

تخمین تبخیر و تعرق پتانسیل روزانه گیاه مرجع چمن با استفاده از شبکه‌های عصبی مصنوعی

محمد شایان نژاد¹ و سید جواد ساداتی نژاد²

تاریخ دریافت: 86/9/3 - تاریخ پذیرش: 87/2/27

چکیده

در این مقاله، کارایی روش شبکه‌های عصبی مصنوعی به منظور تعیین تبخیر و تعرق پتانسیل روزانه (با گیاه مرجع چمن) و مقایسه آن با روش پنمن-مانتیس مورد بررسی قرار گرفته است. برای این کار از اطلاعات اقلیمی و لایسیمتری 5 ساله و پایه زمانی متوسط ده روزه ایستگاه هواشناسی اکباتان واقع در 10 کیلومتری شهر همدان استفاده شده است. ورودی‌های شبکه عصبی، شش پارامتر اقلیمی موثر در تبخیر و تعرق شامل دمای حداقل و حداکثر هوا، رطوبت حداقل و حداکثر هوا، ساعات آفتابی و سرعت باد بوده است. بهترین آرایش شبکه بر اساس حداقل جذر میانگین مربعات خطاها بدست آمد. نهایتاً شبکه ای با یک لایه مخفی و یک نرون، بهترین آرایش شناخته شد. مقدار خطای به دست آمده از شبکه حاصل 0/7 میلی متر در روز و ضریب تعیین برابر با 0/84 بدست آمد. در حالی که خطای روش پنمن-مانتیس 1/2 میلی متر در روز و ضریب تعیین 0/84 برآورد شد. با تحلیل حساسیت مدل شبکه عصبی ساخته شده مشخص گردید که دمای حداقل هوا و رطوبت نسبی حداکثر به ترتیب بیشترین و کمترین تاثیر را داشته است.

واژه های کلیدی: تبخیر و تعرق پتانسیل، شبکه‌های عصبی مصنوعی، پنمن-مانتیس، چمنزار.

1- استادیار گروه آبیاری دانشگاه شهرکرد E-mail: shayannejad@yahoo.com

2- استادیار گروه مهندسی منابع طبیعی دانشگاه شهرکرد

مقدمه

تبخیر و تعرق یکی از اجزاء اصلی سیکل هیدرولوژی است و تعیین صحیح آن برای خیلی از مطالعات از قبیل توازن هیدرولوژیکی آب، طراحی و مدیریت سیستم‌های آبی، شبیه سازی میزان محصول کشاورزی و ارزیابی تولید اکو سیستم های مرتعی و جنگلی از درجه اول اهمیت برخوردار است. تلفات آب به صورت بخار از سطح خاک را تبخیر و از سطح گیاهان را تعرق گویند. از نظر فیزیکی این دو فرایند مشابه هستند زیرا در هر دو صورت تغییر حالت آب از مایع به بخار و انتقال آن به جو رخ می‌دهد. مجموع این دو تلفات را تبخیر و تعرق می‌گویند. حدود 97٪ آبی که در منطقه ریشه گیاه در اختیار آن قرار می‌گیرد، صرف تبخیر و تعرق می‌شود و بر این اساس نیاز آبی گیاهان را برابر با تبخیر و تعرق فرض می‌کنند (4).

برای اندازه‌گیری تبخیر و تعرق هر گیاه از دستگاهی بنام لایسیمتر¹ استفاده می‌شود. به علت این که استفاده از این دستگاه وقت گیر و پرهزینه می‌باشد، محققین مختلف ابتدا روابطی را برای تخمین تبخیر و تعرق پتانسیل ارائه نموده که تابعی از فاکتورهای اقلیمی است. سپس از حاصل ضرب مقادیر تبخیر و تعرق پتانسیل در ضرائب گیاهی، مقدار تبخیر و تعرق واقعی را محاسبه می‌کنند (البته این محاسبه در شرایط بدون تنش آبی² صحیح است).

به‌طور کلی روش های موجود برای تخمین تبخیر و تعرق پتانسیل به سه دسته معادلات تجربی (مانند روش تورنت وایت³، بلینی- کریدل⁴، تورک⁵، جنسن- هیز⁶ و هارگریوز- سامانی⁷)، معادلات انتقال جرم (مانند روش دالتون⁸ و روش آیرودینامیکی⁹) و معادلات ترکیبی (مانند روش نسبت باون¹⁰، روش پنمن¹¹، روش پنمن- مانتیس¹² و روش پنمن- مانتیس- فائو¹³) تقسیم می‌شوند.

