



## مدل سازی بارش - رواناب با استفاده از شبکه عصبی مصنوعی و شبکه فازی - عصبی تطبیقی در حوزه آبخیز کسلیان

نوبد دهقانی<sup>۱</sup>، مهدی وفاخواه<sup>۲</sup> و عبدالرضا بهره‌مند<sup>۳</sup>

۱- دانش‌آموخته کارشناسی ارشد، دانشگاه تربیت مدرس  
۲- دانشیار، دانشگاه تربیت مدرس، (نویسنده مسوول: vafakhah@modares.ac.ir)  
۳- دانشیار، دانشگاه علوم کشاورزی و منابع طبیعی گرگان  
تاریخ دریافت: ۹۱/۹/۱۴ تاریخ پذیرش: ۹۳/۹/۲۳

### چکیده

مدل سازی فرآیند بارش - رواناب و پیش‌بینی دبی رودخانه یک اقدام مهم در مدیریت و مهار سیلاب‌ها، طراحی سازه‌های آبی در حوزه‌های آبخیز و مدیریت خشکسالی است. هدف این تحقیق شبیه‌سازی جریان روزانه در حوزه آبخیز کسلیان با استفاده از شبکه عصبی مصنوعی و شبکه عصبی - فازی تطبیقی است. روش‌های هوشمند دارای قابلیت بالایی برای برقراری ارتباط بین داده‌های ورودی و خروجی می‌باشند. در این تحقیق از آمار بارش، تبخیر و دما ایستگاه هواشناسی سنگده که ورودی مدل‌ها و آمار دبی ایستگاه ولیک‌بن که خروجی مدل‌ها محسوب می‌شود طی سال‌های ۱۳۸۲ تا ۱۳۸۸ استفاده شد. تعداد تأخیرهای لازم برای ورود متغیرهای ورودی به شبکه‌ها با استفاده از نمودار خودهمبستگی جزئی به دست آمد. از بین متغیرهای مختلف در هر دو مدل ساختار بارش و تبخیر با یک روز تأخیر برای مدل بهینه انتخاب شد. سپس نتایج با استفاده از نمایه‌های RMSE، NSH، MAE و Rmod برای مدل بهینه در هر دو مدل ارزیابی گردید. نتایج نشان داد که شبکه عصبی - فازی تطبیقی با تابع عضویت زنگوله‌ای شکل، شعاع تأثیر ۰/۱۴ و نمایه‌های آماری  $NSH = 0/80$ ،  $RMSE = 0/056$ ،  $MAE = 0/11$  و  $Rmod = 0/81$  نسبت به مدل شبکه عصبی مصنوعی با همان ساختار با الگوریتم آموزشی لوبنبرگ - مارکوارت، تابع انتقال سیگموئید، ۱۴ نرون در لایه مخفی و نمایه‌های آماری  $NSH = 0/54$ ،  $RMSE = 0/056$ ،  $MAE = 0/14$  و  $Rmod = 0/87$  در دوره آزمون توانایی بهتری برای مدل‌سازی بارش - رواناب در حوزه آبخیز کسلیان دارد.

واژه‌های کلیدی: مدل‌سازی بارش - رواناب، حوزه آبخیز کسلیان، شبکه عصبی مصنوعی، شبکه عصبی - فازی تطبیقی

### مقدمه

حوزه آبخیز با شرایط آب و هوایی و فیزیوگرافی متفاوت در مریند آمریکا مدل‌سازی کرده و نتایج حاصله را با مدل مفهومی Watbal<sup>۱</sup> مقایسه کردند. نتایج نشان داد مدل شبکه عصبی مصنوعی در همه موارد دارای کارایی بالاتری است. نایاک و سودهر (۱۲) از شبکه عصبی - فازی تطبیقی برای مدل‌سازی سری‌های زمانی هیدرولوژیکی در رودخانه بیترا نی در اندونزی استفاده کردند. این مدل در مقایسه با سایر روش‌های مدل‌سازی از قبیل شبکه عصبی مصنوعی و شبکه عصبی - فازی تطبیقی با توجه به نمایه‌های ارزیابی جریان مشاهداتی را بهتر برآورد کرد. نیلسون و همکاران (۱۳) با استفاده از مدل‌های مفهومی و شبکه‌های عصبی مصنوعی و ترکیب آن‌ها، مقادیر ماهانه رواناب خروجی از دو حوزه آبخیز در نروژ را شبیه‌سازی نمودند و به این نتیجه رسیدند که روش شبکه عصبی مصنوعی و ترکیب آن با مدل‌های مفهومی برآورد بهتری از رواناب ماهانه را برای هر دو حوزه آبخیز داده است. فیرت و گانگر (۵) شبکه عصبی - فازی تطبیقی را برای پیش‌بینی جریان رودخانه بزرگ منادر در ترکیه مورد ارزیابی قرار داده و به این نتیجه رسیدند که شبکه عصبی - فازی تطبیقی می‌تواند با موفقیت، صحت و قابلیت اطمینان بالا برای پیش‌بینی جریان رودخانه به کار رود. اکیل و همکاران (۲) با بهره‌گیری از شبکه عصبی مصنوعی و روش شبکه

یکی از پیچیده‌ترین فرآیندهای هیدرولوژیکی فرآیندهای بارش - رواناب است که از پارامترهای مختلف فیزیکی و هیدرولوژیکی تأثیر می‌پذیرد. لذا درک و پیش‌بینی فرآیندهای تولید رواناب و انتقال آن به نقطه خروجی حوزه آبخیز یکی از اساسی‌ترین مباحث علم هیدرولوژی محسوب می‌شود (۱۶). از سوی دیگر، با توجه به محدودیت منابع آب شیرین قابل استحصال، پیش‌بینی هرچه دقیق‌تر دبی جریان و تغییرات آن در طول سال از ارکان اساسی برنامه‌ریزی و مدیریت منابع آب‌های سطحی است (۱۴). از این رو، متخصصان همواره برای تخمین صحیح دبی رودخانه و تدقیق روش‌های موجود در تلاش هستند. امروزه استفاده از روش‌های هوشمند از قبیل شبکه عصبی مصنوعی، فازی و شبکه عصبی - فازی تطبیقی برای شبیه‌سازی مسائل مختلف هیدرولوژیکی مورد توجه قرار گرفته است. از مزایای روش‌های هوشمند این است که می‌توان از آنها برای شبیه‌سازی مسائل غیرخطی و پیچیده استفاده کرد. امروزه روش‌های هوشمند در شبیه‌سازی بارش - رواناب بسیار مورد توجه قرار گرفته‌اند (۷). تحقیقات مختلفی در خارج و داخل کشور انجام شده است. توکر و مارکوس (۱۷) با استفاده از شبکه عصبی مصنوعی رابطه بارندگی - رواناب را برای پیش‌بینی جریان ماهانه در سه

