



مقایسه کارایی شبکه‌های عصبی CANFIS، MLP و MLP بهینه شده به روش ژنتیک در شبیه‌سازی رسوب معلق رودخانه (مطالعه موردی: حوزه آبخیز زشک - ابرده، شاندیز)

سید محمد تاجبخش^۱، هادی معماریان^۲ و فاطمه محمدی^۳

۱- استادیار، دانشکده منابع طبیعی و محیط‌زیست دانشگاه بیرجند
۲- استادیار، دانشکده منابع طبیعی و محیط‌زیست دانشگاه بیرجند (نویسنده مسئول: hadi_memarian@birjand.ac.ir)
۳- دانش‌آموخته کارشناسی ارشد علوم و مهندسی آبخیزداری، دانشگاه بیرجند
تاریخ دریافت: ۹۶/۴/۲ تاریخ پذیرش: ۹۶/۱۰/۲۳

چکیده

در این پژوهش شبکه عصبی مصنوعی CANFIS و پرسپترون چندلایه (MLP) در برآورد بار رسوب حوزه زشک ابرده شهرستان شاندیز مورد ارزیابی قرار گرفت. بدین منظور سه سناریو شبیه‌سازی شد. به‌منظور شبیه‌سازی سناریوی S1 از ورودی دبی آب، سناریوی S2 از دبی آب و باران روزانه و سناریوی S3 از ورودی دبی آب، باران و دمای روزانه استفاده گردید. نتایج نشان داد سناریوی S3-CANFIS با معماری تابع عضویت بل، تابع انتقال تانژانت هایپربولیک و قانون آموزش لوبنرگ مارکوارت با NSE (ضریب نش) برابر با ۰/۷۴۳ و AM (سنجه جمعی) برابر با ۰/۸۰۶ نسبت به S2-CANFIS و S1-CANFIS کارایی بهتری در پیش‌بینی بار رسوبی دارد. نتایج شبکه MLP حاکی از این است که سناریوی S2_MLP با معماری ۵ نورون مخفی در ۲ لایه پنهان، تابع انتقال سیگموئید و قانون یادگیری مومنتم با NSE برابر با ۰/۶۰۴ و AM برابر با ۰/۶۲۶ در مقایسه با سایر سناریوهای MLP بهتر عمل کرده است. از آنجایی که شبکه MLP در مقایسه با شبکه CANFIS عملکرد ضعیف‌تری را در برآورد میزان رسوب نشان داد، از الگوریتم ژنتیک برای آموزش و تعیین بهینه پارامترهای معماری شبکه S2_MLP کمک گرفته شد. نتایج نشان داد که الگوریتم ژنتیک با ضریب نش-ساتلکف برابر با ۰/۶۵۸ و AM برابر با ۰/۶۵۵ نسبت به مدل MLP عملکرد بهتری داشته است. با مقایسه شبکه عصبی CANFIS با MLP-GA مشخص می‌شود که CANFIS عملکرد بهتری را در پیش‌بینی رسوب حوزه نسبت به سایر شبکه‌ها داشته است. اما باین وجود در مجموع شبکه عصبی در این حوزه کارایی کاملاً رضایت‌بخشی را در پیش‌بینی دقیق بار رسوبی نشان نداد که این می‌تواند ناشی از کمبود داده‌های آموزشی (به‌ویژه مقادیر حدی) و غیردقیق بودن و وجود خطا در آمار حوزه باشد.

واژه‌های: الگوریتم ژنتیک، پرسپترون چندلایه، تحلیل حساسیت، دبی آب، دبی رسوب، شبکه عصبی، شبکه عصبی فازی

مقدمه

در کشور ما اطلاعات دقیق و صحیح از فرسایش، انتقال رسوب و رسوب‌گذاری بسیار کم است و بین اندازه‌گیری و برآوردهای انجام‌شده نیز اختلاف زیادی مشاهده می‌شود. جوان بودن تحقیقات در این رشته و فقدان اندازه‌گیری‌های درازمدت رسوب، مانع از دستیابی به اعداد قابل‌اعتماد شده است. با توجه به اینکه در رودخانه‌ها همواره فرسایش و انتقال رسوب صورت می‌گیرد، بنابراین بررسی ظرفیت حمل رسوب جریان و مکانیسم انتقال رسوب در هیدرولیک رودخانه و مورفولوژی آن، از اهمیت ویژه‌ای برخوردار می‌باشد (۱۲). پدیده انتقال رسوب از جمله فرایندهای هیدرودینامیکی مهمی است که بسیاری از سازه‌های رودخانه‌ای و تأسیسات عمرانی را تحت تأثیر قرار می‌دهد و به‌عنوان بزرگ‌ترین مشکلات بهره‌برداری از منابع آب‌های سطحی در جهان مطرح است (۱۲). همچنین تخمین دقیق بار رسوبی رودخانه‌ها در امر بهداشت و سلامت و نیز مهندسی هیدرولیک حائز اهمیت است. لذا بار رسوبی از نقطه نظر مواد آلاینده حمل شده توسط بار رسوبی معلق، اهمیت فزاینده‌ای دارد (۱). استفاده از روش‌های کلاسیک مانند منحنی سنج رسوب با توجه به رفتار غیرخطی متغیرهای هیدرولوژیکی، از دقت کافی برخوردار نیستند (۴). از این لحاظ شبکه عصبی مصنوعی از جمله مدل‌های شبیه‌سازی است که می‌تواند با دقت مناسبی واقعیات موجود را به تصویر بکشد و پیش‌بینی آن به واقعیت

نزدیک‌تر باشد (۳۰). شبکه عصبی مصنوعی مدلی ریاضی است که توانایی مدل‌سازی و ایجاد روابط غیرخطی برای درون‌یابی را دارد و می‌تواند نگاشت یا تبدیل از فضای چندبعدی دیگر را انجام دهد و قابلیت‌هایی از قبیل شناسایی الگو، نگاشت غیرخطی، حافظه انجمنی، خودسازمان‌دهی و کنترل را دارا است (۲۹).

شبکه‌های عصبی مصنوعی اساساً توسط یک سری محدود از داده‌های واقعی آموزش می‌بینند و چنانچه پارامترهای مؤثر بر پدیده مورد بررسی به‌صورت صحیح انتخاب و به شبکه داده شوند می‌توان انتظار داشت که جواب‌های منطقی از شبکه دریافت نمود. همچنین شبکه عصبی یک روش محاسباتی قدرتمند است که در حوزه مدیریت منابع آب و محیط‌زیست نیز می‌تواند مورد استفاده قرار می‌گیرد. مطالعات زیادی با شبکه عصبی مصنوعی در سطح جهان انجام‌شده است که می‌توان به نمونه‌های زیر اشاره کرد: مساعدی و همکاران (۳۱) از شبکه عصبی مصنوعی برای برآورد بار معلق (مطالعه موردی ایستگاه اهواز) استفاده کردند آن‌ها از سه پارامتر دبی، عرض سطح آب و بارندگی روز قبل برای شبیه‌سازی استفاده کرده و در مقایسه با روش USBR نتایج دقیق‌تری به دست آمد. نورانی و ملکانی (۳۵) به مدل‌سازی فرآیند بارش- رواناب با سه مدل شبکه عصبی، فازی و نروفازی پرداختند. این مدل‌ها جهت پیش‌بینی رواناب روزانه و ماهانه در حوزه‌ی لیقوان‌چای ارائه شدند. در نهایت


به‌دست‌آمده نشان داد که این الگوریتم عملکرد قابل‌اعتمادی در پیش‌بینی رسوب دارد.

هدف از این مطالعه بررسی کارایی شبکه عصبی مصنوعی CANFIS و پرسپترون چندلایه MLP و بهینه‌سازی آن با الگوریتم ژنتیک در پیش‌بینی بار معلق رسوب در حوزه زشک-ابرهه می‌باشد. لازم به ذکر است که هرچند در سال‌های اخیر تحقیقاتی در خصوص برآورد رسوبات معلق با استفاده از شبکه‌های عصبی مصنوعی در نقاط مختلف جهان و ایران انجام شده است ولی بدیهی است که کارایی این روش در نقاط مختلف و بر اساس تعداد و نوع داده‌های موجود متفاوت خواهد بود و زمانی می‌توان قضاوت مطمئنی در خصوص کارایی آن داشت که تحقیقات کافی در نقاط مختلف با شرایط اقلیمی و زمینی و نیز نوع و تعداد داده‌ها و همچنین انواع مختلف شبکه‌های عصبی صورت پذیرد.

