

مقایسه عملکرد شبکه‌های عصبی RBF و MLP در برآورد تبخیر و تعرق گیاه مرجع

حبیب صیادی^۱، ابوالفتح اولاد غفاری^۱، احد فعالیان^۱ و علی اشرف صدرالدینی^{۲*}

تاریخ پذیرش: 87/8/6

1- دانشجویان سابق کارشناسی ارشد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز

2- گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز

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

چکیده

تبخیر و تعرق یکی از اجزای اصلی چرخه‌ی هیدرولوژی است. این فرایند پیچیده به عوامل متعدد اقلیمی وابسته است. شبکه‌های عصبی مصنوعی در چند دهه‌ی اخیر و در مطالعات صورت گرفته برای مدل‌سازی سیستم‌های پیچیده و غیر خطی قابلیت بسیار بالایی از خود نشان داده‌اند. در تحقیق حاضر امکان استفاده از شبکه‌های با تابع پایه‌ی شعاعی (RBF) و شبکه‌های پرسپترون چند لایه (MLP) برای تخمین تبخیر و تعرق گیاه مرجع مورد مطالعه قرار گرفته است. با استفاده از سری داده‌های هواشناسی سال‌های 1330-1383 ایستگاه تبریز، ابتدا مقادیر متوسط تبخیر و تعرق ماهانه‌ی گیاه مرجع از روش استاندارد پنمن - مونتیت (PM)، محاسبه شد. سپس با استفاده از این مقادیر به عنوان خروجی‌های هدف، شبکه‌های مختلفی با ساختار متفاوت تعریف و آموزش داده شد. در نهایت قابلیت شبکه برای تخمین تبخیر و تعرق با استفاده از قسمتی از داده‌ها که در طراحی و یا آموزش شبکه استفاده نشده‌اند، مورد بررسی قرار گرفت. با بررسی‌های انجام گرفته مشخص شد که تنها با استفاده از دو پارامتر دمای میانگین و سرعت باد به عنوان ورودی، می‌توان میزان تبخیر و تعرق گیاه مرجع را با استفاده از این دو نوع شبکه با دقت قابل قبولی ($RMSE < 0/4081$ و $0/976 < R^2$ برای مجموعه‌ی صحت‌سنجی) تخمین زد. همچنین با مقایسه‌ی نتایج حاصل از دو شبکه مشخص شد که شبکه‌های MLP نسبت به RBF در تخمین تبخیر و تعرق گیاه مرجع از دقت نسبتاً بیشتری برخوردارند و تنها مزیت شبکه‌های RBF زمان کمتر مورد نیاز برای آموزش است.

واژه‌های کلیدی: تبخیر و تعرق گیاه مرجع، روش پنمن - مونتیت، شبکه‌های با تابع پایه‌ی شعاعی، شبکه‌های پرسپترون چند لایه

Comparison of RBF and MLP Neural Networks Performance for Estimation of Reference Crop Evapotranspiration

H Sayyadi¹, A Oladghaffari¹, A Faalian¹ and AA Sadraddini^{2*}

¹MSc. Student, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran

²Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran

*Corresponding author: [E-mail: alisadraddini@yahoo.com](mailto:alisadraddini@yahoo.com)

Abstract

Evapotranspiration is one of the most important components of the hydrologic cycle. This complex phenomenon is related to several climatological factors. Over the last decades, Artificial Neural Networks (ANNs) have shown a good ability for modeling complex and nonlinear systems. In the present research, the ability of Radial Basis Function (RBF) and Multi Layer Perceptron (MLP) neural networks in estimation of reference crop evapotranspiration (ET_o) was studied. First, using meteorological dataset of 1951-2004 years for Tabriz Station, the mean values of monthly reference crop evapotranspiration were calculated by Penman-Monteith (PM) method. Then, using these calculated values as target outputs various networks with different structures were defined and trained. Finally, the capabilities of these networks for estimation of evapotranspiration were analyzed using some values of dataset that were not used in the training of neural networks. The obtained results showed that, the value of reference crop evapotranspiration might acutely be estimated (RMSE<0.4081 and R²>0.976 for validation dataset) when the parameters of average temperature and wind velocity were used as the inputs of model. Also, comparison of these two neural network results specified that MLP neural networks had a relatively more accuracy than RBF neural networks in estimation of ET_o, and the only advantage of RBF neural networks was their much less time of training.

Keywords: Reference Crop Evapotranspiration, Penman-Monteith Method, Multi Layer Perceptrons, Radial Basis Functions

به صورت معقول و در میزان و تناوب مطلوب برای
رشد کامل گیاه با استفاده‌ی برنامه‌ریزی شده از منابع
آب در دسترس انجام پذیرد (زانتی و همکاران 2007).

مقدمه

طراحی نامناسب و مدیریت ضعیف آبیاری فاریاب باعث
خسارات جبران ناپذیری می‌شود. سیستم‌های آبیاری
زمانی به خوبی طراحی و مدیریت خواهند شد که پخش آب

برگیرنده‌ی قابلیت درک و تعمیم راه‌حل‌های معنی‌دار برای مسائلی از نمونه‌ها، حتی در صورتی که داده‌های ورودی حاوی خطا و یا ناقص باشند، و سازگار نمودن راه‌حل‌ها با شرایط متغیر و پردازش سریع‌تر اطلاعات می‌باشند (بشیر و حاجمیر 2000).

