

بررسی تأثیر عناصر اقلیمی بر افزایش دقت روش شبکه عصبی مصنوعی در پیش‌بینی خشک‌سالی منطقه یزد

حمیده افخمی^{*}، محمدتقی دستورانی، حسین ملکی نژاد و محمد حسین مبین^۱

(تاریخ دریافت: ۱۳۸۸/۵/۲۴؛ تاریخ پذیرش: ۱۳۸۸/۱۰/۲۶)

چکیده

خشک‌سالی یک شکل طبیعی از اوضاع آب و هوایی است که تکرار آن در طول زمان امری اجتناب ناپذیر می‌باشد. هدف اصلی این تحقیق بررسی تأثیر نوع عوامل اقلیمی در پیش‌بینی خشک‌سالی با استفاده از شبکه عصبی مصنوعی در مناطق مختلف استان یزد است. در اغلب ایستگاه‌های هواشناسی منطقه یزد (ایستگاه‌های باران‌سنجی) تنها داده‌های مربوط به عامل بارش موجود می‌باشد، در حالی که ایستگاه‌های همدیدی علاوه بر بارش سایر عوامل هواشناسی از جمله دمای بیشینه، دمای میانگین، رطوبت نسبی، سرعت میانگین باد، جهت باد و میزان تبخیر را نیز دارا هستند. در این تحقیق سعی گردید که نقش تعداد و نوع عوامل اقلیمی (به عنوان عوامل ورودی مدل) در دقت پیش‌بینی خشک‌سالی بر اساس شبکه‌های عصبی مصنوعی مورد ارزیابی قرار گیرد. منطقه مورد بررسی بخشی از استان یزد است که در بر گیرنده ۱۳ ایستگاه کلیماتولوژی و ۱ ایستگاه همدیدی است. جهت انجام این بررسی میانگین متحرک سه ساله بارش در تمام ایستگاه‌ها محاسبه شد و سپس با استفاده از مدل شبکه برگشتی با تأخیر زمانی (Time Lag Recurrent Network)، میانگین متحرک بارش یک سال آینده پیش‌بینی گردید، که خود عامل اصلی ارزیابی وضعیت خشک‌سالی در سال آتی است. علاوه بر آن در ایستگاه همدیدی یزد نیز شبیه‌سازی‌ها با ترکیبات مختلفی از ورودی‌ها انجام گرفت. بهترین ترکیب ورودی ترکیب "میانگین متحرک بارش - دمای بیشینه" بود که ضریب کارایی آن حدود ۰/۹۰ محاسبه شد. بررسی‌ها نشان داد علی‌رغم این که در ۱۳ ایستگاه باران‌سنجی منطقه شبیه‌سازی‌ها تنها با یک ورودی (بارش) انجام گرفت، در برخی ایستگاه‌ها نتایج قابل قبولی به دست آمد که حتی ضریب کارایی محاسبه شده بر اساس نتایج حاصله بسیار نزدیک به ایستگاه یزد (با ورودی‌های مختلف) محاسبه گردید. (R^2 از ۰/۴۸ تا ۰/۹۰ در ایستگاه آقا خرائق تا ۰/۹۰ در ایستگاه گاریز متغیر بود). البته میزان درستی پیش‌بینی‌ها هنگامی که فقط از یک عامل ورودی در مدل استفاده شده است از ایستگاهی به ایستگاه دیگر متفاوت بوده است. نتایج به دست آمده گویای انعطاف‌پذیری قابل ملاحظه مدل‌های شبکه عصبی مصنوعی است که آنها را به ابزار مناسبی جهت مدل‌سازی در شرایطی که با فقر داده مواجه هستیم مبدل می‌سازد.

واژه‌های کلیدی: پیش‌بینی خشک‌سالی، شبکه عصبی مصنوعی، میانگین متحرک بارش، شبیه‌سازی

۱. به ترتیب دانش آموخته و استادیاران آبخیزداری، دانشکده منابع طبیعی و کویر شناسی، دانشگاه یزد

*: مسئول مکاتبات، پست الکترونیکی: hamide.afkhami@gmail.com

مقدمه

در اغلب موارد خشک‌سالی حالتی رایج و مرسوم از اقلیم بوده که در گذشته با فواصل زمانی مختلف اتفاق افتاده است. اگر چه بسیاری به اشتباه آن را واقعه‌ای تصادفی و نادر می‌پندارند، اما این پدیده تقریباً در تمامی مناطق اقلیمی رخ می‌دهد و مشخصات آن می‌تواند از یک منطقه‌ای به منطقه دیگر کاملاً متفاوت باشد. مفهوم خشک‌سالی با خشکی کاملاً متفاوت است. خشکی صرفاً محدود به مناطقی با بارندگی اندک بوده و حالتی دائمی از اقلیم است. در حالی که خشک‌سالی معمولاً می‌تواند در هر نوع اقلیمی حتی مرطوب اتفاق افتد، در تعریف خشک‌سالی معمولاً برای هر منطقه‌ای یک شرایط خاص به عنوان "شرایط نرمال" تعریف می‌شود که معمولاً این شرایط نرمال در خشک‌سالی‌های هواشناسی میانگین درازمدت بارندگی سالانه و در خشک‌سالی بیولوژیک آستانه نیاز آبی گیاه مد نظر گرفته می‌شود. در این حالت مقدار بارش برای یک دوره زمانی خیلی کمتر از آستانه‌های نیاز آبی (خشک‌سالی بیولوژیک)، و یا کمتر از میانگین دراز مدت بارش (خشک‌سالی هواشناسی) می‌باشد. افزون بر این پدیده خشک‌سالی با زمان (فصل اصلی وقوع این پدیده، تأخیر در شروع فصل بارانی، وقوع بارش در ارتباط با مراحل اصلی رشد گیاه) و نیز مؤثر بودن بارش‌ها (شدت، بارش، نوع بارش، تعداد رخداد‌های بارندگی و ...) مرتبط است. سایر فاکتورهای اقلیمی نظیر دمای بالا، باد شدید و رطوبت نسبی پایین غالباً در بسیاری از نقاط جهان با این پدیده همراه شده و می‌تواند به طرز قابل ملاحظه‌ای بر شدت اثرات آن بیفزاید (۱).