مواد و روش‌ها منطقه مورد مطالعه

حوزه آبخیز زشک-ابرهه با مساحتی در حدود ۹۲۲۵/۹ هکتار در محدوده شهرستان طرقله-شاندیز و بخش شاندیز بین طول‌های جغرافیایی ۵۹ درجه، ۴ دقیقه و ۳۹ ثانیه تا ۵۹ درجه، ۱۶ دقیقه و ۱۳ ثانیه و عرض جغرافیایی ۳۶ درجه، ۱۵ دقیقه و ۱۶ ثانیه تا ۳۶ درجه، ۲۳ دقیقه و ۱۲ ثانیه واقع شده است. از لحاظ وضعیت قرارگیری حوزه زشک - ابرهه در حوزه‌های آبریز بزرگ نیز، این حوزه جزء آبریز کشف رود بوده و کل رواناب آن از خروجی بالادست روستای ابرهه علیا خارج می‌گردد. حوزه زشک دارای متوسط بارندگی ۴۰۴ میلی‌متر در سال، متوسط درجه حرارت سالیانه ۱۲ درجه سانتی‌گراد است. اقلیم منطقه در روش آمپروژه و دومارتن به ترتیب، نیمه مرطوب سرد و مدیترانه‌ای طبقه‌بندی می‌شود. شکل ۱ موقعیت حوزه زشک ابرهه را نشان می‌دهد.

نتایج مقایسه این مدل‌ها با روش‌های رگرسیون و سری زمانی نشان داد که مدل نروفازی از سایر مدل‌ها دقیق‌تر است و بیشترین مقدار نش-ساتکلیف و کمترین خطا را دارد. زارع ابیانه و همکاران (۴۵) کاربرد مدل شبکه عصبی (ANN)، شبکه عصبی- فازی (CANFIS) و مدل‌های تجربی را در برآورد رواناب در حوزه سد زاینده‌رود بررسی کردند. نتایج آن‌ها نشان داد که شبکه عصبی مصنوعی و شبکه عصبی- فازی از دقت مناسبی در برآورد رواناب برخوردار بودند. ضمن اینکه ترکیب شبکه عصبی با منطق فازی در قالب شبکه عصبی فازی (CANFIS) کارایی لازم را در بهبود نتایج شبکه عصبی نداشت. رضایی و معماریان (۳۸) با ترکیب سیگنال‌های اقلیمی بزرگ‌مقیاس با میزان بارش و مقادیر پیشین شاخص خشک‌سالی SPI، به بررسی کارایی شبکه‌های عصبی-فازی CANFIS در پیش‌بینی خشک‌سالی منطقه اقلیمی بیرجند پرداختند. بر اساس محاسبات آماری و شاخص‌های ارزیابی شبکه مشخص شد که همبستگی با تأخیر شاخص‌های اقلیمی نتایج قابل‌قبول‌تری بین خشک‌سالی و ENSO را ارائه می‌دهد. فیض‌نیا و همکاران (۱۶) به‌منظور برآورد رسوب معلق حوزه آبخیز زرد رامهرمز در استان خوزستان، از شبکه عصبی پرسپترون چندلایه استفاده کرده و به این نتیجه رسیدند که برآوردهای مدل شبکه عصبی، در مقایسه با مدل رگرسیونی دارای دقت بالاتری است. معماریان و بالاسوندرام (۲۵)، عملکرد پیش‌بینی رسوب در دو شبکه عصبی یعنی تابع پایه شعاعی و پرسپترون چندلایه را بر روی رودخانه لانگات مالزی مورد مقایسه قرار دادند. نتایج روند آموزش مدل شبکه MLP خروجی کمی بهتر از مدل شبکه RBF را نشان داد. همچنین در تحقیقی دیگر معماریان و همکاران (۲۸) از الگوریتم ژنتیک ادغام شده با شبکه عصبی برای پیش‌بینی رسوب بر روی رودخانه لانگات مالزی استفاده کردند آن‌ها از میان پارامترهای دبی آب، بارش و سطح مخزن، بارش ورودی را به‌عنوان مناسب‌ترین پارامتر در پیش‌بینی معرفی کردند. نتایج



شکل ۱- موقعیت منطقه مطالعاتی در حوزه کشف رود و ایران همراه با نقشه کاربری اراضی حوزه
Figure 1. Geographic location of study area with land use map

گرانروی سیال بشمار می‌رود و گرانروی نیز نقش مهمی برافزایش تنش برشی سیال داشته و متعاقباً مؤثر بر فرسایش دیواره‌ها و بستر جریان است. بارش نیز مهم‌ترین مؤلفه مؤثر بر دبی جریان است که خود بر دبی رسوب مؤثر خواهد بود.

داده‌های ورودی و خروجی

در این تحقیق از ۱۰۵ داده دبی رسوب متناظر با دبی آب، دما و باران روزانه ایستگاه هیدرومتری زشک استفاده شده است. پارامتر دما یکی از عوامل مؤثر بر ویسکوزیته یا

پیش فرض ۶۵٪ داده‌ها به منظور آموزش شبکه، ۱۵٪ داده‌ها به منظور آزمون، ۲۰٪ داده‌ها به منظور اعتبارسنجی متقابل مورد استفاده قرار می‌گیرند ولی در این پژوهش با آزمون و خطا درصد بهینه این داده‌ها برای هر نوع شبکه تعیین شد. مهم‌ترین گام در شبکه عصبی انتخاب ورودی مناسب است (۴۶). بنابراین ابتدا باید سناریوهایی با ورودی‌های مختلف مشخص شود. مشخصات هر سناریو در جدول ۱ نشان داده شده است.

این رکوردها در طی ۲۷ سال (۱۳۶۶-۱۳۶۵ تا ۱۳۹۲-۱۳۹۱) برداشت شده و آنچه در این تحقیق مورد استفاده قرار گرفته پس از حذف رکوردهای دارای خطاست. این ایستگاه با مختصات UTM برابر با $X=697026$ و $Y=4023333$ در حوضه زشک-ابرهه شهرستان شاندیز واقع شده است. پس از انتخاب داده‌های آموزش و آزمون اقدام به طراحی شبکه عصبی گردید. برای انجام مدل‌سازی شبکه عصبی از نرم‌افزار NeuroSolutions استفاده شده است. در این نرم‌افزار به‌طور

جدول ۱- پارامترهای ورودی و مطلوب در مدل‌های تدوین شده با شبکه عصبی MLP و CANFIS
Table 1. Input parameters in MLP and CANFIS neural networks


سناریو	داده مطلوب	تعداد ورودی	پارامترهای لایه ورودی
S1	$Q_s(t)$	۱	$Q_w(t)$
S2	$Q_s(t)$	۲	$Q_w(t), PCP(t)$
S3	$Q_s(t)$	۳	$Q_w(t), PCP(t), TMP(t)$

عضویت را بر روی خروجی‌های شبکه ماژولار اعمال می‌کند. در آخر خروجی‌های ترکیب شده بدون لایه خروجی نهایی هدایت شده و خطاب به سمت توابع عضویت و شبکه‌های ماژولار پس انتشار می‌یابد. هر گره در لایه اول رتبه عضویتی است از یک مجموعه فازی (A_1, A_2, B_1, B_2) و تعیین‌کننده درجه عضویت متغیر ورودی به یکی از مجموعه‌های فازی است. مجموعه‌های فازی به وسیله توابع عضویت تعریف می‌شوند. لایه دوم دریافت‌کننده ورودی است به شکل ضرب جفت‌های خروجی از لایه اول. لایه سوم دارای دو مؤلفه است، مؤلفه بالایی اعمال کننده توابع عضویت بر هر یک از ورودی‌ها است درحالی‌که مؤلفه پایینی بیانی است از شبکه ماژولار که برای هر خروجی جمع وزن‌ها را محاسبه می‌کند. لایه چهارم خروجی نهایی شبکه را تولید می‌کند. در این مطالعه از ساختار فازی سوگنو بهره گرفته شده است (۶). شکل شماره ۲ حاصل تلفیق شبکه تطبیقی عصبی با قوانین فازی است. در نرم‌افزار NeuroSolutions، دو نوع کلی از توابع عضویت فازی وجود دارد: تابع بل و تابع گوسی. تابع بل نسبت به تابع گوسی با توجه به داشتن سه پارامتر آزاد جهت تصحیح در مقابل دو پارامتر تابع گوسی، قابلیت انعطاف بیشتری دارد (۳۷) که در این مطالعه از این تابع استفاده شد.

