



دانشگاه گلستان

مجله پژوهش‌های حفاظت آب و خاک
جلد هفدهم، شماره دوم، ۱۳۸۹
www.gau.ac.ir/journals

تخمین تبخیر روزانه از تشت تبخیر با استفاده از سه شبکه عصبی پرسپترون چندلایه، تابع پایه شعاعی و المانی

*امیراحمد دهقانی^۱، مهدی پیری^۲، موسی حسام^۱ و نوید دهقانی^۳

^۱استادیار گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، دانشجوی کارشناسی ارشد گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، ^۲دانشجوی کارشناسی ارشد گروه آبخیزداری، دانشگاه تربیت مدرس تاریخ دریافت: ۸۷/۹/۲۰؛ تاریخ پذیرش: ۸۹/۳/۱۱

چکیده

تبخیر یکی از جمله پارامترهای مهم در هیدرولوژی و مهندسی منابع آب است که مورد توجه محققان قرار دارد. به دلیل تأثیر متقابل پارامترهای مختلف هواشناسی در محاسبه تبخیر، روابطی غیرخطی برای تخمین مقدار آن وجود دارد که از دقت بالایی برخوردار نیستند. شبکه‌های عصبی مصنوعی از جمله روش‌های نوین می‌باشد که برای تخمین و پیش‌بینی پارامترها با استفاده از ارتباط ذاتی بین داده‌ها توسعه یافته است. در این پژوهش، با استفاده از آمار روزانه هواشناسی ایستگاه هاشم‌آباد گرگان به آموزش شبکه‌های عصبی مصنوعی با ساختار پرسپترون چند لایه، تابع پایه شعاعی و شبکه عصبی المانی پرداخته شد. ترکیب‌های مختلف پارامترهای درجه حرارت هوا، رطوبت نسبی، سرعت باد، ساعات آفتابی به عنوان ورودی‌های شبکه و تبخیر روزانه از تشت تبخیر به عنوان خروجی شبکه در نظر گرفته شد. همچنین با استفاده از فرمول‌های تجربی، میزان تبخیر محاسبه شده و با نتایج به دست آمده از شبکه عصبی مصنوعی مورد مقایسه قرار گرفت. به منظور بررسی تأثیر پارامترهای ورودی در تخمین تبخیر از آنالیز حساسیت استفاده گردید. نتایج نشان داد که پارامترهای دما و سرعت باد به ترتیب بیشترین و کمترین تأثیر را در تخمین مقدار تبخیر از تشتک دارا می‌باشند. همچنین شبکه‌های عصبی مصنوعی از دقت بالاتری برای تخمین تبخیر روزانه نسبت به روش‌های تجربی موجود برخوردارند.

واژه‌های کلیدی: الگوریتم پس‌انتشار خطا، آنالیز حساسیت، تبخیر روزانه، شبکه عصبی مصنوعی

* مسئول مکاتبه: a.dehghani@gau.ac.ir

مقدمه

تبخیر از سطوح آب، زمین، خاک، دریاچه‌ها و مخازن آبی، یکی از فرایندهای بسیار مهم در هواشناسی و هیدرولوژی می‌باشد (اجلالی، ۲۰۰۴). هر ساله میلیون‌ها مترمکعب آب شیرین از مخازن سدها که با هزینه زیادی جمع‌آوری گردیده، تبخیر شده و از دست می‌رود و املاح و نمک بر جای مانده از حجم آب تبخیر شده، کیفیت آب را کاهش می‌دهد (کارآموز و عراقی‌نژاد، ۲۰۰۶).

محاسبه آب هدر رفته به وسیله تبخیر، در درجه اول برای بررسی و مدیریت منابع آب، در مقیاس کشاورزی و منطقه‌ای، یا حوضه‌های آبخیز، دارای اهمیت می‌باشد.

در بسیاری از مناطق که منابع آبی محدودی دارند، اجرای محاسبه اتلاف آب توسط تبخیر، برای طرح‌ریزی و مدیریت شیوه‌های آبیاری لازم و ضروری می‌باشد (براتسائرت، ۱۹۸۲؛ جکسون، ۱۹۸۵؛ شریفان و همکاران، ۲۰۰۶).

سال‌های زیادی است که محققان و مهندسين، برای محاسبه تبخیر از سطح دریاچه‌ها و مخازن آبی و همچنین اندازه‌گیری تبخیر- تعرق گیاهان، از تشت‌های تبخیر استفاده می‌کنند. برای این منظور میزان تبخیر از تشت، اندازه‌گیری شده و آنگاه با استفاده از ضرایب مخصوصی میزان تبخیر از سطح آب و یا تبخیر- تعرق پتانسیل به دست می‌آید (فرورت و همکاران، ۱۹۸۳؛ ایرماک و همکاران، ۲۰۰۲).

در ایران بیشتر از تشت‌های استاندارد آمریکایی کلاس A استفاده می‌شود، که قطری در حدود ۴ فوت، ارتفاع ۱۰ اینچ دارند و حدود ۶ اینچ بالاتر از سطح زمین قرار می‌گیرند. تعدادی از محققان (استفان و استوارت، ۱۹۶۳؛ ریس و دیاس، ۱۹۹۸؛ کلمب و همکاران، ۲۰۰۱). برای محاسبه تبخیر روش‌های متعددی را پیشنهاد داده‌اند، اما بسیاری از این روش‌ها نیاز به داده‌هایی دارند که به آسانی در دسترس نیستند.

شبکه‌های عصبی مصنوعی، کاربردهای موفقیت‌آمیزی در زمینه‌های گوناگون از جمله مطالعات منابع آب داشته‌اند. در زمینه‌های هیدرولوژیکی نیز، پژوهش‌های اخیر بیانگر آن است که شبکه‌های عصبی مصنوعی^۱، قادرند نتایج رضایت‌بخشی ارائه دهند (تی‌فور، ۲۰۰۲؛ سیگیزوگلو و کیسی، ۲۰۰۶؛ کیسی، ۲۰۰۴؛ کیسی، ۲۰۰۵ a؛ کیسی، ۲۰۰۵ b؛ کیسی، ۲۰۰۶).

1. Artificial Neural Networks

برتن و همکاران (۲۰۰۰)، با استفاده از شبکه‌های عصبی مصنوعی، تبخیر روزانه از تشتک را مورد بررسی قرار دادند. بارندگی، درجه حرارت، رطوبت نسبی، تشعشعات خورشیدی و سرعت باد به‌عنوان پارامترهای ورودی شبکه و میزان تبخیر از تشتک به‌عنوان پارامتر خروجی شبکه مورد استفاده قرار گرفتند. نتایج ایشان نشان داد که روش شبکه‌های عصبی مصنوعی دارای کمترین خطا نسبت به سایر روش‌ها بوده و خطایی برابر ۱/۱۱ میلی‌متر در روز داشته است.