یک سیستم ممکن است غیر خطی و چند متغیره باشد، و متغیرهای دخیل ممکن است دارای روابط داخلی پیچیده‌ای باشند. شبکه‌های عصبی مصنوعی توانایی مطابقت این پیچیدگی را دارند و دقت آنها با افزایش هرچه بیشتر داده‌های ورودی، افزایش می‌یابد. همچنین شبکه‌های عصبی مصنوعی توانایی استخراج رابطه‌ی بین داده‌های ورودی و خروجی یک فرایند را بدون هیچ گونه اطلاع از اصول آن دارند. به دلیل توانایی‌های تعمیم یافته‌ی تابع استخراجی، نیازی به هیچگونه فرضی در مورد رابطه‌ی (خطی یا غیر خطی) بین داده‌های ورودی و خروجی نیست (جین و همکاران 2004).

در چند دهه‌ی اخیر استفاده از شبکه‌های عصبی مصنوعی در علوم آب گسترش فراوانی یافته است. در زمینه‌ی تخمین تبخیر و تعرق با استفاده از شبکه‌های عصبی نیز تا کنون مطالعاتی صورت گرفته است. کومار و همکاران (2002) مقدار تبخیر و تعرق روزانه‌ی گیاه مرجع (ET₀) را با استفاده از شبکه‌های عصبی مصنوعی تخمین زدند. سپس با مقایسه‌ی این مقادیر با نتایج حاصل از روش متداول محاسبه‌ی ET₀ یعنی روش پنمن مونتیث، قابلیت شبکه‌های عصبی مصنوعی را برای محاسبه‌ی این پارامتر مورد ارزیابی قرار دادند. در این مطالعه، با استفاده از یک شبکه‌ی پرسپترون چند لایه (MLP) و روش پس انتشار خطا (BP)، شبکه با استفاده از داده‌های هواشناسی روزانه از جمله تشعشع خورشیدی، حداکثر و حداقل دما، حداکثر و حداقل رطوبت نسبی و سرعت باد به عنوان ورودی و نتایج حاصل از تخمین ET₀ به روش پنمن - مونتیث به عنوان خروجی،

تبخیر و تعرق (ET) یکی از مهم‌ترین اجزای چرخه‌ی هیدرولوژیک می‌باشد و تخمین دقیق آن برای بسیاری از مطالعات نظیر بیلان هیدرولوژیک آب، طراحی و مدیریت سیستم‌های آبیاری، شبیه‌سازی تولید گیاهی و برنامه‌ریزی و مدیریت منابع آب ضروری است. یکی از متداول‌ترین روش‌های تخمین تبخیر و تعرق برای گیاهان زراعی، محاسبه‌ی تبخیر و تعرق گیاه مرجع نظیر تبخیر و تعرق چمن و یا تبخیر و تعرق یونجه از یک سطح استاندارد و سپس استفاده از ضرایب گیاهی می‌باشد.

تبخیر و تعرق می‌تواند به‌طور مستقیم توسط لایسیمتر یا روش بیلان آب اندازه‌گیری و یا با داده‌های هواشناسی تخمین زده شود. با این وجود امکان استفاده از لایسیمتر برای اندازه‌گیری تبخیر و تعرق همواره میسر نخواهد بود، زیرا این روش زمان‌گیر و نیازمند عملیات و برنامه‌ریزی دقیق می‌باشد. از این رو روش‌های غیر مستقیم بر پایه‌ی داده‌های هواشناسی برای تخمین تبخیر و تعرق گیاه مرجع استفاده می‌شود. این روش‌ها شامل معادلات تجربی و یا روش‌های پیچیده‌ی مبتنی بر فرایندهای فیزیکی می‌باشند. روش‌های ترکیبی تغییرات تبخیر را با شار تابش خالص و خصوصیات انتقال انرژی دینامیک یک سطح طبیعی مرتبط می‌نمایند. یکی از روش‌های ترکیبی که به‌طور گسترده‌ای برای تخمین تبخیر و تعرق مرجع مورد استفاده قرار می‌گیرد، روش پنمن - مونتیث می‌باشد (کومار و همکاران، 2002). با توجه به تحقیقات صورت گرفته، روش پنمن - مونتیث یکی از دقیق‌ترین روش‌های تخمین تبخیر و تعرق می‌باشد و می‌توان از آن برای اقلیم‌های مختلف استفاده نمود (چیو و همکاران 1995).

تبخیر و تعرق فرایندی پیچیده و غیر خطی است زیرا به عوامل متعدد اقلیمی نظیر دما، رطوبت، سرعت باد، تابش، نوع و مرحله‌ی رشد گیاه و غیره وابسته است. شبکه‌های عصبی مصنوعی (ANNs) ابزار مناسبی برای مدل‌سازی سیستم‌های غیر خطی می‌باشند. شبکه‌های عصبی مصنوعی مدل‌های ریاضی ساده‌شده‌ی شبکه‌های عصبی بیولوژیک را ارائه می‌کنند. این شبکه‌ها در

شبکه‌های عصبی مصنوعی را نسبت به روش هارگریوز - سامانی در برآورد تابش نشان داد. در تحقیق حاضر با استفاده از شبکه‌های عصبی با تابع پایه‌ی شعاعی (RBF)¹ و شبکه‌های پرسپترون چند لایه (MLP)²، مقادیر تبخیر و تعرق متوسط ماهانه، محاسبه شده از روش پنمن - مونتیت با استفاده از داده‌های هواشناسی ماهانه‌ی مربوط به منطقه‌ی تبریز مدل‌سازی شده است. نتایج این دو مدل با یکدیگر و همچنین با مقادیر محاسبه شده از روش پنمن - مونتیت مقایسه شده است.