بر اساس در دسترس بودن پارامترهای فیزیکی مؤثر بر رسوب $Q_s(t)$ ، ورودی‌های اولیه به شرح زیر تعریف شده‌اند: $Q_w(t)$: جریان دبی آب در روز t ، واقع در ایستگاه هیدرومتری زشک؛ $PCP(t)$: بارش در روز t ، واقع در ایستگاه هیدرومتری زشک؛ و $TMP(t)$: دمای متوسط در روز t ، واقع در ایستگاه هیدرومتری زشک

ساختار شبکه عصبی مصنوعی CANFIS

مدل CANFIS از ویژگی‌های شبکه عصبی (ANN) به همراه سیستم استنتاج فازی (FIS) در قالب یک محیط عصبی فازی بهره می‌گیرد (۵) و می‌تواند به عنوان تخمین زنده کلی برای توابع غیرخطی مورد استفاده قرار بگیرد (۲۱). مؤلفه اصلی CANFIS یک نورون فازی است که تابع عضویت را بر روی ورودی‌ها اعمال می‌کند ($42, 18, 5$). این شبکه همچنین دارای یک آکسون نورمال کننده است که خروجی را در دامنه بین صفر تا یک استاندارد می‌کند. دومین مؤلفه اصلی این ساختار یک شبکه ماژولار است که قوانین تابعی را بر روی ورودی‌ها اعمال می‌نماید. تعداد شبکه‌های ماژولار منطبق است بر تعداد خروجی‌های شبکه و تعداد عناصر پردازش کننده در هر شبکه نیز منطبق بر تعداد توابع عضویت است (۳۸). CANFIS همچنین دارای یک آکسون ترکیب کننده است که خروجی‌های توابع



شکل ۲- شبکه CANFIS (۵)
Figure 2. CANFIS general architecture

مشخص می‌کند. سنج‌های NMSE و MSE در روابط زیر آورده شده است:

$$MSE = \frac{\sum_{j=0}^P \sum_{i=0}^N (d_{ij} - y_{ij})^2}{NP} \quad \text{رابطه (۳)}$$

$$NMSE = \frac{P \cdot NMSE}{\sum_{j=0}^P \frac{N \sum_{i=0}^N d_{ij}^2 - (\sum_{i=0}^N d_{ij})^2}{N}} \quad \text{رابطه (۴)}$$

$$r = \frac{\sum_i (x_i - \bar{x})(d_i - \bar{d})}{\sqrt{\frac{\sum_i (d_i - \bar{d})^2}{N}} \sqrt{\frac{\sum_i (x_i - \bar{x})^2}{N}}} \quad \text{رابطه (۵)}$$

در روابط فوق، p تعداد خروجی عناصر پردازش شده، N تعداد نمونه‌ها در مجموعه داده‌ها، y_{ij} خروجی شبکه برای نمونه i در عنصر پردازش شده j ، d_{ij} خروجی موردنظر برای نمونه i در عنصر پردازش شده j می‌باشد. MSE اختلاف بین مقدار مشاهده شده و مقدار محاسبه شده را نشان می‌دهد. کمترین مقدار MSE بالاترین صحت پیشگویی را بیان می‌کند. همچنین r نشانگر میزان بازده شبکه است که در آن x_i خروجی شبکه، d_i خروجی موردنظر، $\bar{x}$ میانگین خروجی شبکه و میانگین خروجی موردنظر است. بهترین جواب برای مدل هنگامی ایجاد خواهد شد که r و MSE به ترتیب به یک و صفر میل کنند (۲۸،۳۶،۳۷). از دیگر معیارهای اعتبار سنجی می‌توان به اریبی یا انحراف مدل (MB)، ضریب همبستگی اصلاح شده (r_{mod}) و ضریب کارایی ناش ساتلکف (NSE) اشاره کرد. ارزش ایده آل برای سنج MB صفر است و میزان ایده آل سنج AM، ۱ می‌باشد که نشان‌دهنده تطابق ۱۰۰٪ داده‌های مشاهداتی و شبیه‌سازی شده است. همچنین میزان ایده آل برای ضریب ناش-ساتلکف بین یک تا منفی بی‌نهایت تغییر می‌کند. مقدار بهینه این شاخص یک است. اگر میزان آن از ۰/۵ بیشتر باشد، مدل شبیه‌سازی خوبی داشته است و در صورت منفی شدن آن بهتر است که به نتایج مدل بسنده نشود و از متوسط مقادیر مشاهده‌ای استفاده شود (۴۰،۴۶) محاسبات در روابط زیر آورده شده است:

$$MB = [\sum_{i=1}^n (Q_{si} - Q_{oi}) / \sum_{i=1}^n Q_{oi}] \quad \text{رابطه (۶)}$$

$$r_{mod} = \left[\frac{(\min(\sigma_o, \sigma_s) * r)}{\max(\sigma_o, \sigma_s)} \right] \quad \text{رابطه (۷)}$$

$$NSE = 1 - \frac{\sum_{i=1}^n (Q_{si} - Q_{oi})^2}{\sum_{i=1}^n (Q_{oi} - \bar{Q}_o)^2} \quad \text{رابطه (۸)}$$

که Q_{oi} و Q_{si} به ترتیب دبی‌های شبیه‌سازی شده و مشاهداتی رسوب در گام زمانی i ، $\bar{Q}_o$ متوسط دبی مشاهده‌ای در دوره شبیه‌سازی، σ_o و σ_s به ترتیب میزان انحراف معیار دبی مشاهده‌ای و شبیه‌سازی شده، r ضریب همبستگی بین داده‌های مشاهداتی و شبیه‌سازی و n تعداد مشاهدات در دوره شبیه‌سازی است. برای ارزیابی صحت اندازه، شکل و مقدار هیدروگراف شبیه‌سازی شده، از معیار AM به شرح زیر

ساختار شبکه عصبی مصنوعی MLP

یکی از متداول‌ترین انواع شبکه‌های عصبی، پرسپترون چندلایه MLP است (۲۷،۱۱). این شبکه متشکل از یک لایه ورودی، یک یا چند لایه پنهان و یک خروجی است. MLP می‌تواند توسط یک الگوریتم انتشار به عقب آموزش داده شود (۳۹). به‌طور معمول MLP به‌عنوان مجموعه‌ای از لایه‌های به هم پیوسته از نورون‌های مصنوعی ورودی، لایه پنهان و خروجی سازمان‌دهی شده است (۲۸،۲۷). سپس با مقایسه خروجی شبکه و خروجی واقعی، مقدار خطا محاسبه می‌شود، این خطابه صورت پس انتشار (BP) (۴۴) در شبکه بازگشت داده می‌شود تا وزن‌های اتصال‌دهنده گره‌ها دوباره تنظیم شوند (۳). طبق نظر مصطفی و همکاران (۳۳) گرادیان نزولی و گرادیان نزولی با مونتیم به عامل نرخ یادگیری و فاکتور مونتیم حساس هستند. از این رو ممکن است اگر به‌صورت صحیح انتخاب نشوند باعث بی‌ثباتی شبکه شود. بنابراین در این پژوهش نرخ مونتیم و اندازه گام با الگوریتم ژنتیک بهینه‌سازی شد. بدین‌وسیله کارایی این روش در بهینه‌سازی شبکه عصبی، در زمینه برآورد رسوب معلق، بررسی گردید.

آموزش شبکه

آموزش شبکه مبتنی بر روش تصحیح خطاست و مشخص بودن پاسخ مطلوب از الزامات این روش است. در این روش خطای لحظه‌ای $e_i(n)$ به‌صورت زیر تعریف می‌شود:

$$e_i(n) = d_i(n) - y_i(n) \quad \text{رابطه (۱)}$$

که در آن: $y_i(n)$ پاسخ سیستم در نورون i ام و تکرار n ام و $d_i(n)$ پاسخ مطلوب است. با تکیه بر تئوری آموزش کاهش گرادیان (۲۸،۳۷)، هر وزن در شبکه در تکرار $n+1$ با استفاده از رابطه زیر به‌صورت زیر محاسبه می‌شود:

$$w_{ij}(n+1) = w_{ij}(n) + \eta \delta_i(n) x_i(n) + a(w_{ij}(n) - w_{ij}(n-1)) \quad \text{رابطه (۲)}$$

خطای محلی یا $\delta_i(n)$ به‌صورت مستقیم از $e_i(n)$ در نورون خروجی به دست می‌آید و یا اینکه به‌صورت جمع وزنی خطاهای نورون‌های داخلی محاسبه می‌گردد. ثابت η اندازه گام و a نرخ گشتاور است (۲۵،۳۷). در این پژوهش از الگوریتم ژنتیک (GA) (۱۹) به‌منظور بهینه کردن پارامترها در قانون یادگیری شبکه عصبی و همچنین بهینه‌سازی معماری شبکه استفاده شد. پارامترهایی از جمله تعداد نورون پنهان و نرخ یادگیری بهینه شدند. GA راه‌حل بهینه را تا رسیدن به معیار پایان الگوریتم جستجو می‌کند (۳۷،۲۸).