کیسی (۲۰۰۶)، نیز با استفاده از شبکه‌های عصبی و منطق فازی تبخیر روزانه از تشتک را محاسبه کرد. درجه حرارت، رطوبت نسبی، تشعشعات خورشیدی، سرعت باد و فشار هوا به‌عنوان ورودی‌های شبکه و میزان تبخیر از تشتک به‌عنوان خروجی شبکه مورد استفاده قرار گرفتند. نتایج نشان داد که روش منطق فازی نتایج بهتری را نسبت به شبکه عصبی مصنوعی ارائه می‌کند. البته نتایج به‌دست آمده از شبکه‌های عصبی نیز در این پژوهش رضایت‌بخش بوده و خطایی برابر ۰/۱۷ میلی‌متر در روز داشته است.

شایان‌نژاد و همکاران (۲۰۰۷) تبخیر بالقوه را از روش‌های رگرسیون فازی، شبکه عصبی مصنوعی و روش پنمن مانتیث تعیین نمودند. نتایج نشان داد که بهترین ترکیب ورودی برای شبیه‌سازی تبخیر، دما، میانگین رطوبت نسبی، ساعات آفتابی و سرعت باد می‌باشند.

هدف از این پژوهش مدل‌سازی روزانه تبخیر از تشتت با استفاده از شبکه‌های عصبی مصنوعی و تعیین میزان تأثیر هر کدام از پارامترهای ورودی بر مقدار تبخیر بوده است. در این پژوهش با استفاده از آمار ایستگاه هواشناسی هاشم‌آباد گرگان و به‌کارگیری شبکه عصبی مصنوعی، میزان تبخیر از تشتک تخمین زده شده است. پارامترهای ورودی شبکه عصبی مصنوعی، درجه حرارت هوا، رطوبت نسبی، سرعت باد و ساعات آفتابی است که به‌منظور بررسی اثر این پارامترها از ترکیب‌های مختلف آنها برای تخمین میزان تبخیر از تشتت استفاده شده است.

روش‌های تجربی موجود برای تخمین تبخیر از سطح آزاد آب: تاکنون کوشش‌های زیادی به‌عمل آمده است تا رابطه‌ها و معادله‌های عملی و ساده‌ای برای تخمین تبخیر از سطح آزاد آب ارائه شود (علیزاده، ۱۹۹۸). از جمله رابطه‌های ارائه شده که در مطالعات هیدرولوژی از آنها استفاده می‌شود، عبارتند از:

$$E = 0.35(e_s - e_d)(0.5 + U_p / 10.0) \quad (1)$$

در این فرمول E تبخیر از سطح آزاد آب (میلی متر در روز)، e_s و e_d به ترتیب، فشار بخار اشباع و فشار واقعی بخار آب (برحسب میلی متر جیوه) در دمای متوسط روزانه هوا (T) و U_2 سرعت متوسط روزانه باد در ارتفاع ۲ متری از سطح زمین (برحسب میل در روز) می‌باشد.

برای استفاده از رابطه (۱)، ابتدا لازم است مقدار $e_s - e_d$ که به نام کمبود فشار بخار معروف است محاسبه شود. کمبود فشار بخار، با در دست داشتن متوسط دمای روزانه (T) و رطوبت نسبی (RH)، از رابطه زیر قابل محاسبه است.

$$e_s - e_d = 4/581 \exp\left[\frac{17/27T}{T + 237/3}\right] (1 - RH/100) \quad (2)$$

در این رابطه T برحسب درجه سلسیوس، RH برحسب درصد و $e_s - e_d$ برحسب میلی متر جیوه می‌باشد. روش پنمن: پنمن (۱۹۴۸) از ترکیب روش بیلان انرژی و فرایند فیزیکی تبخیر، یک ترکیب وزنی از نتایج به‌کارگیری این دو مدل، به‌عنوان رابطه محاسبه تبخیر اعلام نمود که به‌صورت زیر است (به نقل از علیزاده، ۱۹۹۸).

$$E = \left[\frac{\Delta}{\Delta + \gamma} Q_n + \frac{\gamma}{\Delta + \gamma} E_a \right] \quad (3)$$

در رابطه بالا:

Q_n تابش خالص دریافتی برحسب واحد تبخیر، E_a تبخیر مشاهده شده برای تشت تبخیر کلاس A ، γ ضریب رطوبتی یا سایکرومتریک (میلی بار بر درجه سانتی‌گراد)، Δ شیب منحنی فشار بخار آب (میلی بار بر درجه سانتی‌گراد) و E میزان تبخیر از سطح آزاد آب (میلی متر در روز) می‌باشد.

در رابطه بالا:

$$E_a = f(u)(e_s - e_d) \quad (4)$$

که در آن $f(u)$ تابع باد می‌باشد و از رابطه زیر به‌دست می‌آید:

$$f(u) = 0.27(1 + 0.01U_p) \quad (5)$$

در رابطه‌های (۴) و (۵)، $e_s - e_d$ برحسب میلی بار و U_2 برحسب متر بر ثانیه می‌باشد. بنابراین E_a به‌صورت زیر تعریف می‌شود:

$$E_a = 0.27(1 + 0.01U_p)(e_s - e_d) \quad (6)$$

برای استفاده از رابطه (۶)، مقدار $e_s - e_d$ از رابطه زیر قابل محاسبه است:

$$e_s - e_d = 33/8639[(0.00738T + 0.8072)^4 - 0.000019(1/8T + 48) + 0.001316](1 - \frac{RH}{100}) \quad (7)$$


با توجه به این که هدف از این پژوهش مدل‌سازی روزانه تبخیر از تشت با استفاده از شبکه‌های عصبی مصنوعی بوده است. برای این منظور از شبکه‌های پرسپترون چند لایه، شبکه تابع پایه شعاعی و شبکه‌های عصبی المانی سه لایه استفاده شده است. زیرا این شبکه‌ها در شناخت الگو و تابع حاکم بر مسائل غیرخطی کاربرد بیشتری دارند (جیراک و همکاران، ۱۹۹۶). بنابراین در زیر خلاصه‌ای از شبکه عصبی مصنوعی و ساختار هر کدام از شبکه‌های عصبی پرسپترون چند لایه، شبکه تابع پایه شعاعی و شبکه‌های عصبی المانی سه لایه آمده است.

