

ارزیابی کارایی دو نرم افزار شبکه عصبی مصنوعی در پیش بینی تبخیر - تعرق گیاه مرجع

حمید زارع ایبانه^{۱*}، عادل قاسمی^۲، مریم بیات ورکشی^۲، کوروش محمدی^۳ و علی اکبر سبزی پرور^۳

تاریخ دریافت: ۸۷/۱/۱۶

تاریخ پذیرش: ۸۸/۶/۱۴

۱، ۲ و ۳- به ترتیب استادیار، دانشجویان کارشناسی ارشد و دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی سینا

۴- دانشیار گروه آبیاری، دانشکده کشاورزی، دانشگاه تربیت مدرس

* مسئول مکاتبه E-mail: zare_h2000@yahoo.com

چکیده

در این تحقیق، کارایی دو نرم افزار شبکه عصبی مصنوعی (ANN) در برآورد تبخیر-تعرق گیاه مرجع (ET_0) بررسی گردید. بدین منظور از داده های ۲ سال لایسیمتری به عنوان ارقام شاهد برای ارزیابی استفاده شده و دو نرم افزار مرسوم NS و NW با قابلیت به کارگیری الگوریتم های متفاوت، به کار رفت. جهت ارزیابی اجرای دو نرم افزار برای آرایش ها، قواعد یادگیری و توابع محرک مختلف، از شاخص های آماری جذر میانگین مربعات خطا (RMSE)، میانگین خطای مطلق (MAE) و ضریب تعیین (R^2) استفاده شد. با اجرای نرم افزار NS آرایش مطلوب با ویژگی حداقل RMSE، MAE و حداکثر R^2 در مقایسه با ارقام مشاهداتی (لایسیمتری) به ترتیب معادل ۰/۰۸ (میلی متر در روز)، ۰/۰۷ (میلی متر در روز) و ۰/۸۷ بدست آمد. نتایج تحقیق نشان داد نرم افزار NS با آرایش مطلوب که ویژگی مدل آموزشی گرادیان مزدوج و تابع محرک سیگموئید را دارا باشد، نسبت به نرم افزار NW با توجه به تعداد تکرار کمتر و زمان محاسباتی کوتاه تر برتری دارد. نتایج نشان داد وجود دو لایه پنهان نسبت به یک لایه پنهان بر دقت تبخیر-تعرق برآورد شده از نرم افزار، تاثیری نداشت. بررسی حساسیت مدل شبکه عصبی مصنوعی نشان داد که تبخیر-تعرق بیشترین وابستگی را به حداکثر دمای هوا و کمترین وابستگی را به حداقل رطوبت نسبی دارد.

واژه های کلیدی: تبخیر-تعرق گیاه مرجع، دمای هوا، رطوبت نسبی، شبکه عصبی مصنوعی

Evaluation of Two Artificial Neural Network Software in Predict of Crop Reference Evapotranspiration

H Zare Abyaneh^{1*}, A Gasemi², M Bayat Varkeshi², K Mohammadi⁴ and AA Sabziparvar³

^{1,2,3}Assistant Professor, MSc Students and Associate Professor, Department of Water Engineering, Faculty of Agriculture Bu-Ali Sina University, Hamedan, Iran

⁴Associate Professor, Department of Irrigation, Faculty of Agriculture Tarbiat Modares University, Tehran, Iran

*Corresponding author: E-mail: zare_h2000@yahoo.com

Abstract

In this study, the performance of two different artificial neural network software's named neuro solution (NS) and neural works professional II (NW) in estimation of crop reference evapotranspiration (ET_0) were evaluated. For models evaluation, some statistical parameters such as root mean square error (RMSE), mean absolute error (MAE) and coefficient of determination (R^2) were calculated for different arrays, learning rules and transfer functions. For the NS software the best fitted array characterizing with lowest values of RMSE, MAE and highest R^2 were found to be 0.08, 0.07 (mm day^{-1}) and 0.87, respectively. Results showed that the NS software with the best fitted network array of: learning rule of conjugate gradient and transfer function of sigmoid type, which required shorter computational time and less iteration loops, can perform better prediction. The results indicated that using two hidden layers did not improve the accuracy of ET_0 predictions, in comparison with the results obtained by one hidden layer layout. The sensitivity analysis of neural network model revealed that ET_0 is very sensitive to maximum air temperature (T_{\max}). In contrast, the estimated daily ET_0 showed the lowest sensitivity to minimum relative humidity (RH_{\min}).

Keywords: Air temperature, Artificial, Neural Networks, Reference Evapotranspiration, Relative humidity

در اندرکنش با یکدیگرند و به همین دلیل اندازه‌گیری دقیق تمام پارامترها میسر نیست. با توجه به عدم امکان اندازه‌گیری دقیق تمام پارامترها، بکارگیری مدل‌های تجربی و یا شبکه‌های عصبی مصنوعی با ساختاری مشابه مغز قابل توجه و مقرون به صرفه می‌باشد. در ساختار شبکه عصبی مصنوعی با معرفی عملکرد یک سیستم دینامیکی و آموزش آن، عملکرد سیستم در

مقدمه

فرآیند تبخیر-تعرق از اساسی‌ترین اجزای چرخه هیدرولوژی می‌باشد. تخمین دقیق مقدار تبخیر-تعرق برای انجام بسیاری از تحقیقات ضروری و از مهمترین مسائل در طرح‌های آبیاری و زهکشی و منابع آب به شمار می‌رود. در فرآیند تبخیر-تعرق عوامل مختلف طبیعی (خاک، گیاه و اتمسفر) و انسانی وجود دارند که

عصبی مصنوعی با مدل‌های پهن و هارگریوز نشان داد که شبکه عصبی مصنوعی با دقت بالاتری قادر است تا تبخیر - تعرق را به کمک داده‌های هواشناسی پیش‌بینی نماید. زانتی و همکاران (۲۰۰۷) از شبکه عصبی با حداقل داده‌های هواشناسی برای تخمین تبخیر - تعرق در شهر ریودو ژانیروی برزیل استفاده کردند. آنان از سری زمانی داده‌های هواشناسی سپتامبر ۱۹۹۶ تا آگوست ۲۰۰۲ برای آموزش شبکه استفاده نمودند. نتایج بدست آمده نشان داد که شبکه عصبی مصنوعی با دمای حداکثر و حداقل هوا به عنوان ورودی، قابلیت پیش‌بینی تبخیر - تعرق را دارد. آرکا (۱۹۹۸) از شبکه عصبی مصنوعی جهت پیش‌بینی تبخیر از تشت کلاس A و تکمیل داده‌های مفقوده تبخیر سنوات گذشته، بهره جست. شایان‌نژاد (۱۳۸۵) برآوردهای حاصل از روش پنمن‌مانتیت فائو و شبکه عصبی مصنوعی از نرم‌افزار MATLAB را با نتایج لایسیمتری مقایسه کرد. وی روش شبکه عصبی مصنوعی را دقیق‌تر و مزیت آن را نیاز اطلاعاتی کمتر نسبت به روش پنمن‌مانتیت دانست. پلنگی و همکاران (۱۳۸۵) نیز به طریق مشابه با مطالعه تبخیر - تعرق گیاه مرجع در منطقه اهواز نتیجه گرفتند پیش‌بینی‌های شبکه عصبی مصنوعی با استفاده از نرم - افزار Qnet 2000 در مقایسه با روش پنمن‌مانتیت فائو دارای خطای کمتری است. قاسمی و همکاران (۱۳۸۶) نرم‌افزار^۳ NW را ابزاری مناسب، دارای سرعت و دقت کافی در تعیین تبخیر - تعرق گیاه مرجع برای منطقه همدان معرفی نمودند. حق‌وردی و همکاران (۱۳۸۶) برآوردهای نرم‌افزار^۴ NS، برای پارامترهای تبخیر - و تبخیر از تشت را مناسب دانستند.

