

## ارزیابی کارایی مدل‌های شبکه عصبی-فازی تطبیقی و شبکه عصبی مصنوعی در پیش‌بینی رسوب معلق روزانه (مطالعه موردی: حوضه آبخیز گرو)

مجتبی دولت کردستانی - دانشجوی دکتری بیابان‌زدایی دانشگاه هرمزگان، راتبه بخش مرتع و آبخیزداری، دانشگاه جیرفت.  
احمد نوحه‌گر\* - استاد گروه برنامه‌ریزی، مدیریت و آموزش محیط زیست، دانشکده محیط زیست دانشگاه تهران.  
سعید جانی‌زاده - دانشجوی دکتری آبخیزداری، گروه مهندسی آبخیزداری، دانشکده منابع طبیعی و علوم دریایی دانشگاه تربیت مدرس.

پذیرش مقاله: ۱۳۹۶/۰۶/۲۵      تأیید نهایی: ۱۳۹۷/۰۱/۲۸

### چکیده

مدلسازی و پیش‌بینی دقیق رسوب معلق در رودخانه عنصر کلیدی مدیریت منابع آب و سیاست‌های محیط زیستی می‌باشد. در این پژوهش کارایی مدل‌های شبکه عصبی مصنوعی و شبکه عصبی-فازی تطبیقی در پیش‌بینی بار رسوب معلق روزانه ایستگاه گرو واقع در حوضه آبخیز گرو مورد ارزیابی قرار گرفت. بدین منظور از آمار ۷۸۲ نمونه (۱۳۸۰-۱۳۹۳) رسوب معلق برحسب میلی گرم بر لیتر و دبی جریان اندازه‌گیری شده متناظر با رسوب بر حسب متر مکعب بر ثانیه در سه الگوی ورودی مختلف استفاده شد. برای اجرای مدل‌های شبکه عصبی مصنوعی و شبکه عصبی-فازی تطبیقی داده‌ها به دو دسته آموزش و آزمون تقسیم به طوری که ۸۰٪ داده‌ها برای آموزش و ۲۰٪ برای آزمون در نظر گرفته شد. در شبکه عصبی مصنوعی از دو تابع سیگموئید و تابع تانژانت هیپربولیک در لایه میانی و از تابع خطی در لایه خروجی و برای انجام مدل شبکه عصبی-فازی تطبیقی از روش تفکیک شبکه‌ای با سه تابع عضویت (مثلی، گوسی و زنگوله‌ای تعمیم یافته) با تعداد عضویت بهینه که با سعی و خطا تعیین شد استفاده گردید. نتایج حاصل از پیش‌بینی رسوب معلق نشان داد که بهترین پیش‌بینی با ضریب همبستگی ۰/۹۶، ضریب کارایی ۰/۹۵ و میانگین مربعات خطای ۴۷۸۹/۱۲ میلی گرم بر لیتر مربوط به الگوی ورودی ۲ با متغیرهای ورودی دبی جریان روز جاری (Qt) و تاخیر دبی جریان روزانه تا ۱ روز قبل از مبدا زمانی پیش‌بینی (Qt-1) و تاخیر رسوب معلق روزانه تا ۱ روز قبل از مبدا زمانی پیش‌بینی (St-1) می‌باشد. بررسی نتایج حاصل از مدل‌های شبکه عصبی-فازی تطبیقی و شبکه عصبی مصنوعی نشان داد که مدل شبکه عصبی-فازی تطبیقی در هر سه الگو عملکرد بهتری نسبت به شبکه عصبی مصنوعی در پیش‌بینی رسوب معلق روزانه داشته است.

واژگان کلیدی: حوضه آبخیز گرو، شبکه عصبی مصنوعی، شبکه عصبی-فازی تطبیقی، رسوب معلق روزانه.