مواد و روش‌ها

1- محاسبه‌ی ETo

در مطالعه‌ی حاضر، داده‌های اقلیمی متوسط ماهانه‌ی حداقل و حداکثر دما، حداقل و حداکثر رطوبت نسبی، سرعت باد و تابش خورشیدی مربوط به ایستگاه سینوپتیک تبریز مربوط به دوره‌ی آماری سال 1330 تا 1383 برای محاسبه‌ی تبخیر و تعرق متوسط ماهانه‌ی گیاه مرجع مورد استفاده قرار گرفته است. این ایستگاه در $38^{\circ} 05'$ عرض جغرافیایی و $46^{\circ} 17'$ طول جغرافیایی و در ارتفاع 1361 متری از سطح دریا واقع شده است. میانگین حداکثر و حداقل دما در ایستگاه به ترتیب 18 و 7 درجه‌ی سانتی‌گراد و میانگین سرعت باد در منطقه 6 متر بر ثانیه می‌باشد. به دلیل عدم دسترسی به داده‌های لایسیمتری، از روش پنمن - مونتیت برای تخمین تبخیر و تعرق گیاه مرجع استفاده شده است. روش پنمن - مونتیت در میان روش‌های مختلف تخمین تبخیر و تعرق گیاه مرجع همواره بیشترین دقت را دارا بوده است از این رو مقادیر محاسبه شده از روش پنمن - مونتیت به عنوان مقادیر استاندارد برای آموزش و صحت سنجی

آموزش داده شد و شبکه‌ای با ساختار 1-7-6 بعنوان بهترین ساختار برای تخمین ETo انتخاب شد. در بخش دیگری از این مطالعه شبکه‌های عصبی با استفاده از مقادیر ETo اندازه‌گیری شده توسط لایسیمتر آموزش داده شد و با مقایسه‌ی مقادیر ETo حاصل از شبکه‌های عصبی مصنوعی و روش پنمن - مونتیت نتیجه گرفته شد که شبکه‌های عصبی مصنوعی مقدار ETo را دقیق‌تر از روش پنمن - مونتیت تخمین می‌زنند.

زانتی و همکاران (2007) قابلیت شبکه‌های عصبی مصنوعی را برای تخمین تبخیر و تعرق گیاه مرجع در ایالت ریودوژانیروی آرژانتین با استفاده از حداکثر و حداقل دمای هوا مورد بررسی قرار دادند. برای آموزش شبکه از یک سری داده‌های هواشناسی روزانه (از سپتامبر 1996 تا اوت 2002) منطقه‌ی مورد مطالعه استفاده شد. شبکه‌های عصبی مصنوعی (از نوع پرسپترون چند لایه) برای تخمین ETo به عنوان تابعی از حداکثر و حداقل دمای هوا، و دو پارامتر تشعشع خورشیدی و ساعات آفتابی روزانه که خود تابعی از عرض جغرافیایی منطقه هستند، به کار گرفته شد. با توجه به نتایج به دست آمده از ANN، نتیجه گرفته شد که فقط با بکارگیری حداکثر و حداقل دما، می‌توان مقادیر ETo را در این منطقه تخمین زد.


رحیمی خوب (2008) عملکرد شبکه‌های عصبی مصنوعی و روش هارگریوز را در تخمین تبخیر و تعرق گیاه مرجع برای 12 ایستگاه هواشناسی خوزستان مقایسه نمود. تبخیر و تعرق گیاه مرجع با استفاده از روش پنمن - مونتیت محاسبه و مبنای مقایسه‌ی دو روش هارگریوز و شبکه‌ی عصبی قرار گرفت. در این تحقیق نتیجه گرفته شد که شبکه‌های عصبی در برآورد تبخیر و تعرق گیاه مرجع نسبت به روش هارگریوز از دقت بیشتری برخوردارند.

سلطانی و مرید (1384) برای برآورد مقادیر تابش خورشیدی که یکی از مولفه‌های مورد نیاز روش پنمن - مونتیت می‌باشد، از شبکه‌های عصبی مصنوعی استفاده نمودند و نتایج را با مقادیر حاصل از روش هارگریوز - سامانی مقایسه کردند. نتایج این تحقیق، عملکرد بهتر

¹Radial Basis Function

²Multi Layer Preceptron

بین لایه‌ی ورودی و لایه‌ی پنهان و یک تابع محرک خطی بین لایه‌ی پنهان و لایه‌ی خروجی به کار رفته است.



شکل 1- تصویر شماتیک شبکه‌ی پرسپترون چند لایه (MLP)

از میان روش‌های مختلف آموزش به روش پس انتشار خطا، الگوریتم لونیبرگ - مارکواریت¹، به دلیل همگرایی سریع‌تر در آموزش شبکه‌های با اندازه‌ی متوسط، برای استفاده در تحقیق حاضر انتخاب شده است. الگوریتم پس انتشار خطا، وزن‌های شبکه و مقادیر بایاس² را در جهتی تغییر می‌دهد که تابع عملکرد با سرعت بیشتری کاهش یابد. الگوریتم پس انتشار خطا را می‌توان به شکل زیر نشان داد:

$$x_{k+1} = x_k - \alpha_k g_k \quad [2]$$

که در آن x_k بردار وزن‌ها و بایاس در تکرار k ام، α_k نرخ آموزش در تکرار k ام و g_k گرادیان در تکرار k ام می‌باشد. الگوریتم لونیبرگ - مارکواریت برای دستیابی به آموزش سریع‌تر شبکه بسط داده شده است و از رابطه‌ی [3] استفاده می‌کند:

$$x_{k+1} = x_k - [J^T J + ml]^{-1} J^T e \quad [3]$$

که در آن x_k بردار وزن‌ها و بایاس در تکرار k ام، J ماتریس ژاکوبین شامل اولین مشتقات خطای شبکه با توجه به وزن‌ها و بایاس، e بردار خطاهای شبکه، I

ساختارهای متفاوت شبکه‌ی عصبی مورد استفاده قرار گرفته است.

