

## پیش‌بینی رواناب با استفاده از مدل‌های هوشمند

محبوبه معتمدنیا<sup>۱</sup>، احمد نوحه‌گر<sup>۲</sup>، آرش ملکیان<sup>۳\*</sup>، مریم صابری<sup>۴</sup>، کمال کریمی<sup>۵</sup>

۱. دکتری علوم و مهندسی آبخیزداری

۲. استاد گروه آموزش، برنامه‌ریزی و مدیریت محیط زیست، دانشکده محیط زیست، دانشگاه تهران، کرج

۳. دانشیار گروه احیای مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج

۴. مدرس دانشگاه فنی و حرفه‌ای، یزد

۵. رئیس اداره منابع طبیعی شهرستان بافق

(تاریخ دریافت ۱۳۹۵/۱۱/۱۰؛ تاریخ تصویب ۱۳۹۶/۰۲/۳۰)

## چکیده

پیش‌بینی رواناب رودخانه‌ها به دلیل اهمیت زیاد آن در برنامه‌ریزی‌ها، بهره‌برداری از مخازن و همچنین مدیریت آب‌های سطحی همواره مورد توجه مسئولان، برنامه‌ریزان و مهندسان آب و منابع آبی بوده است. از طرفی، به دلیل تغییرات زمانی و مکانی موجود، روابط غیرخطی و عدم قطعیت و بسیاری از عوامل دیگر پیش‌بینی رابطه بارش- رواناب بسیار مشکل است، اما امروزه استفاده از سامانه‌های هوشمند در پیش‌بینی چنین پدیده‌های پیچیده‌ای می‌تواند مفید و مؤثر باشد. در این پژوهش سعی شده است با استفاده از داده‌های هواشناسی و هیدرومتری طی دوره زمانی ۱۳۴۹-۱۳۵۰ تا ۱۳۹۰-۱۳۹۱ رواناب در حوضه آبخیز امامه با استفاده از مدل‌های شبکه عصبی پرسپترون چندلایه، تابع پایه شعاعی و سیستم عصبی فازی تطبیقی تخمین زده شود. نتایج نشان داد از بین مدل‌های یادشده سیستم عصبی فازی تطبیقی عملکرد بسیار زیادی داشته است و به خوبی می‌تواند رواناب را پیش‌بینی کند به طوری که با توجه به خطاها ساختار ۵۴ با هشت ورودی شامل بارندگی و دبی تا تأخیر دو روز و دما، تبخیر و تعرق و رطوبت نسبی همان روز که دارای تابع عضویت گوسی و جداسازی از نوع خوشه‌ای با خطای MSE، RMSE و MAE به ترتیب ۰/۰۰۱، ۰/۰۲۵ و ۰/۰۰۸ در مرحله آموزش و ۰/۰۰۱، ۰/۰۲۶ و ۰/۰۰۸ در مرحله آزمایش به عنوان بهترین مدل حوضه امامه بوده است.

**کلیدواژگان:** حوضه آبخیز معرف امامه، رابطه بارش- رواناب، مدل‌های هوشمند.

## مقدمه

برنامه‌ریزی برای مهار و مدیریت سیلاب و رواناب‌ها و حفاظت از کیفیت و نیز بهره‌برداری مناسب از آنها مستلزم درک صحیح و دقیق از مدل‌سازی بارش-رواناب است. تا کنون روابط و الگوهای گوناگونی برای پیش‌بینی جریان رودخانه مانند انواع الگوهای بارش-رواناب، الگوهای سری زمانی و ترکیبی از آنها ارائه شده است که در بعضی موارد به دلیل عدم شناخت دقیق و پیچیدگی‌های عوامل تأثیرگذار در بسیاری از موارد نتایج با واقعیت تطابق ندارند و فاصله زیادی با یکدیگر دارند [۱]. یکی از روش‌های موجود در بین مدل‌های هوشمند، شبکه عصبی مصنوعی<sup>۱</sup> است که با یک ساختار ریاضی قادر به شناسایی و تشخیص روابط پیچیده غیرخطی بین ورودی و خروجی است. شبکه‌های عصبی مصنوعی، کاربردهای موفقیت‌آمیزی در زمینه‌های گوناگون از جمله مطالعات منابع آب به خصوص در زمینه‌های هیدرولوژیکی داشته‌اند، به طوری که پژوهشگران مختلف در نقاط مختلف از این روش استفاده کردند و نشان دادند شبکه عصبی نتایج رضایت‌بخشی دارد. یکی از روش‌های پرکاربرد استفاده‌شده، شبکه عصبی پرسپترون چندلایه<sup>۲</sup> است که در بسیاری از مسائل پیچیده ریاضی که به حل معادلات غیرخطی می‌انجامد، به‌سادگی استفاده می‌شود. علاوه بر روش MLP در این پژوهش از نوع تابع پایه شعاعی استفاده شده است که به‌واسطه آموزش سریع، قابلیت تعمیم‌بخشی و سادگی زیادی که دارد بسیار جالب است و زمانی که تعداد بردارهای ورودی زیاد باشد، بهترین کاربرد را دارد [۲ و ۳]. از دیگر روش‌های موجود در بین مدل‌های هوشمند، شبکه عصبی فازی تطبیقی<sup>۳</sup> است که از ترکیب منطق فازی<sup>۴</sup> و شبکه عصبی مصنوعی ایجاد شده که در زمینه منابع آبی کاربرد بسیاری داشته است. در ANFIS قوانین ثابت است و آنچه بهینه‌سازی می‌شود پارامترهای توابع عضویت است که توسط شبکه عصبی و با استفاده از الگوریتم‌های آموزشی بهینه می‌شود. برای محاسبه توابع عضویت باید داده‌های ورودی تفکیک شوند که به دو روش خوشه‌ای و شبکه‌ای تقسیم می‌شوند. Nayak و همکارانش [۴] به‌منظور مدل‌سازی جریان رودخانه بایتارانی<sup>۵</sup>

