



دانشگاه گوارز و منابع آب

نشریه پژوهش‌های حفاظت آب و خاک

جلد بیستم، شماره پنجم، ۱۳۹۲

<http://jwsc.gau.ac.ir>

مدل‌سازی تبخیر- تعرق گیاه پتانسیل با استفاده از شبکه عصبی مصنوعی با حداقل متغیرهای اقلیمی در ایستگاه سینوپتیک مشهد

*سمیرا نوری^۱، غلامعباس فلاح‌قاله‌ری^۲ و سیدحسین ثنائی‌نژاد^۳

^۱دانشجوی کارشناسی ارشد گروه مهندسی آب، دانشگاه فردوسی مشهد، ^۲دانشجوی دکتری گروه اقلیم‌شناسی، دانشگاه اصفهان و عضو گروه پژوهشی اقلیم‌شناسی کاربردی پژوهشکده اقلیم‌شناسی مشهد، ^۳دانشیار گروه مهندسی آب، دانشگاه فردوسی مشهد
تاریخ دریافت: ۸۹/۲/۱؛ تاریخ پذیرش: ۹۱/۹/۱۵

چکیده

برآورد تبخیر- تعرق پتانسیل در مواردی مانند برنامه‌ریزی آبیاری، توازن هیدرولوژیکی، طراحی و مدیریت سیستم‌های آبیاری و پیش‌بینی میزان عملکرد محصول ضروری است. تعداد زیاد پارامترهای مؤثر در برآورد تبخیر- تعرق گیاه پتانسیل و از طرفی اندازه‌گیری برخی از این پارامترها در بعضی ایستگاه‌ها، سبب گردیده تا امکان برآورد دقیق آن میسر نباشد. بنابراین در این مقاله، امکان کاربرد شبکه عصبی مصنوعی در برآورد تبخیر- تعرق گیاه پتانسیل با حداقل پارامترهای اقلیمی مورد بررسی قرار گرفته است. به این منظور از شبکه عصبی پرسپترون چندلایه با قانون پس‌انتشار خطا و داده‌های ماهانه دمای حداکثر، دمای حداقل، رطوبت نسبی، سرعت باد و تعداد ساعات آفتابی ایستگاه هواشناسی سینوپتیک مشهد، طی دوره آماری ۲۰۰۵-۱۹۵۱ به‌عنوان ورودی مدل استفاده گردید. همچنین روش فائو پنمن- مانیتث ۵۶ برای برآورد تبخیر- تعرق پتانسیل و استفاده به‌عنوان خروجی مدل به‌کار گرفته شد. برای ارزیابی کارایی روش شبکه‌های عصبی مصنوعی تحت شرایط نبود برخی پارامترهای اقلیمی، نتایج به‌دست آمده با برآوردهای به‌دست آمده از روش‌های هارگریوز- سامانی، بلانی- کریدل، پریستلی- تیلور و ماکینک مقایسه گردید. نتایج نشان‌دهنده کارایی بهتر شبکه‌های عصبی مصنوعی نسبت به روش‌های تجربی در برآورد تبخیر- تعرق گیاه پتانسیل می‌باشد. براساس نتایج به‌دست آمده، در صورت کمبود پارامترهای اقلیمی، تنها با اندازه‌گیری دمای حداقل و حداکثر و محاسبه تابش فرازمینی می‌توان با خطایی معادل ۰/۲۸۶ میلی‌متر در روز، برآورد مناسبی از تبخیر- تعرق گیاه پتانسیل با استفاده از شبکه‌های عصبی مصنوعی در منطقه مورد مطالعه به‌دست آورد.

واژه‌های کلیدی: تبخیر- تعرق پتانسیل، دما، شبکه عصبی مصنوعی، قانون آموزش پس‌انتشار خطا

*مسئول مکاتبه: noori.samira@gmail.com

مقدمه

با توجه به میزان اندک نزولات جوی و محدودیت منابع آب در ایران، مدیریت صحیح منابع آب از اهمیت زیادی برخوردار بوده و لازم است که در استفاده از آب دقت لازم به عمل آید. در این راستا تعیین نیاز آبی گیاهان قدم اساسی در هر طرح آبیاری و زه‌کشی است و لازمه آن محاسبه تبخیر-تعرق پتانسیل سطوح گیاهی برای منطقه طرح می‌باشد.

تاکنون روش‌های گوناگونی برای اندازه‌گیری و برآورد تبخیر-تعرق پتانسیل ارائه شده است. دقیق‌ترین روش به‌دست آوردن تبخیر-تعرق پتانسیل، استفاده از لایسی‌متر است که البته این روش به دلیل زمان‌بر بودن و هزینه زیاد مقرون به صرفه نمی‌باشد، بنابراین پژوهش‌گران بسیاری تلاش نمودند تا با ایجاد رابطه‌های مختلف برآورد این مؤلفه مهم سیکل هیدرولوژی را سهل‌تر نمایند (کومار و همکاران، ۲۰۰۲). سازمان خواروبار جهانی (فائو)^۱، در نشریه ۵۶، رابطه پنمن-مانتیث را که دارای اساس فیزیکی است به‌عنوان روش مناسب برای برآورد تبخیر-تعرق پتانسیل پیشنهاد نموده است (آلن و همکاران، ۱۹۹۸). پژوهش‌گران بسیاری از این روش برای برآورد تبخیر-تعرق پتانسیل استفاده نموده‌اند. جنسن و همکاران (۱۹۹۰) طی پژوهشی ۲۰ روش متفاوت برآورد تبخیر-تعرق پتانسیل را با اندازه‌گیری‌های لایسی‌متری به‌دست آمده از ۱۱ ایستگاه در مناطق اقلیمی مختلف در سرتاسر جهان مقایسه نمودند و در نهایت دریافتند که روش پنمن-مانتیث، بهترین روش در همه مناطق اقلیمی بوده است.

