



دانشگاه گورگان، دانشکده کشاورزی

مجله پژوهش‌های حفاظت آب و خاک

جلد هجدهم، شماره دوم، ۱۳۹۰

www.gau.ac.ir/journals

محاسبه تبخیر و تعرق واقعی گیاه سیر به روش مدل‌سازی چندگانه تحت شرایط کاشت لایسمتر

*حمید زارع‌ابیانه^۱، مریم بیات‌ورکشی^۲ و صفر معروفی^۳

^۱استادیار گروه مهندسی آب، دانشگاه بوعلی‌سینا، همدان، ^۲دانش‌آموخته کارشناسی ارشد گروه مهندسی آب،

دانشگاه بوعلی‌سینا، همدان، ^۳دانشیار گروه مهندسی آب، دانشگاه بوعلی‌سینا، همدان

تاریخ دریافت: ۸۸/۱۰/۱۹؛ تاریخ پذیرش: ۸۹/۳/۲۲

چکیده

روش‌های متعددی به منظور پیش‌بینی فرایندهایی مانند تبخیر و تعرق پدیده‌ها وجود دارند که در این میان، روش‌های فراابتکاری ترکیبی (مدل‌سازی چندگانه) از قابلیت بیش‌تری برخوردارند. در این مطالعه از دو مدل فراابتکاری ترکیبی شامل تلفیق عصبی-ژنتیک و عصبی-فازی در کنار شبکه عصبی مصنوعی جهت پیش‌بینی نیاز آبی گیاه سیر به‌عنوان گیاهی با اهمیت دارویی و ارزش غذایی بالا، استفاده گردید. به این منظور از اطلاعات هواشناسی دمای حداقل و حداکثر هوا، رطوبت نسبی حداقل و حداکثر هوا، ساعات آفتابی، سرعت باد و لایسمتری گیاه سیر طی سال‌های ۱۳۸۷ و ۱۳۸۸ مستقر در ایستگاه هواشناسی دانشکده کشاورزی دانشگاه بوعلی‌سینا، برای مدل‌کردن روش‌های هوشمند استفاده شد. حداکثر مقدار تبخیر و تعرق سیر از لایسمتر ۱۱/۲۲ میلی‌متر و میانگین دو ساله آن ۴/۷۹ میلی‌متر در روز به‌دست آمد. نتایج مدل‌سازی تبخیر و تعرق گیاه سیر نشان از برتری روش تلفیقی عصبی-ژنتیک در مقایسه با دو روش عصبی و عصبی-فازی داشت. به‌عبارت دیگر بهینه‌سازی شبکه عصبی مصنوعی موفق‌تر از منطق فازی بود به‌طوری‌که الگوریتم ژنتیک در ترکیب با شبکه عصبی توانست خطای آزمون شبکه را نسبت به عصبی-فازی به‌میزان ۲۴ درصد کاهش دهد. اما ترکیب منطق فازی نه تنها سبب بهبود نتایج شبکه عصبی مصنوعی نشد، بلکه دقت پیش‌بینی را به‌میزان ۱۲

*مسئول مکاتبه: zareabyaneh@gmail.com

مجله پژوهش‌های حفاظت آب و خاک جلد (۱۸)، شماره (۲) ۱۳۹۰

درصد کاهش داد. آماره میانگین مجذور مربعات خطا در برآورد تبخیر و تعرق گیاه سیر با مدل بهینه عصبی-ژنتیک برابر ۰/۱۲ میلی‌متر در روز و مقدار ضریب تعیین آن ۰/۸۸ به‌دست آمد. معیارهای ضریب تعیین، عرض از مبدا و شیب خط برازش داده شده به داده‌های برآورد شده از مدل ترکیبی عصبی-ژنتیک در طول دوره (دو سال) در مقایسه با مدل ترکیبی عصبی-فازی نیز بیانگر کارایی این مدل می‌باشند.

واژه‌های کلیدی: تبخیر و تعرق، عصبی-ژنتیک، عصبی-فازی، گیاه سیر، همدان

مقدمه

مدل‌سازی فرآیند تبخیر و تعرق گیاهان زراعی به‌طور عمده به روش‌های تجربی، آئرودینامیک و بیلان انرژی صورت می‌گیرد. در این روش‌ها با بهره‌گیری از میانگین پارامترهای هواشناسی در گام‌های مختلف زمانی، تبخیر و تعرق برآورد می‌گردد. تغییرپذیری زیاد تبخیر و تعرق سبب شده که مدل‌های خطی، عملکرد مناسبی در این زمینه نداشته باشند و محققان به استفاده از مدل‌های غیرخطی روی آورند. برای برآورد دقیق این پارامتر، باید با صرف وقت و هزینه، داده‌های زیادی اندازه‌گیری شود. استفاده از روش‌های غیرمستقیم مانند شبکه‌های عصبی مصنوعی از راه‌های چیرگی بر این مشکل می‌باشد (وانگ و همکاران، ۲۰۰۹). شبکه عصبی به‌عنوان یک تخمین‌گر توابع عمومی قادر است با در نظر گرفتن تعداد صحیحی نرون در لایه میانی هر تابع پیوسته از فضای R^N را به فضای R^M تخمین بزند (آدپاژو و همکاران، ۲۰۰۷). دیدگاه‌های کلی در برآورد تبخیر و تعرق شامل سه دسته عمده می‌باشند. دسته اول، روش‌های تجربی و ترکیبی با مبنای تئوریک که از سال ۱۹۴۸ با پیشنهاد مدل پنمن توسعه چشم‌گیری یافتند. نتیجه تلاش‌های محققان در این بخش ارایه بیش از ۵۰ مدل مختلف برآورد تبخیر و تعرق بوده است (گریسمر و همکاران، ۲۰۰۲). دسته دوم شامل روش‌های فراابتکاری مانند شبکه‌های عصبی مصنوعی، الگوریتم ژنتیک و الگوریتم فازی می‌باشند که در سال‌های اخیر مطرح شده‌اند. این روش‌ها با جستجوی عمیق در فضای جواب در پی یافتن جواب‌هایی با کیفیت بالاتر هستند (قیصری و قنادپور، ۲۰۰۹). دسته سوم از ترکیب دو الگوریتم فراابتکاری (PFIH)^۱ مانند الگوریتم شبکه‌های عصبی با الگوریتم ژنتیک و یا الگوریتم شبکه عصبی با

