. بنابراین استفاده از یک روش دقیق یکی از مراحل اساسی در توسعه کشاورزی، بویژه در مناطق خشک و نیمه خشک می باشد. در این تحقیق به منظور تعیین دقیق تبخیر- تعرق گیاه سیر، با استفاده از اندازه‌گیری لایسیمتری و شبکه عصبی مصنوعی (ANN)، یک مدل مناسب بدین منظور ارائه شد. بدین منظور از داده‌های هواشناسی دماهای حداکثر و حداقل هوا، مقادیر رطوبت نسبی حداکثر و حداقل، سرعت باد و ساعات آفتابی روزانه در نرون‌های لایه ورودی استفاده گردید. اندازه‌گیری تبخیر-تعرق گیاه سیر به کمک چهار دستگاه لایسیمتر زهکش‌دار به ابعاد ۲×۲×۲ متر مستقر در ایستگاه کلیماتولوژی دانشکده کشاورزی طی سال‌های ۱۳۸۵، ۱۳۸۶ و ۱۳۸۷ انجام شد. آماره‌های مجذور میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE)، انحراف معیار میانگین قدر مطلق خطا (STD_{MAE}) و ضریب تعیین (R^2)، به منظور ارزیابی روش‌های بکار برده شده استفاده گردید. نتایج مبین عملکرد مناسب شبکه عصبی مصنوعی پرسپترون چند لایه با الگوریتم پس‌انتشار خطا در پیش‌بینی تبخیر-تعرق گیاه سیر بود. نتایج نشان داد که مقادیر RMSE، MAE، STD_{MAE} و R^2 برای آرایش ۱-۶-۶ بر پایه قانون آموزش لونبرگ مارکوات و تابع محرک سیگموئید به ترتیب ۰/۰۸۸ میلی‌متر بر روز، ۰/۰۷ میلی‌متر بر روز، ۰/۰۶۱ میلی‌متر بر روز و ۰/۸۸ به دست آمد. نتایج نشان داد میانگین روزانه نیاز آبی گیاه سیر معادل ۸/۳ میلی‌متر از لایسیمتر و ۶/۵ میلی‌متر از شبکه عصبی به دست آمد. بطور کلی، مقایسه عملکرد شبکه ANN با مقادیر لایسیمتری نشان داد که دقت شبکه عصبی مصنوعی در حد قابل قبولی بوده است. همچنین مشخص گردید که مدل مطلوب شبکه عصبی مصنوعی در حالت تغییرات افزایشی نسبت به دمای حداکثر هوا، دارای بیشترین حساسیت و نسبت به پارامتر حداقل رطوبت نسبی، کمترین حساسیت را دارد.

واژه‌های کلیدی: شبکه‌های عصبی مصنوعی، تبخیر-تعرق، لایسیمتر، سیر، همدان

مقدمه

برای مناطق نیمه خشک کشور اسپانیا اشاره نمود. آنان نیاز آبی سیر را ۴۷۰ میلی‌متر و معادله پنمن ماتنیث را در برآورد نیاز آبی گیاه سیر غیر کارا دانستند. هانسون و همکاران (۱۷) تنش‌های ناشی از کم آبیاری برای محصول سیر را در خاک‌های سبک سبب کاهش عملکرد آن دانستند. فایرو و همکاران (۱۶) آخرین مرحله از رشد محصول سیر (رسیدن محصول) و مرحله میانی را نسبت به کم آبی حساس دانسته و کم آبیاری در این دو مرحله را به واسطه تاثیرات منفی بر کیفیت و کمیت محصول، صحیح ندانستند. آنان نیاز آبی سیر در مناطق نیمه خشک اسپانیا تحت شرایط کم آبیاری را ۴۶۰ میلی‌متر گزارش نمودند.

معمولاً برای تعیین نیاز آبی گیاهان از طریق اندازه‌گیری‌های مستقیم (لایسیمتری) و یا از روش‌های غیرمستقیم (مدل‌های تجربی و ترکیبی) عمل می‌شود. در چند سال اخیر استفاده از روش‌های حل

سیر (*Allium sativum*) از جمله گیاهان زراعی- دارویی، دارای ارزش اقتصادی و صادراتی استان همدان می‌باشد. سطح زیر کشت این محصول در استان همدان حدود ۲۰۰۰۰ هکتار و تولیدی برابر با ۳۳۱۰۰ تن برای آن گزارش شده است (۴ و ۸). این گیاه در مناطق با آب و هوای خنک به خوبی عمل می‌آید. تحقیقات محدودی در خصوص تعیین نیاز آبی گیاه سیر انجام شده است. از جمله می‌توان به تحقیقات ویلاولوباس و همکاران (۲۵) در تعیین تبخیر-تعرق سیر

۱ و ۴- به ترتیب استادیار و دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی سینا
(*) - نویسنده مسئول : (Email: zare_h2000@yahoo.com)

۲ و ۳- به ترتیب دانشجوی سابق و دانشجوی مقطع کارشناسی ارشد آبیاری و زهکشی، دانشکده کشاورزی، دانشگاه بوعلی سینا

میانگین بارندگی سالیانه ۳۱۲/۳ می‌باشد (۶). مشخصات فیزیکی و شیمیایی خاک درون لایسیمترها در جدول ۱ ارائه شده است.