از آن‌جا که تبخیر-تعرق پدیده‌ای غیرخطی و پیچیده است و پارامترهای هواشناسی بسیاری در برآورد آن مؤثرند و از طرفی به‌علت اندازه‌گیری نکردن برخی از این متغیرها در بعضی نقاط، امروزه کارشناسان تمایل دارند از روش‌هایی که بتوانند برآورد تبخیر-تعرق پتانسیل را با حداکثر دقت و حداقل تعداد پارامترهای مورد نیاز انجام دهند، استفاده نمایند (وانگ و همکاران، ۲۰۰۸). البته رابطه‌های تجربی بسیاری از جمله هارگریوز و بلانی کریدل برای برآورد تبخیر-تعرق پتانسیل پیشنهاد شده‌اند که نیاز به پارامترهای ورودی کمی دارند اما این رابطه‌ها در همه نواحی اقلیمی دقت خوبی ندارند، بنابراین استفاده از آن‌ها با خطای زیادی همراه است (جنسن و همکاران، ۱۹۹۷).

شبکه‌های عصبی مصنوعی^۲ ابزاری مؤثر برای مدل کردن سیستم‌های غیرخطی هستند. زیرا این شبکه‌ها نیازی به رابطه ریاضی برای پدیده پیچیده مورد بررسی ندارند (کومار و همکاران، ۲۰۰۲).

1- Food and Agriculture Organization

2- Artificial Neural Network

تاکنون مطالعات زیادی در رابطه با قابلیت استفاده از شبکه‌های عصبی مصنوعی برای برآورد تبخیر-تعرق پتانسیل در سطح جهان انجام شده است (اکسوی و همکاران، ۲۰۰۷؛ تراچکویک و همکاران، ۲۰۰۳؛ چائوهان و شریواستاوا، ۲۰۰۹).

سودهیر و همکاران (۲۰۰۲) از مقادیر تبخیر به‌دست آمده از تست تبخیر به‌عنوان خروجی و داده‌های روزانه دمای حداقل و حداکثر، رطوبت نسبی حداقل و حداکثر، تعداد ساعات آفتابی و سرعت باد به‌عنوان ورودی شبکه عصبی مصنوعی استفاده کردند. نتایج آن‌ها نشان داد که چنان‌چه از تمامی پارامترهای نام برده به‌عنوان ورودی استفاده شود بهترین نتایج به‌دست می‌آید. همچنین آن‌ها بیان کردند که استفاده از مقادیر میانگین پارامترهای ورودی به‌جای مقادیر حداقل و حداکثر، تأثیر معنی‌داری در کاهش دقت مقادیر خروجی ندارد. زنتی و همکاران (۲۰۰۷) نیز تنها با استفاده از دمای هوا، تابش فرازمینی و ساعات آفتابی روزانه توانستند به نتایج قابل‌قبولی در زمینه برآورد ET دست یابند.

در پژوهشی که در شمال اسپانیا انجام شد نتایج تبخیر-تعرق پتانسیل به‌دست آمده از روش شبکه عصبی مصنوعی در ۴ ایستگاه هواشناسی با تغییر در تعداد پارامترهای ورودی مورد بررسی قرار گرفت. نتایج نشان داد که در صورت استفاده از پارامتر دما، می‌توان تبخیر-تعرق پتانسیل را در تمامی ایستگاه‌ها به‌خوبی برآورد نمود (لاندراس و همکاران، ۲۰۰۸).

در بررسی که توسط وانگ و همکاران (۲۰۰۸) در منطقه بورکینافاسو در آفریقا انجام شد، نتایج نشان داد که شبکه عصبی مصنوعی با داده‌های دمای حداکثر، دمای حداقل و تابش فرازمینی به‌عنوان ورودی، در مقایسه با روش بلانی-کریدل و هارگریوز در نواحی با اقلیم نیمه‌خشک از دقت بیشتری برخوردار است. در ایران نیز مطالعات زیادی پیرامون استفاده از شبکه‌های عصبی مصنوعی برای برآورد تبخیر و تعرق شده است. شایان‌نژاد (۲۰۰۷) در مقایسه‌ای که بین نتایج روش فائو پنمن-مانتیث ۵۶ و شبکه‌های عصبی در همدان انجام داد، دریافت که شبکه‌های عصبی مصنوعی قادرند با مقدار خطایی معادل ۰/۷ میلی‌متر در روز موفق‌تر عمل کنند. در پژوهشی دیگر که توسط کوچک‌زاده و بهمنی (۲۰۰۶) در تهران انجام شد، ایشان بیان کردند در صورت کمبود پارامترهای اقلیمی، شبکه‌های عصبی مصنوعی قادرند در مقایسه با روش‌های تجربی هم‌چون بلانی-کریدل، جنسن-هیز و هارگریوز-سامانی برآوردهای بهتری از تبخیر-تعرق پتانسیل ارائه کنند.