شبکه‌های عصبی مصنوعی: آغاز نظریه شبکه‌های عصبی مصنوعی تقریباً به دهه ۴۰ میلادی بر می‌گردد، زمانی که مک‌کلاچ روانشناس معروف و والتر پیترز ریاضی‌دان (۱۹۴۳) آن را پایه‌گذاری کردند. نخستین کاربرد عملی شبکه‌های عصبی مصنوعی توسط روزنبلات (۱۹۵۸) با معرفی شبکه‌های چند لایه پرسپترون انجام شد. بعد از آن مطالعات زیادی روی توانایی شبکه‌های عصبی به‌عنوان یک ابزار محاسباتی که می‌تواند یک نگاشت یا تبدیل از فضای چند بعدی به یک فضای چند بعدی دیگر انجام دهد، صورت گرفته است. از دیدگاه ریاضی یک شبکه عصبی به‌عنوان یک تقریب‌گر است. توانایی آن در تقریب بین الگوهای یک مساله باعث می‌شود تا بتوان مسائل با پیچیدگی زیاد مانند شناسایی الگو، تفکیک الگو، نگاشت غیرخطی^۳، حافظه انجمنی^۴، خودسازمان‌دهی^۵ و کنترل را انجام دهد. اگر چه ایده شبکه عصبی مک‌کلاچ و پیترز بیشتر از ۶۰ سال پیش ارائه شد ولی با توسعه آن در سال ۱۹۸۲ با کار هاپفیلد در معرفی شبکه‌های حافظه انجمنی، تولدی دوباره یافت و توسعه زیاد، زمانی اتفاق افتاد که راملهارت و همکاران (۱۹۸۶) الگوریتم پس‌انتشار خطا را به‌عنوان پایه تئوریک قوی برای شبکه عصبی ارائه کردند (سیگیزوخلو و کیسی، ۲۰۰۶).

شبکه‌های عصبی مصنوعی با ساختار پرسپترون چند لایه: شبکه عصبی پرسپترون چند لایه، رایج‌ترین شبکه‌های عصبی می‌باشد. این شبکه‌ها جز شبکه‌های عصبی پیشخور می‌باشند که قادرند با انتخاب مناسب تعداد لایه‌ها و نرون‌ها، یک نگاشت غیرخطی را با دقت دلخواه انجام دهند. پارامترهای قابل

1. Pattern Recognition
2. Pattern Classification
3. Nonlinear Mapping
4. Associative Memory
5. Self Organization

تنظیم در شبکه‌های MLP وزن اتصالات مابین لایه‌ها است و فرآیند آموزش در این شبکه‌ها، به معنی یافتن مقادیر مناسب برای وزن‌های اتصالات مابین نرون‌ها است. متداول‌ترین الگوریتم یادگیری این شبکه‌ها، الگوریتم پس‌انتشار خطا است. در شبکه‌های پیشخور نرون‌ها در لایه‌هایی که در لایه اول (ورودی)، شروع و به لایه خروجی ختم می‌شوند، آرایش می‌یابند. همچنین در این نوع شبکه، چندین لایه پنهان نیز وجود داشته و هر لایه دارای یک یا چندین نرون می‌باشد. نرون‌های یک لایه به نرون‌های لایه بعدی اتصال می‌یابند و خروجی یک نرون در یک لایه، فقط به نرون‌های لایه قبل که به آن نرون متصل هستند و وزن اتصالات بین آن‌ها بستگی دارد. از مهم‌ترین قسمت‌های تعیین ساختار بهینه شبکه پرسپترون چند لایه، تعیین تعداد لایه‌های پنهان و تعداد نرون‌های هر لایه پنهان برای دستیابی به کمترین خطا می‌باشد. قضیه‌ای در تئوری‌های مربوط به شبکه عصبی مصنوعی وجود دارد که اثبات می‌کند که یک لایه پنهان با تعداد نرون کافی، قادر به تخمین هر رابطه غیر خطی است (چیو و همکاران، ۲۰۰۴). شکل (۱)، نمای ساده‌ای از ساختار یک شبکه عصبی پرسپترون چند لایه را نشان می‌دهد که در آن لایه‌های ورودی، پنهان و خروجی نشان داده شده است.




شکل ۱- ساختار شبکه عصبی مصنوعی پرسپترون چند لایه.

بین نرون‌های لایه‌های مختلف اتصالاتی وجود دارد که هر کدام دارای وزن‌هایی می‌باشد. طی فرآیند آموزش این وزن‌ها و مقادیر ثابتی که با آنها جمع می‌شود و در اصطلاح بایاس^۱ نامیده می‌شود، به‌طور پی‌درپی تغییر می‌کنند تا خطای بین مقادیر تخمین زده شده و مقادیر واقعی به حداقل مقدار

1. Bias

خود برسد. برای انتقال خروجی‌های هر لایه به لایه‌های بعدی از توابع محرک استفاده می‌شود. توابع محرک انواع مختلفی دارند که از معروف‌ترین آن‌ها تابع خطی، تابع سیگموئید، تانژانت هیپربولیک و... را می‌توان نام برد (چیو و همکاران، ۲۰۰۴).


شبکه‌های المانی: شبکه‌های المانی اغلب دو لایه با یک پس‌خورد از لایه خروجی به ورودی لایه پنهان می‌باشد. این اتصال برگشتی به شبکه در تشخیص و تولید الگوهای زودگذر و وابسته به زمان کمک می‌کند. تفاوت اصلی این شبکه‌ها با شبکه‌های دو لایه معمول در پس‌خورد آن می‌باشد که تأخیر موجود در این پس‌خورد اطلاعات مربوط به گام قبلی را در گام فعلی در اختیار قرار می‌دهد. معماری این شبکه دو لایه در شکل ۲ نشان داده شده است.



شکل ۲- ساختار شبکه عصبی مصنوعی المانی.

