مرتع و آبخیزداری، مجله منابع طبیعی ایران
دوره ۷۰، شماره ۴، زمستان ۱۳۹۶
ص ۱۰۶۶-۱۰۴۵

تاریخ دریافت: ۱۳۹۴/۰۸/۱۹
تاریخ تصویب: ۱۳۹۵/۰۷/۱۳

تأثیر ساختارها و ورودی‌های مختلف شبکه‌های عصبی مصنوعی در تخمین دبی روزانهٔ حوزهٔ آبخیز معرّف امامه

❖ **محبوبه معتمدنیا*؛** دکتری علوم و مهندسی آبخیزداری
❖ **احمد نوحه‌گر؛** استاد گروه آموزش، برنامه‌ریزی و مدیریت محیط زیست، دانشکدهٔ محیط زیست، دانشگاه تهران، کرج
❖ **آرش ملکیان؛** دانشیار گروه احیا مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج
❖ **مریم صابری اناری؛** مربی دانشگاه فنی و حرفه‌ای، یزد

چکیده

یکی از مهم‌ترین محاسبات هیدرولوژیک در یک اکوسیستم، تعیین ارتباط بین بارش و رواناب است. به طوری که بررسی فرایندهای به‌وقوع پیوسته در آن و برآورد خروجی‌های مهّم حوزه از قبیل سیلاب و رسوب از مهّم‌ترین هدف‌های یک پروژهٔ آبخیزداری تلقی می‌شود. به دلیل ویژگی‌های متغیر زمانی و مکانی وقایع در چرخهٔ آبی، روابط غیر خطی و عدم قطعیت، هیچ کدام یک از مدل‌های آماری و مفهومی نتوانسته به‌عنوان یک مدل برتر و توانا کارگشا باشد. اما امروزه استفاده از شبکه‌های غیرخطی به‌عنوان سامانه‌های هوشمند در پیش‌بینی چنین پدیده‌های پیچیده و حل بسیاری از مشکلات اکوهیدرولوژی می‌تواند مفید و مؤثر باشد. به این منظور از داده‌های روزانهٔ بارندگی، دما، تبخیر و تعرق، رطوبت نسبی و همچنین دبی در مقیاس روزانه و در دورهٔ زمانی مشترک ۴۲ ساله و بررسی ۶۲ ساختار پیشنهادی مختلف در حوزهٔ آبخیز معرّف امامه استفاده شد. در این راستا و به منظور مقایسه از شبکه‌های عصبی پرسپترون چندلایه و تابع پایهٔ شعاعی استفاده گردید. نتایج نشان داد که از بین بیش از ۶۰۰۰ مدل موجود در تخمین دبی رودخانه، مدل ۵۴ با ساختار ۱-۸-۹-۸ و ورودی‌های دما، رطوبت نسبی، بارندگی و تأخیر بارندگی و دبی تا دو روز بوده و با روش پرسپترون چندلایه دارای بهترین عملکرد بوده است. میزان خطای مدل مذکور برابر با ۰/۰۳، ۰/۱۸ و ۰/۰۴ در مرحلهٔ مدلسازی و آموزش و ۰/۰۲، ۰/۱۴ و ۰/۰۲ در مرحلهٔ آزمایش برای معیارهای ارزیابی به ترتیب شامل میانگین مربعات خطا (MSE)، مجذور میانگین مربعات خطا (RMSE)، میانگین مطلق خطا (MAE) بوده است.

کلید واژگان: الگوریتم پس‌انتشار خطا، شبکهٔ عصبی مصنوعی، حوزهٔ آبخیز معرّف امامه، رابطهٔ بارش- رواناب

* نویسنده مسئول: شماره تماس: ۰۹۸۹۱۳۴۵۰۱۷۹۷+
Email: mmoatamednia@yahoo.com

۱. مقدمه

آب یکی از عوامل مهم در توسعهٔ پایدار هر منطقه می‌باشد. با توجه به منابع آبی و شرایط اقلیمی، کمی و کیفیتی آن به‌خصوص محدودیت آب شیرین قابل استحصال در راستای توسعهٔ اقتصادی و زیست محیطی اکثر نقاط ایران کافی نمی‌باشد [۳۵]. از طرفی تهیّه و اجرای طرح‌های مختلف نظیر طرح‌های توسعه‌ای، طراحی سازه‌های هیدرولوژیک و هیدرولیک و برنامه‌ریزی‌های مربوط به حفاظت آب و خاک نیاز به دانستن مجموعه‌ای از اطّلاعات مربوط به بارندگی و رواناب دارد [۲۷]. لذا پیش‌بینی هر چه دقیق‌تر دبی جریان و تغییرات آن در طول رودخانه از ارکان اساسی مدیریت منابع و برنامه‌ریزی‌ها و سیاست‌گذاری‌ها است به طوری‌که متخصصان همواره برای تخمین صحیح دبی رودخانه و تدقیق روش‌های موجود تلاش می‌نمایند [۸، ۱۶]. برای آن‌که بتوان یک مدل مناسب برای پیش‌بینی میزان دبی جریان آب رودخانه تهیه نمود، لازم است تا حد امکان تمامی عوامل مؤثر اندازه‌گیری و در مدل دخالت داده شود. در بیشتر مواقع اندازه‌گیری غلط، ثبت اشتباه داده‌ها، کمبود وقت و یا منابع مالی جهت احداث ایستگاه‌های هیدرومتری و نهایتاً کافی نبودن طول سری داده‌ها باعث می‌شود که پژوهشگر قادر به تهیهٔ مدل با دقت قابل‌قبول نباشد. بدیهی است که مدل‌های به کار رفته به‌خصوص در فرایند واسنجی، سازگاری و پذیرش غیرخطی بودن فرآیندها دارای ضعف‌ها و مشکلات زیادی هستند [۱۴]. لذا در سال‌های اخیر رویکرد به مدل‌های هوشمند به‌عنوان ابزاری قوی و توانمند در فرآیند هیدرولوژی و عدم نیاز به آگاهی روابط پیچیدهٔ ریاضی بین ورودی و خروجی و نیز توصیف صریح و کمّی از خواص و شرایط فیزیکی نسبت به مدل‌های فیزیکی و مفهومی افزایش یافته و قادرند فرایندهای غیر خطی همچون جریان رودخانه را به‌خوبی برآورد کنند [۵، ۶، ۲۲]. یکی از روش‌های موجود در بین مدل‌های هوشمند شبکهٔ عصبی مصنوعی[1] بوده که با یک ساختار ریاضی قادر به شناسایی و تشخیص روابط پیچیدهٔ غیرخطی بین ورودی و خروجی می‌باشد. شبکه‌های عصبی مصنوعی، کاربردهای موفقیت‌آمیزی در زمینه‌های گوناگون از جمله مطالعات منابع آب به‌خصوص در زمینه‌های هیدرولوژیک داشته‌اند به طوری که پژوهش‌گران مختلف در اقصی نقاط مختلف [۷، ۱۶، ۲۰، ۲۴، ۲۹، ۳۴، ۳۶، ۴۱، ۴۵] از این روش استفاده و نشان دادند که شبکهٔ عصبی دارای نتایج رضایت‌بخشی است. شبکهٔ عصبی مصنوعی با الگوبرداری از ویژگی‌های پردازش مغز انسان به دنبال ارائهٔ روشی جدید برای مدل‌سازی پدیده‌های فیزیکی است. ظهور شبکه‌های عصبی مصنوعی مربوط به دههٔ ۴۰ میلادی بود زمانی که مک‌کلاچ روانشناس معروف و پیتز ریاضیدان (۱۹۴۳) آن را پایه‌گذاری کردند. اما نخستین کاربرد عملی شبکه‌های عصبی مصنوعی مربوط به روزنبلات (۱۹۸۵) با معرّفی شبکه‌های چندلایهٔ پرسپترون انجام شد. اگرچه ایدهٔ شبکهٔ عصبی مک‌کلاچ و پیتز بیشتر از ۶۰ سال پیش ارائه شد ولی با توسعهٔ آن در سال ۱۹۸۲ با کار هاپفیلد در معرّفی شبکه‌های حافظهٔ انجمنی، تولدی دوباره یافت و توسعهٔ زیاد، زمانی اتفاق افتادکه راملهارت و همکاران (۱۹۸۶) الگوریتم پس‌انتشار خطا را به‌عنوان پایهٔ تئوریکی قوی برای شبکهٔ عصبی از طرفی خصوصیّاتی از قبیل سرعت پردازش بالا به دلیل ساختار موازی، استفاده از مفهوم یادگیری[2]، ایجاد نگاشت غیرخطی، ذخیرهٔ اطّلاعات در یک حافظهٔ گسترده که سبب عدم اختلال در عملکرد شبکه در صورت بروز اختلال در بخشی از ارتباطات، توانایی تعمیم‌دهی[3]، شناسایی و دسته‌بندی الگوها، ایجاد حافظهٔ انجمنی، بهینه‌سازی و قابلیّت خودسازماندهی و بسیاری از ویژگی‌های دیگر از خصوصیّات بارز شبکه‌های عصبی مصنوعی است [۱۵، ۳۶]. به طور معمول یک شبکهٔ عصبی مصنوعی از سه لایهٔ ورودی، پنهان و خروجی تشکیل شده است. هر کدام از این لایه‌ها از تعدادی نورون یا گره به‌عنوان واحدهای پردازنده که با اتصالاتی وزن‌دار به یکدیگر تشکیل شده‌اند. نحوهٔ اتصال نورون‌ها و چگونگی تنظیم پارامترهای