کشت سیر در نیمه دوم آبان سال ۱۳۸۴ به صورت دستی انجام گرفت. روش کاشت به صورت ردیفی به فواصل ۲۰ سانتی‌متر، در عمق ۱۰ سانتی‌متری از سطح خاک بود. فاصله بوته‌ها روی ردیف‌ها ۱۰ سانتی‌متر انتخاب گردید. زمین محل آزمایش در سال زراعی قبل به صورت آیش بود که در اواخر تابستان به منظور کشت، شخم زده شد. برای کمک به رشد بوته‌های سیر به میزان ۳۷/۵ تن در هکتار کود دامی پوسیده روی سطح لایسیمترها پخش، و با ادوات ساده زراعی با خاک مخلوط گردید. موجودی فسفر خاک تا عمق ۳۰ سانتی‌متری بیش از ۲۰ میلی‌گرم در کیلوگرم خاک بود. از این رو کود فسفر مصرف نشد. برای کنترل علف‌های هرز در طی فصل رشد به تعداد دفعات لازم، وجین دستی انجام گرفت. سیرها پس از جبه شدن و کنترل صحت و سلامت ظاهری در محل‌های کاشت روی هر ردیف کاشته شدند. عملیات آبیاری به صورت دستی پس از جوانه‌زنی و استقرار بوته‌ها در اول فروردین ماه براساس تامین روزانه آب مورد نیاز صورت گرفت. رطوبت خاک با نصب بلوک گچی به قطر ۲۰ و ارتفاع ۳۰ میلی‌متر در عمق ریشه گیاه سیر توسط دستگاه مقاومت‌سنج مدل MC-305B ساخت شرکت ELE انگلستان به شکل روزانه برآورد گردید. زه آب خروجی از لایسیمترها به شکل روزانه به صورت حجم‌سنجی از طریق استوانه مدرج تعیین شد.

اندازه‌گیری‌های تبخیر- تفرق سیر براساس معادله بیلان آب درون لایسیمتر، به صورت زیر انجام شد (۲۴):

$$ET_{ci} = I_i + P_i - D_i \pm (W_{i-1} - W_i) \quad (1)$$

که در آن ET_{ci} تبخیر- تفرق گیاه سیر (میلی‌متر در روز)، I_i مقدار آب آبیاری (میلی‌متر)، P_i مقدار بارندگی (میلی‌متر)، D_i مقدار زه‌آب (میلی‌متر)، W_{i-1} مقدار رطوبت خاک در زمان اول اندازه‌گیری (میلی‌متر) و W_i مقدار رطوبت خاک در زمان دوم اندازه‌گیری (میلی‌متر) می‌باشد.

برای پیش‌بینی تبخیر- تفرق سیر از طریق شبکه‌های عصبی مصنوعی، به اطلاعات هواشناسی و لایسیمتری نیاز است. پارامترهای میانگین دمای حداکثر و حداقل هوا (T_{min} و T_{max})، میانگین حداکثر و حداقل رطوبت نسبی (RH_{min} و RH_{max})، سرعت باد (U) و ساعات آفتابی (n) به عنوان اطلاعات ورودی به شبکه عصبی مصنوعی انتخاب شد. صحت انتخاب پارامترهای فوق به عنوان اطلاعات نرون‌های ورودی که سبب کمترین خطا و بهترین جواب در برآورد تبخیر- تفرق می‌شود، براساس روش استاندارد پنمن مانیتیت فائو ۵۶ می‌باشد که از سوی محققین مختلف گزارش شده است (۷، ۵ و ۱). به اعتقاد قاسمی (۶) تعداد الگوهای مورد نیاز جهت آموزش یک مدل شبکه عصبی مصنوعی بایستی حداقل ۱۵ الی ۲۰ برابر تعداد

هوشمند هم به عنوان راهکاری دقیق و سریع در بسیاری از زمینه‌ها از جمله برآورد نیاز آبی گیاهان رایج شده است. رهیافت شبکه‌های عصبی مصنوعی به دلیل طبیعت غیرخطی و کارآمد بودن در مدل‌سازی سیستم‌های پیچیده مورد توجه بسیاری از محققان می‌باشد. در استفاده از شبکه‌های عصبی مصنوعی (ANNs) می‌توان به شبیه‌سازی فرآیند بارش-رواناب (۳)، برآورد تبخیر (۲۳)، پیش‌بینی مقدار محصول (۱۸)، برآورد جریان سیل یک روز آینده (۹) و برآورد مشخصات پرش هیدرولیکی (۲)، اشاره نمود. قاسمی و همکاران (۷) شبکه‌های عصبی مصنوعی را ابزاری کارا و دقیق در پیش‌بینی تبخیر- تفرق گیاه مرجع توصیف نمودند. کومار و همکاران (۲۰) شبکه عصبی را ابزاری برتر و توانمندتر در مقایسه با روش‌های تجربی برای پیش‌بینی تبخیر- تفرق گیاه مرجع در دیویس (کالیفرنیا) دانستند. برتن و همکاران (۱۲) به کمک شبکه عصبی مصنوعی، تبخیر روزانه تشت را در بازه زمانی ۱۹۹۲ تا ۱۹۹۶ برای برخی از شهرهای مهم جهان با خطایی معادل ۰/۱۱ میلی‌متر در روز پیش‌بینی کردند. بهاکار و همکاران (۱۱) دقت شبکه‌های عصبی مصنوعی در پیش‌بینی تبخیر- تفرق گیاه مرجع و گندم در مقایسه با برآوردهای معادله پنمن مانیتیت مناسب و دارای دقت بالاتر ارزیابی نمودند. بررسی‌های فوق نشان می‌دهد که شبکه عصبی مصنوعی در پیش‌بینی پدیده‌های غیرخطی نظیر تبخیر- تفرق می‌تواند موثر باشد. به منظور بررسی فرآیند تبخیر- تفرق تا کنون مدل‌ها و معادلات متفاوتی پیشنهاد شده است. ولی برای گیاه سیر به عنوان گیاهی با خواص دارویی و دارای ارزش اقتصادی، تحقیقات جامعی در خصوص اندازه‌گیری‌های میدانی و یا استفاده از مدل‌های هوش مصنوعی صورت نگرفته است. هدف این پژوهش مقایسه کارآمدی شبکه‌های عصبی مصنوعی در شبیه‌سازی فرآیند تبخیر- تفرق گیاه سیر در مقایسه با نتایج و اندازه‌گیری‌های مستقیم حاصل از لایسیمتر می‌باشد.