در کشور هند از روش ANFIS، ANN و همچنین مدل آماری ARMA استفاده کردند. نتایج پژوهش ایشان نشان داد از بین روش‌های موجود ANFIS قابلیت بیشتری داشته است. Motamednia و همکارانش [۵] جریان روزانه رودخانه را با استفاده از شبکه‌های عصبی مصنوعی و ورودی‌هایی از قبیل بارندگی همان روز، یک تا پنج روز قبل و دبی همان روز و یک روز قبل در دوره زمانی ۱۹۵۱ تا ۲۰۰۶ (۵۵ سال) پیش‌بینی کردند. نتایج پژوهش آنها با توجه به آماره‌های ارزیابی ضمن برتری شبکه عصبی پرسپترون چندلایه بر تابع پایه شعاعی نشان داد در حوضه مطالعه‌شده بارندگی تا دو روز قبل و دبی تا یک روز قبل می‌تواند بر رواناب تأثیر داشته باشد. Kalin و Noori [۶] از مدل شبکه عصبی مصنوعی و SWAT<sup>۶</sup> به‌منظور پیش‌بینی روزانه جریان رودخانه در ۲۹ حوضه آبخیز نزدیک و اطراف آتلانتا<sup>۷</sup> در جنوب شرقی ایالات متحده استفاده کردند. با توجه به نتایج مدل‌های به‌دست‌آمده و خطاهای آنها هم شبکه عصبی مصنوعی و هم SWAT عملکرد خوبی به‌منظور پیش‌بینی جریان رودخانه داشتند و نتایج قابل قبولی ارائه دادند. Nabezadeh و همکارانش [۷] جریان رودخانه را با استفاده از ANFIS و FIS در حوضه آبخیز لیقوان‌چای در استان آذربایجان شرقی و با استفاده از داده‌های دبی روزانه به مدت شش سال پیش‌بینی کردند. نتایج پژوهش آنها نشان داد با توجه به پارامترهای آماری ANFIS قدرت بیشتری نسبت به FIS به خصوص در برآورد دبی‌های اوج داشته است. همان‌طور که از تحقیق مشخص می‌شود استفاده از مدل‌های هوشمند به دلیل قابلیت زیاد آنها در مهندسی منابع آب افزایش یافته و در مناطق مختلف به دلیل شرایط هیدرولوژیکی و جغرافیایی متفاوت نتایج متفاوتی نیز به‌دست آمده است. بنابراین، تحقیق حاضر تلاش دارد با استفاده از سامانه‌های هوشمند به‌عنوان روش‌های پیش‌بینی جریان رودخانه در حوضه‌های آبخیز معرف امامه به‌واسطه موقعیت جغرافیایی و داده‌های مناسب پردازد.

## مواد و روش‌ها

## منطقه مطالعه‌شده

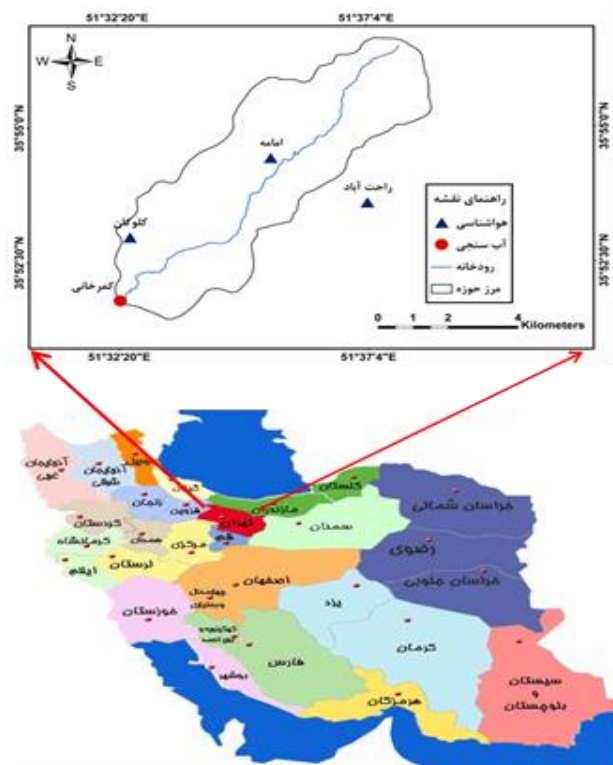
حوضه آبخیز معرف امامه در استان تهران با متوسط بارندگی ۷۵۶/۶۰ میلی‌متر در بین عرض‌های جغرافیایی ۳۵° ۵۱'۰۰"

6. Soil and Water Assessment Tool (SAWT)  
7. Atlanta

1. Artificial Neuron Network (ANN)  
2. Multi layer perceptron (MLP)  
3. Adaptive Neuro-Fuzzy Inference System (ANFIS)  
4. Fuzzy Inference System (FIS)  
5. Baitarani River

شاخه اصلی رودخانه جاجرود می‌پیوندد [۸]. شایان یادآوری است که به‌منظور انجام این تحقیق از داده‌های ایستگاه هواشناسی امامه در مرکز ثقل حوضه و ایستگاه هیدرومتری کمرخانی در خروجی حوضه به‌دلیل موقعیت ایستگاه‌ها و همچنین وجود داده‌های کامل استفاده شد. موقعیت ایستگاه‌های هواشناسی و هیدرومتری در شکل ۱ آورده شده است.

تا  $35^{\circ} 57' 00''$  شمالی و طول‌های جغرافیایی  $51^{\circ} 32' 00''$  تا  $51^{\circ} 39' 00''$  شرقی واقع شده است. حوضه آبخیز رودخانه امامه، یکی از سرشاخه‌های رودخانه جاجرود است که از ارتفاعات جنوبی دره لار سرچشمه می‌گیرد و در جهت شمال شرقی به جنوب غربی از میان حوضه عبور می‌کند و پس از عبور از روستاهای امامه و کلوکان در پایین‌دست روستای کلوکان (پس از عبور از ایستگاه هیدرومتری کمرخانی) به



شکل ۱. نمایی از موقعیت حوضه معرف امامه و ایستگاه‌های هواشناسی و هیدرومتری آن

تأخیرهای زمانی لازم متغیرهای ورودی با استفاده از نرم‌افزار Minitab 16 اقدام به همبستگی مقاطع در سطح معناداری  $0/05$  و  $0/01$  شده و در نهایت تعداد ۶۲ ساختار و مدل برای این تحقیق در نظر گرفته شده که در جدول ۲ آورده شده است. برای این تحقیق از سال‌های آبی  $1349-1350$  تا  $1382-1383$  به‌عنوان داده‌های آموزشی<sup>۲</sup> (۳۴ سال) و بالاخره از سال‌های آبی  $1383-1384$  تا  $1390-1391$  و برای اعتبارسنجی<sup>۳</sup> (هشت سال) انتخاب شده‌اند. بعد از تعیین ساختارهای مناسب برای پیش‌بینی رواناب کلیه داده‌ها قبل از ورود به نرم‌افزار استاندارد شدند و در محدوده صفر تا یک قرار

## روش کار

به‌منظور انجام تحقیق حاضر، داده‌های هیدرومتری و هواشناسی جمع‌آوری شدند و چنانچه نقص آماری داشتند با استفاده از ضریب همبستگی<sup>۱</sup> برطرف شد [۹]. در نهایت، دوره مشترک آماری  $1349-1350$  تا  $1390-1391$  برای کلیه متغیرهای تحقیق حاضر در نظر گرفته شد. به‌منظور پیش‌بینی رواناب در حوضه امامه از متغیرهای هواشناسی از قبیل داده‌های میانگین بارندگی روزانه (P)، داده‌های روزانه میانگین دما (T)، داده‌های روزانه میانگین تبخیر و تعرق (ET) داده‌های روزانه میانگین رطوبت نسبی (RH) و همچنین دبی‌های روزهای قبل (Q) استفاده شد. به‌منظور

2. Training  
3. Testing

1. Correlation Coefficient

فازی عصبی تطبیقی با استفاده از داده‌های هواشناسی و هیدرومتری و در قالب ۶۲ ساختار پیشنهادی انجام شده و در جدول ۱ نشان داده شده است.