شاخص‌های ارزیابی

از MSE، NMSE، ضریب همبستگی (r)، به‌عنوان معیارهای عملکرد شبکه در آموزش و اعتبار سنجی شبکه استفاده شد، درحالی‌که معیار آکایی^۱ (AIC) و طول توصیف حداقل^۲ (MDL) به‌وسیله نرم‌افزار برای تولید یک شبکه با بهترین تعمیم استفاده می‌شود. معیار AIC ایجاد تعادل بین اندازه و عملکرد شبکه را بر عهده دارد. معیار MLD کارکردی مشابه ALC دارد و سطح تعمیم‌یافتگی مدل را تعیین می‌کند (۲۸،۳۷،۳۶). MSE و NMSE برآورد کمی خطا را مورد ارزیابی قرار می‌دهند، درحالی‌که r قدرت و جهت خطی بین بار رسوب پیش‌بینی شده و مشاهده شده را

استفاده شد. جدول ۲ نشان‌دهنده طبقات مختلف کارایی مدل بر اساس سنجه AM است.

جدول ۲- طبقات مختلف کارایی مدل بر اساس سنجه AM (۲۸،۴۰)

Table 2. Model performance categories based on the AM

نیکویی برازش	Aggregated Measure (AM)
عالی	> 0.85
خیلی خوب	$0.70 - 0.85$
خوب	$0.55 - 0.70$
ضعیف	$0.40 - 0.55$
خیلی ضعیف	< 0.40

آنالیز حساسیت

آنالیز حساسیت اهمیت نسبی ورودی‌های شبکه عصبی را بررسی کرده و چگونگی تغییرات خروجی مدل را نسبت به تغییرات ورودی نشان می‌دهد. میانگین تغییرات اولین ورودی به $-/+$ تعداد انحراف معیار کاربر بستگی دارد، درحالی‌که ورودی‌های دیگر به‌طور میانگین ثابت هستند. تعداد خروجی شبکه توسط کاربر محاسبه می‌شود و به کمترین و بیشترین میانگین بستگی دارد. این فرایند برای هر ورودی اتفاق می‌افتد (۲۸،۳۷). حساسیت ورودی به‌صورت زیر محاسبه می‌شود:

$$\text{Sensitivity} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad \text{رابطه (۱۰)}$$

که x_i بار رسوب در گام i ، μ میانگین بار رسوب در طول آنالیز حساسیت، N تعداد گام است. در این پژوهش انحراف معیار استاندارد و گام برای هر طرف مثبت و منفی به ۱ تا ۵۰ در نظر گرفته شد.

طراحی و معماری شبکه CANFIS

با توجه به اینکه شبکه‌های عصبی نمی‌توانند خارج از محدوده داده‌های آموزش‌دهنده برون‌یابی کنند، چندین ترکیب تصادفی از مجموعه‌های آموزش و آزمایش بررسی شد تا اینکه مجموعه سازگار از لحاظ آماری به دست آمد. پارامترهای آماری برای مجموعه سازگار برای این مدل در جدول شماره ۳ آمده است. برای تعیین درصد بهینه، از بین ۱۰۵ ورودی، ۶۰٪ به‌منظور آموزش، ۱۰٪ به‌منظور ارزیابی و ۲۰٪ به‌منظور آزمون انتخاب گردید.

جدول ۳- پارامترهای آماری برای مجموعه سازگار شبکه CANFIS

Table 3. Statistical characteristics of the CANFIS Input parameters

آموزش		آزمون	
میانگین	دبی جریان (m^3/s)	دبی رسوب (ton/day)	دبی رسوب (ton/day)
۱/۴۸	۱/۸۰	۳۱۱/۴۹	۳۳۲/۸۱
۴/۸۴	۵	۳۹۱۲/۵۱	۴۱۵۴/۱
۰/۱۱	۰/۲۶۳	۰/۰۰۱	۰/۱۱۴
۱/۰۵	۱/۱۹	۵۸۸/۱۶	۸۳۵/۳۷

در این پژوهش از قانون یادگیری مومنتم برای طراحی سناریوی اول و از قانون یادگیری لونبرگ مارکوات برای طراحی سناریو دوم و سوم استفاده شده است. تحقیقات نشان می‌دهد که قانون آموزش لونبرگ مارکوات برای اکثر کاربردها نتایج دقیق و سریعی نسبت به سایر روش‌های آموزش دارد (۱۷،۴۱). همچنین در این مطالعه از فن آموزش افزایشی بجای آموزش یکجا استفاده شد. آموزش افزایشی سرعت بیشتری داشته و توانایی بیشتری در فرار از حداقل‌های محلی دارد (۴۳). همچنین در مدل‌های

اجراشده به‌منظور ارتقای عملکرد شبکه تعداد تابع عضویت فازی مختلفی جهت آموزش استفاده گردید و درنهایت با توجه آزمون و خطاهای انجام‌شده تعداد تابع عضویت برای هر شبکه مشخص گردید. اندازه گام و نرخ گشتاور نیز به ترتیب برابر با ۱ و ۰/۷ انتخاب شد. همچنین تابع انتقال مورد استفاده در این مطالعه، تانژانت هیپربولیک است. از مدل فازی سوگنو نیز برای آموزش شبکه استفاده شد. جدول ۴ خلاصه معماری سناریوها را نشان می‌دهد.

جدول ۴- معماری شبکه CANFIS

Table 4. CANFIS architecture

مشخصات شبکه	S1_CANFIS	S2_CANFIS	S3_CANFIS
تابع عضویت	گوسی	گوسی	بل
تعداد تابع عضویت	۶	۴	۳
مدل فازی	سوگنو	سوگنو	سوگنو
تابع انتقال	تانژانت هیپربولیک	تانژانت هیپربولیک	تانژانت هیپربولیک
قانون یادگیری	مومنتم	لونبرگ مارکوات	لونبرگ مارکوات
اندازه گام و ضریب مومنتم	۰/۷ و ۱	-	-
تعداد الگوها برای یادگیری	۱۰۰۰	۱۰۰۰	۱۰۰۰
تکراری که در آن خطای اعتبارسنجی حداقل است	۴۵۷	۳۳	۲۸

طراحی و معماری شبکه MLP

بعد از انتخاب ورودی بایستی مجموعه سازگار انتخاب شود، بدین منظور چندین مجموعه متفاوت به صورت کاملاً تصادفی انتخاب شد و سپس پارامترهایی نظیر میانگین داده‌ها، حداقل، حداکثر و انحراف معیار آن‌ها در مجموعه

آزمون و آزمایش محاسبه گردید و بر اساس آن مجموعه برتر انتخاب شد. جدول ۵ پارامترهای آماری برای مجموعه سازگار مدل MLP را نشان می‌دهد. سپس با آزمون و خطا مجموعه‌ای با ۶۵٪ داده‌ها به منظور آموزش شبکه، ۱۵٪ به منظور صحت سنجی و ۲۰٪ به منظور اعتبار سنجی انتخاب شد.

جدول ۵- پارامترهای آماری برای مجموعه سازگار شبکه MLP

Table 5. Statistical characteristics of the MLP Input parameters

آموزش		آزمون	
پارامتر آماری	دبی جریان (m ³ /s)	دبی رسوب (ton/day)	دبی رسوب (ton/day)
میانگین	۱/۵۹	۳۰۵/۰۸	۲۰۸/۸۱
حداکثر	۵	۴۱۵۴/۱	۲۰۱۳/۳۴۵
حداقل	-۰/۱۱	-۰/۰۰۱	-۰/۰۲۹
انحراف معیار	۱/۱۶	۷۱۰/۷۶۳	۵۳۰/۴۰

برای انتخاب پارامترهای قابل تنظیم و در نتیجه تعیین بهترین ساختار شبکه عصبی، تعداد زیادی شبکه عصبی با ساختار مختلف طراحی و ارزیابی گردید. این شبکه‌های عصبی با تغییر پارامترهای قابل تنظیم (شامل تابع انتقال، قانون یادگیری، مقدار مومنتم، تعداد لایه میانی، تعداد نرون‌های لایه میانی، تعداد الگوها و متغیرهای ورودی)

ساخته و اجرا شدند. دقت این شبکه‌ها به وسیله معیارهای آماری محاسبه شده در مرحله آزمون، بررسی گردید و در نهایت شبکه‌ای که نزدیک‌ترین نتیجه را با واقعیت داشت به عنوان شبکه اصلی انتخاب شد. همان‌طور که از جدول ۶ مشاهده می‌شود، تابع فعال اصلی مورد استفاده در این مطالعه سیگموئید است که یک تابع لجستیک است.

