

شبیه‌سازی فرایند بارش رواناب در زیرحوضه جنوبی رودخانه قره‌سو با

استفاده از مدل شبکه‌های عصبی مصنوعی (ANNs)

برومند صلاحی: استادیار اقلیم‌شناسی، دانشگاه محقق اردبیلی، اردبیل، ایران *

طاهره سرمستی: دانشجوی کارشناسی ارشد اقلیم‌شناسی، دانشگاه محقق اردبیلی، اردبیل، ایران

وصول: ۱۳۹۰/۹/۱ پذیرش: ۱۳۹۱/۵/۲۲، صص ۱۳۴-۱۱۹

چکیده

در سال‌های اخیر، عدم کنترل به موقع رواناب حاصل از بارش‌های غیر مترقبه، عامل تهدید کننده‌ای در وقوع سیل محسوب می‌شود. پیش‌بینی بارش در مدیریت و هشدار معضل سیل نقش مهمی بر عهده دارد. به منظور جلوگیری از خسارات ناشی از سیل و سعی در کنترل و مهار آن، پیش‌بینی رواناب امری اجتناب ناپذیر به نظر می‌رسد زیرا با اطلاع از میزان و شدت بارندگی، می‌توان امکان وقوع سیل را پیش‌بینی و اقدامات لازم را به عمل آورد. حوضه‌ی آبریز رودخانه‌ی قره‌سو به ویژه زیرحوضه‌ی جنوبی این رودخانه، از حوضه‌های سیل‌خیز کشور است لذا در این پژوهش، مقادیر رواناب این زیرحوضه، بر اساس آمار بلندمدت ۴ ایستگاه هیدرومتری نیر، پل الماس، گیلانده و نمین و با استفاده از برخی پارامترهای اقلیمی مؤثر بر میزان رواناب این حوضه (شامل متوسط ماهانه‌ی دما، رطوبت نسبی، بارندگی، تبخیر) و رواناب سال‌های قبل و با بهره‌گیری از مدل شبکه‌های عصبی مصنوعی (ANNs) مدل‌سازی گردید. برای انجام محاسبات، از نرم‌افزار مت‌لب ۷ استفاده شد. ورودی‌های شبکه، داده‌های متوسط ماهانه‌ی متغیرهای بارش، دبی رودخانه، دما، رطوبت نسبی و تبخیر سال‌های قبل و خروجی شبکه، مقادیر متوسط پیش‌بینی شده‌ی دبی ماهانه‌ی زیرحوضه‌ی جنوبی رودخانه‌ی قره‌سو می‌باشد. این آمار، بازه‌ی زمانی سال‌های ۱۹۷۲ تا ۲۰۱۰ را در بر می‌گیرد. حدود ۹۰ درصد داده‌ها (۳۵ سال یا ۴۲۰ ماه) برای آموزش و ۱۰ درصد باقی‌مانده (۴ سال یا ۴۸ ماه)، جهت تست شبکه به کار رفته و برای هر ماه، یک شبکه با خطای کمتر از ۵ درصد طراحی شد. تحلیل نتایج خروجی شبکه‌ی عصبی نشان داد که این مدل، توانایی بهتر و دقت بالاتری برای شبیه‌سازی بارش - رواناب نسبت به روش‌های آماری معمول دارد. نتایج همچنین نشان داد که با افزایش فاکتورهای ورودی به شبکه، دقت بالاتری در پیش‌بینی به دست می‌آید. میزان ضریب همبستگی شبکه، ۰/۹۹۸ و میانگین خطای هر شبکه با داده‌های واقعی، ۲/۶ درصد به دست آمد. نتایج شاخص‌های عملکرد شبکه (ضریب تعیین، مجذور میانگین مربعات خطا، میانگین مطلق خطا و ضریب همبستگی) نیز نشان دادند که مقادیر ارائه شده برای پیش‌بینی رواناب حوضه‌ی مورد مطالعه، قابل قبول است. واژه‌های کلیدی: پیش‌بینی، رواناب، زیرحوضه‌ی جنوبی رودخانه‌ی قره‌سو، شبکه‌های عصبی مصنوعی، شبیه‌سازی.

مقدمه

مهار آب‌های سطحی، شبیه‌سازی، شناسایی و مدل-بندی رفتار رودخانه‌ها به منظور انجام برنامه‌ریزی‌های بلندمدت و بهره‌برداری مناسب و معقول از پتانسیل جریان‌های رودخانه‌ای را آشکار می‌سازد. شبیه‌سازی

در کشور ما، اغلب رودخانه‌های مناطق مختلف جغرافیایی، فصلی بوده و بسیاری از آن‌ها سیلابی هستند. این مسأله به علاوه‌ی کمبود آب و ضرورت

توجه کنند (جاین^۴ و همکاران، ۱۹۹۶: ۳۲). عدم نیاز به تثبیت تابع تبدیل به منظور شبیه‌سازی فرآیند بارندگی - رواناب، از امتیازات عمده‌ی شبکه‌های عصبی مصنوعی در مقایسه با روش‌های معمول به شمار می‌رود.

در زمینه‌ی مدل‌سازی بارش - رواناب، پژوهش‌های متنوعی در سطح جهان و ایران صورت گرفته است. هسو^۵ و همکاران (۱۹۹۵) با استفاده از مدل‌های شبکه‌های عصبی مصنوعی و سری‌های زمانی ARMAX، مقادیر رواناب حوضه‌ی رودخانه‌ی لیف^۶ در مجاورت کولینز^۷ می‌سی‌سی‌پی را بر اساس تلفیق مدل‌های فیزیکی و اقلیمی پیش‌بینی نموده و ثابت کردند که مدل‌های شبکه‌های عصبی مصنوعی در این خصوص بر دیگر مدل‌ها برتری نسبی دارند. اسمیت و الی^۸ (۱۹۹۵) با استفاده از مدل‌های شبکه‌های مصنوعی، داده‌های سنجش از دور و مدل فوریه، فرآیند بارش - رواناب و دبی‌های سیلابی در پنج حوضه‌ی آبریز را شبیه‌سازی نمودند. مینز و هال^۹ (۱۹۹۶)، اهمیت درجه‌ی غیرخطی الگوی بارش - رواناب و فاکتور نرمال‌سازی و تعداد لایه‌های مخفی را در مدل‌سازی شبکه‌ی عصبی بارش - رواناب در یک حوضه‌ی فرضی بررسی کردند. آن‌ها به این نتیجه رسیدند که عملکرد شبکه‌ی عصبی، به اندازه‌ی نمونه و سطوح خطا بستگی دارد. داوسون و ویلبی^{۱۰}

فرآیند بارندگی - رواناب در حوضه‌های آبریز، اهمیت خاصی در مدیریت منابع آب و مهندسی رودخانه‌ها دارد. به دلیل تعدد عوامل هیدرولوژیکی حوضه‌های آبریز، عکس‌العمل اغلب حوضه‌ها در برابر نزولات جوی، پیچیده و متفاوت است. بارش، مهم‌ترین منبع تأمین آب حوضه‌های آبخیز است که از نظر زمان و محدوده‌ی اثرگذاری بر حوضه‌ها، به گونه‌های مختلف عمل می‌کند (نورانی و صالحی، ۱۳۸۷: ۲) لذا وجود وجود اطلاعات دقیق و کنترل شده‌ی بارش می‌تواند در فرآیند شبیه‌سازی رواناب به عنوان اولین متغیر، مورد بهره‌برداری قرار گیرد (لورای و سچی^۱، ۱۹۹۵: ۳۰۱). مدل‌های زیادی برای شبیه‌سازی فرآیند بارندگی - رواناب توسط پژوهشگران پیشنهاد شده است که عموماً بر پایه‌ی روش‌های متداول آماری استوار بوده است اما امروزه، پیشرفت‌های درخور توجه در زمینه‌های مختلف هوش مصنوعی^۲ (که شبکه‌های عصبی مصنوعی^۳ هم از آن جمله می‌باشند) مورد توجه بسیاری دانشمندان و محققان قرار گرفته است (اکبرپور و شکرالهی، ۱۳۸۳: ۲). اقلیم‌شناسان، استفاده از مدل‌های کلاسیک مانند روش‌های رگرسیون خطی ساده در پیش‌بینی فرآیند بارش - رواناب (با توجه به پیچیدگی زیاد و غیرخطی بودن فاکتورهای اقلیمی) را مؤثر و کارا نمی‌دانند. در دهه‌های اخیر، حرکت‌های زیاد و شتابنده‌ای به سوی مدل‌های ترکیبی مشاهده می‌شود. مدل‌های شبکه‌های عصبی مصنوعی قادرند مسائل غیرخطی را به خوبی

^۴ - Jain

^۵ - Hsu

^۶ - Leaf

^۷ - Collins

^۸ - Smith & Eli

^۹ - Minns & Hall

^{۱۰} - Dawson & Wilby

^۱ - Lorrai & Sechi

^۲ - Artificial Intelligence

^۳ - Artificial Neural Networks (ANNs)

آن‌ها دریافتند که مدل شبکه‌ی عصبی مصنوعی، جریان‌های روزانه‌ی حوضه‌ی رودخانه‌ی مذکور را برای سه روز آینده بهتر از بازه‌های زمانی دیگر پیش‌بینی می‌کند. هونگ^۱ و همکاران (۲۰۰۹) با استفاده از داده‌های ساعتی بارش، رطوبت نسبی، فشار هوا، دمای تر و ابرناکی آسمان در ۷۵ ایستگاه باران‌سنجی منطقه‌ی بانکوک^{۱۱} تایلند و با بهره‌گیری از مدل‌های شبکه‌های عصبی مصنوعی دریافتند که این مدل‌ها، بارش‌های ساعتی ایستگاه‌های مورد مطالعه را بهتر از سایر مدل‌ها پیش‌بینی می‌نمایند. آن‌ها همچنین دریافتند که عناصر بارش و دمای تر، مهم‌ترین پارامترها در ورود به شبکه‌ی عصبی مصنوعی ایجاد شده می‌باشند. وو و چاو^{۱۲} (۲۰۱۱) با بهره‌گیری از مدل شبکه‌های عصبی مصنوعی و تحلیل‌های یک طیفی، جریان‌های رودخانه‌های دانینگ^{۱۳} و لوشوی^{۱۴} چین را شبیه‌سازی نموده و به نتایج قابل قبولی دست یافتند.