خشک‌سالی را نباید صرفاً به عنوان پدیده‌ای کاملاً فیزیکی یا طبیعی در نظر گرفت. تأثیر خشک‌سالی در جامعه، ماحصل ایفای نقشی مابین یک رخداد طبیعی (بارش کمتر از حد مورد انتظار به دلیل تغییرات اقلیمی) و نیاز مردم به منابع تامین آب می‌باشد. انسان‌ها معمولاً از تأثیرات خشک‌سالی لطمه می‌بینند. خشک‌سالی‌های اخیر در هر دو گروه کشورهای توسعه یافته و در حال توسعه نتایج اقتصادی، تأثیرات زیست محیطی و

دشواری‌هایی به بار آورده که جملگی باعث شده‌اند که آسیب‌پذیری تمام جوامع به این پدیده زیان‌بخش طبیعی مد نظر قرار گرفته شود. آگاهی از وقوع خشک‌سالی در آینده می‌تواند جهت پیشگیری و یا کاهش آثار زیانبار حاصل از وقوع آن بسیار مفید واقع شود. از این رو تاکنون روش‌های مختلفی در رابطه با پیش‌بینی خشک‌سالی بیان گردیده است. مطالعات انجام شده نشان می‌دهد در اغلب موارد جهت پیش‌بینی انواع مختلف خشک‌سالی از مدل‌های آماری استفاده می‌شود که این مدل‌ها بر اساس مدل‌های سری‌های زمانی طراحی شده‌اند. روش‌های رگرسیونی و اتورگرسیونی از انواع مدل‌های سری‌های زمانی هستند که در پیش‌بینی‌ها استفاده می‌شوند. این مدل‌ها از انواع مدل‌های خطی هستند که داده‌ها در آنها به صورت ثابت فرض شده و دارای توانایی‌های محدودی در مواجهه با داده‌های غیر خطی و غیر آماری هستند. با توجه به آنچه بیان شد نیاز به مدل‌های غیر آماری و غیر خطی در پیش‌بینی‌ها ضروری می‌باشد. در دهه‌های اخیر استفاده از تکنیک شبکه‌های عصبی مصنوعی از میان انواع مدل‌های غیر خطی در پیش‌بینی مسائل مربوط به مهندسی آب و هیدرولوژی نتایج درخشانی را نشان داده است (۱۴).

استفاده از تکنیک شبکه‌های عصبی مصنوعی (ANN) در حل مسائل مهندسی از اواخر ۱۹۸۰ آغاز شد (۹ و ۱۰). مفاهیم ابتدایی شبکه عصبی مصنوعی و کاربرد آن در هیدرولوژی در قالب گزارش توسط انجمن مهندسين عمران آمریکا (ASCE) (American Society of Civil Engineers) (۴) و هم‌چنین توسط گاوینداراجو و روآ شرح داده شده است (۱۱). لیست کامل از کاربردهای ANN در هیدرولوژی را می‌توان در گزارش دوم ASCE جستجو کرد (۵). اغلب استفاده از ANN جهت پیش‌بینی و شبیه‌سازی در مسائل مربوط به منابع آب توانایی بالایی را از خود نشان داده است که در ذیل به برخی از آنها اشاره شده است. در رابطه با مدل‌سازی بارش - رواناب با استفاده از شبکه‌های عصبی مصنوعی در داخل و خارج کشور تحقیقات گسترده‌ای صورت گرفته است (۲، ۳، ۸ و ۱۷). در

تمام موارد محققان با استفاده از برخی عوامل‌های فیزیکی و اقلیمی در بالادست حوزه حجم و دبی رواناب را در خروجی حوزه پیش‌بینی کرده‌اند که در بیشتر موارد نیز نتایج موفقیت آمیزی به دست آمده است. ناجی و همکاران در سال ۲۰۰۲ به پیش‌بینی دبی رسوبی رودخانه‌ها با استفاده از شبکه پرسپترون چند لایه پرداختند. جهت انجام این تحقیق از داده‌های اندازه‌گیری شده نظیر عمق، دبی، سرعت جریان، شیب بستر، عدد فرود، سرعت سقوط ذرات و ... استفاده کرده و دبی خروجی رودخانه را پیش‌بینی کردند (۱۶).

سیگیز و گلا نیز به پیش‌بینی دبی رسوب در دو رودخانه شمال انگلستان با استفاده از شبکه عصبی مصنوعی پرداخت و سپس نتایج را با روش منحنی سنج مقایسه کرد که نتایج نشان‌دهنده برتری شبکه‌های عصبی نسبت به روش منحنی می‌باشد (۶). در تحقیق دیگری که توسط دستورانی و رایت به انجام رسیده است استفاده از شبکه عصبی مصنوعی در پیش‌بینی جریان در حوضه‌های فاقد آمار است که علاوه بر آن در این تحقیق کاربرد این تکنیک در شناسایی و طبقه‌بندی حوزه‌هایی که از نظر هیدرولوژیکی مشابه هستند نیز مورد ارزیابی قرار گرفت و در هر دو مورد نتایج مناسبی ارائه نمود [۷]. در رابطه با خشک‌سالی نیز مطالعاتی انجام شده که از آن جمله می‌توان به تحقیقات میشر و دیسای در این خصوص اشاره کرد (۱۲، ۱۳ و ۱۴). این دو محقق در سال ۲۰۰۵ پیش‌بینی خشک‌سالی در حوزه کانسباتی هند را با استفاده از مدل‌های آماری انجام دادند و سپس در سال ۲۰۰۶ به مقایسه روش‌های آماری و شبکه‌های عصبی مصنوعی در پیش‌بینی خشک‌سالی پرداختند که نتایج نشان‌دهنده برتری شبکه‌های عصبی نسبت به روش‌های آماری بود. در تحقیق دیگری که در همین سال توسط نامبردگان انجام گرفت پیش‌بینی خشک‌سالی با استفاده از سه روش آماری، شبکه عصبی مصنوعی و مدل‌های هیبریدی با هم مقایسه شد که مدل‌های هیبرید نتایج برتری نسبت به دو روش دیگر داشت. مرید نیز پیش‌بینی خشک‌سالی در استان تهران را با به کارگیری شبکه‌های عصبی مصنوعی و استفاده از برخی


شاخص‌های خشک‌سالی انجام داد که در نهایت شاخص خشک‌سالی مؤثر (Effective Drought Index) در پیش‌بینی خشک‌سالی نسبت به شاخص‌های دیگر مؤثرتر واقع شد (۱۵). در این تحقیق نیز به پیش‌بینی خشک‌سالی در ۱۴ ایستگاه استان یزد پرداخته شده است. جهت دست‌یابی به این هدف میانگین بارش متحرک سه ساله برای یک سال آینده در تمام ایستگاه‌ها پیش‌بینی شده است. ایستگاه هواشناسی یزد یک ایستگاه همدیدی است که علاوه بر عامل بارش سایر عوامل مؤثر در پیش‌بینی خشک‌سالی را نیز دارا می‌باشد در حالی که در ۱۳ ایستگاه دیگر تنها عامل موجود، بارش است. در این مقاله سعی شده تا با مقایسه ضریب کارایی بین نتایج حاصله در ایستگاه‌های مختلف نقش حضور عوامل‌های غیر از بارش مشخص شود و اینکه آیا می‌توان با یک عامل (بارش) نیز نتایج قابل قبولی در پیش‌بینی‌ها ارائه نمود یا خیر؟