با توجه به رابطه مستقیم بین مقادیر تبخیر - تعرق گیاه مرجع، نیاز آبی گیاهان و ارزش اقتصادی آب مصرفی گیاهان بویژه در اقلیم‌های خشک و نیمه خشک و همچنین کمبود مطالعات در واسنجی نتایج شبکه‌های

مقایسه با شرایط واقعی سنجیده می‌شود. شبکه‌های عصبی مصنوعی می‌توانند با حداقل تعداد متغیرهای مستقل اندازه‌گیری شده، پیش‌بینی مناسبی از متغیرهای وابسته با دقت قابل قبول ارائه دهند. میثاقی و محمدی (۱۳۸۳) توانمندی شبکه‌های عصبی مصنوعی را در حل مسائل غیرخطی، موازی، حجیم و خطادار مناسب دانسته‌اند. زیرا داده‌های ورودی نادرست یا ناقص در توابع ریاضی باعث ایجاد خطای زیاد در نتایج خروجی می‌شود، در صورتی که در شبکه‌های عصبی مصنوعی تا حد زیادی این خطاها تأثیر خود را از دست می‌دهند (طهماسبی و زمردیان ۱۳۸۳).

کومار و همکاران (۲۰۰۲) استفاده از شبکه عصبی مصنوعی را برای پیش‌بینی تبخیر - تعرق گیاه مرجع برتر از روش پنمن‌مانتیت تشخیص دادند. بروتن و همکاران (۲۰۰۰) به کمک شبکه عصبی مصنوعی، تبخیر روزانه تشتک را در بازه زمانی ۱۹۹۲ تا ۱۹۹۶ برای برخی از شهرهای مهم جهان پیش‌بینی کردند. خطای شبکه عصبی مصنوعی در مقایسه با سایر روش‌ها در مطالعه فوق کمتر و حداکثر معادل ۰/۱۱ میلی‌متر در روز گزارش شد. تراجکویک و همکاران (۲۰۰۳) در پیش‌بینی تبخیر - تعرق گیاه مرجع با استفاده از شبکه عصبی مصنوعی از مقادیر تبخیر - تعرق ۱۱ و ۲۳ روز قبل استفاده کردند به طوری که نسبت مقادیر تبخیر - تعرق پیش‌بینی به اندازه‌گیری شده ۰/۹۹۴ بود که نشان‌دهنده کارایی خوب شبکه عصبی مصنوعی است. کانون و ویتفیلد (۲۰۰۲) با انجام مطالعاتی در خصوص پیش‌بینی رواناب مربوط به ریزش‌های جوی ۲۱ حوزه در کانادا، شبکه عصبی مصنوعی را دارای کارایی بالایی نسبت به مدل رگرسیون خطی دانستند. کیسی (۲۰۰۶) در پیش‌بینی تبخیر - تعرق مرجع روزانه، از شبکه عصبی مصنوعی با دو مدل آموزش لونیگ-مارکوات^۱ (LM) و گرادیان مزدوج^۲ (CG) استفاده کرد. مقایسه نتایج شبکه

^۳ NeuralWork^۴ NeuroSolution^۱ Levenberg Marquat^۲ Conjugate Gradient

هواشناسی مذکور و خروجی شبکه مقدار تبخیر-تعرق می‌باشد.

در این تحقیق از داده‌های دو ساله لایسیمتری چمن در مقیاس روزانه برای مقایسه با برآوردهای تبخیر تعرق توسط شبکه عصبی مصنوعی و انتخاب مناسب‌ترین آرایش پیشنهادی استفاده شد. داده‌ها از یک دستگاه لایسیمتر از جنس آهن گالوانیزه به ابعاد $1^*1^*2/25$ متر در یک کیلومتری شمال شرق ایستگاه هواشناسی واقع در یک منطقه همگن اقلیمی برداشت شدند. حجم آب داده شده و زه‌آب خروجی از لایسیمتر به صورت دستی (روزانه) با استوانه مدرج اندازه‌گیری شد. از داده‌های لایسیمتری میانگین تبخیر-تعرق ماهانه محاسبه گردید. جهت رعایت دقت در نتایج لایسیمتری، خاک داخل لایسیمتر با پروفیلی مشابه خاک طبیعی زمین اطراف پر و حدود ۱۵۰۰ مترمربع اطراف آن نیز با شرایط یکسان کشت و آبیاری شد. لایسیمتر از نوع زهکش‌دار با کف شیب‌دار و دیواره‌های اندود شده از قیر و گونی بود. برای بهبود زهکشی، ۲۰ سانتی‌متر شن‌ریزی (قلوه سنگ و شن) در کف لایسیمتر انجام شد. محل استقرار لایسیمتر برای جلوگیری از نشست، بتون-ریزی شد.

نرم‌افزارهای مورد استفاده

در انجام این بررسی پس از مطالعات مختلف، دو بسته‌ی نرم‌افزاری (NeuroSoluton (Ver.5) و NeuralWorks Professional II Plus (Ver.5.23) با قابلیت اجرا در محیط ویندوز مورد توجه قرار گرفتند (بی‌نام ۱۹۹۲ و بی‌نام ۱۹۹۴).
ناسیه و همکاران (۲۰۰۹) با بکارگیری نرم‌افزار NS در تخمین افت فشار در ونتوری، توانایی این نرم‌افزار را در بهینه‌سازی پارامترهای ورودی شبکه عصبی مصنوعی را خاص و ویژه دانستند. چان و اسپدینگ (۲۰۰۳) نرم‌افزار NW را به دلیل تولید کدهای اتوماتیک بر اساس پارامترهای ورودی و کاهش معنی‌دار زمان اجرا، در

عصبی با داده‌های لایسیمتری، مطالعه حاضر صورت گرفت. در این تحقیق ابتدا مقدار تبخیر-تعرق روزانه براساس داده‌های هواشناسی با دو نرم‌افزار شبکه عصبی مصنوعی برآورد و سپس با نتایج دو ساله لایسیمتری چمن مقایسه شد. در خاتمه، ضمن مقایسه تبخیر-تعرق تخمینی از شبکه عصبی مصنوعی با داده‌های واقعی لایسیمتری، خطای محاسباتی و سرعت دو نرم‌افزار مذکور تجزیه و تحلیل گردید.