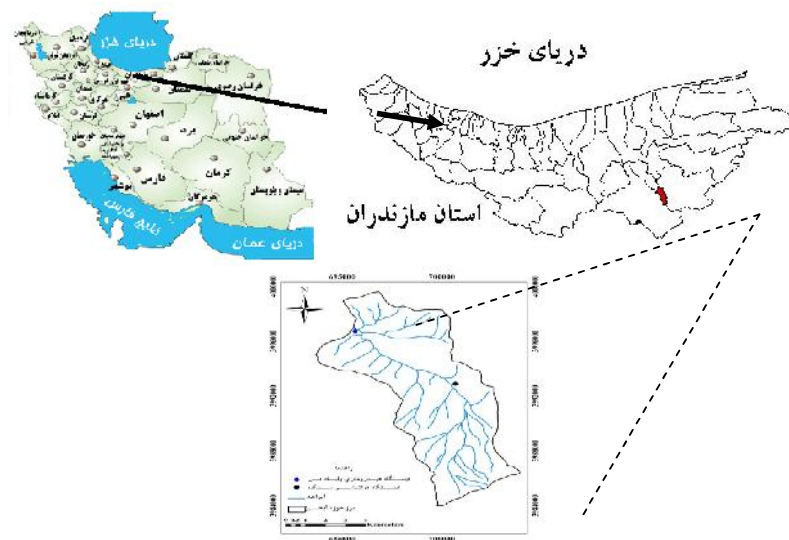
عصبی- فازی تطبیقی (ANFIS) با جداسازی خوشه‌ای) اقدام به شبیه‌سازی فرآیند بارش- رواناب در دو مقیاس ساعتی و روزانه حوزه آبخیز سیلاوی اندونزی کردند. در این بررسی از آمار دبی و بارش مربوط به سال‌های ۲۰۰۱ تا ۲۰۰۳ بهره‌گیری شد که از این آمار دو سوم آن برای آموزش شبکه و یک سوم آن برای صحت‌سنجی گزینش شد. مدل‌های مختلف عصبی با دو الگوریتم آموزش لونیگ - مارکوارت و الگوریتم بیزین<sup>۱</sup> ساخته شد که مدل با یک لایه مخفی و چهارگره در لایه مخفی بهترین مدل ارزیابی شد. در مدل‌های ANFIS مدل با چهار تابع عضویت گوسی برای ورودی‌ها و خروجی‌ها بهترین مدل شناخته شد. همچنین نتایج نشان داد که مدل‌های ANFIS عملکرد بهتری نسبت به مدل‌های شبکه عصبی مصنوعی دارند. کیسی (۹) به منظور پیش‌بینی رواناب روزانه در دو ایستگاه کربوک و درک ویران روی رودخانه فلیوس واقع در کشور ترکیه از رگرسیون موجه<sup>۲</sup> استفاده نمود و نتایج آن را با شبکه عصبی مصنوعی و سری زمانی مقایسه کرد. نتایج نشان داد که رگرسیون موجه با دقت بالاتری نسبت به سری زمانی و شبکه عصبی مصنوعی رواناب را پیش‌بینی نموده است. کورتولوس و رازاخ (۱۰) دو روش شبکه عصبی مصنوعی و شبکه عصبی- فازی تطبیقی (ANFIS) را برای پیش‌بینی دبی روزانه در یک رودخانه کارستی در جنوب شرقی فرانسه به کار بردند و نتیجه گرفتند که ANFIS به طور کلی، جواب مناسب‌تری نسبت به شبکه عصبی مصنوعی ارائه می‌نماید. در داخل کشور هم حسینی (۶) از مدل شبکه عصبی مصنوعی برای پیش‌بینی هیدروگراف سیل در حوزه آبخیز باروت آغاجی، ناورود آسالم و ابوالعباس استفاده نموده است. نتایجی که از ارزیابی آبخیزها به دست آمد نشان می‌دهد که شبکه عصبی مصنوعی و شبکه عصبی- فازی تطبیقی در شرایط مختلف و با ترکیب‌های مختلف پارامترهای ورودی، نتایج متفاوتی از خود نشان می‌دهند ولی در کل این دو روش به میزان قابل قبولی قادر به تخمین رواناب حاصل از بارش با به کارگیری پارامترهای ورودی مناسب و استفاده از ساختارهای مناسب شبکه عصبی مصنوعی و شبکه عصبی- فازی تطبیقی، هستند. ابراهیمی و بشری (۴) در مدل‌سازی تغییرات دبی ماهانه رودخانه قره‌سو با استفاده از سری‌های زمانی و شبکه‌های عصبی مصنوعی و با به کارگیری داده‌های بارندگی، دما، تبخیر و دبی، به این نتیجه رسیدند که نتایج حاصل از پیش‌بینی بر اساس مدل شبکه عصبی مصنوعی انطباق بیش‌تر با مقادیر مشاهده شده دارد. دستورانی و همکاران (۳) کارایی شبکه عصبی مصنوعی