در ایران نیز کارآموز و همکاران (۱۳۸۵) با استفاده از شبکه‌های عصبی، به پیش‌بینی بلندمدت بارش حوضه‌های غربی ایران پرداختند. نتایج به دست آمده حاکی از کارایی مناسب و دقت قابل قبول شبکه‌های عصبی بود. رضایی و همکاران (۱۳۸۶) در مدل‌سازی دبی اوج حوضه‌ی آبخیز سفیدرود (ناحیه‌ی غیر-خزری)، از شبکه‌ی عصبی مصنوعی استفاده کردند. این بررسی نشان داد که مدل شبکه‌ی عصبی، کارایی

(۱۹۹۸)، با استفاده از شبکه‌های عصبی مصنوعی، مدل‌های بارش - رواناب را برای پیش‌بینی جریان رودخانه‌ای دو حوضه‌ی سیل‌خیز انگلستان (آمبر و مول^۱) ارائه نمودند. توکار و مارکوس^۲ (۲۰۰۰) با استفاده از شبکه‌ی عصبی مصنوعی، رابطه‌ی بارندگی - رواناب را برای پیش‌بینی جریان ماهانه در سه حوضه‌ی آبخیز با شرایط آب و هوایی و فیزیوگرافی متفاوت در مریلند مدل‌سازی کردند. جنگ و کیم^۳ (۲۰۰۵)، جریان‌های رودخانه‌ای منتهی به سد چندمنظوره‌ی داچنگ^۴ گره‌ی جنوبی را با استفاده از مدل‌های شبکه‌ی عصبی مصنوعی منفرد^۵ (SNN) و شبکه‌ی عصبی مصنوعی جمعی^۶ (ENN) پیش‌بینی نمودند. آن‌ها دریافتند که مدل شبکه‌ی عصبی مصنوعی منفرد (SNN) بهتر از مدل شبکه‌ی عصبی مصنوعی جمعی (ENN)، دبی‌های جریان‌های رودخانه‌ای مذکور را پیش‌بینی می‌کنند. آگاروال^۷ و همکاران (۲۰۰۹) با بهره‌گیری از شبکه‌های عصبی مصنوعی، مقادیر رواناب و رسوب را در حوضه‌های آبریز هندوستان پیش‌بینی کردند. اختر^۸ و همکاران (۲۰۰۹)، از مدل شبکه‌های عصبی مصنوعی در پیش‌بینی جریان‌های روزانه‌ی حوضه‌ی رودخانه‌ی گنگ^۹ بهره برده و توزیع فضایی بارش در آن حوضه را مطالعه نمودند.

^۱ - Amber & Mole

^۲ - Tokar & Markus

^۳ - Jeong & Kim

^۴ - Daecheong

^۵ - Single Neural Network

^۶ - Ensemble Neural Network

^۷ - Akhtar

^۸ - Agarwal

^۹ - Ganges

^{۱۰} - Hung

^{۱۱} - Bangkok

^{۱۲} - Wu & Chau

^{۱۳} - Daning

^{۱۴} - Lushui

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. حوضه‌ی آبریز قره‌سو دارای پتانسیل بالایی از نظر تولید رواناب است. در این پژوهش، سعی شده است مقادیر رواناب زیرحوضه‌ی جنوبی این رودخانه، بر اساس آمار بلند-مدت ۴ ایستگاه هیدرومتری نیر، پل الماس، گیلانده و نمین و با استفاده از برخی پارامتر اقلیمی مؤثر بر میزان رواناب آن زیرحوضه، رواناب سال‌های آینده مدل‌سازی و میزان خطای محاسباتی آن با داده‌های واقعی مورد بررسی و ارزیابی قرار گیرد.


مواد و روش‌ها

حوضه‌ی آبریز مورد مطالعه که از زیرحوضه‌های جنوبی رودخانه‌ی قره‌سو (از زیرحوضه‌های رودخانه-ی ارس) محسوب می‌شود بین طول‌های جغرافیایی ۴۶° ۴۷' تا ۴۷° ۴۸' شرقی و عرض‌های جغرافیایی ۴۷° ۳۷' تا ۳۸° ۳۶' قرار گرفته است. مساحت حوضه ۳۲۶۳/۸ کیلومتر مربع و محیط آن ۲۹۲ کیلومتر می‌باشد. حداقل، حداکثر و متوسط ارتفاع حوضه به ترتیب برابر با ۱۲۹۰، ۴۷۸۱ و ۱۷۸۷ متر، طول رودخانه‌ی اصلی، طول و عرض مستطیل معادل و طول کل آبراه‌ها به ترتیب برابر با ۱۱۴، ۱۹۸/۵، ۲۰/۸ و ۳۲۶۸ کیلومتر و متوسط شیب رودخانه‌ی اصلی و شیب حوضه به ترتیب ۹ و ۱۱/۳ درصد است. متوسط بارش سالانه‌ی حوضه ۳۴۰/۵ میلی‌متر و مجموع جریان خروجی سالانه از حوضه ۲۸۱/۴۰۷ میلیون متر مکعب برآورد شده است. آبراه‌های درجه‌ی ۱ تا ۶ به ترتیب ۶/۶، ۱۳/۶، ۲۵/۶، ۶/۴،

بالایی در پیش‌بینی دبی حداکثر خروجی از حوضه‌ی آبخیز سفیدرود دارد. آن‌ها همچنین دریافته‌اند که شبکه‌های عصبی مصنوعی، بهتر از مدل‌های متداول دیگر می‌توانند مقادیر رواناب حوضه‌ی آبخیز سفیدرود را در سال‌های آینده با دقت بالایی تخمین بزنند. شادمان مطلق و همکاران (۱۳۸۶)، جریان رودخانه‌ی سفیدرود را با استفاده از شبکه‌های عصبی مصنوعی پیش‌بینی نمودند. قلخانی و همکاران (۱۳۸۶)، سیلاب رودخانه‌ی کارون را با استفاده از شبکه‌های عصبی مصنوعی پیش‌بینی کردند. نوری و همکاران (۱۳۸۶)، در الگوبندی بارش - رواناب حوضه‌ی آبریز هلیل-رود، عملکرد شبکه‌ی عصبی پرسپترون چندلایه را با استفاده از موجک بهبود بخشیده و الگوی بارش - رواناب حوضه‌ی مورد مطالعه خود را با شبکه‌ی عصبی ارائه نمودند. آن‌ها با ضریب همبستگی و ریشه میانگین مربعات خطا، محاسبات خود را کنترل نمودند. نورانی و صالحی (۱۳۸۷)، مدل بارش - رواناب حوضه‌ی آبریز ليقوان‌چای را با استفاده از روش شبکه‌های عصبی ارائه کردند. جهانگیر و همکاران (۱۳۸۷)، فرایند بارش - رواناب حوضه‌ی آبریز کارده را با شبکه‌ی عصبی مصنوعی شبیه‌سازی نموده و دریافته‌اند که شبکه‌ی عصبی پرسپترون چندلایه با تعداد ۲۹ نرون در لایه‌ی میانی (پنهان)، فرایند بارش - رواناب آن حوضه را با دقت خوبی شبیه‌سازی می‌کند. نصیری و یمانی (۱۳۸۸)، با بهره‌گیری از تکنیک شبکه‌های عصبی مصنوعی در حوضه‌ی امامه (از زیرحوضه‌های جاجرود) و نیز با بهره‌مندی از تکنیک‌های ژئومورفولوژی، رواناب مستقیم آن حوضه را بررسی نموده و برکارا بودن مدل شبکه‌های عصبی مصنوعی صحه گذاشتند. نتایج مطالعات پژوهشگران

رواناب در زیرحوضه‌ی جنوبی رودخانه‌ی قره‌سو می‌باشد، لذا از داده‌های دما، بارش، رطوبت نسبی، تبخیر و رواناب حوضه‌ی مورد بررسی در یک دوره‌ی آماری ۳۹ ساله (۱۹۷۲-۲۰۱۰) استفاده شده است. دلیل انتخاب این دوره‌ی آماری، موجود بودن داده‌ها تا همین دوره‌ی زمانی می‌باشد. شکل شماره ۱، موقعیت جغرافیایی حوضه‌ی آبریز مورد مطالعه را نشان می‌دهد.