در روش MLP تعداد نورون‌ها و لایه‌های پنهان به صورت سعی و خطا تعیین شده است. تعداد زیادی مدل برای این حوضه (بیش از ۱۰ هزار مدل) به دست آمد که با توجه به معیارهای ارزیابی یادشده بهترین مدل‌ها که خطای کمتری در پیش‌بینی رواناب داشتند، در جدول‌های ۲ و ۳ ارائه شدند. تعداد تکرار برای آموزش برابر با هزار، تابع انتقال سیگموئید و خطی به ترتیب برای لایه پنهان و خروجی، الگوریتم آموزشی به کاررفته لوببرگ مارکوارت و تعداد لایه پنهان یک، دو و سه لایه و تعداد نورون‌ها در لایه پنهان از یک تا ۳۰ در نظر گرفته شد.

گرفتند. در این تحقیق از تابع محرک غیرخطی سیگموئید برای لایه پنهان و از تابع خطی برای لایه خروجی استفاده شد [۱۰]. یکی از نکات مهم در روش ANFIS تعیین نوع و تعداد توابع عضویت است. تعداد و نوع توابع عضویت برای ورودی‌ها و خروجی به روش سعی و خطا تعیین می‌شود. به منظور گروه‌بندی داده‌های ورودی و خروجی از دو نوع روش جداسازی شبکه‌ای<sup>۱</sup> و خوشه‌ای<sup>۲</sup> استفاده می‌شود که هر دو نوع آن در این تحقیق به منظور مقایسه و دوری از پیش‌داوری استفاده شده و نتایج در جدول‌های ۲-۴ آورده شده است.

### نتایج و بحث

با توجه به روش کار یادشده و اهداف این تحقیق از شبکه‌های عصبی پرسپترون چندلایه، تابع پایه شعاعی و

جدول ۱. ساختارهای پیشنهادی حوضه آبخیز معرف امامه

شماره ساختار	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	$T_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	$Q_t$

ادامهٔ جدول ۱. ساختارهای پیشنهادی حوضهٔ آبخیز معرف امامه

شمارهٔ ساختار	ورودی	خروجی
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	$P_t, T_t, ET_t, RH_t, Q_{t-1}$	$Q_t$
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	$P_t, P_{t-1}, P_{t-2}, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}$	$Q_t$
۵۵	$P_t, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	$Q_t$
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	$P_t, P_{t-1}, P_{t-2}, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	$Q_t$

در روابط بالا  $Q_t$  دبی خروجی،  $P_t$  میانگین بارندگی،  $ET_t$  میانگین تبخیر و تعرق،  $RH_t$  میانگین رطوبت نسبی،  $T_t$  میانگین دما،  $Q_{t-1}$  دبی یک روز قبل،  $P_{t-1}$  میانگین بارندگی یک روز قبل،  $Q_{t-2}$  دبی دو روز قبل،  $P_{t-2}$  میانگین بارندگی دو روز قبل،  $Q_{t-3}$  دبی سه روز قبل،  $Q_{t-4}$  دبی چهار روز قبل،  $Q_{t-5}$  دبی پنج روز قبل،  $Q_{t-6}$  دبی شش روز قبل هستند.

جدول ۲. نتایج مدل‌های شبکه عصبی پرسپترون چندلایه در حوضه آبخیز امامه

شماره ساختار	آرایش شبکه			آموزش			اعتبارسنجی		
	شماره	لایه	نورون	MAE	RMSE	MSE	MAE	RMSE	MSE
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
۳۵	۶-۶-۹-۱			۰/۰۴	۰/۱۹	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۳۶	۶-۸-۱			۰/۰۴	۰/۲۰	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲
۳۷	۶-۱۰-۱۲-۱			۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۲	۰/۱۵	۰/۰۲
۳۸	۶-۵-۶-۱			۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۲	۰/۱۵	۰/۰۲
۳۹	۶-۷-۱۰-۱			۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۲	۰/۱۵	۰/۰۲
۴۰	۶-۸-۲-۱			۰/۰۴	۰/۲۱	۰/۰۶	۰/۰۲	۰/۱۵	۰/۰۲
۴۱	۶-۷-۵-۱			۰/۲۴	۰/۴۹	۰/۳۷	۰/۱۰	۰/۳۲	۰/۱۱
۴۲	۶-۱۰-۱۰-۱			۰/۰۴	۰/۱۹	۰/۰۵	۰/۰۲	۰/۱۴	۰/۰۲

ادامه جدول ۲. نتایج مدل‌های شبکه عصبی پرسپترون چندلایه در حوضه آبخیز امامه

شماره ساختار	آرایش شبکه			آموزش			اعتبارسنجی		
	MAE	RMSE	MSE	MAE	RMSE	MSE	MAE	RMSE	MSE
۴۳	۰/۰۹	۰/۲۶	۰/۰۷	۰/۱۰	۰/۲۸	۰/۰۸	۰/۰۹	۰/۲۶	۰/۰۷
۴۴	۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۰/۰۲	۰/۱۴	۰/۰۲
۴۵	۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۰/۰۲	۰/۱۴	۰/۰۲
۴۶	۰/۰۲	۰/۱۵	۰/۰۲	۰/۰۶	۰/۲۱	۰/۰۴	۰/۰۲	۰/۱۵	۰/۰۲
۴۷	۰/۰۲	۰/۱۵	۰/۰۳	۰/۰۶	۰/۲۱	۰/۰۴	۰/۰۲	۰/۱۵	۰/۰۳
۴۸	۰/۰۲	۰/۱۶	۰/۰۳	۰/۰۶	۰/۲۱	۰/۰۴	۰/۰۲	۰/۱۶	۰/۰۳
۴۹	۰/۰۲	۰/۱۵	۰/۰۲	۰/۰۶	۰/۲۱	۰/۰۴	۰/۰۲	۰/۱۵	۰/۰۲
۵۰	۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۱۹	۰/۰۴	۰/۰۲	۰/۱۴	۰/۰۲
۵۱	۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۱۹	۰/۰۳	۰/۰۲	۰/۱۴	۰/۰۲
۵۲	۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۰/۰۲	۰/۱۴	۰/۰۲
۵۳	۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۰/۰۲	۰/۱۴	۰/۰۲
۵۴	۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۴	۰/۱۸	۰/۰۳	۰/۰۲	۰/۱۴	۰/۰۲
۵۵	۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۰/۰۲	۰/۱۴	۰/۰۲
۵۶	۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۰/۰۲	۰/۱۴	۰/۰۲
۵۷	۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۱۹	۰/۰۳	۰/۰۲	۰/۱۴	۰/۰۲
۵۸	۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۰/۰۲	۰/۱۴	۰/۰۲
۵۹	۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۱۹	۰/۰۴	۰/۰۲	۰/۱۴	۰/۰۲
۶۰	۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۰/۰۲	۰/۱۴	۰/۰۲
۶۱	۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۱۹	۰/۰۴	۰/۰۲	۰/۱۴	۰/۰۲
۶۲	۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۰/۰۲	۰/۱۴	۰/۰۲