جدول ۶- معماری شبکه MLP

Table 6. MLP architecture

شبکه	تعداد لایه مخفی	تعداد نورون	تابع انتقال	قانون یادگیری (اندازه گام، نرخ گشتاور)
S1_MLP	۲	۴	سیگموئید	مومنتم (۰/۷، ۱)
S2_MLP	۲	۵	سیگموئید	مومنتم (۰/۷، ۱)
S3_MLP	۲	۴	سیگموئید	مومنتم (۰/۷، ۱)

نتایج و بحث

آنالیز خطا

آنالیز خطا در مرحله آموزش شبکه CANFIS

حداقل MSE و MSE نهایی به دست آمده طی مرحله آموزش برای S3_CANFIS به ترتیب با ارزش ۰/۰۲۶ و ۰/۰۲۶ که نسبت به S2_CANFIS و S1_CANFIS مقدار کمتری به دست آمد (جدول ۷).

همچنین S3_CANFIS در مقایسه با دیگر سناریوها در مرحله اعتبارسنجی نیز قادر به تولید خروجی مناسب‌تری است. با توجه به تعداد ورودی‌ها مشخص می‌شود که هر سه ورودی دبی آب، دما و باران تأثیر مثبتی را در مرحله آموزش بر عملکرد شبکه داشته‌اند. به عبارتی با افزایش اطلاعات ورودی عملکرد شبکه افزایش می‌یابد. این یافته نیز با نتایج تحقیق سایر محققان تأیید شده است (۷).

جدول ۷- آنالیز خطا در مرحله آموزش شبکه CANFIS

Table 7. Error metrics in training phase of CANFIS

	S1_CANFIS		S2_CANFIS		S3_CANFIS	
	Training (آموزش)	Cross Validation (اعتبارسنجی متقابل)	Training (آموزش)	Cross Validation (اعتبارسنجی متقابل)	Training (آموزش)	Cross Validation (اعتبارسنجی متقابل)
Epoch (تکرار)	۸۷	۴۵۷	۱۳۷	۳۳	۵۵	۲۸
Minimum MSE	۰/۰۳۲	۰/۰۳۳	۰/۰۲۶	۰/۰۲۸	۰/۰۲۶	۰/۰۲۳
Final MSE	۰/۰۴۸	۰/۰۹۲	۰/۰۲۶	۰/۰۲۸	۰/۰۲۶	۰/۰۲۷


آنالیز خطا در مرحله آزمون شبکه CANFIS

نتایج نشان داد که هر سه شبکه قدرت و کارایی نسبتاً مشابهی در طول فرایند آزمون دارند. با توجه به جدول ۹ می‌توان دریافت که S3_CANFIS در مجموعه آزمون با داشتن MSE و NMSE کمتر در مقایسه با سایر سناریوها

بهتر عمل کرده است و همچنین این سناریو دارای NSE (۰/۷۴۳) و AM (۰/۸۰۶) بالاتری بوده که نسبت به سناریوی S1_CANFIS با NSE برابر با ۰/۷۰۳ و AM برابر با ۰/۷۷۴ و مدل S2_CANFIS با NSE برابر با ۰/۶۸۱ و AM برابر با ۰/۷۱۰ عملکرد بهتری را نشان

تحقیقات دستورانی و همکاران (۱۱) و معماریان و بالاسوندرام (۲۵) و معماریان و همکاران (۲۸) نیز همخوانی دارد.

می‌دهد. همان‌طور که در شکل ۵ نشان داده‌شده، شبکه عصبی CANFIS در برآورد نقاط حدی دچار تخمین کمتر از حد می‌شود که یکی از دلایل آن می‌تواند کمبود حضور داده‌های حدی در مرحله آموزش شبکه باشد که با نتایج



شکل ۵- بار رسوب مشاهداتی در مقابل رسوب برآورد شده توسط S3_CANFIS در طول فرآیند آزمون شبکه
Figure 5. Observed sediment load versus simulated sediment load by the S3-CANFIS during testing process

همچنین S2_MLP در مقایسه با دیگر سناریوها در مرحله اعتبارسنجی نیز به تولید خروجی مناسب‌تری است. با توجه به تعداد ورودی‌ها مشخص می‌شود که دو ورودی دبی آب و باران تأثیر مثبتی را در مرحله آموزش بر عملکرد شبکه داشته‌اند.

آنالیز خطا در مرحله آموزش شبکه عصبی MLP
همان‌طور که از جدول ۸ مشاهده می‌شود حداقل MSE و پایانی طی مرحله آموزش برای شبکه S2_MLP به ترتیب با ارزش ۰/۰۰۷۱ و ۰/۰۰۷۱، که نسبت به S1-MLP و S3_MLP مقدار کمتری به دست آمد.


جدول ۸- آنالیز خطا در مرحله آموزش شبکه MLP

Table 8. Error metrics in training phase of MLP

	S1_MLP		S2_MLP		S3_MLP	
	(آموزش)	(اعتبارسنجی)	(آموزش)	(اعتبارسنجی)	(آموزش)	(اعتبارسنجی)
Epoch (تکرار)	۱۰۰۰	۸۷۹	۱۰۰۰	۱۰۰۰	۱۰۰۰	۸۰۴
Minimum MSE	۰/۰۰۹۰	۰۰/۰۰۱۶	۰/۰۰۷۱	۰/۰۰۱۴	۰/۰۰۷۴	۰/۰۰۱۴
Final MSE	۰/۰۰۹۰	۰/۰۰۱۶	۰/۰۰۷۱	۰/۰۰۱۴	۰/۰۰۷۴	۰/۰۰۱۶

با ۰/۶۰۳ و مدل S3_MLP با NSE برابر با ۰/۵۹۸ و AM برابر با ۰/۶۰۷ عملکرد بهتری را نشان می‌دهد. همان‌طور که در شکل ۶ نشان داده‌شده، شبکه عصبی MLP در برآورد نقاط حدی پیک دچار تخمین کمتر از حد می‌شود، که یکی از دلایل آن می‌تواند کمبود حضور داده‌های حدی در مرحله آموزش شبکه باشد که با نتایج تحقیقات معماریان و بالاسوندرام (۲۵) و معماریان و همکاران (۲۸) نیز همخوانی دارد.

آنالیز خطا در مرحله آزمون شبکه MLP
نتایج نشان داد که هر سه شبکه قدرت و کارایی نسبتاً مشابهی در طول فرایند آزمون دارند. با توجه به جدول ۹ می‌توان دریافت که S2_MLP در مجموعه آزمون با داشتن MSE و NMSE کمتر در مقایسه با سایر سناریوها بهتر عمل کرده است. همچنین این سناریو دارای NSE (۰/۶۰۴) و AM (۰/۶۲۶) بالاتری بوده که نسبت به سناریوی S1_MLP با NSE برابر با ۰/۵۹۴ و AM برابر




شکل ۶- بار رسوب مشاهداتی در مقابل رسوب برآورد شده توسط S2_MLP در طول فرآیند آزمون شبکه
Figure 6. Observed sediment load versus simulated sediment load by the S2-MLP during testing process

مدل MLP-GA

نقطه‌ای با احتمال ۰/۹ و جهش یکنواخت با احتمال ۰/۱ استفاده گردید و تعداد تکرار برابر با ۱۰۰۰، تعداد جمعیت ۵۰ و حداکثر نسل تولیدشده ۲۰۰ در نظر گرفته شد. شکل ۷ رسوب برآورد شده توسط MLP-GA در طول فرآیند آزمون را نشان می‌دهد. همچنین آنالیز خطا و معیارهای اعتبارسنجی نیز در جدول ۹ قابل مشاهده است. همان‌طور که مشاهده می‌شود الگوریتم ژنتیک با میزان r برابر ۰/۸۹، NMSE برابر ۰/۵۵۴، همچنین با ضریب نش-ساتکیف برابر ۰/۶۵۸ و AM برابر ۰/۶۵۵ نسبت به مدل MLP عملکرد بهتری داشته است و بر اساس سنجه AM، در طبقه "خوب" قرار می‌گیرد.