1- Push Forward Insertion Heuristic

منطق فازی می‌باشند. لاً این روش‌ها برای سری‌های زمانی مانند تبخیر و تعرق جواب‌های بهتری نسبت به روش‌های دسته اول در زمان کوتاه‌تری تولید می‌کنند (رحیمی‌خوب، ۲۰۰۸). شبکه‌های عصبی مصنوعی (ANNs)^۱، الگوریتم ژنتیک (GA)^۲ و سیستم‌های استنتاج فازی (FIS)^۳ از الگوریتم‌های فراابتکاری معروف هستند که به اعتقاد کیسی (۲۰۰۷) در حال حاضر از روش‌های معتبر برآورد تبخیر و تعرق محسوب می‌شوند. از مهم‌ترین پژوهش‌های صورت گرفته در حوزه عصبی می‌توان به مطالعات زارع‌ایبانه و همکاران (۲۰۰۹)، کیسی (۲۰۰۷) و کمار و همکاران (۲۰۰۸) اشاره کرد که کاربرد ANN را در تبخیر و تعرق بررسی کرده‌اند. بررسی‌های صورت گرفته، نشان داد که الگوریتم ژنتیک عملکرد خوبی از نظر زمان حل و کیفیت جواب‌های به‌دست آمده در حل سری‌های زمانی داشته است (آیتک و کیسی، ۲۰۰۸؛ کیم و کیم، ۲۰۰۸). تیموپولوس و همکاران (۲۰۰۸) و مقدم‌نیا و همکاران (۲۰۰۹) از منطق فازی در برآورد تبخیر و تعرق و تبخیر استفاده کردند. لین و همکاران (۲۰۰۸) دقت و سرعت محاسبات سیستم‌های فازی را در برآورد فرایندهای هیدرولوژیکی مناسب و کارا می‌دانند. محققان مختلف به فراخور نیاز خود، سعی در ترکیب دو یا چند الگوریتم فراابتکاری برای شبیه‌سازی داده‌های تبخیر و تعرق داشته‌اند. شاید بتوان به الگوریتم‌های فراابتکاری ترکیبی، مدل‌سازی چندگانه^۴ نیز اطلاق نمود. مدل‌سازی چندگانه روشی برای اعمال چند مدل در توصیف نوع فرآیند حاکم، برای حصول نتیجه بهتر است. به‌عبارت دیگر قرار گرفتن دو مدل فراابتکاری در کنار یکدیگر می‌تواند ما را به سطح بالاتری از توانمندی‌ها در پاسخ‌گویی به نیازهایمان برساند. به‌عنوان نمونه تلفیق شبکه عصبی با الگوریتم ژنتیک، منجر به برآوردهای مناسب‌تری از مشخصات پرش هیدرولیکی در جریان غیرماندگار نسبت به روش شبکه عصبی شد (پرورش‌ریزی و همکاران، ۲۰۰۶). گلدبرگ (۱۹۸۹) علت برآوردهای بهتر الگوریتم عصبی-ژنتیک را در آموزش مناسب‌تر شبکه عصبی می‌داند. کسکین و همکاران (۲۰۰۹) ترکیب منطق فازی و شبکه عصبی را در تخمین فرآیند تبخیر موفق‌تر از منطق فازی گزارش کردند. برتری روش ترکیبی عصبی-فازی نسبت به شبکه‌های عصبی در تخمین رسوبات معلق و شناسایی تومورهای سرطانی سینه به‌ترتیب توسط کوبانر و همکاران (۲۰۰۹) و پارتیبان و سابرامانیان (۲۰۰۹) گزارش شد. در پژوهشی دیگر ناسه و

- 1- Artificial Neural Networks
- 2- Algorithm Genetic
- 3- Fuzzy Interface System
- 4- Multiple Modeling

همکاران (۲۰۰۹) ترکیب الگوریتم ژنتیک و شبکه عصبی مصنوعی را روشی قابل اعتماد و موفق در تخمین فشارهای به‌دست آمده از دستگاه ونتوری^۱ معرفی کردند. کاربرد الگوریتم ژنتیک با هدف کاهش خطاهای شبکه عصبی مصنوعی در برآورد مشخصات جریان چندفازی توسط لارنتیو و همکاران (۲۰۰۲) بررسی شد.

اگرچه تاکنون پژوهش‌های مختلفی در زمینه برآورد تبخیر و تعرق انجام پذیرفته، ولی در بیش‌تر این پژوهش‌ها به استفاده از روش‌های تجربی و یا استفاده از یک روش هوشمند عصبی بسنده شده است. این در حالی است که تبخیر و تعرق یک متغیر زمانی غیرخطی است و زمان حل مسأله با بزرگ‌تر شدن ابعاد زمانی آن به‌طور نمایی رشد می‌کند (زارع‌ایبانه و همکاران، ۲۰۱۰). یکی از دلایل عمده در استفاده از الگوریتم‌های عصبی در ترکیب با سایر الگوریتم‌های هوشمند، سرعت دست‌یابی به جواب‌های با کیفیت بالا است. مطالعات آدهیامبو و همکاران (۲۰۰۱)، تزیموپولوس و همکاران (۲۰۰۸)، لین و همکاران (۲۰۰۸)، آیتک (۲۰۰۸) و شایان‌نژاد و همکاران (۲۰۰۸) نشان‌دهنده عملکرد مناسب مدل‌های هوشمند عصبی - فازی در تخمین تبخیر و تعرق گیاه مرجع می‌باشد. همچنین پژوهش صورت گرفته توسط کیم و کیم (۲۰۰۸) نیز بیانگر قابلیت مدل ترکیبی عصبی - ژنتیک در تخمین تبخیر و تعرق گیاه مرجع بود.

هدف بیش‌تر مطالعات ارزیابی مدل‌های هوشمند در تخمین تبخیر و تعرق گیاه مرجع بوده در حالی که مطالعات محدودی در خصوص مدل‌سازی تبخیر و تعرق دیگر گیاهان انجام گرفته است. بررسی منابع نشان داد تنها مطالعه صورت گرفته در این زمینه، پژوهش انجام شده توسط زارع‌ایبانه و همکاران (۲۰۰۹a) می‌باشد که گویای موفق بودن شبکه عصبی مصنوعی در برآورد تبخیر و تعرق گیاه سیر بود.

در این پژوهش از ترکیب شبکه عصبی به‌عنوان الگوریتم اصلی با الگوریتم فازی و الگوریتم ژنتیک در برآورد تبخیر و تعرق گیاه سیر (ETC)^۲ به‌عنوان محصول اقتصادی منطقه همدان استفاده شد. برآورد تبخیر و تعرق پتانسیل گیاه سیر، براساس آمار و اطلاعات هواشناسی صورت گرفت و نتایج الگوهای مختلف هوشمند با مقادیر لایسیمتری مقایسه گردید. بنابراین انتظار می‌رود که با اعمال مدل‌سازی چندگانه و ارزیابی روش‌های مختلف ترکیبی بتوان ضمن معرفی مدل ترکیبی مناسب، برآوردهای مناسبی از تبخیر و تعرق پتانسیل گیاه سیر در منطقه همدان (دانشکده کشاورزی) را در مقایسه با مقادیر اندازه‌گیری شده از لایسیمتر ارائه داد.

