

مدل‌سازی و پیش‌بینی دبی‌های رودخانه‌های استان اردبیل با استفاده از مدل شبکه عصبی مصنوعی

*برومند صلاحی^۱

دانشیار گروه جغرافیای طبیعی، دانشگاه محقق اردبیلی

۱۳۹۲/۱۰/۹ پذیرش مقاله:

۱۳۹۳/۸/۱۱ تأیید نهایی مقاله:

چکیده

در این پژوهش، مقادیر دبی‌های رودخانه‌های استان اردبیل با بهره‌گیری از مدل شبکه‌های عصبی مصنوعی و نیز با استفاده از توابع و امکانات نرم افزار MATLAB، مدل‌سازی شد. بدین منظور، از آمار بلندمدت ایستگاه‌های هیدرومتری رودخانه‌های این استان و برخی پارامترهای اقلیمی (دما، رطوبت نسبی، بارندگی و فشار) ایستگاه‌های سینوپتیک موثر بر میزان دبی‌های حوضه‌های این استان در طول دوره آماری ۳۰ ساله (سال آبی ۱۳۵۷-۱۳۸۷ تا ۱۳۵۸-۸۸) بهره گرفته شد. ورودی‌های شبکه، داده‌های متوسط ماهانه‌ی متغیرهای بارش، دما، رطوبت نسبی (حدائق، میانگین و حداکثر) و متوسط فشار ایستگاه‌های سینوپتیک اردبیل و خلخال و خروجی شبکه نیز مقادیر متوسط دبی‌های ماهانه‌ی شش ایستگاه هیدرومتری بران، دوست‌بیگلو، مشیران، گیلانده، سامیان و درو می‌باشند. برای هر ایستگاه یک شبکه با خطای کمتر از ۵ درصد طراحی گردید. پس از بررسی شاخص‌های عملکرد شبکه از جمله ضریب تعیین، مجدد میانگین مربعات خطای میانگین مربعات خطای میانگین مطلق خطای میانگین درصد خطای ضریب همبستگی مشاهده شد که پیش‌بینی دبی با دقت قابل قبولی انجام شده به طوری که میزان ضریب همبستگی آن ۰/۹۹ و حداکثر خطای آنها ۳/۵۱ درصد بوده است.

واژه‌های کلیدی: پیش‌بینی، دبی، رودخانه‌های استان اردبیل، شبکه‌های عصبی مصنوعی

مقدمه

پیش‌بینی‌ها دست یافتند. در ایران نیز (کارآموز و همکاران، ۱۳۸۵) در پیش‌بینی بلندمدت بارش حوضه‌های غربی ایران، (رضایی و همکاران، ۱۳۸۶) در پیش‌بینی دبی حداقل خروجی از حوضه‌ی در آبخیز سفیدرود، (شادمان مطلق و همکاران، ۱۳۸۶) در پیش‌بینی جریان رودخانه‌ی سفیدرود، (قلخانی و همکاران، ۱۳۸۶) در بررسی و پیش‌بینی سیلاب رودخانه‌ی کارون، (نوری و همکاران، ۱۳۸۶) در ارائه‌ی الگوی بارش – رواناب حوضه‌ی آبریز هلیل- رود و (نورانی و صالحی، ۱۳۸۷) در معروفی مدل بارش – رواناب حوضه‌ی آبریز لیقوان‌چای از مدل شبکه‌های عصبی مصنوعی بهره گرفتند و ثابت کردند که این مدل‌ها در مدل‌سازی و پیش‌بینی جریان‌های رودخانه‌ای دارای برتری قابل قبولی نسبت به مدل‌های آماری دیگر دارند. همچنین (جهانگیر و همکاران، ۱۳۸۷) در شبیه‌سازی فرایند بارش – رواناب حوضه‌ی آبریز کارده دریافتند که شبکه‌ی عصبی پرسپترون چندلایه با تعداد ۲۹ نرون در لایه‌ی میانی (پنهان)، این کار را با دقت خوبی انجام می‌دهد. نتایج مطالعات پژوهشگران داخلی و خارجی نشان داد که مدل شبکه‌های عصبی مصنوعی می‌تواند جایگزین مناسبی برای روش‌های متداول دیگر از جمله رگرسیون خطی و غیرخطی در پیش‌بینی جریان‌های رودخانه‌ای و مدل‌بندی و شبیه‌سازی فرایند بارش – رواناب باشد. برخی از حوضه‌های آبریز رودخانه‌ی استان اردبیل، از حوضه‌های سیل خیز کشور محسوب می‌شوند. در این پژوهش، مقادیر دبی‌های رودخانه‌های استان اردبیل با بهره‌گیری از مدل‌های ANNs، بر اساس آمار بلندمدت ایستگاه‌های هیدرومتری رودخانه‌های این استان و با استفاده از برخی پارامترهای اقلیمی مؤثر بر میزان دبی‌های حوضه این استان (دما، رطوبت نسبی، بارندگی و فشار) و رواناب سال‌های

شناسایی و مدل‌بندی رفتار رودخانه‌ها اهمیت زیادی دارد. به دلیل تعدد عوامل هیدرولوژیکی حوضه‌های آبریز، عکس‌العمل اغلب حوضه‌ها در برابر نزولات جوی، پیچیده است. مدل‌های زیادی برای مدل‌بندی رفتار رودخانه‌ها پیشنهاد شده است که عموماً بر پایه‌ی روش‌های متداول آماری استوار بوده است اما امروزه، پیشرفت‌های در خور توجه در زمینه‌های مختلف هوش مصنوعی مورد توجه بسیاری دانشمندان و محققان قرار گرفته است (اکبرپور و شکرالله‌ی، ۱۳۸۳). استفاده از مدل‌های کلاسیک مانند روش‌های رگرسیون خطی ساده در پیش‌بینی دبی‌ها، مؤثر و کارا نیستند. مدل‌های شبکه‌های عصبی مصنوعی قادرند مسائل غیرخطی را به خوبی توجیه کنند (جاین و همکاران، ۱۹۹۶). بررسی‌های مختلفی در زمینه‌ی مدل‌سازی و پیش‌بینی جریان‌های رودخانه‌ای در سطح دنیا و ایران صورت گرفته است که به دلیل محدودیت صفات مقاله و رعایت اختصار، فقط به تعداد محدودی از آن‌ها به طور خلاصه اشاره می‌شود. (هسو و همکاران، ۱۹۹۵) مدل‌های شبکه‌های عصبی مصنوعی را در تخمین مقادیر رواناب حوضه‌ی رودخانه‌ی لیف مناسب دانستند. (داوسون و ویلبی، ۱۹۹۸) در مدل‌سازی بارش – رواناب جریان رودخانه‌ای حوضه‌های آبریز آمبر و مول، (آگاروال و همکاران، ۲۰۰۹) در پیش‌بینی مقادیر رواناب و رسوب در حوضه‌های آبریز هندوستان، (اختر و همکاران، ۲۰۰۹) در پیش‌بینی جریان‌های روزانه‌ی حوضه‌ی رودخانه‌ی گنگ، (هونگ و همکاران، ۲۰۰۹) در پیش‌بینی بارش‌های ساعتی ایستگاه‌های منطقه‌ی بانکوک تایلند و همچنین (وو و چاو، ۲۰۱۱) در شبیه‌سازی جریان‌های رودخانه‌های دانینگ و لوشوی چین از مدل شبکه‌های عصبی مصنوعی استفاده کردند و به نتایج قابل قبولی در