آلن و همکاران (1998) در نشریه‌ی شماره‌ی 56 سازمان فائو رابطه‌ی [1] را که به نام رابطه‌ی فائو - پنمن - مونتیت معروف است، بعنوان دقیق‌ترین روش برای برآورد نیاز آبی گیاه ارائه نموده‌اند:

$$ET_o = \frac{0.408\Delta(R_n - G) + g \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + g(1 + 0.34u_2)} \quad [1]$$

که در آن ET_o تبخیر و تعرق گیاه مرجع (mm/day)، R_n تابش خالص در سطح پوشش گیاهی ($MJ/m day$)، G شار گرما به داخل خاک ($MJ/m day$)، T متوسط دمای هوا در ارتفاع دو متری از سطح زمین ($^{\circ}C$)، U_2 سرعت باد در ارتفاع دو متری از سطح زمین (m/s)، e_a فشار بخار واقعی (kPa)، e_s فشار بخار اشباع (kPa)، $e_s - e_a$ کمبود فشار بخار اشباع (kPa)، Δ شیب منحنی فشار بخار ($kPa/^{\circ}C$) و g ضریب رطوبتی ($kPa/^{\circ}C$) می‌باشد.

2- شبکه‌های پرسپترون چند لایه (MLP)

شبکه‌های چند لایه‌ی پیشخور یکی از مهم‌ترین ساختارهای شبکه‌های عصبی مصنوعی می‌باشد. به‌طور معمول این شبکه‌ها شامل مجموعه‌ای از واحدهای حسی (نرون‌های پایه) می‌باشند که تشکیل‌دهنده‌ی لایه‌ی ورودی، یک یا چند لایه‌ی پنهان و یک لایه‌ی خروجی می‌باشند. سیگنال ورودی در خلال شبکه و در مسیری رو به جلو به صورت لایه به لایه منتشر می‌شود. این نوع شبکه معمولاً با عنوان پرسپترون چند لایه (MLP) نامیده می‌شود (هایکین 1999). شکل 1 تصویر شماتیک این نوع شبکه‌ی عصبی را نشان می‌دهد.

در تحقیق حاضر، برای مدل‌سازی با استفاده از شبکه‌های MLP، از یک شبکه‌ی سه لایه‌ی پیشخور استفاده شده است. یک تابع محرک سیگموئید (تانژانت هیپربولیک)

¹Levenberg-Marquardt

²Bias

لایه‌ی پنهان ارسال می‌کند. هر یک از گره‌های واقع در لایه‌ی پنهان (نرون‌ها) با یک تابع انتقال f مشخص می‌شوند که سیگنال‌های ورودی را انتقال می‌دهند. در شکل 3 نمودار تابع انتقال شعاعی نشان داده شده است.


برای p امین الگوی ورودی یعنی X^p ، پاسخ z امین گره پنهان یعنی y_j برابر است با:

$$y_j = f \left\{ \frac{\|X^p - U_j\|}{2s_j^2} \right\} \quad [4]$$

که در آن $\|\dots\|$ برابر نرم اقلیدسی، U_j مرکز زامین تابع با پایه‌ی شعاعی، و σ گستره‌ی 1 RBF که شاخص فاصله‌ی شعاعی از مرکز RBF است که در آن مقدار تابع بطور مشخص از صفر متفاوت است. خروجی شبکه با استفاده از مجموع وزن‌دار خطی پاسخ‌های لایه‌ی پنهان در هر یک از گره‌های خروجی بدست می‌آید. خروجی k امین گره در لایه‌ی خروجی یعنی z_{pk} از رابطه‌ی زیر محاسبه می‌شود:

$$z_{pk} = \sum_{j=1}^L y_j w_{kj} \quad [5]$$

که در آن w_{kj} وزن پیوند بین گره‌های پنهان و خروجی است. متداول‌ترین تابع RBF تابع گاوسی² می‌باشد (سودهیر و جین، 2003).



شکل 3- تابع انتقال با پایه‌ی شعاعی


4- پردازش مقدماتی داده‌ها

برای افزایش بازده آموزش، ورودی‌ها و داده‌های هدف شبکه برای قرارگیری در بازه‌ی $[-1, 1]$

ماتریس واحد و μ یک کمیت اسکالر است. μ پس از هر گام موفق کاهش می‌یابد و در صورتی که یک گام منفرد، تابع عملکرد را افزایش دهد، μ نیز افزایش می‌یابد. به این ترتیب، تابع عملکرد در هر تکرار الگوریتم کاهش خواهد یافت. در این تحقیق از مقدار اولیه‌ی $0/001$ برای μ استفاده شده است.

3- شبکه‌های با تابع پایه‌ی شعاعی (RBF)

شبکه‌های RBF نیازمند نرون‌های بیشتری نسبت به شبکه‌های استاندارد پیشخور با الگوریتم پس انتشار خطا می‌باشند ولی اغلب این شبکه‌ها را می‌توان در زمانی کوتاه‌تر نسبت به زمان مورد نیاز برای شبکه‌های پیشخور، آموزش داد. این شبکه‌ها زمانی که بردارهای ورودی فراوانی در دسترس باشد از عملکرد مطلوب‌تری برخوردارند (بی‌نام 2007). شبکه‌های RBF نوعی شبکه‌ی عصبی پیشخور می‌باشند و ساختار آنها شبیه شبکه‌های MLP می‌باشد. شکل 2 تصویر شماتیک شبکه‌ی RBF را با N ، L و M گره به ترتیب در لایه‌های ورودی، پنهان و خروجی نشان می‌دهد. این شبکه، الگوی ورودی N بعدی را با استفاده از گره‌های واقع در لایه‌ی مجاور به یک الگوی خروجی Z بعدی نگاشت می‌کند.