مواد و روش‌ها

این تحقیق با کاشت سیر توده همدانی در چهار دستگاه لایسیمتر زهکش‌دار به ابعاد ۲×۲×۲ متر به منظور برآورد نیاز آبی آن در اراضی دانشکده کشاورزی دانشگاه بوعلی‌سینا (همدان) برای ارزیابی نتایج شبکه عصبی مصنوعی انجام شد. محل اجرای آزمایش در مختصات جغرافیایی ۳۴ درجه و ۴۸ دقیقه عرض شمالی و ۴۸ درجه و ۲۸ دقیقه طول شرقی، با میانگین ارتفاع ۱۸۲۰ متر از سطح دریا می‌باشد. منطقه از نظر اقلیمی جزء مناطق نیمه خشک سرد است که حداقل دمای آن حدود ۶/۷- درجه سانتی‌گراد، حداکثر آن ۳۶ درجه سانتی‌گراد و دارای

شبکه، داده‌ها پس از نرمال‌سازی و قرار گرفتن در محدوده صفر و یک، به سه دسته شامل داده‌های آموزش (۷۰ درصد)، داده‌های اعتبارسنجی (۲۰ درصد) و داده‌های آزمون (۱۰ درصد) تقسیم شدند (۶).

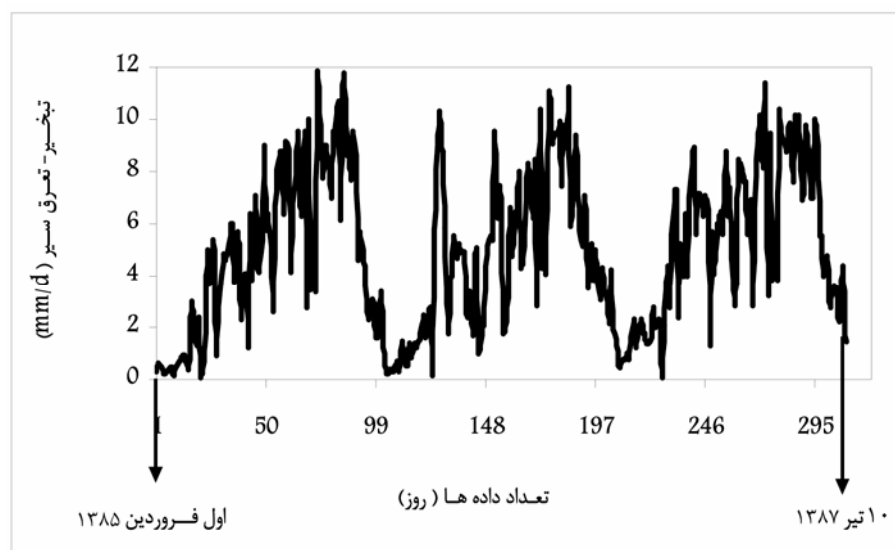
ورودی‌های مدل باشد. بدین ترتیب از ۳۰۹ الگوی لایسمتری و اقلیمی اندازه‌گیری شده در قالب طرحی ۳ ساله استفاده شد که شرط ۱۵ تا ۲۰ برابر بودن تعداد نرون‌های ورودی به شبکه عصبی مصنوعی (۶ نرون) قابل ارضا است. به جهت افزایش سرعت و دقت

(جدول ۱) - برخی مشخصات فیزیکی و شیمیایی خاک لایسمترها

هدایت الکتریکی خاک (dSm^{-1})	pH ماده آلی (درصد)	کربن آلی (درصد)	نیتروژن (درصد)	فسفر ($mgkg^{-1}$)	چگالی ظاهری (gcm^{-3})	رطوبت وزنی		نسبت (درصد) رس (درصد) بافت	شن (درصد)	لایسمتر (درصد)			
						نقطه پژمردگی (درصد)	ظرفیت مزرعه (درصد)						
۰/۳۶	۷/۸	۰/۹۸	۰/۵۷	۰/۰۳	۳۹/۷	۱/۵	۱۰/۸	۲۲/۸	رسی شنی	۳۶/۳	۱۳/۸	۵۰	۱
۰/۴	۸/۰	۰/۸۶	۰/۵۰	۰/۰۲	۷۲/۲	۱/۵	۸	۲۷/۵	لومی رسی	۳۶/۳	۱۸/۳	۴۵	۲
۰/۲۷	۷/۷	۰/۸۲	۰/۴۸	۰/۰۳	۲۱/۵	۱/۴	۷/۴	۱۶/۶	رسی شنی	۳۱/۳	۱۳/۸	۵۵	۳
۰/۳۷	۷/۹	۰/۸۲	۰/۴۸	۰/۰۳	۸۹/۶	۱/۴	۱۰/۱	۲۱/۵	لومی رسی شنی	۳۱/۳	۱۸/۸	۵۰	۴

(جدول ۲) - دامنه تغییرات پارامترهای ورودی شبکه عصبی مصنوعی در طول فصل رشد سیر مورد استفاده

پارامتر نماد	دما ($^{\circ}C$)		رطوبت نسبی (%)		سرعت باد (ms^{-1})	ساعات آفتابی (h)
	T_{min}	T_{max}	RH_{min}	RH_{max}		
حداکثر	۱۶/۶	۳۶	۶۰	۹۸	۱۳	۱۳/۵
حداقل	-۶/۷	۱۰/۲	۲/۲	۲۴	۰	۰
میانگین	۶/۶	۲۴/۱	۲۱/۶	۵۵/۶	۳/۱	۹/۴



(شکل ۱) - پراکندگی داده‌های لایسمتری سیر مورد استفاده در شبکه عصبی مصنوعی

$$R^2 = 1 - \frac{\sum_{i=1}^n [T_i - Y_i]}{\sum_{i=1}^n [\bar{Y} - Y_i]} \quad (5)$$