در پنج دهه گذشته مطالعاتی روی توسعه روش‌های تخمین تبخیر و تعرق و بهبود روش‌های موجود انجام شده است و تلاش در این جهت هنوز هم ادامه دارد. بعضی از این روش‌ها مانند روش بلینی - کریدل ساده و بعضی مانند روش ترکیبی پنمن (بر اساس فرآیندهای فیزیکی) پیچیده هستند. در روش‌های ترکیبی، دینامیک تبخیر با شدت تشعشعات خالص و مشخصه‌های انتقال آیرودینامیکی سطح ترکیب می‌شود. بعدها مانتیس مقاومت روزنه‌ای گیاه را وارد معادله پنمن نمود و معادله‌ای تحت عنوان معادله پنمن - مانتیس ارائه نمود. بسیاری از دانشمندان مانند آلن¹⁴ (1986) اعتبار این معادله را بررسی کردند. همچنین جنسن¹⁵ و

1-Thornthwaite
2-Blany-Criddle
3-Turc
4-Jensen-Haise
5-Hargreaves-Samani
6-Dalton
7-Aerodynamic
8-Bowen ratio
9-Penman
10-Penman-Monteith
11-Penman-Monteith-FAO
14 - Allen
15 - Jensen

1-Lysimeter
2-water stress

با پیشرفت روش‌های محاسباتی و شبکه‌های عصبی مصنوعی، استفاده از این شبکه‌ها در علوم مختلف مهندسی شروع شد. فرنچ^۳ و همکاران (1992) پیش‌بینی بارندگی بارندگی در مکان و زمان، رگرز و دولاً^۴ (1994)، بهینه‌سازی آبهای زیرزمینی، شوکلا^۵ و همکاران (1996)، طراحی زهکش‌ها زهکش‌ها در حالت غیر ماندگار، یانگ^۶ و همکاران (1996 و 1997)، مهندسی زهکشی اراضی، تیرمالایان و دئو^۷ (1998)، پیش‌بینی سطح آب در رودخانه‌ها، جین^۸ و همکاران (1999) پیش‌بینی جریان آب ورودی به مخازن و پریدا^۹ و همکاران (2006) پیش‌بینی رواناب را با استفاده از شبکه‌های عصبی مصنوعی ارائه دادند. همه این تحقیقات حاکی از بالا بودن کارایی شبکه‌های عصبی مصنوعی در موضوعات مذکور بود.

برتن^{۱۰} و همکاران (2000) با استفاده از شبکه‌های عصبی مصنوعی، تبخیر روزانه از تشتک را با استفاده از 2044 داده از شهرهای مختلف جهان مانند رم طی سال‌های 1992 تا 1996 شامل بارندگی، درجه حرارت، رطوبت نسبی، تشعشعات خورشیدی و سرعت باد با میزان خطای 1/11 میلی‌متر در روز تخمین زدند. ادھیامبو^{۱۱} و همکاران (2001) با استفاده از روش عصبی- فازی، تبخیر و

همکاران (1990)، بیست روش تخمین تبخیر و تعرق را نسبت به نتایج لایسیمتر در یازده ایستگاه در نقاط مختلف جهان با اقلیم‌های متفاوت مقایسه کرده و نتیجه گرفتند که در همه اقلیم‌ها روش پنمن - مانتیس بهترین روش مناسب بود.

تبخیر و تعرق یک پدیده غیر خطی و پیچیده بوده که به عوامل اقلیمی مختلفی بستگی دارد. بنابراین تهیه یک مدل ریاضی برای آن با در نظر گرفتن تمام عوامل اقلیمی مؤثر در آن، کاری مشکل، دارای خطاهای قابل توجه و یا نیاز به اطلاعات زیادی دارد که اندازه‌گیری آنها مشکل و وقت‌گیر است (تراجکویک^۱ و همکاران، 2003). از این گذشته این عوامل اقلیمی روی یکدیگر تاثیر متقابل دارند که در مدل‌های ریاضی نمی‌توان این مسئله را وارد نمود. بنابراین با توجه به ماهیت مسئله تبخیر و تعرق، استفاده از شبکه‌های عصبی مصنوعی (ANN) برای تعیین آنها مناسب است.

بطور کلی شبکه‌های عصبی مصنوعی، ابزار مؤثری برای مدل کردن سیستم‌های غیرخطی هستند. زیرا این شبکه‌ها نیاز به رابطه ریاضی از پیش تعیین شده برای مدل نمودن پدیده پیچیده مورد بررسی ندارند. هر شبکه عصبی مصنوعی شامل یک لایه ورودی، یک لایه خروجی بوده و در بین این دو لایه، یک یا چند لایه مخفی قرار می‌گیرد. در هر لایه یک یا چند نرون^۲ وجود داشته که مجموعاً شبیه یک شبکه عصبی بیولوژیک عمل می‌کنند.