شکل 2- تصویر شماتیک شبکه RBF

ورودی‌های یک نرون شعاعی، با سایر نرون‌ها متفاوت است. در نرون شعاعی ورودی‌های تابع انتقال برابر است با بردار فاصله بین وزن‌ها و ورودی‌ها، ضربدر بایاس. لایه‌ی ورودی، مقادیر ورودی را به هر یک از گره‌های

¹Spread

²Gaussian Function

که جذر میانگین مربعات خطا (RMSE) در دو مجموعه‌ی آموزش و صحت سنجی کمینه گردد.

6- توابع عملکرد

عملکرد شبکه‌های MLP و RBF در تخمین مقادیر ETO با استفاده از جذر میانگین مربعات خطا (RMSE) سنجیده شده است. این مقدار از رابطه‌ی [6] بدست خواهد آمد:

$$RMSE = \sqrt{\frac{1}{p} \sum_{i=1}^p [(ETO_m)_i - (ETO_s)_i]^2} \quad [6]$$

که در آن p تعداد مشاهدات، ETO_m مقدار محاسبه شده‌ی تبخیر و تعرق از روش پنمن - مونتیت و ETO_s مقدار تخمینی از شبکه‌های عصبی می‌باشند. همچنین برای بی‌بعد سازی مقادیر خطا از RMSE نرمال (بر حسب درصد) استفاده شده است که از رابطه‌ی [7] بدست می‌آید:

$$NRMSE = \left(\frac{RMSE}{ETO_{max} - ETO_{min}} \right) \times 100 \quad [7]$$

از ضریب نکویی برازش (R²) نیز برای مقایسه‌ی بین مقادیر تخمینی و مقادیر واقعی استفاده شده است.

نتایج و بحث

با استفاده از جعبه ابزار شبکه‌های عصبی در MATLAB[®] و تعریف 12 سناریو برای پارامترهای موثر، شبکه‌های متعددی با ساختارها و پارامترهای ورودی متفاوت برای تخمین تبخیر و تعرق گیاه مرجع تعریف شد. تعداد نرون‌های لایه‌ی پنهان و نرخ آموزش در شبکه‌های MLP و مقادیر گستره و تعداد توابع انتقال در شبکه‌های RBF با استفاده از آزمون و خطا تعیین گردید. پس از بررسی ساختارهای متفاوت برای شبکه‌های MLP و RBF، با توجه به مقادیر

نرمالیزه شده است. پس از اتمام آموزش، داده‌های شبیه‌سازی شده با روش معکوس از مقادیر نرمالیزه حاصل می‌گردند.

5- بهبود قدرت تعمیم‌دهی شبکه

برای تعمیم‌دهی مناسب شبکه، باید به نحوی از آموزش بیش از اندازه جلوگیری نمود. در مطالعه‌ی حاضر برای جلوگیری از آموزش بیش از اندازه در شبکه‌های MLP از روش متوقف سازی زود هنگام آموزش استفاده شد (بی‌نام، 2007). برای تصمیم‌گیری در مورد زمان متوقف ساختن آموزش، داده‌ها به صورت تصادفی به سه مجموعه تقسیم شد، 60 درصد داده‌ها برای آموزش، 20 درصد برای صحت سنجی و 20 درصد برای آزمون بکار رفت.

برای متوقف سازی زود هنگام، خطا، یعنی تفاوت بین داده‌های هدف اندازه‌گیری شده و مقادیر شبیه‌سازی شده، برای مجموعه‌ی آموزش، مجموعه‌ی صحت سنجی و آزمون به‌طور جداگانه و در هر تکرار آموزش محاسبه می‌گردد. خطا در مجموعه‌ی صحت‌سنجی به‌طور عادی در اوایل آموزش کاهش می‌یابد. اما، در هنگامی که شبکه شروع به آموزش بیش از اندازه‌ی داده‌ها می‌کند، خطای مجموعه‌ی صحت‌سنجی شروع به افزایش می‌نماید. وقتی این افزایش برای تعداد معینی از تکرارها ادامه می‌یابد، آموزش شبکه متوقف شده و مقادیر وزن‌ها حفظ می‌گردد. مجموعه‌ی آزمون برای کنترل صحت تقسیم داده‌ها بکار می‌رود، بگونه‌ای که تفاوت معنی‌دار خطا در دو مجموعه‌ی صحت‌سنجی و آزمون نشانگر تقسیم نادرست داده‌ها می‌باشد.

همچنین در مطالعه‌ی حاضر برای آموزش شبکه‌ی RBF به نحوی که از قابلیت تعمیم‌دهی مناسبی برخوردار باشد، ابتدا مقداری به عنوان خطای هدف به صورت مجموع مربعات خطا (SSE) در نظر گرفته شد، سپس مقادیر گستره و تعداد توابع انتقال با آزمون و خطا به گونه‌ای انتخاب شد

توابع عملکرد، در هر سناریو یک ساختار به عنوان ساختار بهینه انتخاب گردید. جدول 1 پارامترهای دخیل در هر سناریو را نمایش می‌دهد.