(ANNs) مدل‌سازی خواهند شد. داده‌های مربوطه پس از تهیه از وب سایت هواشناسی و سازمان آب منطقه‌ای استان و کنترل کیفی آن‌ها، مورد محاسبه قرار گرفتند. (جدول ۱) نام رودخانه‌های مورد بررسی، نام ایستگاه‌های هیدرومتری و سینوپتیک و برخی مشخصات آن‌ها ارائه شده است. این رودخانه‌ها از زیرحوضه‌های پرآب جنوبی رود ارس محسوب می‌شوند.

قبل و با بهره‌گیری از شبکه‌های عصبی مصنوعی مواد و روش‌ها

در پژوهش حاضر، از آمار هواشناسی ایستگاه‌های سینوپتیک اردبیل و خلخال و داده‌های ۵ ایستگاه هیدرومتری مستقر بر برخی رودخانه‌های محدوده استان اردبیل استفاده شده است. آمار مذکور، پارامترهای مختلف ماهانه مربوط به سال آبی ۱۳۵۷-۸۸ تا سال آبی ۱۳۸۷-۸۸ را در بر می‌گیرد.

جدول ۱: نام رودخانه‌های مورد بررسی، نام ایستگاه‌های هیدرومتری و سینوپتیک و برخی مشخصات آن‌ها

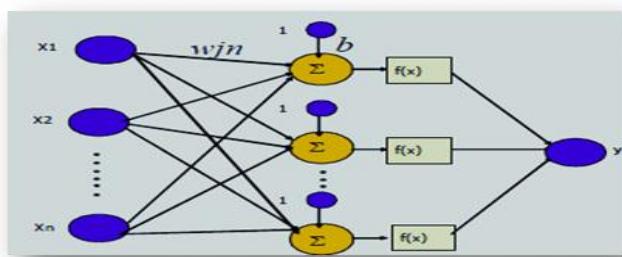
سال تأسیس	ارتفاع (متر)	مشخصات جغرافیایی		نام ایستگاه	نام رودخانه	نوع ایستگاه	محدوده مطالعاتی
		عرض	طول				
۱۳۳۷	۲۴۴	۴۱-۱۷-۳۹	-۳۱-۴۷ ۰.۸	بران	دره رود	هیدرومتری	۱۳۳۷-۱۳۵۱
۱۳۲۸	۷۰۵	۱۰-۴۱-۳۸	-۳۲-۴۷ ۰.۱	مشیران	دره رود		
۱۳۵۰	۱۲۹۰	۵۳-۲۲-۳۸	-۱۴-۴۸ ۴۸	سامیان	قره سو		
۱۳۵۱	۷۸۰	۳۸-۳۳-۳۸	-۳۲-۴۷ ۴۸	دوست بیگلو	قره سو		
۱۳۵۰	۱۳۳۲	۲۶-۱۸-۳۸	-۲۱-۴۸ ۴۳	گیلاندہ	بالخلوچای		
۱۳۶۸	۱۶۵۱	۳۸-۲۴-۳۷	-۴۱-۴۸ ۴۸	درو	شاھرودچای		
۱۹۷۶	۱۳۳۲	۳۸-۱۵-۰۰	-۱۷-۰۰ ۴۸	اردبیل	-	سینوپتیک	۱۹۷۶-۱۹۸۷
۱۹۸۷	۱۷۹۶	۳۸-۳۷-۰۰	-۳۱-۰۰ ۴۸	خلخال	-		

(۱۳۸۹). در این پژوهش سعی می‌شود بر اساس روابط ذاتی مابین داده‌ها، نگاشتی غیرخطی مابین متغیرهای مستقل و وابسته برقرار گردد. ایده اصلی شبکه عصبی بر مبنای شبیه‌سازی عملکرد مغز انسان بوده و در مقیاس خیلی کوچک، می-

شبکه‌های عصبی مصنوعی یکی از موفق‌ترین تکنیک‌های داده‌کاوی است که از طریق یک سری مدل‌های پیوندی الهام گرفته شده از رفتار مغز انسان، می‌تواند رابطه غیر خطی بین پدیده‌ها را پیش‌بینی کند (فرج‌زاده و دارند به نقل از هایکین،

(۱۳۸۴) و بر اساس بردارهای ورودی، وقوع پدیده را پیش‌بینی نمایند (کنرادس و روهل، ۱۹۹۹). ساختار عادی یک شبکه عصبی مصنوعی، معمولاً از لایه ورودی، لایه‌های مخفی و لایه خروجی تشکیل شده است (شکل ۱). لایه ورودی یک لایه انتقال دهنده و وسیله‌ای برای تهیه کردن داده‌هاست. لایه خروجی شامل مقادیر پیش‌بینی شده بوسیله شبکه می‌باشد و لایه مخفی محل پردازش داده‌هاست (اصغری مقدم و همکاران، ۱۳۸۷).

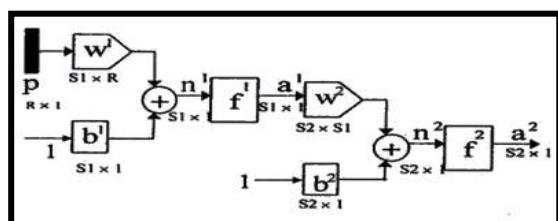
تواند مانند شبکه‌ای زیستی قدرت یادگیری داشته باشد و این یادگیری را تعمیم دهد (فتحی و همکاران، ۱۳۸۷). شبکه‌های عصبی مصنوعی با تقلید ساده از سیستم عصبی بیولوژیک ساخته شده‌اند (فولاب و همکاران، ۱۹۹۸). قدرت انعطاف و تصحیح‌پذیری بالایی در انطباق خود با داده‌های موجود را دارند (رنجیتان و همکاران، ۱۹۹۵) و می‌توانند با تجهیز به سازماندهی، نظم و هماهنگی موجود در داخل این داده‌ها را پیدا نموده (منهاج،



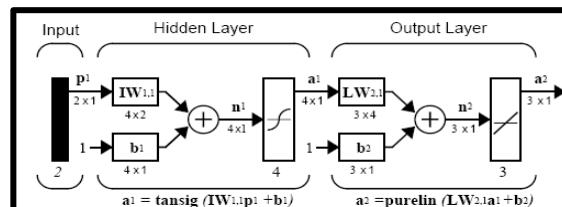
شکل ۱: ساختار عادی یک شبکه عصبی مصنوعی (خلیلی و همکاران، ۱۳۸۵)

گردید (حسینی، ۱۳۸۸). در شبکه‌های پرسپترون چندلایه، هر نرون در هر لایه به تمام نرون‌های لایه قبل متصل می‌باشد (منهاج، ۱۳۸۴) که در این پژوهش جهت مدل‌سازی پیش‌بینی دبی‌ها استفاده شده است.