1- Venturi Scrubbers

2- Crop Evapotranspiration

مواد و روش‌ها

داده‌ها و اطلاعات مورد استفاده: داده‌های مورد استفاده، در این مطالعه از ۴ دستگاه لایسیمتر مستقر در ایستگاه هواشناسی دانشکده کشاورزی به ابعاد $2 \times 2 \times 2$ متر برداشت گردید. داده‌ها شامل مقادیر روزانه تبخیر و تعرق گیاه سیر بود که پس از آماده‌سازی لایسیمترها و کاشت توده سیر همدانی در پاییز سال‌های ۱۳۸۶ و ۱۳۸۷ به صورت روزانه از فروردین‌ماه سال بعد به دست آمد. انجام عملیات آبیاری و اندازه‌گیری‌های مرتبط با آن شامل زه آب خروجی و رطوبت خاک هر لایسیمترها از اول فروردین ماه به ترتیب به روش حجم‌سنجی و با دستگاه بلوک گچی تعیین و ثبت شد. تعیین تبخیر و تعرق پتانسیل گیاه سیر از لایسیمتر براساس معادله بیلان آب در بازه زمانی فروردین‌ماه تا تیرماه ۱۳۸۷ و ۱۳۸۸ صورت گرفت که به‌طور هم‌زمان پارامترهای هواشناسی نیز اندازه‌گیری گردید. به این ترتیب در سال اول ۱۰۳ داده تبخیر و تعرق پتانسیل از گیاه سیر و برای دو سال ۲۰۶ داده و همین تعداد داده اطلاعات هواشناسی اندازه‌گیری و ثبت گردید. از اطلاعات هواشناسی دمای حداقل (T_{min}) و حداکثر هوا (T_{max})، رطوبت نسبی حداقل (RH_{min}) و حداکثر هوا (RH_{max})، ساعات آفتابی (n)، سرعت باد (U_2) در بردار ورودی شبکه و مقدار تبخیر و تعرق گیاه سیر (ETc) در خروجی شبکه استفاده شد. از تمامی عوامل بالا در مطالعات کیسی و اوزترک (۲۰۰۷)، سودر و همکاران (۲۰۰۳) و سودر و همکاران (۲۰۰۲) در برآورد تبخیر و تعرق گیاه مرجع (ET_0) با شبکه عصبی استفاده شده است. در این پژوهش برای اجرای شبکه‌های هوشمند، مجموعه داده‌ها طبق عرف معمول به دو دسته تقسیم شدند. به این ترتیب، از ۸۰ درصد این ۲۰۶ الگو برای آموزش و بقیه به منظور آزمون کارایی شبکه آموزش دیده استفاده گردید (کسکین و همکاران، ۲۰۰۹).

مدل‌های مورد استفاده: به منظور پردازش داده‌ها، از روش مدل‌سازی چندگانه استفاده شد. در روش مدل‌سازی چندگانه، شبکه عصبی مصنوعی به‌عنوان روش اصلی انتخاب گردید. یکی از مشکلات عمده در استفاده از شبکه عصبی، فرآیند آزمون و خطا برای تعیین معماری بهینه آن می‌باشد، که در اینجا از الحاق الگوریتم ژنتیک و الگوریتم فازی به صورت جداگانه در شبکه عصبی استفاده شد. به‌کارگیری مدل هوشمند دوم در ترکیب با شبکه عصبی جهت مرتفع نمودن فرآیند آزمون و خطا است (شهبان و احمدی، ۲۰۰۷).

روش ترکیبی عصبی-ژنتیک (ANNGA): گاهی به دلیل ماهیت غیرخطی مسأله، روش‌های معمول آموزش، منجر به پاسخ مناسب شبکه عصبی نمی‌شود. بنابراین از الگوریتم ژنتیک با توجه به توانایی

جستجوی در فضاهای بزرگ به منظور یافتن نقطه بهینه توابع پیچیده غیرخطی در ترکیب با شبکه عصبی مصنوعی به جهت کاهش خطای شبکه استفاده شد. هدف از به‌کارگیری الگوریتم ژنتیک، بهینه‌سازی پارامتر وزن شبکه عصبی مصنوعی بود. بنابراین تابع هدف الگوریتم ژنتیک، تابعی از نتایج آمار شبکه عصبی مصنوعی است. برای آموزش ابتدا تعداد P (جمعیت هر نسل) شبکه عصبی به‌طور تصادفی مقداردهی اولیه شد و میزان خطا با استفاده از داده‌های آموزش محاسبه گردید. در مرحله بعد به روزرسانی پارامترهای شبکه با توجه به مقادیر تبخیر و تعرق گیاه سیر و نرخ‌های جهش^۱ و آمیزش^۲ انجام شد. الگوریتم بالا تا نبود بهبودی در پارامترهای شبکه با در نظر گرفتن جمعیت جدید به‌دست آمده تکرار گردید. در آخرین مرحله خروجی به‌دست آمده از اجرای شبکه با مقادیر واقعی مقایسه و در صورت حداقل شدن تفاوت بین دو مقدار بالا، اجرای مدل خاتمه یافت.

سیستم استنتاجی عصبی - فازی (CANFIS):^۳ در ترکیب دوم، شبکه عصبی با منطق فازی (CANFIS) به‌صورت ساختار شبکه‌ای پیش‌رونده به‌کار گرفته شد. مدل CANFIS از ویژگی‌های شبکه عصبی (ANN) به همراه سیستم استنتاج فازی (FIS)^۴ در قالب یک محیط عصبی - فازی بهره می‌گیرد (آیتک، ۲۰۰۸). در منطق فازی روند سینماتیکی برای طراحی یک کنترل‌کننده فازی وجود ندارد در حالی که شبکه عصبی با توجه به ویژگی آموزش از محیط، توانایی تطبیق با شرایط جدید را دارد. سیستم فازی، سیستمی منطبق بر قواعد منطقی شرط - نتیجه است و نقطه شروع ساخت آن به‌دست آوردن مجموعه‌ای از قواعد بالا تحت عنوان اگر - آنگاه^۵ فازی با استفاده از دانش فرد خبره یا دانش حوزه موردنظر می‌باشد (زاده، ۱۹۶۵). در مدل‌سازی CANFIS، کاربر قادر است تا مشخصات شبکه عصبی مصنوعی و مدل فازی را بر خلاف ساختار ANFIS به تفکیک انتخاب و به ساختار بهینه آن به روش آزمون و خطا دست یابد. برای آموزش شبکه ANFIS ابتدا تمامی داده‌های ورودی به بازه‌های فازی تقسیم و وزن قانون‌ها و وزن نسبی قوانین براساس مقادیر ورودی به هر گره به‌دست آمد. تکرار مراحل بالا تا حصول حداقل خطا و نبود بهبودی آن در صورت تکرارهای مجدد ادامه یافت و در پایان با اجرای شبکه، خروجی آن با مقادیر لایسمتری مقایسه شد.