3 - French

4 - Rogers & Dowl

5 - Shukla

6 - Yang

7 - Thirumalaian & Deo

8 - Jain

9 - Parida

10 - Bruton

11 - Odhiambo

1 - Trajkovic

2 - Neuron

شده، به طور متوسط 0/994 بود. حق وردی و همکاران (1386) با استفاده از روش شبکه های عصبی مصنوعی، تبخیر از تشتک را تخمین زدند. بهترین شبکه طراحی شده برای این کار دارای 9 نرون در لایه مخفی بود. جمع بندی سوابق تحقیق نشان می دهد که مطالعه در خصوص تبخیر و تعرق جوامع گیاهی مرتعی بسیار کم مورد توجه قرار گرفته حال آن که بررسی این موضوع خصوصا در چمنزارها از اهمیت زیادی برخوردار است. از این رو در تحقیق حاضر سعی بر آن بوده است که تخمین تبخیر و تعرق پتانسیل چمن در همدان به دلیل وجود اطلاعات با استفاده از شبکه های عصبی مصنوعی به عنوان ابزاری کارآمد در مدل سازی اجزای مختلف چرخه آب صورت پذیرد.

مواد و روش ها

داده های مورد استفاده

اطلاعات مورد نیاز این تحقیق از ایستگاه هواشناسی اکباتان واقع در 10 کیلومتری شهر همدان بدست آمد. این ایستگاه دارای طول جغرافیائی 48 درجه و 32 دقیقه شمالی و عرض جغرافیائی 52 درجه و 34 دقیقه شرقی و ارتفاع 1730 متر از سطح دریا می باشد (شکل 1). این منطقه دارای آب و هوای نیمه خشک و سرد است.

حداکثر و حداقل دما به ترتیب 40 و 34- درجه سانتی گراد است. میانگین بارش سالانه آن در دوره آماری 1363 الی 1383 برابر با 312/3 میلی متر گزارش شده است. اطلاعات اقلیمی مورد نیاز این تحقیق به صورت

تعرق مرجع چمن را با کمک داده های ورودی شامل تشعشعات خورشیدی، رطوبت نسبی، سرعت باد و درجه حرارت تخمین زدند. میزان خطای محاسبه شده با این روش برابر با 0/48 میلی متر در روز بوده و میزان خطای به دست آمده از روش پنمن-مانتیس-فائو برابر با 0/56 میلی در روز بوده است.

کومار¹ و همکاران (2002) با استفاده از شبکه های عصبی مصنوعی تبخیر و تعرق مرجع چمن را تخمین زدند. در این مطالعه داده های اقلیمی نرمال شده شامل حداقل و حداکثر درجه حرارت هوا، حداقل و حداکثر رطوبت نسبی هوا، سرعت باد و تشعشعات خورشیدی از دیویس کالیفرنیا جمع آوری شده و به عنوان داده های ورودی استفاده شدند. نهایتاً شبکه ای با یک لایه ورودی (با 6 نرون)، یک لایه مخفی (با 7 نرون) و یک لایه خروجی (با یک نرون) بهترین نتایج را داده است. به طوری که مقدار خطا کمتر از 0/6 میلی متر در روز بود در حالی که مقدار خطای روش پنمن-مانتیس برای داده های این تحقیق برابر با 0/97 میلی متر در روز بود. تراجکویس و همکاران (2003) برای پیش بینی تبخیر و تعرق مرجع از روش شبکه های عصبی مصنوعی با یک لایه ورودی و دو نرون استفاده نمودند.

بدین صورت که برای پیش بینی تبخیر و تعرق در روز آینده، از مقادیر تبخیر و تعرق 11 و 23 روز قبل استفاده نمودند. نسبت تبخیر و تعرق پیش بینی شده به اندازه گیری

سانتیمتر مکعب و دارای خاصیت قلیائی می باشد. کف لایسیمتر جهت خروج زهاب شیبدار بوده و به ضخامت 20 سانتیمتر از شن ریز و درشت پر شده و روی آن لایه های خاک به تفکیک افق ها اضافه شده است. میزان تبخیر و تعرق پتانسیل با اندازه گیری میزان آب ورودی، میزان زهاب و رطوبت خاک در هر روز و با استفاده از توازن آب در لایسیمتر طی سالهای 1373 الی 1377 اندازه گیری شده است.

میانگین ده روزه و شامل دمای حداکثر و حداقل هوا، رطوبت حداقل و حداکثر هوا، سرعت باد و ساعات آفتابی بوده است. در این ایستگاه برای اندازه گیری تبخیر و تعرق پتانسیل (با گیاه مرجع چمن) از یک لایسیمتر زهکش دار به ابعاد $1 \times 2/25 \times 1/2$ متر استفاده شد. خاک محل احداث لایسیمتر، عمیق، دارای بافت متوسط تا سنگین، با شوری 0/35 تا 0/61 دسی زیمنس بر متر، دارای وزن مخصوص ظاهری بین 1/74 تا 1/91 گرم بر