در آموزش شبکه‌های MLP ملاحظه شد که افزایش تعداد نرون‌های لایه‌ی پنهان، تاثیر معنی‌داری در افزایش عملکرد شبکه ندارد. از این رو برای اجتناب از بزرگ‌تر شدن ساختار شبکه‌ی عصبی، از 3 یا 4 نرون در لایه‌ی پنهان برای تمام سناریوهای آموزش استفاده شد. در نهایت پس از انتخاب ساختار بهینه‌ی MLP برای هر سناریو و محاسبه‌ی مقادیر توابع عملکرد، این سناریوها با در نظر گرفتن میزان خطای نرمال (NRMSE) رتبه‌بندی شدند.

جدول 2 نتایج کلی محاسبات صورت گرفته برای شبکه‌های MLP را نشان می‌دهد. برای شبکه‌های RBF نیز ساختار بهینه در هر سناریو انتخاب شد و با توجه به مقادیر توابع عملکرد این سناریوها رتبه‌بندی شدند. جدول 3 نتایج کلی محاسبات انجام گرفته را برای شبکه‌های RBF نشان می‌دهد.

چنانچه در جداول 2 و 3 مشخص است، تمام سناریوهای پیشنهادی دقت قابل قبولی در برآورد تبخیر و تعرق گیاه مرجع دارند. سناریوی شماره 1 که از تمام پارامترهای دخیل برای برآورد ETo استفاده می‌کند، با داشتن کمترین خطا (RMSE میانگین برابر 0/2916) برای دو شبکه‌ی MLP و RBF می‌تواند دقیق‌ترین جواب‌ها را تولید نماید. با این وجود با مقایسه‌ی نتایج مشخص شد که سناریوی 6 که تنها از دو پارامتر دمای میانگین ماهانه و سرعت باد برای تخمین تبخیر و تعرق گیاه مرجع استفاده می‌کند، در هر دو شبکه‌ی MLP و RBF می‌تواند به عنوان بهینه‌ترین سناریو انتخاب گردد، زیرا با وجود اینکه این سناریو از تعداد پارامترهای کمتری به عنوان ورودی شبکه استفاده می‌نماید ولی دقت آن قابل مقایسه با سناریوهای دارای تعداد پارامتر ورودی بیشتر می‌باشد.

جدول 1- پارامترهای دخیل در سناریوهای مختلف

شماره سناریو	پارامترهای ورودی شبکه
1	دمای حداقل، دمای حداکثر، رطوبت نسبی حداقل، رطوبت نسبی حداکثر، سرعت باد، ساعات آفتابی
2	دمای میانگین، رطوبت نسبی حداقل، رطوبت نسبی حداکثر، سرعت باد، ساعات آفتابی
3	دمای میانگین، رطوبت نسبی حداکثر، سرعت باد، ساعات آفتابی
4	دمای میانگین، رطوبت نسبی حداقل، سرعت باد، ساعات آفتابی
5	دمای میانگین، سرعت باد، ساعات آفتابی
6	دمای میانگین، سرعت باد
7	دمای حداقل، سرعت باد
8	دمای حداکثر، سرعت باد
9	دمای میانگین، ساعات آفتابی
10	دمای حداقل، دمای حداکثر
11	دمای میانگین
12	ساعات آفتابی

باد در ماه‌های مختلف دوره‌ی آماری مورد مطالعه استفاده شد. نمونه‌ای از مقادیر ETo محاسبه شده از این دو شبکه به همراه مقادیر محاسبه شده از روش پنمن - مونتیتث برای سال‌های 1330 تا 1340 در شکل

پس از انتخاب سناریوی بهینه‌ی پیشنهادی و صحت‌سنجی آن، با نگارش برنامه‌ای در محیط MATLAB از دو شبکه‌ی MLP و RBF برای محاسبه‌ی مقادیر ETo با دو پارامتر ورودی دمای میانگین ماهانه و متوسط سرعت

4 نمایش داده شده است. همانگونه که در جداول 2 و 3 و شکل 4 مشخص است، مقادیر ETo بدست آمده از شبکه‌های RBF و MLP با دو پارامتر ورودی، بسیار نزدیک به مقادیر استاندارد بدست آمده از روش پنمن - مونتیت می‌باشد. با این وجود مقادیر R^2 برای داده‌های


آموزش شبکه‌ی RBF اندکی بیشتر از مقادیر R^2 برای داده‌های استفاده شده در آموزش شبکه‌های MLP می‌باشد و در مورد داده‌های صحت‌سنجی تقریباً عکس این موضوع صادق است.

جدول 2- نتایج کلی آموزش و صحت‌سنجی شبکه‌های MLP

رتبه	شماره سناریو	RMSE	R^2 (آموزش)	R^2 (صحت سنجی)	NRMSE (%)
1	1	0/2946	0/990	0/987	2/62
2	2	0/3102	0/989	0/985	2/76
3	4	0/3303	0/987	0/989	3/94
4	3	0/3442	0/986	0/989	3/07
5	5	0/3814	0/983	0/983	3/40
6	8	0/4205	0/979	0/981	3/74
7	6	0/4276	0/979	0/981	3/81
8	7	0/4609	0/975	0/970	4/10
9	9	0/6570	0/950	0/957	5/85
10	10	0/7355	0/937	0/937	6/55
11	11	0/7460	0/935	0/925	6/64
12	12	0/9411	0/897	0/892	8/38