و سیستم استنتاج عصبی- فازی تطبیقی به منظور برآورد بارش- رواناب در حوزه سدزاینده‌رود را مورد بررسی قرار دادند. ایشان با استفاده از نرم‌افزار WinGamma پارامترهای ورودی مناسب به علاوه تعداد مناسب داده برای آموزش شبکه را تعیین نمودند. نتایج حاصل از این مطالعه نشان داد که شبکه عصبی مصنوعی و شبکه عصبی- فازی تطبیقی در شرایط مختلف و با ترکیب‌های مختلف پارامترهای ورودی، نتایج متفاوتی از خود نشان می‌دهند ولی در کل، این دو روش به میزان قابل قبولی قادر به تخمین رواناب حاصل از بارش با به کارگیری پارامترهای ورودی مناسب و استفاده از ساختارهای مناسب شبکه عصبی مصنوعی و شبکه عصبی- فازی تطبیقی، هستند. نورانی و همکاران (۱۵) برای پیش‌بینی رواناب ماهانه و روزانه در حوزه آبخیز لیقوان‌چای از سه مدل هوشمند (شبکه‌های عصبی مصنوعی، سیستم استنتاج فازی و سیستم عصبی-فازی تطبیقی) استفاده کردند و نتایج سه مدل مذکور را با نتایج به‌دست آمده از روش‌های رگرسیون خطی و مدل سری زمانی ARIMA مقایسه کردند که مدل‌سازی فازی (تطبیقی و استنتاجی) بیشترین مقدار نش- ساتکلیف و کمترین خطا را در پی داشت. با توجه به اهمیت پیش‌بینی مناسب جریان رودخانه و شبیه‌سازی فرآیند بارش- رواناب در مدیریت مخازن سدها، کنترل سیلاب و ... در این پژوهش با بهره‌گیری از روش‌های هوش مصنوعی شامل شبکه عصبی مصنوعی و شبکه عصبی- فازی تطبیقی اقدام به پیش‌بینی جریان رودخانه و شبیه‌سازی فرآیند بارش- رواناب در سطح حوزه آبخیز کسپیلان واقع در استان مازندران گردید.

## مواد و روش‌ها

### حوزه آبخیز مورد تحقیق

حوزه آبخیز کسپیلان با مساحت ۶۶/۷۵ کیلومتر مربع از زیر حوزه‌های رودخانه تالار در مازندران به‌شمار می‌رود. این آبخیز با توجه شرایط طبیعی و آب و هوایی خود معرف مناطق کوهستانی و جنگلی در نظر گرفته می‌شود. حوزه آبخیز کسپیلان دومین حوزه آبخیز معرفی است که از سوی وزارت نیرو در ایران تجهیز شده و در جاده فیروزکوه واقع شده و فاصله مرکز آبخیز (ده‌سنگده) تا تهران ۲۳۰ کیلومتر می‌باشد. متوسط بارندگی منطقه ۷۹۱ میلی‌متر بوده و عمدتاً به صورت بارش ریزش می‌نماید. اقلیم منطقه نیز نیمه مرطوب سرد می‌باشد. گروه‌های هیدرولوژیک خاک منطقه شامل B، C و D است (۵). شکل ۱ موقعیت حوزه آبخیز کسپیلان در استان مازندران و ایران را نشان می‌دهد.



شکل ۱- موقعیت حوزه آبخیز کسلیان در استان مازندران و ایران.

سیستم ANFIS است. این مدل یک سیستم فازی سوگنو را در یک ساختار عصبی اجرا می کند و برای فرآیند آموزش از ترکیبی از روش های آموزش پس انتشار خطا و کمینه مربعات خطا بهره گیری می نماید. اگر فرض شود که یک سیستم فازی با دو ورودی  $X$  و  $Y$  و یک خروجی  $Z$  باشد در این صورت با بهره گیری از سیستم تاکاگی سوگنو قوانین اگر آنگاه آن به صورت زیر می باشد.

قانون ۱:

$$\text{If } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ THEN } f_1 = p_1x + q_1y + r_1$$

قانون ۲:

$$\text{If } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ THEN } f_2 = p_2x + q_2y + r_2$$

در این معادله ها ANFIS قوانین ثابت است و آن چه بهینه سازی می شود پارامترهای توابع عضویت می باشد که برای تعیین پارامترهای توابع عضویت (با همان شکل توابع عضویت) از الگوریتم های آموزشی شبکه عصبی بهره گیری می شود. نوع توابع عضویت (مانند مثلثی، گوسی و ....) و شمار توابع عضویت برای ورودی ها و خروجی ها به روش سعی و خطا تعیین می شود. در ANFIS لازم است که در لایه اول نوع توابع عضویت و شمار آنها مشخص شود.

#### شعاع تأثیر

از مهم ترین پارامترهای قابل تنظیم در ANFIS می توان به شعاع تأثیر اشاره کرد. شعاع تأثیر مشخص کننده ی محدوده ی نفوذ یک مرکز خوشه در هر یک از ابعاد داده ها است. در این تحقیق از مقادیر اسکالری این شعاع جهت به کارگیری در تمامی ابعاد داده ها بهره گرفته شده است. به منظور تصور بهتر این پارامتر می توان گفت شعاع تأثیر همانند کره ای است که

#### داده های مورد استفاده

در این تحقیق از اطلاعات هواشناسی روانه ایستگاه هواشناسی سینوپتیک سنگده و اطلاعات هیدرولوژیکی ایستگاه هیدرومتری ولیک بن طی سال های ۱۳۸۲ تا ۱۳۸۸ استفاده شد. پارامترهای مورد استفاده شامل بارش (R)، تبخیر (ET)، دما (T) و دبی (Q) است.

#### معرفی اجمالی مدل ها

##### شبکه عصبی مصنوعی

شبکه عصبی مصنوعی یک مکانیسم محاسباتی است که قادر است با گرفتن اطلاعات و محاسبه کردن آن ها یک سری اطلاعات جدید را ارائه دهد (۸). یکی از متداول ترین شبکه های عصبی مورد بهره گیری در هیدرولوژیکی شبکه عصبی پرسپترون چند لایه است. این شبکه از یک لایه ورودی، یک لایه خروجی و یک یا چند لایه بین آن ها که به طور مستقیم به داده های ورودی و نتایج خروجی متصل نیستند، تشکیل یافته اند که واحدهای لایه ورودی تنها وظیفه توزیع میزان های ورودی ها به لایه بعد و لایه خروجی نیز پاسخ سیگنال های خروجی را ارائه می دهد. در این دو لایه شمار نرون ها برابر با شمار ورودی ها و خروجی ها است و لایه یا لایه های پنهان وظیفه ارتباط لایه های ورودی به لایه های خروجی را بر عهده دارند. در شبکه عصبی پرسپترون چند لایه الگوریتم مشخصی برای تعیین تعداد لایه های پنهان و تعداد نرون ها وجود ندارد و این امر اغلب به روش سعی و خطا انجام می گیرد.