شبکه‌های عصبی از لحاظ نوع شبکه نیز به دو گروه شبکه‌های پیشخور و پسخور تقسیم می‌شوند که در این بررسی از شبکه‌های پیشخور (شکل ۲) و ساختار پرسپترون چندلایه (MLP) شکل ۳ به دلیل کاربرد بیشتر در مسائل اقلیم‌شناسی و مدل‌سازی و پیش‌بینی پارامترهای اقلیمی استفاده



شکل ۳: شبکه پرسپترون چند لایه MLP (منهاج، ۱۳۸۴). هوای سطح ایستگاه (QFE) و میانگین ماهانه دما می‌باشند. از ۳۰ سال دوره آماری (۳۶۰ داده) موجود ۲۶ سال (۳۱۲ داده) جهت آموزش شبکه و ۴ سال (۴۸ داده) باقی‌مانده در مرحله تست شبکه به کار برده شد. جهت افزایش سرعت شبکه، ابتدا داده‌ها در بازه $[-1, 1]$ و نرمالیزه



شکل ۲: شبکه پیشخور (دموث و بیل، ۲۰۰۲) در پژوهش حاضر، ابتدا عناصر تأثیرگذار بر دبی رودخانه‌های مورد مطالعه مشخص و سپس جهت ورود به شبکه عصبی، اقدام به تشکیل ماتریس مربوطه گردید. ورودی‌های شبکه مربوط به متغیرهای رطوبت نسبی (میانگین، حداقل و حداکثر)، مجموع ماهانه‌ی بارش، میانگین فشار

مقایسه و ارزیابی مدل با استفاده از شاخص‌های آماری و نمودارهای مختلف پرداخته شد. تمامی مراحل کار در محیط برنامه نویسی نرم افزار MATLAB7 صورت گرفته است سپس نمودارهای مربوطه در محیط Excel ترسیم گردیدند. در مجموع جهت دقت بالای شبکه، برای هر ایستگاه یک شبکه طراحی گردید.

(الف) ضریب همبستگی: بیان کننده میزان همبستگی بین نتایج برآورد شده مدل و داده‌های واقعی می‌باشد که بر اساس رابطه ۱ محاسبه می‌شود. بدینهی است هر چه مقدار آن به یک نزدیک-تر باشد، نشان دهنده نزدیکی بیشتر مقادیر برآورد شده به مقادیر واقعی است (خلیلی و همکاران، ۱۳۸۵) در واقع ضریب همبستگی ارتباط خطی بین دو متغیر را اندازه‌گیری می‌کند و یک ابزار ریاضی است که در پایه‌ریزی تحلیل‌های اقلیمی بسیار کاربرد دارد (صدقت‌کردار و فتاحی، ۱۳۸۷).

$$R^2 = \frac{\sum_{k=1}^K X_k Y_k}{\sqrt{\sum_{k=1}^K X_k^2 \sum_{k=1}^K Y_k^2}} \quad (رابطه ۲)$$

محاسبه آن را نشان می‌دهد (صدقت‌کردار و فتاحی، ۱۳۸۷):

در رابطه فوق، X_K مقادیر مشاهداتی، Y_K مقادیر برآورد شده و K تعداد داده‌ها می‌باشد. (ج) درصد نسبی خطأ و میانگین مربعات خطأ: برای محاسبه آن‌ها نیز از روابط ۳ و ۴ استفاده می‌شود که می‌تواند از صفر در عملکرد عالی تا بی‌نهایت تغییر کند (کار آموز و همکاران، ۱۳۸۵):

$$Error_i = \frac{Obs_i - For_i}{Obs_i} \times 100 \quad (رابطه ۳)$$

گردید و پس از تعیین ساختار شبکه، شبکه با استفاده از الگوریتم آموزشی مارکوارت-لونبرگ و با شروع از کمترین تعداد نرون در لایه مخفی و اپوک ادامه یافت تا شبکه به جواب مطلوب همگرا شد. اگر شبکه با هر تعداد لایه و نرون پنهان و اپوک به جواب مورد نظر می‌رسید آن شبکه به عنوان شبکه بهینه انتخاب می‌گردید. سپس به

نتایج

از ریاضیات عملکرد مدل: بررسی چگونگی عملکرد و مقایسه قدرت پیش‌بینی به منظور ارزیابی عملکرد شبکه‌ها لازم و ضروری است که در این پژوهش علاوه بر ترسیم نمودارهای مقادیر مشاهده شده در برابر مقادیر پیش‌بینی شده توسط مدل شبکه عصبی مصنوعی، از شاخص‌های کمی ضریب همبستگی (R)، ضریب تعیین (R^2)، درصد نسبی خطأ (Er)، مجدور میانگین مربعات خطأ (MSE) و میانگین مطلق خطأ (MAE) استفاده شده است.

$$R = \frac{\sum_{i=1}^n (y_{act} - \bar{y}_{act})(y_{est} - \bar{y}_{est})}{\sqrt{\sum_{i=1}^n (y_{act} - \bar{y}_{act})^2 \sum_{i=1}^n (y_{est} - \bar{y}_{est})^2}} \quad (رابطه ۱)$$

که در آن، y_{act} : مقادیر واقعی، \bar{y}_{act} : میانگین مقادیر واقعی، y_{est} : مقادیر برآورد شده و \bar{y}_{est} : میانگین مقادیر برآورد شده می‌باشد.

(ب) ضریب تعیین: معیاری بدون بعد که بهترین مقدار

آن برابر یک می‌باشد. رابطه ۲ نحوه

که بهترین مقدار آن‌ها برابر صفر است و از طریق روابط ۵ و ۶ محاسبه می‌شوند (صدقایت‌کردار و فتاوی، ۱۳۸۷):

$$RMSE = \sqrt{\frac{\sum_{K=1}^K (X_K - Y_K)^2}{K}} \quad (5)$$

رابطه ۵

رابطه ۶

$$MAE = \frac{\sum_{K=1}^K |X_K - Y_K|}{K}$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (Obs_i - For_i)^2 \quad (4)$$

در روابط فوق $Error_i$ خطای مدل برای برآورد حداقل دما و For و Obs_i به ترتیب مقدار مشاهداتی و برآورده شده حداقل دما و n تعداد کل داده‌های مشاهداتی می‌باشد.