توابع پایه شعاعی: شبکه‌های تابع پایه شعاعی از نوع شبکه‌های پیشرو همراه با یک لایه میانی هستند که برای اولین بار در سال ۱۹۸۸ توسط برومهد و لاو معرفی شدند (شکل ۳). در این روش اغلب، تابع محرک در لایه میانی، تابع گوسین و در لایه خروجی تابع خطی است. اغلب آموزش شبکه RBF به ۲ بخش تقسیم می‌شود، بخش اول اغلب یادگیری از نوع بدون راهنما است که با استفاده از روش‌های خوشه‌بندی، پارامترهای توابع پایه (مراکز و عرض‌ها)، با استفاده از اطلاعات ورودی تعیین

می‌شود و در بخش دوم که از نوع یادگیری با راهنما^۱ است وزن‌های بین لایه میانی و لایه خروجی با استفاده از روش‌های کاهش شیب و رگرسیون خطی تعیین می‌شود. تفاوت عمده این شبکه با شبکه‌های پسانتشار خطا در این است که دارای یک لایه میانی بوده و توابع محرک نرون‌ها، توابع شعاعی همراه با مرکز و عرض خاصی می‌باشد. علاوه بر این برخلاف شبکه پسانتشار خطا که مجموع وزن‌دار نرون‌های رسیده به نرون لایه میانی به‌عنوان ورودی تابع تحریک محاسبه می‌شوند، در این جا فاصله بین هر الگو با بردار مرکز هر نرون در لایه میانی، به‌عنوان ورودی تابع تحریک شعاعی محاسبه می‌شوند در فضای چند بعدی سطح آستانه نرون‌های لایه میانی به‌صورت توابع گوسی است که بیشترین مقدار را در مرکز دارد. و با افزایش فاصله از مرکز پاسخ به سمت صفر میل می‌کند. به‌علت انتخاب تابع گوسی در نرون‌های لایه میانی، این شبکه مسائل دسته‌بندی را به‌خوبی حل می‌کند زیرا به‌صورت شعاعی می‌تواند الگوها را بر روی دایره متحدالمرکزی تقسیم نماید و بردارهای مختلف با فاصله‌های یکسان از مرکز را در یک دسته قرار دهد. خطی بودن توابع تحریک نرون‌های خروجی از تفاوت‌های دیگر این شبکه با شبکه پسانتشار خطا است و به همین دلیل می‌توان از الگوریتم‌های بهینه‌سازی خطی استفاده کرد که هم سرعت پردازش را بالا برده و از افتادن در چاله‌های موضعی جلوگیری می‌شود.



شکل ۳- ساختار شبکه عصبی مصنوعی تابع پایه شعاعی.

1. Supervised

آموزش شبکه‌های عصبی: جهت یادگیری شبکه عصبی مصنوعی از فرآیند آموزش استفاده می‌شود. در این پژوهش از ساختارهای مختلف جهت آموزش شبکه استفاده شده و در هر ساختار پارامترهای مختلف به‌عنوان ورودی در نظر گرفته شده است. در ابتدا جهت آموزش شبکه از ورودی‌های نرمال شده استفاده شد که رابطه (۸) به این منظور مورد استفاده قرار گرفته است (سیگیزوگلو و کیسی، ۲۰۰۶).

$$N_i = 0.5 \times \left[\frac{x_i - x_{mean}}{x_{max} - x_{min}} \right] + 0.5 \quad (8)$$

در این رابطه N_i مقادیر نرمال شده، x_i مقادیر واقعی، x_{mean} میانگین مقادیر واقعی، x_{max} حداکثر مقادیر واقعی، x_{min} حداقل مقادیر واقعی است.

آنچه که در آموزش یک شبکه مهم می‌باشد آن است که شبکه قادر باشد به ازای یک بردار ورودی که با آن آموزش ندیده است خروجی مرتبط با آن را ارائه نماید. به‌طور کلی هدف از آموزش شبکه عصبی، قابلیت درونیابی آن برای کلیه سری‌های آموزشی است. تاکنون روش‌های متعددی جهت آموزش شبکه‌ها ارائه شده است. برتری هر روش نسبت به روش دیگر را می‌توان در دقت و سرعت یادگیری جستجو نمود.

در این پژوهش از تکنیک بهینه‌سازی لونیبرگ-مارکوات^۱ با توجه به سرعت بالای هم‌گرایی آن به جواب نهایی، برای آموزش شبکه استفاده شده است. این روش یک تقریب برای ماتریس هسین^۲ در تغییر وزن‌ها مانند روش نیوتن در نظر می‌گیرد و رابطه آن به‌صورت زیر است (کیسی، ۲۰۰۴):

$$x_{k+1} = x_k - [J^T \cdot J + \mu \cdot I]^{-1} \cdot J^T \cdot e \quad (9)$$

در رابطه بالا، x وزن‌های شبکه عصبی، J ژاکوبین ماتریس معیار اجرای شبکه است که باید حداقل شود، μ عددی است که فرایند آموزش را کنترل می‌کند و e بردار خطای باقی‌مانده است. وقتی μ صفر باشد، معادله فوق همان روش نیوتن است که از روش هسین استفاده می‌کند، ولی وقتی μ مقداری بزرگ باشد، معادله تبدیل به یک رابطه کاهش گرادیان با فاصله زمانی کم می‌شود. روش نیوتن از سرعت بالایی برخوردار است و نتایج آن بسیار نزدیک به حداقل خطا خواهد بود.

معیارهای ارزیابی نتایج شبکه عصبی مصنوعی: منظور از میزان یادگیری و عملکرد این است که شبکه تا چه حد قادر است به ورودی‌هایی که توسط آن‌ها آموزش داده شده و به ورودی‌های جدیدی

1. Levenberg Marquardt
2. Hessian

که در دسته آموزشی نیستند جواب قابل قبول ارائه دهد. به این منظور از آماره‌های مختلف مانند ضریب تعیین، جذر میانگین مربعات خطا و مقایسه داده‌های واقعی با داده‌های مقایسه شده با توجه به خط ایده‌آل (۱:۱) استفاده شده است. در این پژوهش جهت ارزیابی نتایج شبکه عصبی مصنوعی، از معیارهای میانگین مجذورات خطا ($MSE, mm^2/day^2$) و ضریب نکویی برازش (R) ضریب همبستگی) استفاده شده است (کیسی، ۲۰۰۴).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_{actual_i} - y_{forecast_i})^2 \quad (10)$$

$$R = \frac{\sum x \cdot y}{\sqrt{\sum (x^2) \cdot \sum (y^2)}} \quad (11)$$

در رابطه‌های بالا، y_{actual} : مقدار واقعی متغیر، $y_{forecast}$: مقدار پیش‌بینی شده متغیر، \bar{y} : مقدار متوسط متغیر، n : تعداد الگوها و $x = y_{forecast} - \bar{y}_{forecast}$ ، $y = y_{actual} - \bar{y}_{actual}$ است.