۳/۲، ۱/۶ و ۰/۴ کیلومتر طول دارند. زمان تمرکز در حوضه‌ی مورد مطالعه ۱۸/۵ ساعت است. فرارگیری سرشاخه‌های زیرحوضه‌ی مورد مطالعه در نواحی کوهستانی سبب شده است تا حوضه‌ی مورد مطالعه، همانند اغلب حوضه‌های شمال‌غرب کشور، دارای رژیم برفی - بارانی باشد و در فصل بهار، حالت‌های طغیانی به خود بگیرد. از آنجایی که این پژوهش در صدد مدل‌سازی و شبیه‌سازی فرایند بارش -



شکل شماره ۱: موقعیت جغرافیایی حوضه‌ی آبریز مورد مطالعه

درون‌سلولی نرون‌های مغز را شبیه‌سازی کنند و از طریق وزن‌های محاسباتی موجود در خطوط ارتباطی نرون‌های مصنوعی، عملکرد سیناپسی را در نرون‌های طبیعی به مدل درآوردند (شریفی، ۱۳۸۴: ۲). نرون‌ها کوچک‌ترین واحد تشکیل دهنده‌ی شبکه‌ی عصبی مصنوعی می‌باشند. هر شبکه از یک لایه‌ی ورودی، یک لایه‌ی خروجی و یک یا چند لایه‌ی میانی تشکیل شده است. نرون‌های هر لایه بوسیله‌ی وزن‌هایی به نرون‌های لایه‌ی بعدی متصل می‌شوند. طی فرایند آموزش شبکه، این وزن‌ها و مقادیر ثابتی که با آن‌ها جمع می‌شوند (بایاس)، مرتباً تغییر یافته تا این که خطا


شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی، مدل ساده شده‌ای از مغز انسان می‌باشند. این شبکه‌ها یک ساختار ریاضی هستند که توانایی نشان دادن فرایندها و ترکیبات غیرخطی جهت ارتباط بین ورودی‌ها و خروجی‌های هر سیستمی را دارا هستند. شبکه‌های عصبی مصنوعی، طی فرایند یادگیری، آموزش دیده و برای پیش‌بینی در آینده مورد استفاده قرار می‌گیرند (اکبرپور و همکاران، ۱۳۸۲: ۲). به عبارت دیگر، شبکه‌های عصبی مصنوعی با ساختاری هوشمند، با الگوبرداری از نرون‌های مغز انسان می‌توانند از طریق توابع مشخص ریاضی، رفتار

یادگیری، میزان فراگیری شبکه توسط توابع هدف، دائماً سنجش می‌شود. در نهایت، شبکه‌ای مورد پذیرش قرار می‌گیرد که کم‌ترین میزان خطا را داشته باشد (اکبرپور و همکاران، ۱۳۸۲: ۳). به طور کلی، شبکه‌های عصبی مصنوعی به دو گروه شبکه‌های پیش‌خور و پس‌خور تقسیم می‌شوند. در این مقاله، با توجه به کاربرد شبکه‌های پرسپترون چندلایه‌ی پیش‌خور در پیش‌بینی پارامترهای هیدرولوژی و قابلیت بالای آن‌ها در تعمیم نتایج، از این شبکه‌ها برای پیش‌بینی رواناب استفاده شده است.

شبکه‌ی پرسپترون چندلایه، با تعریف اوزان و توابع مناسب، برای حل مسائل پیچیده‌ی ریاضی مورد استفاده قرار می‌گیرد. توابع فعالیت مختلفی در نرون‌ها مورد استفاده قرار می‌گیرند. در این نوع شبکه‌ها از یک لایه‌ی ورودی جهت اعمال ورودی‌های مسئله، یک لایه‌ی پنهان و یک لایه‌ی خروجی که پاسخ‌های مسئله را ارائه می‌نماید، استفاده می‌شود (شریفی، ۱۳۸۴: ۳). در شبکه‌ی عصبی پرسپترون چندلایه، نرون‌هایی که در یک لایه قرار دارند در یک مرحله فعال شده و به ورودی‌های خود پاسخ می‌دهند یعنی دارای یک نوع تابع تحریک می‌باشند. گره‌هایی که در لایه‌ی ورودی هستند، نرون‌های حسی^۲ و گره‌های لایه‌ی خروجی، نرون‌های پاسخ‌دهنده^۳ هستند. در لایه‌ی پنهان نیز نرون‌های پنهان^۴ وجود دارند. آموزش آموزش این‌گونه شبکه‌ها معمولاً با روش پس‌انتشار خطا^۵ که از نوع آموزش کاهش گرادیان بوده و مبنای

به حداقل ممکن خود برسد. برای انتقال خروجی‌های هر لایه به لایه‌های بعدی، از توابع محرک استفاده می‌شود. از توابع محرک معروف می‌توان به توابع سیگموئیدی، خطی و آستانه‌ای اشاره کرد که در این مقاله نیز از تابع سیگموئیدی (پورلاین) استفاده گردیده است. در شکل شماره ۲، یک شبکه‌ی عصبی بسیار ساده نشان داده شده است. در این شکل، ورودی، W وزن، b بایاس، f تابع محرک و a خروجی می‌باشد (اکبرپور و همکاران، ۱۳۸۲: ۳).



شکل شماره ۲: یک شبکه‌ی عصبی بسیار ساده

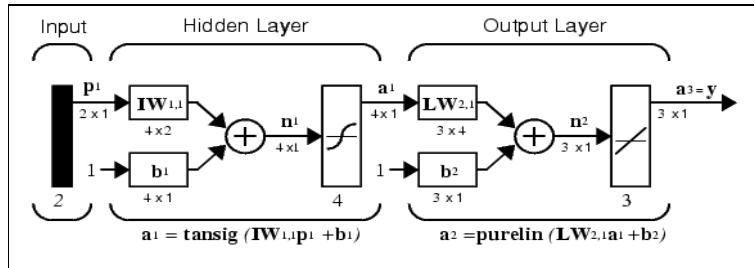
روشی که برای ایجاد وزن‌ها و به منظور دستیابی به مقدار بهینه، انتخاب می‌شود، قانون یادگیری (که یک الگوریتم ریاضی پیچیده است) نام دارد. به عبارت دیگر، قانون یادگیری، فرآیند تغییر وزن‌های ارتباط دهنده برای دستیابی به قابلیت پاسخ‌گویی به الگوهای متفاوت از ورودی‌هایی که برای آموزش شبکه استفاده شده است (الگوهای آزمایش‌کننده)، اطلاق می‌شود (سانچز و ساینسیو^۱، ۱۹۹۲). هر شبکه، شبکه، برای ایجاد و مطلوبیت، به دو سری داده (آموزش و آزمون) نیازمند است. در حدود هشتاد درصد داده‌ها صرف آموزش و مابقی صرف تست شبکه می‌گردند (که البته در این پژوهش، نود درصد داده‌ها صرف آموزش شبکه گردیده است). طی فرایند

2 -Sensory
3 - Responding
4 - Hidden
5 -Back Propagation


1 -Sanchez & Sienencio

(همان منبع). نمونه‌ای از یک شبکه‌ی پرسپترون چندلایه در شکل‌های شماره‌ی ۳ و ۴ نمایش داده شده است.

ریاضی آن، تکنیک بهینه‌سازی است انجام می‌شود (قلخانی و همکاران، ۱۳۸۶: ۴) که در این پژوهش نیز از آن استفاده شده است. شبکه‌های پرسپترون چندلایه می‌توانند با هر تعداد لایه، ساخته و به کار گرفته شوند



شکل شماره‌ی ۳: ساختار پرسپترون چندلایه با نرون‌های پنهان تانسیگ و نرون‌های خروجی با تابع خطی



شکل شماره‌ی ۴: شبکه‌ی پرسپترون چندلایه

پیش‌بینی بارش - رواناب در زیرحوضه‌ی مورد مطالعه از داده‌های دما، بارش، رطوبت نسبی، تبخیر و رواناب ۳۹ ساله (۱۹۷۲-۲۰۱۰) استفاده شده است. نتایج آزمون ران تست، تصادفی بودن این داده‌ها را تأیید نمود. ارتباط بین پارامترهای مذکور در مقیاس ماهانه به دست آمد آنگاه برای تعیین مؤثرترین عوامل بر بارش حوضه، از روش تجزیه رگرسیون گام به گام استفاده شد. نتایج حاصله نشان داد که بیشترین همبستگی رواناب حوضه با بارش می‌باشد. در شبیه‌سازی با استفاده از شبکه‌های عصبی مصنوعی، ورود داده‌ها به صورت نمره‌ی استاندارد به شبکه، خطاها را کاهش می‌دهد. به عبارت دیگر، ورود داده‌ها به

همان‌گونه که در شکل شماره‌ی ۴ ملاحظه می‌گردد شبکه‌ی پرسپترون چندلایه، عملاً از به هم پیوستن سه شبکه‌ی پرسپترون تک‌لایه ایجاد شده است. لایه‌ی آخر، لایه‌ی خروجی و دو قسمت دیگر، لایه‌های میانی نامیده می‌شوند. خروجی‌های لایه‌ی اول، بردار ورودی لایه‌ی دوم را تشکیل می‌دهند و به همین ترتیب، بردار خروجی لایه‌ی دوم، ورودی لایه‌ی سوم را می‌سازند و خروجی‌های لایه‌ی سوم، پاسخ واقعی شبکه را شکل می‌دهند. اصولاً نوع یک شبکه‌ی عصبی، توسط ساختار و همچنین آموزش آن مشخص می‌شود (منهاج، ۱۳۸۴: ۷۱۲ به نقل از حسینی، ۱۳۸۸: ۳۰). همان‌گونه که گفته شد، در این پژوهش جهت