جدول 3- نتایج کلی آموزش و صحت‌سنجی شبکه‌های RBF

رتبه	شماره سناریو	SSE (هدف)	گستره	تعداد تابع انتقال	RMSE	R^2 (آموزش)	R^2 (صحت سنجی)	NRMSE (%)
1	2	1	0/5	25	0/2877	0/990	0/979	2/56
2	3	1	0/5	75	0/2879	0/990	0/984	2/56
3	1	1	0/5	50	0/2885	0/990	0/964	2/57
4	5	1	0/5	100	0/2886	0/990	0/956	2/57
5	4	1	0/5	50	0/2887	0/991	0/974	2/57
6	7	2	0/3	25	0/4080	0/979	0/973	3/63
7	8	2	0/3	25	0/4081	0/980	0/978	3/63
8	6	2	0/3	25	0/4081	0/981	0/976	3/63
9	9	3	0/3	100	0/5001	0/971	0/907	4/45
10	10	4	0/1	100	0/5753	0/963	0/833	5/12
11	11	5	0/1	125	0/6951	0/941	0/948	6/19
12	12	5	0/1	125	0/9433	0/895	0/909	8/40



شکل 4- مقادیر نمونه‌ی ET₀ محاسبه شده برای سال‌های 1330 تا 1340

برای ارائه جدولی خلاصه که تعدادی از مهم‌ترین مقادیر ET₀ تولید شده توسط شبکه‌های MLP و RBF را مورد مقایسه قرار دهد و همچنین برای ارزیابی و مقایسه‌ی بهتر این دو شبکه، مقادیر تبخیر و تعرق مربوط به ماه حداکثر در هر سال انتخاب گردید. مقادیر مذکور اصطلاحاً حداکثر تبخیر و تعرق سالانه نامیده می‌شوند و بدلیل اینکه مبنای محاسبات ظرفیت طراحی سیستم‌های انتقال و پخش آب می‌باشند، از اهمیت ویژه‌ای برخوردارند. جدول 4 نمونه‌هایی از مقادیر محاسبه شده‌ی حداکثر تبخیر و تعرق سالانه توسط دو شبکه‌ی MLP و RBF را در برابر مقادیر استاندارد بدست آمده از روش پنمن - مونتیت برای سال‌های 1357 تا 1383 نمایش می‌دهد. مقدار RMSE در تخمین حداکثر تبخیر و تعرق سالانه برای شبکه‌ی MLP برابر 0/2942 و برای شبکه‌ی RBF برابر 0/3490 بدست آمد. شکل‌های 5 و 6 ضریب تبیین محاسبه شده را به ترتیب در مقایسه‌ی مقادیر تخمینی از روش MLP و RBF با مقادیر استاندارد بدست آمده از روش پنمن - مونتیت نمایش می‌دهند. همان‌گونه که از شکل‌های مذکور و مقادیر RMSE مشخص است، هر دو شبکه‌ی MLP و RBF از دقت نسبتاً مناسبی در تخمین حداکثر تبخیر و تعرق


جدول 4- مقادیر نمونه‌ی حداکثر تبخیر و تعرق سالانه

سال	حداکثر تبخیر و تعرق سالانه (mm/day)		
	RBF	MLP	PM
57	9/08	9/09	9/08
58	10/05	9/38	9/36
59	9/05	8/89	8/71
60	10/25	9/50	9/96
61	8/51	8/37	8/16
62	9/35	9/30	9/27
63	7/89	7/77	8/31
64	8/42	9/59	9/08
65	8/76	8/66	8/62
66	8/95	8/87	8/85
67	8/86	8/31	8/22
68	7/80	7/90	7/67
69	10/63	10/41	10/67
70	8/64	8/59	8/52
71	8/18	8/40	8/32
72	7/54	7/28	7/51
73	8/96	8/76	8/60
74	8/55	8/46	8/44
75	7/88	7/73	8/42
76	9/86	9/84	9/85
77	9/21	9/32	8/96
78	9/33	9/47	9/28
79	9/40	9/29	9/28
80	10/44	10/01	9/46
81	9/36	9/49	9/43
82	9/02	9/07	8/87
83	9/01	9/06	8/87


مطالعه‌ی کومار و همکاران (2002) با هدف تخمین تبخیر و تعرق روزانه‌ی گیاه مرجع انجام پذیرفته است و بدین منظور همواره از شش پارامتر به عنوان ورودی شبکه‌ی **MLP** (همانند سناریوی شماره 1 در تحقیق حاضر) استفاده شده است. محققین مذکور با انتخاب نتایج رابطه‌ی پنمن - مونتیث به عنوان مقادیر هدف، ضریب R^2 را در محدوده‌ی 0/987 تا 0/989 برای کل داده‌ها (آموزش به علاوه‌ی صحت‌سنجی) به دست آورده‌اند. ولی در تحقیق حاضر مقادیر تبخیر و تعرق میانگین ماهانه برای مدل‌سازی با دو نوع شبکه‌ی عصبی (یعنی **MLP** و **RBF**) استفاده شده است و سناریوهای مختلفی با پارامترهای ورودی متفاوت برای دستیابی به شرایط بهینه به کار گرفته شده است.