تعدد پارامترهای مؤثر در برآورد تبخیر- تعرق گیاه پتانسیل و از طرفی اندازه‌گیری نکردن برخی از این پارامترها در بعضی ایستگاه‌های سطح کشور سبب گردیده است امکان برآورد دقیق آن در مناطق نام برده میسر نباشد. بنابراین در این مقاله سعی شده است تا ضمن ارزیابی عملکرد شبکه‌های عصبی مصنوعی در برآورد تبخیر- تعرق پتانسیل، رفتار مدل‌های مختلف طراحی شده با کاهش تعداد پارامترهای اقلیمی بردار ورودی مورد بررسی قرار گیرد و در نهایت مقایسه‌ای بین نتایج مدل‌های طراحی شده با شبکه عصبی مصنوعی و نتایج به‌دست آمده از روش‌های تجربی که نیاز به متغیرهای اقلیمی کمی دارند، انجام شود.


مواد و روش‌ها

مشخصات ایستگاه هواشناسی و داده‌های مورد استفاده: داده‌های هواشناسی مورد نیاز برای انجام این پژوهش، از ایستگاه هواشناسی سینوپتیک مشهد، با مختصات جغرافیایی ۳۶ درجه و ۱۶ دقیقه عرض شمالی و ۵۹ درجه و ۳۸ دقیقه طول شرقی، که در ارتفاع ۹۹۹/۲ متری از سطح دریا واقع است، به‌دست آمده است. طبق گزارش سازمان هواشناسی خراسان رضوی و براساس روش دومارتن اقلیم منطقه مورد مطالعه خشک و نیمه‌خشک می‌باشد. مقدار میانگین سالانه دمای هوا در ایستگاه مورد مطالعه ۱۴/۲۵ درجه سانتی‌گراد و مقدار بارندگی آن ۲۴۱/۸ میلی‌متر در سال است. آمار مورد استفاده در این پژوهش، میانگین‌های ماهانه دمای کمینه (T_{min})، دمای بیشینه (T_{max})، رطوبت نسبی (RH_{mean})، سرعت باد (U_2) و تعداد ساعات آفتابی (n) طی دوره آماری ۲۰۰۵-۱۹۵۱ می‌باشد.

با توجه به آمار ماهانه داده‌های هواشناسی موجود طی سال‌های ۲۰۰۵-۱۹۵۱، طراحی شبکه با ۶۶۰ الگو انجام شد. دو سوم دوره آماری نام برده که معادل ۴۴۰ الگو می‌باشد برای آموزش شبکه و یک سوم دوره آماری که معادل ۲۲۰ الگو است به‌منظور آزمون مدل‌های طراحی شده در نظر گرفته شد. مقدار تبخیر- تعرق پتانسیل برای هر ماه طی دوره آماری نام برده، با روش فائو پنمن- مانتیث ۵۶ محاسبه شد و به‌عنوان خروجی شبکه مورد استفاده قرار گرفت. به‌منظور طراحی مدل‌های شبکه عصبی مصنوعی از نرم‌افزار Qnet2000 استفاده گردید.

شبکه عصبی مصنوعی: شبکه‌های عصبی مصنوعی همانند شبکه عصبی طبیعی، از اجزایی به‌نام سلول عصبی تشکیل شده‌اند. همان‌طوری‌که در شبکه عصبی طبیعی، تعدادی از سلول‌ها دریافت اثر محرک خارجی، تعدادی پردازش اطلاعات و تعدادی نیز انتقال پاسخ محرک به عضو موردنظر را بر عهده

دارند، در شبکه‌های عصبی مصنوعی نیز تعدادی از سلول‌ها دریافت معلومات مسأله، تعدادی پردازش اطلاعات و تعدادی نیز ارایه پاسخ مسأله را بر عهده دارند. شبکه عصبی به‌ترتیب شامل لایه ورودی، لایه پنهان و لایه خروجی می‌باشد، به‌طوری‌که این سلول‌ها توسط اتصالاتی با وزن‌های مختلف به هم وصل می‌باشند. در تمام شبکه‌های عصبی مصنوعی یک لایه ورودی، یک لایه خروجی و تعدادی لایه پنهان وجود دارد. در مدل‌سازی ریاضی نرون، مجموعه‌ای از داده‌ها به‌عنوان ورودی نرون (که شاید خروجی‌های نرون‌های دیگر باشند)، به‌کار برده می‌شوند. هر ورودی در وزن متناظرش ضرب می‌شود و بعد همه ورودی‌های وزن‌دار شده، به‌منظور تعیین سطح فعالیت نرون، با هم جمع می‌شوند. شکل ۱ مدل یک نرون چند ورودی را نشان می‌دهد.



شکل ۱- مدل ریاضی یک نرون چند ورودی.

در این شکل تعدادی ورودی x_1, x_2, \dots, x_k وارد نرون می‌شوند که به‌طور خلاصه با بردار X مشخص می‌شوند. هر یک از ورودی‌های نرون به یکی از سیگنال‌های ورودی متعلق است. هر سیگنال در یک وزن ارتباطی متناظر متشکل از w_1, w_2, \dots, w_k که به‌طور خلاصه با بردار W نشان داده می‌شود، ضرب می‌گردد. مقادیر به‌دست آمده در داخل نرون جمع شده و مقدار خروجی محاسبه می‌گردد.

$$NET = X.W \quad (1)$$

$$NET = x_1.w_1 + x_2.w_2 + \dots + x_n.w_n = \sum_{i=1}^n x_i.w_i \quad (2)$$

مجموع به‌دست آمده، بیش‌تر توسط یک تابع - که به تابع فعالیت موسوم است - ارزیابی شده و خروجی نرون مشخص می‌شود.

$$OUT = g(NET) \quad (۳)$$

که در آن، g : تابع فعالیت می‌باشد. نحوه و شکل اتصال سلول‌های عصبی در لایه‌های مختلف، باعث ایجاد ساختارهای مختلفی در شبکه‌های عصبی مصنوعی می‌شود (فلاح‌قاله‌ری و همکاران، ۲۰۰۹). لازم به ذکر است که در این پژوهش، از تابع فعالیت تانژانت هایپربولیک در لایه پنهان استفاده گردید. از آن‌جا که هدف از این پژوهش بررسی توانایی شبکه‌های عصبی مصنوعی در شرایط کمبود داده‌های اقلیمی است، بنابراین در طراحی مدل‌ها تعداد پارامترهای ورودی به تدریج کاهش یافت و ۸ ترکیب بردار ورودی به شرح جدول ۱ در نظر گرفته شد:

جدول ۱- ترکیب متغیرهای ورودی در مدل‌های طراحی شده.