##### شبکه عصبی- فازی تطبیقی (ANFIS)

در سال های اخیر از ترکیب منطق فازی با شبکه های عصبی مصنوعی، شبکه عصبی- فازی تطبیقی به وجود آمده اند. یکی از متداول ترین سیستم های عصبی- فازی

هم‌چنین برای آموزش صحیح شبکه باید مقادیر حداقل و حداکثر داده‌ها در مجموعه آموزشی قرار داشته باشد. با رعایت این اصول سال‌های آبی ۱۳۸۲-۸۳ تا ۸۴-۱۳۸۳ با تعداد ۷۳۰ داده برای آموزش<sup>۱</sup>، سال آبی ۸۵-۱۳۸۴ با تعداد ۳۶۵ داده برای صحت‌سنجی مدل<sup>۲</sup> و سال‌های آبی ۸۶-۱۳۸۵ (از بهمن ماه) تا ۸۸-۱۳۸۷ با تعداد ۹۷۵ داده برای آزمون<sup>۳</sup> انتخاب شد. برای به دست آوردن بهترین ساختار ورودی ابتدا نمایه‌های آماری ریشه میانگین مربعات خطا و ضریب ناش ساتکلیف برای تمام مدل‌ها تعیین گردید و سپس کلیه نمایه‌های آماری برای مدل برگزیده تعیین شد.

#### شبکه عصبی - فازی تطبیقی

برای به دست آوردن بهترین ساختار در شبکه عصبی- فازی تطبیقی با استفاده از شعاع بهینه تأثیر، تابع عضویت زنگوله ای شکل تعمیم‌یافته<sup>۴</sup> به دلیل داشتن بالاترین کارایی در بین توابع عضویت و غیرفازی‌ساز متوسط وزنی<sup>۵</sup> و تعداد داده‌ها برای مرحله آموزش و آزمون تعیین شد. سپس همانند شبکه عصبی مصنوعی نمایه‌های آماری ریشه میانگین مربعات خطا و نش- ساتکلیف برای تمام مدل‌ها تعیین شد. سال‌های آبی ۸۳-۱۳۸۲ تا ۸۵-۱۳۸۴ با تعداد ۱۰۹۵ داده دوره آموزش و سال‌های آبی ۸۶-۱۳۸۵ (از بهمن ماه) تا ۸۸-۱۳۸۷ با تعداد ۹۷۵ داده دوره آزمون برای شبکه عصبی- فازی تطبیقی انتخاب شد. برای به دست آوردن بهترین ساختار ورودی همانند مدل شبکه عصبی مصنوعی ابتدا نمایه‌های آماری ریشه میانگین مربعات خطا و ضریب نش ساتکلیف برای تمام مدل‌ها تعیین گردید و سپس کلیه نمایه‌های آماری برای مدل برگزیده تعیین شد.

#### نمایه‌های کارایی و ارزیابی مدل‌ها

برای ارزیابی بهترین برآزش بین هیدروگراف‌های روزانه محاسبه‌شده و مشاهده‌ای، نمایه‌های ارزیابی زیر مورد استفاده قرار گرفت.

۱- ضریب نش- ساتکلیف<sup>۶</sup>

$$NS = 1 - \frac{\sum_{i=1}^N (Q_o - Q_s)^2}{\sum_{i=1}^N (Q_o - \bar{Q}_o)^2} \quad \text{رابطه (۲)}$$

۲- ضریب همبستگی اصلاح شده<sup>۷</sup> نشان‌دهنده تفاوت اندازه هیدروگراف و شکل آن می‌باشد.

$$R_{\text{mod}} = \left[ \frac{\min\{\delta_o, \delta_s\}}{\max\{\delta_o, \delta_s\}} * r \right] \quad \text{رابطه (۳)}$$

مرکز خوشه در مرکز آن قرار گرفته است و تمامی داده‌های موجود در این فضا را تحت تأثیر خود قرار می‌دهد.

به‌طور کلی، محققین با تغییر مقادیر شعاع تأثیر سعی در دستیابی به شبکه‌های کارا تر را دارند، در این تحقیق به‌منظور جلوگیری از اتلاف وقت با نوشتن زیر برنامه‌ی در MATLAB میزان بهینه برای شعاع تأثیر محاسبه شد و سپس شبکه با در نظر گرفتن مقدار بهینه شعاع تأثیر، مجدداً مدل وارد مرحله‌ی آموزش و آزمون گردید.

#### تعیین ساختار شبکه‌ها

بدین منظور با استفاده از نمودار خودهم‌بستگی جزئی تعداد تأخیرهای لازم برای ورود متغیرهای ورودی به شبکه و هم‌چنین خودهم‌بستگی متقاطع به منظور تعیین متغیرهای مستقل در نرم‌افزار Minitab<sup>۱۴</sup> به دست آمد. به طوری که به دلیل همبستگی بالای تبخیر و دما از مدل‌سازی ترکیبی این دو پارامتر صرف‌نظر گردید (جدول ۲). هم‌چنین تعداد تأخیرها لازم برای بارندگی تا یک تأخیر، برای دما و تبخیر تا سه تأخیر مناسب می‌باشد. شکل ۲ برای نمونه نمودار خودهم‌بستگی جزئی بارش را نشان می‌دهد. در جدول ۱ ساختار ریاضی مدل‌های طراحی شده را نشان می‌دهد.

#### شبکه عصبی مصنوعی

یکی از مراحل آماده‌سازی و محاسبات عددی برای تغذیه شبکه‌های عصبی نرمال‌سازی داده‌ها به منظور افزایش حساسیت به بزرگی داده‌ها و افزایش قدرت یادگیری می‌باشد که باعث افزایش توانایی پیش‌بینی می‌شود. در این تحقیق بردارهای ورودی و خروجی شبکه‌ها به کمک رابطه (۱) در بازه‌ی {۱و۰} استاندارد شدند.

$$\text{رابطه (۱)} \quad X_s = 0.5 + 0.5 \left[ \frac{X - \bar{X}}{X_{\max} - X_{\min}} \right]$$

که در آن:  $X_s$ : مقدار نرمال شده،  $X$ : مقدار داده‌ها،  $\bar{X}$ ،  $X_{\max}$  و  $X_{\min}$ : به ترتیب مقدار میانگین حداکثر و داده‌ها می‌باشد.

پس از استانداردسازی داده‌ها باید ساختار بهینه شبکه تعیین شود. در شبکه عصبی مصنوعی ساختار شبکه شامل ورودی‌ها و خروجی‌ها، تعداد لایه‌های مخفی و تعداد نرون‌ها در هر لایه مخفی، نوع تابع فعال‌سازی و نوع الگوریتم آموزشی می‌باشد. در این روش‌ها پارامترهای ورودی باید طوری تعیین شوند که شمار کمی از الگوهای ورودی بتواند ویژگی‌های منحصر به فرد موجود در داده‌ها را تعیین کنند. برای انتخاب داده‌ها، شرط اساسی این است که داده‌ها کلیه ویژگی‌های یک مجموعه آماری را داشته باشند.