مواد و روش‌ها

توصیف داده‌ها و مشخصات منطقه و ایستگاه هواشناسی مورد استفاده: اطلاعات مورد نیاز برای انجام این پژوهش، از ایستگاه هواشناسی هاشم‌آباد گرگان واقع در شمال غرب گرگان و به فاصله ۸ کیلومتری از مرز تراکم شهر گرگان، اخذ گردید. این ایستگاه دارای طول جغرافیایی ۵۴ درجه و ۱۶ دقیقه و عرض جغرافیایی ۳۶ درجه و ۵۱ دقیقه و ارتفاع ۱۳/۳ متر از سطح دریا می‌باشد. نوع خاک منطقه، خاک‌های عمیق رسی لومی و براون جنگلی می‌باشد. محصولات کشت شده در منطقه، گندم، جو، پنبه، سویا، برنج، آفتابگردان، ذرت، کلزا، صیفی و سبزی، مرکبات و زیتون است. اقلیم کشاورزی منطقه مطابق با تقسیم‌بندی دومارتن، نیمه‌خشک و بر اساس طبقه‌بندی آمبرژه، نیمه‌مرطوب می‌باشد (شریفان و همکاران، ۲۰۰۶). متوسط حداکثر دما در دوره بلندمدت ۲۳ ساله، ۲۲/۶ درجه سانتی‌گراد و متوسط حداقل دما، ۱۲/۴ درجه سانتی‌گراد و میانگین سالانه بارندگی، ۵۲۷/۴ میلی‌متر و متوسط میزان تبخیر سالانه، ۱۳۲۱ میلی‌متر است.

در این پژوهش از آمار هواشناسی ایستگاه یاد شده در بازه زمانی ۱۳۸۶-۱۳۸۲، استفاده شد. پارامترهای روزانه هواشناسی عبارتند از: درجه حرارت، T ، رطوبت نسبی، RH ، سرعت باد، W ، ساعات آفتابی، S و تبخیر، E . جهت آموزش و صحت‌سنجی شبکه عصبی از ۸۰ درصد داده‌ها استفاده

گردید و بقیه جهت آزمون شبکه مورد استفاده قرار گرفت. پارامترهای آماری مجموعه داده‌ها در جدول (۱) ارائه شده است. در جدول ۱، x_{mean} میانگین داده‌ها، s_x انحراف معیار داده‌ها، CV، ضریب تغییرات c_{sx} ، ضریب چولگی، x_{max} مقدار حداکثر، x_{min} مقدار حداقل و R، مقدار همبستگی داده‌ها با تبخیر می‌باشند.

جدول ۱- پارامترهای آماری مجموعه داده‌ها.

| R | C_{sx} | X_{min} | X_{max} | CV | S_x | X_{mean} | واحد اندازه‌گیری | مجموعه داده‌ها |
|-------|----------|-----------|-----------|------|-------|------------|----------------------|------------------|
| ۰/۸۶ | -۰/۱۰ | ۳/۱۰ | ۳۲/۷۰ | ۰/۴۱ | ۷/۸۱ | ۱۸/۹۶ | درجه سانتی‌گراد (°C) | درجه حرارت (T) |
| -۰/۵۷ | -۰/۲۶ | ۲۷/۵۰ | ۹۲/۵۰ | ۰/۱۵ | ۱۰/۰۴ | ۶۷/۱۹ | درصد (%) | رطوبت نسبی (RH) |
| ۰/۲۵ | ۱/۷۳ | ۲/۰۰ | ۱۷/۰۰ | ۰/۴۰ | ۲/۲۷ | ۵/۶۳ | متر بر ثانیه (m/s) | سرعت باد (W) |
| ۰/۴۵ | -۰/۳۱ | ۰/۱۰ | ۱۳/۳۰ | ۰/۵۳ | ۳/۷۳ | ۷/۰۷ | ساعت (hr) | ساعات آفتابی (S) |
| ۰/۱ | ۰/۴۸ | ۰/۱۰ | ۹/۸۰ | ۰/۶۸ | ۲/۴۱ | ۳/۵۸ | میلی‌متر (mm) | تبخیر (E) |

همان‌طور که مشخص است، درجه حرارت بیشترین همبستگی را با تبخیر نشان داده و تأثیر آن بر میزان تبخیر بیشتر است. همچنین ضریب تغییرات رطوبت نسبی از سایر پارامترها کمتر بوده و تقریباً از توزیع نرمال پیروی می‌کند و با توجه به مقدار انحراف معیار آن پراکندگی بیشتری دارد. با توجه به مقادیر ضریب چولگی، دنباله کشیده توزیع سرعت باد در سمت راست قرار دارد.

مراحل تعیین ساختار بهینه شبکه عصبی مصنوعی: در این پژوهش به منظور شبیه‌سازی ساختار شبکه عصبی مصنوعی، از نرم‌افزار MATLAB نسخه ۷/۶ استفاده شد. به این منظور از ۱۴۶۰ رکورد ثبت شده برای این ایستگاه، تعداد ۱۱۶۰ رکورد برای آموزش و صحت‌سنجی و تعداد ۳۰۰ رکورد برای آزمون شبکه‌های مختلف استفاده شده است. در لایه‌های مخفی شبکه‌ها از تعداد نرون‌های متفاوتی استفاده شده و تعداد بهینه آن‌ها برای حداقل نمودن خطا تعیین گردیده است. روند کار با تعداد نرون‌های کم آغاز و افزودن نرون‌های اضافی تا زمانی ادامه داشت که افزایش نرون‌های بیشتر تأثیری در بهبود خطا نداشته باشند و به این منظور از ۲ تا ۱۵ نرون استفاده گردید. هم‌چنین افزایش لایه‌های مخفی از یک لایه به دو و سه لایه و آزمون توابع محرک مختلف تانژانت سیگموئید، لوگ سیگموئید و... با الگوریتم آموزشی پس‌انتشار خطا مورد استفاده قرار گرفت.

به‌منظور طراحی ساختار بهینه، شبکه عصبی برای الگوهای متعددی اجرا شد و توابع تحریک مختلف در لایه پنهان آزمون گردید. سپس از بین حالت‌های مختلف، ساختاری که در آن بیشترین ضریب تبیین و کمترین خطا وجود داشت، انتخاب شد. همچنین به‌منظور بررسی اثر پارامترهای مختلف ورودی در این پژوهش از ۵ ساختار مختلف برای ورودی شبکه عصبی استفاده شده است. در شبکه عصبی نوع اول تنها پارامتر دما، در شبکه عصبی نوع دوم درجه حرارت و ساعات آفتابی، در شبکه عصبی نوع سوم درجه حرارت، سرعت باد و رطوبت نسبی، در شبکه عصبی نوع چهارم درجه حرارت، سرعت باد و ساعات آفتابی و در نهایت در شبکه عصبی نوع پنجم درجه حرارت، ساعات آفتابی، سرعت باد و رطوبت نسبی بعنوان پارامترهای ورودی در نظر گرفته شده است.