مواد و روش‌ها

اطلاعات و داده‌های تحقیق

برآورد تبخیر-تعرق براساس شبکه عصبی مصنوعی، از اطلاعات هواشناسی ایستگاه سینوپتیک فرودگاه همدان (اکباتان) به عنوان متغیرهای کلیدی در لایه ورودی انجام شد. ایستگاه فوق در ارتفاع ۱۷۳۰ متری از سطح دریا با طول جغرافیایی $32^{\circ} E$ و 48° عرض جغرافیایی $52^{\circ} N$ قرار دارد. اقلیم منطقه مورد مطالعه براساس اقلیم‌نمای دومارتن سرد نیمه خشک است (تفضلی و همکاران، ۱۳۸۶). داده‌های هواشناسی شامل: دمای حداکثر و حداقل هوا، رطوبت نسبی حداکثر و حداقل هوا، سرعت باد و ساعات آفتابی به عنوان ورودی شبکه عصبی مصنوعی بودند. انتخاب ورودی‌های شبکه عصبی مصنوعی بر اساس پارامترهای ورودی مدل پنمن ماننیت فائو ۵۶ به عنوان کامل‌ترین مدل برآورد تبخیر-تعرق و توصیه‌های محققین مد نظر قرار گرفت (مجرد و همکاران ۱۳۸۳ و شایان‌نژاد ۱۳۸۵). ساعات آفتابی در بخش تشعشعی و سایر پارامترهای هواشناسی انتخابی برای شبکه عصبی مصنوعی در بخش آئرودینامیک رابطه پنمن ماننیت از موثرترین داده‌های اثرگذار بر مقدار تبخیر-تعرق می‌باشند. ضمن آن-که تقوی و محمدی (۱۳۸۶) اطلاعات مرتبط با دما و باد را بهترین اطلاعات نشان‌دهنده تغییرات و جهت تغییرات مکانی دانسته‌اند. پارامترهای ورودی شامل شش پارامتر

شبکه MLP به صورت سری از ورودی شبکه به سمت خروجی است. به طوری که خروجی هر لایه به عنوان ورودی لایه بعدی محسوب و مقادیر خطای محاسباتی به لایه‌های قبلی انتشار می‌یابد. در این پژوهش بنا به ماهیت مسئله مورد مطالعه که ایجاد نگاشت مابین متغیرهای اقلیمی و تبخیر - تعرق می‌باشد، از شبکه MLP با توابع آستانه‌ای مختلف برای بسط و واسنجی مدل شبکه عصبی مصنوعی استفاده شد. برای تعیین تعداد لایه‌های مخفی شبکه و تعداد نرون‌های هر لایه با فرض ۱ و ۲ لایه مخفی، تعداد نرون‌ها ۱، ۲، ۳، ... و ۱۵ نرون در نظر گرفته شد. در نهایت بعد از آموزش شبکه، با محاسبه و ثبت مقدار جذر میانگین مربعات خطا، میانگین خطای مطلق^۷، انحراف معیار^۸ و ضریب تعیین هر مرحله، شبکه مناسب انتخاب شد.

برای آموزش شبکه در NW، ابتدا مطابق معمول ۷۰ درصد داده‌های هواشناسی به طور تصادفی برای آموزش شبکه و ۳۰ درصد باقی‌مانده برای تست شبکه در نظر گرفته شد. در نرم‌افزار NS نیز ۷۰ درصد داده‌ها برای آموزش، ۲۰ درصد برای تشخیص و ۱۰ درصد هم به تست شبکه اختصاص یافت. برای تعیین مقدار بهینه تعداد تکرار محاسباتی شبکه^۹ از روش سعی و خطا استفاده و خطای پیش‌بینی آن با مقادیر مختلفی از تکرارهای محاسباتی برای شبکه بهینه، محاسبه گردید. روند تغییرات خطای شبکه بر حسب تعداد تکرار برای آموزش و تست در قالب نمودار چرخه تکرار محاسباتی نشان داده شد.

نتایج و بحث

از مقادیر روزانه‌ی پارامترهای هواشناسی ذکر شده در جدول ۱ طی سال‌های ۱۳۷۶ و ۱۳۷۷ به عنوان ورودی در لایه اول شبکه عصبی مصنوعی استفاده شد.

بهینه کردن فرآیندهای چند بعدی سیستم‌های ساخت مناسب می‌دانند.

نرم‌افزار NS از توانمندی نرمال‌سازی داده‌ها برخوردار و مجهز به ابزار اعتبارسنجی متقابل^۱ است که در بررسی خوبی آرایش کاربرد دارد. برای این منظور در هر آرایش یک جذر میانگین مربعات خطا آموزش^۲ ($RMSE_{learn}$) و یک جذر میانگین مربعات خطای آرایش^۳ ($RMSE_{cv}$) داریم. در صورتی که آرایش خوب عمل کند تفاوت این دو خطا باید ناچیز و مقدار آن‌ها نیز کمترین باشد. در غیر این صورت آرایش پیشنهادی سبب بیش آموزشی^۴ شبکه شده و نرم‌افزار آموزش شبکه را پایان می‌دهد. نرم‌افزار NW توانایی جداسازی داده‌ها به شکل آموزش و تست و قابلیت نرمال‌سازی داده‌ها را ندارد. نرمال‌سازی به منظور حداقل نمودن تغییرات وزن نرون‌ها و پاسخ سریع‌تر نرون‌ها به سیگنال ورودی است (کومار و همکاران ۲۰۰۲ و حسینی و همکاران ۱۳۸۶). نرمال‌سازی داده‌ها قبل از آموزش شبکه و با استفاده از رابطه ۱ انجام شد:

$$X_n = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad [1]$$

که X_n مقدار هنجار شده، X_i مقدار واقعی متغیر، X_{\min} کمینه مقدار واقعی متغیر و X_{\max} بیشینه مقدار واقعی متغیر است.