۳- ریشه میانگین مربعات خطا<sup>۱</sup> ANN را نشان می‌دهد. با توجه به جدول ۳ مدل

شبکه

عصبی با ساختار بارش با یک روز تأخیر و تبخیر با یک روز تأخیر و الگوریتم آموزش لونیگ- مارکوارت، تابع انتقال سیگموئید و ۱۴ نرون در لایه مخفی بهترین مدل شبکه عصبی مصنوعی انتخاب شد. شکل‌های ۳ و ۴ آبنمودهای مشاهده‌ای و شبیه‌سازی شده دوره آموزش، صحت‌سنجی و آزمون از طریق شبکه عصبی مصنوعی در حوزه آبخیز کسلیان را نشان می‌دهد. جدول ۴ نمایه‌های آماری برای آرایش‌های مختلف ANFIS را نشان می‌دهد. با توجه به جدول ۴ مدل شبکه فازی- عصبی تطبیقی با ساختار بارش با یک روز تأخیر و تبخیر با یک روز تأخیر و با تعداد قوانین فازی ۱۶ و تابع زنگوله‌ای شکل تعمیم یافته به عنوان بهترین مدل شبکه عصبی- فازی تطبیقی تعیین شد. جدول ۵ تفاوت مقادیر سنجش شبکه را به ازای داده‌های بی بعد نرمال شده برای دستیابی به میزان بهینه شعاع تأثیر نشان می‌دهد. لازم به ذکر است مقدار اولیه برای شعاع تأثیر ۰/۱۴ در نظر گرفته شده است. شکل‌های ۴ و ۵ آبنمودهای مشاهده‌ای و شبیه‌سازی شده دوره آموزش و آزمون توسط شبکه عصبی- فازی تطبیقی در حوزه آبخیز کسلیان را نشان می‌دهد.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Q_{oi} - Q_{si})^2} \quad \text{رابطه (۴)}$$


۴- میانگین قدرمطلق خطا<sup>۲</sup>

$$MAE = \frac{1}{n} \sum_{i=1}^n |Q_{oi} - Q_{si}| \quad \text{رابطه (۵)}$$

در این معادله‌ها  $Q_{oi}$ ،  $Q_{si}$ : جریان شبیه‌سازی شده و مشاهده‌ای در گام زمانی  $i$  (مترمکعب بر ثانیه)،  $N$ : تعداد گام‌های زمانی در طول دوره شبیه‌سازی است.  $\bar{Q}_o$  متوسط دبی جریان مشاهده شده.  $\delta_o$  و  $\partial_s$ : به ترتیب انحراف نمایه دبی‌های مشاهده‌ای و محاسبه‌ای و  $\Gamma$ : ضریب هم‌بستگی می‌باشد. مقدار NS از یک مقدار منفی تا یک در تغییر است و زمانی که یک باشد، نمایانگر انطباق کامل بین هیدروگراف‌های مشاهده‌ای و شبیه‌سازی شده می‌باشد. RMSE هر چه مقدار آن به صفر نزدیک‌تر باشد مدل از دقت بیش‌تری برخوردار است.

## نتایج و بحث

جدول ۳ نمایه‌های آماری برای آرایش‌های مختلف




شکل ۲- تابع خودهمبستگی جزئی بارش.

جدول ۱- همبستگی متقاطع دما و تبخیر


تأخیر	۰	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰
ضریب همبستگی	۰/۶۶۹	۰/۶۷۶	۰/۶۴۶	۰/۶۱۴	۰/۵۹۲	۰/۵۸۶	۰/۵۸۲	۰/۵۷۹	۰/۵۷۷	۰/۵۷۴	۰/۵۷۵

جدول ۲- ساختار ریاضی مدل‌های طراحی شده

شماره مدل	ساختار ریاضی و متغیرها	خروجی مدل
۱	$R_t$	$Q_w$
۲	$R_t, R_{t-1}$	$Q_w$
۳	$R_t, T_t$	$Q_w$
۴	$R_t, T_t, T_{t-1}$	$Q_w$
۵	$R_t, R_{t-1}, T_t, T_{t-1}$	$Q_w$
۶	$R_t, T_t, T_{t-1}, T_{t-2}$	$Q_w$
۷	$R_t, R_{t-1}, T_t, T_{t-1}, T_{t-2}$	$Q_w$
۸	$R_t, R_{t-1}, T_t, T_{t-1}, T_{t-2}, T_{t-3}$	$Q_w$
۹	$R_t, E_t$	$Q_w$
۱۰	$R_t, R_{t-1}, E_t$	$Q_w$
۱۱	$R_t, E_t, E_{t-1}$	$Q_w$
۱۲	$R_t, R_{t-1}, E_t, E_{t-1}$	$Q_w$
۱۳	$R_t, R_{t-1}, E_t, E_{t-1}, E_{t-2}$	$Q_w$
۱۴	$R_t, R_{t-1}, E_t, E_{t-1}, E_{t-2}, E_{t-3}$	$Q_w$



شکل ۳- دبی روزانه مشاهده‌ای و شبیه‌سازی شده شبکه عصبی مصنوعی برای دوره آموزش و صحت سنجی.



شکل ۴- دبی روزانه مشاهده‌ای و شبیه‌سازی شده شبکه عصبی مصنوعی برای دوره آزمون.