[1] Artificial Neuron Network (ANN)
[2] Learninig
[3] Generalization

آن‌ها از طریق قانون یادگیری که در واقع یک الگوریتم ریاضی پیچیده است انجام می‌گردد. این شبکه با داده‌های موجود طی فرایند یادگیری، آموزش دیده و جهت پیش‌بینی در آینده مورد استفاده قرار می‌گیرند. طی فرآیند آموزش این وزن‌ها و مقادیر ثابتی که با آن‌ها جمع می‌شود و اصطلاحاً اریب[1] نامیده می‌شود، به طور پی در پی تغییر می‌کند تا این‌که خطا به کم‌ترین مقدار خود برسد. آن‌چه که در امر آموزش شبکه مهم است این بوده که به ازای یک بردار ورودی آموزش ندیده شده شبکه قادر باشد خروجی مرتبط با آن را ارائه نماید. به طورکلی هدف از آموزش شبکهٔ عصبی، قابلیت درون‌یابی آن برای کلیهٔ سری‌های آموزشی است. تاکنون روش‌های متعددی جهت آموزش شبکه‌ها ارائه شده است. برتری هر روش نسبت به روش دیگر را می‌توان در دقت و سرعت یادگیری جستجو نمود [۱۰]. برای انتقال خروجی‌های هر لایه به لایه‌های بعدی از توابع محرک[2] استفاده می‌شود. یکی از پرکاربردترین روش‌های مورد استفاده شبکه عصبی پرسپترون چندلایه[3] می‌باشد که در بسیاری از مسائل پیچیده ریاضی که به حل معادلات غیرخطی می‌انجامد به سادگی مورد استفاده قرار گیرد و در عین حال قادر است هر نوع فضایی را تفکیک کند و در زمینهٔ هیدرولوژی و منابع آبی بسیار کاربردی است [۹، ۲۶، ۴۰، ۴۳] متداول‌ترین شیوهٔ آموزش این نوع شبکه‌ها از نوع پس‌انتشار خطا[4] و از نوع آموزش با سرپرست می‌باشد [۱۱]. همچنین در حل مسائل هیدرولوژی، با توجه به تغییرات شدید داده‌ها، اغتشاش حاکم بر داده‌ها استفاده از شبکه‌های پس‌انتشار خطا به دلیل قابلیت انعطاف‌پذیری آن‌ها با دو لایهٔ مخفی و توابع محرک سیگموئیدی توصیه شده است [۱۳، ۳۲]. از دیگر از روش‌های موجود در این تحقیق تابع پایهٔ شعاعی[5] است. این نوع شبکهٔ عصبی برای اولین بار توسط Broomhead و Lowe در سال ۱۹۸۸ معرّفی شد که همانند روش پرسپترون چندلایه دارای ساختار رو به جلو بوده و از توابع محرک گوسی در لایهٔ پنهان و خطی در لایهٔ خروجی استفاده می‌کند [۹، ۱۱]. تفاوت عمدهٔ این نوع شبکه‌ها با شبکه‌های MLP در این است که دارای یک لایهٔ پنهان بوده و توابع محرک نورون‌ها به صورت توابع شعاعی همراه با مرکز و عرض خاصی می‌باشند. در این نوع شبکه‌ها فاصله هر الگو با بردار مرکز هر نورون در لایهٔ پنهان به‌عنوان ورودی تابع تحریک شعاعی محاسبه می‌شود. معمولاً آموزش شبکهٔ RBF به دو قسمت تقسیم می‌شود، بخش اول اغلب یادگیری از نوع بدون راهنما است که با استفاده از روش‌های خوشه‌بندی، پارامترهای توابع پایه (مراکز و عرض‌ها) و با استفاده از اطلاعات ورودی تعیین گشته و مرحلهٔ دوم از نوع یادگیری با راهنما است و وزن‌های بین لایهٔ میانی و لایهٔ خروجی با استفاده از روش‌های کاهش شیب و رگرسیون خطی تعیین می‌شود. در این نوع شبکه به دلیل یک لایهٔ میانی سرعت یادگیری بالاتر و ساده‌تر است [۱۰، ۹، ۳۸]. در تحقیقی با استفاده از شبکهٔ عصبی پرسپترون چندلایه و مدل درختی M_5 اقدام به پیش‌بینی سیل در بالادست رودخانهٔ Huai در کشور چین کردند. از نتایج آن‌ها مشخص شد که سرعت آموزش در مدل درختی M_5 بسیار بالاتر و دقّت برآورد آن بسیار نزدیک به شبکهٔ عصبی مصنوعی بوده است. علاوه بر این با ترکیب شبکهٔ عصبی با مدل درختی برآورد سیلاب با دقّت بالاتری انجام شده است [۳۷]. همچنین در مقاله‌ای دیگر جهت شبیه‌سازی بار معلق با استفاده از شبکهٔ عصبی مصنوعی MLP و با استفاده از الگوریتم آموزش پس‌انتشار خطا و RBF استفاده کردند، سپس برای تخمین دقّت روش‌های مذکور از پارامترهای آماری استفاده کردند. نتایج آنان نشان داد که روش پرسپترون چندلایه و با استفاده از الگوریتم پس‌انتشار خطا بار رسوبی رودخانه را با دقّت بهتر و خطای کمتری برآورد می‌کنند [۲۹]. به منظور مقایسه و کارایی روش نامبرده با دیگر روش‌ها از جمله روش‌های آماری در رودخانهٔ جاوپن تایوان و همچنین رودخانه‌ای در نواحی شمال‌غربی چین از رگرسیون خطی و چندمتغیره و شبکهٔ عصبی با روش MLP

[1] Bias
[2] Activation Function
[3] Multi layer perceptoron (MLP)
[4] Error Back Propagation (EBP)
[5] Radial Basis Function (RBF)

و با الگوریتم پس‌انتشار خطا و RBF استفاده شد که با توجه به پارامترهای آماری همچون مجموع میانگین مربعات خطا، خطای نسبی نشان از برتری این روش‌ها بر دیگر روش‌های مذکور داشته است [۷، ۱۶]. همچنین در ایران طی مطالعه‌ای به منظور پیش‌بینی جریان ورودی به مخزن سد دز و با استفاده از روش‌های ARIMA و ARMA، ۴ و ۶ پارامتره به منظور افزایش دقّت پیش‌بینی پارامترها و مقایسهٔ آن‌ها با روش شبکهٔ عصبی مصنوعی دینامیکی آماری و با تابع محرک سیگموئید و شعاعی پرداخته شد، بدین منظور از داده‌های دبی ماهانه در دورهٔ زمانی ۱۹۶۰ تا ۲۰۰۷ استفاده و ۴۲ سال برای آموزش و ۵ سال آن برای پیش‌بینی استفاده کردند. نتایج نشان داد که شبکهٔ عصبی با تابع محرک سیگموئید و ۱۷ نورون در لایهٔ پنهان به‌عنوان بهترین مدل برای پیش‌بینی جریان ورودی به مخزن سد دز شناخته شد [۴۲]. به منظور تخمین و برآورد دبی در دو رودخانهٔ مارک[1] و دندر[2] و در بلژیک با استفاده از چندین روش از جمله الگوریتم شاخه‌درختی M_5، شبکهٔ عصبی مصنوعی و دیگر روش‌های سنتی مورد استفاده در منحنی دبی- اشل نموده‌اند. نتایج نشان داد که در بین روش‌های موجود شبکهٔ عصبی دارای دقت نسبتاً خوبی بوده است اما هنگامی که مقدار کمی از داده‌ها برای فرایند آموزش مورد استفاده قرار می‌گیرند شبکهٔ عصبی قادر به تخمین درستی از آن‌ها نبوده و دچار تخمین بیش از اندازهٔ[3] داده‌ها می‌شود. همچنین نتایج نشان داد که مدل شاخه‌درختی M_5 نسبت به شبکهٔ عصبی مصنوعی دارای نتایج دقیق‌تر بوده و تفسیر نتایج آن راحت‌تر می‌باشد[۴۴]. در پژوهشی دیگر در راستای پیش‌بینی روزانهٔ جریان رودخانه از ۷۰ و ۳۰ درصد داده‌ها به ترتیب برای آموزش و آزمایش و با استفاده از شبکه‌های عصبی مصنوعی در دورهٔ زمانی ۱۹۵۱ تا ۲۰۰۶ (پنجاه و پنج سال) استفاده شد. با توجه به آماره‌های ارزیابی ضمن برتری شبکهٔ عصبی پرسپترون چندلایه بر تابع پایه شعاعی نشان داد که بارندگی تا دو روز قبل و دبی تا یک روز قبل می‌توانند بر رواناب تأثیر با مقدار عددی مجذور میانگین مربعات خطا برابر با ۰/۸۰ و ۰/۷۵ برای داده‌های آموزش و آزمایش به دست آمد [۲۸]. همچنین در ۲۹ حوزهٔ آبخیز نزدیک و اطراف آتلانتا[4] در جنوب شرقی ایالات متحده از مدل شبکهٔ عصبی مصنوعی و SWAT[5] به منظور پیش‌بینی روزانهٔ جریان رودخانه استفاده شد. در ابتدا به منظور پیش‌بینی جریان از مدل SWAT استفاده کردند و سپس جریان پایه و رگبار شبیه‌سازی شده به‌عنوان ورودی مدل شبکهٔ عصبی مصنوعی در نظر گرفته شد. نتایج نشان داد که از بین ۲۹ حوزهٔ آبخیز مورد برررسی ۶۲ و ۸۲ درصد از آن‌ها دارای معیار ناش ساتکلیف بالای ۰/۵۰ در طول فصول سرد و گرم می‌باشند. با توجه به نتایج مدل‌های به دست آمده و خطاهای آنها هم شبکهٔ عصبی مصنوعی و هم SWAT دارای عملکرد خوبی در راستای پیش‌بینی جریان رودخانه دارای نتایج قابل قبولی بودند [۳۰]. با توجه به این‌که شبکه‌های عصبی پرسپترون چندلایه و تابع پایه شعاعی به شناخت الگو و تابع حاکم بر مسائل غیرخطی قادر بوده و از جمله کاربرد بیشتری در مسائل منابع آب و هیدرولوژی دارند [۱۰، ۱۸] لذا در این تحقیق از روش‌های شبکه‌های عصبی نامبرده به منظور برآورد و پیش‌بینی دبی رودخانهٔ حوزهٔ آبخیز معرّف امامه به واسطه موقعیّت جغرافیایی و داده‌های مناسب (به‌عنوان نمایندهٔ مناطق جنوبی رشته کوه البرز و داده‌های روزانهٔ ۴۲ ساله و روزانه) استفاده شده است.

۲. روش‌شناسی تحقیق

۱.۲. منطقهٔ مورد مطالعه

حوزهٔ آبخیز معرّف امامه در استان تهران، اوّلین آبخیز تجهیز شدهٔ وزارت نیرو به منظور اندازه‌گیری پارامترهای جوی و رواناب در سال ۱۳۴۹ در کشور می‌باشد. حوزهٔ آبخیز مذکور با متوسط بارندگی ۷۵۶/۶۰ میلی‌متر در بین

[1] Marke
[2] Dender
[3] Overtraining
[4] Atlanta
[5] Soil and Water Assessment Tool (SAWT)

عرض‌های جغرافیایی ″۰۰′۵۱ °۳۵ تا ″۰۰′۵۷ °۳۵ شمالی و طول‌های جغرافیایی ″۰۰′۳۲ °۵۱ تا ″۰۰′۳۹ °۵۱ شرقی واقع شده است. حوزهٔ آبخیز رودخانهٔ امامه، یکی از سرشاخه‌های رودخانهٔ جاجرود می‌باشد که از ارتفاعات جنوبی درهٔ لار سرچشمه گرفته و در جهت شمال شرقی به جنوب غربی از میان حوزه عبور می‌کند و پس از عبور از روستاهای امامه و کلوکان در پایین‌دست روستای کلوکان (پس از عبور از ایستگاه آب‌سنجی کمرخانی) به شاخهٔ اصلی رودخانهٔ جاجرود می‌پیوندد [۳۱]. متوسط آبدهی ثبت شده در این ایستگاه در طول دورهٔ آماری ۱۳۵۰-۱۳۴۹ تا ۱۳۹۱-۱۳۹۰ (۴۲سال دادهٔ روزانه) برابر با ۰/۵۹ مترمکعب بر ثانیه می‌باشد. لازم به ذکر است که به منظور انجام این تحقیق از داده‌های ایستگاه هواشناسی امامه در مرکز ثقل حوزه و ایستگاه آب‌سنجی کمرخانی در خروجی حوزه به دلیل موقعیّت ایستگاه‌ها و همچنین وجود داده‌های کامل استفاده شد. برخی از خصوصیّات فیزیوگرافی این حوزه و به همراه موقعیّت ایستگاه‌های هواشناسی و آب‌سنجی آن به ترتیب در جدول ۱ و شکل ۱ آورده شده است.

۲.۲. روش تحقیق

به منظور انجام تحقیق حاضر داده‌های آب‌سنجی و هواشناسی حوزهٔ آبخیز معرّف امامه به دلیل طولانی، مستند و مطمئن بودن از کیفیت و کمیت آمار و اطلاعات آن‌ها به دلیل معرّف و مرجع بودن آن در نظر گرفته شد. داده‌های مورد نیاز شامل دبی، بارش، دما، تبخیر و رطوبت نسبی در مقیاس روزانه در حوزهٔ آبخیز معرّف امامه تهیّه گردید.

۱.۲.۲. پیش‌پردازش اطلاعات

۱.۱.۲.۲. بررسی کیفیت و کمیت داده‌ها

بعد از جمع‌آوری داده‌های مورد نیاز شرایط داده‌ها از حیث سه شرط مرتبط بودن[1]، کفایت[2] و درستی[3] مورد بررسی قرار گرفت [۲۳]. در رابطه با کفایت داده‌ها از آزمون هرست استفاده شد. ضریب هرست برابر با ۰/۵ برای یک سری نشان‌دهنده، یک سری مستقل نرمال می‌باشد. هر چه این ضریب از ۰/۵ بیشتر باشد نشان‌دهندهٔ این مطلب است که حافظهٔ بلند مدت در سری زمانی بیشتر و احتیاج به تطویل اطّلاعات سری نمی‌باشد [۱۹]. این آزمون با توجه به فرمول ارائه شده توسط هرست برای حوزهٔ آبخیز معرّف امامه و برای تمامی متغیرهای دبی، باران، دما، رطوبت نسبی و تبخیر انجام شد که نتایج آن در جدول ۲ آورده شده است.