## مقدمه

یکی از مهم‌ترین مسائلی که در مدیریت حوضه‌های آبخیز مطرح است، پیش‌بینی فرآیندهای هیدرولوژیکی است (فیرات و گنگور<sup>۱</sup>، ۲۰۰۷). پیش‌بینی بار رسوبی در طیف وسیعی از مباحث مانند تعیین حجم سدها، انتقال رسوب‌ها در رودخانه، طراحی ستون پل‌ها، لایروبی و برداشت شن و ماسه از بستر رودخانه مورد استفاده قرار می‌گیرد (ناکوتو<sup>۲</sup>، ۱۹۹۰؛ مک بین<sup>۳</sup>، ۱۹۸۸). همچنین رسوب‌ها منشاء آلودگی‌هایی چون میکروبوها، آفت‌کش‌های برداشت شده از مزارع و دیگر ترکیبات شیمیایی هستند (لوپز<sup>۴</sup> و همکاران، ۲۰۰۲). لذا برآورد دقیق میزان بار معلق رسوبی می‌تواند در مسائلی مانند طراحی مخازن، برآورد آلودگی دریاچه، تعیین خسارت ناشی از رسوب‌گذاری به محیط زیست و تعیین تأثیرات مدیریت آبخیز مفید باشد (طهمورث و همکاران، ۱۳۸۸). با توجه به عدم وجود اطلاعات کافی و صحیح از فرسایش، انتقال رسوب و رسوب‌گذاری در رودخانه‌ها و مخازن سدهای ایران و همچنین جوان بودن تحقیقات در این زمینه و فقدان اندازه‌گیری‌های درازمدت رسوب، دسترسی به داده‌های قابل اعتماد رسوب مشکل بوده و لزوم استفاده از روش‌های برآورد و پیش‌بینی رسوب را مطرح می‌سازد (دهقانی و همکاران، ۱۳۸۸). از جمله روش‌های متداول در تخمین بار رسوب معلق در ایستگاه‌های هیدرومتری استفاده از روش‌های منحنی‌های سنج رسوب است که همواره با خطای زیادی همراه است (اسلمن<sup>۵</sup>، ۲۰۰۰). در این شرایط استفاده از روش‌های هوشمند (شبکه‌های عصبی مصنوعی، سیستم استنتاج فازی-عصبی و ...) به لحاظ توانایی آن‌ها در برقرار کردن ارتباط بین ورودی و خروجی یک فرآیند بدون در نظر گرفتن فیزیک آن مسئله ابزار مناسبی در پیش‌بینی رسوب معلق محسوب می‌گردد (وفاخواه، ۲۰۱۲). در خصوص برآورد رسوب معلق مطالعات مختلفی صورت گرفته است. کیشی<sup>۶</sup> و همکاران (۲۰۰۹) دقت روش محاسباتی شبکه عصبی-فازی تطبیقی را در تخمین رسوبات بار معلق ماهانه مورد بررسی قرار دادند، نتایج نشان داد که روش شبکه عصبی-فازی تطبیقی دقت خوبی در برآورد رسوب معلق دارد. رضایی بنفشه و همکاران (۱۳۹۲) با استفاده از مدل‌های سیستم استنتاج فازی عصبی، رگرسیون چند متغیره و منحنی سنج رسوب، بار رسوبی را در حوضه رودخانه قرائقو آذربایجان شرقی مدل‌سازی نمودند نتایج این بررسی نشان داد که مدل استنتاج فازی عصبی نسبت به دو مدل دیگر با عملکرد بالایی توانسته بار رسوبی را برآورد نماید. برزگری و دستورانی (۱۳۹۴) بار معلق رودخانه گرگانرود را با استفاده از مدل‌های سری زمانی و شبکه عصبی مصنوعی پیش‌بینی نمودند، نتایج نشان داد که شبکه عصبی مصنوعی در مقایسه با مدل‌های سری زمانی توانایی بهتری در پیش‌بینی و مدل‌سازی رسوب ماهانه دارد. خورشید دوست و همکاران (۱۳۹۴) قابلیت مدل‌های سیستم استنتاج فازی عصبی و مدل‌های شبکه عصبی مصنوعی را در تخمین بار معلق رودخانه زرینه رود حوضه دریاچه ارومیه مورد ارزیابی قرار دادند، بررسی‌ها نشان داد که مدل ANFIS با داشتن خطای کم نسبت به سایر مدل‌ها کارایی بهتری دارد. ذونعمت کرمانی و همکاران (۲۰۱۶) به مدل‌سازی غلظت بار معلق رسوبی در سه ایستگاه هیدرومتری در آمریکا با استفاده از مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان پرداختند، نتایج نشان داد که استفاده از الگوریتم BFGS باعث بهبود عملکرد شبکه عصبی شعاعی و ماشین بردار پشتیبان با تابع کرنل در پیش‌بینی می‌گردد. کیشی و ذونعمت کرمانی (۲۰۱۶) غلظت بار معلق رسوبی را در دو ایستگاه مونتانا آمریکا با استفاده از مدل‌های شبکه عصبی مصنوعی، شبکه عصبی فازی تطبیقی و شبکه عصبی فازی تطبیقی با الگوریتم خوشه‌ای مورد بررسی قرار دادند، نتایج آنان نشان داد که شبکه عصبی فازی تطبیقی عملکرد بهتری نسبت به شبکه عصبی مصنوعی در پیش‌بینی غلظت بار معلق رسوب دارد و شبکه عصبی فازی تطبیقی با الگوریتم