در روابط فوق، T_i : مقدار واقعی (هدف)، Y_i : مقدار پیش‌بینی شده، n : تعداد الگوها (۳۰۹)، \bar{Y} : میانگین مقادیر پیش‌بینی شده توسط شبکه عصبی مصنوعی

نتایج اجرای حالات مختلف الگوریتم شبکه عصبی مصنوعی، در قالب جداول و نمودارهای مختلف ترسیم شد. به منظور مقایسه بهتر شبکه عصبی مصنوعی، اطلاعات آماری حالات مختلف اجرای شبکه در قالب معیارهای آماری محاسبه و در جداول مربوطه انعکاس یافت. شبکه عصبی مصنوعی نسبت به نوع و ماهیت داده‌ها و اطلاعات انتخابی در لایه ورودی حساس است و این حساسیت در دقت عملکرد شبکه عصبی تاثیر می‌گذارد، بدین منظور از آنالیز حساسیت استفاده گردید. به طوری که به عوامل ورودی ۲۰٪ تغییرات افزایشی و کاهش‌ی داده و میانگین اختلاف میان مقادیر پیش‌بینی شده توسط شبکه در حالت ایجاد تغییرات و بدون ایجاد تغییرات به عنوان حساسیت در نظر گرفته شد (۶).

نتایج و بحث

پراکنش داده‌ها

در جدول ۲ حداکثر، حداقل و میانگین پارامترهای مورد استفاده در اجرای شبکه عصبی مصنوعی آورده شده است.

برای دستیابی به ساختار بهینه ANN، تبخیر- تعرق گیاه سیر به صورت روزانه در طول فصل رشد در ۴ دستگاه لایسیمتر زهکش‌دار در طول ۳ سال (۱۳۸۷-۱۳۸۴) اندازه‌گیری و میانگین آن در شکل ۱ ارائه شده است. اندازه‌گیری و ثبت اطلاعات لایسیمتری گیاه سیر از روز اول فروردین هر سال شروع و پایان آن دهم تیرماه بوده است. به عبارت دیگر طول دوره رشد سیر برای هر فصل کشت ۱۰۳ روز بود که در مجموع سه سال، ۳۰۹ عدد ثبت شده در پیش‌بینی استفاده شد.

روند تغییرات در شکل ۱، میانگین حداکثر تبخیر- تعرق گیاه سیر را در نیمه اول خرداد ماه معادل ۱۱/۳۸ میلی‌متر نشان می‌دهد. این مقدار حاصل مقادیر ۱۱/۷۸ میلی‌متر برای سال اول کشت، ۱۱/۱۳ میلی‌متر برای سال دوم کشت و ۱۱/۲۲ میلی‌متر برای سال سوم کشت می‌باشد. به همین ترتیب میانگین حداقل تبخیر- تعرق نیز معادل ۰/۱۲ میلی‌متر به دست آمد.

نوع شبکه عصبی مصنوعی براساس پژوهش‌های (۱۰) ASCE و برادوک و همکاران (۱۳) در خصوص مسائل آب‌شناختی و پژوهش‌های کولیالی و همکاران (۱۴) در مسائل اقلیم‌شناختی، پرسپترون چند لایه با الگوریتم پس‌انتشار خطا انتخاب شد. روش آموزش شبکه همانند گزارشات کیسی (۱۹)، لاندراکس و همکاران (۲۱) بر پایه قوانین لونبرگ مارکوات^۱، مومنتوم^۲، دلتا-بار-دلتا^۳، استپ^۴، گرادیان مزدوج^۵ و تند انتشار^۶ بود. از تابع محرک سیگموئید به واسطه عملکرد مناسب آن در مدل‌سازی پدیده تبخیر- تعرق استفاده شد (۲۶). عملیات مدل‌سازی در نرم‌افزار Ver.5 NeuroSolution تحت ویندوز که در آن امکان تعیین همه پارامترهای مربوط به طراحی ساختار بهینه شبکه وجود دارد، انجام شد. مهمترین این پارامترها، شمار نرون لایه پنهان و شمار لایه‌های پنهان، تعداد تکرارهای آموزش و توانمندی تشخیص و رآموزی شبکه از طریق آزمون اعتبارسنجی متقابل^۷ (CV)، جهت توقف آموزش شبکه است. جهت گزینش ساختار بهینه، از شبکه عصبی مصنوعی سه و چهار لایه با تعداد نرون‌های مختلف در لایه (های) میانی استفاده شد. تعداد گام‌های پیش فرض در آموزش شبکه عصبی مصنوعی چند لایه ۱۰۰۰ گام و تغییرات نرون لایه (های) میانی بین ۱ تا ۱۵ در نظر گرفته شد. این تعداد نرون با توجه به کاربرد بیشتر آن‌ها در شبکه‌های عصبی انتخاب گردید. معیار گزینش ساختار بهینه شبکه عصبی مصنوعی، کمینه مجذور میانگین مربعات خطا^۸ (RMSE)، میانگین قدر مطلق خطا^۹ (MAE)، انحراف معیار میانگین قدر مطلق خطا^{۱۱} (STD_{MAE}) از روابط ۲ تا ۴ بر حسب میلیمتر بر روز و بیشترین مقدار ضریب تعیین^{۱۱} (R^2) از رابطه ۵ بود.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (T_i - Y_i)^2}{n}} \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |T_i - Y_i| \quad (3)$$


$$STD_{MAE} = \sqrt{\frac{\sum_{i=1}^n |T_i - Y_i| - |\bar{T}_i - \bar{Y}_i|}{n-1}} \quad (4)$$