جدول ۱. برخی از خصوصیّات فیزیوگرافی حوزهٔ آبخیز معرّف امامه [۳۲۱]

ویژگی	مقدار
مساحت (km^2)	۳۷/۲۰
محیط (km)	۳۱/۰۰
ارتفاع متوسط حوزه (m)	۲۶۵۰
شیب متوسط سطح حوزه (٪)	۹/۲
طول آبراههٔ اصلی (km)	۱۳
ضریب فشردگی یا گراولیوس	۱/۴۲

[1] Relevance
[2] Adequency
[3] Accuracy

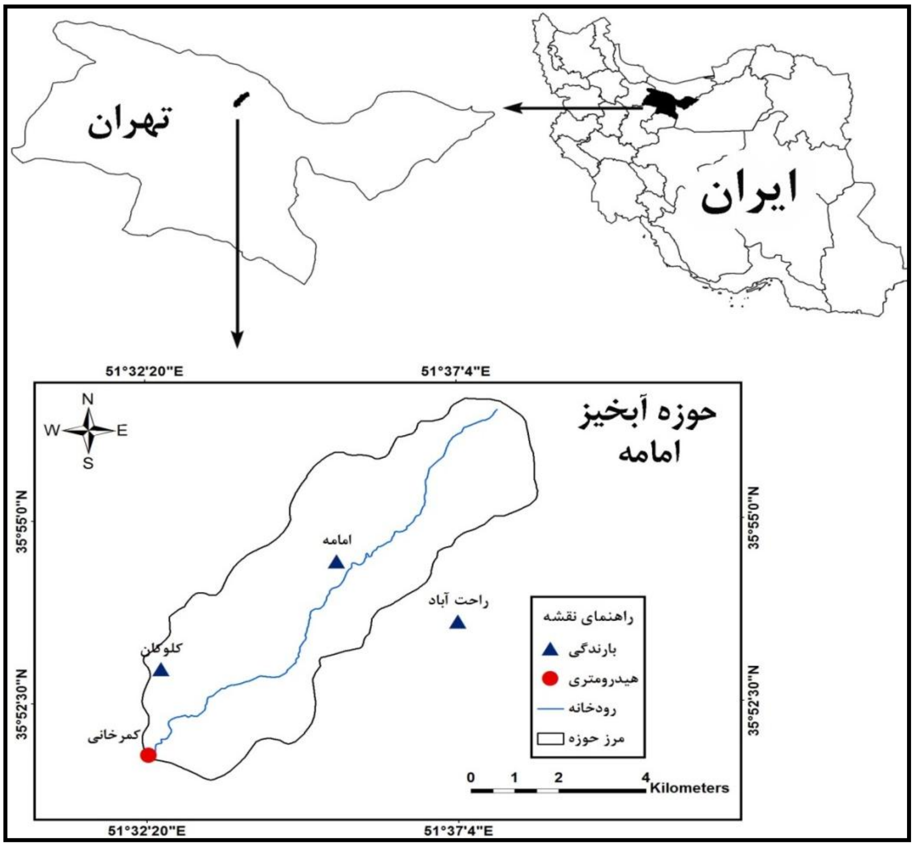

شکل ۱. موقعیّت حوزهٔ معرّف امامه و ایستگاه‌های هواشناسی و آب‌سنجی آن

جدول ۲. نتایج آزمون کفایت طول داده‌ها در حوزهٔ آبخیز امامه

متغیرها	دبی (Q)	بارندگی (P)	دما (T)	تبخیر و تعرق (ET)	رطوبت نسبی (Rh)
مقدار ضریب هرست	۰/۶۷	۰/۶۳	۰/۷۴	۰/۸۱	۰/۸۳

۲.۱.۲.۲. بازسازی آمار ناقص ایستگاه‌ها

به منظور بازسازی آمار ناقص از ضریب همبستگی[1] در نرم‌افزار SPSS21 و با توجه به همبستگی بین ایستگاه‌ها استفاده گردید [۳، ۲۳]. در نهایت با توجه به موارد ذکر شده دورهٔ مشترک آماری ۱۳۵۰-۱۳۴۹ تا ۱۳۹۱-۱۳۹۰ (۴۲ سال دادهٔ روزانه) برای کلیّه متغیرهای تحقیق حاضر در نظر گرفته شد. همچنین آماره‌های مختلف هر یک از متغیرها در حوزهٔ آبخیز معرّف امامه در جدول ۳ آورده شده است.

[1] Correlation Coefficient

۲.۲.۲. تعیین مدل‌های ورودی و تأخیرهای زمانی مناسب

برای پیش‌بینی جریان روزانهٔ رودخانهٔ حوزهٔ امامه (Q) از متغیرهای هواشناسی از قبیل داده‌های میانگین بارندگی روزانه (P)، داده‌های روزانهٔ میانگین دما (T)، داده‌های روزانهٔ میانگین تبخیر و تعرق (ET) داده‌های روزانهٔ میانگین رطوبت نسبی (RH) و همچنین دبی‌های روزهای قبل (Q) این رودخانه استفاده گردید. از طرفی از آنجا که در این تحقیق از سری زمانی استفاده می‌شود و هر واقعه‌ای می‌تواند از وقایع اتفاق افتاده از روزهای

گذشته تأثیر پذیرفته و بر روی وقایع آینده نیز تأثیرگذار باشد. متغیرهای ورودی باید طوری انتخاب و تعیین شوند که شمار کمی از الگوهای ورودی بتواند ویژگی‌های منحصر به فرد موجود در داده‌ها را تعیین کند.

جدول ۳. آماره‌های مختلف متغیرهای سالانهٔ حوزهٔ آبخیز امامه در دورهٔ آماری ۱۳۵۰-۱۳۴۹ تا ۱۳۹۱-۱۳۹۰

متغیرها / آماره‌ها	دبی متوسط مترمکعب بر ثانیه (Q)	بارندگی (میلی‌متر) (P)	دما (درجه سانتی‌گراد) (T)	تبخیر و تعرق پتانسیل (میلی‌متر) (ET)	رطوبت نسبی (درصد) (Rh)
بیشینه	۹/۶۳	۹۵/۰۰	۳۷/۰	۲۴/۱۰	۹۹/۰۰
کمینه	۰/۰۱	۰/۰۰	-۱۸/۵	۰/۰۰	۴/۰۰
میانگین	۰/۶۱	۱/۸۳	۱۰/۱	۳/۴۷	۵۱
انحراف معیار	۰/۷۵	۶/۰۶	۹/۴	۳/۳۳	۱۵/۴۹
ضریب تغییرات	۱/۲۲	۳/۳۰	۰/۹	۰/۹۶	۰/۳۰

یکی از راه‌های تعیین مناسبت‌ترین تأخیرهای زمانی تهیّه نمودارهای خودهمبستگی[1] و خود همبستگی جزیی[2] و همبستگی متقاطع[3] می‌باشد [۹، ۱۶، ۳۹]. در این تحقیق با توجه به منابع مذکور به منظور ایجاد تاخیرهای زمانی لازم متغیرهای ورودی برای مدلسازی با استفاده از سامانه‌های هوشمند، از نرم‌افزار Minitab16 اقدام به همبستگی متقاطع در سطح معنی‌داری ۰/۰۱ و ۰/۰۵ درصد شد. با توجه به نتایج مشخص می‌گردد که در حوزهٔ آبخیز معرّف امامه تعداد تأخیرهای لازم برای دبی، بارندگی، دما، تبخیر و تعرق و رطوبت نسبی به ترتیب برابر با ۶، ۲، ۰، ۰، ۰ به دست آمد. لذا به منظور بررسی تأثیر پارامترهای مختلف بر پیش‌بینی و سنجش مدل‌های مختلف، مدل‌ها به سه دستهٔ ترکیب پارامترهای هواشناسی همراه با تأخیرهای زمانی به تنهایی، ترکیب پامترهای هواشناسی با آب‌سنجی همراه با تأخیرهای زمانی و پارامترهای آب‌سنجی همراه با تأخیرهای زمانی به تنهایی، تقسیم شدند و در نهایت تعداد ۶۲ ساختار و مدل برای این تحقیق در نظر گرفته شده که در جدول ۴ آورده شده است.

[1] Autocorrelation Function (ACF)
[2] Partial Autocorrelation Function (PACF)
[3] Cross Correlation
[4] Normalization

۳.۲.۲. استاندارد کردن[4]

به منظور انجام این تحقیق می‌توان داده‌ها را بدون استاندارد کردن و با استاندار کردن به شبکه اعمال کرد اما در صورت عدم استاندار کردن و یا نرمال کردن داده‌ها و بزرگ بودن مقادیر اولیه، میزان حساسیت سامانه به بزرگی داده‌ها کمتر شده و از توانایی پیش‌بینی آن می‌کاهد و لذا موجب افزایش خطا و کاهش سرعت محاسبات می‌گردد. برای همین برای رفع این مشکل و دستیابی به نتیجهٔ مطلوب داده‌ها قبل از انجام هر گونه عملیاتی و به‌عنوان پیش‌فرض ورود به نرم‌افزار استاندارد شده و در محدودهٔ ۰ تا ۱ و یا ۱- تا ۱ به منظور همگون شدن و یکدست شدن ارزش داده‌ها قرار می‌گیرند [۱۲، ۳۴، ۳۶]. در این پژوهش داده‌ها قبل از ورود در نرم‌افزار با استفاده از رابطهٔ ۱ نرمال و در محدودهٔ ۰ تا ۱ قرار گرفتند.

$$XN = \frac{X\max - Xi}{X\max - X\min} \qquad \text{رابطهٔ (۱)}$$

که در آن XN دادهٔ نرمال شده، X_{max} دادهٔ بیشینه، X_i دادهٔ مورد نظر و X_{min} دادهٔ کمینه می‌باشند.

۴.۲.۲. تقسیم‌بندی داده‌ها

در تقسیم‌بندی داده‌ها معمولاً بیشتر داده‌ها در فرایند

آموزش شرکت کرده تا مقادیر حداکثر و حداقل داده‌ها در مجموعهٔ آموزش شرکت کنند. بدین منظور برای این تحقیق از سال‌های آبی ۱۳۵۰-۱۳۴۹ تا ۱۳۸۳-۱۳۸۲ به‌عنوان داده‌های آموزشی [1] (۳۴ سال) و از سال‌های آبی ۱۳۸۴-۱۳۸۳ تا ۱۳۹۱-۱۳۹۰ و برای آزمایش و اعتبارسنجی [2] (۸ سال) انتخاب شده‌اند [۳۳]. بعد از اینکه داده‌ها آماده شدند وارد نرم‌افزار شده و با استفاده از جعبه ابزار مربوط به شبکهٔ عصبی در نرم‌افزار MATLAB2014 محاسبات انجام شده که نتایج در جدول ۵ و ۶ آورده شده است.

۵.۲.۲. معیارهای ارزیابی

به منظور ارزیابی دقت مدل‌های پیش‌بینی از روابط ۲ تا ۴ شامل میانگین مربعات خطا (MSE)، مجذور میانگین مربعات خطا (RMSE)، میانگین مطلق خطا (MAE) استفاده و نتایج با یکدیگر مقایسه شدند [۱، ۹، ۲۱، ۳۶]، انجام و نتایج با یکدیگر مقایسه شدند.

$$MSE = \frac{\sum_{1}^{i=n}\left(QO - Qe\right)^2}{n}$$ رابطهٔ (۲)

$$RMSE = \sqrt{\frac{\sum_{1}^{i=n}(Qo-Qe)^2}{n}}$$ رابطهٔ (۳)

$$MAE = \frac{1}{n}\sum_{i=1}^{n}\left|Qo - Qe\right|$$ رابطهٔ (۴)

که در آن‌ها Q_0 مقدار مشاهده‌ای متغیّر وابسته (دبی)، Qe مقدار تخمینی متغیّر وابسته (دبی تخمینی) و n تعداد داده می‌باشد.