مدل سازی بارش - رواناب با استفاده از شبکه عصبی مصنوعی و شبکه فازی - عصبی تطبیقی ..... ۱۳۴

جدول ۳- نمایه های آماری برای آرایش های مختلف ANN


شماره مدل	آرایش شبکه	الگوریتم یادگیری	آموزش				صحت سنجی				آزمون			
			MAE	R	NSH	RMSE	MAE	R	NSH	RMSE	MAE	R	NSH	RMSE
۱	۱-۶-۱	لونیبرگ - مارکوارت	۰/۰۵۵	۰/۲۷	۰/۳۲	۰/۴۵	۰/۰۵۳	۰/۲۴	۰/۳۵	۰/۴۹	۰/۰۵۵	۰/۲۲	۰/۳۱	۰/۴۶
۲	۱-۸-۲	لونیبرگ - مارکوارت	۰/۰۵۰	۰/۳۹	۰/۴۸	۰/۳۳	۰/۰۴۶	۰/۳۵	۰/۴۵	۰/۳۸	۰/۰۴۹	۰/۳۱	۰/۳۲	۰/۴۵
۳	۱-۷-۲	کاهش گزادیان مزدوج	۰/۰۴۹	۰/۲۹	۰/۳۵	۰/۴۸	۰/۰۴۵	۰/۲۲	۰/۳۲	۰/۵۲	۰/۰۵۲	۰/۱۸	۰/۲۶	۰/۵۶
۴	۱-۱۰-۳	کاهش گزادیان مزدوج	۰/۰۴۳	۰/۳۲	۰/۴۸	۰/۳۵	۰/۰۳۸	۰/۲۴	۰/۴۷	۰/۳۶	۰/۰۵۲	۰/۲۳	۰/۵۱	۰/۳۰
۵	۱-۱۵-۴	لونیبرگ - مارکوارت	۰/۰۳۸	۰/۵۹	۰/۶۰	۰/۱۹	۰/۰۳۹	۰/۵۴	۰/۵۷	۰/۲۱	۰/۰۵۴	۰/۴۲	۰/۵۷	۰/۱۸
۶	۱-۱۲-۴	کاهش گزادیان مزدوج	۰/۰۳۹	۰/۴۷	۰/۴۹	۰/۳۳	۰/۰۳۲	۰/۴۴	۰/۴۸	۰/۲۹	۰/۰۶۲	۰/۳۲	۰/۴۱	۰/۳۵
۷	۱-۱۸-۵	کاهش گزادیان مزدوج	۰/۰۳۱	۰/۵۲	۰/۵۶	۰/۲۴	۰/۰۲۷	۰/۵۴	۰/۵۳	۰/۲۵	۰/۰۶۵	۰/۳۹	۰/۵۸	۰/۲۱
۸	۱-۲۲-۶	گزادیان مزدوج	۰/۰۲۳	۰/۵۱	۰/۵۸	۰/۲۶	۰/۰۲۵	۰/۵۳	۰/۵۷	۰/۲۷	۰/۱۱۲	۰/۳۶	۰/۶۱	۰/۲۵
۹	۱-۹-۲	لونیبرگ - مارکوارت	۰/۰۴۷	۰/۴۶	۰/۵۹	۰/۳۲	۰/۰۴۷	۰/۴۱	۰/۵۵	۰/۳۴	۰/۰۵۰	۰/۲۱	۰/۶۳	۰/۲۹
۱۰	۱-۱۰-۳	کاهش گزادیان مزدوج	۰/۰۵۰	۰/۵۲	۰/۶۳	۰/۲۸	۰/۰۴۳	۰/۴۶	۰/۶۲	۰/۳۳	۰/۰۴۹	۰/۴۱	۰/۶۲	۰/۳۳
۱۱	۱-۱۱-۳	گزادیان مزدوج	۰/۰۴۵	۰/۵۳	۰/۷۰	۰/۲۶	۰/۰۴۱	۰/۴۹	۰/۶۹	۰/۲۳	۰/۰۵۰	۰/۳۷	۰/۶۸	۰/۳۲
۱۲	۱-۱۴-۴	لونیبرگ - مارکوارت	۰/۰۳۸	۰/۶۵	۰/۸۰	۰/۲۰	۰/۰۳۶	۰/۶۴	۰/۸۷	۰/۱۲	۰/۰۵۶	۰/۵۴	۰/۸۷	۰/۱۴
۱۳	۱-۱۶-۵	لونیبرگ - مارکوارت	۰/۰۳۴	۰/۶۳	۰/۷۵	۰/۱۸	۰/۰۳۴	۰/۶۳	۰/۸۴	۰/۱۵	۰/۰۷۶	۰/۵۱	۰/۸۳	۰/۱۴
۱۴	۱-۲۰-۶	لونیبرگ - مارکوارت	۰/۰۳۰	۰/۶۱	۰/۷۷	۰/۱۷	۰/۰۳۲	۰/۶۰	۰/۸۶	۰/۱۶	۰/۰۸۰	۰/۵۰	۰/۷۹	۰/۱۶

جدول ۴- نمایه های آماری برای آرایش های مختلف ANFIS


شماره مدل	تعداد قوانین	آموزش				آزمون			
		MAE	R	NSH	RMSE	MAE	R	NSH	RMSE
۱	۲	۰/۰۵۵	۰/۳۶	۰/۴۲	۰/۴۵	۰/۰۵۰	۰/۳۰	۰/۵۴	۰/۳۱
۲	۴	۰/۰۵۰	۰/۴۸	۰/۴۸	۰/۳۵	۰/۰۴۹	۰/۴۰	۰/۵۳	۰/۳۰
۳	۴	۰/۰۴۹	۰/۵۰	۰/۵۱	۰/۲۲	۰/۰۵۲	۰/۲۷	۰/۵۲	۰/۳۷
۴	۸	۰/۴۳	۰/۶۱	۰/۶۵	۰/۱۸	۰/۰۵۹	۰/۳۶	۰/۵۵	۰/۳۲
۵	۱۶	۰/۰۳۸	۰/۷۰	۰/۷۱	۰/۱۶	۰/۰۵۴	۰/۵۱	۰/۶۱	۰/۱۷
۶	۱۶	۰/۰۳۹	۰/۶۸	۰/۶۹	۰/۱۵	۰/۰۶۲	۰/۵	۰/۶۴	۰/۲۲
۷	۳۲	۰/۰۳۱	۰/۶۹	۰/۶۸	۰/۱۵	۰/۰۶۵	۰/۵۳	۰/۶۳	۰/۲۶
۸	۶۴	۰/۰۲۳	۰/۶۰	۰/۶۳	۰/۱۷	۰/۱۱۲	۰/۴۵	۰/۶۴	۰/۲۴
۹	۴	۰/۰۴۷	۰/۵۵	۰/۶۰	۰/۲۶	۰/۰۵۰	۰/۳۲	۰/۶۵	۰/۲۲
۱۰	۴	۰/۰۵۰	۰/۶۴	۰/۶۴	۰/۲۳	۰/۰۴۹	۰/۵۴	۰/۷۷	۰/۱۶
۱۱	۴	۰/۰۴۵	۰/۶۲	۰/۶۷	۰/۲۲	۰/۰۵۰	۰/۴۷	۰/۷۳	۰/۱۲
۱۲	۱۶	۰/۰۳۸	۰/۸۲	۰/۷۹	۰/۱۳	۰/۰۵۶	۰/۸۰	۰/۸۱	۰/۱۱
۱۳	۳۲	۰/۰۳۴	۰/۷۶	۰/۷۶	۰/۱۴	۰/۰۷۶	۰/۷۱	۰/۷۶	۰/۱۲
۱۴	۶	۰/۰۳۰	۰/۷۴	۰/۷۲	۰/۱۶	۰/۰۸۰	۰/۶۹	۰/۷۷	۰/۱۴