- 1- Mutation
- 2- Crossover
- 3- Co-Active Neuro-Fuzzy Inference System
- 4- Fuzzy Inference System
- 5- If-Then

برای طراحی بخش شبکه عصبی مصنوعی هر یک از مدل‌ها، از توابع فعالیت سیگموئید^۱، تانژانت هایپربولیک^۲، سیگموئید خطی^۳، تانژانت هایپربولیک خطی^۴ و الگوریتم‌های آموزشی گشتاور^۵ و گرادینان مزدوج^۶ استفاده گردید. در بخش فازی هم، سیستم استنتاج سوگنو^۷ با تابع عضویت گوسین^۸ به کار گرفته شد. کلیه عملیات مدل‌سازی در جعبه ابزار نرم‌افزار نروسالوشن^۹ مورد استفاده به صورت یکسان برای تمامی ساختارهای پیشنهادی انجام گرفت. از آنجایی که یکی از مراحل پردازش داده‌ها برای شبکه‌های هوش مصنوعی هم‌ارزش کردن داده‌های ورودی می‌باشد، بنابراین از قابلیت نرمال‌سازی داده‌ها در نرم‌افزار بالا استفاده شد (زارع‌ایبانه و همکاران، ۲۰۰۹).

پس از مدل‌سازی تبخیر و تعرق از شبکه‌های هوشمند، تبخیر و تعرق گیاه سیر با محاسبه تبخیر و تعرق گیاه مرجع و در نظر گرفتن ضریب گیاهی توصیه شده برای سیر نیز برآورد گردید. نتایج این بخش از کار نیز مشابه نتایج مدل‌های هوشمند با مقادیر لایسیمتری مقایسه و ارزیابی شد.

معیارهای ارزیابی و عملکرد مدل‌ها: برای یافتن شبکه‌ای با ساختار مناسب برای هر یک از مدل‌های ANN، ANNGA و CANFIS مقایسه تبخیر و تعرق برآورد و اندازه‌گیری شده برای داده‌های مرحله آموزش و آزمون صورت گرفت. به این منظور علاوه بر مقایسه کیفی نتایج در قالب نمودارهای ترسیمی، از معیار جذر میانگین مربعات خطا (RMSE)^{۱۰} بر حسب میلی‌متر در روز با هدف کمینه شدن خطا و معیار ضریب همبستگی^{۱۱} (r) استفاده شد. معیارهای مورد نظر از رابطه‌های زیر به دست می‌آیند:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (ET_i(lys) - ET_i(cal))^2} \quad (1)$$

-
- 1- Sigmoid
 - 2- Tanhyporbolic
 - 3- Linear Sig
 - 4- Linear Tanh
 - 5- Momentum
 - 6- Conjugate Gradient
 - 7- Sugeno
 - 8- Gaussian
 - 9- NeuroSolution Ver. 5
 - 10- Root Mean Square Error
 - 11- Correlation Coefficient

$$r = \frac{\sum_{i=1}^n (ET_i(lys) - \overline{ET}(lys))(ET_i(cal) - \overline{ET}(cal))}{\sqrt{\sum_{i=1}^n (ET_i(lys) - \overline{ET}(lys))^2 (ET_i(cal) - \overline{ET}(cal))^2}} \quad (2)$$

در رابطه‌های بالا، n : تعداد داده‌ها، $ET_i(Lys)$: مقدار تبخیر و تعرق واقعی (لایسمتر)، $\overline{ET}(lys)$: میانگین تبخیر و تعرق لایسمتر، $\overline{ET}(cal)$: میانگین تبخیر و تعرق هر یک از مدل‌ها و $ET_i(cal)$: تبخیر و تعرق به دست آمده از هر یک از مدل‌ها می‌باشد.

علاوه بر معیارهای بالا، با ترسیم نتایج در نمودار رگرسیونی مطابق مدل خطی $(ET_{(model)} = a + b ET_{(Lys)})$ نیز مناسب بودن عملکرد مدل‌ها ارزیابی گردید. نزدیک بودن ضریب a (عرض از مبدا) به صفر و ضریب b (شیب خط) به یک، نشان‌دهنده مطلوبیت مدل است (زارع‌ایبانه و همکاران، ۲۰۱۰).

نتایج و بحث

اندازه‌گیری‌های لایسمتری نشان داد میزان نیاز آبی سیر در سال اول ۵۴۶/۵ میلی‌متر و در سال دوم ۵۱۹/۲ میلی‌متر بود. به این ترتیب تبخیر و تعرق گیاه سیر در سال دوم ۵/۳ درصد کمتر از سال اول بود. این کاهش با توجه به کاهش دما (۶ درصد) و افزایش بارندگی (۸۴ درصد) در سال دوم نسبت به سال اول منطقی به نظر می‌رسد.

از آنجایی که توانمندی پیش‌بینی مدل‌های هوشمند در انتخاب صحیح نوع اطلاعات ورودی در لایه اول بستگی دارد، بنابراین با ارایه مدل رگرسیونی ارتباط بین پارامترهای هواشناسی (متغیر مستقل) و تبخیر و تعرق گیاه سیر (متغیر وابسته) مشخص شد. معادله کلی اثرات مشترک متغیرهای مستقل عبارت است از:

$$ET_C = 0.46T_{max} + 0.25T_{min} + 0.05RH_{max} + 0.08RH_{min} + 0.29n - 0.6U_p - 0.21 \quad R^2 = 0.41 \quad (3)$$

در این رابطه: ET_C : تبخیر و تعرق گیاه سیر (میلی‌متر بر روز)، T_{max} و T_{min} : دمای حداقل و حداکثر هوا (درجه سلسیوس)، RH_{max} و RH_{min} : رطوبت نسبی حداقل و حداکثر هوا (درصد)، U_2 : سرعت باد ارتفاع دو متری (متر بر ثانیه) و n ساعات آفتابی (ساعت) است.

همان‌گونه که در معادله ۳ مشاهده می‌شود، دمای حداکثر به‌میزان ۴۶ درصد و رطوبت نسبی حداکثر به‌میزان ۵ درصد بیش‌ترین و کم‌ترین تأثیر را در تبخیر و تعرق گیاه سیر دارند. باید توجه داشت که بیش‌تر روابط توسعه‌یافته در برآورد فرآیند تبخیر و تعرق مشابه فرایند تبخیر بر پایه قانون دالتون^۱ بنا نهاده شده‌اند که دما یکی از عوامل اصلی آن می‌باشد (تزیموپولوس و همکاران، ۲۰۰۸).