جدول ۳. نتایج مدل‌های شبکه عصبی تابع پایه شعاعی در حوضه آبخیز امامه

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


ادامه جدول ۳. نتایج مدل‌های شبکه عصبی تابع پایه شعاعی در حوضه آبخیز امامه

شماره ساختار	آرایش شبکه			آموزش			اعتبارسنجی			
	شماره	MSE	RMSE	MAE	MSE	RMSE	MAE	MSE	RMSE	MAE
۲۲	۴-۴۲-۱	۰/۰۶	۰/۲۵	۰/۰۸	۰/۱۱	۰/۳۲	۰/۱۱	۰/۱۱	۰/۳۲	۰/۱۱
۲۳	۴-۴۰-۱	۰/۰۶	۰/۲۵	۰/۰۸	۰/۱۱	۰/۳۳	۰/۱۱	۰/۱۱	۰/۳۳	۰/۱۱
۲۴	۴-۴۷-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰	۰/۱۰	۰/۳۱	۰/۱۰
۲۵	۴-۴۸-۱	۰/۴۳	۰/۶۶	۰/۴۶	۰/۵۰	۰/۷۱	۰/۵۰	۰/۵۰	۰/۷۱	۰/۵۲
۲۶	۴-۴۷-۱	۰/۰۸	۰/۲۸	۰/۱۰	۰/۱۴	۰/۳۷	۰/۱۴	۰/۱۴	۰/۳۷	۰/۱۳
۲۷	۵-۴۹-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۲	۰/۱۰	۰/۱۰	۰/۳۲	۰/۱۱
۲۸	۵-۴۰-۱	۰/۰۶	۰/۲۴	۰/۰۸	۰/۱۰	۰/۳۲	۰/۱۰	۰/۱۰	۰/۳۲	۰/۱۱
۲۹	۵-۳۹-۱	۰/۰۶	۰/۲۵	۰/۰۹	۰/۱۱	۰/۳۳	۰/۱۱	۰/۱۱	۰/۳۳	۰/۱۱
۳۰	۵-۴۵-۱	۰/۰۶	۰/۲۵	۰/۰۹	۰/۱۱	۰/۳۳	۰/۱۱	۰/۱۱	۰/۳۳	۰/۱۱
۳۱	۵-۴۴-۱	۰/۰۶	۰/۲۵	۰/۰۹	۰/۱۱	۰/۳۳	۰/۱۱	۰/۱۱	۰/۳۳	۰/۱۱
۳۲	۵-۴۸-۱	۰/۰۶	۰/۲۵	۰/۰۹	۰/۱۱	۰/۳۳	۰/۱۱	۰/۱۱	۰/۳۳	۰/۱۱
۳۳	۵-۴۹-۱	۰/۰۶	۰/۲۵	۰/۰۸	۰/۱۱	۰/۳۲	۰/۱۱	۰/۱۱	۰/۳۲	۰/۱۱
۳۴	۵-۵۵-۱	۰/۰۹	۰/۳۰	۰/۱۰	۰/۱۵	۰/۳۹	۰/۱۵	۰/۱۵	۰/۳۹	۰/۱۴
۳۵	۶-۵۶-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰	۰/۱۰	۰/۳۱	۰/۱۰
۳۶	۶-۵۷-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰	۰/۱۰	۰/۳۱	۰/۱۱
۳۷	۶-۵۷-۱	۰/۰۶	۰/۲۵	۰/۰۹	۰/۱۲	۰/۳۵	۰/۱۲	۰/۱۲	۰/۳۵	۰/۱۲
۳۸	۶-۵۸-۱	۰/۰۶	۰/۲۵	۰/۰۹	۰/۱۳	۰/۳۵	۰/۱۳	۰/۱۳	۰/۳۵	۰/۱۲
۳۹	۶-۴۷-۱	۰/۰۶	۰/۲۶	۰/۰۹	۰/۱۳	۰/۳۶	۰/۱۳	۰/۱۳	۰/۳۶	۰/۱۳
۴۰	۶-۴۹-۱	۰/۰۶	۰/۲۵	۰/۰۹	۰/۱۲	۰/۳۴	۰/۱۲	۰/۱۲	۰/۳۴	۰/۱۲
۴۱	۶-۴۰-۱	۰/۳۶	۰/۶۰	۰/۴۱	۰/۵۰	۰/۷۱	۰/۵۰	۰/۵۰	۰/۷۱	۰/۵۱
۴۲	۶-۳۹-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰	۰/۱۰	۰/۳۱	۰/۱۰
۴۳	۶-۴۵-۱	۰/۱۱	۰/۳۳	۰/۱۱	۰/۱۶	۰/۴۰	۰/۱۶	۰/۱۶	۰/۴۰	۰/۱۴
۴۴	۷-۴۴-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰	۰/۱۰	۰/۳۱	۰/۱۰
۴۵	۷-۴۸-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰	۰/۱۰	۰/۳۱	۰/۱۰
۴۶	۷-۴۹-۱	۰/۰۷	۰/۲۶	۰/۰۹	۰/۱۳	۰/۳۶	۰/۱۳	۰/۱۳	۰/۳۶	۰/۱۳
۴۷	۷-۵۵-۱	۰/۰۷	۰/۲۶	۰/۰۹	۰/۱۳	۰/۳۶	۰/۱۳	۰/۱۳	۰/۳۶	۰/۱۳
۴۸	۷-۵۶-۱	۰/۰۷	۰/۲۶	۰/۰۹	۰/۱۳	۰/۳۶	۰/۱۳	۰/۱۳	۰/۳۶	۰/۱۳
۴۹	۷-۵۷-۱	۰/۰۶	۰/۲۶	۰/۰۹	۰/۱۳	۰/۳۶	۰/۱۳	۰/۱۳	۰/۳۶	۰/۱۳
۵۰	۷-۵۷-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰	۰/۱۰	۰/۳۱	۰/۱۰
۵۱	۷-۵۸-۱	۰/۰۵	۰/۲۲	۰/۰۸	۰/۰۹	۰/۳۱	۰/۰۹	۰/۰۹	۰/۳۱	۰/۱۰
۵۲	۸-۴۷-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰	۰/۱۰	۰/۳۱	۰/۱۰
۵۳	۸-۴۹-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰	۰/۱۰	۰/۳۱	۰/۱۰
۵۴	۸-۴۰-۱	۰/۰۴	۰/۲۰	۰/۰۸	۰/۰۹	۰/۳۰	۰/۰۹	۰/۰۹	۰/۳۰	۰/۱۰
۵۵	۸-۳۹-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰	۰/۱۰	۰/۳۱	۰/۱۰
۵۶	۹-۴۵-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰	۰/۱۰	۰/۳۱	۰/۱۰
۵۷	۹-۴۴-۱	۰/۰۵	۰/۲۲	۰/۰۸	۰/۰۹	۰/۳۱	۰/۰۹	۰/۰۹	۰/۳۱	۰/۱۰
۵۸	۹-۴۸-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰	۰/۱۰	۰/۳۱	۰/۱۰
۵۹	۱۰-۴۹-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰	۰/۱۰	۰/۳۱	۰/۱۰
۶۰	۱۰-۵۵-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰	۰/۱۰	۰/۳۱	۰/۱۰
۶۱	۱۱-۵۶-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰	۰/۱۰	۰/۳۱	۰/۱۰
۶۲	۱۲-۵۷-۱	۰/۰۵	۰/۲۳	۰/۰۸	۰/۱۰	۰/۳۱	۰/۱۰	۰/۱۰	۰/۳۱	۰/۱۰


جریان تا دو روز بیشترین تأثیر را روی جریان داشته‌اند و تأخیر روزهای سوم و چهارم جریان تأثیر چندانی روی پیش‌بینی رودخانه یادشده نداشته‌اند (شکل‌های ۲ و ۳).