صورت خام، سرعت و دقت شبکه را کاهش می‌دهد لذا لازم بود داده‌های ورودی به شبکه (پارامترهای مورد استفاده)، استاندارد گردند. استاندارد نمودن داده‌ها همچنین اجازه می‌دهد تا مقادیر چند متغیر وابسته به هم در یک نمونه، با مقایسه شوند. از محاسن این رابطه، امکان انجام بهتر پیش‌بینی‌های خارج از مقادیر حدی در داده‌های دوره‌ی آموزش می‌باشد که به صورت زیر بیان می‌شود (خسروی و شکیبیا، ۱۳۸۹: ۸) (ساجیکومار و تانداورسوارا^۱، ۱۹۹۹: ۳۴):

$$N_i = 0.8 \left[\frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \right] + 0.1$$

در رابطه‌ی فوق، N_i : مقادیر نرمال شده، X_i : مقادیر واقعی، X_{\max} : حداکثر مقادیر واقعی و X_{\min} : حداقل مقادیر واقعی است. با معکوس نمودن الگوریتم استاندارد سازی، خروجی‌های شبکه به حالت اولیه برمی‌گردند. در پژوهش حاضر، داده‌ها بر اساس رابطه‌ی فوق بین ۰/۱ و ۰/۹ نرمال شده‌اند. پیش‌بینی رواناب ماهانه با استفاده از شبکه‌های عصبی مصنوعی و تشکیل ماتریس داده‌ها انجام گرفت. ورودی‌های شبکه شامل متغیرهای متوسط بارش ماهانه (میلی متر)، متوسط دبی ماهانه (میلیون متر مکعب)، متوسط رطوبت نسبی ماهانه (درصد)، متوسط دمای ماهانه (درجه‌ی سانتی‌گراد) و متوسط تبخیر ماهانه (میلی متر) در زمان‌های قبل) و خروجی شبکه، پیش‌بینی رواناب ماهانه در سال‌های آینده بود که وارد این ماتریس شد. از ۳۹ سال دوره‌ی آماری موجود (۲۰۱۰ - ۱۹۷۲)، نود درصد آن یعنی ۳۵ سال (۴۲۰ ماه) برای آموزش شبکه و ۴ سال (۴۸ ماه) باقی‌مانده در مرحله‌ی آزمون

شبکه مورد استفاده قرار گرفت. پس از انتخاب داده‌های ورودی و خروجی شبکه و تعیین ساختار شبکه از لحاظ تابع محرک، تعداد نرون‌ها و لایه‌های پنهان، تعداد تکرار (اپوک)، مقادیر پارامترهای آموزشی و تابع عملکرد، آموزش شبکه با استفاده از الگوریتم‌های آموزشی برنامه، ابتدا با یک نرون پنهان و ۱۰ تکرار شروع شده و با افزایش آن تا حداکثر تعداد نرون و تکرار ادامه یافت. پس از هر بار آموزش، از طریق آنالیز رگرسیون و ضریب همبستگی بین داده‌های ورودی و خروجی (در مرحله‌ی آموزش) و درصد خطا (در مرحله‌ی آزمون) شبکه مورد آزمون قرار گرفت مبنای تعیین تعداد نرون‌های مخفی و تکرارها، بالاترین مقدار همبستگی و خطای کمتر از ۵ درصد بود. با مشخص بودن تعداد نرون‌های بهینه‌ی مخفی و تکرار، مقادیر پارامترهای آموزشی و نوع تابع محرک و همچنین تعداد لایه‌های پنهان، برای حصول به یک شبکه‌ی بهینه، چندین بار تغییر یافت تا شبکه‌ی بهینه انتخاب گردد. طبق نظر نیرومند و بزرگ‌نیا (۱۳۷۲: ۲۸۳)، تعداد پیش‌بینی‌ها نباید بیشتر از یک چهارم داد-ها باشد. از آنجایی که شبکه بر اساس یک دوره‌ی آماری بلند مدت (۳۵ ساله) آموزش دیده است لذا شبکه به گونه‌ای طراحی گردید که بتوان با ورود پارامترهای بارش، رطوبت نسبی، دما، تبخیر و رواناب سال‌های قبل، دبی سال‌های بعد را با خطای کمتر از ۵ درصد برآورد کرد. پس از طراحی ۱۲ شبکه به منظور برآورد دبی حوضه، ساختارهای مختلف شبکه پرسپترون از نظر پارامترهای آموزشی با استفاده از ۱۲ الگوریتم، طراحی و شبکه‌ی بهینه انتخاب گردید. در

² -Epoch

³¹ - Sajikumar; Thandaveswara

شبکه بالاتر و با افزایش سال‌های آماری، دقت شبکه افزایش می‌یافت

نتایج حاصل در تمامی ماه‌ها ضریب همبستگی بالای ۰/۹۳ را نشان داد که در حد بسیار قابل قبولی است. حداقل ضریب همبستگی در مرحله‌ی آموزش مربوط به ماه آوریل با ۰/۹۳ و حداکثر آن ۰/۹۸ مربوط به ماه ژوئن است. پس از هر بار آموزش شبکه، نموداری که نشانگر روند تغییرات خطای داده‌های آموزشی و تست شبکه می‌باشد ترسیم گردید (شکل شماره ۵). در این نمودار، خط ممتد، مربوط به بهترین خط برازش یافته از بین نقاط داده‌ها و خط نقطه چین، نیمساز ربع اول دو محور عمودی و افقی است. هر قدر این خط به بهترین خط برازش یافته (خط ممتد) نزدیک‌تر باشد، بیانگر برازش عالی و برآورد دقیق خروجی‌های شبکه خواهد بود (داده‌های موجود در نمودار نرمال شده است). شکل شماره ۵، حداکثر و حداقل ضریب همبستگی به دست آمده در ماه‌های ژوئن و آوریل را نشان می‌دهد. حداکثر ضریب همبستگی در مرحله‌ی آموزش مربوط به ماه ژوئن با ۰/۹۸ و حداقل آن مربوط به ماه آوریل با ۰/۹۳ با سطح خطای ۰/۰۰۵ است (جدول شماره ۱).

نهایت، برای ارزیابی و مقایسه‌ی دقت عملکرد شبکه‌ی عصبی منتخب در پیش‌بینی رواناب، از شاخص‌های ضریب تعیین (R^2)^۱، مجذور میانگین مربعات خطا (RMSE)^۲، میانگین مطلق خطا (MAE)^۳ و ضریب همبستگی (R)^۴ بهره گرفته شد. بهترین مقدار برای (R^2) و (R) برابر یک است و (RMSE) و (MAE) نزدیک صفر می‌باشد.

نتایج و بحث

در تعیین بهترین متغیرهای ورودی به شبکه، از ضرایب همبستگی و رگرسیونی بین رواناب واقعی و برآورد شده‌ی تمامی شبکه‌ها (ماه‌ها) استفاده گردید که نتایج آن‌ها در جدول شماره ۱ ارائه شده است. در تمامی ماه‌ها، رواناب ماه t ام از سال t ام با متغیر متوسط بارش، نم نسبی، دما، تبخیر و دبی ماهانه سال $i-1+i-2+\dots+i-n$ ام همبستگی نشان داد. البته این حالت با سعی و خطا و بررسی فراوان به دست آمده است بدین صورت که در تمامی حالات در تمامی ماه‌ها، متغیر رواناب با متغیرهای متوسط بارش ماهانه، متوسط تبخیر ماهانه، متوسط رطوبت نسبی ماهانه و متوسط دمای ماهانه همبستگی بالایی نشان داد و در نهایت، رواناب سال t ام نسبت به متوسط بارش ماهانه، متوسط تبخیر ماهانه، متوسط رطوبت نسبی ماهانه و متوسط دما ماهانه همان سال t ام بیش‌ترین همبستگی را نشان داد و برای برآورد رواناب از آن استفاده گردید. در کل، با افزایش تعداد متغیرها، دقت

23 -Determination Coefficient

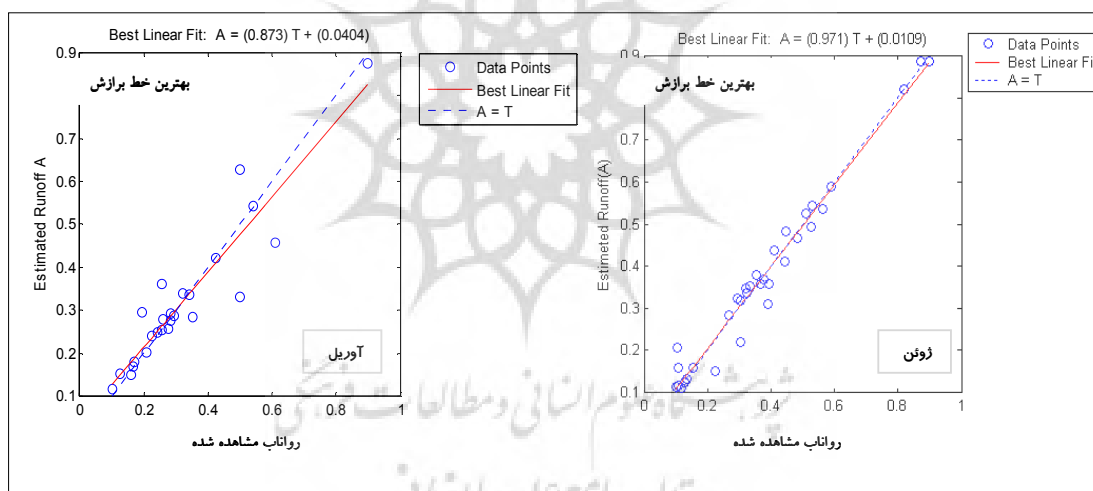
24 -Root Mean Square Error

25 -Mean Absolute Error


26 -Correlation Coefficient

جدول شماره ۱: پارامترهای آموزشی بهینه برای شبکه‌ی پرسپترون چندلایه جهت پیش‌بینی رواناب