مواد و روش‌ها

ناحیه مورد مطالعه

استان یزد با مساحت حدود ۱۳۱۵۱۷ کیلومتر مربع در قسمت مرکزی فلات ایران قرار دارد. این استان در محدوده ۲۹ درجه و ۳۵ دقیقه تا ۳۵ درجه و ۷ دقیقه عرض شمالی و ۵۲ درجه و ۵۰ دقیقه تا ۵۸ درجه و ۱۶ دقیقه طول شرقی واقع شده است. ناحیه مورد مطالعه در این تحقیق بخشی از استان یزد در نظر گرفته شده است که موقعیت منطقه و ایستگاه‌های مورد نظر در شکل ۱ نمایش داده شده است.

اساس انتخاب این منطقه وجود ایستگاه‌های هواشناسی بود که در آن‌ها طول دوره آماری مربوط به بارش کافی بوده و حدود ۴۰ سال باشد. به طور کلی استان یزد به دلیل قرارگیری در کمربند خشک جهانی (۲۵ تا ۴۰ درجه عرض شمالی) و دوری از دریا یکی از استان‌های خشک کشور محسوب می‌شود که وقوع پدیده خشک‌سالی در آن خسارت‌بارتر می‌باشد. بیشینه دما در تیرماه به 46°C می‌رسد و دوره‌های خشک اغلب با دماهای بالا منطبق است که این منجر به تبخیر بالا از سطح



شکل ۱. نمایش نقشه موقعیت ایستگاه‌های منتخب در این تحقیق

نوع، موقعیت جغرافیایی و مشخصات این ایستگاه‌ها در جدول ۱ نمایش داده شده است. ایستگاه یزد به عنوان تنها ایستگاه همدیدی با آمار طولانی مدت در منطقه مورد نظر می باشد که علاوه بر عامل بارش دارای آمار مربوط به دمای بیشینه، دمای میانگین، سرعت باد، جهت باد، رطوبت نسبی و تبخیر نیز می باشد. در سایر ایستگاه‌ها که عبارت اند از مزرحه آقا خرائق، مزرحه نو عقدا، اردکان، ابرکوه، گارین، باجگان، حاج آباد زردین، باجنار تفت، دهشیر، خویدک، نصرآباد، قطروم و ساغند تنها

خاک و تعرق از سطح پوشش گیاهی می شود. میزان بارش سالیانه در استان از ۵۰ تا ۶۰ میلی متر در مناطق دشتی تا ۳۰۰ میلی متر در ارتفاعات شیرکوه متغیر است. وقوع خشک سالی و برداشت بیش از حد از سطح آب های زیرزمینی در سال های اخیر منجر به افت شدید آب در این استان شده است. از این رو اعمال مدیریت مناسب منابع آب در منطقه امری ضروری می باشد.

در این مطالعه ۱۴ ایستگاه هواشناسی در نظر گرفته شد که

جدول ۱. موقعیت ایستگاه‌های انتخابی در منطقه مورد نظر در این تحقیق

ردیف	ایستگاه	نوع	شهرستان	تأسیس	ارتفاع	طول جغرافیایی	عرض جغرافیایی
۱	ابركوه	همدیدی	ابركوه	۲۰۰۲	۵۰۶	۵۳° ۲۸' ۰۰"	۳۱° ۱۳' ۰۰"
۲	اردكان	اقلیم شناسی	اردكان	۱۹۸۱	۱۱۰۴	۵۴° ۰۲' ۰۰"	۳۲° ۳۲' ۰۰"
۳	مزرعه آقا خرائق	باران سنجی	اردكان	۱۹۶۶	۱۶۰۰	۵۴° ۳۶' ۵۵"	۳۲° ۲۰' ۴۱"
۴	مزرعه نو عقدا	باران سنجی	اردكان	۱۹۷۱	۱۳۵۰	۵۳° ۲۴' ۵۲"	۳۲° ۰۴' ۴۹"
۵	ساغند	اقلیم شناسی	اردكان	۱۹۹۰	۱۳۵۰	۵۵° ۱۴' ۴۱"	۳۲° ۳۲' ۰۲"
۶	حاج آباد زرین	باران سنجی	اردكان	۱۹۶۶	۱۳۳۸	۵۴° ۵۱' ۵۱"	۳۲° ۰۵' ۰۶"
۷	قطروم	باران سنجی	بافق	۱۹۶۵	۱۵۴۰	۵۴° ۴۸' ۰۸"	۳۱° ۲۵' ۴۱"
۸	باجگان	باران سنجی	بافق	۱۹۶۵	۲۰۶۰	۵۵° ۵۲' ۵۳"	۳۱° ۲۷' ۲۹"
۹	پاچنار تفت	اقلیم شناسی	تفت	۱۹۹۹	۱۶۰۰	۵۴° ۱۴' ۰۰"	۳۱° ۴۵' ۰۰"
۱۰	دهشیر	باران سنجی	تفت	۱۹۶۸	۱۸۵۰	۵۴° ۴۴' ۴۹"	۳۱° ۳۷' ۲۳"
۱۱	گاریز	همدیدی	تفت	۲۰۰۲	۲۴۲۰	۵۴° ۰۶' ۰۵"	۳۱° ۱۸' ۱۸"
۱۲	نصر آباد	اقلیم شناسی	تفت	۱۹۶۷	۲۰۵۰	۵۳° ۵۱' ۴۹"	۳۱° ۴۵' ۳۷"
۱۳	یزد	همدیدی	یزد	۱۹۶۱	۱۲۳۰	۵۴° ۱۷' ۰۰"	۳۱° ۵۳' ۵۶"
۱۴	خویدك	باران سنجی	یزد	۱۹۶۶	۱۲۵۰	۵۴° ۳۰' ۲۵"	۳۱° ۴۸' ۱۳"

آمار بارش ماهیانه (با طول دوره آماری بالای ۳۰ سال) موجود می‌باشد.