[1] Trainning
[2] Testing

۳. نتایج

هدف از انجام این تحقیق تخمین آورد رودخانه در حوزهٔ آبخیز معرّف امامه به دلیل موقعیت جغرافیایی و اطلاعات کامل و طولانی‌مدت با استفاده از دو رویکرد روش شبکهٔ عصبی پرسپترون چندلایه (MLP) و تابع پایهٔ شعاعی (RBF) و با استفاده از داده‌های هواشناسی و آب‌سنجی و در قالب ۶۲ مدل و ساختار در جهت تخمین آورد روزانهٔ حوزهٔ مذکور انجام شده است. همان‌طور که قبلاً ذکر شد یک شبکهٔ عصبی مصنوعی از سه لایهٔ ورودی، پنهان و خروجی تشکیل شده است. تعداد نورون در لایهٔ ورودی و خروجی برابر با تعداد ورودی و خروجی است. اما تعداد لایه و نرون در لایهٔ پنهان به صورت سعی و خطا می‌باشد. در این تحقیق از تابع محرک سیگموئید برای لایهٔ پنهان به دلیل تغییرات شدید داده‌ها [۱۳، ۳۲] و از تابع محرک خطی برای لایهٔ خروجی، تعداد تکرار شبکهٔ عصبی برابر با ۱۰۰۰ تکرار، تعداد لایهٔ پنهان به کار رفته یک، دو و سه تا لایه، تعداد نرون‌های لایهٔ پنهان به صورت سعی و خطا و از الگوریتم آموزشی لونبرگ مارکوارت به دلیل استفادهٔ متداول و کارایی بالای آن در مطالعات هیدرولوژی استفاده شد. ساختار و مدل‌های پیشنهادی در جدول ۴ و نتایج مدل‌ها در جداول ۵ و ۶ آورده شده است.

با نگاهی به جدول ۴ مشخص می‌شود که مدل‌ها به سه نوع مدل‌های که در آنها فقط از متغیرهای هواشناسی استفاده شده است. دستهٔ دوم مدل‌هایی هستند که در آن‌ها فقط از تأخیر زمانی جریان در جهت تأثیر توالی دبی بر جریان رودخانه و دستهٔ سوم ترکیب مدل‌های که از تأخیر متغیرهای هواشناسی و تأخیر آب‌سنجی برای پیش‌بینی جریان استفاده شده است. با توجه به نتایج شبکهٔ عصبی پرسپترون چندلایه که در جدول ۵ آورده شده است و در وهله اول سنجش مدل‌ها بر اساس خطای مدل‌ها در مرحلهٔ آزمایش و در صورت یکسان بودن به خطاهای صحت‌سنجی و سپس خطاهای مدل در مرحلهٔ آموزش توجه شده است. زیرا داده‌های آزمایش مربوط به

داده‌های هستند که وارد مدل نشده‌اند و به اصطلاح یـک می‌باشند. قضاوت سخت‌گیرانه‌تر از خطاهای مـدل و صـحت‌سـنجی

جدول ۴. ساختارهای در نظرگرفته شدهٔ شبکهٔ عصبی مصنوعی در حوزهٔ آبخیز امامه

شماره مدل	ورودی	خروجی
۱	P_t	Q_t
۲	ET_t	Q_t
۳	RH_t	Q_t
۴	T_t	Q_t
۵	Q_{t-1}	Q_t
۶	P_t, P_{t-1}	Q_t
۷	P_t, Q_{t-1}	Q_t
۸	ET_t, Q_{t-1}	Q_t
۹	RH_t, Q_{t-1}	Q_t
۱۰	T_t,Q_{t-1}	Q_t
۱۱	Q_{t-1}, Q_{t-2}	Q_t
۱۲	P_t, P_{t-1}, P_{t-2}	Q_t
۱۳	P_t, P_{t-1}, Q_{t-1}	Q_t
۱۴	P_t, Q_{t-1}, Q_{t-2}	Q_t
۱۵	ET_t, Q_{t-1}, Q_{t-2}	Q_t
۱۶	RH_t, Q_{t-1}, Q_{t-2}	Q_t
۱۷	T_t,Q_{t-1}, Q_{t-2}	Q_t
۱۸	$Q_{t-1}, Q_{t-2}, Q_{t-3}$	Q_t
۱۹	$P_t, P_{t-1}, P_{t-2}, Q_{t-1}$	Q_t
۲۰	$P_t, P_{t-1}, Q_{t-1}, Q_{t-2}$	Q_t
۲۱	$P_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	Q_t
۲۲	$ET_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	Q_t
۲۳	$RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	Q_t
۲۴	$T_t,Q_{t-1}, Q_{t-2}, Q_{t-3}$	Q_t
۲۵	P_t, T_t, ET_t, RH_t	Q_t
۲۶	$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	Q_t
۲۷	$P_t, P_{t-1}, P_{t-2}, Q_{t-1}, Q_{t-2}$	Q_t
۲۸	$P_t, P_{t-1}, Q_{t-1}, Q_{t-2}, Q_{t-3}$	Q_t
۲۹	$P_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	Q_t
۳۰	$ET_t, Q_{t-1}, Q_{t-2}, Q_{t-3},Q_{t-4}$	Q_t
۳۱	$RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3},Q_{t-4}$	Q_t
۳۲	$T_t,Q_{t-1}, Q_{t-2}, Q_{t-3},Q_{t-4}$	Q_t
۳۳	$P_t, T_t, ET_t, RH_t, Q_{t-1}$	Q_t

ادامه جدول ۴.

شماره مدل	ورودی	خروجی
۳۴	$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	Q_t
۳۵	$P_t , P_{t-1}, P_{t-2}, Q_{t-1}, Q_{t-2}, Q_{t-3}$	Q_t
۳۶	$P_t, P_{t-1}, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	Q_t
۳۷	$P_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	Q_t
۳۸	$ET_t, Q_{t-1}, Q_{t-2}, Q_{t-3},Q_{t-4}, Q_{t-5}$	Q_t
۳۹	$RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3},Q_{t-4}, Q_{t-5}$	Q_t
۴۰	$T_t,Q_{t-1}, Q_{t-2}, Q_{t-3},Q_{t-4}, Q_{t-5}$	Q_t
۴۱	$P_t, P_{t-1}, P_{t-2}, T_t, ET_t, RH_t$	Q_t
۴۲	$P_t, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}$	Q_t
۴۳	$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	Q_t
۴۴	$P_t, P_{t-1}, P_{t-2}, Q_{t-1}, Q_{t-2}, Q_{t-3},Q_{t-4}$	Q_t
۴۵	$P_t, P_{t-1}, Q_{t-1}, Q_{t-2}, Q_{t-3},Q_{t-4},Q_{t-5}$	Q_t
۴۶	$P_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	Q_t
۴۷	$ET_t, Q_{t-1}, Q_{t-2}, Q_{t-3},Q_{t-4}, Q_{t-5},Q_{t-6}$	Q_t
۴۸	$RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3},Q_{t-4}, Q_{t-5},Q_{t-6}$	Q_t
۴۹	$T_t,Q_{t-1}, Q_{t-2}, Q_{t-3},Q_{t-4}, Q_{t-5},Q_{t-6}$	Q_t
۵۰	$P_t, P_{t-1}, P_{t-2}, T_t, ET_t, RH_t, Q_{t-1}$	Q_t
۵۱	$P_t, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	Q_t
۵۲	$P_t, P_{t-1}, P_{t-2}, Q_{t-1}, Q_{t-2}, Q_{t-3},Q_{t-4},Q_{t-5}$	Q_t
۵۳	$P_t, P_{t-1}, Q_{t-1}, Q_{t-2}, Q_{t-3},Q_{t-4},Q_{t-5}, Q_{t-6}$	Q_t
۵۴	$P_t, P_{t-1}, P_{t-2}, Tt, ET_t, RH_t, Q_{t-1}, Q_{t-2}$	Q_t
۵۵	$P_t, Tt, ETt, RHt, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	Q_t
۵۶	$P_t, P_{t-1}, P_{t-2}, Q_{t-1}, Q_{t-2}, Q_{t-3},Q_{t-4},Q_{t-5}, Q_{t-6}$	Q_t
۵۷	$P_t, P_{t-1}, P_{t-2}, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	Q_t
۵۸	$P_t, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	Q_t
۵۹	$P_t, P_{t-1}, P_{t-2}, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	Q_t
۶۰	$P_t, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	Q_t
۶۱	$P_t, P_{t-1}, P_{t-2}, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	Q_t
۶۲	$P_t, P_{t-1}, P_{t-2}, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	Q_t

جدول ۵. نتایج مدل‌های شبکهٔ عصبی پرسپترون چندلایه در حوزهٔ آبخیز امامه

شماره مدل	ساختار شبکه	آموزش			اعتبارسنجی		
		MSE	RMSE	MAE	MSE	RMSE	MAE
۱	۱-۴-۱	۰/۳۳	۰/۵۷	۰/۳۴	۰/۱۴	۰/۳۷	۰/۱۳
۲	۱-۶-۱۲-۱	۰/۳۴	۰/۵۸	۰/۳۷	۰/۱۵	۰/۳۹	۰/۱۴
۳	۱-۷-۹-۱	۰/۳۵	۰/۵۹	۰/۳۹	۰/۱۶	۰/۴۰	۰/۱۴
۴	۱-۱۲-۱	۰/۳۱	۰/۵۶	۰/۳۳	۰/۱۳	۰/۳۶	۰/۱۳
۵	۱-۱۱-۱	۰/۰۵	۰/۲۲	۰/۰۸	۰/۰۴	۰/۲۰	۰/۰۶
۶	۲-۴-۴-۱	۰/۲۹	۰/۵۴	۰/۳۱	۰/۱۲	۰/۳۵	۰/۱۲
۷	۲-۱۱-۱	۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۳	۰/۱۸	۰/۰۳
۸	۲-۸-۱۰-۱	۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۴	۰/۲۰	۰/۰۳
۹	۲-۷-۱-۱	۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۴	۰/۲۰	۰/۰۳
۱۰	۲-۹-۴-۱	۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۳	۰/۱۷	۰/۰۳
۱۱	۲-۸-۱۲-۱	۰/۰۴	۰/۲۰	۰/۰۶	۰/۰۳	۰/۱۷	۰/۰۳
۱۲	۳-۵-۱	۰/۲۵	۰/۵۰	۰/۲۸	۰/۱۰	۰/۳۲	۰/۱۱
۱۳	۳-۱۴-۱	۰/۰۴	۰/۲۰	۰/۰۶	۰/۰۲	۰/۱۴	۰/۰۲
۱۴	۳-۱۴-۱	۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۲	۰/۱۵	۰/۰۲
۱۵	۳-۶-۳-۱	۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۲	۰/۱۵	۰/۰۲
۱۶	۳-۵-۱-۱	۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۲	۰/۱۵	۰/۰۲
۱۷	۳-۱۰-۱	۰/۰۴	۰/۲۰	۰/۰۶	۰/۰۲	۰/۱۵	۰/۰۲
۱۸	۳-۴-۱۰-۱	۰/۰۴	۰/۲۰	۰/۰۶	۰/۰۳	۰/۱۷	۰/۰۳
۱۹	۴-۲-۱	۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۳	۰/۱۶	۰/۰۳
۲۰	۴-۹-۱۲-۱	۰/۰۴	۰/۲۰	۰/۰۶	۰/۰۲	۰/۱۴	۰/۰۲
۲۱	۴-۱۳-۱	۰/۰۴	۰/۲۰	۰/۰۶	۰/۰۲	۰/۱۴	۰/۰۲
۲۲	۴-۵-۶-۱	۰/۰۴	۰/۲۰	۰/۰۶	۰/۰۲	۰/۱۴	۰/۰۲
۲۳	۴-۷-۱۰-۱	۰/۰۴	۰/۲۰	۰/۰۶	۰/۰۲	۰/۱۴	۰/۰۲
۲۴	۴-۵-۳-۱	۰/۰۴	۰/۲۰	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۲۵	۴-۷-۱	۰/۲۷	۰/۵۲	۰/۲۹	۰/۱۱	۰/۳۳	۰/۱۱
۲۶	۴-۱۵-۱	۰/۰۶	۰/۲۴	۰/۰۸	۰/۰۵	۰/۲۲	۰/۰۸
۲۷	۵-۳-۷-۱	۰/۰۴	۰/۲۰	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۲۸	۵-۱۰-۱۱-۱	۰/۰۴	۰/۲۰	۰/۰۶	۰/۰۲	۰/۱۴	۰/۰۲
۲۹	۵-۹-۹-۱	۰/۰۴	۰/۲۰	۰/۰۶	۰/۰۲	۰/۱۵	۰/۰۲
۳۰	۵-۳-۳-۱	۰/۰۴	۰/۲۰	۰/۰۶	۰/۰۲	۰/۱۵	۰/۰۲
۳۱	۵-۷-۱۱-۱	۰/۰۴	۰/۲۰	۰/۰۶	۰/۰۲	۰/۱۵	۰/۰۲
۳۲	۵-۴-۱۲-۱	۰/۰۴	۰/۲۰	۰/۰۶	۰/۰۲	۰/۱۴	۰/۰۲
۳۳	۵-۴-۱-۱	۰/۰۴	۰/۲۰	۰/۰۶	۰/۰۲	۰/۱۴	۰/۰۲
۳۴	۵-۸-۳-۱	۰/۰۷	۰/۲۶	۰/۰۹	۰/۰۶	۰/۲۴	۰/۰۸

ادامه جدول ۵.