نام مدل	پارامترهای بردار ورودی
مدل ۱	$T_{max}, T_{min}, RH_{mean}, U_v, n, R_a$
مدل ۲	$T_{max}, T_{min}, RH_{mean}, U_v$
مدل ۳	T_{max}, T_{min}, n, R_a
مدل ۴	T_{max}, T_{min}, U_v
مدل ۵	$T_{max}, T_{min}, RH_{mean}$
مدل ۶	T_{max}, T_{min}, n
مدل ۷	T_{max}, T_{min}, R_a
مدل ۸	T_{max}, T_{min}

به منظور به دست آوردن بهترین آرایش شبکه، طراحی مدل‌ها ابتدا با یک لایه پنهان و سپس با ۲ لایه پنهان انجام شد. برای بررسی اثر ترم مومنتم، ۳ مقدار ۰/۷، ۰/۸ و ۰/۹ برای آن در نظر گرفته شد. از آن‌جا که تغییر در تعداد گره‌های لایه‌های پنهان، می‌تواند تأثیر به‌سزایی در دقت خروجی شبکه بگذارد، بنابراین برای تعیین مناسب‌ترین تعداد گره در لایه‌های پنهان، تعداد گره‌ها نیز بین ۱-۱۰ گره تغییر داده شد. با توجه به مطالب ذکر شده، در نهایت ۴۸۰ مدل (۸ ترکیب بردار ورودی × تعداد ۱-۲ لایه پنهان × ۳ حالت مومنتم × تعداد ۱-۱۰ گره در لایه‌های پنهان) با هدف حصول مناسب‌ترین ترکیب و آرایش شبکه، برای برآورد تبخیر- تعرق پتانسیل با استفاده از شبکه‌های عصبی مصنوعی طراحی گردید.

معادله‌های برآورد تبخیر- تعرق پتانسیل: در این مقاله از نتایج معادله فائو پنمن- مانتیث ۵۶ به عنوان خروجی شبکه‌های طراحی شده و همچنین به عنوان روش مبنا برای مقایسه نتایج به دست آمده، استفاده گردید که رابطه آن به صورت زیر می‌باشد (آلن و همکاران، ۱۹۹۸):

$$ET_o = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 273} u_v (e_s - e_a)}{\Delta + \gamma(1 + 0.34u_v)} \quad (4)$$

که در آن، ET_o : میزان تبخیر- تعرق پتانسیل (میلی‌متر در روز)، R_n : تابش خالص (مگاژول بر مترمربع در روز)، G : شار حرارتی خاک (مگاژول بر مترمربع در روز)، T : میانگین دمای هوا در ارتفاع ۲ متری (درجه سانتی‌گراد)، u_v : سرعت باد در ارتفاع ۲ متری (متر بر ثانیه)، e_s : فشار بخار اشباع (کیلوپاسکال)، e_a : فشار بخار واقعی (کیلوپاسکال)، Δ : شیب منحنی فشار بخار آب اشباع (کیلوپاسکال بر درجه سانتی‌گراد) و γ : ثابت سایکرومتریک (کیلوپاسکال بر درجه سانتی‌گراد) می‌باشد.

همچنین برای بررسی کارایی روش شبکه‌های عصبی مصنوعی، نتایج بهترین آرایش شبکه با روش‌های هارگریوز- سامانی، بلانی- کریدل و ماکینک مورد مقایسه قرار گرفت. روش هارگریوز- سامانی (۱۹۸۵) یکی از ساده‌ترین رابطه‌ها برای برآورد تبخیر- تعرق پتانسیل است که در آن تنها به دمای حداقل و حداکثر و تابش فرازمینی نیاز می‌باشد (وانگ و همکاران، ۲۰۰۸):

$$ET_o = 0.023 \frac{R_a}{\lambda} \left(\frac{T_{\max} + T_{\min}}{2} + 17/8 \right) \sqrt{T_{\max} - T_{\min}} \quad (5)$$

روش بلانی- کریدل تنها از مقادیر میانگین دما برای برآورد میزان تبخیر- تعرق پتانسیل استفاده می‌نماید (وانگ و همکاران، ۲۰۰۸):

$$ET_o = p(0.46T_{mean} + 8/13) \quad (6)$$

ماکینک (۱۹۵۷) در معادله خود از پارامترهای حداقل، حداکثر و میانگین دما و همچنین میزان تابش خورشیدی به منظور تخمین تبخیر- تعرق پتانسیل استفاده نموده است (لاندراس و همکاران، ۲۰۰۸):

$$ET_o = 0.61 \frac{\Delta}{\Delta + \gamma} \frac{R_s}{\lambda} - 0.12 \quad (7)$$

که در آن‌ها، T_{max} : دمای حداکثر (درجه سانتی‌گراد)، T_{min} : دمای حداقل (درجه سانتی‌گراد)، T_{mean} : میانگین دمای هوا (درجه سانتی‌گراد)، R_a : تابش فرازمینی (مگاژول بر مترمربع در روز)، P : درصد ساعات روشنایی روزانه به کل سال که به عرض جغرافیایی بستگی دارد، R_s : میزان تابش خورشیدی (مگاژول بر مترمربع در روز)، Δ : شیب منحنی فشار بخار آب اشباع (کیلوپاسکال بر درجه سانتی‌گراد)، γ : ثابت سایکرومتریک (کیلوپاسکال بر درجه سانتی‌گراد) و λ : گرمای نهان تبخیر (مگاژول بر کیلوگرم) می‌باشد.