1- Firat and Gungor

2- Nakato

3- McBean

4- Lopez

5- Asselman

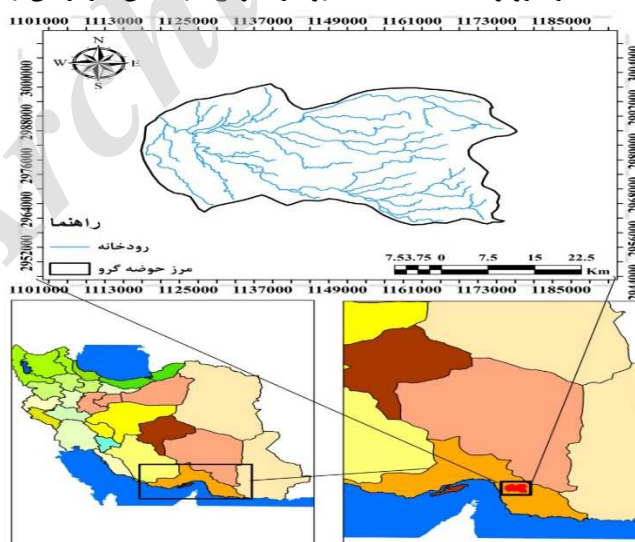
6- Kisi

خوشه‌ای باعث افزایش عملکرد بهتر و کاهش زمان کالیبراسیون می‌گردد. کاوه و همکاران (۲۰۱۷) به پیش‌بینی رسوب معلق روزانه با استفاده از سه الگوریتم شبکه عصبی فازی تطبیقی پرداختند، نتایج نشان داد که الگوریتم هیبرید و لونبرگ-مارگوردت عملکرد مناسبی در پیش‌بینی رسوب معلق روزانه دارند و الگوریتم لونبرگ-مارگوردت نسبت به دو الگوریتم دیگر کارایی بهتری دارد. با توجه به محدودیت‌های ابزار و فنون اندازه‌گیری پارامترهای هیدرولوژی و نیز محدودیت اطلاعات موجود، شبیه‌سازی فرآیندهای هیدرولوژیکی امری اجتناب‌ناپذیر می‌باشد. بنابراین، هدف این تحقیق شناسایی توانایی شبکه عصبی فازی تطبیقی و شبکه عصبی مصنوعی جهت پیش‌بینی رسوب معلق روزانه در حوضه آبخیز گرو می‌باشد.

## مواد و روش‌ها

### منطقه مورد مطالعه

حوضه آبخیز گرو با وسعت  $۱۷/۶۳$  کیلومتر مربع در محدوده جغرافیایی  $۵۷$  درجه و  $۱۵$  دقیقه تا  $۵۷$  درجه و  $۲۷$  دقیقه طول شرقی و در  $۲۶$  درجه و  $۴۸$  دقیقه تا  $۲۶$  درجه و  $۵۶$  دقیقه عرض شمالی واقع شده است. این حوضه در فاصله  $۱۴۰$  کیلومتری شرق بندرعباس و  $۴۰$  کیلومتری جنوب شرق میناب قرار گرفته است. دشت گرو همانند اغلب حوضه‌های آبخیز جنوب کشور در قلمرو مناطق خشک قرار گرفته است. که به سبب جبر جغرافیایی حاکم بر منطقه میزان بارندگی آن کم و رگباری است. جریان‌های سطحی این حوضه از طریق رودخانه زرانی به دریای عمان ریخته می‌شود. بر اساس اطلاعات گردآوری شده از ایستگاه کليما تولوژی مازابی دمای متوسط سالانه این منطقه  $۲۶/۹$  درجه سانتی‌گراد و مقدار بارندگی سالانه  $۲۰۲$  میلی‌متر می‌باشد. این حوضه تحت تأثیر ویژگی‌های زمین‌شناسی و ژئومورفولوژی از نفوذپذیری اندکی برخوردار می‌باشد و تغذیه‌ی آب‌های زیرزمینی آن تنها در قسمت‌های کم‌شیب و مسطح دشت صورت می‌گیرد. علاوه بر تغذیه نامناسب بهره‌برداری بیش از ظرفیت از منابع آبی آن باعث تنزل کمی آبخوان دشت شده است (عقیفی و همکاران، ۲۰۱۲). شکل ۱ موقعیت مکانی حوضه آبخیز گرو و ایستگاه‌های هیدرومتری واقع در استان هرمزگان را نشان می‌دهد.



شکل ۱: موقعیت حوضه گرو

### روش تحقیق

در این پژوهش از آمار  $۷۸۲$  نمونه ( $۱۳۸۰-۱۳۹۳$ ) رسوب معلق برحسب میلی گرم بر لیتر و دبی جریان اندازه‌گیری شده متناظر با رسوب بر حسب متر مکعب بر ثانیه ایستگاه هیدرومتری گرو استفاده شد.

شبکه عصبی مصنوعی<sup>۱</sup>

یک شبکه عصبی مصنوعی (ANN) ایده‌ای است برای پردازش اطلاعات که از سیستم عصبی زیستی الهام گرفته شده و مانند مغز به پردازش اطلاعات می‌پردازد. این سیستم از شمار زیادی عناصر پردازشی فوق العاده به هم پیوسته به نام نرون تشکیل شده که برای حل یک مسأله با هم هماهنگ عمل می‌کند (وفاخواه، ۲۰۱۲). شبکه‌های عصبی مصنوعی، قابلیت یادگیری، فراخوانی و تعمیم یافتن از الگوهای یادگیری داده‌ها را دارا هستند. این شبکه‌ها می‌توانند برای یک عمل خاص با تعدیل وزن‌های بین عناصر، آموزش ببینند. معمولاً شبکه‌های عصبی آموزش می‌بینند تا یک ورودی خاص را به یک خروجی خاص تبدیل نمایند (رید<sup>۲</sup> و همکاران، ۲۰۰۴). جهت انتخاب ساختار بهینه شبکه عصبی مصنوعی، تعداد نرون لایه میانی از ۱ تا ۲۰ برای دو تابع انتقال سیگموئید و تانژانت هیپربولیک مورد بررسی قرار گرفت. برای جلوگیری از کوچک شدن بیش از حد وزن‌های شبکه‌های عصبی مصنوعی، ورودی‌های شبکه‌های عصبی مصنوعی باید استاندارد شوند (وفاخواه، ۲۰۱۲؛ ایمری<sup>۳</sup> و همکاران، ۲۰۰۰؛ حسینی و برهانی، ۲۰۰۹). در این تحقیق به منظور استانداردسازی داده‌ها از رابطه (۱) استفاده شد.