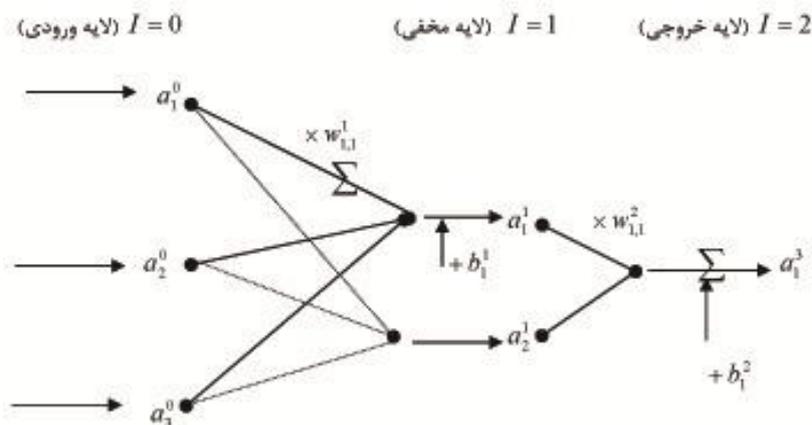


شکل 1: نقشه استان همدان و موقعیت ایستگاه های آن

دو لایه تشکیل می شود (یک لایه ورودی و یک لایه خروجی) ولی می تواند چندین لایه مخفی بین لایه های ورودی و خروجی قرار گیرد شبکه ای که بدین صورت بدست می آید

طراحی شبکه عصبی مصنوعی (ANN)
شبکه های عصبی مصنوعی از تعدادی نرون تشکیل شده اند که به صورت لایه ای در کنار یکدیگر قرار می گیرند. هر شبکه حداقل از

به شبکه چند لایه ای پرسپترون¹ (MLP) معروف است. در هر لایه از این شبکه تعدادی



شکل 2: نمونه ای از شبکه عصبی مصنوعی چند لایه ای پرسپترون

$$n_i^I = \sum_{j=1}^{N_{I-1}} a_j^{I-1} \cdot w_{i,j}^I + b_i^I \quad (2)$$

که در روابط فوق، a_i^I نرون i در لایه I ام، $w_{i,j}^I$ وزن آمده از j امین عنصر لایه $(I-1)$ ام به i امین عنصر لایه I ام، b_i^I جمله بایاس مربوط به i امین عنصر لایه I ام، N_{I-1} تعداد نرون در لایه $(I-1)$ ام و f تابع محرک می باشد. این تابع معمولاً یک تابع تانژانت هیپربولیک، سیگموئید و یا یک تابع خطی است (کومار و همکاران، 2002). بنابراین میتوان تمام عناصر لایه مخفی و نهایتاً عناصر لایه خروجی را محاسبه نمود. این کار برای تمام مجموعه داده های ورودی و خروجی انجام میشود.

پس از این که تمام خروجی ها بدست آمد، با مقادیر واقعی (اندازه گیری شده) آنها مقایسه و مقدار خطا² (RMSE) از رابطه زیر محاسبه میشود (کومار و همکاران، 2002):

نرون وجود دارد. یکی از انواع شبکه های عصبی مصنوعی، شبکه های با ناظر می باشد. در این تحقیق از این نوع شبکه ها استفاده شده است. جهت آموزش در این شبکه ها، وزن های داده شده به نرون به نحوی تنظیم می شود که نزدیکترین مقدار خروجی را نسبت به مقدار مشاهده ای تولید کند.

در شکل 2 نمونه ای از شبکه عصبی چند لایه ای پرسپترون ترسیم شده است. این شبکه دارای یک لایه ورودی (با سه نرون)، یک لایه مخفی (با دو نرون) و یک لایه خروجی (با یک نرون) می باشد. چگونگی رسیدن از سه ورودی به یک خروجی، با دادن وزن های مختلف به نرون و استفاده از یک تابع محرک² به صورت زیر انجام می شود:

$$a_i^I = f(n_i^I) \quad (1)$$

2- Root Mean Square of Error

1-Multiple Layer Preceptron
1- activation function

$$RMSE = \sqrt{\sum_{k=1}^N (C_k - M_k)^2 / N} \quad (3)$$

که در آن N = تعداد مجموعه داده‌ها، C = مقدار خروجی محاسبه شده از شبکه عصبی مصنوعی و M = مقدار خروجی اندازه‌گیری شده (واقعی)

بر اساس مقدار خطای بدست آمده مقادیر وزن‌ها و جملات بایاس اصلاح خواهد شد.