در مطالعه‌ی دیگری که توسط زانتی و همکاران (2007) صورت گرفت، مشخص شد که شبکه‌های عصبی از نوع **MLP** در برآورد تبخیر و تعرق میانگین ماهانه نسبت به تبخیر و تعرق روزانه از دقت بیشتری برخوردارند. نتایج آنها نشان داده است که در منطقه‌ی مورد مطالعه، می‌توان مقادیر تبخیر و تعرق گیاه مرجع را با استفاده از دو پارامتر دمای حداکثر و دمای حداقل با دقت مناسبی تخمین زد. ولی در مطالعه‌ی حاضر شبکه‌ی بهینه‌ی پیشنهاد شده از دو پارامتر سرعت باد و دمای میانگین برای برآورد تبخیر و تعرق گیاه مرجع استفاده می‌کند. به عبارت دیگر بر اساس یافته‌های این تحقیق، در منطقه‌ی مورد مطالعه دو پارامتر مذکور تاثیر و اهمیت بیشتری در تخمین میزان تبخیر و تعرق متوسط ماهانه دارند. به نظر می‌رسد وجود سرعت‌های نسبتاً زیاد باد (میانگین 6 متر بر ثانیه) در منطقه‌ی تبریز و تاثیر آن بر افزایش پتانسیل تبخیر و تعرق سبب گردیده است که استفاده از پارامتر سرعت باد تاثیر محسوسی بر افزایش دقت مدل ارائه شده داشته باشد.

سالانه برخوردارند، ولی خطای شبکه‌ی **MLP** کمتر از شبکه‌ی **RBF** می‌باشد.



شکل 5- مقایسه حداکثر E_{To} سالانه محاسبه‌شده از روش‌های **PM** و **MLP**



شکل 6- مقایسه حداکثر E_{To} سالانه محاسبه‌شده از روش‌های **PM** و **RBF**

در مجموع با توجه به نتایج حاصل مشخص شد شبکه‌های **MLP** که متداول‌ترین نوع شبکه‌های عصبی در مدل‌سازی سیستم‌های مختلف می‌باشند در مدل‌سازی و تخمین تبخیر و تعرق ماهانه‌ی گیاه مرجع از عملکرد بهتری نسبت به شبکه‌های **RBF** برخوردار است و تنها مزیت شبکه‌های **RBF** نسبت به شبکه‌های **MLP** در تخمین تبخیر و تعرق گیاه مرجع، زمان کوتاه‌تر مورد نیاز برای آموزش می‌باشد.

نتیجه‌گیری

با بررسی‌های صورت گرفته مشخص شد که می‌توان با استفاده از مدل‌های ارائه شده مقدار ETo ماهانه در منطقه‌ی مورد مطالعه را از دو پارامتر دمایی متوسط ماهانه و سرعت باد با دقت قابل قبولی تخمین زد. با وجود اینکه هر دو شبکه‌ی RBF و MLP قادر هستند مقادیر تبخیر و تعرق متوسط ماهانه‌ی گیاه مرجع را با دقت مناسبی تخمین بزنند، ولی دقت شبکه‌های MLP در برآورد مقادیر حداکثر تبخیر و تعرق سالانه بیش از شبکه‌های RBF می‌باشد.

در تحقیق حاضر از دو نوع شبکه‌ی عصبی مصنوعی با عناوین RBF و MLP برای تخمین تبخیر و تعرق گیاه مرجع ایستگاه تبریز مورد استفاده قرار گرفت. در این بررسی برای نخستین بار از شبکه‌های RBF برای تخمین تبخیر و تعرق گیاه مرجع در منطقه‌ی مورد مطالعه استفاده شد. با محاسبه‌ی مقادیر ETo از روش پنمن - مونتیث و در نظر گرفتن این مقادیر به عنوان مقادیر هدف در آموزش شبکه‌های عصبی، شبکه‌های متفاوتی با سناریوهای تعریف‌شده‌ی مختلف ایجاد شد و عملکرد آنها مورد بررسی قرار گرفت.

منابع مورد استفاده

- سلطانی س و مرید س، ۱۳۸۴. مقایسه برآورد تابش خورشید با استفاده از روش‌های هارگریوز - سامانی و شبکه‌های عصبی مصنوعی. دانش کشاورزی، جلد ۱۵، شماره ۱. صفحه‌های ۶۹-۷۸.
- Allen RG, Pereira LS, Raes D and Smith M, 1998. Crop evapotranspiration, guideline for computing water requirements. Irrigation Drainage Paper No.56. FAO, Rome Italy.
- Anonymous, 2007. Neural network toolbox 5, User's guide, 9th printing version 5. The Mathworks Inc. Massachusetts, USA.
- Basheer IA and Hajmeer M, 2000. Artificial neural networks: fundamentals, computing, design, and application. J Microbiologic Meth 43: 3-31.
- Chiew FHS, Kamaladassa NN, Malano HM and MacMahon TA, 1995, Penman-Monteith, FAO-24 reference crop evapotranspiration and class-A pan data in Australia. Agric Water Manage 28: 9-21.
- Haykin S, 1999. Neural networks: A comprehensive foundation. NJ. Prentice-Hall Inc. Englewood Cliffs.
- Jain SK, Singh VP and van Genuchten MTh, 2004. Analysis of soil water retention data using artificial neural networks. J Hydrol Engin ASCE. 9 (5): 415-420.
- Kumar M, Raghuwanshi NS, Singh R, Wallender, WW and Pruitt WO, 2002. Estimating evapotranspiration using artificial neural network. J Irrig Drain Engin ASCE 128 (4): 224-233.
- Rahimi Khoob A, 2008. Comparative study of Hargreaves's and artificial neural network's methodologies in estimating reference evapotranspiration in a semiarid environment. Irrigation Science 26: 253-259.
- Sudheer KP and Jain SK, 2003. Radial basis function neural network for modeling rating curves. J Hydrol Engin ASCE 8 (3): 161-164.
- Zanetti SS, Sousa EF, Oliveira VPS, Almeida FT and Bernardo S, 2007. Estimating evapotranspiration using artificial neural network and minimum climatological data. J Irrig and Drain Engin ASCE 133 (2): 83-89.