جدول ۵- مقایسه نتایج حاصل از عملکرد شبکه به ازای مقادیر اولیه و بهینه شعاع

مرحله ی دست یابی به شعاع بهینه				آموزش		آزمون	
				RMSE	NSH	RMSE	NSH
سعی اول مقدار بهینه				۰/۰۴۳	۰/۷۷	۰/۰۶۴	۰/۷۴
				۰/۰۳۸	۰/۸۲	۰/۰۵۶	۰/۸۰



شکل ۵- دبی روزانه مشاهده‌ای و شبیه‌سازی شده شبکه عصبی- فازی تطبیقی برای دوره آموزش.



شکل ۶- دبی روزانه مشاهده‌ای و شبیه‌سازی شده شبکه عصبی- فازی تطبیقی برای دوره آزمون.

برای دوره‌های آموزش، صحت‌سنجی و آزمون برای مدل انتخاب شده شبکه عصبی مصنوعی به دست آمد. در بخش بعد مدل‌سازی با شبکه عصبی- فازی تطبیقی صورت گرفت. همانند مدل شبکه عصبی ساختارهای ورودی پس از تقسیم‌بندی به مراحل آموزش و آزمون در کد نوشته شده در برنامه ۲۰۰۹ MATLAB اجرا شد. سپس شبکه با در نظر گرفتن مقدار بهینه شعاع تأثیر، مجدد وارد مرحله‌ی آموزش و آزمون شد که نمایه نش- ساتکلیف ۰/۷۴ در مرحله آزمون به ازای مقدار بهینه شعاع برابر با ۰/۸۰ گردید. به عبارت دیگر شعاع تأثیر افزایشی ۶٪ را در میزان نمایه نش ساتکلیف برای داده‌های آزمون به همراه داشت. سپس همانند شبکه عصبی نمایه‌های آماری ریشه میانگین مربعات خطا، نش- ساتکلیف، ضریب همبستگی و میانگین قدرمطلق خطا برای تمام مدل‌ها تعیین گردید که در نهایت همانند مدل شبکه عصبی مصنوعی ساختار بارش با یک روز تأخیر و تبخیر با یک روز تأخیر با تعداد قوانین فازی ۱۶ و تابع زنگوله‌ای شکل تعمیم یافته بهترین مدل شبکه عصبی- فازی تطبیقی تعیین شد. پس از آن نتایج حاصل از تعیین مقادیر شاخص‌های کارایی برای دوره‌های آموزش و آزمون برای مدل انتخاب شده به دست آمد. به طور کلی نتایج حاصل از این پژوهش نیز،

در این تحقیق کارایی مدل‌های هوشمند شبکه عصبی مصنوعی و شبکه عصبی- فازی تطبیقی به منظور برآورد میزان رواناب روزانه حوزه آبخیز کسلیان مورد بررسی قرار گرفت.

ابتدا به منظور انجام تأخیرهای لازم برای مدل‌سازی متغیرهای ورودی به شبکه در نرم‌افزار Minitab نمودار خودهم‌بستگی جزئی و متقاطع برای داده‌ها در سطح معنی‌داری ۰/۰۵ به دست آمد که در نهایت، ۱۴ ساختار مختلف برای مدل‌سازی تعیین شد. سپس ساختارهای مختلف به نرم‌افزار Statistica Neural Network وارد شد، از ویژگی‌های اصلی این نرم‌افزار یافتن اتوماتیک بهترین تابع تحریک، الگوریتم آموزش و نرون لایه مخفی می‌باشد. پس از مشخص کردن تعداد نرون لایه مخفی، الگوریتم آموزش و تابع انتقال در هر سه مرحله آموزش، صحت‌سنجی و آزمون، نمایه‌های آماری ریشه میانگین مربعات خطا، نش- ساتکلیف، ضریب همبستگی و میانگین قدرمطلق خطا برای هر یک از مدل‌ها تعیین شد که در نهایت ساختار بارش با یک روز تأخیر و تبخیر با یک روز تأخیر و ۱۴ نرون در لایه مخفی با الگوریتم آموزشی لونیبرگ- مارکارت و تابع انتقال سیگموئید بهترین مدل شبکه عصبی مصنوعی تعیین شد. پس از آن نتایج حاصل از تعیین مقادیر شاخص‌های کارایی



مدل‌سازی، مفروض به خطا و دارای نبود قطعیت می‌باشند، بنابراین منطق فازی ابزار مناسبی برای مدل‌سازی این سیستم‌ها است و مدل‌سازی فازی (تطبیقی و استنتاجی) از سایر مدل‌ها دقیق‌تر بوده و بیش‌ترین مقدار نش-ساتکلیف و کم‌ترین خطا را در پی داشته است. این مقاله پیشنهاد می‌نماید که شبکه عصبی-فازی تطبیقی با توجه به دارا بودن کارایی بالا به منظور مدل‌سازی بارش-رواناب مورد استفاده قرار گیرد و همچنین از سایر روش‌های شبیه‌سازی از قبیل موجک و منطق فازی به منظور مدل‌سازی بارش-رواناب استفاده شود.