کلیه محاسبات با نرم افزار کامپیوتری MATLAB نسخه 7 انجام شد. در این تحقیق با استفاده از نرم افزار مذکور و با انتخاب یک شبکه MLP تبخیر و تعرق پتانسیل محاسبه گردید. تعداد نرون در لایه ورودی (برابر متغیرهای ورودی) 6 فاکتور اقلیمی موثر در تبخیر و تعرق پتانسیل میباشد که عبارتند از: دمای حداقل هوا، دمای حداکثر هوا، رطوبت نسبی حداقل هوا، رطوبت نسبی حداکثر هوا، ساعات آفتابی و سرعت باد. لایه خروجی دارای یک نرون است که همان تبخیر و تعرق پتانسیل می‌باشد. برای هر یک از مراحل آموزش و تایید 50 درصد داده‌ها به صورت تصادفی استفاده شده است. لازم به ذکر است که داده‌ها با استفاده از رابطه 8 بین صفر تا یک استاندارد شده اند.

$$X_n = \frac{X_{\max} - X}{X_{\max} - X_{\min}} \quad (8)$$

که در رابطه فوق: X = داده معمولی، X_n = داده استاندارد، X_{\max} = ماکزیمم داده‌ها در هر ستون (یا سطر)

X_{\min} = مینیمم داده‌ها در هر ستون (یا سطر).

معادله پنمن-مانتیس

معادله پنمن-مانتیس به صورت زیر است:

$$ET_a = \frac{\Delta(R_n - G) + \rho_a C_p (e_s - e_a) / r_a}{\Delta + (1 + r_c / r_a) \cdot \gamma} \quad (9)$$

در رابطه فوق، Δ = شیب منحنی رابطه بین فشار بخار اشباع و درجه حرارت میانگین هوا، G = انرژی که موجب تغییر دمای خاک می‌شود. ρ_a = جرم مخصوص هوا، C_p = گرمای ویژه هوا در فشار ثابت، e_s = فشار بخار اشباع هوا، e_a = فشار بخار واقعی هوا، r_a = مقاومت آیرودینامیکی هوا و γ = ثابت سایکرومتری.

آنالیز حساسیت

برای بررسی نقش هر یک از پارامترهای ورودی در کنترل تبخیر و تعرق پتانسیل روزانه، از دو روش حذف یا اضافه کردن پارامترهای ورودی استفاده شد. ملاک تاثیر آنالیز مذکور میزان تغییرات ایجاد شده در مقدار RMSE نتایج بوده که نهایتاً منجر به ارزیابی متغیرها می‌شود. بر این اساس هر پارامتری که اضافه کردن آن بیشترین کاهش را در RMSE یا حذف آن بیشترین افزایش را در RMSE داشته باشد، حساس‌ترین پارامتر می‌باشد. در این تحقیق از روش حذف متغیر برای انجام آنالیز حساسیت استفاده شده است. برای این کار در هر مرحله از بین شش پارامتر ورودی، یکی از آنها حذف شده و مقدار

مساوی برای مراحل آموزش و تایید تقسیم و در برنامه MATLAB استفاده شد. نهایتاً بهترین شبکه عصبی برای 6 ورودی با مشخصات مندرج در جدول (1) بدست آمد. شبکه حاصل در شکل (3) این شبکه نمایش داده شده است. این شبکه با انجام سعی و خطا روی تعداد لایه های مخفی و تعداد نرون در هر لایه بدست آمده است.

RMSE محاسبه گردید. منظور از حذف یک پارامتر این است که بدون آن پارامتر تمام مراحل آموزش و تایید شبکه تکرار می شود.

نتایج و بحث

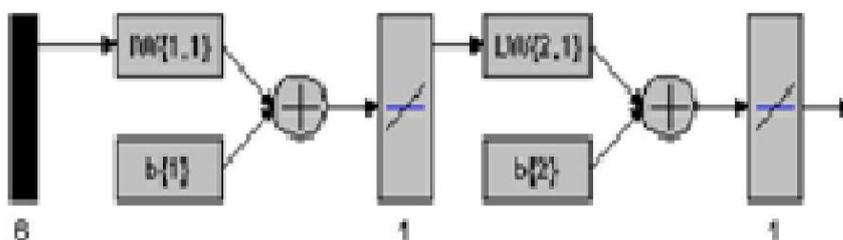
مشخصات شبکه عصبی انتخاب شده و مقایسه خطای آن با روش پنمن-مانتیس اطلاعات اقلیمی و لایسیمتری سالهای 1373 تا 1377 بطور تصادفی به دو قسمت

جدول 1: مشخصات بهترین شبکه عصبی بدست آمده برای تخمین تبخیر و تعرق پتانسیل روزانه در جمنزار مورد مطالعه

نوع لایه	تعداد نرون	ماهیت نرونها	روش آموزش	تابع محرک	RMSE
ورودی	6	دما و رطوبت حداقل و حداکثر هوا، سرعت باد و ساعات آفتابی	انتشار به عقب	خطی	0/7426
مخفی	1	-			میلیمتر در روز
خروجی	1	تبخیر و تعرق پتانسیل			

شکل (5) مقادیر تبخیر و تعرق اندازه گیری شده و محاسبه شده با روش پنمن-مانتیس (P-M) ارائه شده است.