برای مقایسه عددی، خطای پیش‌بینی هر یک از ساختارهای ANN، ANNGA و CANFIS به تفکیک داده‌های مرحله آموزش و آزمایش در جدول ۱ ارایه شده است. طبق جدول ۱ در تمامی الگوریتم‌های شبکه عصبی، تعداد نرون، تعداد لایه‌ها و در سیستم استنتاج عصبی فازی تعداد تابع عضویت یکسان در نظر گرفته شد تا نتایج در شرایط مشابه قابل مقایسه باشند.

میزان خطای پیش‌بینی برای ۴۱ الگو (۲۰ درصد الگوهای آزمایش) و ۱۶۵ الگو (۸۰ درصد الگوهای آموزش) به تفکیک هر سه شبکه به کمک رابطه ۲ محاسبه شد (جدول ۱). میانگین خطای RMSE در حالت کلی برای تمامی الگوریتم‌های ANNGA در مرحله آزمون معادل ۰/۱۹ میلی‌متر در روز و برای همه الگوریتم‌های CANFIS برابر ۰/۲۸ میلی‌متر در روز به‌دست آمد. از این منظر الگوریتم ژنتیک در ترکیب با شبکه عصبی توانسته است خطای آزمون شبکه را نسبت به عصبی-فازی به‌میزان ۳۲/۱ درصد در مرحله آموزش و آزمون کاهش دهد که رقم قابل توجهی می‌باشد. به همین ترتیب نتایج نشان می‌دهند که میانگین خطای الگوریتم ANNGA به اندازه ۱۴ درصد و ۲۴ درصد نسبت به الگوریتم ANN، بهبود یافته است. با ملاحظه مقادیر ضریب همبستگی الگوریتم ANNGA نسبت به ANN در جدول ۱ هم مشخص می‌شود که وضعیت معیار بالا بهبود یافته است. این امر نشان‌دهنده برآوردهای بهتر عصبی ژنتیک نسبت به الگوریتم عصبی می‌باشد. به نظر محمدی (۲۰۰۶) توانمندی الگوریتم عصبی-ژنتیک در بی‌نیازی به مشتقات تابع جواب به‌واسطه ارتباط مستقیم با تابع اصلی و استفاده از قواعد آماری به‌جای قواعد صریح است. گلدبرگ (۱۹۸۹) آموزش‌پذیری مناسب الگوریتم عصبی-ژنتیک را با توجه به گستردگی فضای جستجو، انتخاب جمعیت اولیه و تعداد نسل‌های مناسب نسبت به الگوریتم عصبی-فازی در افزایش دقت مؤثر می‌داند. در تأیید مطلب بالا می‌توان به افزایش ۲۹ درصدی ضریب همبستگی الگوریتم ANNGA نسبت به الگوریتم CANFIS در مرحله آموزش اشاره کرد (جدول ۱). هر چند الگوریتم عصبی-فازی سعی داشته تا در مرحله

آزمون با افزایش ۳۴ درصدی ضریب همبستگی نسبت به مرحله آموزش کاستی‌ها را جبران نماید، اما این افزایش منجر به افزایش دقت RMSE نشده است. در این راستا کیم و کیم (۲۰۰۸)، شهابیان و احمدی (۲۰۰۷) و قیصری و قنادپور (۲۰۰۹) الگوریتم ANNGA را به ترتیب در برآورد تبخیر و تعرق گیاه مرجع (ET_0)، بهینه‌سازی وزن سازه‌ها و مسیریابی لوکوموتیوها موفق دانستند. از نکات قابل توجه جدول ۱، نبود افزایش دقت پیش‌بینی روش CANFIS نسبت به شبکه عصبی مصنوعی است. مقایسه میانگین خطای روش ANN در هر دو مرحله آموزش و آزمایش با روش CANFIS بیانگر مطلب بالا است. به عبارت دیگر ترکیب منطق فازی نه تنها سبب بهبود نتایج نشد، بلکه دقت پیش‌بینی (RMSE) الگوریتم CANFIS به میزان ۲۷ درصد در مرحله آموزش و ۱۲ درصد در مرحله آزمایش نسبت به ANN کاهش یافت. نبود افزایش دقت در پیش‌بینی تبخیر از چاه‌نیمه‌های منطقه سیستان و بلوچستان به روش ANFIS نسبت به روش ANN توسط مقدم‌نیا و همکاران (۲۰۰۹) و برآورد تبخیر و تعرق گیاه مرجع توسط زارعیانیه و همکاران (۲۰۱۰) گزارش شده است.







در شکل ۱ نمودارهای تبخیر و تعرق پیش‌بینی شده گیاه سیر از سه مدل بهینه ANNGA، ANN و CANFIS طبق جدول ۱ (الگوهای شماره ۶ و ۸)، در مقایسه با تبخیر و تعرق اندازه‌گیری شده از لایسیمتر در دو سال ۱۳۸۷ و ۱۳۸۸ برای داده‌های مرحله آزمون نشان داده شده است. از آنجایی که داده‌های بالا در آموزش مدل‌ها مشارکت نداشته و انتخاب آن‌ها به صورت تصادفی از بین کل داده‌ها صورت گرفته، بنابراین نتایج آماری به دست آمده از آن به دلیل انتخاب تصادفی داده‌ها، تشابه متغیرهای مستقل و یکسانی داده‌های آموزش و آزمون در هر دو مدل می‌تواند قابل اعتماد باشد.

با در نظر گرفتن میزان انحراف از خط نیم‌ساز نتایج، مشاهده می‌شود که بین برآوردهای مدل عصبی-ژنتیک و عصبی تفاوت چندانی وجود ندارد، اما مقدار ضریب تعیین بیانگر برتری مدل عصبی-ژنتیک می‌باشد. همچنین مقایسه مقدار شیب و عرض از مبدا خط رگرسیون به دست آمده از مدل عصبی-فازی، گویای تفاوت قابل ملاحظه مدل عصبی-فازی با دو مدل دیگر است. تفاوت رفتاری مدل بالا در شکل ۱، با توجه به آماره‌های خطا طبق جدول ۱ منطقی به نظر می‌رسد.

جدول ۱- نتایج اجرای ساختارهای بهینه مدل‌های هوشمند در تخمین تبخیر و تعرق گیاه سیر.