(۱)

$$N_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}}$$

که در این رابطه:  $N_i$  مقادیر استاندارد شده،  $X_i$  مقادیر واقعی،  $X_{\min}$  حداقل مقادیر واقعی و  $X_{\max}$  حداکثر مقادیر واقعی می‌باشد که این رابطه ورودی‌های شبکه عصبی را بین ۰ و ۱ نرمال می‌نماید. به منظور مدل‌سازی از شبکه پیش‌خور با الگوریتم آموزش انتشار خطا به عقب و توقف آموزش مورد استفاده قرار گرفت. و داده‌ها به دو دسته آموزش و آزمون تقسیم به طوری که ۸۰٪ داده‌ها برای آموزش و ۲۰٪ برای آزمون در نظر گرفته و از دو تابع سیگموئید و تابع تانژانت هیپربولیک در لایه میانی و از تابع خطی در لایه خروجی استفاده شد. جهت انتخاب ساختار بهینه شبکه عصبی مصنوعی، تعداد نرون لایه میانی از ۱ تا ۲۰ برای دو تابع انتقال سیگموئید و تانژانت هیپربولیک در لایه پنهان تغییر داده شد و در هر مرحله میزان خطا، کارایی و ضریب همبستگی محاسبه و در نهایت ساختاری که دارای کمترین خطا بود به عنوان ساختار بهینه انتخاب شد.

شبکه عصبی فازی - تطبیقی<sup>۴</sup>

در طراحی مدل نروفازی، از شبکه عصبی چند لایه پیش‌خور (MFNN) با الگوریتم یادگیری پس انتشار خطا و سیستم استنتاج فازی ساگنو<sup>۵</sup> با تابع ورودی تفاوت دو سیگموئید و تابع خروجی خطی و برای غیر فازی نمودن از تابع میانگین متحرک استفاده گردید (وفاخواه، ۲۰۱۲). شبکه‌های عصبی فازی - تطبیقی در حقیقت ترکیبی از شبکه‌های عصبی مصنوعی و سیستم‌های فازی می‌باشد، که با استفاده از یک مجموعه اطلاعات ورودی و خروجی، تابع جعبه ابزار منطق فازی ANFIS یک سیستم استنتاج فازی (FIS) می‌سازد، که پارامترهای تابع عضویت آن به روش انتشار برگشتی به

1- Artificial Neural Network

2- Riad

1- Imrie

2- Adaptive Neuro-Fuzzy Inference System (ANFIS)

3- Sugno

تنهایی و یا همراه با روش حداقل مربعات تعدیل می‌شوند (جانگ، ۱۹۹۳). برای انجام مدل شبکه عصبی فازی - تطبیقی از روش تفکیک شبکه‌ای با سه تابع عضویت (مثلی، گوسی و زنگوله‌ای تعمیم یافته) با تعداد عضویت بهینه که با سعی و خطا تعیین شد، استفاده گردید.

### الگوهای ورودی مدل

در جدول ۱ الگوهای مورد استفاده در مدل شبکه عصبی مصنوعی و شبکه عصبی فازی - تطبیقی ارائه شده است. این الگوها شامل ۳ الگو می‌باشد. الگوی اول شامل دبی جریان روز جاری ( $Q_t$ : مبدا زمانی پیش بینی) و تاخیر دبی جریان روزانه تا ۱ روز قبل از مبدا زمانی پیش بینی ( $Q_{t-1}$ ) می‌باشند. الگوی دوم شامل دبی جریان روز جاری ( $Q_t$ : مبدا زمانی پیش بینی) و تاخیر دبی جریان روزانه تا ۱ روز قبل از مبدا زمانی پیش بینی ( $Q_{t-1}$ ) و تاخیر رسوب معلق روزانه تا ۱ روز قبل از مبدا زمانی پیش بینی ( $S_{t-1}$ ) و الگوی سوم شامل دبی جریان روز جاری ( $Q_t$ : مبدا زمانی پیش بینی) و تاخیر دبی جریان روزانه ۱ تا ۲ روز قبل از مبدا زمانی پیش بینی ( $Q_{t-1}, Q_{t-2}$ ) و تاخیر رسوب معلق روزانه ۱ تا ۲ روز قبل از مبدا زمانی پیش بینی ( $S_{t-1}, S_{t-2}$ ) می‌باشند.