آماده‌سازی داده‌ها

در مطالعه حاضر به منظور پیش‌بینی خشک‌سالی در ۱۲ ماه آینده از داده‌های بلندمدت مربوط به بارش ماهیانه ایستگاه‌ها استفاده شد. این آمار در تمام ایستگاه‌ها از سال ۱۳۴۵ تا ۱۳۸۴ موجود است. با توجه به این‌که استان یزد جزء مناطق خشک کشور محسوب می‌شود، نوسانات شدید بارش از سالی به سال دیگر و حتی در ماه‌های مختلف یک سال کاملاً مشهود می‌باشد. نوسانات شدید بارش و به تبع آن پراکندگی زیاد داده‌ها منجر به پیچیدگی در فرایند آموزش مدل شده و توانایی مدل را کاهش می‌دهد. از این‌رو در این تحقیق ابتدا داده‌ها طبق رابطه (۱) نرمال شدند و سپس میانگین متحرک ۳ ساله آنها محاسبه شد و به عنوان ورودی مدل مورد استفاده قرار گرفت. خروجی مدل نیز میانگین متحرک بارش در ۱۲ ماه آینده (یکسال بعد)

می‌باشد. شایان ذکر است در ایستگاه همدیدی یزد ترکیبات مختلفی از عوامل نام برده شده تهیه و به مدل معرفی شد و در نهایت ترکیبی که مطلوب‌ترین نتیجه را به همراه داشت به عنوان ترکیب برتر و عوامل موجود در ترکیب ورودی به عنوان مهم‌ترین عوامل مؤثر در پیش‌بینی خشک‌سالی معرفی شدند.

$$X_n = \frac{x_0 - x_{\min}}{x_{\max} - x_{\min}} \quad [1]$$

که x_0 و x_n داده‌های نرمال شده و داده‌های اولیه و $x_{\max}$ و $x_{\min}$ کمینه و بیشینه داده‌های اولیه را نشان می‌دهد.

مدل‌های شبکه عصبی

شبکه عصبی مصنوعی در حقیقت یک سیستم محاسباتی است که بر اساس سیستم عصبی انسان ساخته شده است. این شبکه از تعداد بیشمار نرون‌های مصنوعی تشکیل شده است. در شبکه عصبی جانداران انتقال پیام از یک نرون به نرون دیگر توسط فضای بین سلولی به نام سیناپس (Sinaps) انجام می‌گیرد که با ترشح هورمون‌های شیمیایی پیام در بین سلول‌ها منتقل

می‌شود. همان‌گونه که میزان هورمون ترشح شده در محل اتصال سلول‌های عصبی نشان‌دهنده شدت و ضعف پیام انتقالی است، در شبکه‌های عصبی نیز مقدار عددی وزن‌ها مشخص‌کننده شدت و ضعف پیام است. انتقال پیام در شبکه‌های عصبی مصنوعی نیز از نرونی به نرون دیگر توسط مقادیر عددی انجام می‌گیرد که به آنها وزن (Weight) اطلاق می‌شود. اساس کار شبکه‌های عصبی مصنوعی بر پایه یادگیری فرایند از طریق الگو می‌باشد. این شبکه‌ها توسط داده‌های مناسبی که دربرگیرنده ورودی و خروجی باشد آموزش می‌بینند، به این دسته از داده‌ها، داده‌های آموزشی (Training data) اطلاق می‌شود. داده‌های آموزشی در این تحقیق که معمولاً ۷۰٪ کل داده‌ها را تشکیل می‌دهند میانگین متحرک سه ساله بارش می‌باشد که از سال ۱۳۴۵ تا ۱۳۸۰ در نظر گرفته شده است. در پایان مرحله آموزش شبکه توسط بخش دیگری از داده‌ها مورد آزمایش قرار می‌گیرد. این داده‌ها که به داده‌های آزمایشی (Testing data) معروف هستند اغلب ۲۰٪-۳۰٪ از کل داده‌ها را شامل می‌شوند و در این تحقیق داده‌های ماهیانه میانگین متحرک سه ساله بارش ما بین سال‌های ۱۳۸۰-۱۳۸۴ به عنوان داده‌های آزمایشی در نظر گرفته شد. لازم به ذکر است که داده‌های آزمایشی قبلاً در آموزش مدل استفاده نشده‌اند و جهت ارزیابی کارایی مدل آموزش دیده مورد استفاده قرار می‌گیرند.


مدل مورد استفاده (شبکه‌های برگشتی با تأخیر زمانی)

شبکه‌های برگشتی با تأخیر زمانی یکی از انواع شبکه‌های عصبی از نوع دینامیک هستند که دارای لایه‌هایی با اتصال برگشتی محلی می‌باشند. از ویژگی‌های مهم این شبکه‌ها وجود یک حافظه (Unit memory) بی‌نهایت عمیق است که این واحد حافظه می‌تواند بین لایه ورودی و میانی یا بین لایه میانی و خروجی و یا بین عوامل موجود در لایه میانی قرار گیرد. این حافظه اطلاعات مربوط به چرخش‌های قبلی را در خود نگه می‌دارد، بنابراین قادر است روابط بین ورودی و خروجی‌ها را

به صورت لحظه‌ای و آنی تخمین بزند. از طرفی در این نوع ساختار شبکه عصبی، آموزش مدل هم به سادگی امکان‌پذیر می‌باشد. در این تحقیق جهت انجام شبیه‌سازی از این نوع شبکه استفاده شده است. شکل ۲ حالت ساده‌ای از این نوع شبکه را نمایش می‌دهد. البته لازم به ذکر است که چندین نوع شبکه عصبی از جمله پرسپترون چند لایه و شبکه برگشتی معمولی نیز مورد آزمون قرار گرفت ولی با توجه به این‌که نتایج شبکه‌های برگشتی با تأخیر زمانی از دقت بیشتری برخوردار بود (به عبارت دیگر در این نوع شبکه مقادیر شبیه‌سازی شده به مقادیر اندازه‌گیری شده نزدیک‌تر بود)، شبکه‌های برگشتی با تأخیر زمانی به عنوان شبکه مناسب در این تحقیق در نظر گرفته شد. لازم به ذکر است در این مدل، داده‌های ورودی (بارش، دما، رطوبت و ...) از لایه ورودی به مدل داده شده است. (تعداد نرون‌های ورودی معادل تعداد عوامل ورودی می‌باشد) و سپس با تنظیم مقادیر مربوط به ضرایب و توابع مدل و قرار دادن یک لایه میانی (با تعداد نرونی معادل دو برابر تعداد عوامل ورودی) اقدام به آموزش مدل شده است. نتایج مدل که در حقیقت مقادیر بارش (میانگین متحرک بارش) در یک سال آینده بود، در لایه خروجی اخذ شده است.