د) مجذور میانگین مربعات خطا و میانگین مطلق خطای نشان دهنده میزان خطای مدل می‌باشد. در روابط فوق X_K مقدار مشاهداتی، Y_K مقدار برآورده شده و K تعداد داده‌ها می‌باشد.

نتیجه را با واقعیت داشت به عنوان شبکه بهینه انتخاب شد که نتایج حاصل از آن به همراه پارامترهای آموزشی بهینه در جدول ۲ آورده شده است. بهترین پارامترهای ورودی برای ایستگاه‌های بران، دوست‌بیگلو، گیلانده، مشیران و سامیان شامل شش متغیر رطوبت نسبی ماهانه (حداقل، میانگین و حداکثر)، بارش ماهانه، متوسط فشار سطح ایستگاه (QFE) و میانگین ماهانه دمای ایستگاه سینوپتیک اردبیل می‌باشد ولی برای ایستگاه درو شامل سه متغیر، میانگین ماهانه دما، مجموع بارش ماهانه و متوسط فشار سطح دریا (QFF) ایستگاه سینوپتیک خلخال می‌باشد که هر کدام از مدل‌های طراحی شده با این تعداد ورودی و این پارامترها به نتیجه مطلوب (خطای زیر ۵ درصد) رسیدند و نیازی به افزایش تعداد لایه‌های ورودی احساس نشد. بهترین تعداد لایه میانی نیز یک لایه با حداقل و حداکثر تعداد نرون در لایه پنهان به ترتیب مربوط به مدل‌های ایستگاه‌های دوست‌بیگلو با ۴ نرون و گیلانده با ۱۰ نرون انتخاب گردید. بهترین توابع محرک لایه پنهان و خروجی نیز برای هر ۶ مدل طراحی شده

بحث

در این پژوهش از مدل شبکه عصبی مصنوعی از نوع پرسپترون با ساختار پیش‌خور چندلایه برای برآورد مکانی مقدار دبی ماهانه در ایستگاه‌های هیدرومتری بران، دوست‌بیگلو، مشیران، گیلانده، سامیان و درو استفاده گردید. در طراحی ساختار مدل هر یک از ایستگاه‌ها، ابتدا تعداد نرون‌های لایه‌های ورودی و خروجی به ترتیب با توجه به تعداد متغیرهای ورودی (پارامترهای اقلیمی ایستگاه‌های سینوپتیک مجاور) و خروجی مدل (دبی ایستگاه هیدرومتری) انتخاب شد. سپس برای انتخاب پارامترهای قابل تنظیم و در نتیجه تعیین بهترین ساختار شبکه عصبی، تعداد زیادی شبکه عصبی با ساختار مختلف طراحی و ارزیابی گردید. این شبکه‌های عصبی با تغییر پارامترهای قابل تنظیم (شامل توابع محرک، الگوریتم یادگیری، تعداد لایه میانی، تعداد نرون‌های لایه میانی، تعداد الگوها و متغیرهای ورودی) ساخته و اجرا شدند. دقت این شبکه‌ها نیز به وسیله معیارهای آماری محاسبه شده در مرحله آزمون، بررسی گردید و در نهایت، شبکه‌ای که نزدیکترین

بران با ۰/۷۶ و مدل گیلانده با ۰/۶۶ است. بهترین نوع الگوریتم آموزشی نیز برای تمامی مدل‌ها الگوریتم لونبرگ- مارکوارت (LM) است که هم دارای سرعت عملکرد بالا و همچنین نیاز به تعداد نروهای کمتر در لایه پنهان دارد (جدول ۲).

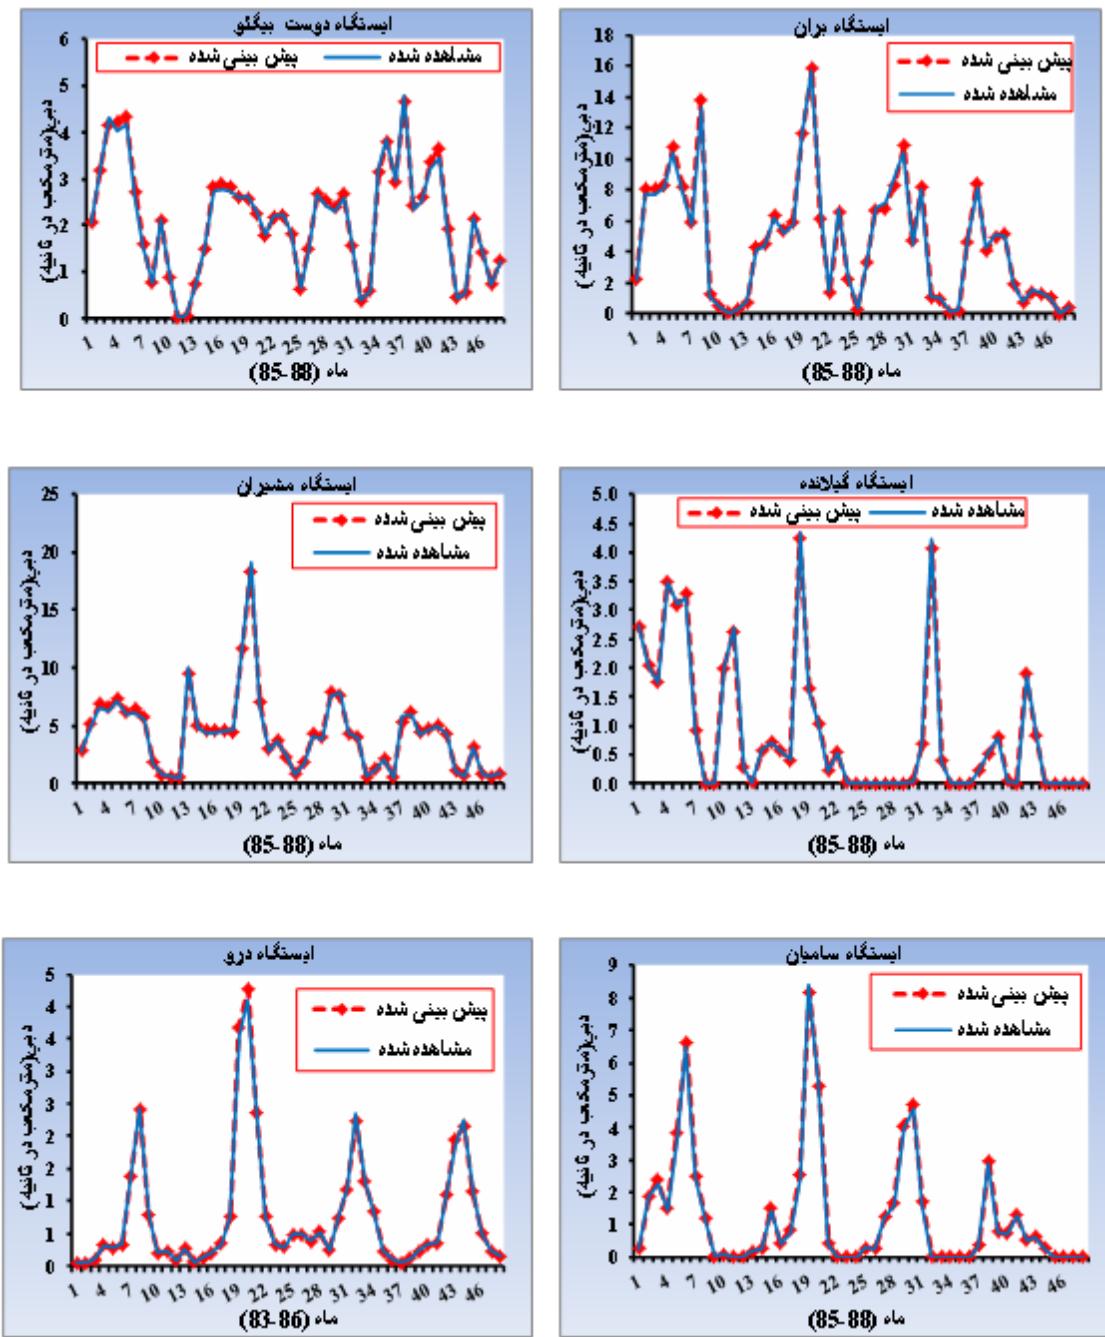
به ترتیب تابع تانزانت هیپربولیک (Tansig) و تابع خطی (Pureline) می‌باشد. بیشترین و کمترین دور تکرار نیز مربوط به مدل‌های بران و سامیان به ترتیب با ۱۱۳ و ۲۷ دور آموزش می‌باشد. بیشترین و کمترین ضریب همبستگی در مرحله آزمون شبکه‌ها نیز مربوط به مدل‌های مشیران و