پارامتر آموزشی ماه	تعداد نرون	تابع محرک لایه‌ی پنهان		تعداد تکرار	هدف عملکرد	ضریب همبستگی (R)	خطا بر حسب درصد میانگین	الگوریتم یادگیری
		رتبه اول	رتبه دوم					
ژانویه	۱۰-۲	لوگ سیگ	تان سیگ	۲۰	۰/۰۰۵	۰/۹۷۴	۲/۱۶	ال ام
فوریه	۸	تان سیگ	لوگ سیگ	۴۰	۰/۰۰۵	۰/۹۵۱	۱/۹۸	ال ام
مارس	۶	لوگ سیگ	...	۲۰۰	۰/۰۰۵	۰/۹۷	۲/۸۰	ال ام
آوریل	۷-۵	تان سیگ	لوگ سیگ	۸۰	۰/۰۰۵	۰/۹۳۵	۴/۴۵	ال ام
می	۹	تان سیگ	لوگ سیگ	۴۰۰	۰/۰۰۵	۰/۹۷۶	۳/۰۸	ال ام
ژوئن	۴-۳	تان سیگ	...	۲۰	۰/۰۰۵	۰/۹۸۵	۰/۵۵	ال ام
ژوئیه	۸	لوگ سیگ	تان سیگ	۱۰	۰/۰۰۵	۰/۹۸۱	۱/۴۲	ال ام
آگوست	۶-۴	لوگ سیگ	تان سیگ	۵۰	۰/۰۰۵	۰/۹۴۲	۲/۳۷	ال ام
سپتامبر	۳-۸	تان سیگ	...	۲۰	۰/۰۰۵	۰/۹۴۸	۲/۷۳	ال ام
اکتبر	۳	لوگ سیگ	...	۱۸	۰/۰۰۵	۰/۹۷۶	۲/۹۴	ال ام
نوامبر	۲-۶	تان سیگ	لوگ سیگ	۳۰	۰/۰۰۵	۰/۹۵	۴/۰۸	ال ام
دسامبر	۵	لوگ سیگ	...	۷۰۰	۰/۰۰۵	۰/۹۶۲	۲/۶۸	ال ام




شکل شماره ۵: ضریب همبستگی مرحله‌ی آموزش با الگوریتم LM مربوط به ماه ژوئن و آوریل



شکل شماره ۶: ساختار بهترین شبکه‌ی پرسپترون چندلایه‌ی به کار برده شده با ۵ لایه‌ی ورودی، ۴ نرون در لایه‌ی

پنهان اول، ۳ نرون در لایه‌ی پنهان دوم، ۲ تابع محرک لایه‌ی پنهان و ۱ خروجی مربوط به ماه ژوئن



شکل شماره ۷: ساختار ضعیف‌ترین شبکه‌ی پرسپترون چندلایه‌ی به کار برده شده با ۵ لایه‌ی ورودی، ۷ نرون در لایه‌ی پنهان اول، ۵ نرون در لایه‌ی پنهان دوم، ۲ تابع محرک لایه‌ی پنهان و ۱ خروجی مربوط به ماه آوریل

در تعیین بهترین الگوریتم، از الگوریتم LM به منظور شناسایی بهترین روش با بالاترین بازده برای آموزش شبکه استفاده شده است. الگوریتم مارکوآرت - لونبرگ، تغییر یافته‌ی الگوریتم کلاسیک نیوتن است که برای پیدا کردن راه‌حلی مناسب برای مسائلی که نیاز به کمینه‌سازی دارند به کار می‌رود. این روش یک تقریب برای ماتریس هیزن در تغییر وزن‌ها مثل روش نیوتن در نظر می‌گیرد (نورانی و صالحی، ۱۳۸۷: ۳). $X_{k+1} = X_k - [J^T J + \mu I]^{-1} J^T + e$

در رابطه‌ی فوق، X وزن‌های شبکه‌ی عصبی، J ژاکوبین ماتریس معیار اجرای شبکه که باید حداقل شود، μ عددیست که فرآیند آموزش را کنترل می‌کند و e بردار خطای باقیمانده است. الگوریتم مارکوآرت - لونبرگ به دلیل همبستگی بیشتر در مرحله‌ی آموزش و خطای پایین در مرحله‌ی آزمون و نیز دارا بودن بهترین عملکرد، بالاترین ضریب همبستگی و کمترین تعداد نرون در لایه‌ی پنهان، از میان دیگر الگوریتم‌ها انتخاب گردید.

حداکثر تعداد نرون چندلایه‌ی به کار برده شده با ۵ لایه‌ی ورودی، ۷ نرون در لایه‌ی پنهان اول، ۵ نرون در لایه‌ی پنهان دوم، ۲ تابع محرک لایه‌ی پنهان و ۱ خروجی مربوط به ماه آوریل

حداکثر تعداد نرون در این پژوهش برای هر ۱۲ شبکه، ۱۰ نرون انتخاب گردید به طوری که تعداد پارامترهای شبکه بیشتر از تعداد داده‌های یادگیری که برای هر شبکه ۶۶ داده بودند، نگردند. بدین صورت که تعداد نرون‌های پنهان، با یک نرون در لایه‌ی پنهان شروع و تا حداکثر تعداد نرون (۱۰ نرون) ادامه یافت. به طور متوسط، الگوریتم مارکوآرت - لونبرگ با سرعت بالای همگرایی نسبت به دیگر الگوریتم‌ها به تعداد نرون‌های کمتری نیاز دارد. معمولاً با افزایش اطلاعات ورودی به شبکه، شبکه با ساختار ساده‌تری رابطه ورودی و خروجی را یاد می‌گیرد. در نتیجه، تعداد نرون‌های مورد نیاز نیز کاهش می‌یابد. در شبکه‌های مورد بررسی، بیشترین تعداد نرون مربوط به ماه ژانویه با ۱۰ نرون در لایه‌ی اول، ۲ نرون در لایه‌ی پنهان دوم و کمترین آن با ۳ نرون در لایه‌ی پنهان اول مربوط به ماه اکتبر است (جدول شماره ۲). در ماه‌های فوریه، مارس، می، ژوئیه، اکتبر و دسامبر به دلیل نوسانات کمتر رواناب، شبکه با لایه‌های پنهان کمتر عملکرد خوبی را نشان داد ولی در بقیه‌ی ماه‌ها به دلیل نوسانات زیاد رواناب، با یک لایه‌ی پنهان و با حداکثر تعداد نرون، عملکرد مناسبی را از خود نشان

نداد. تعداد اولیه‌ی تکرارهای آموزشی شبکه برای هر ماه برای الگوریتم ماراکوارت- لونبرگ ابتدا از ۱۰ تکرار برای هر نرون در لایه‌ی پنهان و با مقدار اولیه‌ی خطای هدف برابر با ۰/۰۰۵ شروع و تا حداکثر تعداد تکرار ۷۰۰ ادامه یافت. با ثابت نگه داشتن مقدار خطای هدف، به بررسی مقادیر مختلف تکرار پرداخته شد. هر شبکه‌ای که در هر تکراری به بالاترین ضرایب همبستگی در مرحله‌ی آموزش و خطای زیر ۵ درصد می‌رسید آن تکرار به عنوان تکرار بهینه برای آن شبکه انتخاب می‌گردید که در پژوهش حاضر، شبکه با کمترین تعداد تکرار در ماه ژوئیه با ۱۰ تکرار و بیشترین تعداد تکرار مربوط به ماه دسامبر با ۷۰۰ سیکل به هدف مورد نظر رسیده است (جدول شماره‌ی ۱).


پس از مراحل ذکر شده، شبکه با مقدار خطای ۰/۰۰۰۱ (دقت اندازه‌گیری داده‌ها) مورد تست قرار گرفت. با توجه به این‌که بیشتر شبکه‌ها با الگوریتم ماراکوارت- لونبرگ و با خطای ۰/۰۰۵ عملکرد بهتری از خود نشان دادند، بنابراین به عنوان مقدار بهینه خطای هدف انتخاب گردید. پس از تعیین موارد مذکور، شبکه با تابع لگاریتم سیگموئیدی و تانژانت سیگموئیدی سنجیده شد. در هر شبکه، از تابع محرکی استفاده گردید که عملکرد بهتری را نشان می‌داد و بسته به عملکرد شبکه در بعضی از شبکه‌ها فقط از یکی از آنها و در بعضی دیگر از هر دو آنها استفاده گردید. بنابراین، از تابع محرک تانژانت سیگموئید، تابع محرک لگاریتم سیگموئید در لایه‌ی پنهان و تابع

محرک خطی (پورلاین) در لایه‌ی خروجی جهت پیش‌بینی رواناب استفاده شد. علت انتخاب این تابع، غیرخطی بودن و پرکاربرد بودن‌شان است. بنابراین، آموزش و تست شبکه‌ها با مقادیر تعداد تکرار، خطای هدف، تعداد نرون‌ها و لایه‌های پنهان و توابع محرک انتخاب شده در این پژوهش، صحیح بوده که خلاصه نتایج آن برای ۱۲ شبکه (ماه) در جدول شماره‌ی ۱ آورده شده است.