بعد از انتخاب داده‌های ورودی، طراحی شبکه عصبی مصنوعی از نوع پرسپترون چند لایه^۵ (MLP) و قانون یادگیری پس‌انتشار خطا^۶ (BP) انجام شد. شبکه MLP بیشترین کاربرد را در حل مسائل مهندسی در سطح جهان دارد و قادر به تخمین هر نگاشت پیچیده‌ای است (کومار و همکاران، ۲۰۰۲ و هیجت-نیلسن، ۱۹۸۷ و کارآموز ۱۳۸۵). روند محاسبات در فرآیند آموزش

¹ Cross validation

² Root mean square error learn

³ Root mean square error Cross validation

⁴ Over training

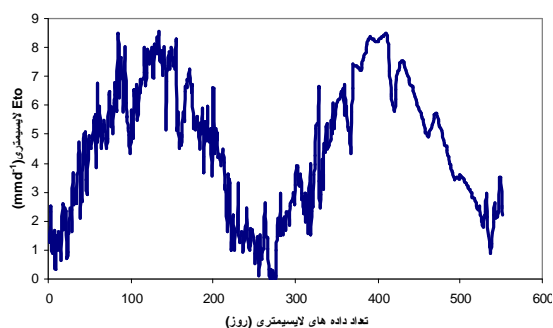
⁵ Multi layer perspetron

⁶ Back propagation

⁷ Mean absolute error

⁸ Absolute standard division

⁹ Epoch



شکل ۱- تغییرات زمانی ET₀ روزانه گیاه مرجع (لایسمتری)

مورد استفاده در شبکه عصبی مصنوعی

لذا پس از آماده‌سازی و نرمال نمودن داده‌های هواشناسی به کمک رابطه ۱، آموزش شبکه از طریق بخشی از داده‌ها انجام و سناریوهای متفاوت برای برآورد تبخیر-تعرق در منطقه همدان بررسی گردید. جدول ۲ نتایج ۲۱ اجرا از آرایش‌های مختلف شبکه عصبی مصنوعی در نرم‌افزار NW را نشان می‌دهد.

به عنوان یک نتیجه کلی از جدول ۲، آرایش‌های ردیف ۳، ۴، ۱۱ و ۱۵ در ترکیب با تابع محرک سیگموئید و آرایش ردیف‌های ۵ و ۱۲ با تابع محرک دیجیتالی^۱ (Dnna) به واسطه خطای کمتر و ضریب تعیین بالا دارای جواب‌های مناسب‌تری هستند. از آنجایی که معیارهای خطا نظیر RMSE، MAE و St_{dev} برابر هستند لذا بین نتایج حاصل از نظر تعداد لایه‌های پنهان و تعداد نرون لایه‌های پنهان تفاوتی وجود ندارد.

بنابراین با توجه به ضریب تعیین، تعداد لایه پنهان کمتر و تعداد نرون کمتر در لایه میانی، آرایش ۱-۶-۶-۳ با تابع محرک سیگموئید به عنوان بهترین آرایش جهت برآورد تبخیر-تعرق روزانه پیشنهاد می‌گردد. آرایش فوق با تابع محرک سیگموئید به واسطه سرعت بالا و زمان کوتاه‌تر در دستیابی به جواب با نتایج منهای (۱۳۷۷) و قاسمی و همکاران (۱۳۸۶) همخوانی دارد.

بنابراین خروجی شبکه عصبی مصنوعی براساس مقیاس زمانی داده‌های ورودی به صورت روزانه بود.

جدول ۱- پارامترهای ورودی شبکه عصبی مصنوعی و محدوده‌های

کمینه و بیشینه آن‌ها

پارامتر	نماد	کمینه	بیشینه	میانگین
دمای حداکثر (°C)	T _{max}	۰	۳۹/۸	۱۹/۹
دمای حداقل (°C)	T _{min}	-۷	-۲۰/۳	-۱۳/۷
رطوبت نسبی حداکثر (%)	RH _{max}	۳۳	۱۰۰	۶۶/۵
رطوبت نسبی حداقل (%)	RH _{min}	۸	۹۲	۵۰
سرعت باد (ms ⁻¹)	U ₂	۰	۷/۵	۳/۵
ساعات آفتابی (h)	n	۰	۱۴/۱	۷/۱

میانگین اعداد جدول ۱ در محدوده میانگین‌های دراز مدت منطقه قرار دارند. اعداد جدول ۱ تغییرات کوتاه مدت در مقیاس منطقه‌ای را نشان می‌دهند. به عنوان نمونه وجود رطوبت نسبی و دمای نسبتاً پایین منطقه معمولاً سبب ریزش‌های جوی به صورت برف و ماندگاری آن می‌شود.

شکل ۱ مقادیر تبخیر-تعرق لایسمتری را برای دو فصل زراعی سال‌های ۱۳۷۶ و ۱۳۷۷ بر حسب میلی-متر در روز نشان می‌دهد. از داده‌های شکل ۱ برای ارزیابی برآوردهای شبکه عصبی مصنوعی استفاده شد. براساس شکل ۱ داده‌های سال دوم از نوسانات کمتری برخوردار هستند. این امر می‌تواند ناشی از بهبود ساختمان خاک در اثر کشت و کار ناشی از سال قبل و دقت در اندازه‌گیری‌ها باشد. در سال اول نیز سعی شد تا خاک درون لایسمتر مشابه خاک زمین طبیعی باشد اما چنین حالتی به خاطر جابجایی خاک به طور کامل قابل اجرا نبود و تجربه و مهارت سال دوم نیز بیش از سال اول بود. حداکثر مقدار تبخیر-تعرق براساس شکل ۱ در هر دو سال زراعی تقریباً در اواسط فصل زراعی (مرداد) در حدود ۸/۵ میلی-متر در روز قابل مشاهده است.

¹ Digital neural network architect

جدول ۲- خلاصه نتایج آماری مربوط به اجرای آرایش‌های بهینه مختلف شبکه عصبی در نرم‌افزار Neura Work