به منظور ارزیابی و مقایسه عملکرد مدل‌ها از داده‌هایی استفاده شد که در فرآیند آموزش شبکه دخالت نداشتند. برای تعیین بهترین آرایش شبکه، از شاخص‌های جذر میانگین مربعات خطا ($RMSE$)، ضریب تعیین (r^2) و حداکثر خطای مطلق (MAE) به شرح ذیل استفاده گردید:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y - \hat{Y})^2}{n}} \quad (8)$$

$$r = \frac{\sum_{i=1}^n Y \cdot \hat{Y}}{\sqrt{\sum_{i=1}^n Y^2 \sum_{i=1}^n \hat{Y}^2}} \quad (9)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Z^*(x_i) - Z(x_i)| \quad (10)$$

که در آن‌ها، Y : مقدار تبخیر-تعرق پتانسیل محاسبه شده به روش فائو پنمن-مانتیت ۵۶ و \hat{Y} : مقدار تبخیر-تعرق پتانسیل پیش‌بینی شده توسط شبکه عصبی مصنوعی است. $Z^*(x_i)$ و $Z(x_i)$ هم به همین ترتیب مقادیر محاسبه شده و پیش‌بینی شده متغیر x در زمان i و n تعداد مشاهدات می‌باشد.

-
- 1- Root Mean Square Error
2- Maximum Absolute Error

نتایج و بحث

نتایج به دست آمده برای ۸ ترکیب اولیه، در جدول ۲ منظور گردیده است. همان‌طور که در این جدول مشاهده می‌شود، مدل ۱ با ۶ ورودی و خطایی برابر با ۰/۱۰۶ میلی‌متر در روز، بهترین عملکرد را از خود نشان داده است که دلیل آن شرکت دادن تعداد پارامترهای اقلیمی بیش‌تر در بردار ورودی شبکه می‌باشد. از آن‌جا که هدف، بررسی عملکرد شبکه تحت شرایط کمبود متغیر اقلیمی است، بنابراین در انتخاب پارامترهای بردار ورودی سعی شده است تا حد امکان از دخالت عناصری که نیاز به اندازه‌گیری دارند، اجتناب گردد. از آن‌جا که تابش فرازمینی (R_a) پارامتری است که تنها به عرض جغرافیایی محل و روز از سال بستگی دارد، بنابراین با استفاده از مدل ۷ و مدل ۸ می‌توان تنها با داشتن حداقل و حداکثر دمای هوا، میزان تبخیر- تعرق پتانسیل را برآورد نمود.

جدول ۲- مقایسه نتایج شبکه‌های عصبی مصنوعی طراحی شده با مقادیر به دست آمده از روش پنمن- مانیتث فائو ۵۶.

نام شبکه	ساختار بهینه	ترم مومتم	(RMSE)		(r^2)		(MAE)	
			آموزش	آزمون	آموزش	آزمون	آموزش	آزمون
مدل ۱	۶-۹-۱	۰/۹	۰/۰۸۷	۰/۱۰۶	۰/۹۹۹	۰/۹۹۹	۰/۲۸۰	۰/۲۷۶
مدل ۲	۴-۶-۱	۰/۹	۰/۲۲۸	۰/۳۵۸	۰/۹۹۳	۰/۹۸۸	۰/۸۵۴	۱/۲۸۱
مدل ۳	۴-۹-۹-۱	۰/۷	۰/۱۸۵	۰/۲۶۲	۰/۹۹۵	۰/۹۹۱	۰/۶۵۳	۰/۷۷۵
مدل ۴	۳-۴-۴-۱	۰/۹	۰/۲۳۰	۰/۳۴۴	۰/۹۹۳	۰/۹۸۷	۰/۸۶۴	۱/۱۹۹
مدل ۵	۳-۱۰-۱۰-۱	۰/۹	۰/۲۹۵	۰/۴۸۵	۰/۹۸۸	۰/۹۷۸	۱/۰۷۴	۱/۳۶۵
مدل ۶	۳-۴-۴-۱	۰/۹	۰/۲۶۷	۰/۴۱۴	۰/۹۹۰	۰/۹۸۲	۱/۱۰۷	۱/۱۱۱
مدل ۷	۳-۵-۵-۱	۰/۹	۰/۲۴۵	۰/۲۸۶	۰/۹۹۲	۰/۹۹۰	۰/۹۴۷	۰/۹۵۸
مدل ۸	۲-۳-۱	۰/۷	۰/۳۱۵	۰/۴۳۷	۰/۹۸۶	۰/۹۷۹	۱/۰۲۶	۱/۱۹۹

* اعداد ساختار شبکه، به ترتیب از چپ به راست تعداد گره‌های لایه ورودی، لایه پنهان اول (لایه پنهان دوم) و لایه خروجی می‌باشد.