جدول ۲: پارامترهای آموزشی بهینه‌ی مدل طراحی شده جهت پیش‌بینی دبی

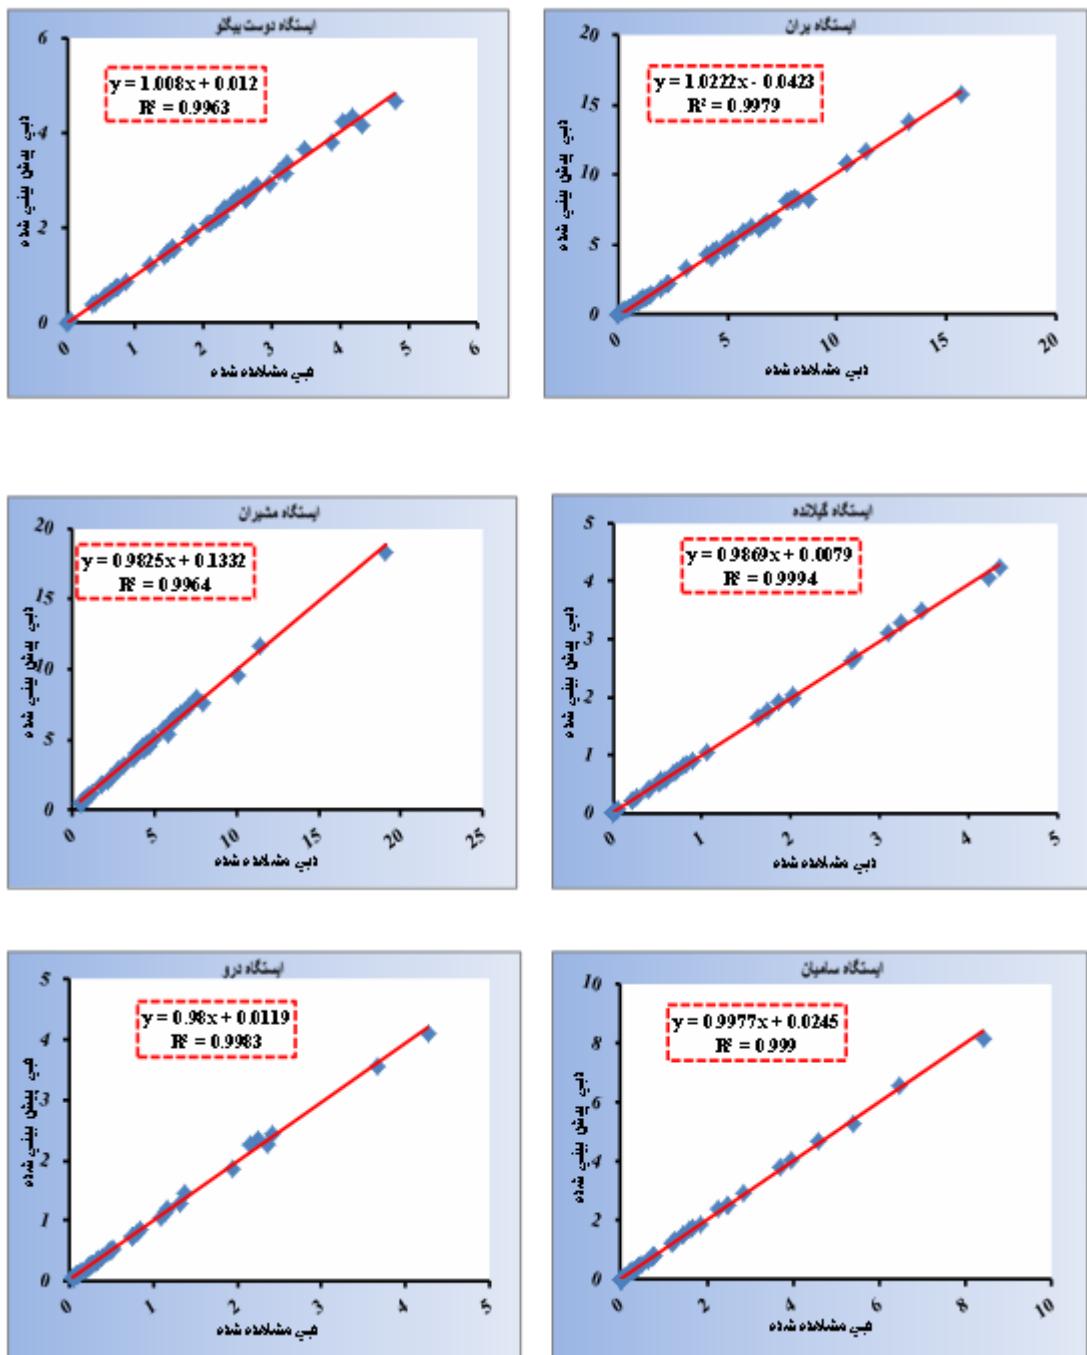
الگوریتم یادگیری	ضریب همبستگی (R)	هدف عملکرد	دور تکرار	تابع محرك لایه خروجی	تابع محرك لایه پنهان	تعداد نرون در لایه پنهان	تعداد نرون در لایه پنهان	تعداد نرون در لایه پنهان	مدل
Lm	۰/۷۶	۰/۰۰۵	۱۱۳	pureline	tansig	۵	۶	۶	بران
Lm	۰/۷۵	۰/۰۰۵	۵۷	pureline	tansig	۴	۶	۶	دوسن‌بیگلو
Lm	۰/۶۶	۰/۰۰۵	۳۱	pureline	tansig	۱۰	۶	۶	گیلانده
Lm	۰/۷۶	۰/۰۰۵	۸۰	pureline	tansig	۶	۶	۶	مشیران
Lm	۰/۷۳	۰/۰۰۵	۲۷	pureline	tansig	۷	۶	۶	سامیان
Lm	۶۷	۰/۰۰۵	۳۷	pureline	tansig	۶	۳	۳	درو