از آنجایی که شبکه MLP در مقایسه با شبکه CANFIS عملکرد ضعیف‌تری را در برآورد میزان رسوب نشان داد، از الگوریتم ژنتیک برای آموزش و تعیین بهینه پارامترهای معماری شبکه S2_MLP کمک گرفته شد. در این تحقیق پارامترهای شبکه عصبی، شامل متغیرهای ورودی و تعداد نورون‌ها در لایه پنهان، با الگوریتم ژنتیک به نحوی بهینه‌سازی شدند که در مرحله آزمون، نتایج برآورد شده توسط مدل، یا داده‌های خروجی، بهترین برآزش را با داده‌های واقعی یا داده‌های مطلوب، داشته باشند. برای اجرای این بهینه‌سازی، در الگوریتم ژنتیک از تلاقی یک



شکل ۷- بار رسوب مشاهداتی را در مقابل رسوب برآورد شده توسط شبکه MLP-GA در طول فرآیند آزمون بر اساس سناریو S2_MLP
Figure 7. Observed sediment load versus simulated sediment load by the MLP-GA during testing process based on the scenario S2_MLP

جدول ۹- پارامترهای ارزیابی در مرحله آزمون شبکه‌های عصبی مختلف

Table 9. Evaluation metrics of different ANNs during testing phase

معیار ارزیابی	S1_CANFIS	S2_CANFIS	S3_CANFIS	S1_MLP	S2_MLP	S3_MLP	MLP-GA (S2_MLP)
MSE	۲۳۸۶۲۴/۷۵۶	۲۵۵۹۰۸/۸۹۲	۲۰۵۸۵۰/۳۷۵	۱۰۵۸۹۳/۰۳۹	۹۰۰۵۵/۳۱۲	۱۰۴۴۳۰/۴۰۰	۱۴۶۲۲۵/۹۶۵
NMSE	۰/۲۹۶	۰/۳۱۸	۰/۲۵۶	۰/۴۰۱	۰/۳۴۱	۰/۳۹۵	۰/۵۵۴
MAE	۲۵۲/۰۵۳	۲۳۵/۹۸۲	۲۲۱/۹۶۴	۲۲۲/۶۲۰	۲۱۲/۶۶۷	۲۳۶/۲۸۴	۱۷۱/۶۳۶
Min Abs Error	۶/۱۸۵	۰/۳۶۳	۴/۷۹۸	۴۸/۴۵۶	۵۱/۴۲۳	۷۱/۳۵۹	۲۹/۴۵۰
Max Abs Error	۱۶۲۴/۹۹۴	۲۰۵۱/۲۸۹	۱۷۱۸/۵۸۴	۹۲۲/۷۰۳	۷۹۸/۲۰۵	۸۴۹/۲۷۴	۱۲۷۰/۱۱۸
r	۰/۸۴۳*	۰/۸۶۳*	۰/۸۷۸*	۰/۸۶۷*	۰/۸۸۹*	۰/۸۵۷*	۰/۸۹۰*
r_{mod}	۰/۸۰۹	۰/۵۳۹	۰/۶۳۲	۰/۳۴۱	۰/۳۸۱	۰/۴۲۶	۰/۴۴۶
MB	۰/۱۹۱	-۰/۹۰۰	-۰/۰۴۳	۰/۱۲۶	۰/۱۰۰	۰/۲۰۷	۰/۱۳۸
NSE	۰/۷۰۳	۰/۶۸۱	۰/۷۴۳	۰/۵۹۴	۰/۶۰۴	۰/۵۹۸	۰/۶۵۸
AM	۰/۷۷۴	۰/۷۱۰	۰/۸۰۶	۰/۶۰۳	۰/۶۲۶	۰/۶۰۷	۰/۶۵۵
نکویی برآزش	خیلی خوب	خیلی خوب	خیلی خوب	خوب	خوب	خوب	خوب

*: معنی‌دار در سطح ۵ درصد

انتخاب بهترین مدل

داشته باشد. ضمن این‌که توانایی درج چندین خروجی و محاسبات منطبق بر آن‌ها را نیز دارا است. در واقع با تسهیم ارزش‌های عضویت فازی، قوانین فازی در این نوع از شبکه‌ها به‌گونه‌ای ساخته می‌شوند که بتوانند همبستگی بین خروجی‌ها را نیز در شبیه‌سازی لحاظ کرده و جهت تسریع دریافتن جواب صحیح از آن استفاده کنند. این یافته‌ها با نتایج سایر محققان نیز تأییدشده است (۱۸،۲۶،۴۲). اما با این‌وجود در مجموع شبکه عصبی در این حوزه کارایی رضایت بخشی را در پیش‌بینی دقیق بار رسوبی نشان نداد. این می‌تواند به دلیل

با توجه به جدول ۱۰ مشاهده می‌شود که شبکه CANFIS با توجه به معیارهای MB برابر با ۰/۰۴۳، NSE برابر با ۰/۷۴۳ و AM برابر با ۰/۸۰۶ عملکرد بهتری را در پیش‌بینی رسوب حوزه نسبت به سایر شبکه‌ها داشته است، که این می‌تواند به دلیل برتری این شبکه نسبت به سامانه‌های معمول فازی و سایر شبکه‌های عصبی مانند MLP باشد که ورودی‌های فازی را با شبکه ماژولار عصبی ادغام کرده تا بتواند تخمینی سریع و صحیح از توابع پیچیده

طبیعی در معرض ابتلا به تغییرات مکانی قابل توجهی در مقدار بارش هستند (۲۸،۱۴). بنابراین به نظر می‌رسد که در صورت وجود چندین ایستگاه باران‌سنجی و استفاده از آمار آن‌ها در پیش‌بینی رسوب به‌وسیله شبکه عصبی شاید بتوان به نتایج دقیق‌تری از بار رسوبی حوزه رسید.

کمبود داده‌های آموزشی و غیردقیق بودن و وجود خطا در آمار حوزه باشد، که با نتایج معماریان و همکاران (۲۸) و معماریان و بالاسوندرام (۲۵) نیز همخوانی دارد. به دلیل کمبود اطلاعات دقیق و کافی باران و دما در این حوزه از اطلاعات یک ایستگاه استفاده شد. می‌دانیم که حوزه‌های آبخیز به‌طور

جدول ۱۰- مقایسه شبکه عصبی مصنوعی MLP، CANFIS و MLP-GA بر اساس بهترین سناریوهای استخراج شده


Table 10. Comparison of the networks CANFIS, MLP, and MLP-GA based on the best scenarios

معیار ارزیابی	S3_CANFIS	S2_MLP	MLP- GA (S2)
MSE	۲۰۵۸۵۰/۳۷۵	۹۰۰۵۵/۳۱۲	۱۴۶۳۲۵/۹۶۵
NMSE	۰/۲۵۶	۰/۳۴۱	۰/۵۵۴
MAE	۲۲۱/۹۶۴	۲۱۲/۶۶۷	۱۷۱/۶۳۶
Min Abs Error	۴/۷۹۸	۵۱/۴۲۳	۳۹/۴۵۰
Max Abs Error	۱۷۱۸/۵۸۴	۷۹۸/۲۰۵	۱۲۷۰/۱۱۸
r	۰/۸۷۸	۰/۸۸۹	۰/۸۹۰
r _{mod}	۰/۶۳۲	۰/۳۸۱	۰/۴۴۶
MB	-۰/۰۴۳	۰/۱۰۰	۰/۱۳۸
NSE	۰/۷۴۳	۰/۶۰۴	۰/۶۵۸
AM	۰/۸۰۶	۰/۶۲۶	۰/۶۵۵
نکویی برازش	خیلی خوب	خوب	خوب

برابر بیشتر از دما است (شکل شماره ۸). حساسیت کم شبکه‌های عصبی مصنوعی نسبت به تغییرات بارش در حوزه زشک می‌تواند به دلیل پیچیدگی توزیع باران همراه با پیچیدگی فرایند دبی رسوب باشد. نتایج به‌دست‌آمده با نتایج تحقیقات کیسی و همکاران (۲۲) و کیسی و گیون (۲۳) همخوانی دارد.

تحلیل حساسیت مدل

آنالیز حساسیت نشان می‌دهد که همه شبکه‌های بهینه نسبت به تغییرات دبی آب حساس هستند که نتایج حاصل از تحقیقات گذشته (۲۸) نیز نتایج به‌دست‌آمده از تحلیل حساسیت مدل CANFIS در حوزه آبخیز زشک را تأیید می‌کند. به‌عنوان مثال در شبکه S3_CANFIS حساسیت مدل به تغییرات در دبی آب حدوداً ۲۰ برابر بیشتر از باران و ۶



شکل ۸- تحلیل حساسیت شبکه S3_CANFIS

Figure 8. Sensitivity analysis of the S2_CANFIS network

است. با توجه به تعداد ورودی‌ها مشخص می‌شود که هر سه ورودی دبی آب، دما و باران تأثیر مثبتی را در مرحله آموزش بر عملکرد شبکه داشته‌اند. به عبارتی با افزایش اطلاعات ورودی عملکرد شبکه افزایش می‌یابد. نتایج نشان داد که هر سه شبکه CANFIS قدرت و کارایی نسبتاً مشابهی در طول فرایند آزمون دارند. ولی S3_CANFIS در مجموعه آزمون با داشتن MSE و NMSE کمتر در مقایسه با سایر سناریوها بهتر عمل کرده است. از طرفی این سناریو دارای NSE (ضریب نش) برابر با ۰/۷۴۳ و AM (سنجه جمعی) برابر با ۰/۸۰۶ بوده که نسبت به سناریوی S1_CANFIS با NSE