- 1- Levenberg Marquart
- 2- Momentum
- 3- Delta bar Delta
- 4- Step
- 5- Conjugate Gradient
- 6- Quick prop
- 7- Cross Validation
- 8- Root Mean Square Error
- 9- Mean absolute error
- 10- Standard deviation mean absolute error
- 11- Coefficient of determination

(جدول ۳) - نتایج بهترین آرایش‌های شبکه عصبی مصنوعی در تخمین تبخیر - تعرق گیاه سیر

آرایش	قانون آموزش	RMSE _{CV}	RMSE _L	RMSE _T	R ² _T	MAE	STD _{MAE}
۶-۶-۱	LM	۰/۱۱۴	۰/۰۸۰	۰/۰۸۸	۰/۸۸۴	۰/۰۷۰	۰/۰۶۱
۶-۵-۱	LM	۰/۱۱۸	۰/۰۸۶	۰/۰۹۰	۰/۸۸۳	۰/۰۷۳	۰/۰۷۳
۶-۶-۱	CG	۰/۱۴۶	۰/۱۱۵	۰/۱۲۰	۰/۸۷۸	۰/۰۸۲	۰/۰۷۲
۶-۶-۱	CG	۰/۱۴۲	۰/۱۱۹	۰/۱۲۲	۰/۸۷۵	۰/۰۹۹	۰/۰۹۰
۶-۱۲-۱	momentum	۰/۱۴۰	۰/۱۱۶	۰/۱۱۸	۰/۸۷۸	۰/۰۸۲	۰/۰۷۲
۶-۷-۷-۱	momentum	۰/۱۴۴	۰/۱۱۹	۰/۱۲۷	۰/۸۸۲	۰/۰۷۰	۰/۰۶۰
۶-۱۰-۱	Step	۰/۲۰۲	۰/۱۸۲	۰/۱۸۷	۰/۷۹۶	۰/۱۷۷	۰/۱۵۷
۶-۱۰-۱-۱	Step	۰/۲۵۲	۰/۲۳۵	۰/۲۵۶	۰/۸۶۰	۰/۲۱۶	۰/۲۰۶
۶-۹-۱	quickprop	۰/۱۹۵	۰/۱۷۳	۰/۱۷۷	۰/۸۱۳	۰/۱۲۷	۰/۱۰۵
۶-۱۰-۱-۱	quickprop	۰/۲۵۲	۰/۲۳۵	۰/۲۵۷	۰/۸۵۱	۰/۲۱۷	۰/۱۹۷
۶-۶-۱	D.B.D	۰/۱۴۰	۰/۱۱۷	۰/۱۲۸	۰/۸۷۷	۰/۰۸۲	۰/۰۷۲
۶-۸-۸-۱	D.B.D	۰/۱۴۲	۰/۱۱۸	۰/۱۲۳	۰/۸۷۱	۰/۰۷۵	۰/۰۷۵

L یادگیری، T آزمون



(شکل ۲) - تغییرات RMSE همگام با افزایش تعداد نرون در لایه میانی برای مدل بهینه

آرایش‌های پیشنهادی به صورت $۶-n-۱$ و $۶-m-n-۱$ هستند که n و m به عنوان تعداد نرون‌ها در لایه (های) میانی می‌باشند. لازم به ذکر است که به منظور ایجاد ساختار متقارن، تعداد نرون‌ها در دو لایه پنهان یکسان در نظر گرفته شدند.

در میان آرایش‌های مورد بررسی، آرایش ۳ لایه با شش نرون در لایه پنهان یعنی آرایش ۶-۶-۱ از کمترین RMSE برخوردار بود (جدول ۳). در این زمینه پژوهشگران دیگری چون پلنگی و همکاران (۱)، شایان نژاد و همکاران (۵) و قاسمی و همکاران (۷) نیز آرایش‌هایی با شمار نرون‌های مشابه برای پدیده تبخیر- تعرق، پیشنهاد کرده‌اند. در این تحقیق آرایش‌هایی با دو لایه پنهان و تعداد نرون‌های متفاوت دیگر هم به اجرا در آمد، که به بهبود چشم‌گیری در

بررسی روند تغییرات تبخیر- تعرق گیاه سیر نشان داد میانگین سه ساله نیاز آبی گیاه سیر طی فصل رشد در شرایط فراهمی کامل آب، معادل ۵۴۶/۵ میلی‌متر بود. رقم فوق بیش از ارقام گزارش شده توسط ویلالوباس و همکاران (۲۵) و فابرو و همکاران (۱۶) در شرایط کم آبی است. دلیل فزونی نیاز آبی در تحقیق حاضر نسبت به نتایج دو محقق فوق علاوه بر شرایط متفاوت آب و هوایی و فیزیولوژیکی توده سیر کاشته شده، بیشتر ناشی از عدم اعمال تنش آبی است.

نتایج اجرای شبکه عصبی مصنوعی

آرایش‌های بهینه شبکه عصبی مصنوعی از میان تمامی حالات مورد بررسی در شبکه ۳ لایه و ۴ لایه، در جدول ۳ ارائه شده است.

است. این شکل نیز نتیجه‌ای مشابه شکل ۲ را به تصویر کشیده است. در شکل ۳ ارتباط مناسب و خوبی میان تعداد نرون در لایه (های) میانی و ضریب تعیین برای شبکه عصبی دیده می‌شود که در راستای نتایج قبلی، دو آرایش ۱-۶-۶ و ۱-۵-۵-۶ را براساس حداکثر شدن معیار ضریب تعیین، تایید می‌کند. این نتیجه با گزارش توصیه‌ای انجمن مهندسان آمریکا (ASCE) در سال ۲۰۰۰ برای مسائل هیدرولوژی هم‌خوانی دارد. (۱۰) ASCE در گزارش خود اظهار داشته سرعت یادگیری و قدرت تعمیم‌پذیری شبکه به ازای افزایش تعداد نرون لایه میانی کاهش می‌یابد.