وسیله شبکه عصبی با داده‌های مشاهداتی، تشخیص منحنی‌های دبی واقعی و پیش‌بینی شده از همدیگر مشکل است و حتی در بعضی از ماهها دو منحنی بر هم منطبق شده‌اند که نمایانگر دقت بالای مدل‌های طراحی شده در پیش‌بینی دبی-های رودخانه‌های استان اردبیل است.

پس از برگرداندن داده‌ها به بازه اصلی، نمودار پیش‌بینی دبی به وسیله مدل‌های شبکه عصبی با داده‌های مشاهداتی شکل ۴ و معادله خط رگرسیونی و پراکنش بین داده‌های مشاهداتی و پیش‌بینی شده شکل ۵ جهت مقایسه دقت شبکه ترسیم شد. همانطور که ملاحظه می‌شود به دلیل همبستگی بالای داده‌های پیش‌بینی شده به



شکل ۴: مقادیر دبی مشاهداتی و پیش‌بینی شده با استفاده از شبکه عصبی مصنوعی



شکل ۵: پراکنش دبی مشاهداتی و پیش‌بینی شده با استفاده از شبکه عصبی مصنوعی

هستند که نشان دهنده توانایی و دقت بالای شبکه‌های عصبی مصنوعی در پیش‌بینی دبی‌های رودخانه‌های استان اردبیل است و می‌توان اظهار داشت که مدل‌های طراحی شده دارای عملکرد مناسبی است. کمترین و بیشترین میانگین خطا در شبکه‌های طراحی شده نیز به ترتیب مربوط به

نتایج حاصل از ارزیابی عملکرد مدل شبکه عصبی مصنوعی با شاخص‌های ارزیابی مختلف نیز در جدول ۳ آورده شده است. همانطور که ملاحظه می‌شود مدل‌های طراحی شده دارای خطای کمتر از ۵ درصد و همچنین دارای ضریب همبستگی با سطح معنی‌داری یک درصد و ضریب تعیین بالای

ضعیف‌ترین مدل‌ها در این پژوهش معرفی می‌گردند.

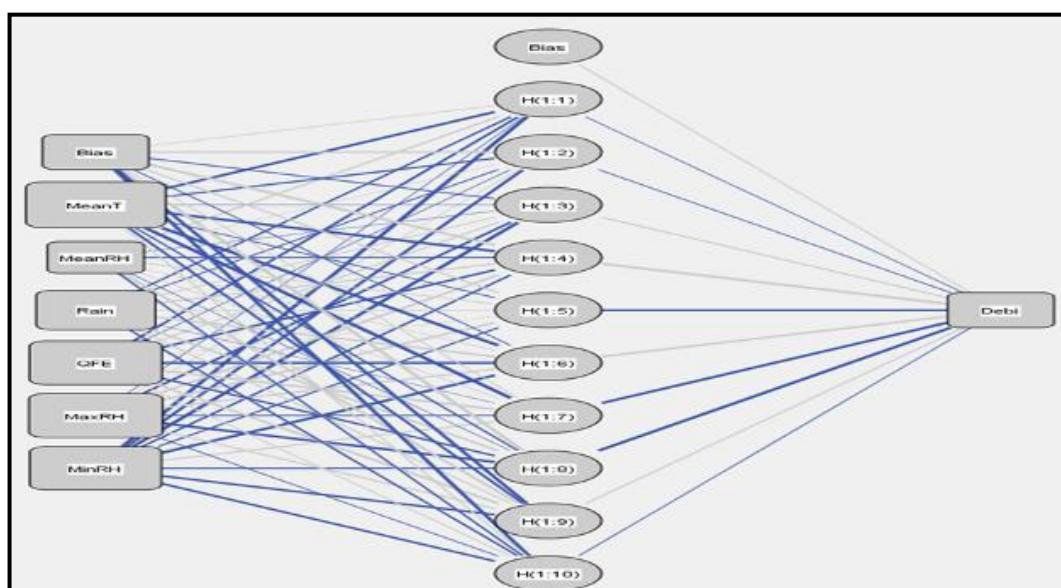
مدل‌های گیلانده با ۱/۴۶ درصد و بران با ۳/۵۱ درصد خطای می‌باشد که به عنوان قوی‌ترین و

جدول ۳: نتایج حاصل از ارزیابی عملکرد مدل شبکه عصبی در مدل‌سازی پیش‌بینی دبی

میانگین مطلق خطای میانگین محدود مربوطات خطای میانگین مربوطات خطای میانگین خطای (درصد) ضریب تعیین سطح معنی داری همبستگی شاخص‌های ارزیابی مدل ایستگاه							
۰/۱۶	۰/۲۱	۰/۰۴	۳/۵۱	۰/۹۹	۰/۰۱	۰/۹۹	بران
۰/۰۵	۰/۰۸	۰/۰۱	۲/۰۴	۰/۹۹	۰/۰۱	۰/۹۹	دوست‌بیگلو
۰/۰۲	۰/۰۳	۰/۰۰	۱/۴۶	۰/۹۹	۰/۰۱	۰/۹۹	گیلانده
۰/۱۶	۰/۲۲	۰/۰۵	۳/۴۶	۰/۹۹	۰/۰۱	۰/۹۹	مشیران
۰/۰۴	۰/۰۶	۰/۰۰	۲/۴۸	۰/۹۹	۰/۰۱	۰/۹۹	سامیان
۰/۰۲	۰/۰۴	۰/۰۰	۱/۸۷	۰/۹۹	۰/۰۱	۰/۹۹	درو

میانگین ماهانه حداکثر دما، میانگین ماهانه حداکثر رطوبت نسبی، میانگین ماهانه حداکثر رطوبت نسبی، میانگین ماهانه رطوبت نسبی و مجموع ماهانه بارش) و ۱۰ نرون در لایه پنهان و یک نرون در لایه خروجی (دبی) و میانگین خطای نسبی ۱/۴۶ درصد بهترین ساختار شبکه‌های طراحی شده در این پژوهش را به خود اختصاص داده‌اند.