جدول ۱- الگوهای ورودی مدل

الگوی ورودی	ردیف
$Q_{t-1}, Q_t$	الگوی ۱
$S_{t-1}, Q_{t-1}, Q_t$	الگوی ۲
$S_{t-2}, S_{t-1}, Q_{t-2}, Q_{t-1}, Q_t$	الگوی ۳

### معیار ارزیابی مدل‌ها

به منظور مقایسه مدل‌های مورد استفاده در این تحقیق از نمایه‌های آماری ضریب کارایی ناش - ساتکیف ( $CE$ ) (رابطه ۲)، مجذور میانگین مربعات خطا ( $RMSE$ ) (رابطه ۳) و ضریب تبیین (رابطه ۴) استفاده گردید.

$$CE = 1 - \frac{\sum_{i=1}^n (Y_o - Y_e)^2}{\sum_{i=1}^n (Y_o - \bar{Y}_o)^2} \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_o - Y_e)^2} \quad (3)$$

$$R^2 = \frac{\sum_{i=1}^n (Y_o - \bar{Y}_o)(Y_e - \bar{Y}_e)}{(\sum_{i=1}^n (Y_o - \bar{Y}_o)^2)^{0.5} (\sum_{i=1}^n (Y_e - \bar{Y}_e)^2)^{0.5}} \quad (4)$$

که در آن‌ها  $Y_o$  مقدار مشاهده‌ای متغیر وابسته، مقدار تخمینی متغیر وابسته،  $\bar{Y}_o$  میانگین مقدار مشاهده‌ای متغیر وابسته و میانگین مقدار تخمینی متغیر وابسته است.

## بحث و یافته‌ها

نتایج شبکه عصبی مصنوعی برای دو تابع سیگموئید و تانژانت هیپربولیک در جدول ۲ نشان داده شده است. در جدول ۳ نیز نتایج حاصل از شبکه عصبی فازی تطبیقی برای الگوی ورودی ۱ با نوع تابع عضویت نشان داده شده است.

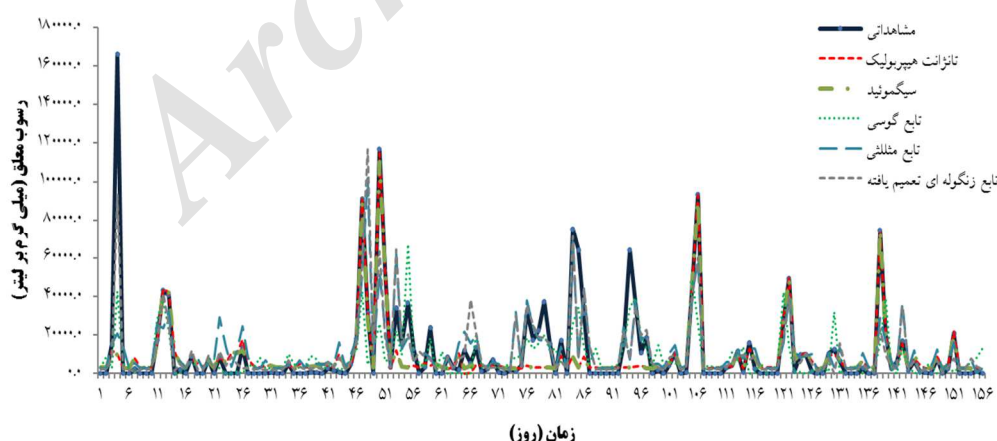
جدول ۲- نتایج شبکه عصبی مصنوعی در مرحله آزمون بر اساس الگوی ورودی ۱

ارایش شبکه	تابع انتقال	R <sup>2</sup>	RMSE	CE
۲-۶-۱	تانژانت هیپربولیک	۰/۴۸	۱۶۹۹۹/۳	۰/۴۷
۲-۳-۱	سیگموئید	۰/۴۵	۱۷۰۵۹/۰۳	۰/۴۶

جدول ۳- نتایج شبکه عصبی-فازی تطبیقی در مرحله آزمون بر اساس الگوی ورودی ۱

روش	تابع فازی ساز	R <sup>2</sup>	RMSE	CE
	مثلثی	۰/۴	۱۸۰۲۵/۲۶	۰/۴
تفکیک شبکه ای	گوسی	۰/۴۸	۱۷۰۵۱/۵۱	۰/۴۶
	زنگوله ای-تعمیم یافته	۰/۵۸	۱۵۰۵۰/۷۳	۰/۵۸

با توجه به نتیجه جدول ۲ مشاهده می‌گردد که در مدل شبکه عصبی مصنوعی دو تابع تانژانت هیپربولیک و سیگموئید کارایی پایینی در پیش‌بینی رسوب معلق روزانه دارند. نتیجه جدول ۳ نشان دهنده این است که شبکه عصبی فازی-تطبیقی با تابع زنگوله‌ای تعمیم یافته با ضریب همبستگی ۰/۵۸، ضریب کارایی ۰/۵۸ و میانگین مربعات خطای ۱۵۰۵۰/۷۳ میلی گرم بر لیتر عملکرد بهتری نسبت به سایر توابع فازی ساز داشته و توابع فازی ساز مثلثی و گوسی کارایی پایینی در پیش‌بینی رسوب معلق روزانه دارند. همچنین بررسی نتایج جدول ۲ و ۳ بیانگر این است که مدل شبکه عصبی فازی-تطبیقی با تابع فازی ساز زنگوله‌ای تعمیم یافته عملکرد بهتری نسبت به مدل شبکه عصبی مصنوعی دارد. نتایج حاصل از پیش‌بینی رسوب معلق روزانه با استفاده از دو مدل شبکه عصبی مصنوعی و شبکه عصبی فازی تطبیقی بر اساس الگوی ورودی ۱ در شکل ۲ نشان داده شده است.