با توجه به جدول‌های ۲ و ۳ بهترین ساختار (۵۴) که در آن از متغیرهای بارندگی، تأخیر بارندگی تا دو روز، دما، تبخیر و تعرق، رطوبت نسبی و همچنین میزان تأخیرهای





شکل ۲. نمودار دبی روزانه مشاهده‌ای و پیش‌بینی شده با MLP در حوضه آبخیز امامه بر حسب ساختار ۴-۵۴ برای سال‌های ۱۳۴۹-۱۳۵۰ (آموزش)




شکل ۳. نمودار دبی روزانه مشاهده‌ای و پیش‌بینی شده با MLP در حوضه آبخیز امامه بر حسب ساختار ۴-۵۱ برای سال‌های ۱۳۸۳-۱۳۸۴ (آزمایش)

خروجی استفاده شده است چرا که مشتق این تابع بر حسب مقدار خود تابع قابل بیان است. با توجه به نتایج RBF مشخص می‌شود که در این روش خطاهای مدل‌ها بیشتر از مقداری است که MLP برآورد کرده و تأیید می‌کند که در این نوع روش نیز همانند MLP مدل‌هایی که در آن فقط از یک متغیر به‌عنوان ورودی استفاده شده، خطای زیادتری نسبت به دیگر مدل‌ها داشته‌اند. به‌طوری که در بین متغیرهای هواشناسی رطوبت نسبی با آرایش ۱-۳-۱ و میزان خطای ۰/۴۹، ۰/۷۰ و ۰/۵۱ در مرحله آموزش، ۰/۵۶، ۰/۷۵ و ۰/۶۰ در مرحله آزمایش برای معیارهای ارزیابی به‌ترتیب شامل MSE، RMSE و MAE بوده است. در RBF ساختار ۵۴ نیز همانند روش قبلی دارای عملکرد بهتر با آرایش ۱-۴۰-۸ و میزان خطای ۰/۰۴، ۰/۲۰ و ۰/۰۸ در مرحله آموزش، ۰/۰۹، ۰/۳۰ و ۰/۱۰ در مرحله آزمایش برای معیارهای ارزیابی یادشده (شکل‌های ۴ و ۵) و بعد از آن ساختار ۵۷ با اندک اختلاف به‌عنوان مدل‌های خوبی شناخته


یکی از موارد شایان یادآوری این است که از مشکلات و ضعف‌های ANN ناتوانی آنها در برون‌یابی داده‌هاست. به‌طوری که چنانچه بیشترین میزان عددی داده‌های آزمایش از بیشترین میزان داده‌های آموزش بیشتر باشد، این روش نمی‌تواند آن را به‌خوبی تخمین بزند چرا که شبکه‌های عصبی مصنوعی به‌اصطلاح زندانی و محصور داده‌های آموزش خود هستند [۱۱]، اما به‌منظور حل این مشکل طبق نظر Kia [۲]، Yosefi و همکارانش [۳] و همچنین Kaastra و Boyd [۱۲] می‌توان این مشکل را با استفاده از تابع محرک سیگموئید و خطی به‌ترتیب در لایه پنهان و خروجی به‌دلیل ساختار ریاضی که دارند، حل کرد. در صورت استفاده از تابع سیگموئید در لایه خروجی، خروجی شبکه به مقدار کوچکی محدود می‌شود در حالی که در صورت استفاده از تابع محرک خطی، خروجی می‌تواند هر مقداری را اختیار کند. برای همین در تحقیق حاضر از تابع محرک سیگموئید به‌عنوان تابع محرک در لایه پنهان و تابع محرک خطی در لایه

این، با نگاهی به نتایج مربوط به RBF می‌توان دریافت که به‌طور متوسط و تقریبی (در نظر گرفتن بعضی موارد عکس) هرچه تعداد ورودی‌ها افزایش می‌یابد، تعداد نورون‌های لایه پنهان نیز زیاد می‌شود به‌طوری‌که در ساختار ۶۲ که بیشترین میزان ورودی (۱۲ ورودی) را دارد، تعداد نورون‌های لایه پنهان به ترتیب به ۵۹ نورون می‌رسد و نشان می‌دهد که با افزایش ورودی‌ها که خود سبب افزایش پیچیدگی مدل است، لایه پنهان با افزایش تعداد نورون‌ها سعی در افزایش ارتباط بین نورون‌های خود دارد و این پیچیدگی را تا حدی با افزایش تعداد نورون جبران می‌کند. از طرفی، RBF بر خلاف MLP که می‌تواند تعداد مختلفی لایه پنهان داشته باشد، این روش فقط یک لایه پنهان داشت که همین مسئله سبب شده است که انجام این روش با استفاده از تعداد نورون بیشتر سرعت زیادتری نسبت به MLP داشته باشد که پژوهشگران دیگری [۲، ۳، ۵، ۱۶ و ۱۸] نیز آن را تأکید کرده‌اند.

شده‌اند. اگرچه در بیشتر مقالات و پژوهش‌هایی که از شبکه عصبی مصنوعی استفاده می‌کنند فقط روش MLP را به کار می‌برند [۶ و ۱۳-۱۵] به‌طوری‌که Dawson و Wilby [۱۶] طی تحقیقی نشان دادند ۸۹ درصد پژوهش‌ها فقط از این نوع شبکه عصبی مصنوعی استفاده کرده‌اند، در این پژوهش سعی شد از هر دو نوع شبکه عصبی استفاده شود. هر چند که بر اساس نتایج به‌دست‌آمده مشخص شد که در کل MLP عملکرد بهتری نسبت به RBF داشته است که با نظرات Tokar و Markus [۱۷]، Dibike و Solomatine [۱۸]، Mendez و همکارانش [۱۹]، Melesse و همکارانش [۲۰] هم‌راستاست، RBF هم عملکرد خوبی داشته و با اینکه عصبی MLP اختلاف زیادی نداشته است و با توجه به اینکه یک لایه پنهان و سرعت زیادی دارد، می‌تواند در پژوهش‌ها به‌خصوص در زمینه‌های هیدرولوژی و با توجه به پیچیدگی‌های حاکم بر داده‌های آن استفاده شود. علاوه بر



شکل ۴. نمودار دبی روزانه مشاهده‌ای و پیش‌بینی‌شده به روش RBF حوضه آبخیز امامه بر حسب ساختار ۵۴ برای سال‌های ۱۳۴۹-۱۳۵۰ (آموزش)



شکل ۵. نمودار دبی روزانه مشاهده‌ای و پیش‌بینی‌شده به روش RBF حوضه آبخیز امامه بر حسب ساختار ۵۴ برای سال‌های ۱۳۸۳-۱۳۹۰ (آزمایش)

در مدل‌های ANFIS و از نوع جداسازی شبکه‌ای از تابع عضویت گوسی و برای جداسازی از نوع شبکه‌ای از توابع عضویت زنگوله‌ای شکل، گوسی، گوسی ۲ یا گوسی ترکیبی، مثلی و با تعداد تکرار برابر با ۳۰۰ و تعداد بهینه قوانین نیز به صورت سعی و خطا بین ۲ تا ۱۰ متغیر استفاده شد که نتایج آن در جدول ۴ ارائه شده است.