ردیف	آرایش شبکه	قانون یادگیری	تابع محرک	R^2	$RMSE_{Learn}$	$RMSE_{Test}$	MAE	St_{dev}
۱	۶-۵-۵-۱	Delta-Rule	Linear	۰/۸۵	۰/۱۵	۰/۱۶	۰/۰۷	۰/۰۷
۲	۶-۵-۵-۱	Delta-Rule	Tan H	۰/۸۶	۰/۱۴	۰/۱۵	۰/۰۷	۰/۰۶
۳	۶-۶-۱	Delta-Rule	Sigmoid	۰/۸۶	۰/۰۶	۰/۰۶	۰/۰۷	۰/۰۷
۴	۶-۶-۶-۱	Delta-Rule	Sigmoid	۰/۸۵	۰/۰۶	۰/۰۶	۰/۰۷	۰/۰۷
۵	۶-۵-۱	Delta-Rule	Dnna	۰/۸۵	۰/۰۶	۰/۰۶	۰/۰۷	۰/۰۷
۶	۶-۷-۷-۱	Delta-Rule	Sine	۰/۸۶	۰/۱۵	۰/۱۴	۰/۰۷	۰/۰۷
۷	۶-۶-۱	Norm-Cum	Tan H	۰/۸۴	۰/۱۵	۰/۱۵	۰/۰۷	۰/۰۷
۸	۶-۳-۱	Norm-Cum	Sigmoid	۰/۸۱	۰/۰۶	۰/۰۶	۰/۰۸	۰/۰۷
۹	۶-۳-۱	Norm-Cum	Dnna	۰/۸۰	۰/۰۷	۰/۰۶	۰/۰۸	۰/۰۷
۱۰	۶-۴-۱	Norm-Cum	sine	۰/۸۵	۰/۱۵	۰/۱۵	۰/۰۷	۰/۰۷
۱۱	۶-۳-۱	Ext-Dbd	Sigmoid	۰/۸۵	۰/۰۶	۰/۰۶	۰/۰۷	۰/۰۷
۱۲	۶-۵-۱	Ext-Dbd	Dnna	۰/۸۵	۰/۰۶	۰/۰۶	۰/۰۷	۰/۰۷
۱۳	۶-۷-۱	Ext-Dbd	sine	۰/۸۶	۰/۱۵	۰/۱۵	۰/۰۷	۰/۰۷
۱۴	۶-۵-۱	Quick Prop	Tan H	۰/۸۴	۰/۱۸	۰/۲۱	۰/۱۱	۰/۰۸
۱۵	۶-۳-۱	Quick Prop	Sigmoid	۰/۸۴	۰/۰۶	۰/۰۶	۰/۰۷	۰/۰۷
۱۶	۶-۵-۱	Quick Prop	Dnna	۰/۸۱	۰/۰۶	۰/۰۶	۰/۰۸	۰/۰۷
۱۷	۶-۸-۸-۱	Quick Prop	Sine	۰/۸۳	۰/۲۹	۰/۱۸	۰/۱۴	۰/۱۰
۱۸	۶-۵-۵-۱	Delta-Bar-De	Linear	۰/۸۲	۰/۱۷	۰/۱۷	۰/۰۸	۰/۰۷
۱۹	۶-۸-۸-۱	Delta-Bar-De	Tan H	۰/۸۳	۰/۱۶	۰/۱۶	۰/۰۷	۰/۰۷
۲۰	۶-۴-۱	Delta-Bar-De	Dnna	۰/۳۰	۰/۱۱	۰/۱۰	۰/۱۵	۰/۱۱
۲۱	۶-۸-۸-۱	Delta-Bar-De	Sine	۰/۸۴	۰/۱۶	۰/۰۲	۰/۰۷	۰/۰۷

خلاصه‌ای از نتایج اجرای آرایش‌های مختلف در نرم‌افزار NS در جدول ۳ ارائه شده است. جدول ۳ براساس اعتبارسنجی متقابل و ناچیز بودن تفاوت بین جذر میانگین مربعات خطای آموزش ($RMSE_{learn}$) و جذر میانگین مربعات خطای آرایش ($RMSE_{cv}$) ارائه شده است.


مقایسه جداول ۲ و ۳ نشان می‌دهد نرم‌افزار NS به واسطه تعریف قواعد آموزشی و توابع محرک بیشتر نسبت به نرم‌افزار NW از نظر تعداد آرایش برتری دارد. برای تشخیص آرایش مناسب طبق عرف معمول و با توجه به معیار اعتبارسنجی متقابل، ۲۰-۳۰

درصد از آرایش‌های با کمترین $RMSE_{learn}$ و $RMSE_{cv}$ شامل آرایش‌های ۱، ۲، ۳، ۴، ۱۵، ۱۷ و ۱۸ با تابع محرک سیگموئید و سیگموئید خطی انتخاب شدند. چون بین دو پارامتر تبخیر- تعرق برآوردی از شبکه عصبی مصنوعی و تبخیر- تعرق اندازه‌گیری (لایسیمتری) به لحاظ حداقل بودن معیارهای خطا و ضریب تعیین ارتباط قوی‌تری وجود دارد.

به این ترتیب با توجه به جدول ۳ حداقل مقادیر $RMSE_{Test}$ ، MAE و St_{dev} به ترتیب ۰/۰۷، ۰/۰۶ و ۰/۰۵ و حداکثر R^2 معادل ۰/۸۷ برای آرایش ۶-۱-۶ با قانون یادگیری گرادیان مزدوج و تابع محرک سیگموئید به

خود همگرا شده لیکن در نرم افزار NW پس از حدود ۸۰۰۰ تکرار به همگرایی می‌رسد. مقایسه فوق نشان می‌دهد نرم افزار NS با حجم عملیات کمتر و در زمان کوتاه‌تر به جواب می‌رسد، هر چند هر دو نرم افزار آرایش ۱-۶-۶ را پیشنهاد دادند.


پس از پیشنهاد آرایش ۱-۶-۶ با تابع محرک سیگموئید و قانون یادگیری گرادینت مزدوج به بررسی تعداد نرون‌ها در لایه (های) پنهان پرداخته شد. بدین منظور RMSE برای تعداد نرون‌های متفاوت تا سقف ۱۵ نرون برای یک لایه و دو لایه پنهان با نرم افزار NS محاسبه و در شکل ۴ نشان داده شد. روند نمودارهای شکل ۴ با افزایش تعداد نرون به سمت مانایی میل می‌کند. شکل ۴ نشان داد بین یک و دو لایه پنهان در تعداد نرون کمتر تفاوت وجود دارد اما با افزایش تعداد نرون تفاوت کاهش یافت. به طوری که در تعداد نرون ۶ بین یک و دو لایه پنهان تفاوتی از نظر خطا وجود ندارد. لذا انتخاب آرایش ۱-۶-۶ قابل تایید است.




شکل ۴- تغییرات RMSE همگام با افزایش تعداد نرون در لایه میانی برای مدل بهینه در نرم افزار NeuroSolution

شکل ۴ هم چنین نشان می‌دهد که افزایش تعداد نرون در لایه میانی می‌تواند به خطای کمتر منجر شود. به عنوان نمونه اگر تعداد نرون در لایه میانی به ۱۰ نرون افزایش یابد خطا کاهش می‌یابد. لازم به ذکر است که تنها خطا ملاک انتخاب نیست و لازم است ضریب تعیین نیز بررسی شود. برای این منظور مجدداً RMSE به همراه ضریب تعیین برای آرایش سه لایه محاسبه

عنوان آرایش بهینه محاسبه شد. نوع آرایش پیشنهادی مشابه نتایج کیسی (۲۰۰۶) و نتایج منهاج (۱۳۷۷) برای تقریب تبخیر-تعرق به عنوان پدیده‌ای غیرخطی است. در بررسی عملکرد دو نرم افزار NW و NS نمودار تعداد تکرارهای محاسباتی برای رسیدن به پایداری در جواب به تفکیک رسم شد (شکل ۲ و ۳). شکل ۲ و شکل ۳ روند خطا به همراه تعداد تکرارهای محاسباتی را به ترتیب در نرم افزار NW و نرم افزار NS نمایش می‌دهند.