* RMSE = جذر میانگین مربعات خطا


* MAE = حداکثر خطای مطلق

همان‌طور که در جدول ۲ مشاهده می‌گردد مدل ۳ با مقدار خطای ۰/۲۶۱ میلی‌متر در روز و مدل ۷ با خطایی معادل ۰/۲۸۶ میلی‌متر در روز توانسته‌اند نتایج بهتری را نسبت به سایر مدل‌ها ارائه دهند. این مطلب می‌تواند نشان‌دهنده اهمیت و تأثیر بسیار زیاد متغیر R_a در تخمین تبخیر- تعرق پتانسیل


توسط شبکه‌های عصبی مصنوعی باشد. مقایسه نتایج مدل‌های ۷ و ۸ نیز این امر را تأیید می‌کند. افزودن پارامتر تعداد ساعات آفتابی (n) نیز می‌تواند در حد مطلوبی دقت برآورد را افزایش دهد، این در حالی است که در مدل‌های ۲، ۴، ۵ و ۸ که از پارامترهای مربوط به تابش (Ra, n) صرف‌نظر شده است، دقت نتایج به میزان قابل توجهی کاهش یافته است.

همچنین نتایج نشان می‌دهد که به‌طور کلی با افزایش ترم مومنتم، مقدار خطا کاهش می‌یابد. اما این مسأله در رابطه با تمامی مدل‌ها صادق نمی‌باشد. از طرف دیگر، نتایج به‌دست آمده از تغییر در تعداد لایه‌های پنهان شبکه‌های طراحی شده نیز منجر به تصمیم‌گیری قاطعانه‌ای در رابطه با برتری یک لایه پنهان و یا دو لایه پنهان نمی‌شود و تنها بستگی به پارامترهای ورودی به شبکه دارد. این در حالی است که در مطالعات زیادی با فرض کارایی بالاتر یک لایه پنهان و البته اجرای سریع‌تر مدل، تنها از یک لایه پنهان استفاده گردیده است (سودهیر و همکاران، ۲۰۰۲؛ وانگ و همکاران، ۲۰۰۸؛ چائوهان و شریواستاوا، ۲۰۰۹).

به‌منظور مقایسه بهتر نتایج مدل‌های ۱ و ۳، مقدار ET_0 برآورد شده توسط بهترین آرایش هر یک از این مدل‌ها، با مقادیر ET_0 محاسبه شده با استفاده از روش پنمن-مونتیث در شکل‌های ۲ و ۳ نمایش داده شده است.



شکل ۲- مقایسه Model 1 و روش پنمن-مونتیث.



شکل ۳- مقایسه Model 3 و روش پنمن - ماتیتث.

برای بررسی دقیق‌تر کارایی شبکه‌های عصبی مصنوعی در برآورد تبخیر- تعرق پتانسیل، از نتایج تبخیر- تعرق پتانسیل محاسبه شده با روش‌های تجربی هارگریوز- سامانی، بلانی- کریدل و ماکینک استفاده گردید. به این منظور مقادیر تبخیر- تعرق پتانسیل با استفاده از روش‌های نام برده طی دوره آماری معادل با مرحله تست شبکه‌های عصبی مصنوعی، محاسبه گردید و سپس نتایج به دست آمده با نتایج روش فائو- پنمن- ماتیتث ۵۶ مقایسه گردید (جدول ۳).


با توجه به مقادیر ارایه شده در جدول ۳، روش هارگریوز- سامانی که تنها نیازمند پارامتر دمای حداقل، دمای حداکثر و تابش فرازمینی است، در میان سایر روش‌های تجربی با خطای ۰/۵۰۶ میلی‌متر در روز، نتایج بهتری را در ایستگاه سینوپتیک مشهد ارایه کرده است. روش بلانی- کریدل که از دمای میانگین و درصد ساعات روشنایی استفاده می‌نماید، با خطایی معادل ۱/۱۵۶ میلی‌متر در روز بیش‌ترین خطا را به همراه داشته است.

جدول ۳- خلاصه نتایج آماری تبخیر- تعرق پتانسیل محاسبه شده با روش‌های تجربی در مقایسه با روش پنمن- ماتیتث.

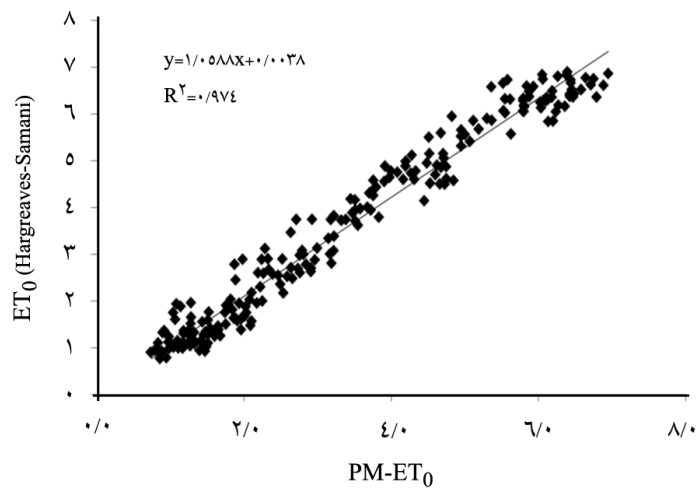
روش مورد استفاده	(RMSE)	(r^2)
هارگریوز- سامانی	۰/۵۰۶	۰/۹۷۴
بلانی- کریدل	۱/۱۵۶	۰/۹۷۱
ماکینک	۰/۶۵۱	۰/۹۸۱