ارزیابی عملکرد شبکه عصبی مصنوعی با آرایش ۱-۶-۶ در قالب شکل ۴ نشان داده شد. شکل ۴ همبستگی بالا و مناسبی میان تبخیر- تعرق پیش‌بینی شده گیاه سیر از شبکه عصبی و مقادیر تبخیر- تعرق اندازه‌گیری شده گیاه سیر در لایسیمتر ($R^2=0/88$) را نشان می‌دهد. این شکل گویای شبیه‌سازی مناسب تبخیر- تعرق گیاه سیر توسط ANN است. در شکل فوق داده‌های پیش‌بینی شده توسط شبکه عصبی مصنوعی با آرایش ۱-۶-۶ در محور افقی و داده‌های اندازه‌گیری شده از لایسیمتر در محور عمودی جای گرفتند.

از دیگر نتایج این پژوهش وابستگی شبکه عصبی مصنوعی به تعداد و نوع اطلاعات ورودی است، لیکن می‌توان گفت ترتیب اطلاعات در حصول جواب‌های بهتر بی‌تاثیر است. عدم وابستگی به ترتیب اطلاعات به دلیل ارتباط هر نرون در لایه ورودی با تمامی نرون‌های لایه پنهان، قابل توجیه است. به عبارت دیگر خروجی هر نرون در لایه اول به عنوان ورودی برای تمامی نرون‌ها در لایه دوم می‌باشد.


ساختار شبکه بهینه پیشنهادی در این تحقیق (۱-۶-۶)، در شکل ۵ ارائه شده است.

عملکرد شبکه منجر نشد (جدول ۳).


شکل ۲ نتیجه اعمال تعداد نرون‌های متفاوت (۱ تا ۱۵) در لایه میانی از نظر خطای برآوردی برای آرایش‌های ۱-۶-n-۱ و ۱-m-n-۶ با اعمال قانون آموزش لونیگ مارکوات به عنوان قانون بهینه می‌باشد. تغییر در تعداد نرون‌ها در دو آرایش پیشنهادی از جدول ۳ صورت گرفته است. تعداد گوناگون نرون در لایه (های) میانی و انتخاب ساختار بهینه‌ی حاصل از آن به‌واسطه تکنیک سعی و خطا است.

همان‌گونه که در شکل ۲ مشاهده می‌گردد روند کلی خطا با افزایش تعداد نرون در لایه (های) میانی کاهش می‌یابد. اختلاف خطا در آرایش یک و دو لایه (میانی) برای تعداد کمتر از ۴ نرون قابل ملاحظه نبوده، در حالی که اختلاف فوق در تعداد بیش از ۹ نرون، آشکارتر است و در مجموع مقدار خطای آرایش یک لایه کمتر از دو لایه است. با توجه به اینکه معیار انتخاب تعداد نرون حداقل گشتن خطا می‌باشد، نتایج نشان داد که تعداد ۶ و ۵ نرون به ترتیب برای یک و دو لایه میانی قابل پیشنهاد است. در این راستا جهانگیر و همکاران (۳) نیز با بکارگیری شبکه عصبی مصنوعی در شبیه‌سازی بارش- رواناب، نشان دادند افزایش تعداد نرون‌ها در لایه میانی به‌مورد چشمگیری را در پی ندارد و به اعتقاد مینس و هال (۲۲) بهبودهای ناشی از افزایش تعداد لایه‌های پنهان نیز از نظر محاسبات اضافی لازم، توجیه‌پذیری آن‌ها را کاهش می‌دهد. لذا به عنوان یک نتیجه کلی از شکل ۲ می‌توان دریافت که تعداد شش نرون در یک لایه میانی منجر به حصول کمترین مقدار خطا برای پیش‌بینی تبخیر- تعرق شده است که با نتایج جدول ۳ هم‌خوانی دارد.


تغییرات ضریب تعیین (R^2) برای ۱ تا ۱۵ نرون از ۲ آرایش پیشنهادی یعنی ۱-۶-۶ و ۱-۵-۵-۶ در شکل ۳ نشان داده شده




(شکل ۳)- تغییرات R^2 همگام با افزایش تعداد نرون در لایه میانی برای مدل بهینه



(شکل ۴) - همبستگی میان مقادیر پیش‌بینی‌شده توسط شبکه عصبی مصنوعی و مقادیر لایسیمیتری سیر



(شکل ۵) - ساختار شبکه بهینه مورد استفاده در پیش‌بینی تبخیر تعرق گیاه سیر



(شکل ۶) - نتایج آنالیز حساسیت تبخیر - تعرق گیاه سیر به پارامترهای ورودی شبکه در مدل بهینه

و هنگام آزمون شبکه عصبی با ساختار پس‌انتشار پس از چند ثانیه اول، ورودی‌های شبکه همان خروجی‌های شبکه در لحظات قبل می‌باشند که این امر به پدیده انباشت خطا منجر می‌شود. به عبارت دیگر اگر خطای قابل توجهی در هر لحظه حادث شود خروجی غیردقیق به دست آمده در لحظات بعد به عنوان ورودی دوباره به شبکه وارد شده و تاثیر این خطا به خروجی‌های بعدی هم منتقل می‌شود که در صورت دقت بسیار بالای شبکه می‌توان از ایجاد خطاهای بسیار بزرگ اجتناب کرد. با این حال رفتار مدل به رفتار سیستم اصلی (لایسیمتر) بسیار نزدیک و خطای مدل که تفاوت رفتار آن با سیستم اصلی است در همه مراحل عملکرد، کوچک باقی می‌ماند. در نتیجه، مدل پیشنهادی از قابلیت اعتماد و اعتبار مناسبی برخوردار است. مقایسه رفتار سیستم اصلی (لایسیمتر) با مدل منتخب ANN نشان می‌دهد که این روش با الگوریتم پس‌انتشار (BP)، در تخمین تبخیر- تفرق گیاه سیر از دقت بالایی برخوردار است. علت آن است که تبخیر- تفرق در هر لحظه به پتانسیل تبخیرخواهی هوا و محتوای رطوبت خاک در لحظه قبل وابسته است. این بیان دیگری از دینامیکی بودن سیستم است.