در شکل (4) مقادیر تبخیر و تعرق اندازه گیری شده و محاسبه شده توسط شبکه عصبی مصنوعی جدول (1) و همچنین در



شکل 3: نمایش بهترین شبکه عصبی بدست آمده جهت تخمین تبخیر و تعرق پتانسیل روزانه در جمنزار مورد مطالعه

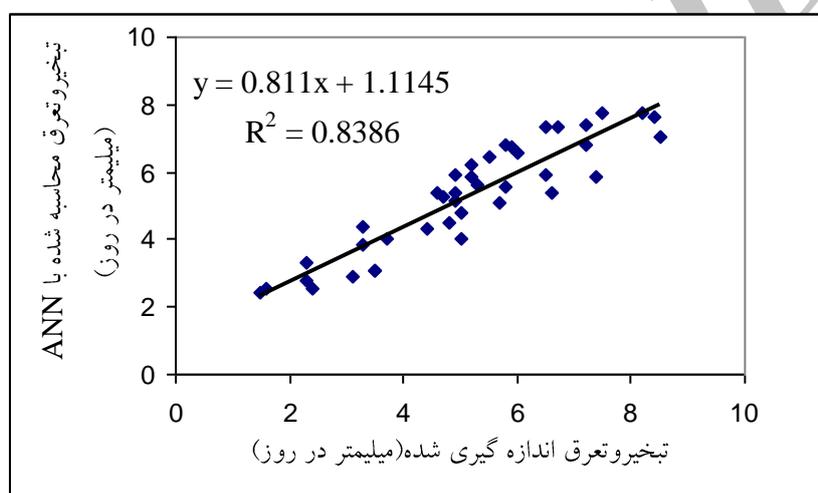
پنمن-مانتیس با خطای تخمین 1/206 میلی متر در روز بیشتر است. این در حالی است که تحقیقات انجام شده توسط جنسن و همکاران

با توجه به شکل های (4) و (5) مشخص می شود که دقت روش شبکه های عصبی مصنوعی با خطای تخمین 0/726 از روش

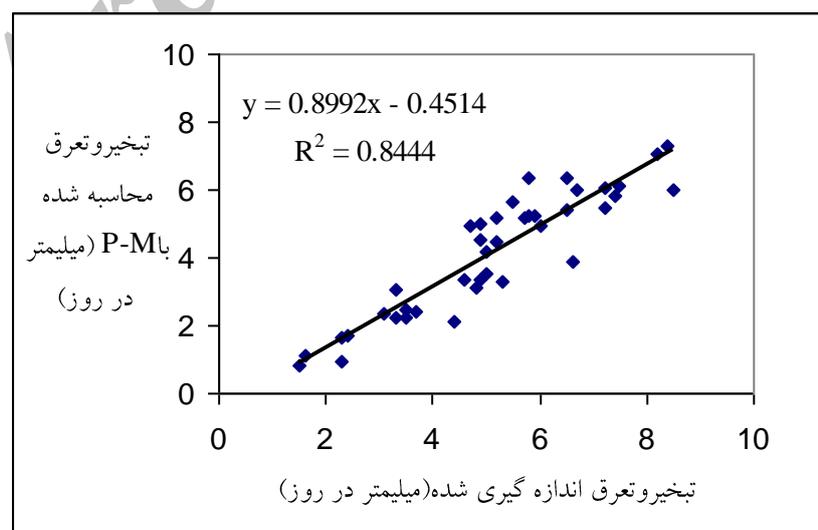
بنابراین نمی توان گفت که چون ضریب همبستگی در شکل (5) بیشتر از شکل (4) است، روش پنمن-مانتیس دقیق تر از روش شبکه های عصبی مصنوعی است. در حالی که میزان خطای روش شبکه های عصبی مصنوعی کمتر از روش پنمن-مانتیس است. پس روش روش شبکه های عصبی مصنوعی دقیق تر از روش پنمن-مانتیس است.

نشان می دهد که از بین بیست روش تخمین تبخیر و تعرق در یازده ایستگاه در نقاط مختلف جهان با اقلیمهای متفاوت، برای همه اقلیمها روش پنمن - مانتیس بهترین روش بوده است.

ضریب همبستگی در اشکال (4) و (5) بیانگر میزان همبستگی بین دو متغیر (و نه میزان نزدیکی بین آنها) را نشان می دهد.



شکل 4: مقادیر تبخیر و تعرق اندازه گیری شده و محاسبه شده توسط شبکه عصبی مصنوعی



شکل 5: مقادیر تبخیر و تعرق اندازه گیری شده و محاسبه شده با روش پنمن-مانتیس

Archive of SID

هواشناسی و لایسیمتری این ایستگاه در طی سال‌های 1994 الی 1998 میلادی استفاده شد. مقدار خطای بدست آمده 7/6 میلی‌متر در روز بدست آمد.