براساس نتایج به دست آمده از جدول‌های ۲ و ۳، شبکه عصبی مصنوعی در تمامی موارد، مقدار خطای کم‌تری نسبت به روش‌های تجربی نام برده داشته است. مدل ۷ با ساختار ۱-۵-۳ که دارای پارامترهای ورودی مشابه با پارامترهای مورد نیاز معادله هارگریوز-سامانی است، توانسته است با خطای $0/286$ میلی‌متر در روز در مقابل خطای به دست آمده از روش هارگریوز-سامانی که معادل $0/506$ میلی‌متر در روز است، نتیجه رضایت‌بخشی را ارایه نماید. مدل طراحی شده توسط وانگ و همکاران (۲۰۰۸) با ساختار ۱-۱۰-۳ نیز در مقابل روش هارگریوز-سامانی دارای نتیجه مشابهی بوده است. همچنین با توجه به نتایج می‌توان دریافت که شبکه‌های عصبی مصنوعی قادرند تنها با استفاده از پارامتر دما به عنوان ورودی با خطای $0/437$ میلی‌متر در روز، موفق‌تر از روش‌های تجربی عمل نمایند.


نمودارهای مربوط به نتایج ET_0 محاسبه شده از روش‌های بلانی-کریدل، هارگریوز-سامانی و ماکینک به منظور مقایسه مطلوب‌تر نتایج به دست آمده با روش شبکه‌های عصبی مصنوعی، در شکل‌های ۴، ۵ و ۶ نمایش داده شده است.



شکل ۴- مقایسه روش بلانی-کریدل و روش پنمن-مانتیت.



شکل ۵- مقایسه روش هارگریوز-سامانی و روش پنمن-مانتیت.



شکل ۶- مقایسه روش ماکینک و روش پنمن-مانتیت.

نرم افزار *Qnet2000* قادر است اهمیت نسبی متغیرهای شرکت کننده در مدل ها را محاسبه نماید، با بررسی این مقادیر می توان درجه اهمیت هر یک از پارامترهای ورودی را تعیین نمود (جدول ۴).

نتایج این جدول نیز بیانگر اهمیت زیاد فاکتورهای اقلیمی مربوط به تابش و دما در تعیین میزان تبخیر- تعرق پتانسیل توسط شبکه‌های عصبی مصنوعی می‌باشد. با توجه به نتایج جدول‌های ۲ و ۴، در صورت دخالت پارامتر تابش فرازمینی در مدل‌ها، برآورد بهتری از تبخیر- تعرق پتانسیل به دست می‌آید (مدل‌های ۳ و ۷) و در صورت حذف تابش، کارایی مدل به میزان قابل توجهی کاهش می‌یابد (مدل ۸). در رابطه با پارامترهای سرعت باد و رطوبت نسبی نیز می‌توان گفت به طور کلی در همه مدل‌ها، این دو متغیر از تأثیر کم‌تری بر روی خروجی شبکه برخوردار بوده‌اند.

جدول ۴- اهمیت نسبی متغیرهای ورودی در بهترین ساختار هر ترکیب (درصد).

نام شبکه	ساختار بهینه	مومتم	T_{min}	T_{max}	RH_{maen}	U_r	n	R_a
مدل ۱	۶-۹-۱	۰/۹	۱۴/۲۲	۲۲/۱۷	۸/۹۰	۱۳/۷۹	۱۸/۹۲	۲۱/۹۹
مدل ۲	۴-۶-۱	۰/۹	۴۰/۷۵	۳۴/۹۲	۶/۳۷	۱۷/۹۶		
مدل ۳	۴-۹-۹-۱	۰/۷	۳۵/۴۲	۸/۱۴			۳۳/۷۲	۲۲/۷۲
مدل ۴	۳-۴-۴-۱	۰/۹	۳۷/۵۰	۴۴/۵۷		۱۸/۹۳		
مدل ۵	۳-۱۰-۱۰-۱	۰/۹	۷۶/۰۸	۶/۶۵	۱۷/۲۷			
مدل ۶	۳-۴-۴-۱	۰/۹	۶۱/۹۹	۷/۸۴			۳۰/۱۶	
مدل ۷	۳-۵-۵-۱	۰/۹	۲۷/۴۷	۴۶/۸۵				۲۵/۶۸
مدل ۸	۲-۳-۱	۰/۷	۶۵/۷۹	۳۴/۲۱				

نتیجه‌گیری

از آن‌جا که تبخیر- تعرق پدیده‌ای غیرخطی و پیچیده است و پارامترهای هواشناسی بسیاری در برآورد آن مؤثرند و از طرفی اندازه‌گیری نکردن برخی از این متغیرها در بعضی نقاط، باعث شد تا در این پژوهش تلاش بر یافتن روشی باشد تا با حداکثر دقت و کم‌ترین خطا، با حداقل پارامترهای اقلیمی، تخمینی درست از تبخیر- تعرق پتانسیل ارائه دهد. با توجه به نتایج و جدول‌های ارائه شده، در صورت اندک بودن تعداد پارامترهای اقلیمی، شبکه‌های عصبی مصنوعی قادرند تنها با استفاده از دمای حداقل و حداکثر در مقایسه با روش‌های هارگریوز- سامانی، بلانی- کریدل و ماکینک، برآورد بهتری از تبخیر- تعرق پتانسیل در منطقه مشهد ارائه دهند. این در حالی است که با وارد نمودن پارامتر تابش فرازمینی (R_a) که قابل محاسبه بوده و در هر منطقه و برای هر روز از سال ثابت است، می‌توان دقت برآورد را افزایش داد، به طوری که مقدار خطا در این حالت معادل ۰/۲۸۶ میلی‌متر در روز می‌باشد.