مدل کردن پدیده بارش-رواناب دارد. که نتایج آن با نایاک و سودهر (۹)، فیرت و گانگر (۵)، اکیل و همکاران (۲)، کورتولوس و رازاخ (۱۰) و نورانی و همکاران (۱۵) مبنی بر دقت بالاتر شبکه عصبی-فازی تطبیقی نسبت به شبکه عصبی مصنوعی هم‌خوانی دارد. این محققین در تحقیقات خود مقایسه‌ای بین مدل‌های مختلف برای شبیه‌سازی فرآیند بارش-رواناب انجام دادند و به این نتیجه رسیدند که روش‌های هوشمند در برابر روش‌های دیگر دارای دقت بالایی است که نتایج این تحقیق با نتایج این محققین هم‌خوانی دارد. همچنین به دلیل این‌که پارامترهای بارش و رواناب به‌کار رفته در

## منابع

- Ahmat Nor, N.I.B. 2005. Rainfall-Runoff Modelling Using Artificial Neural Network Method, PhD of Dissertation, Faculty of Civil Engineering, Malaysia Technology University, 189 pp.
- Aqil, M., I. Kita, A. Yano and S. Nishiyama. 2007. A Comparative Study of Artificial Neural Networks and Neuron-Fuzzy in Continuous Modeling of the Daily and Hourly Behavior of Runoff. Journal of Hydrology, 337: 22- 34.
- Dastorani, M.T., H. Sharifi Darani, A. Talebi and A. Moghadam Nia. 2011. Evaluation of the Application of Artificial Neural Networks and Adaptive Neuro-Fuzzy Inference Systems for Rainfall-Runoff Modelling in Zayandeh\_Rood Dam Basin. Iranian Journal of Water and Wastewater, 22: 114-125 (In Persian).
- Ebrahimi Mohammadi, S.H. and M. Boshri S. Ghaleh. 2011. Modeling and Prediction of Monthly Discharge Stream (Case Study: Qarasou River) 4<sup>th</sup> Iran Water Resources Management Conference, Amir Kabir University of Technology Tehran, 10 pp (In Persian).
- Firat, M. and M. Gungor. 2006. River Flow Estimation Using Adaptive Neuro-Fuzzy Inference System. Mathematics and Computers in Simulation, 75: 87-96.
- Hosseini, H. 1999. Artificial Neural Network Model for Determining Flood Hydrograph. Master's Thesis in Civil Engineering. Iran University of Science and Technology. 103 pp.
- Karamouz, M. and S. Araghinejad. 2005. Advanced Hydrology. University of Technology Amir Kabir Press 484 pp (In Persian).
- Khaleghi, M., J. Ghodosi, H. Ahmadi and M. Kamyar. 2010. Hydrograph methods for performance evaluation Geomorphological instantaneous unit estimate peak flood discharge. Journal of Science and Technology of Agriculture and Natural ... and Natural Resources, Water and Soil Science, 5: 89-100 (In Persian).
- Kisi, O. 2010. Wavelet Regression Model for Short-Term Streamflow Forecasting, Journal of Hydrology, 389: 344-353.
- Kurtulus, B. and M. Razack. 2010. Modeling Daily Discharge Responses of a Large Karstic Aquifer Using Soft Computing Methods: Artificial Neural Network and Neuro-fuzzy, Journal of Hydrology, 381: 101-111.
- Lee, S., J.H., Ryu, M.J., Lee and J.S. Won. 2006. The Application of Artificial Neural Networks to landslide Susceptibility Mapping at Janghung, Korea, Mathematical Geology, 38: 199-220.
- Nayak, P.C. and K.P. Sudheer. 2003. Neuro-Fuzzy Computing Technique for Modeling Hydrological Time Series. Journal of Hydrology. 291: 52-66.
- Nilsson, P., C.B. Uvo and R. Bentsen. 2005. Monthly Runoff Simulation: Comparing and Combining Conceptual and Neural Network Models, Journal of Hydrology, 321: 344-363.
- Nabizadeh, M., A. Mosaedi and A.A. Dehghani. 2012. Intelligent Estimation of Stream Flow by Adaptive Neuro-Fuzzy Inference System. Journal of Water and Irrigation Management. 2: 69-80 (In Persian).
- Nourani, V., M. Keynezhad and L. Makani. 2009. Using Adaptive Neuro-Fuzzy Inference System Rainfall-Runoff Modeling. Journal of Civil and Environmental Engineering, 39: 75-81 (In Persian).
- Salajegheh, A., A. Fathabadi and M. Mahdavi. 2009. Investigation on the Efficiency of Neuro-Fuzzy Method and Statistical Models in Simulation of Rainfall-Runoff Process. Journal of Range and Watershed Management. Iranian Journal of Natural Resources, 62: 65-79 (In Persian).
- Toker, A.S. and M. Markus. 2000. Precipitation-Runoff Modeling Using Artificial Neural Network and Conceptual Models, Journal of Hydrologic Engineering, 5: 156-161.
- Zareazadeh, M. and I. Bozorghdad. 2011. Simulation and Prediction Discharge Using A Hybrid Algorithm ANN-GA. Journal of Soil and Water, 24: 942-954 (In Persian).

## **Rainfall-Runoff Modeling using Artificial Neural Network and Neuro-Fuzzy Inference System in Kasilian Watershed**

**Navid Dehghani<sup>1</sup>, Mehdi Vafakhah<sup>2</sup> and Abdolreza Bahremand<sup>3</sup>**

1- Graduate M.Sc., Tarbiat Modares University

2- Associate Professor, Tarbiat Modares University  
(Corresponding author: vafakhah@modares.ac.ir)

3- Associate Professor, Gorgan University of Agricultural Sciences and Natural Resources  
Received: December 4, 2012      Accepted: December 14, 2014

### **Abstract**

Rainfall runoff modeling and prediction of river discharge is one of the important practices in flood control and management, hydraulic structure design and drought management. The present article aims to simulate daily streamflow in Kasilian watershed using an artificial neural network (ANN) and neuro-fuzzy inference system (ANFIS). The intelligent methods have the high potential for determining the relationship between inputs and output. In this study, the input parameters are rainfall, evaporation and temperature of Sangdeh station and streamflow data of Valikbon station are selected as output during 2003 to 2009. The partial auto-correlation function (PACF) was employed for selecting appropriate input parameters to the ANN and ANFIS models. Among different variables in both models, rainfall and evaporation with 1-day lag time were selected as optimal parameters. Then, the results were evaluated using RMSE, NSH, MAE and Rmod statistical criteria for presenting optimal model. The results showed that ANFIS with bell-shaped function and radius of influence=0.14 and NSH=0.80, RMSE=0.056, MAE=0.11, Rmod=0.81 statistical criteria were found to be superior to the ANN with the similar structure, the Levenberg-Marquardt training algorithm, sigmoid transfer function, 14 neurons in the hidden layer and NSH=0.54, RMSE=0.056, MAE=0.14, Rmod=0.87 in testing stage for rainfall-runoff modeling in Kasilian watershed.

**Keywords:** ANN, ANFIS, Kasilian Watershed, Rainfall-Runoff Modeling