شماره مدل	ساختار شبکه	آموزش			اعتبارسنجی		
		MSE	RMSE	MAE	MSE	RMSE	MAE
۳۵	۱-۹-۶-۶	۰/۰۴	۰/۱۹	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۳۶	۱-۸-۶	۰/۰۴	۰/۲۰	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۳۷	۱-۱۲-۱۰-۶	۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۲	۰/۱۵	۰/۰۲
۳۸	۱-۶-۵-۶	۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۲	۰/۱۵	۰/۰۲
۳۹	۱-۱۰-۷-۶	۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۲	۰/۱۵	۰/۰۲
۴۰	۱-۲-۸-۶	۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۲	۰/۱۵	۰/۰۲
۴۱	۱-۵-۷-۶	۰/۲۴	۰/۴۹	۰/۲۷	۰/۱۰	۰/۳۲	۰/۱۱
۴۲	۱-۱۰-۱۰-۶	۰/۰۴	۰/۱۹	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۴۳	۱-۱-۶-۶	۰/۰۸	۰/۲۸	۰/۱۰	۰/۰۷	۰/۲۶	۰/۰۹
۴۴	۱-۱۱-۹-۷	۰/۰۴	۰/۲۰	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۴۵	۱-۵-۹-۷	۰/۰۴	۰/۲۰	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۴۶	۱-۱۰-۱۰-۷	۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۲	۰/۱۵	۰/۰۲
۴۷	۱-۵-۹-۷	۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۳	۰/۱۵	۰/۰۲
۴۸	۱-۱۲-۴-۷	۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۳	۰/۱۶	۰/۰۲
۴۹	۱-۷-۷-۷	۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۲	۰/۱۵	۰/۰۲
۵۰	۱-۴-۴-۷	۰/۰۴	۰/۱۹	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۵۱	۱-۸-۸-۷	۰/۰۳	۰/۱۹	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۵۲	۱-۱۶-۸	۰/۰۴	۰/۲۰	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۵۳	۱-۱۲-۹-۸	۰/۰۴	۰/۲۰	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۵۴	۱-۸-۹-۸	۰/۰۳	۰/۱۸	۰/۰۴	۰/۰۲	۰/۱۴	۰/۰۲
۵۵	۱-۱۱-۶-۸	۰/۰۴	۰/۲۰	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۵۶	۱-۶-۹-۹	۰/۰۴	۰/۲۰	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۵۷	۱-۱۲-۹	۰/۰۳	۰/۱۹	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۵۸	۱-۱۰-۹-۹	۰/۰۴	۰/۲۰	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۵۹	۱-۲-۸-۱۰	۰/۰۴	۰/۱۹	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۶۰	۱-۵-۷-۱۰	۰/۰۴	۰/۲۰	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۶۱	۱-۲-۹-۱۱	۰/۰۴	۰/۱۹	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۶۲	۱-۲-۱۰-۱۲	۰/۰۴	۰/۲۰	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲

جدول ۶. نتایج مدل‌های شبکهٔ عصبی تابع پایهٔ شعاعی در حوزهٔ آبخیز امامه

شماره مدل	ساختار شبکه	آموزش			اعتبارسنجی		
		MSE	RMSE	MAE	MSE	RMSE	MAE
۱	۱-۲۹-۱	۰/۴۷	۰/۶۹	۰/۵۰	۰/۵۳	۰/۷۳	۰/۵۶
۲	۱-۳۰-۱	۰/۴۸	۰/۶۹	۰/۵۱	۰/۵۳	۰/۷۳	۰/۵۷
۳	۱-۳۰-۱	۰/۴۹	۰/۷۰	۰/۵۱	۰/۵۶	۰/۷۵	۰/۶۰
۴	۱-۲۹-۱	۰/۴۶	۰/۶۸	۰/۵۰	۰/۵۲	۰/۷۲	۰/۵۵
۵	۱-۲۸-۱	۰/۰۷	۰/۲۶	۰/۰۹	۰/۱۳	۰/۳۶	۰/۱۳
۶	۲-۳۳-۱	۰/۴۴	۰/۶۶	۰/۴۹	۰/۵۱	۰/۷۱	۰/۵۵
۷	۲-۳۱-۱	۰/۰۷	۰/۲۶	۰/۰۹	۰/۱۵	۰/۳۸	۰/۱۴
۸	۲-۳۳-۱	۰/۰۷	۰/۲۶	۰/۰۹	۰/۱۵	۰/۳۹	۰/۱۴
۹	۲-۳۴-۱	۰/۰۷	۰/۲۶	۰/۰۹	۰/۱۶	۰/۴۰	۰/۱۴
۱۰	۲-۳۸-۱	۰/۰۷	۰/۲۶	۰/۰۹	۰/۱۵	۰/۳۸	۰/۱۳
۱۱	۲-۳۶-۱	۰/۰۶	۰/۲۴	۰/۰۸	۰/۱۲	۰/۳۵	۰/۱۲
۱۲	۳-۳۰-۱	۰/۳۷	۰/۶۱	۰/۴۲	۰/۵۰	۰/۷۱	۰/۵۲
۱۳	۳-۳۸-۱	۰/۰۶	۰/۲۴	۰/۰۸	۰/۱۰	۰/۳۲	۰/۱۱
۱۴	۳-۳۹-۱	۰/۰۶	۰/۲۵	۰/۰۹	۰/۱۱	۰/۳۴	۰/۱۱
۱۵	۳-۳۷-۱	۰/۰۶	۰/۲۵	۰/۰۹	۰/۱۱	۰/۳۴	۰/۱۲
۱۶	۳-۳۷-۱	۰/۰۶	۰/۲۵	۰/۰۹	۰/۱۱	۰/۳۴	۰/۱۲
۱۷	۳-۲۹-۱	۰/۰۶	۰/۲۵	۰/۰۹	۰/۱۱	۰/۳۴	۰/۱۱
۱۸	۳-۳۸-۱	۰/۰۶	۰/۲۴	۰/۰۸	۰/۱۲	۰/۳۵	۰/۱۲
۱۹	۴-۴۰-۱	۰/۰۷	۰/۲۶	۰/۰۹	۰/۱۵	۰/۳۸	۰/۱۳
۲۰	۴-۴۱-۱	۰/۰۶	۰/۲۵	۰/۰۸	۰/۱۱	۰/۳۳	۰/۱۱
۲۱	۴-۴۸-۱	۰/۰۶	۰/۲۵	۰/۰۸	۰/۱۱	۰/۳۲	۰/۱۱
۲۲	۴-۴۲-۱	۰/۰۶	۰/۲۵	۰/۰۸	۰/۱۱	۰/۳۲	۰/۱۱
۲۳	۴-۴۰-۱	۰/۰۶	۰/۲۵	۰/۰۸	۰/۱۱	۰/۳۳	۰/۱۱
۲۴	۴-۴۷-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰
۲۵	۴-۴۸-۱	۰/۴۳	۰/۶۶	۰/۴۶	۰/۵۰	۰/۷۱	۰/۵۲
۲۶	۴-۴۷-۱	۰/۰۸	۰/۲۸	۰/۱۰	۰/۱۴	۰/۳۷	۰/۱۳
۲۷	۵-۴۹-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۲	۰/۱۱
۲۸	۵-۴۰-۱	۰/۰۶	۰/۲۴	۰/۰۸	۰/۱۰	۰/۳۲	۰/۱۱
۲۹	۵-۳۹-۱	۰/۰۶	۰/۲۵	۰/۰۹	۰/۱۱	۰/۳۳	۰/۱۱
۳۰	۵-۴۵-۱	۰/۰۶	۰/۲۵	۰/۰۹	۰/۱۱	۰/۳۳	۰/۱۱
۳۱	۵-۴۴-۱	۰/۰۶	۰/۲۵	۰/۰۹	۰/۱۱	۰/۳۳	۰/۱۱
۳۲	۵-۴۸-۱	۰/۰۶	۰/۲۵	۰/۰۹	۰/۱۱	۰/۳۳	۰/۱۱
۳۳	۵-۴۹-۱	۰/۰۶	۰/۲۵	۰/۰۸	۰/۱۱	۰/۳۲	۰/۱۱
۳۴	۵-۵۵-۱	۰/۰۹	۰/۳۰	۰/۱۰	۰/۱۵	۰/۳۹	۰/۱۴
۳۵	۶-۵۶-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰
۳۶	۶-۵۷-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۱
۳۷	۶-۵۷-۱	۰/۰۶	۰/۲۵	۰/۰۹	۰/۱۲	۰/۳۵	۰/۱۲
۳۸	۶-۵۸-۱	۰/۰۶	۰/۲۵	۰/۰۹	۰/۱۳	۰/۳۵	۰/۱۲

ادامه جدول ۶.

شماره مدل	ساختار شبکه	آموزش MSE	آموزش RMSE	آموزش MAE	اعتبارسنجی MSE	اعتبارسنجی RMSE	اعتبارسنجی MAE
۳۹	۶-۴۷-۱	۰/۰۶	۰/۲۶	۰/۰۹	۰/۱۳	۰/۳۶	۰/۱۳
۴۰	۶-۴۹-۱	۰/۰۶	۰/۲۵	۰/۰۹	۰/۱۲	۰/۳۴	۰/۱۲
۴۱	۶-۴۰-۱	۰/۳۶	۰/۶۰	۰/۴۱	۰/۵۰	۰/۷۱	۰/۵۱
۴۲	۶-۳۹-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰
۴۳	۶-۴۵-۱	۰/۱۱	۰/۳۳	۰/۱۱	۰/۱۶	۰/۴۰	۰/۱۴
۴۴	۷-۴۴-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰
۴۵	۷-۴۸-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰
۴۶	۷-۴۹-۱	۰/۰۷	۰/۲۶	۰/۰۹	۰/۱۳	۰/۳۶	۰/۱۳
۴۷	۷-۵۵-۱	۰/۰۷	۰/۲۶	۰/۰۹	۰/۱۳	۰/۳۶	۰/۱۳
۴۸	۷-۵۶-۱	۰/۰۷	۰/۲۶	۰/۰۹	۰/۱۳	۰/۳۶	۰/۱۳
۴۹	۷-۵۷-۱	۰/۰۶	۰/۲۶	۰/۰۹	۰/۱۳	۰/۳۶	۰/۱۳
۵۰	۷-۵۷-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰
۵۱	۷-۵۸-۱	۰/۰۵	۰/۲۲	۰/۰۸	۰/۰۹	۰/۳۱	۰/۱۰
۵۲	۸-۴۷-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰
۵۳	۸-۴۹-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰
۵۴	۸-۴۰-۱	۰/۰۴	۰/۲۰	۰/۰۸	۰/۰۹	۰/۳۰	۰/۱۰
۵۵	۸-۳۹-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰
۵۶	۹-۴۵-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰
۵۷	۹-۴۴-۱	۰/۰۵	۰/۲۲	۰/۰۸	۰/۰۹	۰/۳۱	۰/۱۰
۵۸	۹-۴۸-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰
۵۹	۱۰-۴۹-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰
۶۰	۱۰-۵۵-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰
۶۱	۱۱-۵۶-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰
۶۲	۱۲-۵۷-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰

۴. بحث و نتیجه‌گیری

پژوهش حاضر با هدف تخمین آورد روزانهٔ حوزهٔ آبخیز معرّف امامه به‌عنوان معرّف و نماینده‌ای از مناطق جنوبی رشته کوه البرز انجام شد. دقت در نتایج مدل‌ها نشان می‌دهد که اولاً مدل‌هایی که در آنها فقط از یک متغیر و یا یک نوع متغیر استفاده شده و یا به عبارتی دارای یک ورودی و یا فقط از یک نوع ورودی استفاده شده دارای خطای بالایی نسبت به دیگر مدل‌ها می‌باشند و دوم این‌که خطاهای مدل‌هایی که در آن‌ها فقط از متغیرهای هواشناسی استفاده شده به مراتب بیشتر از خطاهای مدل‌هایی است که در آن‌ها از متغیرهای آورد روزهای قبل استفاده شده است و این نشان می‌دهد که دبی‌های روزهای قبل در حوزهٔ آبخیز امامه اثر معنادارتر و بیشتری بر روی جریان رودخانه نسبت به متغیرهای هواشناسی دارند اما از طرفی مدل‌هایی که در آن‌ها فقط از یک نوع متغیر و یک متغیر استفاده شده هم نمی‌تواند به تنهایی کافی باشد و بیش از یک عامل و یا متغیر و به‌عبارتی دسته‌ای از عوامل هواشناسی و آب‌سنجی بر پیش‌بینی جریان رودخانه در این حوزه دخالت داشته‌اند که این نشان‌دهندهٔ تأثیر عوامل مختلف بر روی جریان رودخانه

است. از بین مدل‌های موجود با یک ورودی به ترتیب رطوبت نسبی دارای کمترین اثر و لذا با بالاترین خطای معیارهای ارزیابی به ترتیب شامل MSE، RMSE و MAE برابر با ۰/۳۵، ۰/۵۹ و ۰/۳۹ در مرحله آموزش، ۰/۱۶، ۰/۴۰ و ۰/۱۴ در مرحلهٔ آزمایش و برای متغیر دما که دارای بیشترین اثر (از بین مدل‌های با یک متغیر هواشناسی) بر روی جریان خروجی تأثیر داشتند که معیارهای ارزیابی به ترتیب MSE، RMSE، MAE برابر با ۰/۳۱، ۰/۵۶ و ۰/۳۳ در مرحله آموزش و ۰/۱۳، ۰/۳۶ و ۰/۱۳ در مرحلهٔ آزمایش بوده‌اند. در رابطه با بارندگی نیز مشاهده می‌گردد که میزان خطای مدل وقتی که بارندگی با دو تأخیر استفاده می‌شود نسبت به وقتی که از بارندگی همان روز و یا یک روز قبل استفاده شده خطای مدل کاهش می‌یابد و این نشان می‌دهد که در حوزهٔ آبخیز معرّف امامه بارندگی تا دو روز دارای اثر بیشتری است تا بارندگی روزهای قبل و یا همان روز به طوری که میزان خطاها در مدل که فقط از بارندگی همان روز (مدل شماره ۱) با آرایش شبکه ۱-۴-۱ استفاده شده برابر با ۰/۳۳، ۰/۵۷ و ۰/۳۴ در مرحلهٔ آموزش و ۰/۱۴، ۰/۳۷ و ۰/۱۳ در مرحلهٔ آزمایش بوده در حالی که در مدل شماره ۱۲ و با آرایش شبکه ۱-۵-۳ برابر با ۰/۲۵، ۰/۵۰ و ۰/۲۸ در مرحلهٔ آموزش و ۰/۱۰، ۰/۳۲ و ۰/۱۱ در مرحلهٔ آزمایش برای معیارهای ارزیابی به ترتیب MSE، RMSE و MAE به دست آمده و این یافته با نتایج شریفی و همکاران [۳۵] مبنی بر تأثیر بارندگی روزهای قبل در این حوزه هم‌خوانی دارد. علاوه بر این با دقت بر خطاهای مدل‌های پرسپترون چندلایه مشخص می‌گردد که مدل‌هایی که در آنها فقط از تأخیرهای زمانی و به‌عبارتی از توالی جریان استفاده شده است نسبت به موقعی که فقط از متغیرهای هواشناسی استفاده شده دارای خطای کمتر و عملکرد بهتری می‌باشند و علاوه بر این از بین مدل‌هایی که فقط از توالی و یا تأخیر زمانی روزانهٔ جریان استفاده شده نشان می‌دهد که در این حوزه و با توجه به معیارهای ارزیابی تأخیر جریان رودخانه با تأخیر دو و سه روز بر روی جریان رودخانهٔ حوزهٔ امامه تأثیر یکسان داشته و از تأخیر چهارم، پنجم و ششم نه تنها تأثیری نداشته‌اند بلکه خطاها نیز افزایش یافته است و این نشان می‌دهد که حداکثر میزان توالی آورد رودخانهٔ حوزهٔ مذکور برابر با ۲ تأخیر بوده که این یافته با نتایج شریفی و همکاران [۳۵] که با استفاده از آزمون گاما به این نتیجه رسیده‌اند هم‌خوانی دارد. با توجه به موارد ذکر شده بهترین ساختار مدل ۵۴ برای دو مرحلهٔ آموزش و آزمایش (شکل‌های ۲ و ۳) که در آن از متغیرهای بارندگی، تأخیر بارندگی تا دو روز، دما، تبخیر و تعرق، رطوبت نسبی بدون تأخیر و همچنین میزان تأخیرهای جریان تا ۲ روز بیشترین تأثیر را بر روی جریان داشته‌اند و میزان خطا برابر با ۰/۰۳، ۰/۱۸ و ۰/۰۴ در مرحلهٔ مدلسازی و ۰/۰۲، ۰/۱۴ و ۰/۰۲ در مرحلهٔ آزمایش برای معیارهای ارزیابی مذکور و با ضریب همبستگی به ترتیب ۰/۹۰۳ و ۰/۹۱۵ بوده است (شکل‌های ۴ و ۵). لذا با توجه به نتایج جدول ۵ و با استفاده از روش پرسپترون چندلایه مدل شمارهٔ ۵۴ با ۸ متغیر ورودی و با ساختار ۲ لایهٔ پنهان که در لایهٔ اول و دوم با ۹ و ۸ نرون (آرایش ۱-۸-۹-۸) دارای بهترین عملکرد بوده است. علاوه بر این در این پژوهش از یک، دو و سه لایهٔ پنهان استفاده شده است که نتایج نشان داد استفاده از سه لایهٔ پنهان هیچ تأثیری بر بهتر شدن شرایط مدل‌ها نداشته و همچنین با توجه به آرایش شبکه‌های عصبی در جدول ۵ مشخص می‌شود که از ۶۲ ساختار ۴۸ مدل (۷۷ درصد) دارای دو لایهٔ پنهان در ساختار خود بوده‌اند به طوری که با افزایش ورودی‌ها و پیچیده شدن شبکهٔ عصبی استفاده از شبکهٔ عصبی پرسپترون چهار لایه که دارای دو لایه پنهان است مناسب می‌باشد که نتایج یافته‌های این تحقیق با نظر Food و Kartman [۱۳] وRipley [۳۲] مبنی بر استفاده از شبکه‌های پس‌انتشار خطای دو لایهٔ مخفی به دلیل قابلیت انعطاف‌پذیری آن‌ها در حل مسائل هیدرولوژی به دلیل تغییرات شدید داده‌ها، اغتشاش حاکم بر داده‌ها هم‌خوانی دارد. همچنین با توجه به نتایج تابع پایهٔ

شعاعی در جدول ۶ مشخص می‌گردد که در روش شبکهٔ عصبی تابع پایهٔشعاعی نیز گر چه عملکرد پایین‌تری نسبت به پرسپترون چندلایه داشته باشد و خطاهای مدل‌ها بیش‌تر از آن می‌باشد اما مؤید این بوده که چندان اختلافی با شبکهٔ عصبی پرسپترون چندلایه نداشته است. علاوه بر این متذکر شده که این نوع شبکهٔ عصبی دارای یک لایه بوده و برای تخمین و مقدار پیش‌بینی شده احتیاج به تعداد نرون بیشتری دارد. همچنین سرعت RBF از MLP بالاتر بوده است. در این روش مدل‌هایی که در آن فقط از یک متغیر به عنوان ورودی استفاده شده به‌خصوص هواشناسی دارای خطای زیادتری نسبت به دیگر مدل‌ها بوده است. در این نوع روش نیز از بین متغیرهای هواشناسی رطوبت نسبی با آرایش ۱-۳۰-۱ و میزان خطا ۰/۴۹، ۰/۷۰ و ۰/۵۱ در مرحلهٔ مدلسازی و ۰/۵۶، ۰/۷۵ و ۰/۶۰ در مرحلهٔ آزمایش برای معیارهای ارزیابی MSE، RMSE و MAE بوده است. به طوری که ترتیب خطاها در بین متغیرهای با یک نوع ورودی و آن‌هم هواشناسی رطوبت نسبی، تبخیر و تعرق، باران و در نهایت دما به ترتیب دارای بیشترین و کمترین میزان خطاها بوده‌اند. و این نشان می‌دهد که در این حوزه رطوبت نسبی دارای اثر کمتری بر روی جریان رودخانه است و دما تأثیر بیشتری دارد. در آخر در روش RBF مدل شمارهٔ ۵۴ نیز همانند روش قبلی دارای عملکرد بهتر با آرایش ۱-۴۰-۸ و میزان خطا ۰/۰۴، ۰/۲۰ و ۰/۰۸ در مرحلهٔ مدلسازی و ۰/۰۹، ۰/۳۰ و ۰/۱۰ در مرحلهٔ آزمایش برای معیارهای ارزیابی MSE، RMSE و MAE می‌باشد (شکل‌های ۶ و ۷). همچنین میزان ضریب همبستگی برای دو مرحلهٔ آموزش و آزمایش در روش RBF برای حوزهٔ مورد بررسی به ترتیب برابر با ۰/۸۷۴ و ۰/۸۵۲ بوده است که نمودار آن‌ها در شکل‌های ۸ و ۹ ارائه شده است.

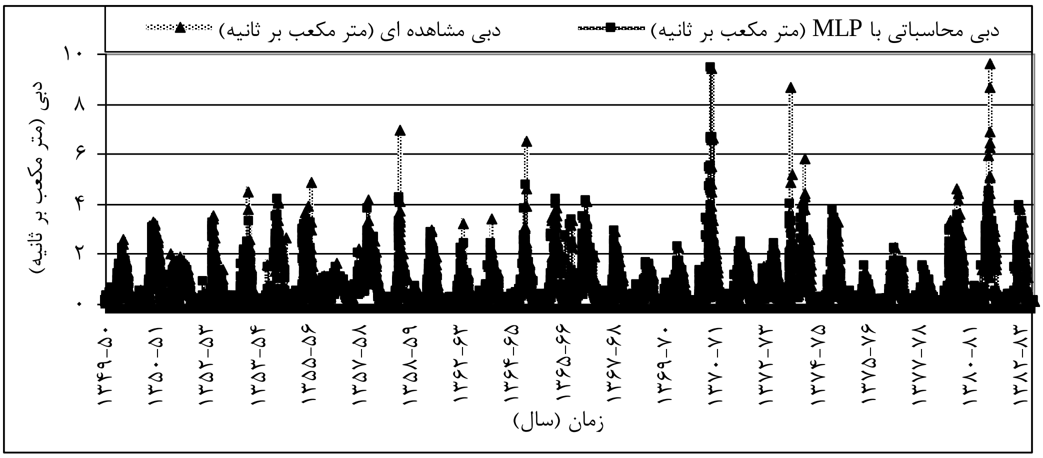

شکل ۲. نمودار دبی روزانهٔ مشاهده‌ای و پیش‌بینی شده به روش شبکهٔ عصبی MLP حوزهٔ آبخیز امامه بر حسب ساختار ۵۴ برای سال‌های ۱۳۴۹-۱۳۵۰ تا ۱۳۸۲-۱۳۸۳ (آموزش)