شکل ۲- نمودار مشاهداتی و پیش‌بینی رسوب معلق روزانه بر اساس الگوی ورودی ۱ در مرحله آزمون

در جدول ۴ و ۵ نتایج حاصل از شبکه عصبی مصنوعی و شبکه عصبی فازی تطبیقی بر اساس الگوی دو نشان داده شده است.

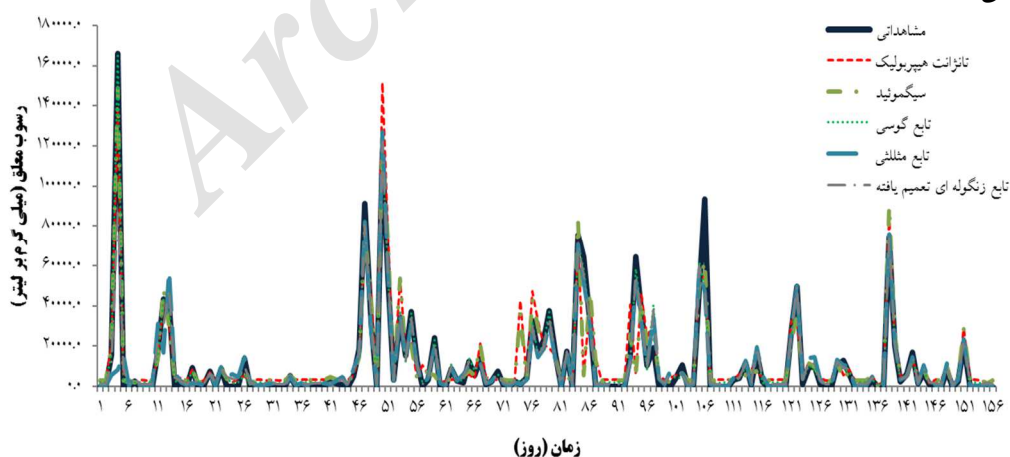
جدول ۴- نتایج شبکه عصبی مصنوعی در مرحله آزمون بر اساس الگوی ورودی ۲

ارایش شبکه	تابع انتقال	R <sup>2</sup>	RMSE	CE
۳-۵-۱	تانژانت هیپربولیک	۰/۷۹	۱۰۸۳۱/۶۸	-۰/۷۸
۳-۳-۱	سیگموئید	۰/۸۳	۹۶۶۳/۵۶	-۰/۸۳

جدول ۵- نتایج شبکه عصبی-فازی تطبیقی در مرحله آزمون بر اساس الگوی ورودی ۲

روش	تابع فازی ساز	R <sup>2</sup>	RMSE	CE
تفکیک شبکه ای	مثلثی	۰/۶۴	۱۳۹۰۹/۷۶	-۰/۶۴
	گوسی	۰/۹۶	۴۷۸۹/۱۲	-۰/۹۵
	زنگوله ای تعمیم یافته	۰/۹۰	۸۰۴۹	-۰/۸۸

با توجه به نتیجه جدول ۴ مشاهده می گردد که در مدل شبکه عصبی مصنوعی تابع سیگموئید با ضریب تبیین ۰/۸۳، ضریب کارایی ۰/۸۳ و میانگین مربعات خطای ۹۶۶۳/۵۶ میلی گرم بر لیتر عملکرد بهتری نسبت به تابع تانژانت هیپربولیک داشته است. نتیجه جدول ۵ بیانگر این است که شبکه عصبی فازی- تطبیقی با تابع گوسی با ضریب همبستگی ۰/۹۶، ضریب کارایی ۰/۹۵ و میانگین مربعات خطای ۴۷۸۹/۱۲ میلی گرم بر لیتر عملکرد بهتری نسبت به سایر توابع فازی ساز داشته است. همچنین بررسی نتایج جداول ۴ و ۵ نشان می دهد که در مدل شبکه عصبی فازی- تطبیقی توابع فازی ساز گوسی و زنگوله ای تعمیم یافته عملکرد بالایی در پیش بینی رسوب معلق روزانه داشته اند در حالی که تابع فازی ساز مثلثی کارایی پایین تری نسبت به سایر توابع فازی ساز و توابع مدل شبکه عصبی مصنوعی دارد. نتایج حاصل از پیش بینی رسوب معلق روزانه با استفاده از دو مدل شبکه عصبی مصنوعی و شبکه عصبی فازی تطبیقی بر اساس الگوی ورودی ۲ در شکل ۳ نشان داده شده است.