بررسی آنالیز حساسیت

نتایج بررسی آنالیز حساسیت در جدول (2) ارائه گردیده است. با توجه به جدول مذکور مشاهده می‌شود که با حذف دمای حداقل، بیشترین افزایش در RMSE ایجاد شده است. بنابراین دمای حداقل بعنوان حساس‌ترین پارامتر محسوب می‌شود. همچنین با حذف رطوبت نسبی حداکثر، بیشترین کاهش در RMSE ایجاد شده است. در این حالت میزان خطا از حالتی که شش پارامتر ورودی وجود دارد نیز کمتر است. بنابراین رطوبت نسبی حداکثر، بعنوان پارامتری با کمترین حساسیت محسوب می‌شود. درجه حساسیت همه پارامترها در جدول (3) ارائه شده است.

با توجه به این که خط رگرسیون در شکل (4) حول محور قطر مستطیل چرخیده است، می‌توان نتیجه گیری نمود که روش شبکه‌های عصبی مصنوعی در مقادیر پائین تبخیر و تعرق را بیشتر و در مقادیر بالای تبخیر و تعرق، آن را کمتر حد تخمین می‌زند. با توجه به این که در شکل (5) خط رگرسیون تقریباً موازی قطر مستطیل و پائین‌تر از آن قرار دارد، میتوان نتیجه گیری نمود که روش پنمن-مانتیس تبخیر و تعرق را کمتر از حد تخمین می‌زند. با مقایسه شبکه طراحی شده در این تحقیق (دارای یک لایه مخفی با یک نرون) و شبکه ای که کومار و همکاران (2002) (دارای یک لایه مخفی با 7 نرون) طراحی کردند، نتیجه‌گیری می‌شود که نمی‌توان برای همه نقاط یک شبکه عصبی مشترکی را استفاده نمود. برای اثبات این موضوع، شبکه طراحی شده در این تحقیق برای تخمین تبخیر و تعرق ایستگاه لایسیمتری اهواز مورد استفاده قرار گرفت. برای این منظور از داده‌های

جدول 2: نتایج آنالیز حساسیت

پارامترهای ورودی بترتیب از چپ به راست	RMSE(mm/day)
¹ Tmin, Tmax, Rhmin, Rhmax, U, n	0/743
Tmin, Tmax, Rhmin, Rhmax, n	0/761
Tmin, Tmax, Rhmin, Rhmax, U	0/842
Tmin, Tmax, Rhmin, U, n	0/675
Tmin, Tmax, Rhmax, U, n	0/742
Tmin, Rhmin, Rhmax, U, n	0/738
Tmax, Rhmin, Rhmax, U, n	0/918

جدول 3: درجه حساسیت پارامترهای مختلف

1- به ترتیب عبارتست از ساعات آفتابی، سرعت باد، رطوبت نسبی حداکثر، رطوبت نسبی حداقل، دمای حداکثر هوا و دمای حداقل هوا

نام پارامتر	Tmin	n	U	Rhmin	Tmax	Rhmax
درجه حساسیت	1	2	3	4	5	6

بررسی تغییر پارامترهای ورودی بر روی خطا
در این قسمت بعضی از متغیرهای ورودی تغییر و یا تعدادشان کاهش یافته است. نتایج این کار در جدول (4) ارائه شده است. نتایج این جدول از مدل شبکه عصبی با مشخصات جدول (1) بدست آمده است.

بررسی دقیق ارزیابی حساسیت خروجی به پارامترهای ورودی نشان می‌دهد که عوامل اقلیمی موثر در تبخیر و تعرق بترتیب اولویت شامل دمای حداقل هوا، ساعات آفتابی، سرعت باد، رطوبت نسبی حداقل هوا، دمای حداکثر هوا و رطوبت نسبی حداکثر هوا می‌باشد.

جدول 4: نتایج حاصل از تغییر پارامترهای ورودی بر روی خطا

پارامترهای ورودی بترتیب از چپ به راست	RMSE(mm/day)
Tmean, Rhmax, Rhmin, U, n	0/809
Tmin, Tmax, Rhmean, U, n	0/717
Tmean, Rhmean, U, n	0/698

در جدول فوق $Tmean=(Tmax+Tmin)/2$ و $Rhmean=(Rhmax+Rhmin)/2$

نتایج تحقیق دلالت بر توانایی شبکه های عصبی مصنوعی در تخمین تبخیر و تعرق پتانسیل روزانه در پوشش مرتعی چمنزار داشته و دقت آن در مقایسه با روش پنمن-مانتیس بیشتر است. بر اساس نتایج بدست آمده از تحقیق حاضر می توان جمع بندی نمود که توسعه روش های کاربردی مدلسازی از قبیل شبکه های عصبی مصنوعی می تواند زمینه ساز مدیریت صحیح منابع آبی در اکوسیستم های مرتعی باشد. البته جمع بندی نهایی نیازمند انجام مطالعات گسترده در سایر جوامع گیاهی می باشد.