آزمایش		آموزش		تعداد نرون عصبی (تابع عضویت فازی)	تابع محرک	قانون آموزش	روش	ردیف
r	RMSE (mmd ⁻¹)	r	RMSE (mmd ⁻¹)					
۰/۸۹	۰/۲۳	۰/۸۹	۰/۲۱	۶-۶-۱*			ANN+GA	
۰/۸۸	۰/۳۲	۰/۷۲	۰/۳۳	(۲و۲و۲و۲و۲و۲)**	تانزان	گشتاور	CANFIS	۱
۰/۸۹	۰/۲۴	۰/۸۴	۰/۲۵	۶-۶-۱			ANN	
۰/۸۴	۰/۱۸	۰/۶۱	۰/۱۸	۶-۶-۱			ANN+GA	
۰/۷۹	۰/۲۴	۰/۵۶	۰/۲۲	(۲و۲و۲و۲و۲و۲)	سیگموئید	گشتاور	CANFIS	۲
۰/۷۸	۰/۲۰	۰/۵۸	۰/۱۹	۶-۶-۱			ANN	
۰/۸۷	۰/۲۴	۰/۹۰	۰/۲۰	۶-۶-۱			ANN+GA	
۰/۸۷	۰/۳۲	۰/۷۱	۰/۳۳	(۲و۲و۲و۲و۲و۲)	تانزان خطی	گشتاور	CANFIS	۳
۰/۹۰	۰/۲۲	۰/۸۲	۰/۲۶	۶-۶-۱			ANN	
۰/۸۸	۰/۱۴	۰/۷۵	۰/۱۵	۶-۶-۱			ANN+GA	
۰/۷۹	۰/۲۱	۰/۵۷	۰/۲۰	(۲و۲و۲و۲و۲و۲)	سیگموئید خطی	گشتاور	CANFIS	۴
۰/۸۶	۰/۱۶	۰/۶۹	۰/۱۷	۶-۶-۱			ANN	
۰/۸۹	۰/۲۳	۰/۸۹	۰/۲۱	۶-۶-۱			ANN+GA	
۰/۸۳	۰/۳۶	۰/۶۱	۰/۳۷	(۲و۲و۲و۲و۲و۲)	تانزان	گردایان	CANFIS	۵
۰/۵۵	۰/۵۶	۰/۸۱	۰/۲۷	۶-۶-۱		مزدوج	ANN	
۰/۸۸	۰/۱۲	۰/۸۰	۰/۱۴	۶-۶-۱			ANN+GA	
۰/۷۹	۰/۲۱	۰/۵۸	۰/۱۹	(۲و۲و۲و۲و۲و۲)	سیگموئید	گردایان	CANFIS	۶
۰/۸۷	۰/۱۳	۰/۷۹	۰/۱۴	۶-۶-۱		مزدوج	ANN	
۰/۸۹	۰/۲۳	۰/۷۹	۰/۲۸	۶-۶-۱			ANN+GA	
۰/۸۵	۰/۳۹	۰/۶۳	۰/۳۷	(۲و۲و۲و۲و۲و۲)	تانزان خطی	گردایان	CANFIS	۷
۰/۸۸	۰/۲۵	۰/۷۹	۰/۲۸	۶-۶-۱		مزدوج	ANN	
۰/۸۷	۰/۱۳	۰/۷۸	۰/۱۴	۶-۶-۱			ANN+GA	
۰/۸۶	۰/۱۸	۰/۶۰	۰/۱۹	(۲و۲و۲و۲و۲و۲)	سیگموئید خطی	گردایان	CANFIS	۸
۰/۶۶	۰/۲۱	۰/۴۵	۰/۲۱	۶-۶-۱		مزدوج	ANN	
۰/۸۸	۰/۱۹	۰/۸۰	۰/۱۹	۶-۶-۱	--	ANN+GA	میانگین	
۰/۸۳	۰/۲۸	۰/۶۲	۰/۲۸	(۲و۲و۲و۲و۲و۲)	--	CANFIS	میانگین	
۰/۸۰	۰/۲۵	۰/۷۲	۰/۲۲	۶-۶-۱	--	ANN	میانگین	

* تعداد نرون در ساختار شبکه عصبی مصنوعی، ** تعداد تابع عضویت فازی برای هر ورودی در سیستم استنتاج عصبی فازی.




شکل ۱- مقدار تبخیر و تعرق سیر مشاهده شده (لایسمتری) و تخمینی به دست آمده از الگوهای بهینه ANNGA و CANFIS.

شکل ۱ نشان می‌دهد که مدل ANNGA برای نواحی خاصی از داده‌های آزمون که دارای تغییرات ساختاری در فرآیند تبخیر و تعرق هستند مناسب‌تر عمل نموده است. هر چند در برخی نواحی نتوانسته مدل موفق باشد. ولی در مجموع به دنبال به دست آوردن کم‌ترین خطای پیش‌بینی است. مقایسه ضرایب مدل‌های خطی به دست آمده از شکل ۱ نشان می‌دهد مدل عصبی-ژنتیک ضمن بالاتر بودن ضریب تعیین ($R^2=0.77$) و شیب مدل برازش داده شده به داده‌ها (۰/۵۹)، مقدار عرض از مبدا کم‌تری (۰/۱۸) نسبت به مدل عصبی-فازی داشته است. به عبارت دیگر بیش‌تر بودن شیب و کم‌تر

بودن عرض از مبدا نشان‌دهنده مطلوب بودن یک مدل است (زارعیبانه و همکاران، ۲۰۱۰). در مطالعه حاضر مدل ANNGA از این نظر نسبت به مدل CANFIS مناسب‌تر عمل نموده و توانایی پیش‌بینی را دارد.

تبخیر و تعرق گیاه مرجع چمن از روش استاندارد پنمن مانیتث فائو ۵۶ به‌صورت روزانه طی دو سال ۱۳۸۷ و ۱۳۸۸ محاسبه گردید. میانگین تبخیر و تعرق گیاه مرجع چمن ۵/۰۶ میلی‌متر در روز مشتمل بر ۰/۰۷ میلی‌متر در روز حداقل و ۱۲/۶ میلی‌متر حداکثر برآورد شد. همچنین ضریب گیاهی سیر به روش فائو برای منطقه مورد مطالعه کالیبره گردید که با اعمال آن در تبخیر و تعرق گیاه مرجع، تبخیر و تعرق گیاه سیر به‌دست آمد. نتایج نشان داد که میانگین تبخیر و تعرق گیاه سیر ۵/۳۲ میلی‌متر در روز شامل ۰/۰۷ میلی‌متر در روز حداقل و ۱۴/۰۴ میلی‌متر در روز حداکثر به‌دست آمد. مقایسه مقادیر به‌دست آمده نسبت به مقادیر اندازه‌گیری شده لایسیمتری نشان داد مقدار ضریب همبستگی و میانگین مجذور مربعات خطا به‌ترتیب برابر ۰/۴۴ و ۰/۲۴۵ میلی‌متر در روز می‌باشد که در مقایسه با نتایج بهینه مدل‌های هوشمند اختلاف قابل توجه است (جدول ۱). مقدار تبخیر و تعرق سیر به‌دست آمده از اعمال ضریب گیاهی و تبخیر و تعرق گیاه مرجع در مقایسه با مقادیر لایسیمتری در شکل ۲ آورده شده است.