شکل ۳- نمودار مشاهداتی و پیش بینی رسوب معلق روزانه بر اساس الگوی ورودی ۲ در مرحله آزمون در جدول ۶ و ۷ نتایج حاصل از شبکه عصبی مصنوعی و شبکه عصبی فازی تطبیقی بر اساس الگوی سه نشان داده شده است.

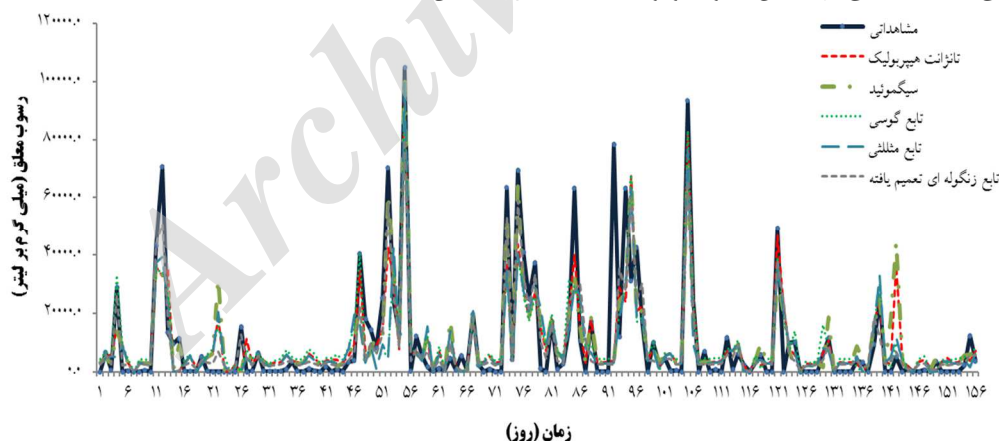
جدول ۶- نتایج شبکه عصبی مصنوعی در مرحله آزمون بر اساس الگوی ورودی ۳

آرایش شبکه	تابع انتقال	R <sup>2</sup>	RMSE	CE
۵-۱-۱	تانژانت هیپربولیک	-/۶۷	۱۱۰۷۵/۴۶	-/۶۶
۵-۳-۱	سیگموئید	-/۶۶	۱۱۲۲۵/۰۷	-/۶۶

جدول ۷- نتایج شبکه عصبی فازی تطبیقی در مرحله آزمون بر اساس الگوی ورودی ۳

روش	تابع فازی ساز	R <sup>2</sup>	RMSE	CE
	مثلثی	-/۵۹	۱۲۳۳۹/۹۸	-/۵۹
تفکیک شبکه ای	گوسی	-/۶۰	۱۲۱۹۴/۷	-/۶۰
	زنگوله ای تعمیم یافته	-/۷۴	۱۰۱۱۹/۳	-/۷۲

با توجه به نتیجه جدول ۶ مشاهده می‌گردد که تابع‌های تانژانت هیپربولیک و سیگموئید دارای نتایج نزدیکی می‌باشند و ضریب کارایی در هر دو تابع ۰/۶۶ می‌باشد. بررسی نتایج جدول ۷ نشان می‌دهد که شبکه عصبی فازی- تطبیقی با تابع زنگوله‌ای تعمیم یافته با ضریب همبستگی ۰/۷۴، ضریب کارایی ۰/۷۲ و میانگین مربعات خطای ۱۰۱۱۹/۳ میلی گرم بر لیتر عملکرد بهتری نسبت به سایر توابع فازی ساز در مدل نروفازی داشته است. مقایسه دو مدل نروفازی و شبکه عصبی مصنوعی نشان می‌دهد که فقط تابع فازی ساز زنگوله‌ای تعمیم یافته عملکرد بهتری نسبت به توابع شبکه عصبی مصنوعی داشته، در حالی که تابع‌های فازی ساز مثلثی و گوسی کارایی پایین‌تری نسبت به توابع شبکه عصبی مصنوعی در پیش‌بینی رسوب معلق روزانه داشته‌اند. نتایج حاصل از پیش‌بینی رسوب معلق روزانه با استفاده از دو مدل شبکه عصبی مصنوعی و شبکه عصبی فازی تطبیقی بر اساس الگوی ورودی ۳ در شکل ۴ نشان داده شده است.



شکل ۴- نمودار مشاهداتی و پیش‌بینی رسوب معلق روزانه بر اساس الگوی ورودی ۳ در مرحله آزمون

با توجه به نتایج حاصل از پیش‌بینی رسوب معلق روزانه در سه الگوی مختلف ورودی مشخص گردید که مدل شبکه عصبی فازی تطبیقی در هر سه الگو کارایی بهتری نسبت به شبکه عصبی مصنوعی در پیش‌بینی غلظت رسوب معلق روزانه دارد. نتایج حاصل از این تحقیق با نتایج کیشی و همکاران (۲۰۰۹)، رضایی بنفشه و همکاران (۱۳۹۲)، خورشید دوست و همکاران (۱۳۹۴)، کیشی و ذونعمت کرمانی (۲۰۱۶) و کاوه و همکاران (۲۰۱۷) همخوانی دارد آنها نیز در مطالعات خود نشان دادند که مدل شبکه عصبی فازی تطبیقی کارایی مناسبی جهت پیش‌بینی بار رسوبی دارد.