نتایج و بحث

تمام ۵ ساختار مختلف پارامترهای ورودی توسط شبکه عصبی پرسپترون چند لایه، شبکه تابع پایه شعاعی و شبکه عصبی المانی آموزش و آزمون شدند که در نتیجه مشخص شد، نتایج به‌دست آمده از شبکه عصبی پرسپترون چند لایه از دقت بالاتری نسبت به دو شبکه پایه شعاعی و شبکه عصبی المانی برخوردار است. نتایج اجرای تعدادی از شبکه‌های عصبی مورد آزمون در جدول‌های ۲ تا ۴ ارائه شده است.

در جدول ۵ نتایج به‌دست آمده از آموزش و آزمون شبکه پرسپترون چند لایه برای ۵ نوع ساختار مختلف ورودی ارائه شده است. پس از آزمون و خطاهای مختلف و در نظر گرفتن ورودی‌ها و توابع محرک مختلف، نتایج بیانگر این واقعیت بود که شبکه عصبی نوع پنجم با سه لایه، شامل یک لایه ورودی با ۴ نرون و یک لایه خروجی با یک نرون و یک لایه مخفی با ۱۰ نرون و تابع محرک تانژانت هیپربولیک، ساختار برگزیده این پژوهش است. هر چند توابع محرک سیگموئید و خطی نیز، در این مطالعه مورد استفاده قرار گرفتند، اما تابع محرک هیپربولیک در شبیه‌سازی تبخیر از توانایی بیشتری برخوردار بود. مقایسه نتایج به‌دست آمده از ساختار دوم و چهارم نشان می‌دهد که افزودن پارامتر سرعت باد تأثیر زیادی در بهبود نتایج ندارد. نتایج نشان می‌دهد که ساختار پنجم از دقت بالاتری نسبت به سایر ساختارها برخوردار است.

امیراحمد دهقانی و همکاران

جدول ۲- نتایج تعدادی از شبکه‌های عصبی پرسپترون سه لایه مورد آزمون.

| مجدور مربعات میانگین خطا | | ضریب تبیین | | تابع محرک | تعداد نرون (لایه پنهان) |
|--------------------------|-------|------------|--------|-------------------|----------------------------|
| آزمون | آموزش | آزمون | آموزش | | |
| ۰/۷۳۰ | ۰/۲۵۹ | ۰/۹۲۸۳ | ۰/۹۱۱۶ | تانزانٹ سیگموئید | ۵ |
| ۰/۷۱۰ | ۰/۲۵۰ | ۰/۹۲۵۱ | ۰/۹۱۴۱ | تانزانٹ سیگموئید | ۹ |
| ۰/۷۰۵ | ۰/۲۴۹ | ۰/۹۲۹۷ | ۰/۹۲۴۷ | تانزانٹ سیگموئید | ۱۴ |
| ۰/۷۳۲ | ۰/۲۶۰ | ۰/۹۲۸۵ | ۰/۹۲۱۲ | تانزانٹ هیپربولیک | ۴ |
| ۰/۶۸۶ | ۰/۲۴۶ | ۰/۹۳۶۰ | ۰/۹۴۰۰ | تانزانٹ هیپربولیک | ۱۰ |

جدول ۳- نتایج تعدادی از شبکه‌های عصبی المانی سه لایه مورد آزمون.

| مجدور مربعات میانگین خطا | | ضریب تبیین | | تابع محرک | تعداد نرون (لایه پنهان) |
|--------------------------|-------|------------|--------|-------------------|----------------------------|
| آزمون | آموزش | آزمون | آموزش | | |
| ۰/۷۳۲۲ | ۰/۲۵۲ | ۰/۹۱۴۱ | ۰/۹۱۳۶ | تانزانٹ سیگموئید | ۴ |
| ۰/۷۱۰۲ | ۰/۲۳۴ | ۰/۹۲۶۰ | ۰/۹۲۸۰ | تانزانٹ سیگموئید | ۵ |
| ۰/۷۳۱۷ | ۰/۲۴۹ | ۰/۹۲۴۹ | ۰/۹۲۴۶ | تانزانٹ هیپربولیک | ۸ |
| ۰/۷۳۱۹ | ۰/۲۴۶ | ۰/۹۲۵۲ | ۰/۹۲۵۵ | تانزانٹ هیپربولیک | ۹ |
| ۰/۷۳۲۶ | ۰/۲۴۷ | ۰/۹۲۴۳ | ۰/۹۲۵۷ | تانزانٹ هیپربولیک | ۱۰ |

جدول ۴- نتایج تعدادی از شبکه‌های عصبی توابع پایه شعاعی مورد آزمون.

| مجدور مربعات میانگین خطا | | ضریب تبیین | تابع محرک | عرض نرون |
|--------------------------|--------|------------|-----------|----------|
| آزمون | آموزش | | | |
| ۰/۷۴۱۰ | ۰/۹۰۶۵ | گوسین | ۴/۵ | |
| ۰/۷۴۱۸ | ۰/۹۰۶۶ | گوسین | ۴/۲ | |
| ۰/۷۳۹۰ | ۰/۹۱۷۱ | گوسین | ۳/۹ | |
| ۰/۷۴۰۱ | ۰/۹۰۱۵ | گوسین | ۳/۶ | |
| ۰/۷۴۱۳ | ۰/۹۰۶۹ | گوسین | ۲/۹ | |

جدول ۵- خلاصه آماره‌های مختلف مربوط به ساختارهای مختلف، با یک لایه پنهان.

| ساختار | مجموعه ورودی | تعداد نرون لایه مخفی | تابع محرک | ضریب تبیین R | |
|------------------|--------------|----------------------|-------------------|----------------|-------|
| | | | | آزمون | آموزش |
| ANN ₁ | T | ۱۰ | تانژانت هیپربولیک | ۰/۹۱ | ۰/۹۰۴ |
| ANN ₂ | T, S | ۸ | تانژانت هیپربولیک | ۰/۹۴ | ۰/۹۳۵ |
| ANN ₃ | T, RH, W | ۸ | تانژانت هیپربولیک | ۰/۹۳ | ۰/۹۲۲ |
| ANN ₄ | T, S, W | ۸ | تانژانت هیپربولیک | ۰/۹۳ | ۰/۹۳۴ |
| ANN ₅ | T, RH, S, W | ۱۰ | تانژانت هیپربولیک | ۰/۹۴ | ۰/۹۳۶ |