نتایج پژوهش حاضر نشان داد روش ANN با آرایش ۶-۶-۱ و اعمال قانون آموزش لوبنگ مارکوات و تابع محرک سیگموئید، در تخمین تبخیر- تفرق گیاه سیر در شرایط اقلیمی مورد مطالعه، نتایج مطلوبی ارائه می‌نماید. به طور کلی می‌توان گفت شبکه‌های هوشمند عصبی در این مساله نیز مانند بسیاری از مسائل مهندسی یا اقلیم‌شناسی و آب‌شناسی، قابلیت تخمین پارامتر مجهول (تبخیر- تفرق گیاه سیر) را دارد.

آنالیز حساسیت مدل بهینه شبکه عصبی مصنوعی

میزان حساسیت مدل بهینه شبکه عصبی مصنوعی در تخمین تبخیر- تفرق گیاه سیر (ET_c)، با افزایش و کاهش ۲۰٪ عوامل موثر، در شکل ۶ نشان داده شده است. با توجه به شکل (۶) می‌توان نتیجه گرفت مدل پیشنهادی شبکه عصبی مصنوعی (۶-۶-۱)، بیشترین حساسیت را در حالت افزایشی به دمای حداکثر هوا و کمترین حساسیت را به حداقل رطوبت نسبی دارد. روند حساسیت افزایشی نشان داده شده در شکل ۷ منطقی به نظر می‌رسد. زیرا فائو نیز در نشریه شماره ۲۴ خود رطوبت نسبی حداقل را در مقابل رطوبت نسبی حداکثر برای ضریب تعدیل مدل پنمن، بی‌تاثیر دانسته است (۱۵). بنا به شکل (۷) حساسیت در حالت کاهش بیشتر از افزایشی است که این امر را می‌توان در مقاومت گیاه به تبخیر- تفرق در حالت افزایش عوامل موثر بر تبخیر- تفرق دانست. به عبارت دیگر به نظر می‌رسد با افزایش مقدار عوامل موثر بر تبخیر- تفرق، توان پاسخ‌گویی گیاه به شرایط جدید برای از دست ندادن آب کاهش می‌یابد. در مقابل، با کاهش مقدار عوامل فوق، گیاه توان پاسخ‌گویی به پتانسیل تبخیر- تفرق را دارد. لذا در چنین حالتی میزان حساسیت افزایش می‌یابد.

نتیجه‌گیری

در این پژوهش شبکه عصبی مصنوعی برای مدل‌سازی سیستم‌های دینامیکی غیرخطی که داده‌های ورودی و خروجی آن‌ها به صورت سری زمانی ارائه شده‌اند، طراحی و مورد استفاده قرار گرفتند. داده‌های آزمون مدل با داده‌های آموزش شبکه متفاوت است

منابع

- ۱- پلنگی ج.ع، معاضد ه. و طارقیان ر. ۱۳۸۵. تخمین تبخیر و تفرق گیاه مرجع با استفاده از شبکه‌های عصبی در اهواز. همایش ملی مدیریت شبکه‌های آبیاری و زهکشی، دانشگاه شهید چمران اهواز.
- ۲- پرورش‌ریزی ع.، کوچک‌زاده ص. و امید م. ۱۳۸۵. برآورد مشخصات پرش هیدرولیکی متحرک با کاربرد شبکه عصبی مصنوعی و روش تلفیقی شبکه عصبی-الگوریتم ژنتیک. مجله علوم کشاورزی ایران. جلد ۳۷. شماره ۱: ۱۹۶-۱۸۷.
- ۳- جهانگیر ع.ر.، رائینی م. و ضیا احمدی م.خ. ۱۳۸۷. شبیه‌سازی فرآیند بارش- رواناب با شبکه عصبی مصنوعی (ANN) با مدل HEC-HMS در حوضه معرف کارده. مجله علمی پژوهشی آب و خاک (علوم و صنایع کشاورزی). جلد ۲۲. شماره ۲: ۸۴-۷۲.
- ۴- سیدان م. ۱۳۷۹. بررسی اقتصاد کشت سیر در استان همدان. مجله اقتصاد کشاورزی و توسعه، جلد ۸، شماره ۳۱: ۱۵۱-۱۳۷.
- ۵- شایان‌نژاد م. ۱۳۸۵. مقایسه دقت روش‌های شبکه‌های عصبی مصنوعی و پنمن - مانیتیس در محاسبه تبخیر و تفرق پتانسیل. همایش ملی مدیریت شبکه‌های آبیاری و زهکشی، دانشگاه شهید چمران اهواز
- ۶- قاسمی ع. ۱۳۸۷. ارزیابی تبخیر و تفرق سیر در همدان با استفاده از مدل‌های تجربی و شبکه‌های عصبی مصنوعی و لایسیمتر. پایان‌نامه کارشناسی ارشد آبیاری و زهکشی دانشکده کشاورزی دانشگاه بوعلی سینا همدان.
- ۷- قاسمی ع.، زارع ایبانه ح.، امیری چایجان ر.، محمدی ک.، معروفی ص. و احمدی م. ۱۳۸۶. ارزیابی دقت تبخیر و تفرق برآوردی (ET_0) از روش‌های تجربی و شبکه‌های عصبی مصنوعی در مقایسه با نتایج لایسیمتری. مجله پژوهش کشاورزی دانشکده کشاورزی دانشگاه بوعلی