داده‌های جدول شماره‌ی ۲ بیانگر آن است که حداقل خطا مربوط به ماه سپتامبر ۲۰۱۰، ژوئن ۲۰۰۸ با ۰/۰۱ درصد و حداکثر خطا مربوط به ماه آوریل ۲۰۰۸ با ۵/۴ درصد است. بهترین و ضعیف‌ترین شبکه‌ها مربوط به ماه ژوئن با میانگین خطای ۰/۰۵ درصد و ماه آوریل با میانگین خطای ۴/۶۳ درصد و کمترین میانگین خطا مربوط به سال ۲۰۱۰ با میانگین سالانه‌ی ۲/۲۶ درصد خطا است. میانگین کل خطای شبکه‌ها برابر با ۲/۶ درصد است. شبکه‌های طراحی شده توانستند رواناب را با حداکثر اختلاف ۲/۸۷ درصد با داده‌های واقعی برآورد نمایند به طوری که میزان همبستگی داده‌های برآورد شده و واقعی به ۰/۹۹ رسیده که با داده‌های برآورد شده در سطح یک درصد معنی‌دار گشتند (شکل‌های شماره‌ی ۸ و ۹). همان‌طور که مشاهده می‌گردد رواناب برآورد شده به وسیله مدل به حدی به رواناب واقعی نزدیک است که رواناب واقعی و برآورد شده در بیشتر موارد برهم منطبق می‌گردند.

جدول شماره‌ی ۲: میزان خطا بر حسب درصد در شبکه‌های عصبی مصنوعی

میانگین خطای هر شبکه	۲۰۱۰	۲۰۰۹	۲۰۰۸	۲۰۰۷	
۲/۱۶	۱/۸۰	۱/۰۷	۳/۲۳	۲/۵۶	ژانویه
۱/۹۸	۰/۱۵	۴/۲۹	۱/۳۳	۲/۱۴	فوریه
۲/۸۰	۴/۳۴	۲/۱۴	۰/۴۸	۴/۲۳	مارس
۴/۴۵	۴/۶۳	۴/۱۵	۵/۴۰	۳/۶۱	آوریل
۳/۰۸	۳/۴۹	۱/۱۹	۳/۱۸	۴/۴۷	می
۰/۵۵	۰/۰۵	۲/۱۰	۰/۰۱	۰/۰۴	ژوئن
۱/۴۲	۲/۱۱	۰/۹۴	۰/۴۳	۲/۱۹	ژوئیه
۲/۳۷	۰/۱۰	۲/۹۵	۱/۳۶	۵/۰۷	اوت
۲/۷۳	۰/۰۱	۴/۵۸	۵/۳۱	۱/۰۳	سپتامبر
۲/۹۴	۳/۰۶	۲/۸۳	۲/۱۵	۳/۷۰	اکتبر
۴/۰۸	۴/۴۱	۳/۰۵	۴/۲۷	۴/۶۱	نوامبر
۲/۶۸	۲/۹۷	۴/۹۷	۱/۹۶	۰/۸۲	دسامبر
۲/۶۰	۲/۲۶	۲/۸۵	۲/۴۳	۲/۸۷	میانگین خطا



شکل شماره‌ی ۸: نتایج مرحله‌ی آزمون در مدل شبکه عصبی



شکل شماره‌ی ۹: معادله‌ی رگرسیونی بین رواناب واقعی و برآورد شده با مدل شبکه‌ی عصبی مصنوعی

جدول شماره‌ی ۳: ارزیابی عملکرد شبکه‌ی عصبی مصنوعی

مدل	RMSE	MSE	MAE	E	R2	R
شبکه‌ی عصبی مصنوعی	۳/۰۸	۹/۴	۲/۶	۲/۸۷	۰/۹۹۸	۰/۹۹۹

ارزیابی عملکرد شبکه (جدول شماره ۳) نیز نشان داد که مجذور میانگین مربعات خطا، میانگین مطلق خطا و میانگین درصد خطا به ترتیب برابر با ۳/۰۸، ۲/۶ و ۲/۸۷ است. این مقادیر هرچه به صفر نزدیک‌تر باشند نشانگر عملکرد بهتر شبکه است. ضریب تعیین و همبستگی شبکه نیز برابر با ۰/۹۹۸ و ۰/۹۹۹ است که ضریب همبستگی در سطح یک درصد معنی‌دار گشته است و با توجه به این که دیگر معیارهای ارزیابی شبکه نیز در حد قابل قبول بودند و رواناب برآورد شده به مقادیر واقعی نزدیک است (شکل شماره ۹)، می‌توان اظهار داشت که شبکه‌ی طراحی شده دارای عملکرد بسیار خوبی است.

نتیجه‌گیری

شبکه‌های عصبی مصنوعی در سیستم‌های غیر خطی و نامعین که روابط بین اجزاء و پارامترهای سیستم به خوبی شناخته شده و توصیف پذیر نمی‌باشد، قادر به تحلیل و شبیه‌سازی پدیده‌ها می‌باشند. پدیده‌ی بارندگی و رواناب حاصله از آن در حوضه‌های آبریز و پیش‌بینی آن‌ها، از نوع سیستم‌های غیر خطی می‌باشند. در بررسی حاضر، جهت پیش‌بینی رواناب زیرحوضه‌ی جنوبی رودخانه‌ی قره‌سو، آمار دبی ایستگاه هیدرومتری انتهای حوضه در یک مدل شبکه‌ی عصبی مصنوعی مورد ارزیابی و بررسی قرار گرفت. نتایج حاصل از همبستگی نشان داد که بارش، بیشترین همبستگی و تبخیر، کمترین همبستگی را با میزان رواناب دارد. بررسی تأثیر استفاده از متغیرهای اقلیمی به ورودی مدل نشان داد که مدلی با ۵ متغیر شامل متوسط بارش ماهانه، متوسط رواناب ماهانه، متوسط رطوبت نسبی ماهانه، متوسط تبخیر ماهانه و متوسط دمای ماهانه، دقیق‌ترین مدل می‌باشد چرا که با خطای کمتر از ۵ درصد و همبستگی بالا، مقادیر

رواناب را برآورد کردند. آزمون تعداد نرون‌های مختلف در لایه‌ی پنهان نیز نشان داد که مدلی با ۴ نرون در لایه‌ی پنهان اول، ۳ نرون در لایه‌ی پنهان دوم، تابع محرک تانژانت سیگموئیدی در لایه‌ی پنهان اول و ۱۰ تکرار، بیشترین دقت را دارد. بنابراین، بهترین مدل شبکه‌ی عصبی مصنوعی در این بررسی، یک مدل پرسپترون ۳ لایه با ۴ نرون در لایه‌ی پنهان اول، ۴ نرون در لایه‌ی پنهان دوم، ۲ تابع محرک لایه‌ی پنهان و ۱ خروجی و الگوریتم آموزشی مارکوارت-لونبرگ می‌باشد. نتایج این بررسی نشان داد که مدل شبکه‌ی عصبی مصنوعی با توجه به خطای اندک و قابلیت مناسبی که در پیش‌بینی مقادیر دبی حوضه‌ی مورد مطالعه داشت، می‌تواند به عنوان مدل مناسبی در برآورد رواناب این زیرحوضه در سال‌های آینده به منظور انجام برنامه‌ریزی‌های محیطی قلمداد شود. از آنجایی که تغییرات دبی در حوضه‌های آبریز، علاوه بر متغیرهای مستقل مورد بررسی در این پژوهش، به سایر عناصر اقلیمی و فیزیوگرافیک حوضه نیز ارتباط زیادی دارد، لذا پیشنهاد می‌شود در این‌گونه مدل-بندی‌ها، نقش سایر عوامل مؤثر بر دبی رودخانه‌های حوضه‌های آبریز نیز مدنظر قرار گیرند.

منابع

- اکبرپور، مهرداد؛ رهنما، محمد باقر؛ بارانی، غلامعباس، (۱۳۸۲)، «مقایسه‌ی شبکه‌ی عصبی مصنوعی و مدل HEC-HMS در فرایند بارندگی - رواناب»، چهارمین کنفرانس هیدرولیک ایران، دانشگاه شیراز، صص ۸ - ۱.
- اکبرپور، مهرداد؛ شکرالهی، ا. (۱۳۸۳)، «به کارگیری شبکه‌های عصبی مصنوعی در تخمین جریانات رودخانه‌ای»، اولین کنگره ملی مهندسی عمران، دانشگاه صنعتی شریف، صص ۷ - ۱.

استفاده از شبکه عصبی مصنوعی»، ششمین کنفرانس هیدرولیک ایران، دانشگاه شهرکرد. کارآموز، محمد؛ رضانی، فرید؛ رضوی، سامان، (۱۳۸۵)، «پیش‌بینی بلند مدت بارش با استفاده از سیگنال‌های هواشناسی: کاربرد شبکه‌های عصبی مصنوعی»، هفتمین کنگره بین‌المللی مهندسی عمران، ص ۴۹-۵۵.