الگوریتم یادگیری پس انتشار (Back Propagation)

الگوریتم یادگیری پس انتشار توسط رومل هارت و همکارانش در سال ۱۹۶۸ توسعه پیدا کرد. این الگوریتم در اغلب موارد در شبکه‌ها عصبی مصنوعی به کار می‌رود که در آن جهت تصحیح وزن‌ها از روش دیگری موسوم به کاهش شیب نزولی (Gradient decent) استفاده می‌شود. در قانون پس انتشار وزن‌ها با استفاده از روش همگرایی خطا مکرراً تغییر یافته و تعدیل می‌شوند تا در نهایت وزن‌های مطلوب به دست آید. در این میان در هر مرحله میزان خطا در لایه خروجی به لایه ورودی انتقال یافته و مجدداً عمل تجدید وزن‌ها صورت می‌گیرد تا در نهایت خروجی مطلوب به دست آید. الگوریتم کاهش شیب جهت حداقل کردن خطا در خروجی مدل کاربرد



شکل ۲. حالت ساده‌ای از شبکه عصبی مصنوعی از نوع "برگشتی با تأخیر زمانی" که در این تحقیق استفاده شده است.

دارد. تابع خطا در خروجی طبق رابطه ۲ تعریف می‌شود:

$$E = \frac{1}{2} \sum_k (T_k - A_k)^2 \quad [2]$$

که T_k و A_k به ترتیب داده‌های واقعی و داده‌های پیش‌بینی شده هستند.

الگوریتم کاهش شیب وزن‌ها را مطابق رابطه ۳ تعدیل

می‌کند:

$$\nabla w_{ij} = \eta \times \frac{\partial E}{\partial w_{ij}} \quad [3]$$

که η نرخ یادگیری می‌باشد و مطابق رابطه ۴ به

دست می‌آید

$$\frac{\partial E}{\partial w_{ij}} = -\delta_j^n A_i^{n-1} \quad [4]$$

با جاگذاری رابطه ۴ در رابطه ۳ خطا طبق رابطه ۵ محاسبه

می‌شود:

$$\nabla w_{ij} = \eta \delta_j^n A_i^{n-1} \quad [5]$$

که A_i^{n-1} ارزش خروجی در زیر لایه مربوط به وزن w_{ij}

می‌باشد و δ_j^n سیگنال خطاست که محاسبه آن بستگی به

این دارد که نرون j در لایه مخفی است یا خروجی. چنانچه

نرون j در لایه مخفی باشد سیگنال خطا طبق رابطه ۶ محاسبه

می‌شود:

$$\delta_j = (T_j - A_j)(1 - A_j) \quad [6]$$

و چنانچه نرون j در لایه مخفی باشد خطا طبق رابطه ۷ به

دست می‌آید:

$$\delta_j = \left[\sum_h \delta_h (w_{hj})_{hj} H_h (1 - H_h) \right] \quad [7]$$

که H_n ارزش لایه مخفی است.

در نهایت ارزش هر وزن طبق رابطه ۸ محاسبه می‌شود:

$$w_{ij}^m = w_{ij}^{m-1} + \nabla w_{ij}^m = w_{ij}^{m-1} + \eta \delta_j^n A_i^{n-1} \quad [8]$$

جهت تسریع همگرایی خطا از الگوریتم دیگری موسوم به

قانون یادگیری ممتن استفاده می‌شود که فرمول کلی آن مطابق

رابطه ۹ محاسبه می‌شود:

$$w_{ij}^m = w_{ij}^{m-1} + \eta \delta_j^n A_i^{n-1} + \alpha \nabla w_{ij}^m \quad [9]$$

که α ضریب ممتن است و بین ۰ و ۱ متغیر است. در این

تحقیق از قانون یادگیری ممتن با ضریب α برابر با ۰/۷

استفاده شده است.

توابع انتقال مورد استفاده در مدل

توابع انتقال مورد استفاده در این تحقیق عبارت‌اند از توابع

سیگموئید و تانژانت هائپربولیک.

$$RMSE = \sqrt{\frac{1}{P} \sum_{i=1}^P [(X_m) - (X_s)]^2} \quad [13]$$

که X_m و X_s به ترتیب مقادیر مربوط به داده‌های واقعی و شبیه‌سازی شده را نشان می‌دهد و P تعداد کل وقایع در نظر گرفته شده است.

نتایج و بحث

این تحقیق به منظور پیش‌بینی خشک‌سالی در ۱۴ ایستگاه منطقه یزد صورت گرفت و طی آن میانگین متحرک بارش در یک‌سال آینده با استفاده از روش شبکه عصبی مصنوعی پیش‌بینی شد. داده‌ها در هر ایستگاه به دو دسته تقسیم شدند. دسته اول شامل داده‌های مربوط به بارش از سال ۱۳۴۵ تا ۱۳۸۰ بود که به عنوان داده‌های آموزشی به شبکه معرفی شد و دسته دوم شامل داده‌های مربوط به سال‌های ۱۳۸۰ تا ۱۳۸۴ بود که به عنوان داده‌های آزمایشی مورد استفاده قرار گرفت. در ایستگاه یزد ورودی‌ها شامل ترکیبات مختلفی از میانگین متحرک بارش، دما، رطوبت، تبخیر، سرعت و جهت باد بوده و خروجی مدل نیز میانگین متحرک بارش در یک سال آینده بود. البته با توجه به محدودیت داده در سایر ایستگاه‌ها، ورودی مدل تنها میانگین متحرک بارش در نظر گرفته شد. در این تحقیق پس از ارزیابی و آزمون ساختارهای مختلف شبکه عصبی، از مدل شبکه‌های برگشتی با تأخیر زمانی استفاده شد و شبیه‌سازی‌ها با تعداد چرخش‌های (Epoch) مختلف مدل انجام گرفت. میزان نرون‌های لایه مخفی متناسب با $2n$ طراحی شد که n متناسب با تعداد عوامل ورودی به مدل می‌باشد. در نهایت به منظور ارزیابی نتایج از دو عامل RMSE و R استفاده شد. نتایج شبیه‌سازی در ایستگاه همدیدی یزد نشان می‌دهد بالاترین مقدار جذر ضریب کارایی مربوط به ترکیب‌ها "میانگین متحرک بارش، دمای بیشینه" و "میانگین متحرک بارش، دمای میانگین" است که میزان عددی هر دو حدود ۰/۹۵ و RMSE آنها به ترتیب برابر با ۰/۰۵ و ۰/۰۶ می‌باشد. بعد از آن، دو ترکیب "میانگین متحرک بارش، سرعت باد" و "میانگین متحرک بارش،

فرمول کلی تابع سیگموئید در رابطه ۱۰ مشاهده می‌شود

$$\alpha = \frac{1}{1 + e^{-n}} \quad [10]$$

این تابع یکی از توابع پرکاربرد در شبیه‌سازی‌هاست که می‌تواند هم در لایه میانی و هم در لایه خروجی به خوبی عمل کند. در این تحقیق تابع سیگموئید در لایه میانی به عنوان یک تابع مطلوب شناخته شده است.