منابع

1. Aksoy, H., Guven, A., Aytok, A., Yuce, M.I., and Unal, N.E. 2007. Discussion of Generalized regression neural network for evapotranspiration modeling. *J. Hydrol. Sci.* 52: 4. 825-831.
2. Allen, R.G., Pereira, L.S., Raes, D., and Smith, M. 1998. Crop Evapotranspiration, guideline for computing water requirement, Irrigation Drainage Paper, 56, FAO, Rome, Italy, 300p.
3. Chauhan, S., and Shrivastava, R.K. 2009. Performance evaluation of reference evapotranspiration estimation using climate based methods and artificial neural network. *J. Water Resour. Manage.* 23: 825-837.
4. Fallah Ghalhary, G.A., Mousavi Baygi, M., and Habibi Nokhandan, M. 2009. Results compression of Mamdani fuzzy inference system and artificial neural networks in the seasonal rainfall prediction, Case study: Khorasan region. *J. Iran Water Resour. Res.* 5: 40-52. (In Persian)
5. Jensen, D.T., Hargreaves, G.H., Temesgen, B., and Allen, R.G. 1997. Computing of ETo under nonideal conditions. *J. Irrig. Drain. Engin.* 123: 5. 394-400.
6. Jensen, M.E., Burman, R.D., and Allen, R.G. 1990. Evapotranspiration and irrigation water requirement, ASCE Manuals and report on engineering practice, ASCE, NY, 70p.
7. Kochak Zadeh, M., and Bahmani, A. 2006. Assessment of artificial neural network revenue in reducing required parameters for estimation of reference evapotranspiration. *J. Agric. Sci.* 4: 87-96. (In Persian)
8. Kumar, M., Raghuwanshi, N.S., Singh, R., Wallender, W.W., and Pruitt, W.O. 2002. Estimating evapotranspiration using artificial neural network. *J. Irrig. Drain. Engin.* 128: 4. 224-233.
9. Landeras, G., Ortiz-Barredo, A., and López, J.J. 2008. Comparison of artificial neural network models and empirical and semi-empirical equations for daily reference evapotranspiration estimation in the Basque Country (Northern Spain). *J. Agric. Water Manage.* 95: 553-565.
10. Makkink, G.F. 1957. Testing the Penman formula by means of lysimeters. *J. Inst. Water Engin.* 11: 3. 277-288.
11. Shayan Nejad, M. 2007. Comparison accuracy of artificial neural network methods and Penman-Monteith in estimation of potential evapotranspiration. National Conference on Management of Irrigation and Drainage Systems, Ahvaz, Iran. (In Persian)
12. Sudheer, K.P., Gosain, A.K., Mohana Rangan, D., and Saheb, S.M. 2002. Modelling evaporation using an artificial neural network algorithm. *J. Hydrol. Processes.* 16: 3189-3202.
13. Trajkovic, S., Todorovic, B., and Stankovic, M. 2003. Forecasting of reference evapotranspiration by artificial neural networks. *J. Irrig. Drain. Engin.* 129: 6. 454-457.
14. Wang, Y.M, Traore, S., and Kerh, T. 2008. Neural network approach for estimating reference evapotranspiration from limited climatic data in Burkina Faso. *WSEAS Transactions on Computers.* 7: 704-713.
15. Zanetti, S.S., Sousa, E.F., Oloveira, V.P.S., Almeida, F.T., and Bernardo, S. 2007. Estimating evapotranspiration using artificial neural network and minimum Climatological data. *J. Irrig. Drain. Engin.* 133: 2. 83-89.



Gorgan University of Agricultural
Sciences and Natural Resources

J. of Water and Soil Conservation, Vol. 20(5), 2013
<http://jwsc.gau.ac.ir>

Modeling of potential evapotranspiration by Artificial Neural Network from minimum climatic variables in Mashhad synoptic station

***S. Noori¹, Gh.A. Fallah-Ghalhary² and S.H. Sanaei-Nejad³**

¹M.Sc. Student, Dept. of Water Engineering, Ferdowsi University of Mashhad, I.R of Iran,

²Ph.D. Student, Dept. of Physical Geography, Isfahan University and Climatological Research Institute (CRI), Mashhad, I.R of Iran, ³Associate Prof., Dept. of Water

Engineering, Ferdowsi University of Mashhad

Received: 04/21/2010; Accepted: 12/05/2012

Abstract

Potential Evapotranspiration (ET_o) determination is a key factor for irrigation scheduling, water balance, irrigation system design and management and crop yields simulation. Many variables needed in estimating evapotranspiration and lack of access to some of the required data has made problems in accurate estimation of ET_o in these areas. This paper examines the ability of artificial neural networks (ANNs) in estimating ET_o from minimum climatic variables. In this study, Multi Layer Perceptron (MLP) Neural Network used with Back-Propagation learning rule (BP) and the weather parameter data used as input were the mean of monthly maximum temperature, minimum temperature, mean relative humidity, wind speed and actual sunshine duration that were available at Mashhad synoptic weather station, from 1951 to 2005. ET_o was estimated by Penman-Monteith and used as output. For evaluation of Neural Network utility under situations of absence of some parameters, a comparison was made between the estimations provided by the Neural Networks models and the following empirical models: Hargreaves-Samani, Blaney-Criddle, Makink. Neural Networks have obtained better results than the empirical methods for modeling potential evapotranspiration. Based on these results, under situations of limited climatic parameters, the Neural Networks was able to estimate ET_o properly even with the minimum temperature, maximum temperature and extraterrestrial radiation in the study of area (RMSE=0.286).

Keywords: Reference evapotranspiration, Artificial Neural Network, Temperature, Back-propagation learning rule

* Corresponding Author; Email: noori.samira@gmail.com