شکل ۲- نمودار خطای چرخه تکرار محاسباتی برای شبکه بهینه در نرم افزار NeuralWork



شکل ۳- نمودار خطای چرخه تکرار محاسباتی برای شبکه بهینه در نرم افزار NeuroSolution

مقایسه اشکال ۲ و ۳ نشان می‌دهد که NS از میانگین خطای کمتری نسبت به NW برخوردار است. براساس شکل ۲ حداقل خطا در نرم افزار NW ۰/۰۶ و در خصوص نرم افزار NS طبق شکل ۳ این مقدار ۰/۰۷ است. ضمن آنکه در نرم افزار NS با حدود ۸۰ بار تکرار محاسباتی روند خطای آموزش و تست در کمترین مقدار

جدول ۳- خلاصه نتایج آماری مربوط به اجرای آرایش‌های بهینه مختلف شبکه عصبی در نرم‌افزار NeuroSolution

ST _{dev}	MAE	R ² _{Test}	RMSE _{Test}	R ² _{Learn}	RMSE _{Learn}	RMSE _{cv}	تابع محرک	قانون یادگیری	آرایش شبکه	ردیف
۰/۰۷	۰/۰۸	۰/۸۳	۰/۱۰	۰/۸۴	۰/۱۰	۰/۱۳	Sigmoid	Momentum	۶-۷-۱	۱
۰/۰۵	۰/۰۶	۰/۸۷	۰/۰۷	۰/۸۸	۰/۰۸	۰/۰۹	Sigmoid	Conjugate Gradient	۶-۶-۱	۲
۰/۰۶	۰/۰۷	۰/۸۶	۰/۰۹	۰/۹۱	۰/۰۷	۰/۱۱	Sigmoid	Levenberg Marquat	۶-۵-۱	۳
۰/۱۰	۰/۱۶	۰/۷۹	۰/۱۷	۰/۸۹	۰/۱۸	۰/۱۷	Sigmoid	Quick Prop	۶-۷-۱	۴
۰/۰۶	۰/۰۷	۰/۸۷	۰/۰۹	۰/۸۹	۰/۰۸	۰/۱۱	Sigmoid	Delta-Bar-Delta	۶-۶-۱	۵
۰/۱۲	۰/۱۵	۰/۶۱	۰/۱۷	۰/۸۳	۰/۱۶	۰/۱۵	Sigmoid	Step	۶-۵-۱	۶
۰/۰۶	۰/۰۷	۰/۸۷	۰/۱۷	۰/۸۹	۰/۱۶	۰/۲۱	Tan H	Momentum	۶-۷-۱	۷
۰/۰۶	۰/۰۷	۰/۸۷	۰/۱۷	۰/۸۷	۰/۱۸	۰/۲۱	Tan H	Conjugate Gradient	۶-۸-۸-۱	۸
۰/۰۶	۰/۰۷	۰/۸۸	۰/۱۶	۰/۹۳	۰/۱۳	۰/۲۲	Tan H	Levenberg Marquat	۶-۸-۱	۹
۰/۰۶	۰/۰۷	۰/۸۷	۰/۱۷	۰/۸۹	۰/۱۷	۰/۲۲	Tan H	Quick Prop	۶-۸-۱	۱۰
۰/۰۶	۰/۰۷	۰/۸۷	۰/۱۷	۰/۸۹	۰/۱۶	۰/۲۱	Tan H	Delta-Bar-Delta	۶-۵-۱	۱۱
۰/۰۶	۰/۰۷	۰/۸۷	۰/۱۷	۰/۸۹	۰/۱۷	۰/۲۲	Tan H	Step	۶-۵-۱	۱۲
۰/۰۶	۰/۰۷	۰/۸۶	۰/۰۹	۰/۸۷	۰/۰۹	۰/۱۲	Linear Sigmoid	Momentum	۶-۵-۱	۱۳
۰/۰۶	۰/۰۹	۰/۸۳	۰/۱۰	۰/۵۸	۰/۱۷	۰/۱۶	Linear Sigmoid	Conjugate Gradient	۶-۸-۱	۱۴
۰/۰۶	۰/۰۷	۰/۸۶	۰/۰۹	۰/۸۷	۰/۰۹	۰/۱۲	Linear Sigmoid	Levenberg Marquat	۶-۶-۱	۱۵
۰/۰۶	۰/۰۸	۰/۸۳	۰/۱۰	۰/۸۵	۰/۱۰	۰/۱۳	Linear Sigmoid	Quick Prop	۶-۵-۱	۱۶
۰/۰۶	۰/۰۷	۰/۸۷	۰/۰۸	۰/۸۹	۰/۰۸	۰/۱۲	Linear Sigmoid	Delta-Bar-Delta	۶-۶-۱	۱۷
۰/۰۶	۰/۰۸	۰/۸۶	۰/۰۹	۰/۸۷	۰/۰۹	۰/۱۱	Linear Sigmoid	Step	۶-۶-۱	۱۸
۰/۰۶	۰/۰۷	۰/۸۷	۰/۱۶	۰/۸۹	۰/۱۶	۰/۲۱	LinearTan H	Momentum	۶-۵-۱	۱۹
۰/۰۶	۰/۰۷	۰/۸۸	۰/۱۷	۰/۸۹	۰/۱۶	۰/۲۱	LinearTan H	Conjugate Gradient	۶-۷-۱	۲۰
۰/۰۶	۰/۰۷	۰/۸۷	۰/۱۷	۰/۹۱	۰/۱۵	۰/۲۰	LinearTan H	Levenberg Marquat	۶-۸-۱	۲۱
۰/۰۶	۰/۰۷	۰/۸۷	۰/۱۷	۰/۸۹	۰/۱۶	۰/۲۴	LinearTan H	Quick Prop	۶-۸-۱	۲۲
۰/۰۶	۰/۰۷	۰/۸۷	۰/۱۷	۰/۹۰	۰/۱۹	۰/۲۴	LinearTan H	Delta-Bar-Delta	۶-۴-۱	۲۳
۰/۰۶	۰/۰۷	۰/۸۷	۰/۱۷	۰/۸۸	۰/۱۷	۰/۲۲	LinearTan H	Step	۶-۶-۱	۲۴
۰/۰۶	۰/۰۷	۰/۸۶	۰/۱۷	۰/۸۸	۰/۱۷	۰/۲۳	Bias	Momentum	۶-۵-۱	۲۵
۰/۰۶	۰/۰۷	۰/۸۶	۰/۱۷	۰/۸۸	۰/۱۷	۰/۲۳	Bias	Conjugate Gradient	۶-۴-۱	۲۶
۰/۰۶	۰/۰۷	۰/۸۶	۰/۱۷	۰/۸۸	۰/۱۷	۰/۲۳	Bias	Levenberg Marquat	۶-۶-۶-۱	۲۷
۰/۰۶	۰/۰۷	۰/۸۶	۰/۱۷	۰/۸۸	۰/۱۷	۰/۲۳	Bias	Quick Prop	۶-۵-۱	۲۸
۰/۰۶	۰/۰۷	۰/۸۶	۰/۱۷	۰/۸۸	۰/۱۷	۰/۲۳	Bias	Delta-Bar-Delta	۶-۶-۱	۲۹
۰/۰۶	۰/۰۷	۰/۸۶	۰/۱۷	۰/۸۸	۰/۱۷	۰/۲۳	Bias	Step	۶-۵-۱	۳۰
۰/۰۶	۰/۰۷	۰/۸۶	۰/۱۷	۰/۸۸	۰/۱۷	۰/۲۳	Linear	Momentum	۶-۸-۱	۳۱
۰/۰۶	۰/۰۷	۰/۸۶	۰/۱۷	۰/۸۸	۰/۱۷	۰/۲۳	Linear	Conjugate Gradient	۶-۸-۱	۳۲
۰/۰۶	۰/۰۷	۰/۸۶	۰/۱۷	۰/۸۸	۰/۱۷	۰/۲۳	Linear	Levenberg Marquat	۶-۸-۱	۳۳
۰/۰۶	۰/۰۷	۰/۸۶	۰/۱۷	۰/۸۸	۰/۱۷	۰/۲۳	Linear	Quick Prop	۶-۸-۱	۳۴
۰/۰۶	۰/۰۷	۰/۸۶	۰/۱۷	۰/۸۸	۰/۱۷	۰/۲۳	Linear	Delta-Bar-Delta	۶-۷-۷-۱	۳۵
۰/۰۶	۰/۰۷	۰/۸۶	۰/۱۷	۰/۸۸	۰/۱۷	۰/۲۳	Linear	Step	۶-۶-۱	۳۶
۰/۰۶	۰/۰۷	۰/۸۶	۰/۱۷	۰/۸۸	۰/۱۷	۰/۲۳	Axon	Momentum	۶-۷-۱	۳۷
۰/۰۶	۰/۰۷	۰/۸۷	۰/۱۷	۰/۸۸	۰/۱۷	۰/۲۳	Axon	Conjugate Gradient	۶-۶-۱	۳۸
۰/۰۶	۰/۰۷	۰/۸۸	۰/۱۷	۰/۸۷	۰/۱۷	۰/۱۷	Axon	Levenberg Marquat	۶-۴-۱	۳۹
۰/۰۶	۰/۰۷	۰/۸۶	۰/۱۷	۰/۸۸	۰/۱۷	۰/۲۳	Axon	Quick Prop	۶-۳-۳-۱	۴۰
۰/۰۶	۰/۰۷	۰/۸۶	۰/۱۷	۰/۸۸	۰/۱۷	۰/۲۳	Axon	Delta-Bar-Delta	۶-۶-۶-۱	۴۱
۰/۰۶	۰/۰۷	۰/۸۶	۰/۱۷	۰/۸۸	۰/۱۷	۰/۲۳	Axon	Step	۶-۳-۳-۱	۴۲