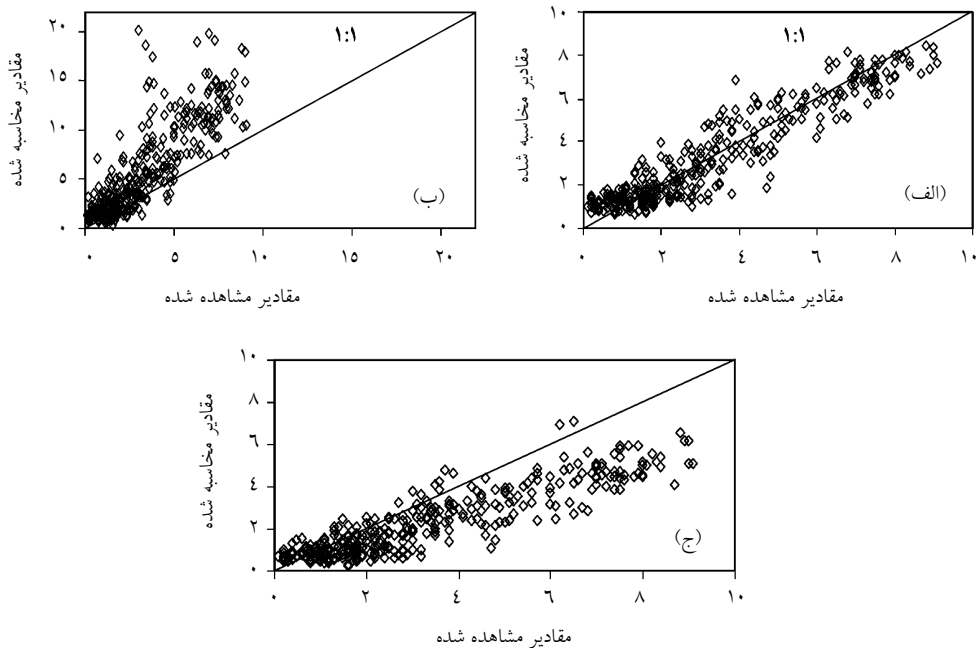
T، درجه حرارت، S، ساعات آفتابی، RH، رطوبت نسبی، W، سرعت باد.

مقایسه نتایج به دست آمده از شبکه عصبی مصنوعی با رابطه‌های تجربی موجود: در جدول ۶ نتایج به دست آمده از رابطه ۱، روش پنمن و روش‌های شبکه عصبی مصنوعی، برای داده‌های آزمون، مورد مقایسه قرار گرفته است. همچنین در شکل ۴، نمودار تغییرات مقادیر محاسبه شده از روش شبکه عصبی مصنوعی، روش عمومی (رابطه ۱) و روش پنمن را برحسب مقادیر مشاهده شده نشان می‌دهد. در این شکل‌ها خطی با شیب ۴۵ درجه نیز نشان داده شده است. با توجه به شکل (۴-الف) مشخص است که نتایج به دست آمده از شبکه عصبی مصنوعی حول خط ۴۵ درجه به خوبی پراکنده شده‌اند، در حالی که نتایج روش عمومی (رابطه ۱) و روش پنمن به ترتیب مقادیر واقعی تبخیر را بیشتر و کمتر محاسبه می‌کنند (شکل ۴-ب و ۴-ج). بنابراین استفاده از روش شبکه عصبی مصنوعی موجب دقیق شدن نتایج تخمین تبخیر شده است.


آنالیز حساسیت و تاثیر هر یک از پارامترها: به منظور بررسی میزان تاثیر پارامترهای ورودی بر مقدار محاسبه شده تبخیر از تشتک، از آنالیز حساسیت به روش هیل (۱۹۹۸) استفاده شد. در این روش هر بار یکی از پارامترهای ورودی به میزان ۱۰ درصد افزایش یافته و با ثابت نگاه داشتن مقادیر بقیه پارامترها، مقدار تبخیر با استفاده از شبکه عصبی آموزش یافته محاسبه می‌گردد. سپس با توجه به اختلاف مقادیر محاسبه شده با مقادیر اندازه‌گیری شده، ضریب نسبی آنالیز حساسیت محاسبه گردید.

جدول ۶- مقایسه ضریب همبستگی و میانگین مربعات خطای نتایج روش شبکه عصبی مصنوعی و روابط تجربی.

| معیار ارزیابی | ANN ₁ | ANN ₂ | ANN ₃ | ANN ₄ | ANN ₅ | رابطه ۱ | روش پنمن |
|---------------------------------|------------------|------------------|------------------|------------------|------------------|---------|----------|
| میانگین مجذورات خطا، <i>MSE</i> | ۱/۰۱۳ | ۰/۷۱۲ | ۰/۸۳۳ | ۰/۷۱۸ | ۰/۶۸۶ | ۱۴/۱۳۸ | ۲/۳۷۸ |
| ضریب نکویی برازش <i>R</i> | ۰/۹۰۴ | ۰/۹۳۵ | ۰/۹۲۲ | ۰/۹۳۴ | ۰/۹۳۶ | ۰/۸۴۷ | ۰/۹۰۱ |



مقادیر ضریب نسبی آنالیز حساسیت برای ۴ پارامتر ورودی در شکل ۵ نشان داده شده است. مطابق شکل ۵ به ترتیب دما، رطوبت نسبی، ساعات آفتابی و در نهایت سرعت باد بر مقدار تبخیر مؤثر هستند. بنابراین پارامترهای دما و سرعت باد به ترتیب بیشترین و کمترین تأثیر را در تخمین مقدار تبخیر از تشتک دارا می‌باشد. این نتایج با مقادیر ماتریس همبستگی تبخیر و سایر پارامترها و نتایج شایان‌نژاد و همکاران (۲۰۰۷) نیز هم‌خوانی دارد.



شکل ۵- مقادیر ضریب نسبی آنالیز حساسیت برای پارامترهای مختلف ورودی.

نتیجه‌گیری

این پژوهش کارایی و توانایی روش شبکه عصبی در پیش‌بینی میزان تبخیر روزانه از تشت تبخیر را نمایش داد. همچنین نتایج نشان داد که در مدل‌سازی تبخیر، بهترین گزینه استفاده از ساختار ANN₅ با ۴ پارامتر ورودی درجه حرارت، ساعات آفتابی، سرعت باد و رطوبت نسبی می‌باشد. ساختارهای ANN₂ و ANN₄ نیز دقت مناسب برای پیش‌بینی تبخیر دارند، اما میزان خطای ساختار ANN₅ کمتر می‌باشد.