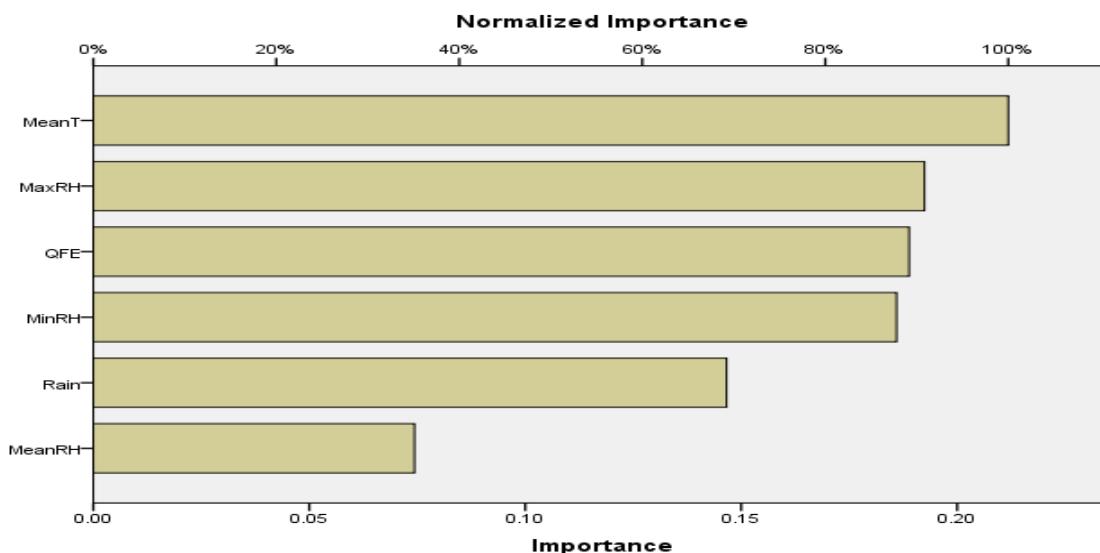
کمترین و بیشترین میانگین خطای در شبکه‌های طراحی شده نیز به ترتیب مربوط به ایستگاه‌های گیلانده با ۱/۴۶ درصد و بران با ۳/۵۱ درصد خطای می‌باشد که به عنوان قوی‌ترین و ضعیف‌ترین مدل‌ها در این پژوهش معرفی می‌گردند. شماتیک بهترین شبکه طراحی شده در شکل ۶ آورده شده است. همانطور که قبل ذکر شد این شبکه از نوع پرسپترون چند لایه (MLP) می‌باشد که با ۶ نرون در لایه ورودی (متوسط فشار سطح ایستگاه،



شکل ۶: نمایش شماتیک بهترین شبکه طراحی شده (گیلانده)

حداکثر رطوبت نسبی، مجموع ماهانه بارش و میانگین ماهانه حداقل رطوبت نسبی نیز به ترتیب در رده‌های بعدی از نظر اهمیت در پیش‌بینی قرار می‌گیرند (شکل ۷).

از نظر مؤثرترین متغیرهای ورودی در پیش‌بینی رخداد دبی‌های منطقه نیز متغیر میانگین ماهانه دما دارای بیشترین تأثیر در خروجی شبکه یعنی متغیر پیش‌بینی شونده (دبی) می‌باشد و متغیرهای میانگین ماهانه حداکثر رطوبت نسبی، متوسط فشار سطح ایستگاه، میانگین ماهانه



شکل ۷: اهمیت بهترین متغیرهای ورودی در پیش‌بینی رخداد دبی‌ها بر حسب درصد

مقدار متوسط درصد نسبی خطا نیز برای تمامی مدل‌ها کمتر از ۵ درصد بدست آمده است. همچنین بررسی‌ها نشان داد که با افزایش اطلاعات ورودی، عملکرد شبکه افزایش می‌یابد. نتایج به دست آمده نشان دهنده دقیق و توانایی بالای مدل شبکه عصبی مصنوعی در پیش‌بینی دبی در منطقه مورد مطالعه می‌باشد. البته لازم است به این نکته نیز توجه داشت که دبی‌ها فقط ناشی از پارامترهای اقلیمی نیست بلکه ویژگی‌های حوضه نیز در آن دخیل هستند که لازم است در پژوهش‌های آینده به آن توجه شود. این نتایج با یافته‌های سایر پژوهشگران نظیر کارآموز و همکاران (۱۳۸۵)، رضایی و همکاران (۱۳۸۶)، شادمان مطلق و همکاران (۱۳۸۶)، قلخانی و همکاران (۱۳۸۶)، نوری و همکاران (۱۳۸۶)،

بحث و نتیجه‌گیری

در این پژوهش، با استفاده از رویکرد شبکه عصبی مصنوعی به پیش‌بینی دبی‌های برخی رودخانه‌های استان اردبیل پرداخته شد. پارامترهای میانگین دمای ماهانه، میانگین رطوبت نسبی، مجموع ماهانه حداقل و حداکثر رطوبت نسبی، متوسط ماهانه بارش و متوسط ماهانه فشار استاندارد سطح ایستگاه (QFE) به عنوان ورودی و میانگین ماهانه دبی بر حسب متر مکعب بر ثانیه بعنوان خروجی مدل تعریف شدند. از مقایسه نتایج حاصل از اجرای مدل‌های مختلف، بهترین نتیجه مربوط به یک مدل پرسپترون سه لایه با ۱۰ نرون در لایه پنهان و الگوریتم آموزشی لونبرگ- مارکوارت با ضریب همبستگی و تعیین مشابه ۰/۹۹ می‌باشد.

دبی در مناطق مختلف و با ورودی‌های و ساختارهای متفاوت در پیش‌بینی پدیده‌های هیدرولوژیکی و اقلیمی پیشنهاد می‌گردد.