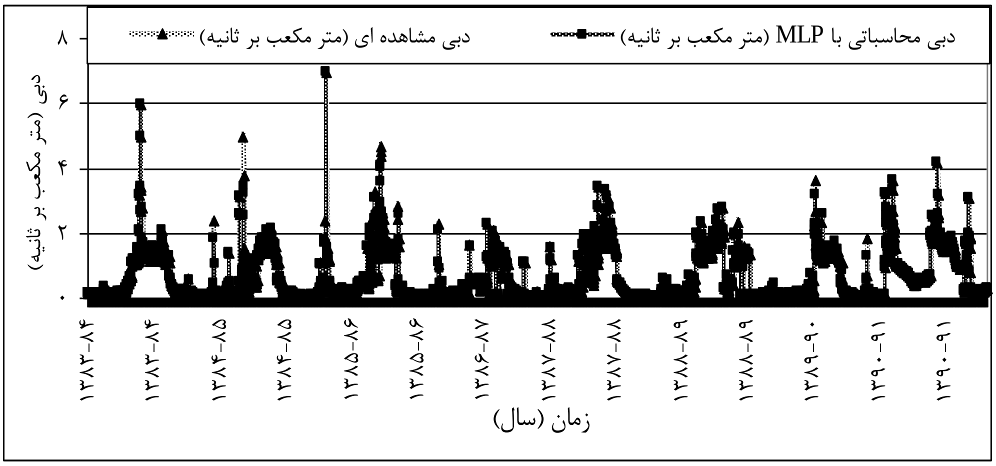

شکل ۳. نمودار دبی روزانهٔ مشاهده‌ای و پیش‌بینی شده به روش شبکهٔ عصبی MLP حوزهٔ آبخیز امامه بر حسب ساختار ۵۴ برای سال‌های ۱۳۸۳-۱۳۸۴ تا ۱۳۹۰-۱۳۹۱ (آزمایش)

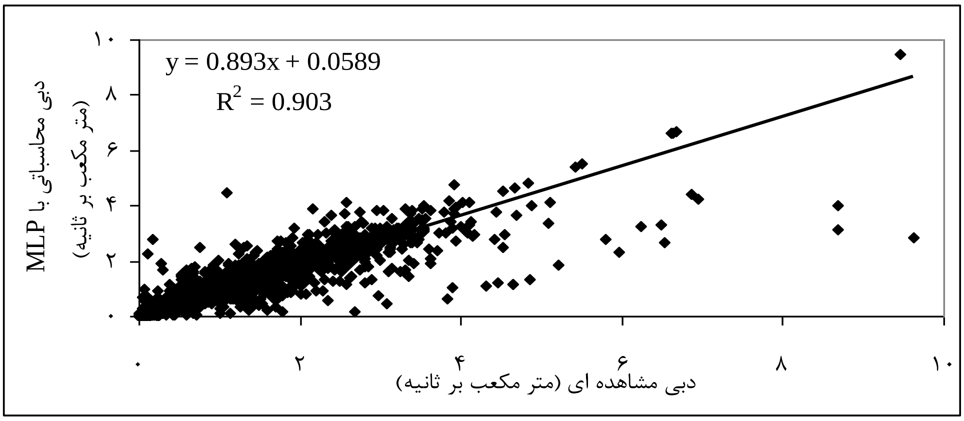

شکل ۴. همبستگی دبی روزانهٔ مشاهده‌ای و پیش‌بینی شده در سطح معنی‌داری یک درصد به روش شبکهٔ عصبی MLP حوزهٔ آبخیز امامه بر حسب ساختار ۵۴ برای سال‌های ۱۳۴۹-۱۳۵۰ تا ۱۳۸۲-۱۳۸۳ (آموزش)

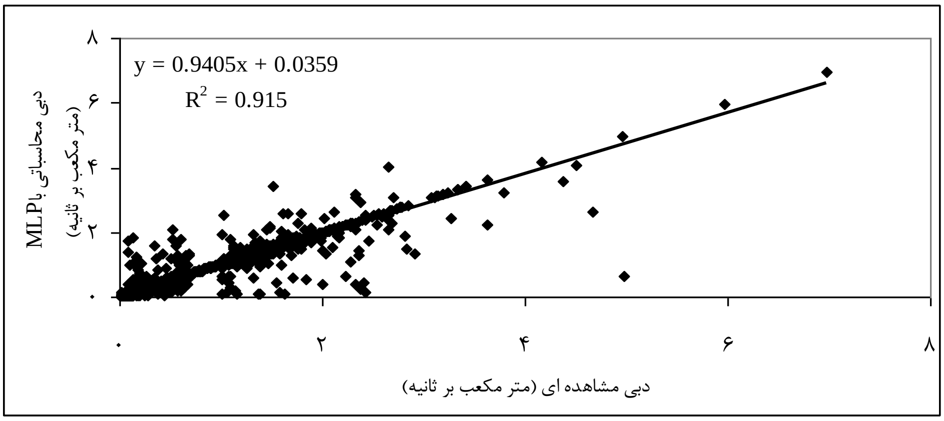

شکل ۵. همبستگی دبی روزانهٔ مشاهده‌ای و پیش‌بینی شده در سطح معنی‌داری یک درصد به روش شبکهٔ عصبی MLP حوزهٔ آبخیز امامه بر حسب ساختار ۵۴ برای سال‌های ۱۳۸۳-۱۳۸۴ تا ۱۳۹۰-۱۳۹۱ (آزمایش)

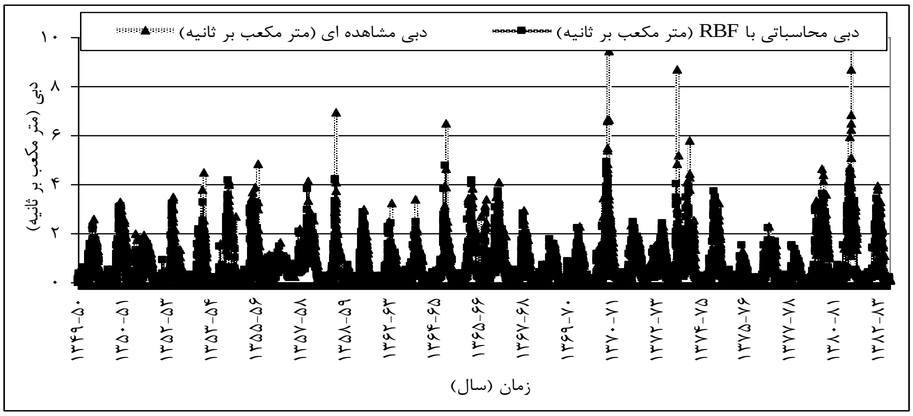

شکل ۶. نمودار دبی روزانهٔ مشاهده‌ای و پیش‌بینی شده به روش شبکهٔ عصبی RBF حوزهٔ آبخیز امامه بر حسب ساختار ۵۴ برای سال‌های ۱۳۴۹-۱۳۵۰ تا ۱۳۸۲-۱۳۸۳ (آموزش)

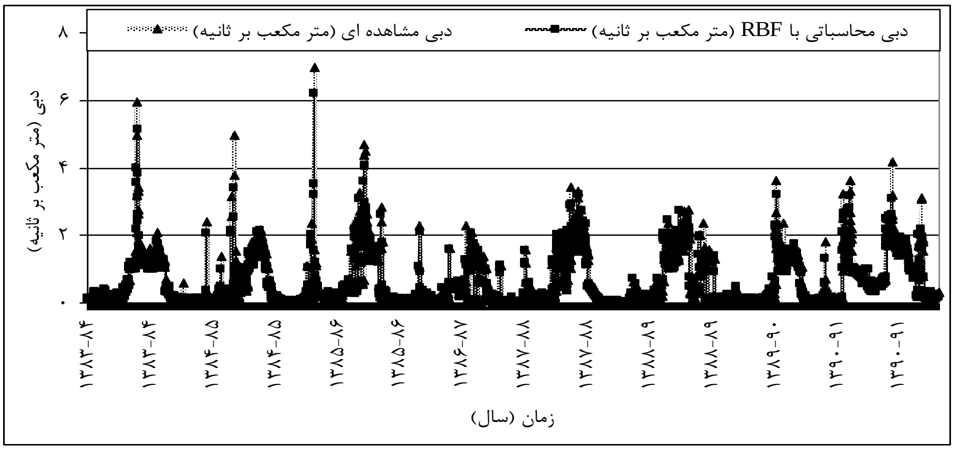

شکل ۷. نمودار دبی روزانهٔ مشاهده‌ای و پیش‌بینی شده به روش شبکهٔ عصبی RBF حوزهٔ آبخیز امامه بر حسب ساختار ۵۴ برای سال‌های ۱۳۸۳-۱۳۸۴ تا ۱۳۹۰-۱۳۹۱ (آزمایش)

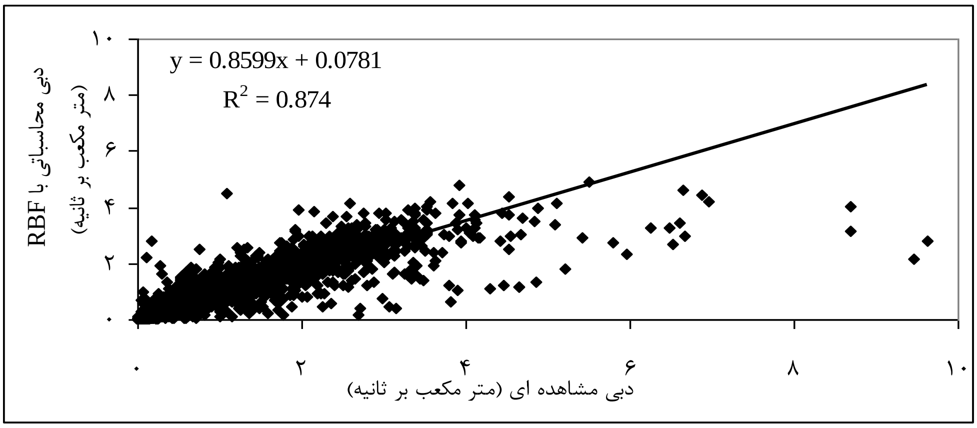

شکل ۸. همبستگی دبی روزانهٔ مشاهده‌ای و پیش‌بینی شده در سطح معنی‌داری یک درصد به روش شبکهٔ عصبی RBF حوزهٔ آبخیز امامه بر حسب ساختار ۵۴ برای سال‌های ۱۳۴۹-۱۳۵۰ تا ۱۳۸۲-۱۳۸۳ (آموزش)

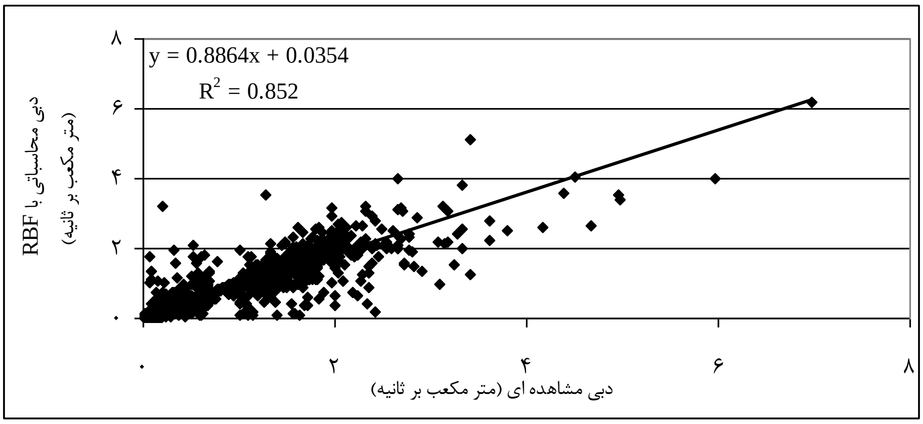

شکل ۹. همبستگی دبی روزانهٔ مشاهده‌ای و پیش‌بینی شده در سطح معنی‌داری یک درصد به روش شبکهٔ عصبی RBF حوزهٔ آبخیز امامه بر حسب ساختار ۵۴ برای سال‌های ۱۳۸۳-۱۳۸۴ تا ۱۳۹۰-۱۳۹۱ (آزمایش)