جدول ۴. نتایج پیش‌بینی شبکه عصبی - فازی تطبیقی در حوضه آبخیز امامه

شماره ساختار	نوع جداسازی	تابع عضویت	آموزش			اعتبارسنجی		
			MAE	RMSE	MSE	MAE	RMSE	MSE
۱	شبکه‌ای	گوسی	۰/۰۱۵	۰/۰۸۴	۰/۰۰۷	۰/۰۱۶	۰/۰۸۹	۰/۰۰۸
۲	خوشه‌ای	گوسی	۰/۰۱۶	۰/۰۸۹	۰/۰۰۸	۰/۰۱۶	۰/۰۹۵	۰/۰۰۹
۳	شبکه‌ای	زنگوله‌ای	۰/۰۱۶	۰/۰۹۵	۰/۰۰۹	۰/۰۱۷	۰/۱۰۰	۰/۰۱۰
۴	خوشه‌ای	گوسی	۰/۰۱۵	۰/۰۷۷	۰/۰۰۶	۰/۰۱۵	۰/۰۸۴	۰/۰۰۷
۵	شبکه‌ای	گوسی ۲	۰/۰۱۳	۰/۰۶۶	۰/۰۰۴	۰/۰۱۳	۰/۰۶۳	۰/۰۰۴
۶	شبکه‌ای	زنگوله‌ای	۰/۰۱۵	۰/۰۷۷	۰/۰۰۶	۰/۰۱۵	۰/۰۷۷	۰/۰۰۶
۷	خوشه‌ای	گوسی	۰/۰۱۱	۰/۰۴۶	۰/۰۰۲	۰/۰۱۲	۰/۰۵۵	۰/۰۰۳
۸	شبکه‌ای	گوسی ۲	۰/۰۱۱	۰/۰۴۷	۰/۰۰۲	۰/۰۱۳	۰/۰۶۳	۰/۰۰۴
۹	شبکه‌ای	گوسی	۰/۰۱۱	۰/۰۴۸	۰/۰۰۲	۰/۰۱۳	۰/۰۶۳	۰/۰۰۴
۱۰	شبکه‌ای	گوسی ۲	۰/۰۱۰	۰/۰۴۳	۰/۰۰۲	۰/۰۱۲	۰/۰۵۵	۰/۰۰۳
۱۱	شبکه‌ای	مثلی	۰/۰۱۳	۰/۰۵۷	۰/۰۰۳	۰/۰۱۳	۰/۰۶۳	۰/۰۰۴
۱۲	شبکه‌ای	گوسی ۲	۰/۰۱۴	۰/۰۷۳	۰/۰۰۵	۰/۰۱۴	۰/۰۷۱	۰/۰۰۵
۱۳	شبکه‌ای	گوسی ۲	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱	۰/۰۱۰	۰/۰۳۳	۰/۰۰۱
۱۴	شبکه‌ای	گوسی ۲	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱	۰/۰۱۱	۰/۰۴۵	۰/۰۰۲
۱۵	خوشه‌ای	گوسی	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱	۰/۰۱۱	۰/۰۴۵	۰/۰۰۲
۱۶	شبکه‌ای	زنگوله‌ای	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱	۰/۰۱۱	۰/۰۴۵	۰/۰۰۲
۱۷	شبکه‌ای	مثلی	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱	۰/۰۱۱	۰/۰۴۵	۰/۰۰۲
۱۸	خوشه‌ای	گوسی	۰/۰۱۳	۰/۰۵۷	۰/۰۰۳	۰/۰۱۳	۰/۰۶۳	۰/۰۰۴
۱۹	شبکه‌ای	گوسی ۲	۰/۰۱۰	۰/۰۴۲	۰/۰۰۱	۰/۰۱۲	۰/۰۵۵	۰/۰۰۳
۲۰	شبکه‌ای	گوسی	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱	۰/۰۱۱	۰/۰۴۵	۰/۰۰۲
۲۱	شبکه‌ای	گوسی ۲	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱	۰/۰۱۱	۰/۰۴۵	۰/۰۰۲
۲۲	شبکه‌ای	مثلی	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱	۰/۰۱۱	۰/۰۴۵	۰/۰۰۲
۲۳	خوشه‌ای	گوسی	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱	۰/۰۱۱	۰/۰۴۵	۰/۰۰۲
۲۴	شبکه‌ای	مثلی	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱
۲۵	شبکه‌ای	گوسی ۲	۰/۰۱۴	۰/۰۷۴	۰/۰۰۵	۰/۰۱۴	۰/۰۷۱	۰/۰۰۵
۲۶	شبکه‌ای	مثلی	۰/۰۱۴	۰/۰۷۱	۰/۰۰۵	۰/۰۱۳	۰/۰۶۴	۰/۰۰۴
۲۷	شبکه‌ای	مثلی	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱
۲۸	خوشه‌ای	گوسی	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱
۲۹	خوشه‌ای	گوسی	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱	۰/۰۱۱	۰/۰۴۵	۰/۰۰۲
۳۰	خوشه‌ای	گوسی	۰/۰۰۹	۰/۰۳۴	۰/۰۰۱	۰/۰۱۱	۰/۰۴۵	۰/۰۰۲
۳۱	شبکه‌ای	مثلی	۰/۰۰۹	۰/۰۳۴	۰/۰۰۱	۰/۰۱۱	۰/۰۴۵	۰/۰۰۲
۳۲	خوشه‌ای	گوسی	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱	۰/۰۱۱	۰/۰۴۵	۰/۰۰۲
۳۳	شبکه‌ای	زنگوله‌ای	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱	۰/۰۱۱	۰/۰۴۵	۰/۰۰۲
۳۴	خوشه‌ای	گوسی	۰/۰۱۴	۰/۰۷۲	۰/۰۰۵	۰/۰۱۳	۰/۰۶۵	۰/۰۰۴
۳۵	خوشه‌ای	گوسی	۰/۰۰۹	۰/۰۳۰	۰/۰۰۱	۰/۰۰۹	۰/۰۳۲	۰/۰۰۱
۳۶	خوشه‌ای	گوسی	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱	۰/۰۰۹	۰/۰۳۳	۰/۰۰۱
۳۷	خوشه‌ای	گوسی	۰/۰۱۰	۰/۰۳۶	۰/۰۰۱	۰/۰۱۲	۰/۰۵۵	۰/۰۰۳
۳۸	شبکه‌ای	زنگوله‌ای	۰/۰۱۰	۰/۰۴۲	۰/۰۰۱	۰/۰۱۲	۰/۰۵۵	۰/۰۰۳
۳۹	شبکه‌ای	گوسی ۲	۰/۰۱۰	۰/۰۴۳	۰/۰۰۲	۰/۰۱۲	۰/۰۵۵	۰/۰۰۳