شکل ۲- مقدار تبخیر و تعرق سیر به‌دست آمده از اعمال ضریب گیاهی در تبخیر و تعرق مرجع و تبخیر و تعرق لایسیمتری سیر.

با مشاهده شکل ۲ این‌گونه استنباط می‌شود که نتایج به‌دست آمده از برآورد تبخیر و تعرق گیاه سیر که از اعمال ضریب گیاهی در تبخیر و تعرق گیاه مرجع (ETC) به‌دست آمده است، تفاوت قابل‌ملاحظه‌ای با نتایج به‌دست آمده از مدل‌های هوشمند دارد که گویای برتری مطلق روش مدل‌سازی تبخیر و تعرق گیاه سیر می‌باشد.

نتیجه‌گیری

پیش‌بینی سری‌های زمانی فرآیندهای هیدرولوژیکی مانند تبخیر و تعرق گیاهان زارعی با دقت بالا، کاربرد زیادی در حوزه‌های گوناگون دارد. از این‌رو روش مدل‌سازی چندگانه (فراابتکاری ترکیبی) در شرایطی که فضای بزرگی از تغییرات ساختاری فرآیند پوشش داده شود، تکنیک مناسبی برای پیش‌بینی فرآیند تبخیر و تعرق است. در این راستا نتایج پژوهش حاضر نشان داد که ترکیب الگوریتم ژنتیک در شبکه عصبی مصنوعی منجر به جواب‌های مطلوب‌تری شد.

به‌طوری‌که خطای آزمون شبکه عصبی را ۲۴ درصد کاهش داد که بیانگر عملکرد مناسب الگوریتم ژنتیک در ترکیب با شبکه عصبی مصنوعی برای برآورد تبخیر و تعرق پتانسیل گیاه سیر بود. به‌عبارت دیگر استفاده از پیش‌بینی دو یا چند مدل و ترکیب نهایی پیش‌بینی مدل‌ها در روش مدل‌سازی چندگانه باعث افزایش کیفیت پیش‌بینی شده است. در این مقاله هم‌زمان با برآورد تبخیر و تعرق گیاه سیر از شبکه عصبی مصنوعی، به بهینه‌سازی و فازی‌سازی پارامترهای آن توسط دو مدل فراابتکاری الگوریتم ژنتیک و الگوریتم فازی پرداخته شده است. مقایسه روش عصبی- فازی با شبکه عصبی نشان داد ترکیب منطق فازی منجر به افزایش ۱۲ درصدی خطای آزمون شبکه عصبی مصنوعی شد که بیانگر عدم وجود افزایش دقت شبکه عصبی مصنوعی به‌واسطه ترکیب منطق فازی است. در بررسی مقایسه‌ای هر دو الگوریتم عصبی- ژنتیک و عصبی- فازی مشاهده شد که الگوریتم عصبی- ژنتیک جواب‌های مناسب‌تری در بین تمامی الگوریتم‌های پیشنهادی داشته است. به‌گونه‌ای روش عصبی- ژنتیک نسبت به روش عصبی- فازی خطای آزمون را ۳۲ درصد کاهش داد. در مجموع ارتباط خوبی بین شبکه عصبی و الگوریتم ژنتیک برقرار شد و الگوریتم ژنتیک نسبت به الگوریتم فازی در بهینه‌سازی رفتار آموزشی شبکه عصبی مصنوعی برای پیش‌بینی، موفق‌تر بوده است.

منابع

1. Adepoju, G.A., Ogunjuyigbe, S.O.A., and Alawode, K.O. 2007. Application of Neural Network to Load Forecasting in Nigerian Electrical Power System, *Pacific J. Sci. and Technol.* 8: 1. 68-72.
2. Aytek, A. 2008. Co-active neurofuzzy inference system for evapotranspiration modeling. *Soft Computing-A Fusion of Foundations, Methodologies and Applications*, 13: 7. 691-700.
3. Aytek, A., and Kisi, O. 2008. A genetic programming approach to suspended sediment modeling. *J. Hydro.* 351: 288-298.
4. Cobaner, M., Unal, B., and Kisi, O. 2009. Suspended sediment concentration estimation by an adaptive neuro-fuzzy and neural network approaches using hydro-meteorological data. *J. Hydro.* 367: 52-61.
5. Goldberg D.E. 1989. Genetic algorithm in search, optimization and machine learning. Addison-Wesley, Reading, MA, 412p.
6. Ghoseiri, K., and Ghannadpour, S.F. 2009. Locomotive Routing Problem Using a Hybrid Genetic Algorithm. *J. Transportation*, 5: 3. 259-273. (In Persian)
7. Grismer, M.E., Orang, M., Snyder, R., and Matyac, R. 2002. Pan Evaporation to reference evapotranspiration conversion methods. *ASCE J. Irrig. and Drain. Eng.* 128: 30. 180-184.
8. Keskin, M.E., Terzi, Ö., and Taylan, D. 2009. Estimating daily pan evaporation using adaptive neural-based fuzzy inference system. *Theor. Appl. Climatol.* 98: 1-2. 79-87.
9. Kim, S., and Kim, H. 2008. Neural Networks and genetic algorithm approach for nonlinear evaporation and evapotranspiration modeling. *J. Hydro.* 351: 299-317.
10. Kisi O. 2007. Evapotranspiration modeling from climatic data using a neural computing technique. *Hydro. Process*, 21: 6. 1925-1934.
11. Kisi, O., and Ozturk, O. 2007. Adaptive neurofuzzy computing technique for evapotranspiration estimation. *J. Irrig. Drain. Eng. ASCE.* 133: 4. 368-379.
12. Kumar, M., Bandyopadhyay, A., Raghuvanshi, N.S., and Singh, R. 2008. Comparative study of conventional and artificial neural network-based ET₀ estimation models. *Irrig. Sci.* 26: 6. 531-545.
13. Laurentiu, A., Bernard, P.A., and Faical, L. 2002. Integrated Genetic Algorithm-Artificial Neural Network Strategy for Modeling Important Multiphase-Flow Characteristics. *Ind. Eng. Chem. Res.* 41: 2543-2551.
14. Lin, C., Chao, C., and Chen, W.F. 2008. Estimation regional evapotranspiration by adaptive network-based fuzzy inference system for Dan-Shui basin in Taiwan. *J. Chinese Inst. Eng.* 30: 6. 1091-1096.
15. Mohamadi, M.S. 2006. Learning without supervision of RBF neural network by using genetic algorithm. P 1-6, In: Ninth Conference on IRAN Electrical Engineering student. (In Persian)