فرمول کلی تابع تانژانت هایپربولیک در رابطه ۱۱ نمایش

داده شده است

$$\alpha = \frac{e^n - e^{-n}}{e^n + e^{-n}} \quad [11]$$

در بررسی حاضر تابع تانژانت هایپربولیک در لایه خروجی منجر به بهبود نتایج شد. در ایستگاه یزد که تعداد عوامل ورودی بیش از یک عامل بود، این تابع در لایه میانی نیز نسبت به تابع سیگموئید نتایج مطلوب‌تری به دنبال داشت.

ارزیابی کارایی نتایج

در این تحقیق به منظور بررسی و ارزیابی نتایج حاصل از شبیه‌سازی‌های بارش از دو عامل جذر ضریب کارایی (Coefficient of efficiency) (R) و ریشه میانگین مربعات خطا (Root Mean Squar Error) (RMSE) استفاده گردید. فرمول کلی این دو عامل به ترتیب در روابط ۱۲ و ۱۳ نمایش داده شده است. در نهایت بهترین نتایج متعلق به ایستگاهی است که بیشترین ضریب کارایی و مقدار کوچکی از RMSE را ارائه نماید.

$$R = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)}{\sum_{i=1}^n (O_i - \bar{O})}} \quad [12]$$

که O_i و P_i به ترتیب مقادیر مربوط به داده‌های واقعی (اندازه‌گیری شده) و پیش‌بینی شده است و $\bar{O}$ میانگین داده‌های مشاهداتی و n تعداد داده‌هاست.

دمای میانگین، رطوبت نسبی " دارای R برابر با $0/93$ می باشد و $RMSE$ آن به ترتیب $0/06$ و $0/07$ است. نتایج در سایر ایستگاه ها تنها با یک عامل ورودی نیز قابل ملاحظه بود، به طوری که ایستگاه های گاریز و نصرآباد با R معادل $0/95$ و $0/94$ و $RMSE$ به ترتیب $0/04$ و $0/05$ مطلوب ترین ایستگاه ها در شبیه سازی شناخته شدند. ایستگاه های حاج آباد زرین، پاچنار تفت و باجگان با R حدود $0/93$ و $RMSE$ $0/04$ و $0/04$ و $0/02$ در رده های بعدی قرار دارند. نتایج کلی این شبیه سازی ها در جدول ۲ نمایش داده شده است. نتایج واقعی با نتایج پیش بینی شده بارش در ایستگاه های ذکر شده در شکل های ۲، ۳، ۴ و ۵ نمایش داده شده است. (نمودارهای ارائه شده مربوط به مرحله آزمایش می باشد. در این نمودارها محور افقی تعداد ماه ها و محور عمودی میانگین متحرک بارش را نمایش می دهد). لازم به ذکر است ترکیب ورودی در ایستگاه یزد (ردیف ۱۵ تا ۱۸) به ترتیب شامل میانگین متحرک بارش نرمال (Year moving average precipitation) ($3-ymap_n$) و سرعت باد ($3-ymap_n-w_s$)، میانگین متحرک بارش نرمال و دمای ماکزیمم و رطوبت نسبی ($3-ymap_n-t_{max}-Rh$)، میانگین متحرک بارش نرمال و دمای میانگین ($3-ymap_n-t_{av}$) و میانگین متحرک بارش نرمال و دمای ماکزیمم ($3-ymap_n-t_{max}$) می باشد. همان گونه که مشاهده می شود در ایستگاه یزد که بیش از یک ورودی به مدل وارد می شود در لایه میانی و خروجی تابع تانژانت هایپربولیک به عنوان تابع مطلوب و در سایر ایستگاه ها با یک ورودی تابع سیگموئید در لایه مخفی و تابع تانژانت هایپربولیک در لایه خروجی به عنوان تابع برتر شناخته شد و در اکثر موارد عناصر دینامیک لاگوار (Lagurre) و تایم دیلی ((Time delay(TDNN) کارایی مطلوبی را از خود نشان دادند. مقایسه نتایج ایستگاه یزد با سایر ایستگاه ها نشان می دهد اگر چه وجود عوامل هواشناسی منجر به بهبود نتایج می شود اما در ایستگاه هایی مثل گاریز و نصرآباد نیز در نبود عوامل هواشناسی نتایج مطلوبی به دست آمد به طوری که نتایج شبیه سازی در ایستگاه یزد در صورت عدم وجود این عامل ها نتایج

ضعیف تری را به همراه دارد (شکل ۶).

ورود عوامل هواشناسی شامل رطوبت نسبی، دما، سرعت باد، تبخیر و ... بر کارایی دقت شبیه سازی ها تأثیر بسزایی داشت، به گونه ای که بر اساس شبیه سازی هایی که در ایستگاه یزد انجام گرفت دمای بیشینه و رطوبت نسبی و سرعت باد از جمله عواملی بودند که به ترتیب بیشترین تأثیر را بر افزایش دقت پیش بینی ها داشتند.

با توجه به آنچه بیان شد، مسلم است در ایستگاه گاریز و نصر آباد، که میزان نوسانات بارش نسبت به یزد کمتر و منظم تر است، چنانچه عواملی افزون بر بارش در ورودی به شبکه استفاده شود نتایج دقیق تری نسبت به آنچه در این تحقیق به دست آمده مورد انتظار است (شکل ۳ و ۴).

نتایج به دست آمده از این تحقیق با نتایج تحقیقات میثرا و مرید که به ترتیب، خشک سالی را با استفاده از شبکه عصبی مصنوعی در حوزه کانسباتی هند و تهران انجام دادند، مقایسه شد. بر این اساس میثرا که در پیش بینی خشک سالی را با استفاده از شاخص SPI (Standard Drought Precipitation)، $3/6$ ، 12 و 24 ماهه و در تأخیرهای زمانی 1 تا 6 ماهه انجام داده بود، بهترین ضریب کارایی را با استفاده از SPI 24 ماهه و تأخیر زمانی 1 ماهه بین $0/93-0/92$ R^2 برآورد کرد. بدیهی است که با افزایش تأخیر زمانی میزان R کاهش می یابد. به طوری که میزان R^2 با تأخیر زمانی 6 ماهه به $0/63-0/59$ کاهش یافت (۱۴ و ۱۵).