بعد از آموزش سناریوهای شبکه عصبی با ورودی‌های متفاوت، شبکه عصبی S3_CANFIS با معماری تابع عضویت بل، مدل فازی سوگنو، تابع انتقال تانژانت هایپربولیک، قانون آموزش لونبرگ مارکوات با حداقل MSE (میانگین مربعات خطا) و MSE نهایی به‌دست‌آمده طی مرحله آموزش به ترتیب با ارزش ۰/۰۲۶ و ۰/۰۲۶ که نسبت به S2_CANFIS و S1_CANFIS مقدار کمتری به دست آمد کارایی بهتری در پیش‌بینی بار رسوبی دارد. همچنین S3_CANFIS در مقایسه با دیگر سناریوها در مرحله اعتبارسنجی نیز قادر به تولید خروجی مناسب‌تری

نقطه‌ای با احتمال ۰/۹ و جهش یکنواخت با احتمال ۰/۰۱ استفاده گردید و تعداد تکرار برابر با ۱۰۰۰ تعداد جمعیت ۵۰ و حداکثر نسل تولیدشده ۲۰۰ در نظر گرفته شد. نتایج نشان می‌دهد الگوریتم ژنتیک با میزان ۲ برابر ۰/۸۹، NMSE برابر ۰/۵۵۴، همچنین با ضریب نش-ساتلکف برابر ۰/۶۵۸ و AM برابر ۰/۶۴۷ نسبت به مدل MLP عملکرد بهتری داشته است. با مقایسه شبکه عصبی CANFIS با MLP-GA با توجه به معیارهای MB برابر با ۰/۰۴۳، NSE برابر با ۰/۷۴۳ و AM برابر با ۰/۸۰۶ مشخص می‌شود که CANFIS عملکرد بهتری را در پیش‌بینی رسوب حوزه نسبت به سایر شبکه‌ها داشته است. اما با این‌وجود در مجموع شبکه عصبی در این حوزه کارایی کاملاً رضایت بخشی را در پیش‌بینی دقیق بار رسوبی نشان نداد. این می‌تواند به دلیل کمبود داده‌های آموزشی و غیردقیق بودن و وجود خطا در آمار حوزه باشد. آنالیز حساسیت نشان می‌دهد که همه شبکه‌های بهینه نسبت به تغییرات دبی آب حساس هستند. عدم حساسیت شبکه‌های عصبی مصنوعی در بهینه‌سازی تغییرات بارش در حوزه زشک می‌تواند به دلیل پیچیدگی توزیع مکانی و زمانی بارندگی همراه با پیچیدگی فرآیند دبی رسوب باشد.

تشکر و قدردانی

به این وسیله از همکاری شرکت آب منطقه‌ای خراسان رضوی به دلیل در اختیار قراردادن داده‌های هیدروکلیماتولوژی حوزه مطالعاتی قدردانی می‌شود.

برابر با ۰/۷۰۳ و AM برابر با ۰/۷۴۴ و مدل S2_CANFIS با NSE برابر با ۰/۶۸۱ و AM برابر با ۰/۷۱۰ عملکرد بهتری را نشان می‌دهد. شبکه عصبی CANFIS در برآورد نقاط حدی دچار تخمین کمتر از حد می‌شود که یکی از دلایل آن می‌تواند کمبود حضور داده‌های حدی در مرحله آموزش شبکه باشد. نتایج شبکه MLP حاکی از این است که سناریو S2_MLP با معماری ۵ نورون مخفی در ۲ لایه پنهان، تابع انتقال سیگموئید و قانون یادگیری مومنتم در مجموعه آزمون با داشتن MSE و NMSE کمتر در مقایسه با سایر سناریوهای MLP بهتر عمل کرده است. همچنین این سناریو دارای NSE (۰/۶۰۴) و AM (۰/۶۲۶) بالاتری بوده که نسبت به سناریوی S1_MLP با NSE برابر با ۰/۵۹۴ و AM برابر با ۰/۶۰۳ و مدل S3_MLP با NSE برابر با ۰/۵۹۸ و AM برابر با ۰/۶۰۷ عملکرد بهتری را نشان می‌دهد. با توجه به تعداد ورودی‌ها مشخص می‌شود که دو ورودی دبی آب و باران تأثیر مثبتی را در مرحله آموزش بر عملکرد شبکه داشته‌اند. از آنجایی که شبکه MLP در مقایسه با شبکه CANFIS عملکرد ضعیف‌تری را در برآورد میزان رسوب نشان داد، از الگوریتم ژنتیک برای آموزش و تعیین بهینه پارامترهای معماری شبکه S2_MLP کمک گرفته شد. در این تحقیق پارامترهای شبکه عصبی، شامل متغیرهای ورودی و تعداد نرون‌ها در لایه پنهان، با الگوریتم ژنتیک به نحوی بهینه‌سازی شدند که در مرحله آزمون، نتایج برآورد شده توسط مدل یا داده‌های خروجی، بهترین برآزش را با داده‌های واقعی، یا داده‌های مطلوب، داشته باشند. برای اجرای این بهینه‌سازی، در الگوریتم ژنتیک از تلاقی یک

منابع

1. Aln. M. and H.K. Cigizoglu. 2007. Suspended sediment load simulation by two artificial neural network methods using hydrometeorological data. *Journal of Environmental Modelling and Software*. 22(234): 2-13.
2. Araghinejad. S. and M. Karamouz. 2005. Long-Lead Stream Flow Forecasting Using Artificial Neural Networks and Fuzzy Inference System *Journal of Iranian Water Resources Research*, 1(2): 29-41 (In Persian).
3. American Society of Civil Engineers (ASCE). 2000. Artificial neural networks in hydrology, I: Preliminary concepts. *Journal of Hydrologic Engineering*. 5(35): 115-123.
4. Asselman. N.E.M. 2000. Fitting and interpretation of sediment rating curves. *Journal of Hydrology*. 234(3): 228-248.
5. Avtek. A. 2009. Co-active neurofuzzy inference system for evapotranspiration modeling. *Soft Computing*. 13(7): 691-700.
6. Aziz. K., A. Rahman. A.Y. Shamseldin and M. Shoaib. 2013. Co-active neuro fuzzy inference system for regional flood estimation in Australia. *Journal Hydrological Environment Result*, 1(1): 11-20.
7. Chuan, C.S. 1997. Weather prediction using artificial neural network. *Journal of Hydrology*, 230(3): 101-119.
8. Coulibaly. P.F., A. Anctil and B. Bohee. 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *Journal of Hydrology*. 230(3): 244-257.
9. Dastorani. M.T. 2007. Evaluation of the Application of Artificial Intelligence Model for Simulation and Real – Time Prediction of Flood Flow. *Journal of Science and Technology of Agriculture and Natural Resources*. 40(20): 27-37 (In Persian).
10. 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 modeling in Zavandeh-rood dam basin. *Journal of Water and Wastewater*. 80: 114-125 (In Persian).
11. Dastorani. M.T., Kh. Azimi Fafhi. A. Talebi and M.R. Ekhtesasi. 2012. Estimation of Suspended Sediment Using Artificial Neural Network (Case Study: Jamishan Watershed in Kermanshah). *Journal of Watershed Management Research*. 3(6): 61-74 (In Persian).
12. Dehghani. A., A. Zanganeh. M.F. Mosaedi and N. Kouhestani. 2009. Comparison of suspended sediment estimation by artificial neural network and sediment rating curve methods (Case Study: Dooz river in Golestan province). *Journal of Agricultural Sciences and Natural Resources*, 16(1-A): 266-276 (In Persian).