ادامه جدول ۴. نتایج پیش‌بینی شبکه عصبی - فازی تطبیقی در حوضه آبخیز امامه

شماره ساختار	نوع جداسازی	تابع عضویت	آموزش			اعتبارسنجی		
			MAE	RMSE	MSE	MAE	RMSE	MSE
۴۰	خوشه‌ای	گوسی	۰/۰۰۱	۰/۰۳۵	۰/۰۰۹	۰/۰۰۳	۰/۰۵۵	۰/۰۱۲
۴۱	خوشه‌ای	گوسی	۰/۰۰۵	۰/۰۷۳	۰/۰۱۴	۰/۰۰۵	۰/۰۷۱	۰/۰۱۴
۴۲	شبکه‌ای	گوسی	۰/۰۰۱	۰/۰۳۲	۰/۰۰۹	۰/۰۰۱	۰/۰۳۲	۰/۰۰۹
۴۳	خوشه‌ای	گوسی	۰/۰۰۱	۰/۰۳۳	۰/۰۰۹	۰/۰۰۲	۰/۰۴۵	۰/۰۱۱
۴۴	خوشه‌ای	گوسی	۰/۰۰۱	۰/۰۳۳	۰/۰۰۹	۰/۰۰۱	۰/۰۳۳	۰/۰۰۹
۴۵	خوشه‌ای	گوسی	۰/۰۰۱	۰/۰۳۳	۰/۰۰۹	۰/۰۰۱	۰/۰۳۳	۰/۰۰۹
۴۶	خوشه‌ای	گوسی	۰/۰۰۱	۰/۰۳۵	۰/۰۰۹	۰/۰۰۳	۰/۰۵۵	۰/۰۱۲
۴۷	شبکه‌ای	مثلثی	۰/۰۰۱	۰/۰۳۵	۰/۰۰۹	۰/۰۰۳	۰/۰۵۵	۰/۰۱۲
۴۸	شبکه‌ای	مثلثی	۰/۰۰۱	۰/۰۳۶	۰/۰۱۰	۰/۰۰۳	۰/۰۵۵	۰/۰۱۲
۴۹	شبکه‌ای	مثلثی	۰/۰۰۱	۰/۰۳۵	۰/۰۰۹	۰/۰۰۳	۰/۰۵۵	۰/۰۱۲
۵۰	شبکه‌ای	مثلثی	۰/۰۰۱	۰/۰۲۹	۰/۰۰۸	۰/۰۰۱	۰/۰۲۹	۰/۰۰۸
۵۱	خوشه‌ای	گوسی	۰/۰۰۱	۰/۰۲۸	۰/۰۰۸	۰/۰۰۱	۰/۰۲۸	۰/۰۰۸
۵۲	خوشه‌ای	گوسی	۰/۰۰۱	۰/۰۳۲	۰/۰۰۹	۰/۰۰۱	۰/۰۳۲	۰/۰۰۹
۵۳	خوشه‌ای	گوسی	۰/۰۰۱	۰/۰۳۳	۰/۰۰۹	۰/۰۰۱	۰/۰۳۳	۰/۰۰۹
۵۴	خوشه‌ای	گوسی	۰/۰۰۱	۰/۰۲۵	۰/۰۰۸	۰/۰۰۱	۰/۰۲۶	۰/۰۰۸
۵۵	خوشه‌ای	گوسی	۰/۰۰۱	۰/۰۳۲	۰/۰۰۹	۰/۰۰۱	۰/۰۳۲	۰/۰۰۹
۵۶	خوشه‌ای	گوسی	۰/۰۰۱	۰/۰۳۲	۰/۰۰۹	۰/۰۰۱	۰/۰۳۳	۰/۰۰۹
۵۷	خوشه‌ای	گوسی	۰/۰۰۱	۰/۰۲۷	۰/۰۰۸	۰/۰۰۱	۰/۰۲۷	۰/۰۰۸
۵۸	خوشه‌ای	گوسی	۰/۰۰۱	۰/۰۳۲	۰/۰۰۹	۰/۰۰۱	۰/۰۳۲	۰/۰۰۹
۵۹	خوشه‌ای	گوسی	۰/۰۰۱	۰/۰۳۱	۰/۰۰۹	۰/۰۰۱	۰/۰۳۲	۰/۰۰۹
۶۰	خوشه‌ای	گوسی	۰/۰۰۱	۰/۰۳۲	۰/۰۰۹	۰/۰۰۱	۰/۰۳۲	۰/۰۰۹
۶۱	خوشه‌ای	گوسی	۰/۰۰۱	۰/۰۳۲	۰/۰۰۹	۰/۰۰۱	۰/۰۳۲	۰/۰۰۹
۶۲	خوشه‌ای	گوسی	۰/۰۰۱	۰/۰۳۲	۰/۰۰۹	۰/۰۰۱	۰/۰۳۲	۰/۰۰۹

شمار مشخصه‌ها در صورت افزایش تعداد ورودی‌ها) در جداسازی داده‌ها با افزایش تعداد ورودی‌های مدل و به‌اصطلاح پیچیده‌شدن ساختار ریاضی مدل از عملکرد آن کاسته شده به‌طوری که فرایند آموزش شبکه ساعت‌ها و حتی در بعضی مدل‌ها به‌خصوص با هفت نوع ورودی هفته‌ها طول کشیده شد. در حالی که در مدل‌های ANFIS با جداسازی خوشه‌ای عملکرد بهتری داشته است و علت این امر را می‌توان ناشی از ساختار این نوع جداسازی دانست که با خوشه‌کردن داده‌ها در لایه اول با افزایش تعداد ورودی‌ها، تعداد پارامترها افزایش پیدا نکرده و بنابراین با پیچیده‌تر شدن مدل به‌دلیل افزایش تعداد ورودی‌ها این نوع جداسازی سبب پیچیدگی مدل و افزایش خطاها نشده است که این یافته با نظرات Yosefi و همکارانش [۳] و Nabezadeh و همکارانش [۷]


با توجه به نتایج جدول ۴ مشخص شد که از ۶۲ ساختار پیشنهادی به‌ترتیب ۳۲ و ۳۰ مدل نهایی مربوط به جداسازی خوشه‌ای و شبکه‌ای بوده‌اند. همچنین از ۳۰ مدل که جداسازی شبکه‌ای داشته‌اند، به‌ترتیب ۱۱، ۱۰، ۵ و ۴ دارای توابع عضویت مثلثی، گوسی ۲ یا گوسی ترکیبی، زنگوله‌ای و گوسی بوده‌اند. علت عملکرد جداسازی شبکه‌ای به‌رغم توانایی کمتر می‌تواند ناشی از تنوع توابع عضویت به‌کاررفته باشد، اما نهایت تعداد ورودی قابل انجام هفت متغیر بود که هفته‌ها به طول انجامید. علاوه بر این، با افزایش تعداد ورودی‌ها، افزایش توابع عضویت نه‌تنها تأثیر مثبتی روی خطاها نداشته بلکه عملکرد آنها بدتر شده و جداسازی خوشه‌ای اثر بهتری داشته است. دلیل این امر را می‌توان چنین توجیه کرد که در جداسازی شبکه‌ای به‌دلیل ماهیتش (افزایش توانی

عضویت گوسی و جداسازی از نوع خوشه‌ای با خطای MSE، RMSE و MAE به ترتیب ۰/۰۰۱، ۰/۰۲۵ و ۰/۰۰۸ در مرحله آموزش و ۰/۰۰۱، ۰/۰۲۶ و ۰/۰۰۸ در مرحله آزمایش به‌عنوان بهترین ساختار در حوضه امامه بوده است (شکل‌های ۶ و ۷).