16. 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.
17. Nasseh, S., Mohebbi, A., Sarrafi, A., and Taheri, M. 2009. Estimation of pressure drop in venturi scrubbers based on annular two-phase flow model, artificial neural networks and genetic algorithm. *J. Chemical Engineering*, 150: 1. 131-138.
18. Odhiambo, L.O., Yoder, R.E., Yoder, D.C., and Hines, J.W. 2001. Optimization of fuzzy evaporation model through neural training with input-output examples. *Trans. ASAE*, 44: 6. 1625-1633.
19. Parthiban, L., and Subramanian, R. 2009. CANFIS-a computer aided diagnostic tool for cancer detection. *J. Biomedical Science and Engineering*, 2: 323-335.
20. Parvaresh Rizi, A., Koochak Zadeh, S., and Omid, M. 2006. Estimating moving hydraulic jump parameters by means of ANN and the integration of ANN and GA. *Agricultural Sciences*, 37: 1. 187-196. (In Persian)
21. Rahimy Koob, A. 2008. Comparative study of Hargrives's and artificial neural network's methodologies in estimating reference evapotranspiration in a semiarid environment. *Irrig. Sci.* 26: 3. 253-259.
22. Shahabian, F., and Ahmadi, S.M. 2007. Optimization of structures with two layers of flat space to work, to help the genetic algorithm and neural network. Eighth Intelligent Systems Conference. Ferdowsi University of Mashhad, Pp: 1-6. (In Persian)
23. Shayannejad, M., Sadatinejad, S.J., and Fahmi, H. 2008. Determination of potential evapotranspiration using the fuzzy regression method. *Iran-Water Resour. Res.* 3: 3. 9-19. (In Persian)
24. Sudheer, K.P., Gosain, A.K., Ranagan, D.M., and Saheb, S.M. 2002. Modeling evaporation using an artificial neural network algorithm. *Hydro. Process*, 16: 3189-3202.
25. Sudheer, K.P., Gosain, A.K., and Ramasastri, K.S. 2003. Estimating actual evapotranspiration from limited climatic data using neural computing technique. *J. Irrig. Drain. Eng. ASCE*, 129: 3. 214-218.
26. Tzimopoulos, C., Mpallas, L., and Papaevangelou, G. 2008. Estimation of evapotranspiration using fuzzy systems and comparison with the blaney-criddle method. *Environ. Sci. and Technol.* 1: 4. 181-186.
27. Wang, Y.M., Traore, S., and Kerh, T. 2009. Computational performance of reference evapotranspiration in semiarid zone of Africa. *Sci. Research and Essay*. 4: 6. 577-583.
28. Zade, L.A. 1965. Fuzzy sets. *Information contro.* 8: 3. 338-353.

29. Zare Abyaneh, H., Ghasemi, A., Bayat Varkeshi, M., Sabziparvar, A.A., and Mohamadi, K. 2009. The Evaluation of two Artificial Neural Network software in predict of crop Reference Evapotranspiration. *J. Water and Soil Science*, 1: 2. 151-163. (In Persian)
30. Zare Abyaneh, H., Bayat Varkeshi, M., Marofi, S., and Amiri Chayjan, R. 2010. Evaluation of artificial neural network and adaptive neuro fuzzy inference system in decreasing of reference evapotranspiration parameters. *Water and Soil (Agr. Sci. and Thechnology)*. 24: 2. 297-305. (In Persian)
31. Zare Abyaneh, H., Ghasemi, A., Bayat varkeshi, M., and Marofi, S. 2009a. Assessment of Artificial Neural Network (ANN) in prediction of garlic evapotranspiration (ETC) with lysimeter in Hamedan. *J. Water and Soil*. 23: 3. 176-185. (In Persian)



Gorgan University of Agricultural
Sciences and Natural Resources

J. of Water and Soil Conservation, Vol. 18(2), 2011
www.gau.ac.ir/journals

Forecasting of garlic (*Allium sativum* L.) evapotranspiration by using multiple modeling

***H. Zare Abyaneh¹, M. Bayat Varkeshi² and S. Marofi³**

¹Assistant Prof., Dept. of Water Engineering, Bu-Ali Sina University, Hamedan,

²Former M.Sc. Student, Dept. of Water Engineering, Bu-Ali Sina University, Hamedan,

³Associate Prof., Dept. of Water Engineering, Bu-Ali Sina University, Hamedan

Received: 2010/01/09; Accepted: 2010/06/12

Abstract

Estimation and evaluation of crop water requirement is important key in scheduling, management and using from agricultural water resources. Many methods for estimation of phenomena are available that in this regard multiple modeling methods are prevalent. In this study Adaptive Neural Network based Genetic Algorithm and Co-Active Neuro-Fuzzy Inference System in side Artificial Neural Network for estimation of garlic evapotranspiration were used. For modeling from meteorological data including minimum and maximum temperature, minimum and maximum relative humidity, wind speed and sunshine hours and lysimeter data in climatology Station of Bu-Ali Sina University Agriculture Faculty during 2008-2009 for modeling were used. The garlic lysimeter Evapotranspiration maximum and average were 11.22 and 4.79 mmd^{-1} respectively. Results showed that Adaptive Neural Network based Genetic Algorithm were more accurate than Co-Active Neuro-Fuzzy Inference System. In other words, optimization of Artificial Neural Network more successful operation of fuzzy logic can be. Also, Artificial Neural Network was more appropriate to Co-Active Neuro-Fuzzy Inference System. So that Adaptive Neural Network based Genetic Algorithm than Co-Active Neuro-Fuzzy Inference System reduced 24 percent the testing error. But Co-Active Neuro-Fuzzy Inference System not only improves the results of artificial neural network was not, but reduced 12 percent the prediction accuracy. For the best architecture of Adaptive Neural Network based Genetic Algorithm, statistical parameters were $\text{RMSE} = 0.12 \text{ mmd}^{-1}$ and $r = 0.88$. Coefficient of determination criteria, the width of the origin and the slope of line fitted to data estimated the Adaptive Neural Network based Genetic Algorithm model period (two years) compared with the Co-Active Neuro-Fuzzy Inference System model also showed, this model is efficiency.

Keywords: Evapotranspiration, Adaptive neural network based genetic algorithm, Co-active neuro-fuzzy inference system, Garlic, Hamedan

* Corresponding Author; Email: zareabyaneh@gmail.com