علاوه بر این با نگاهی به جدول ۵ و ۶ و با توجه به خطاهای مدل‌های موجود در پیش‌بینی جریان رودخانه با استفاده از روش‌های MLP و RBF مشخص می‌شود که در کل روش MLP دارای عملکرد بهتری نسبت به RBF بوده است که با نظرات [۱۳، ۲۴، ۲۵، ۲۸، ۴۱، ۴۲] هم‌راستا است. از طرفی دیگر عملکرد این نوع شبکهٔ عصبی نسبت به RBF دارای عملکرد بالاتری بوده که با نتایج [۱۰، ۲۹] مبنی بر دقت بالاتر MLP نسبت به RBF هم‌خوانی دارد اما با نظرات [۷] مبنی بر عملکرد ضعیف‌تر شبکه پرسپترون چندلایه نسبت به رگرسیون و همچنین با نظرات [۲] مبنی بر عملکرد بالاتر RBF نسبت به پرسپترون چندلایه هم‌خوانی ندارد. در نهایت با توجه به نتایج این تحقیق با توجه به مقیاس روزانه و در دورهٔ آماری ۴۲ ساله نشان داد که MLP دارای عمکرد بالاتری نسبت به RBF داشته و از طرفی از بین ۶۲ ساختار پیشنهادی مدلی که در آن هم از متغیرهای هواشناسی دما، رطوبت نسبی و تبخیر و تعرق بدون تأخیر و بارندگی و تأخیر آن تا ۲ روز و در نهایت از تأخیر دبی روزانهٔ رودخانه تا ۲ روز تأخیر و با ۸ ورودی از عملکرد بالاتری برخوردار بوده است و این مؤید دخالت دسته‌ای از عوامل در این رابطه دخیل می‌باشند و دلیل بر پیچیده بودن رابطهٔ بارش- رواناب و ارتباط درون پیوسته مجموعه‌ای از متغیرها را دارد. همچنین کم‌اهمیت‌ترین و با اهمیت ترین متغیر هواشناسی در این زمینه به ترتیب رطوبت نسبی و دما بوده است. علاوه بر این از دیگر یافته‌های این تحقیق بر عملکرد جریان‌های روز قبل (حداکثر تا دو روز قبل) بر روی جریان بر روی رواناب این حوزه نشان می‌دهد که نسبت به متغیرهای هواشناسی، متغیرهای آب‌سنجی دارای اهمیت بالاتری هستند و در کاهش خطای مدل سهم بالای دارند.

۵. سپاسگزاری

نویسندگان مقاله بر خود واجب می‌دانند از زحمات جناب آقای محمودی در راستای قرار دادن اطّلاعات و همکاری در جهت پیشبرد این تحقیق تشکر و قدردانی ویژه نمایند.

References

[1] Abrahart, R.J. and See, L.M. (2007). Neural network emulation of a rainfall-runoff model, Journal of Hydrology and Earth System Sciences. 4, 287–326.

[2] Akbarpour, M. and Shokrollahi, A. (2004). The use of artificial neural networks to estimate river flows, 1st National Congress of Civil Engineering, 11-12 May, Sharif University of Technology, Tehran, Iran, 8p.

[3] Alizadeh, A. (2003). Principles of Applied Hydrology, 16th edition, Imam Reza University Press, 815 p.

[4] Battachariya, B. and Solomatine, D.P. (2005). Neural networks and M_5 model trees in odeling water level–discharge relationship, Neurocomputing. 63 , 381–396.

[5] Behzad, M. Asghari, K. Eazi, M. and Palhang, M. (2009). Generalization performance of support vector machines and neural networks runoff modeling, Expert System with Applications, 36, 7624-7629.

[6] Cheng, C.T. Ou, C.P. and Chau, K.W. (2002). Combining a fuzzy optimal model with a genetic algorithm to solve multiobjective rainfall–runoff model calibration. Journal of Hydrology, 268 (1–4), 72–86.

[7] Chiang, J.L. and Yeh, C.H.(2010). Suspended sediment forecasting in Gao-Pen river using Artificial neural network, 12, 7532-7549.

[8] Danandehmehr, A. and Majdzadeh Tabatabai, M.R. (2010). The Prediction of daily discharge trend of river flow based on genetic programming, Journal of Water and Soil. 24(2), 325-333.

[9] Dawson, C.W. and Wilby, R.L.(2001). Hydrological modeling using artificial neural network, Progress in Physical Geography 25,1 (2001) pp. 80–108.

[10] Dehghani, A.A. Piri, M. Hesam, M. and Dehghani, N. (2010). Estimation of daily pan evaporation By using MLP, RBF and recuurent neural networks, Journal of Water and Soil Conservation, 17(2), pp. 49-67.

[11] Dibike, Y. and Solomatine, D. (2001). River flow forecasting using artificial neural networks. Journal of Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere 26, 1–8.

[12] Feiznia, S. Mohammad Asgari, H. and Moazzami M. (2008). Investigating the applicability of neural network method for estimating daily suspended sediment yield (Case study: Zard Drainage Basin, Khozestan Province), Journal of the Iranian Natural Resource, 60(4), 1199-1210.

[13] Food, I. and Kartman, N. (1996). Neural network in civil engineering: principal and understanding, Journal of computing in civil engineering, 8 (2): 131-148.

[14] Harun, S., Ahmatnor, N.I. and Kassim, A.H.M. (2002). Artificial neural network model for rainfall-runoff relationship, Journal Technology, 37(B) Dis. 2002: 1–12 © University Technology Malaysia.

[15] Hsu, K.L. Gupta, H.V. and Sorooshian, S. (1995). Artificial neural network modeling of therainfall-runoff process. Water Resources Research, 31 (10): 2517-2530.

[16] Huo, Z. Feng, S. Kang, S. Huang, G. Wang, F. and Guo, P. (2012). Integrated neural networks for monthly river flow estimation in arid inland basin of Northwest China, Journal of Hydrology, 420–421 (2012) 159–170.

[17] Jafari, M. Vafakhah, M. Abghari, H. and Tavasoli, A. (2012). Storm runoff coefficient forecasting using neural networks in Neyshaboor Arieh watershed, Journal of ecosystems Iran, 2(3), pp. 85-97.

[18] Jirak, G.H. Doneker, R.L. and Hinston, S.W. (1996). User's Manual for Cormix:A Hydrodynamic Mixing Zone Model and Decision Support System forPollutant Discharge into Surface Waters", Office of Science and TechnologyUS-EPA, Washington, DC 20460. 46p.

[19] Karamouz, M. and Araghinejad, SH. (2005). Advanced Hydrology, Amirkabir University of Technology press, 480p.

[20] Kisi, O. (2006). Daily pan evaporation odeling using a neuro-fuzzy computingtechnique. Journal of Hydrology. 329; 636-646.

[21] Legates, D.R. and McCabe, G.J. (1999). Evaluating the use of 'goodness-of-fit' measures in hydrologic and hydroclimatic model validation. Water Resources Research, 35, 233–41.

[22] Li, X.Y. Chau, K.W. Cheng, C.T. and Li, Y.S. (2006). A web-based flood forecasting system for Shuangpai region. Advanced Engineering Software Journal, 37 (3), 146–158.

[23] Mahdavi, M. (2002). Applied Hydrology, Fourth edition, University of Tehran press, 364p.

[24] Melesse, A.M. Ahmad, S. McClain, ME. Wang, X. and Lim, YH. (2011). Suspended sediment load prediction of river systems: An Artificial Neural Networks Approach, Agricultural Water Management 98(5): 855-866.

[25] Mendez Maria, C. Wenceslao, G. Manuel P.F. José Manuel, L.P. and Roman, L. (2004). Modelling of the monthly and daily behavior of the runoff of the Xallas river using Box-Jenkins and neural networks methods. Journal of Hydrology, ISSN 0022-1694, CODEN JHYDA7.

[26] Menhaj, M.B. (2002). Fundamentals of Artificial neutal networks, Amirkabir University of Technology press, 715p.

[27] Moatamednia, M. Sadeghi, S.H.R. Moradi, H.R. and Asadi, H. (2010). Evaluation of different modeling procedures in unit hydrograph-hyetograph relationship, Journal of Science and Technology of Agriculture and Natural Resources, Water and Soil Science, 14(52), pp. 27-36.

[28] Motamednia, M. Nohegar, A. Malekian, A. Asadi, H. Tavasoli, A. Safari, M. and Karimi Zarchi, K. (2015). Daily river flow forecasting in a semi-arid region using two data- driven, Desert, 20-1: 11-21.

[29] Murat, A. and Cigizoglu, H.K. (2007). Suspended sediment load simulation by two artificial neural network methods using hydrometeorological data, Environmental Modelling Software Vol. 22, 2-13.

[30] Noori, N. and Kalin, L. (2016). Coupling SWAT and ANN models for enhanced daily streamflow prediction, Journal of Hydrology, 533: 141–151.

[31] Rahimikhoob, A. and Mahmoodi, A. (2012). Estimating actual evapotranspiration in a catchment using artificial neural networks with minimum climatic data case study: Emame Representative Catchment, Iran-Water Resources Research, 7(4), pp. 51-61.

[32] Ripley, B.D. (1996). Neural network and related methods of classification, Journal of royal statistical society, 56(3): 409-456.

[33] Salajegheh, A. Fathabadi, A. and Mahdavi, M. (2009). Investigation on the efficiency of neuro-fuzzy method and statistical models in simulation of rainfall-runoff processJournal of Range and Water shed Management, Iranian Journal of Natural Resources, 62 (1), pp.65-79.

[34] Sarangi, A. and Bhattacharya, A.K. (2005). Comparison of artificial neural network and regression models for sediment loss prediction from Banha watershed in India, Agricultural water management. 2005, 28(4), 373-385.

[35] Sharifi, A.R. Dinpashoh, Y. Fakheri-Fard, A. and Moghaddamnia, A.R. (2013). Optimum combination of variables for runoff simulation in Amameh Watershed using gamma test, Water and Soil Science, 23(4), pp. 59-72.

[36] Solaimani, K. (2009). Rainfall-runoff prediction based on artificial neural network (A Case Study: Jarahi Watershed), American-Eurasian Journal of Agriculture and Environment. Science, 5 (6): 856-865, 2009, ISSN 1818-6769.

[37] Solomatine, D. and Xue, Y. (2004). M5 model trees and neural networks: application to flood forecasting in the upper reach of the Huai River in China. Journal of Hydrology, Engeering, 9(6), 491–501.

[38] Song, X.M. (1996). Radial basis function networksfor empirical modeling of chemical process.MSc thesis, University of Helsinki (http://www.cs.Helsinki.FI/~xianming) (28January 1999).

[39] Sudheer, P.K. Gosain, A.K. and Ramasastri, K.S. (2002). A data driven algorithm for constructing Artificial Neural Network rainfall- runoff models, Journal of Hydrology, 16 (6), 1325–1330.

[40] Tao, W. Kailin, Y. and Yongxin, G. (2008). Application of artificial neural networksto forecasting ıce conditions of the Yellow River in the Inne r Mongolia reach, Journal of Hydrology, 13(9):811-816.

[41] Tokar, A.S. and Markus, M. (2000). Precipitation-Runoff Modeling using Artificial Neural Network and Conceptual Models, Journal of Hydrologic Engineering, 5(2):156-161.

[42] Valipour, M. Banihabib, M.E. and Behbahani, S.M.R. (2013). Comparison of the ARMA, ARIMA, and the autoregressive artificial neural network models in forecasting the monthly inflow of Dez dam reservoir, 476, 7 January 2013, 433–441.

[43] Varoonchotikul, P. (2003). Flood Forecasting using Artificial Neural Networks, vrije universiteit unesco-ihe Institute for Water Education, ISBN 90 5809 631 9, 116pp.

[44] Wolfs, V. and Willems, P. (2014). Development of discharge-stage curves affected by hysteresis using time varying models, model trees and neural networks, Environmental Modelling and Software. 55:107-119.

[45] Zhang, B. and Govindaraju, R.S. (2003). Geomorphology-based artificial neural networks (GANNs) for estimation of direct runoff over watersheds, Journal of Hydrology. 273 (1-4): 18-34.