با توجه به شکل ۶ می‌توان نتیجه گرفت مدل شبکه عصبی مصنوعی بیشترین حساسیت را به دمای حداکثر هوا و کمترین حساسیت را به حداقل رطوبت نسبی دارد. روند حساسیت نشان داده شده در شکل ۶ 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 پهن من بی‌تاثیر دانسته است. بنا به شکل ۶ حساسیت در حالت کاهشی بیشتر از افزایشی است که این امر را می‌توان در مقاومت گیاه به تبخیر- تعرق در حالت افزایشی دانست. به اعتقاد تقوی و محمدی (۱۳۸۶) نیز اطلاعات مربوط به دما، سرعت باد و ویژگی‌های ابرناکی می‌تواند سبب تغییرات در مقیاس فضایی بزرگ و محلی شود. شکل ۶ نشان دهنده انتخاب مناسب تعداد و نوع اطلاعات برای لایه ورودی است.

با وجودی که شبکه عصبی مصنوعی به تعداد و نوع اطلاعات وابسته است لیکن به ترتیب اطلاعات وابستگی ندارد. عدم وابستگی به ترتیب اطلاعات به دلیل ارتباط هر نرون 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.

نتیجه‌گیری

در این تحقیق سعی شد تا کارایی آلوگوریتم‌های مختلف شبکه عصبی مصنوعی در دو نرم‌افزار مرسوم برای برآورد تبخیر- تعرق گیاه مرجع در مقایسه با نتایج لایسمتری از طریق خط‌اسنجی و ضریب تعیین بررسی گردد. شبکه عصبی مصنوعی با شبکه پرسپترون چند لایه (MLP) و قانون یادگیری پس‌انتشارخطا (BP) انتخاب شد. نتایج نشان داد هر دو نرم‌افزار از کارایی مناسبی برخوردار هستند و آرایش یکسانی را پیشنهاد دادند. لیکن نرم افزار NS با توجه به زمان کوتاه‌تر و خطای کمتر در ارائه جواب نهایی نسبت به نرم‌افزار

شد. روند معیارهای R^2 و RMSE محاسبه شده برای نرون‌های متفاوتی از لایه میانی در شکل ۵ نشان داده شده است.




شکل ۵- تغییرات میزان R^2 و RMSE همگام با افزایش تعداد

نرون در لایه میانی برای مدل بهینه در نرم‌افزار

NeuroSolution

شکل ۵ نشان می‌دهد هر چند افزایش تعداد نرون منجر به کاهش RMSE شده اما افزایش ضریب تعیین را در پی نداشته است. لذا براساس شکل ۵ وجود ۶ نرون در لایه میانی کمترین مقدار RMSE و بیشترین R^2 را به همراه دارد که نشان‌دهنده مطلوبیت انتخاب آرایش ۶-۱-۶ در نرم‌افزار NS است.

شکل ۶ حساسیت شبکه عصبی مصنوعی با آرایش ۶-۱-۶ را نسبت به داده‌ها و اطلاعات ورودی در نرون‌های لایه اول نمایش می‌دهد. شکل ۶ براساس افزایش و کاهش ۱۰ درصد متغیرهای ورودی به شبکه عصبی مصنوعی می‌باشد.



شکل ۶- آنالیز حساسیت تبخیر- تعرق به پارامترهای ورودی در

مدل بهینه در نرم‌افزار NeuroSolution

به بررسی حساسیت شبکه عصبی مصنوعی به تعداد و نوع اطلاعات ورودی می‌توان نتیجه گرفت تبخیر - تعرق به مقدار زیادی به دمای حداکثر هوا وابسته است.