نورانی و صالحی (۱۳۸۷) و جهانگیر و همکاران (۱۳۸۷) در خصوص کارایی مدل شبکه عصبی مصنوعی در پیش‌بینی دبی‌ها مطابقت دارد لذا استفاده از شبکه عصبی مصنوعی در پیش‌بینی

- علوم و فنون کشاورزی و منابع طبیعی، سال ۱۱، ش ۱، ص ۳۹-۲۵.
- شادمان مطلق، ع.، ابراهیمی، ح. و رهنما، م.، ۱۳۸۶. پیش‌بینی جریان رودخانه سفیدرود با استفاده از شبکه عصبی مصنوعی (ANN)، ششمین کنفرانس هیدرولیک ایران، دانشگاه شهرکرد.
- صداقت‌کردار، ع. و فتاحی، ا.، ۱۳۸۷. شاخص‌های پیش‌آگاهی خشکسالی در ایران، مجله جغرافیا و توسعه دانشگاه سیستان و بلوچستان، ج ۶، ش ۱۱، ص ۵۹-۷۶.
- فتحی، پ.، محمدی، ا. و همایی، م.، ۱۳۸۷. مدل‌سازی هوشمند سری زمانی آورد ماهانه ورودی به سد وحدت سندج، مجله آب و خاک (علوم و صنایع کشاورزی)، ج ۲۳، ش ۱، ص ۲۰۹-۲۲۰.
- فرج زاده، م. و دارند، م.، ۱۳۸۹. مقایسه روش‌های رگرسیون خطی و شبکه عصبی مصنوعی در پیش‌بینی میزان مرگ و میر به عنوان تابعی از دمای هوا (مطالعه موردي: شهر تهران)، مجله پژوهشی حکیم، ج ۱۲، ش ۳، ص ۴۵-۵۳.
- قلخانی، ح.، یزداندوست، ف. و مشفق، م.، ۱۳۸۶. پیش‌بینی رودخانه کارون با استفاده از شبکه عصبی مصنوعی، ششمین کنفرانس هیدرولیک ایران، دانشگاه شهرکرد.
- کارآموز، م.، رمضانی، ف. و رضوی، س.، ۱۳۸۵. پیش‌بینی بلند مدت بارش با استفاده از سیگنال-های هواشناسی: کاربرد شبکه‌های عصبی مصنوعی، هفتمین کنگره بین‌المللی مهندسی عمران، تهران.

منابع

- اصغری مقدم، ا.، نورانی، و. و ندیری، ع.، ۱۳۸۷. مدل‌سازی بارش دشت تبریز با استفاده از شبکه‌های عصبی مصنوعی، مجله دانش کشاورزی، دانشگاه تبریز، ج ۱۸، ش ۱، ص ۱۵-۱.
- اکبرپور، م. و شکرالهی، ا.، ۱۳۸۳. به کارگیری شبکه‌های عصبی مصنوعی در تخمین جریانات رودخانه‌ای، اولین کنگره ملی مهندسی عمران، دانشگاه صنعتی شریف.
- جهانگیر، ع.، رائینی، م. و ضیاء‌احمدی، م.، ۱۳۸۷. شبیه‌سازی فرایند بارش - رواناب با شبکه عصبی مصنوعی (ANN) و مقایسه با مدل HEC-HMS در حوضه معرف کارده، مجله آب و خاک (علوم و صنایع کشاورزی)، جلد ۲۲، شماره ۲، ص ۷۲-۸۴.
- حسینی، س.، ۱۳۸۸. برآورد و تحلیل دماهای حداقل شهرستان اردبیل با استفاده از مدل تئوری شبکه‌های عصبی مصنوعی، پایان نامه کارشناسی ارشد، به راهنمایی برومند صلاحی، دانشگاه محقق اردبیلی.
- خلیلی، ن.، خداشناس، س. و داوری، ک.، ۱۳۸۵. پیش‌بینی بارش با استفاده از شبکه‌های عصبی مصنوعی، دومین کنفرانس مدیریت منابع آب.
- رضایی، ع.، مهدوی، م.، لوکس، ک.، فیض‌نیا، س. و مهدیان، م.، ۱۳۸۶. مدل‌سازی منطقه‌ای دبی‌های اوج در زیر حوضه‌های آبخیز سد سفید-رود با استفاده از شبکه‌های عصبی مصنوعی، مجله

فازی، چهارمین کنگره ملی مهندسی عمران، دانشگاه تهران.
- نوری، م.، میرحسینی، س.، زینال زاده، ک. و رهنمای، م.، ۱۳۸۶. الگوی جدید بارش- رواناب حوضه آبریز هلیل رود با استفاده از مدل هیبرید شبکه عصبی- موجکی، نشریه زمین شناسی، جلد ۲، شماره ۲، ص ۴۷۲ - ۴۵۱.

- Agarwal, A., RallI, R. K. and Upadhyay, A., 2009. Forecasting of Runoff and Sediment Yield Using Artificial Neural Networks. v.1(5) , p. 368-375
- Akhtar, M. K., Corzo, G. A., van Andel, S. J. and Jonoski, A., 2009. River flow forecasting with artificial neural networks using satellite observed precipitation pre-processed with flow length and travel time information: case study of the Ganges river basin, Hydrology and Earth System Sciences, v. 13, p. 1607–1618.
- Conrads, P.A. and Roehle, E.A., 1999. Comparing Physics- Based and Neural Network Mo Simulating Salinity, Temperature and Dissolved in a Complex, Tidally Affected River Basin. Proceeding of the South Carolina Environmental Conferees.
- Dawson, W. and Wilby, R., 1998. An artificial neural network approach to rainfall-runoff modeling. Hydrological Sciences Journal, v.1, p. 47-66.
- Demuth, H. and Beale, M., 2002. Neural Network Toolbox User's Guide, Copyright 1992-2002, Bt The Math Works, Inc, v. 4, 840p.

- منهاج، م.، ۱۳۸۴. مبانی شبکه‌های عصبی(هوش محاسباتی)، مرکز نشردانشگاه صنعتی امیر کبیر، چاپ سوم، ج ۱، ۷۱۲ ص.

- نورانی، و. و صالحی، ک.، ۱۳۸۷. مدل‌سازی بارش - رواناب با استفاده از روش شبکه عصبی فازی و مقایسه آن با روش‌های شبکه عصبی

- Fulop, I.A., Jozsa, J. and Karamer, T., 1998. A neural network application in estimating wind induced shallow lake motion. Hydro informatics 98, v. 2, p. 753-757.
- Hsu, K., Gupta, H.V. and Sorooshian, S., 1995. Artificial neural network modeling of the rainfall process. Water Resour, v. 31(10), p. 2517-2330.
- Hung, N. Q., Babel, M. S., Weesakul, S. and Tripathi, N. K. 2009., An artificial neural network model for rainfall forecasting in Bangkok, Thailand, Hydrology and Earth System Sciences, v. 13, p. 1413-1425
- Jain, A.K., Mao, J. and Mohiuddin, K.M., 1996. Artificial neural networks: authorial. I EEE, v. 29 (3), p. 31- 44.
- Ranjithan, J., Eheart, J. and Garrett, J.H., 1995. Application of neural network in groundwater remediation under condition of uncertainty. New Uncertainty conception Hydrology and Water Resources. Cambridge University Press, 322 p.
- Wu, C.L. and Chau, K.W., 2011. Rainfall-runoff modeling using artificial neural network coupled with singular spectrum analysis, Journal of Hydrology, v. 399, p. 394–409.