مرید در منطقه تهران با استفاده از دو شاخص SPI و EDI (Effective Drought Index) و چندین مدل شبکه عصبی خشک سالی را برای $1-12$ ماه آینده پیش بینی کرد. بر اساس نتایج به دست آمده از این تحقیق بهترین مدل ها دارای ضریب کارایی بین $0/79-0/66$ R^2 در تأخیر زمانی 6 ماهه بودند که این ضریب در تأخیر زمانی 12 ماهه برای شاخص SPI به $0/62-0/54$ R^2 و برای شاخص EDI به $0/72-0/55$ R^2 کاهش می یابد (۱۵).


در تحقیق حاضر که از شاخص میانگین متحرک بارش

جدول ۲. نتایج مربوط به پیش‌بینی بارش در سایر ایستگاه‌های نام‌برده با استفاده از میانگین متحرک سه ساله


ردیف	نام ایستگاه	مدل	ترکیب ورودی	تابع پهنای مخفی استفاده شده	تابع پهنای مخفی استفاده شده	دیتایمن عنصر	Epoch	Lead Time	میانگین متحرک	R^2	R	RMSE
۱	مزرعه آقا خرائق	TLRN*	3-ymap	Sigmoid	Tanhaxon	TDNN	۲۰۰۰۰	۱۲	3-ymap	۰/۴۸	۰/۶۹	۰/۰۵
۲	ساغند	TLRN	3-ymap	Sigmoid	Tanhaxon	Gama	۲۰۰۰۰	۱۲	3-ymap	۰/۷۱	۰/۸۴	۰/۰۶
۳	ابركوه	TLRN	3-ymap	Sigmoid	Tanhaxon	TDNN	۲۰۰۰۰	۱۲	3-ymap	۰/۷۲	۰/۸۵	۰/۰۴
۴	اردكان	TLRN	3-ymap	Sigmoid	Tanhaxon	TDNN	۲۰۰۰۰	۱۲	3-ymap	۰/۷۲	۰/۸۵	۰/۰۷
۵	مزرعه نو عقدا	TLRN	3-ymap	Sigmoid	Tanhaxon	Laguarre	۲۰۰۰۰	۱۲	3-ymap	۰/۷۸	۰/۸۸	۰/۰۶
۶	يزد	TLRN	3-ymap	Sigmoid	Tanhaxon	Laguarre	۲۰۰۰۰	۱۲	3-ymap	۰/۸۶	۰/۸۷	۰/۰۶
۷	قطروم	TLRN	3-ymap	Sigmoid	Tanhaxon	TDNN	۲۰۰۰۰	۱۲	3-ymap	۰/۷۸	۰/۸۸	۰/۰۵
۸	دهشير	TLRN	3-ymap	Sigmoid	Tanhaxon	TDNN	۲۰۰۰۰	۱۲	3-ymap	۰/۷۸	۰/۸۸	۰/۰۷
۹	خويديک	TLRN	3-ymap	Sigmoid	Tanhaxon	TDNN	۲۰۰۰۰	۱۲	3-ymap	۰/۸۳	۰/۹۱	۰/۰۳
۱۰	باجگان	TLRN	3-ymap	Sigmoid	Tanhaxon	TDNN	۲۵۰۰۰	۱۲	3-ymap	۰/۸۶	۰/۹۳	۰/۰۲
۱۱	پاچنار تفت	TLRN	3-ymap	Sigmoid	Tanhaxon	Laguarre	۲۰۰۰۰	۱۲	3-ymap	۰/۸۶	۰/۹۳	۰/۰۴
۱۲	حاج آباد زرین	TLRN	3-ymap	Sigmoid	Tanhaxon	TDNN	۲۰۰۰۰	۱۲	3-ymap	۰/۸۶	۰/۹۳	۰/۰۴
۱۳	نصر آباد	TLRN	3-ymap	Sigmoid	Tanhaxon	TDNN	۲۰۰۰۰	۱۲	3-ymap	۰/۸۷	۰/۹۴	۰/۰۵
۱۴	گاريز	TLRN	3-ymap	Sigmoid	Tanhaxon	TDNN	۲۰۰۰۰	۱۲	3-ymap	۰/۹۰	۰/۹۵	۰/۰۴
۱۵	يزد	TLRN	3-ymap _n -w _s	tanhaxon	tanhaxon	TDNN	۱۰۰۰۰	۱۲	Pnor&minm3	۰/۸۶	۰/۹۲	۰/۰۶
۱۶	يزد	TLRN	3-ymap _n -t _{max} -Rh	tanhaxon	tanhaxon	TDNN	۱۰۰۰۰	۱۲	Pnor&minm3	۰/۸۶	۰/۹۳	۰/۰۶
۱۷	يزد	TLRN	3-ymap _n -t _{av}	tanhaxon	tanhaxon	TDNN	۱۸۰۰۰	۱۲	Pnor&minm3	۰/۹۰	۰/۹۵	۰/۰۷
۱۸	يزد	TLRN	3-ymap _n -t _{max}	tanhaxon	tanhaxon	TDNN	۲۲۰۰۰	۱۲	Pnor&minm3	۰/۹۰	۰/۹۵	۰/۰۵

*: منظور شبکه برگشتی با تأخیر زمانی (Time Lag Recurrent Network) است.


** : یک واحد حافظه مانند در شبکه است که در حین آموزش مدل جریان اطلاعات در شبکه را تنظیم می‌کند.




شکل ۳. مقایسه نتایج واقعی و پیش‌بینی شده میانگین متحرک بارش در ایستگاه گاريز (ورودی میانگین متحرک بارش)



شکل ۴. مقایسه نتایج واقعی و پیش‌بینی شده میانگین متحرک بارش در ایستگاه نصرآباد (ورودی میانگین متحرک بارش)




شکل ۵. مقایسه نتایج واقعی و پیش‌بینی شده میانگین متحرک بارش در ایستگاه حاج‌آباد زرین (ورودی میانگین متحرک بارش)




شکل ۶. مقایسه نتایج واقعی و پیش‌بینی شده میانگین متحرک بارش در ایستگاه یزد (ورودی میانگین متحرک بارش)

۹). نتایج به دست آمده از این تحقیق با توجه به تأخیر زمانی در نظر گرفته شده می‌تواند هم‌ردیف و گاهی بهتر از دو تحقیق فوق قلمداد گردد. این در حالی است که منطقه تحقیق حاضر از نظر اقلیمی فراخشک بوده و پراکنش داده‌ها در آن بسیار بیشتر از دو منطقه‌ای است که محققین فوق‌الذکر استفاده نموده‌اند که یکی مرطوب و دیگری نیمه خشک تا نیمه مرطوب است که میزان بارندگی سالانه چندین برابر یزد بوده و طبعاً پراکنش داده‌ها و تغییرات آنها کمتر بوده و پیش‌بینی دقیق‌تر امکان‌پذیر است.