NW برتری دارد. نمودارهای خط‌اسنجی و ضریب تعیین نشان داد تفاوت قابل توجهی بین یک و دو لایه پنهان وجود ندارد. لذا وجود یک لایه پنهان با ۶ نرون در لایه پنهان کفایت دارد. شایان ذکر است که با توجه

منابع مورد استفاده

- پلنگی ج، معاضده و طارقیان ر، ۱۳۸۵. تخمین تبخیر و تعرق گیاه مرجع با استفاده از شبکه‌های عصبی در اهواز. همایش ملی مدیریت شبکه های آبیاری و زهکشی، دانشگاه شهید چمران اهواز.
- تفضلی ف، سبزی‌پرور ع، ا، زارع‌ابیانه ح، مریانجی ز و موسوی بایگی م، ۱۳۸۶. ارزیابی مدل های رایج تبخیر و تعرق در اقلیم سرد نیمه خشک به منظور استفاده بهینه از مدل های تابش. چکیده مقالات نهمین سمینار آبیاری و کاهش تبخیر دانشگاه شهید باهنر کرمان. صفحات ۱۵-۱۶.
- تقوی ف و محمدی ح، ۱۳۸۶. بررسی دوره بازگشت رویدادهای اقلیمی حدی به منظور شناخت پیامدهای زیست محیطی. مجله محیط شناسی. سال ۳۳. شماره ۴۳. صفحات ۲۰-۱۱.
- حسینی س م ط، سی‌وسه‌مرده ع، فتحی پ و سی‌وسه‌مرده م، ۱۳۸۶. کاربرد شبکه‌های عصبی و رگرسیون چند متغیره در برآورد عملکرد گندم دیم منطقه قروه استان کردستان. مجله پژوهش کشاورزی: آب، خاک و گیاه در کشاورزی. جلد ۷. شماره ۱. صفحات ۴۱-۵۳.
- حق‌وردی ا، محمدی ک و سبزی‌پرور ع، ا، ۱۳۸۶. برآورد تبخیر تعرق با شبکه‌های پرسپترون چند لایه - مطالعه موردی همدان. چکیده مقالات نهمین سمینار آبیاری و کاهش تبخیر دانشگاه شهید باهنر کرمان. صفحه ۳.
- حق‌وردی ا، محسنی موحد ا و محمدی ک، ۱۳۸۶. تخمین میزان تبخیر از تشتک با استفاده از مدل‌های شبکه‌های عصبی مصنوعی. چکیده مقالات نهمین سمینار آبیاری و کاهش تبخیر دانشگاه شهید باهنر کرمان. صفحه ۲.
- شایان‌نژاد م، ۱۳۸۵. مقایسه دقت روش‌های شبکه‌های عصبی مصنوعی و پنمن - مانتیس در محاسبه تبخیر و تعرق پتانسیل. همایش ملی مدیریت شبکه‌های آبیاری و زهکشی، دانشگاه شهید چمران اهواز.
- طهماسبی ع ر و زمردیان س م ع، ۱۳۸۳. برآورد پتانسیل روانگرایی خاک‌ها با استفاده از شبکه عصبی مصنوعی. دومین کنفرانس ملی دانشجویی منابع آب و خاک. دانشگاه شیراز.
- قاسمی ع، زارع ابیانه ح، امیری چایجان ر و محمدی ک، ۱۳۸۶. ارزیابی دقت روش شبکه‌های عصبی مصنوعی و معادلات تجربی در محاسبه تبخیر-تعرق پتانسیل در استان همدان. چکیده مقالات نهمین سمینار آبیاری و کاهش تبخیر دانشگاه شهید باهنر کرمان. صفحه ۱۷.
- کارآموز م، رحیمی فراهانی م و مریدی ع، ۱۳۸۵. پیش‌بینی بلند مدت بارش با استفاده از سیگنال‌های هواشناسی و کاربرد شبکه‌های عصبی مصنوعی منطقه جنوب شرق ایران. مجموعه مقالات دومین کنفرانس مدیریت منابع آب دانشگاه صنعتی اصفهان.

مجرد ف، قمرنیا ه و نصیری ش، ۱۳۸۳. مطالعه تطبیقی روش‌های برآورد تبخیر- تعرق پتانسیل در جلگه مازندران. نیوار. شماره‌های ۵۴ و ۵۵. صفحات ۹۵-۷۷.

منهاج م ب، ۱۳۷۷. مبانی شبکه‌های عصبی. چاپ اول. مرکز نشر پرفسور حسابی. تهران.

میثاقی ف و محمدی ک، ۱۳۸۳. پیش‌بینی تغییرات کیفیت آب رودخانه زاینده رود با استفاده از شبکه‌های عصبی مصنوعی. دومین کنفرانس ملی دانشجویی منابع آب و خاک. دانشگاه شیراز.

Arca B, Benincasa F, De Vincenzi M and Ventura A, 1998. Neural network to simulate evaporation from Class A pan. Proceedings of the 23rd Conference of agricultural and forest meteorology. New Mexico, 258-288.

Anonymous, 1992. Software Reviews. NeuralWorks Professional II/PlusPublisher: NeuralWare Inc., Penn. Center West. Social Science Computer 10: 407-409.

Anonymous, 1994. NeuroSolutions: Premier Neural Network Development Environment [Online]. <http://www.neurosolutions.com>

Bruton JM, McClendon RW and Hoogenboom G, 2000. Estimating daily pan evaporation with artificial neural network. Trans. ASAE 43(2): 492-496.

Cannon AJ and Whitfield PH, 2002. Down scaling recent stream-flow conditions in British Columbia, Canada using ensemble neural networks. J Hydro 259: 136-151.

Chan KK, Spedding TA, 2003. An integrated multidimensional process improvement methodology for manufacturing systems. Computers & Industrial Eng 44: 673-693.

Hecht-Nielsen R, 1987. Kolmogorov's mapping neural network existence theorem, IEEE International Conference on Neural Networks, SOS Printing, San Diego Vol. 3. pp. 11--14.

Kisi O, 2006. Evapotranspiration estimation using feed-forward neural network. Nordic Hydrology 37(3): 247-260.

Kumar M, Raghuwanshi NS, Singh R, Wallender WW and Pruitt WO, 2002. Estimating evapotranspiration using artificial neural networks. J Irr and Drainage Eng. ASCE 128(4): 224-233.

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 Eng. 150: 131-138.

Trajkovic S, Todorovic B and Standkovic M, 2003. Forecasting of reference evapotranspiration by artificial neural network. J Irr and Drainage Eng. ASCE 129(6): 454-457.

Zanetti SS, Sousa EF, Olivera VPS, Almeida FT and Bernardo S, 2007. Estimating evapotranspiration using artificial neural network and minimum climatologically data. J Irr and Drainage Eng ASCE 133 (2): 83-89.