نتایج نشان می‌دهد که دقت شبکه عصبی مصنوعی حتی با یک ورودی (ANN₁)، نیز از روابط تجربی بیشتر است. اگر چه میزان همبستگی در هر دو روش بسیار نزدیک به هم می‌باشد، اما میزان خطا در ساختار ANN₁ کمتر می‌باشد. همچنین آنالیز حساسیت بر روی پارامترهای ورودی بر میزان تبخیر محاسبه شده توسط شبکه عصبی مصنوعی نشان می‌دهد که پارامترهای دما و سرعت باد به ترتیب بیشترین و کمترین تاثیر را در تخمین مقدار تبخیر از تشتک دارا می‌باشند.

منابع

1. Alizadeh, A. 1998. Applied hydrology principles. Astane Ghods Press (Imam Reza), Iran, 807p. (In Persian)
2. Bruton, J.M., McClendon, R.W., and Hoogenboom, G. 2000. Estimating daily pan evaporation with artificial neural network. Trans. ASAE. 43:2. 492-496.
3. Brutsaert, W.H. 1982. Evaporation into the Atmosphere. D. Reidel, Dordrecht, Holland. 299p

4. Chio, Jae-ho., Teresa, A., Bahia, M., and Hussain, U. 2004. Pavement Roughness Modeling Using Back-Propagation Neural Networks. *Computer-Aided Civil and Infrastructure Engineering*, 19:4. 295-303.
5. Cigizoglu, H.K., and Kisi, O. 2006. Methods to improve the neural network performance in suspended sediment estimation. *J. Hydrology*. 317: 221-238.
6. Coulomb, C.V., Legesse, D., Gasse, F., Travi, Y., and Chernet, T. 2001. Lake evaporation estimates in tropical Africa (Lake Ziway, Ethiopia). *J. Hydrol.* 245:1-18.
7. Ejlali, F. 2004. *Weather and climatology*. Payamnoor University Press, Iran. 328p. (In Persian)
8. Frevert, D.K., Hill, R.W., and Braaten, B.C. 1983. Estimation of FAO evapotranspiration coefficients. *J. Irrig. Drain. Eng. ASCE* 109:2. 265-270.
9. Hill, M.C. 1998. *Methods and guidelines for effective models calibration*. U.S. Geological survey water resources investigation, Report No. 98-4005, Reston, U.S. 90p.
10. Irmak, S., Haman, D., and Jones, J.W. 2002. Evaluation of class 'A' pan coefficients for estimating reference evapotranspiration in a humid location. *J. Irrig. Drain. Eng. ASCE* 128:3. 153-159.
11. Jackson, R.D. 1985. Evaluating evapotranspiration at local and regional scales. *Proc. IEEE* 73:6. 1086-1096.
12. Jirak, G.H., Doneker, R.L., and Hinston, S.W. 1996. *User's Manual for Cormix: A Hydrodynamic Mixing Zone Model and Decision Support System for Pollutant Discharge into Surface Waters*", Office of Science and Technology US-EPA, Washington, DC 20460. 46p.
13. Karamooz, M., and Araghinezhad, Sh. 2006. *Advance Hydrology*. Amirkabir University Press, Iran. 480p. (In Persian)
14. Kisi, O. 2004. Multi-layer perceptions with Levenberg–Marquardt training algorithm for suspended sediment concentration prediction and estimation. *Hydrol. Sci. J.* 49:6. 1025-1040.
15. Kisi, O. 2005a. Suspended sediment estimation using neuro-fuzzy and neural network approaches. *Hydrol. Sci. J.* 50:4. 683-696.
16. Kisi, O. 2005b. Daily river flow forecasting using artificial neural networks and auto-regressive models. *Turk. J. Eng. Environ. Sci.* 29: 9-20.
17. Kisi, O. 2006. Daily pan evaporation modelling using a neuro-fuzzy computing technique. *J. Hydrol.* 329; 636-646.
18. Reis, R.J., and Dias, N.L. 1998. Multi-season lake evaporation: energy budget estimates and CRLE model assessment with limited meteorological observations. *J. Hydrology*. 20:8. 135-147.

19. Stephens, J.C., and Stewart, E.H. 1963. A comparison of procedures for computing evaporation and evapotranspiration. Publication 62, International Association of Scientific Hydrology. International Union of Geodynamics and Geophysics, Berkeley, CA, Pp: 123-133.
20. Sharifan, H., Ghahreman, B., Alizadeh, A., and Mirlatifi, S.M. 2006. Comparison of the different methods of estimated reference evapotranspiration (compound and temperature) with standard method and analysis of aridity effects. J. Agric. Sci. and Natur. Resour. 13: 19-30. (In Persian)
21. Shayannejad, M., Sadatinejad, J., and Fahmi, H. 2007. Determination of evapotranspiration by using fuzzy regression. Iranian Water Research Journal. 3: 9-19. (In Persian)
22. Tayfur, G. 2002. Artificial neural networks for sheet sediment transport. Hydrol. Sci. J. 4:6. 879-892.



Gorgan University of Agricultural
Sciences and Natural Resources

J. of Water and Soil Conservation, Vol. 17(2), 2010
www.gau.ac.ir/journals

Estimation of Daily Pan Evaporation By Using MLP, RBF and Recurrent Neural Networks

***A.A. Dehghani¹, M. Piri², M. Hesam¹ and N. Dehghani³**

¹Assistant Prof., Dept. of Water Engineering, Gorgan University of Agricultural Sciences and Natural Resources, ²M.Sc. Student, Dept. of Water Engineering, Gorgan University of Agricultural Sciences and Natural Resources, ³M.Sc. Student, Dept. of Watershed Management, Tarbiat Modarres, Nour

Abstract

Evaporation is one of the important parameters in hydrology and water resource engineering which is attractive for researchers. Due to interaction between various meteorology parameters, the estimation of evaporation is complicated. There are some nonlinear relations for assessing the evaporation. Artificial neural networks are innovative approaches for estimation and prediction by using learning concept. In this study, by using the daily data of Hashem Abad synoptical station in gorgan, the multilayer perceptron networks, radial basis function networks and element neural networks have been used. The various combinations of daily climatic variables, i. e. air temperature, and duration of sunshine, wind speed and humidity were selected as input parameters and evaporation was used as output parameter. A comparison is made between the estimated provided by ANN models and experimental existence relations as well. To evaluate the effective input parameters on evaporation a sensitivity analysis was used. The results shows that air temperature and wind speed have the maximum and minimum effect on estimation of daily evaporation. The results also show that ANN models perform better than the available experimental relations.

Keywords: Back propagation algorithm, Sensitivity analysis, Daily evaporation, Artificial neural networks

* Corresponding Author; Email: a.dehghani@gau.ac.ir