جهت پیش‌بینی خشک‌سالی در ۱۲ ماه آینده در ایستگاه‌های مختلف استان یزد استفاده شد میزان R^2 از ۰/۴۸ در ایستگاه مزرعه آقا خرائق تا ۰/۹۰ در ایستگاه گاریز متفاوت بود. هم‌چنین در ایستگاه همدیدی یزد که از سایر عوامل هواشناسی در پیش‌بینی خشک‌سالی استفاده شد ضریب کارایی در ترکیبات مختلف از کمتر از ۰/۵۰ تا ۰/۹۰ متغیر بود که بهترین ترکیب، در ورودی مدل ترکیب "میانگین متحرک بارش - دمای بیشینه و سپس میانگین متحرک بارش - دمای میانگین - رطوبت" و میانگین متحرک بارش - سرعت باد شناخته شد (اشکال ۷، ۸ و



شکل ۷. مقایسه نتایج واقعی و پیش‌بینی شده میانگین متحرک بارش در ترکیب "بارش، دمای بیشینه" ایستگاه یزد



شکل ۸. مقایسه نتایج واقعی و پیش‌بینی شده میانگین متحرک بارش در ترکیب "بارش، دمای میانگین، رطوبت" ایستگاه یزد



شکل ۹. مقایسه نتایج واقعی و پیش‌بینی شده میانگین متحرک بارش در ترکیب "بارش، سرعت باد" ایستگاه یزد

نتیجه‌گیری

فراخشک همچون یزد کاری بسیار دشوار بوده و اغلب روش‌های موجود قادر نیستند آن را با دقت قابل قبول پیش‌بینی نمایند. این در حالی است که در این تحقیق شبکه عصبی مصنوعی قادر به انجام پیش‌بینی وقوع بارندگی به مقدار مشخص و با ضریب اطمینان قابل قبول در سال آینده با توجه به داده‌های گذشته است. در نهایت با توجه به میزان بارش اتفاق افتاده در ۱۲ ماه آینده و مقایسه آن با میانگین دراز مدت بارش می‌توان به احتمال وقوع وضعیت ترسالی و یا خشک‌سالی در آینده پی برد.

نتایج حاصل از تحقیق انجام شده، حاکی از انعطاف‌پذیری بالای شبکه‌های عصبی در شرایط فقر داده است و همین عامل آن را به عنوان ابزاری قدرتمند در شبیه‌سازی و پیش‌بینی‌ها مبدل کرده است. افزون بر این عوامل هواشناسی از جمله بارش، دمای بیشینه، رطوبت و سرعت باد به ترتیب از مؤثرترین عوامل در افزایش دقت پیش‌بینی‌ها می‌باشد. لازم به ذکر است که پیش‌بینی بارش و خشک‌سالی با توجه به ماهیت متغیر آن خصوصاً برای مدتی قابل توجه قبل از وقوع (مثلاً ۱۲ ماه) به ویژه در منطقه‌ای

منابع مورد استفاده

۱. افخمی، ح. ۱۳۷۸. بررسی پیش‌بینی وضعیت خشک‌سالی در منطقه یزد با استفاده از روش شبکه‌های عصبی مصنوعی. پایان‌نامه کارشناسی ارشد، دانشگاه یزد.
۲. اکبرپور، م.، م. رهنما و بارانی، غ. ۱۳۸۲. مقایسه شبکه عصبی مصنوعی و مدل HEC-HMS در فرایند بارندگی - رواناب. چهارمین کنفرانس هیدرولیک ایران، دانشکده مهندسی، دانشگاه شیراز.
۳. پوررضا، ب.، ر. طارقیان و م. قمشی. ۱۳۸۵. پیش‌بینی دبی سیلاب با استفاده از ترکیب نتایج مدل‌های بارش - رواناب با استفاده از شبکه عصبی مصنوعی. هفتمین سمینار بین‌المللی مهندسی رودخانه، اهواز.
4. ASCE Task Committee on Application of Artificial Neural Network in Hydrology. 2000a. Artificial neural network in hydrology. I. preliminary concepts. J. Hydrol. Eng. 5(2): 124-137.
5. ASCE Task Committee on Application of Artificial Neural Network in Hydrology. 2000b. Artificial neural network in hydrology. II. Hydrology applications. J. Hydrol. Eng. 5(2): 115-123.
6. Cigizoglu, H. K. 2000. Suspended sediment estimation for river using artificial neural network and sediment Rating curves. Turk. J. Eng. Environ. Sci. 26: 27-36.
7. Dastorani M. T. and N. G. Wright. 2001. Application of Artificial neural network for ungauged catchment flood prediction. Proc. of the flood plain management Association, march 12-16, San Diego, USA.
8. Dawson, C. W. and R. Wilby. An Artificial neural network based real-time flow prediction. 5th International Conference on Hydrodynamics, Cardiff, UK.
9. Flood, I. and N. Kartam. 1994a. Neural networks in civil engineering. I. Principles and understanding. J. Comput. Civil Eng. ASCE 8(2):131-148
10. Flood, I. and N. Kartam. 1994b. Neural networks in civil engineering. II. Principles and understanding. J. Comput. Civil Eng. ASCE 8(2):149-162
11. Govindaraju, R. S. and A. R. Roa. 2000. Artificial Neural Network in Hydrology. Kluwer Acad. Pub., Amsterdam, The Netherlands.
12. Mishra, A. K. and V. R. Desai. 2005. Drought forecasting using stochastic models. J. Stochastic Environ. Res. Risk. Assess. 19:326-339.
13. Mishra, A. K. and V. R. Desai. 2006. Drought forecasting using feed-forward recursive neural network. J. Ecol. Model. 13: 127-138.
14. Mishra A. K. et. al. 2007. Drought forecasting using a hybrid stochastic and neural network model. J. Hydrol. Eng. ASCE 12: 626-638.
15. Morid, S. et. al. 2007. Drought forecasting using artificial neural networks and time series of drought indices. Intl. J. Climatol. 27: 2103-2111
16. Nagy, H. M., K. Watanabe and M. Hirano. 2001. Prediction of load concentration in rivers using artificial neural network model. J. Hydraulic Eng. 128(6):588-595.
17. Tokar, A. S. and P. A. Johnson. 1999. Rain runoff modeling using artificial neural networks. J. Hydrol. Eng. 4(3):232-239.