- ۸- مهدیزاده نراقی ر.، ظفری د.، زمانی زاده ح. و ارجمندیان ر. ۱۳۸۷. شناسایی عوامل بیماری‌زای قارچی سیر در استان همدان. مجله پژوهش کشاورزی دانشکده کشاورزی دانشگاه بوعلی سینا. جلد ۷، شماره ۳: ۲۹-۱۱.
- 9- Anctil F., C.H. Perrin and Andreassian, V. 2003. Impact of length of observed records on the performance of ANN and of conceptual parsimonious rainfall-runoff forecasting models. *Environmental Modeling & Software*, 19: 357-368.
- 10- ASCE Task Committee. 2000. Artificial neural network in hydrology. *Journal of Hydrologic Engineering*, 5, 124-144.
- 11- Bhakar S R., Ojha S., Singh R.V. and Ansari A. 2006. Estimation of Evapotranspiration for wheat crop using artificial neural network. 4th World Congress on Computers in Agriculture. 305-314.
- 12- Bruton J.M., McClendon R.W. and Hoogenboom G. 2000. Estimating daily pan evaporation with artificial neural network. *Trans. ASAE*. 43(2): 492-496.
- 13- Braddock R.D., M.L. Kremmer and L. Sanzogni. 1998. Feed forward artificial neural network model for forecasting rainfall-runoff. *Environmental Sciences*, 9: 419-432.
- 14- Coulibaly P., Anctil F. and Bobe B. 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach *journal of Hydrology*. 230:244-257.
- 15- Doorenbos J. and. Pruitt W.O. 1977. Guidelines for predicting crop water requirements. Irrigation Drainage Paper No. 24. FAO. Rome. Italy
- 16- Fabeiro Cortes C., Martin de Santa Olalla F. and Lopez Urea, R. 2002. Production of garlic under controlled deficit irrigation in a semi-arid climate. *J. Agr. Water Manage*. 59: 155-167.
- 17- Hanson B., May D., Voss R., Cantwell M. and Rice R. 2002. Response of garlic to irrigation water. *J. Agr. Water Manage*. 58: 29-43.
- 18- Kaul M., Hill R.L., Walthall, C., 2005. Artificial neural networks for corn and soybean yield prediction. *Agric. Syst*. 85, 1-18.
- 19- Kisi O. 2006. Evapotranspiration estimation using feed-forward neural network. *Nordic Hydrology*. 37(3): 247-260
- 20- Kumar M., Raghuwanshi, N.S., Singh, R., Wallender, W.W. and Pruitt W.O. 2002. Estimating evapotranspiration using artificial neural networks. *J. Irr. and Drainage*. ASCE. 128(4): 224-233.
- 21- Landeras. Ortiz A. and Javier Lopez, j. 2007. Comparison of artificial neural network models and empirical and semi empirical equation for daily reference evapotranspiration estimation in the Basque country (northern Spain). *agricultural water management*. 95(5): 553-565
- 22- Minns A.W. and M.J. Hall. 1996. Artificial neural network as rainfall-runoff models. *Hydrological Sciences Journal*, 41: 399-417.
- 23- Moghaddamnia A., Ghafari Gousheh, M., Piri, J., Amin, S. and Han, D. 2009. Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques. *Advances in Water Resources*. 32(1): 89-97.
- 24- Utset A., Velicia H., Rio, B.D. and Morillo, R. 2007. Calibrating and validation an agro hydrological model to simulate sugar beet water use under Mediterranean. *Agricultural water management*. 94 (1-3): 11-21.
- 25- Villalobos F.J., Testi, L., Rizzalli Orgaz, F. 2004. Evapotranspiration and crop coefficients of irrigated garlic in a semi-arid climate. *Agr. Water Manage*. 64(3): 233-249.
- 26- Zanetti S.S., Sousa E.F., Olivera V.P.S., Almeida, F.T. and Bernardo, S. 2007. Estimating evapotranspiration using artificial neural network and minimum climatological data. *J. Irr. and Drainage Eng.*. ASCE. 133 (2): 83-89.

Assessment of Artificial Neural Network (ANN) in prediction of garlic evapotranspiration (ET_c) with lysimeter in Hamedan

H. Zare Abyaneh^{1*} - A. Ghasemi² - M. Bayat varkeshi³ - S. Marofi⁴

Abstract

Evapotranspiration as one of the important elements in agriculture has a considerable role in water resource management. Therefore, using a more exact estimation method is an essential step of agricultural development, especially in arid semi-arid area. In this research, in order to exact estimate of garlic evapotranspiration using lysimetric data, an artificial neural network (ANN) model was developed. Maximum and minimum air temperatures, maximum and minimum relative humidity values, wind speed and sunshine hours were used as the input layer data. The crop evapotranspiration was measured using 4 lysimeters of $2 \times 2 \times 2$ m of the Bu-Ali Sina agriculture collage's meteorology station during 2006-2008. Statistic indicators RMSE, MAE, STD_{MAE} R^2 were used for performance evaluation of the models. The results showed the more exact method concerned to the multilayer perceptron (MLP) model with the back propagation algorithm. The 6-6-1 layout with Levenberg-Marquat rule and sigmoid function had the best topology of the model. The evaluation criteria were 0.088, 0.07 and 0.061 mm/day as well as 0.88, respectively. The results also showed that the average daily garlic evapotranspiration were 8.3 and 6.5 mm based on the lysimeter ANN methods, respectively. Overall, evaluation of ANN results showed that the errors of ANN were negligible. The ANN showed high and low sensitivity to maximum air temperature and minimum relative humidity, respectively.

Key words: Artificial Neural Networks, Evapotranspiration, Lysimeter, Garlic, Hamedan

1,4 – Assistant and Associate prof ., Department of irrigation and drainage, Faculty of Agriculture, Bu Ali Sina University
(* - Corresponding author Email: zare_h2000@yahoo.com)
2,3- Graduated Ms and Ms student of irrigation and drainage Bu Ali Sina University