نصیری، علی؛ یمانی، مجتبی، (۱۳۸۸)، «تجزیه و تحلیل شبکه‌های عصبی مصنوعی ژئومورفولوژیکی در برآورد رواناب مستقیم (حوضه جاجرود، زیرحوضه امامه)»، نشریه پژوهش‌های جغرافیای طبیعی دانشگاه تهران، شماره ۶۸، صص ۴۴ - ۳۳. نورانی، وحید؛ صالحی، کامران، (۱۳۸۷)، «مدل‌سازی بارش - رواناب با استفاده از روش شبکه عصبی فازی و مقایسه آن با روش‌های شبکه عصبی فازی»، چهارمین کنگره ملی مهندسی عمران، دانشگاه تهران، صص ۸ - ۱.

نوری، مجتبی؛ میرحسینی، سید محمد؛ زینال زاده، کامران، رهنما، محمد باقر، (۱۳۸۶)، «الگوی جدید بارش - رواناب حوضه آبریز هلیل رود با استفاده از مدل هیبرید شبکه عصبی - موجکی»، نشریه زمین شناسی، جلد ۲، شماره ۲، صص ۴۷۲ - ۴۵۱. نیرومندی، حسینعلی؛ بزرگ‌نیا، ابولقاسم، (۱۳۷۲)، سری‌های زمانی، محل انتشار: دانشگاه پیام نور، تعداد صفحات، ۲۸۶.

Agarwal, A., Rali, R. K., Upadhyay, A. (2009). Forecasting of Runoff and Sediment Yield Using Artificial Neural Networks. Vol.1 No.5.

Akbarpour, M., Rahnema, M.B., Barani, GA. (2003). Comparison of artificial neural networks and HEC-HMS model in runoff-rainfall process. The 4th hydraulic conference, Iran, Shiraz University, pp. 1-8.

Akbarpour, M., Shokrollahi, A. (2004). The use of artificial neural networks in estimation of runoff. The 1th national congress on civil engineering, Sanati-Sharif University, pp. 1-7.

جهانگیر، علیرضا؛ رائینی، محمود؛ ضیاء احمدی، میرخالق، (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، صص ۸۴ - ۷۲. حسینی، سید اسعد، (۱۳۸۸)، برآورد و تحلیل دماهای حداکثر شهرستان اردبیل با استفاده از مدل تئوری شبکه‌های عصبی مصنوعی، پایان‌نامه کارشناسی ارشد، به راهنمایی برومند صلاحی، دانشگاه محقق اردبیلی.

خسروی، محمود؛ شکیبا، هانیه، (۱۳۸۹)، «پیش‌بینی بارش با استفاده از شبکه‌های عصبی مصنوعی به منظور مدیریت سیل: مورد منطقه ایرانشهر»، مجموعه مقالات چهارمین کنگره بین‌المللی جغرافیادانان جهان اسلام، صص ۲۱ - ۱.

رضایی، علی؛ مهدوی، محمد؛ لوکس، کارو؛ فیض‌نیا، سادات؛ مهدیان، محمدحسین، (۱۳۸۶)، «مدل-سازي منطقه‌ای دبی‌های اوج در زیر حوضه‌های آبخیز سد سفیدرود با استفاده از شبکه‌های عصبی مصنوعی»، مجله علوم و فنون کشاورزی و منابع طبیعی، سال ۱۱، ش ۱، صص ۳۹ - ۲۵. شادمان مطلق، عادل؛ ابراهیمی؛ حسین؛ رهنما؛

محمدباقر، (۱۳۸۶)، «پیش‌بینی جریان رودخانه سفیدرود با استفاده از شبکه عصبی مصنوعی (ANN)»، ششمین کنفرانس هیدرولیک ایران، دانشگاه شهرکرد.

شریفی، محمدباقر، (۱۳۸۴)، «کاربرد شبکه‌های عصبی در پیش‌بینی جریان رودخانه در حوزه معرف کارده»، طرح پژوهشی خاتمه یافته، کمیته تحقیقات شرکت سهامی آب منطقه‌ی خراسان.

قلخانی، حسین؛ یزداندوست، فرهاد؛ مشفق، محمدذاکر، (۱۳۸۶)، «پیش‌بینی رودخانه کارون با

- Minns, A.W., Hall, M.J. (1996). Artificial neural network as rainfall – runoff models. *Hydrological Science Journal*. 43(1), 399-417.
- Nasiri, A., Yamani, M. (2009). Analyze of geomorphologic artificial neural networks in estimation of direct runoff (Jajroud basin, Amame sub basin), *Physical geography research, Tehran University*, No. 68, pp. 33-44.
- Niroumand, H., Bozorgnia, A. (1993). Time series. University of Payam-nour, Pages. 286p.
- Noori, M., Mirhosseini, S.M., Zeynalzadeh, K., Rahnama, M, B. (2007). New pattern of Halil-Rood river basin's rainfall-runoff by using of hybrid neural wavelet network model. *Geology magazine*, Issue 2, No. 2. pp. 472-451.
- Nourani, V., Salehi, K. (2008). Modelling of runoff-rainfall by phasic neural networks and comparison with phasic neural networks method, *The fourth congress of reconstruction engineering*, Tehran University, pp. 1-8.
- Rezaei, A., Mahdavi, M., Caro, L., Feyznia, S., Mahdian, M. (2007). Regional Peak Flows Modeling of Sefid rood Dam's Sub Basins Using Artificial Neural Network, *J. of science and technology of agriculture and natural resources*. Issue 11, No. 1, pp.25-39.
- Sanchesz, E., Siencio, L.C. (1992). *Artificial Neural Networks*. First edition. New York.
- Sajikumar, N., Thandaveswara, B.S. (1999). A non-linear rainfall–runoff model using an artificial neural network. *Journal of Hydrology* 216, pp. 32–55.
- Shadman Motlagh, A., Ebrahimi, H., Rahnama, M.B. (2007). Prediction of runoff in Sefid-rood River by artificial neural networks (ANN), *The 6th conference on hydraulic*, Iran, University of Shahrekord.
- Sharifi, M.B. (2005). Application of neural networks in prediction of runoff in Kardeh watershed, *A plan research, The Khorasan's water company*.
- Smith, J., Eli, R.N. (1995). Neural network models of rainfall-runoff process. *Journal of water Resources Planning and Management*. 121(6), 499-508.
- Tokar, A.S., Markus, M. (2000). Precipitation-Runoff modeling using artificial neural networks and conceptual models. *J, Hydrol, Eng*, 5(2), 156-160.
- Akhtar, M. K., Corzo, G. A., van Andel, S. J., 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*, vol. 13, pp. 1607–1618.
- Dawson, W., Wilby, R. (1998). An artificial neural network approach to rainfall-runoff modeling. *Hydrological Sciences Journal*, Volume, Issue 1, pp. 47-66.
- Ghalkhani, H., Yazdandost, F., Moshfegh, M.Z. (2007). Prediction of runoff in Karoun River by artificial neural networks. *The 6th conference on hydraulic*, Iran, University of Shaherkord.
- Hosseini, S.A. (2009). Estimation and analysis of Maximum temperatures in Ardebil municipality by artificial neural networks. *M.A Thesis, University of Mohaghegh Ardabili*, Supervisor: Salehi, Bromand.
- Hsu, K., Gupta, H.V., Sorooshian, S. (1995). Artificial neural network modeling of the rainfall process. *Water Resour, Rest* 31(10), 2517-2330.
- Hung, N. Q., Babel, M. S., Weesakul, S., Tripathi, N. K. (2009). An artificial neural network model for rainfall forecasting in Bangkok, Thailand, *Hydrology and Earth System Sciences*, vol. 13, pp. 1413–1425.
- Jain, A.K., Mao, J., Mohiuddin, K.M. (1996). *Artificial neural networks: atutorial*. I *EEE*, 31-44.
- Jahangir, A., Raeini, M., Ziyae Ahmadi, M. (2008). Comparison of artificial neural networks (ANN) simulation of rainfall-runoff process with HEC-HMS model in Kardeh watershed. *Soil and water magazine (Agricultural science and industries)*, Vol.22, No. 2, pp.72-84.
- Jeong, D, I., Kim, Y, O, (2005). Rainfall-runoff models using artificial neural networks for ensemble stream flow prediction, *Hydrological. Processes*, vol. 19, pp. 3819–3835.
- Karamouz, M., Ramezani, F., Razavi, S. (2006). Long-term prediction of rainfall by aerology signals: Application of artificial neural networks, *the 7th international congress on civil engineering*, pp.49-55.
- Lorrai, M., Sechi, H.M. (1995). Neural nets for modeling rainfall–runoff transformation. *Watercourses management*. Vol.9, 299-313.

Simulation of Runoff- runoff presses in Southern sub-basin of Gharesou by artificial neural networks model (ANNs)

B. Salahi, T. Sarmasti

Received: November 22, 2011/ Accepted: August 12, 2012, 31-34 P

Extended Abstract

1- Introduction

Flooding behavior of rivers of Iran, lack of water and necessity of surface water controlling detect the importance of river's behavior simulating and modeling. In this way we can have a long term plan for proper and reasonable operating from potential of rivers. Rain –Runoff water simulation is main step for managing of basins. This process is one of the complicated nonlinear phenomena in water engineering. Most of calculation and designing in water engineering need a proper evaluation of quantity and quality of running water that comes from a determined rain. There are common and various methods for evaluating of basin's runoff. Nowadays, using of Artificial Neural Networks (ANN) in various branch of hydrology engineering is acceptance because this method is capable with good accuracy simulate and predict the

nonlinear functions. This research tries to predict runoff in southern sub-basin of Gharasoo river in Ardabil province by Artificial Neural Networks (ANNs). This research based on 5 climatic parameters (2007-2010) that affects runoff. These data is obtained from Hydrometric station that located in the end of this basin.