### نتیجه‌گیری

پژوهش حاضر با هدف تخمین جریان رودخانه با استفاده از داده‌های هواشناسی و هیدرومتری و با سه روش RBF، MLP و ANFIS در حوضه آبخیز معرف امامه انجام شد. نتایج این تحقیق نشان داد بهترین و بدترین عملکرد مدل‌ها به ترتیب مربوط به مدل‌های ANFIS و RBF بوده است. از

همراستاست چون در این حوضه وقتی تعداد ورودی‌ها بیشتر از هفت عدد می‌شود این نوع جداسازی می‌تواند مفید باشد. به هر صورت در هر دو نوع جداسازی ملاحظه شد که با افزایش قوانین فازی که به‌طبع متناسب با افزایش تعداد ورودی‌های مدل‌هاست، ANFIS از ساختار پیچیده‌تری استفاده کرده که سبب شده روند آموزش شبکه بسیار طول بکشد. علاوه بر این، نتایج نشان داد در حوضه امامه با افزایش تعداد ورودی‌ها، افزایش توابع عضویت نتایج بهتری داشتند که این یافته با نظرات Zounemat-Kermani و Teshnehlab [۲۱] هم‌راستا بوده است. با توجه به نتایج مدل‌های ANFIS حوضه آبخیز امامه ساختار ۵۴ با توجه به خطاها با هشت ورودی و تابع



شکل ۶. نمودار دبی روزانه مشاهده‌ای و پیش‌بینی شده به روش ANFIS حوضه آبخیز امامه بر حسب ساختار ۵۴ برای سال‌های ۱۳۴۹-۱۳۵۰ تا ۱۳۸۲-۱۳۸۳ (آموزش)



شکل ۷. نمودار دبی روزانه مشاهده‌ای و پیش‌بینی شده به روش ANFIS در حوضه آبخیز امامه بر حسب ساختار ۵۴ برای سال‌های ۱۳۸۳-۱۳۸۴ تا ۱۳۹۰-۱۳۹۱ (آزمایش)

- [10]. Imrie CE, Durucan S, Korre A. River flow prediction using artificial neural networks: generalisation beyond the calibration range, *J. of Hydrology*. 2000; 233: 138-153 pp.
- [11]. Food I, Kartman N. Neural network in civil engineering: principal and understanding, *J. of computing in civil engineering*. 1996; 8 (2): 131-148.
- [12]. Kaastra I, Boyd MS. Forecasting futures trading volume using neural networks, *The J. of Futures Markets*. 1995; 15(8): 953-970.
- [13]. Gharaei-Manesh S, Fathzadeh A, Taghizadeh-Mehrjardi R. Comparison of artificial neural network and decision tree models in estimating spatial distribution of snow depth in a semi-arid region of Iran, *Cold Regions Science and Technology*, 2016; 122: 26–35 pp.
- [14]. Kakaei Lafdani E, Moghaddamnia A, Ahmadi A. Daily suspended sediment load prediction using artificial neural networks and support vector machines, *J. of Hydrology*, 2013; 478: 50–62.
- [15]. Mahjouri N, Integrating support vector regression and a geomorphologic artificial neural network for daily rainfall-runoff modeling, *Applied Soft Computing*, 2014; 38: 329–345 pp.
- [16]. Dawson CW, Wilby R.L., 2001. Hydrological modeling using artificial neural network, *Progress in Physical Geography*. 2001; 25: 80–108.
- [17]. Tokar A S, Markus M. Precipitation rainfall-runoff modeling using artificial neural network and conceptual models, *J. of Hydrologic Engineering*. 2000; 5(2):156-161 pp.
- [18]. Dibike Y, Solomatine D. River flow forecasting using artificial neural networks. *J. of Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere*. 2001; 26: 1–8.
- [19]. Mendez MC, Wenceslao G, ManuelPF, José Manuel LP, Roman L. Modelling of the monthly and daily behaviour of the runoff of the Xallas river using Box-Jenkins and neural networks methods. *J. of Hydrology*. 2004; 1685-1694.
- [20]. Melesse AM, Ahmad S, McClain ME, Wang X, Lim YH. Suspended sediment load prediction of river systems: An Artificial Neural Networks Approach, *Agricultural Water Management*. 2011; 98(5): 855-866.
- [21]. Zounemat-Kermani M, Teshnehlab M. Using adaptive neuro-fuzzy inference system for hydrological time series prediction, *Applied Soft Computing*. 2008; 8(2): 928-936.

طرفی، از بین ۶۲ ساختار پیشنهادی مدلی که در آن هم از متغیرهای هواشناسی بدون تأخیر و از تأخیر آورد روزانه رودخانه تا دو تأخیر و با هشت ورودی عملکرد بیشتری داشته است و این تأییدکننده دخالت دسته‌ای از عوامل در این رابطه است و دلیل بر پیچیده‌بودن رابطه بارش-رواناب و ارتباط درون پیوسته مجموعه‌ای از متغیرها را دارد. علاوه بر این، از دیگر یافته‌های این تحقیق بر عملکرد جریان‌های روز قبل (حداکثر تا دو روز قبل) روی رواناب این حوضه نشان می‌دهد نسبت به متغیرهای هواشناسی، متغیرهای آب‌سنجی اهمیت بیشتر و در کاهش خطای مدل سهم زیادی دارند.

### منابع

- [1]. Danandehmehr A, Majdzadeh Tabatabai MR. Prediction of daily discharge trend of river flow based on genetic programming, *J. of Water and Soil*. 2010; 24 (2): 325-333. [In Persian].
- [2]. Kia SM. Soft computing using MATLAB, Kianrayaneh sabz press, 2011. P. 623. [In Persian].
- [3]. Yosefi M, Talebi A, Poorshareiati R. Application of artificial intelligence in water and soil sciences, Yaz University Press, 2014: P. 516. [In Persian].
- [4]. Nayak PC, Sudheer KP, Rangan, DM, Ramasastri KS. A neuro-fuzzy computing technique for modeling hydrological time series. *J. of Hydrology*. 2004; 29: 52–66.
- [5]. Motamednia M, Nohegar A, Malekian A, Asadi H, Tavasoli A, Safari M, Karimi Zarchi K. Daily river flow forecasting in a semi-arid region using two data-driven, *Desert*. 2015; 20-1: 11-2.
- [6]. Noori N, Kalin L, 2016. Coupling SWAT and ANN models for enhanced daily streamflow prediction, *J. of Hydrology*. 2016; 533: 141–151.
- [7]. Nabezadeh M, Mosaedi A, Hessam M, Dehghani AA, Zakerneya M, Holghi M, 2012. Investigating efficiency fuzzy logic to predict daily river flow, *Iran-Watershed Management Science & Engineering*. 2012; 5(17): 7-14. [In Persian].
- [8]. Nohegar A, Motamednia M, Malekian A. Daily river flood mrepresentative watershed, *Physical Geography Research Quarterly*. 2016; 48(3): 367-383. [In Persian].
- [9]. Mahdavi M, *Applied Hydrology*, First volume, fourth edition, Tehran university press, 2003: P. 364. [In Persian].