13. Dehghani, N. and M. Vafakhah. 2013. Comparison of Daily Suspended Sediment Load Estimations by Sediment Rating Curve and Neural Network Models (Case Study: Ghazaghli Station in Golestan Province). *Journal of Soil and Water Conservation Studies*, 20(2): 221-230 (In Persian).
14. Ebrahimpour, M., S.K. Balasundram, J. Talib, A.R. Anuar and H. Memarian. 2011. Accuracy of GeoWEPP in estimating sediment load and runoff from a tropical watershed. *Malaysian Journal of Soil Science*. 15: 25-33.
15. Faghih, H. 2010. Evaluating Artificial Neural Network and its Optimization Using Genetic Algorithm in Estimation of Monthly Precipitation Data (Case Study: Kurdistan Region). *Journal of Science and Technology of Agriculture and Natural Resources*. 4(51): 27-44 (In Persian).
16. Feiznia, S., H. Asgari and M. Moazzami. 2008. Investigating the applicability of Neural Network method for estimating daily suspended sediment yield (Case study: Zard Drainage Basin, Khuzestan Province). *Journal of the Iranian Natural Resources*. 60(4): 1199-1210 (In Persian).
17. Hagan, M.T. and M.B. Menhai. 1994. Training feedforward networks with the Marquardt algorithm. *IEEE transactions on Neural Networks*, 5(6): 989-993.
18. Hemachandra, S. and R.V.S. Satyanarayana. 2013. Co-active neuro-fuzzy inference system for prediction of electric load. *International Journal of Electrical and Electronics Engineering Research*. 3(2): 217-222.
19. Holland, J.H. 1975. Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence. 228 pp. U Michigan Press.
20. Jang, J.S. 1993. ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*. 23(3): 665-685.
21. Jang, J.S.R., C.T. Sun and E. Mizutani. 1997. Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence. Prentice Hall Upper Saddle River, N.J. P. 614.
22. Kisi, O., A.H. Dailr, M. Cimen and J. Shiri. 2012. Suspended sediment modeling using genetic programming and soft computing techniques. *Journal of Hydrology*. 450(5): 48-58.
23. Kisi, O. and A. Guven. 2010. A machine code-based genetic programming for suspended sediment concentration estimation. *Advances in Engineering Software*. 41(7): 939-945.
24. Melesse, A.M., S. Ahmad, M.E. McClain, X. Wang and Y.H. Lim. 2011. Suspended sediment load prediction of river systems: An artificial neural network approach. *Journal of Agricultural Water Management*. 98(5): 855-866.
25. Memarian, H. and S.K. Balasundram. 2012. Comparison between multi-layer perceptron and radial basis function networks for sediment load estimation in a tropical watershed. *Journal of Water Resource and Protection*. 4(10): 870-876.
26. Memarian, H., M.P. Bilondi and M. Rezaei. 2016. Drought prediction using co-active neuro-fuzzy inference system: validation, and uncertainty analysis (case study: Birjand, Iran). *Theoretical and applied climatology*. 125(3-4): 541-554.
27. Memarian, H., S. Feiznia and K. Zakikhani. 2009. Estimating river suspended sediment yield using MLP neural network in arid and semi-arid basins (Case study: Bar River, Neyshaboor, Iran). *Desert*. 14(1): 43-52.
28. Memarian, H., S.K. Balasundram and M. Taibakhsh. 2013. An expert integrative approach for sediment load simulation in a tropical watershed. *Journal of Integrative Environmental Sciences*, 10(3-4): 161-178.
29. Menhai, M.B. 2002. The Basics of Neural Networks. Amir Kabir University of Technology. First volume, second edition. 715 pp., Tehran, Iran (In Persian).
30. Mohammadi, Y., P. Fathi, A. Naiafi Nejad and N. Nura. 2008. Estimation of the average monthly discharge using Artificial Neural Network (Case study: the Queshlan's watershed of Sanandaj). *Journal of Agricultural Sciences and Natural Resources*. 4: 258-268 (In Persian).
31. Mosaedi, A. and S. Hashemi. 2005. Comparison of Artificial Neural Network Efficiency in Preparation of Sediment Curve. *Proceedings of the 3th National Conference on Erosion and Sediment*, 5 pp., Tehran, Iran (In Persian).
32. Mosaedi, A., M. Jalali and M. Naiafi Hainpour. 2007. Estimation of Suspended Sediment Discharges Applying Artificial Neural Network in Tamar Hydrometric Station (Gorganroud-Iran). *Proceedings of the 7th International River Engineering Workshop*. 8 pp., Ahwaz, Iran (In Persian).
33. Mustafa, M.R., R.B. Rezaei, S. Saiedi and M.H. Isa. 2012. River suspended sediment prediction using various multilayer perceptron neural network training algorithms a (case study: in Malaysia). *Journal of Water resources management*. 26(7): 1879-1897.
34. Nash, J.E. and J.V. Sutcliffe. 1970. River flow forecasting through conceptual models part I A discussion of principles. *Journal of Hydrology*. 10(3): 282-290.
35. Nourani, V. and L. Malekani. 2010. Use of comparative neuro-fuzzy system in rainfall-runoff modeling. *Proceedings of the 5th Congress on Civil Engineering*. 6 pp., Mashhad, Iran (In Persian).
36. Principe, J.C., N.R. Euliano and W.C. Lefebvre. 2000. Neural and adaptive systems: fundamentals through simulations (Vol. 672). New York: Wiley.
37. Principe, J.C., W.C. Lefebvre, G. Ivann, C. Fancourt and D. Wooten. 2007. NeuroSolutions-Documentation, the Manual and On-Line Help. Version 5.05. NeuroDimension, Inc.
38. Rezaei, M. and H. Memarian. 2015. Application of Rainfall Time Series and Climatic Indices for Drought Prediction using Co-Active Neurofuzzy Inference System (Case Study: Birjand, Southern Khorasan). *Journal of Arid Biome*. 5(2): 51-67 (In Persian).
39. Rumelhart, D.E. and D. Zinzer. 1986. Feature discovery by competitive learning, *Parallel distributed processing: explorations in the microstructure of cognition*. vol. 1: foundations.
40. Safari, A.F., D. Smedt and F. Moreda. 2012. WetSna model application in the distributed model intercomparison project (DMIP2). *Journal of Hydrology*, 418: 78-89.

41. Tan. Y. and A.Van Cauwenberghe. 1999. Neural-network-based d-sten-ahead predictors for nonlinear systems with time delay. Engineering applications of artificial intelligence. 12(1): 21-35.
42. Tfwala. S.S., Y.M. Wang and Y.C. Lin. 2013. Prediction of missing flow records using multilayer perceptron and coactive neurofuzzy inference system. Journal of Scientific World. 2013. 1-7.
43. Wilson. D.R. and T.R. Martinez. 2003. The general inefficiency of batch training for gradient descent learning. Journal of Neural Networks. 16(10): 1429-1451.
44. Yosefi. M. and R. Poorshariaty. 2014. Suspended Sediment Estimation using Neural Network and Algorithms Assessment (Case Study: Lorestan Province). Journal of Watershed Management Research. 5(10): 85-97 (In Persian).
45. Zare Ahvaneh. H. and M. Bavat Varkeshi. 2011. Evaluation of Artificial Intelligent and Empirical Models in Estimation of Annual Runoff. Journal of Water and Soil. 25(2): 365-379 (In Persian).
46. Zealand. C.M., D.H. Burn and S.P. Simonovic. 1999. Short term streamflow forecasting using artificial neural networks. Journal of Hydrology, 214(1): 32-48.

Performance Comparison of the Neural Networks CANFIS, MLP and Optimized MLP using Genetic Programming for Suspended Sediment Load Simulation (Case study: Zoshk-Abardeh Watershed, Shandiz, Iran)

Seyed Mohammad Tajbakhsh¹, Hadi Memarian² and Fatemeh Mohammadi³

1- Assistant Professor, Faculty Natural Resources and Environment, University of Birjand

2- Assistant Professor, Faculty Natural Resources and Environment, University of Birjand

(Corresponding Author: hadi_memarian@birjand.ac.ir)

3- Graduated M.Sc. Students, Watershed Management Engineering, University of Birjand

Received: June 23, 2017

Accepted: January 13, 2018

Abstract

In this study, the predictive performance of three Artificial Neural Networks (ANNs), i.e. Co-Active NeuroFuzzy Inference System (CANFIS), Multi-Layer Perceptron (MLP) and MLP integrated with Genetic Algorithm (GA) in the Zoshk-Abardeh watershed were compared. In this study, three scenarios were considered and simulated in each model. In order to simulate the scenario S1 water flow were fed into the network as input. Daily water discharge and rainfall depth were considered as the input for the scenario S2. The scenario S3 was simulated based on the water discharge, daily rainfall and temperature as the inputs. In all scenarios daily sediment load was considered as the network output. Results showed that the optimum architecture for the S3_CANFIS (as the best network) was based on the Bell membership function, hyperbolic tangent transfer function and the Levenberg-Marquardt training algorithm. The S3_CANFIS with the lower MSE and NMSE acted better as compared with other scenarios during the testing process. This scenario based on the NSE equal to 0.743 and the AM equal to 0.806 showed better performance, as well. The results also suggest that the S2_MLP with 5 neurons in two hidden layers, sigmoid transfer function and the momentum learning algorithm with NSE and AM equal to 0.604 and 0.626, respectively acted better as compared with other MLP scenarios. Since the MLP network compared with CANFIS showed weaker performance in sediment yield simulation, the GA was integrated with MLP to determine the optimal network architecture parameters for the S2_MLP. Results showed that GA-MLP with NSE and AM equal to 0.658 and 0.655, respectively led to a higher capability for sediment load simulation in comparison with MLP network. Totally, the S3_CANFIS according to the criteria MB equal to -0.043, NSE equal to 0.743 and AM equal to 0.806 showed better performances in predicting sediment yield than the other networks in the studied watershed. However, both networks did not show a satisfactory power in sediment load simulation which could be arisen from the lack of data (especially extreme data) in the training series and also the existence of systematic error in observed records.

Keywords: Neural network, CANFIS, Multi-Layer Perceptron, Genetic Algorithm, Sensitivity analysis, Water discharge, Sediment load