سپاسگزاری

بدینوسیله مراتب سپاس محققان از مساعدت و همکاری های معاونت های محترم پژوهشی و مالی دانشگاه شهرکرد و همچنین

با توجه به جدول (4) مشاهده می‌شود که جایگزین دمای متوسط به جای دماهای حداکثر و حداقل، سبب افزایش خطا می‌شود در حالیکه جایگزین رطوبت متوسط به جای رطوبت های حداکثر و حداقل و حتی وارد کردن همزمان دما و رطوبت به صورت متوسط، سبب کاهش خطا می‌گردد.

نتیجه گیری و پیشنهادات

در این مقاله یک شبکه عصبی مصنوعی برای تخمین تبخیر و تعرق پتانسیل ایستگاه هواشناسی اکباتان واقع در 10 کیلومتری همدان برای یک پوشش گیاهی مرجع چمنی طراحی شد. خطای بدست آمده با استفاده از این شبکه 0/74 میلیمتر در روز بدست آمد. در حالی که مقادیر خطا در مراجع شماره 3، 8 و 14 بترتیب برابر با 1/11، 0/6 و 0/994 میلی‌متر در روز گزارش شده است. بهر جهت

از مرکز تحقیقات کشاورزی و منابع طبیعی استان همدان ابراز می گردد.

منابع

1. Allen, R. G. 1986. A panman for all season, J. Irrig. & Drain., ASCE. 112(4): 348-368.
2. Bruton, J. M., R. W. McClendon & G. Hoogenboom. 2000. Estimating daily pan evaporation with artificial neural network. Trans. ASAE. 43(2):492-496.
3. Doorenbos, J. & W.O. Pruitt. 1977. Guidelines for predicting crop water requirements, Irrigation Drainage Paper No. 24. FAO. Rome. Italy.
4. French, M.N., W.F. Krayewski and R. R. Cuykendall. 1992. Rainfall forecasting in space and time using a neural networks, J. Hydrol. 137: 1-37.
- 5.
6. Jain, S.K., A. Das, & D. K. Srivastava. 1999. Application of ANN for reservoir inflow prediction and operation, J. Water Res. Plan. Manage. 125(5): 263-271.
7. Jensen, M.E., R. D. Burman & R. G. Allen. 1990. Evapotranspiration and irrigation water requirements, ASCE Manual and Report on Engineering Practice No. 70. New York.
8. Haghwerdi A., Mohsenimovahhed, A. & Mohammadi K., 1386. Estimation of pan evaporation using artificial neural networks, 9th Seminar on Irrigation and evaporation, Kerman University, Iran. (in persian).
9. Kumar, M., N. S. Raghuvanshi, R. Singh, W. W. Wallender, & W. O. Pruitt. 2002. Estimating evapotranspiration using artificial neural networks, J. Irrig. And Drain. ASCE. 128(4):224-233.
10. Odhiambo, L. O., R. E. Yoder, D. C. Yoder & J.W. Hines. 2001. Optimization of fuzzy evaporation model through neural training with input-output examples. Trans. ASAE. 44(6):1625-1633.
11. Parida, B. P., D.B. Moalafhi & P.K. Kenabatho. 2006. Forecasting runoff coefficients using ANN for water resources management: The case of Notwan catchment in Eastern Botswana, Physics and Chemistry of the Earth, Part A/B/c, 31(15):928-934.
12. Rogers, L.L. & F. U. Dowla. 1994. Optimization of groundwater remediation using artificial neural networks with parallel solute transport modelling, Water Resour. Res. 30(2): 457-481.
13. Shukla, M.B., R. Kok, S. O. Prasher, G. Clark, & R. Lacroix. 1996. Use of artificial neural network in transient drainage design, Trans. ASAE. 39(1):119-124.
14. Thirumalaian, K. and M. C. Deo. 1998. River stage forecasting using artificial neural network, J. Hydrol. Eng. 3(1):26-32.
15. Trajkovic, S., B. Todorovic & M. Standkovic. 2003. Forecasting of reference evapotranspiration by artificial neural network, J. Irrig. And Drain., ASCE. 129(6): 454-457.
16. Yang, C. C., S. O. Prasher & R. Lacroix. 1996. Application of artificial neural network to land drainage engineering. Trans. ASAE. 39(2):525-533.

17. Yang, C. C., S. O. Prasher, R. Lacroix S. Sreekanth, N. K. Patni & L. Masse. 1997. Artificial neural network model for subsurface-drained farmlands, J. Irrig. and Drain, ASCE.123(4): 285-292.

Archive of SID