2- Methodology

Artificial Neural Networks (ANNs) is a simple model from human's brain that with a special mathematic structure in each system is able to clarify the process and nonlinear relation between inputs and outputs. These networks during teaching process are taught and are used for feature predicting. For best designing of ANN model in this research to predict runoff in basin under study, first correlation of humidity average, rain average, monthly temperature average and evaporation average with the flow of basin is obtained. Then effective parameter with more correlation for multi-layer perceptron network is selected. Data matrix with following input and output is made. Inputs: monthly rain average (mm), monthly rain average (million m3), monthly relative humidity average

Author(s)

B. Salahi (✉)

Assistant Professor, Department of Physical Geography, University of Mohaghegh Ardabili
E-mail: bromand416@yahoo.com

T. Sarmasti

M. A. student in Physical Geography, University of Mohaghegh Ardabili

(percent) and monthly temperature average (c) Outputs: Predicting monthly runoff in next year's. From existing 39 year statistical period, 90 percent of them is used for net teaching and other 10 percent for test step is used. After selecting input and output data of net and defining net structure (stimulator function, number of neurons, hidden layers, number of cycle, amount of educational parameters) Net teaching by program teaching algorithm, first with one hidden neuron is began and with increasing that up to all neuron number is continuing. After each teaching, net is tested via regression analyzing and correlation coefficient between input and output data (in teaching step) and error percent (in test step). Basis of neuron numbers and cycles was maximum correlation and errors less than 5 percent. By detected number of hidden optimum neurons and cycles, to reach an optimum network several times the value of teaching parameters and the number of hidden layers is changing. For this reason network is designed in a way that by entering last years information (rain, relative humidity, temperature, evaporation, runoff) is able to predict next year's flow with error less than 5 percent. After designing of 12 various networks for predicting of basin flow, various structure of perceptron is selected to reach an optimum network. For evaluating of ANN function, amount of R², RMSE, MAE and R are used

3- Discussion

The result of this research show that in all months there is a high correlation (more than 93%) between runoff and average of rain, humidity, temperature, evaporation and monthly flow. Minimum correlation coefficient in teaching step belongs to April (93%) and Maximum belongs to Jun (98%).

For this research, Marcoart-Levenberg algorithm is the best algorithm because of more correlation in Teaching step and lower error in test step. For defining proper number of hidden neurons, maximum number of neurons for all 12 networks is 10 neurons. In the selected network, most of neuron number belongs to January with 10 neuron in the first- layer and 2 neuron in the second hidden layer and minimum of them is related to October with 3 neuron in the first hidden layer. For defining hidden layer number, some of the networks (except February, March, May, July, October and December) with one hidden layer have a good result and some other with 2 hidden layers have a good result. The primary number of teaching cycles of network for each month in Marcoart-Lonberg algorithm first with 10 cycle for each neuron in hidden layer and with initial error value ($=0.005$) starts and maximum up to 700 continuing and in the end network with minimum cycle (10 cycle) in July and maximum cycle (700 cycle) in December reached to its goal.

4- Result

The result of this research show that one model with 5 parameter including (monthly rain average, monthly runoff average, monthly relative humidity average, monthly evaporation average and monthly temperature average) is the best ANN for predicting the flow of river because with error less than 5 percent and high correlation can predict the runoff level. Number examination of various neuron in hidden layers show that one model with 4 neuron in the first hidden layer and 3 neuron in second hidden layer sigmoid tangent stimulator function in the first hidden layer and 10 cycle, has best accuracy. The best ANN model in this research is one perceptron model

with 3 layers and 4 neuron in the first hidden layer and 4 neuron in the second hidden layer a 2 hidden layer stimulator function an one output and Marcoart-Lonberg teaching algorithm. The result of this research show that ANN model with low error and proper capability for predicting of basin rivers flow is a good model for evaluating of this parameter in future.

Keywords: Artificial Neural Networks, Prediction, Runoff, Simulation, Southern sub-basin of Gharesou

References

- Agarwal, A., Rall, R. K., Upadhyay, A. (2009). Forecasting of Runoff and Sediment Yield Using Artificial Neural Networks. Vol.1 No.5.
- Akbarpour, M., Rahnama, M.B., Barani, GA. (2003). Comparison of artificial neural networks and HEC-HMS model in runoff-rainfall process. The 4th hydraulic conference, Iran, Shiraz University, pp. 1-8.
- Akbarpour, M., Shokrollahi, A. (2004). The use of artificial neural networks in estimation of runoff. The 1th national congress on civil engineering, Sanati-Sharif University, pp. 1-7.
- Akhtar, M. K., Corzo, G. A., van Andel, S. J., 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, vol. 13, pp. 1607–1618.
- Dawson, W., Wilby, R. (1998). An artificial neural network approach to rainfall-runoff modeling. Hydrological Sciences Journal, Volume, Issue 1, pp. 47-66.
- Ghalkhani, H., Yazdandost, F., Moshfegh, M.Z. (2007). Prediction of runoff in Karoun River by artificial neural networks. The 6th conference on hydraulic, Iran, University of Shaherkord.
- Hosseini, S.A. (2009). Estimation and analysis of Maximum temperatures in Ardebil municipality by artificial neural networks. M.A Thesis, University of Mohaghegh Ardabili, Supervisor: Salahi, Bromand.
- Hsu, K., Gupta, H.V., Sorooshian, S. (1995). Artificial neural network modeling of the rainfall process. Water Resour, Rest 31(10), 2517-2330.
- Hung, N. Q., Babel, M. S., Weesakul, S., Tripathi, N. K. (2009). An artificial neural network model for rainfall forecasting in Bangkok, Thailand, Hydrology and Earth System Sciences, vol. 13, pp. 1413–1425.
- Jain, A.K., Mao, J., Mohiuddin, K.M. (1996). Artificial neural networks: atutorial. I IEEE, 31-44.
- Jahangir, A., Raeini, M., Ziyae Ahmadi, M. (2008). Comparison of artificial neural networks (ANN) simulation of rainfall-runoff process with HEC-HMS model in Kardeh watershed. Soil and water magazine (Agricultural science and industries), Vol.22, No. 2, pp.72-84.
- Jeong, D, I., Kim, Y, O, (2005). Rainfall-runoff models using artificial neural networks for ensemble stream flow prediction, Hydrological. Processes, vol. 19, pp. 3819–3835.
- Karamouz, M., Ramezani, F., Razavi, S. (2006). Long-term prediction of rainfall by aerology signals: Application of artificial neural

- networks, the 7th international congress on civil engineering, pp.49-55.
- Lorrai, M., Sechi, H.M. (1995). Neural nets for modeling rainfall-runoff transformation. *Watercourses management*. Vol.9, 299-313.
- Minns, A.W., Hall, M.J. (1996). Artificial neural network as rainfall – runoff models. *Hydrological Science Journal*. 43(1), 399-417.
- Nasiri, A., Yamani, M. (2009). Analyze of geomorphologic artificial neural networks in estimation of direct runoff (Jajroud basin, Amame sub basin), *Physical geography research*, Tehran University, No. 68, pp. 33-44.
- Niroumand, H., Bozorgnia, A. (1993). Time series. University of Payam-nour, Pages. 286p.
- Noori, M., Mirhosseini, S.M., Zeynalzadeh, K., Rahnama, M, B. (2007). New pattern of Halil-Rood river basin's rainfall-runoff by using of hybrid neural wavelet network model. *Geology magazine*, Issue 2, No. 2. pp. 472-451.
- Nourani, V., Salehi, K. (2008). Modelling of runoff-rainfall by phasic neural networks and comparison with phasic neural networks method, The fourth congress of reconstruction engineering, Tehran University, pp. 1-8.
- Rezaei, A., Mahdavi, M., Caro, L., Feyznia, S., Mahdian, M. (2007). Regional Peak Flows Modeling of Sefid rood Dam's Sub Basins Using Artificial Neural Network, *J. of science and technology of agriculture and natural resources*. Issue 11, No. 1, pp.25-39.
- Sanchesz, E., Sienencio, L.C. (1992). *Artificial Neural Networks*. First edition. New York.
- Sajikumar, N., Thandaveswara, B.S. (1999). A non-linear rainfall-runoff model using an artificial neural network. *Journal of Hydrology* 216, pp. 32–55.
- Shadman Motlagh, A., Ebrahimi, H., Rahnama, M.B. (2007). Prediction of runoff in Sefid-rood River by artificial neural networks (ANN), The 6th conference on hydraulic, Iran, University of Shahrekord.
- Sharifi, M.B. (2005). Application of neural networks in prediction of runoff in Kardeh watershed, A plan research, The Khorasan's water company.
- Smith, J., Eli, R.N. (1995). Neural network models of rainfall-runoff process. *Journal of water Resources Planning and Management*. 121(6), 499-508.
- Tokar, A.S., Markus, M. (2000). Precipitation-Runoff modeling using artificial neural networks and conceptual models. *J, Hydrol, Eng*, 5(2), 156-160.
- Wu, C.L., Chau, K.W. (2011). Rainfall-runoff modeling using artificial neural network coupled with singular spectrum analysis, *Journal of Hydrology*, vol, 399, pp. 394–409