### نتیجه گیری

در این تحقیق با استفاده از شبکه عصبی فازی تطبیقی و شبکه عصبی مصنوعی غلظت بار معلق رسوب پیش‌بینی شد. به منظور پیش‌بینی غلظت بار معلق رسوب روزانه از ورودی‌های مختلف دبی روزانه و رسوب معلق روزانه در ۳ الگوی مختلف استفاده گردید. با توجه به نتایج بدست آمده مشاهده گردید که استفاده از متغیرهای دبی جریان روز جاری ( $Q_t$ ): مبدا زمانی پیش‌بینی) و تاخیر دبی جریان روزانه تا ۱ روز قبل از مبدا زمانی پیش‌بینی ( $Q_{t-1}$ ) نمی‌تواند رسوب معلق روزانه را به خوبی پیش‌بینی نماید. در حالی که استفاده از متغیرهای الگوی ورودی ۲ شامل دبی جریان روز جاری ( $Q_t$ ): مبدا زمانی پیش‌بینی) و تاخیر دبی جریان روزانه تا ۱ روز قبل از مبدا زمانی پیش‌بینی ( $Q_{t-1}$ ) و تاخیر رسوب معلق روزانه تا ۱ روز قبل از مبدا زمانی پیش‌بینی ( $S_{t-1}$ ) توانسته عملکرد مدل‌ها را در پیش‌بینی بار رسوب معلق روزانه ارتقا دهد. در حالی که استفاده از متغیرهای تاخیر دبی جریان و رسوب معلق روزانه تا ۲ روز قبل از مبدا زمانی پیش‌بینی، عملکرد هر دو مدل را در پیش‌بینی رسوب معلق روزانه کاهش داده است. همچنین بررسی نتایج نشان داد بهترین ترکیب ورودی جهت پیش‌بینی رسوب معلق روزانه به ترتیب در الگوی ۲، ۳ و ۱ است. (جدول ۴ و ۵). بررسی نتایج حاصل از مدل‌های شبکه عصبی فازی تطبیقی و شبکه عصبی مصنوعی نشان داد که مدل شبکه عصبی فازی تطبیقی در هر سه الگو عملکرد بهتری نسبت به شبکه عصبی مصنوعی در پیش‌بینی رسوب معلق روزانه داشته است. شبکه عصبی فازی تطبیقی سیستم را با کمک قواعد آن توصیف می‌کند که این قواعد در ساختاری شبکه‌ای پیاده‌سازی شده‌اند که می‌توان الگوریتم‌های یادگیری مورد استفاده در شبکه عصبی مصنوعی را به آن‌ها اعمال نمود. به واسطه این ساختار است که مدل شبکه عصبی فازی - تطبیقی، برای تحلیل و تفسیر از شفافیت بیشتری برخوردار است، بدین معنی که نسبت به مدل‌های کاملاً جعبه سیاه نظیر شبکه‌های عصبی مصنوعی، می‌توان از آن‌ها برای توضیح پاسخ استفاده نمود.

همانگونه که ملاحظه شد در این مطالعه تنها از متغیرهای دبی آب و رسوب معلق روزانه برای پیش‌بینی استفاده شده است که معمولاً در دسترس هستند ولی ممکن است به دلیل عواملی همانند تعداد کم برداشت‌ها و برداشت‌های کم در سیلاب‌های حداکثر، داده‌ها از دقت مناسبی برخوردار نباشند. بدیهی است عوامل دیگری از قبیل بارندگی، خصوصیات فیزیکی حوضه، درصد پوشش گیاهی و متغیرهای ژئومورفولوژیکی تأثیر بسزایی در میزان رسوب خروجی از حوضه دارند، که در نظر گرفتن این عوامل می‌تواند تأثیر بسزایی در پیش‌بینی رسوب معلق روزانه داشته باشد. با توجه به اهمیت پیش‌بینی صحیح میزان رسوب معلق در تعیین شاخص‌های کیفی آب، انتقال آلودگی، ظرفیت مخزن و کانال‌ها استفاده از مدل‌سازی هیدرولوژیکی اجتناب ناپذیر می‌باشد و مدل شبکه عصبی فازی تطبیقی با توجه به توانایی بالایی که در تجزیه و تحلیل روابط بین ورودی‌ها و پیش‌بینی خروجی دارد، در این زمینه یکی از مدل‌های موفق بوده و می‌تواند در این زمینه به مسئولین و سازمان‌های مربوط یاری رساند.

### منابع

- برزگری، فاطمه؛ دستورانی، محمد تقی؛ ۱۳۹۴، پیش‌بینی بار معلق رودخانه با استفاده از مدل‌های سری زمانی و شبکه عصبی مصنوعی (مطالعه موردی: ایستگاه قزاقلی رودخانه گرگانرود)، پژوهشنامه مدیریت حوضه آبخیز، سال ۶، شماره ۱۲، صص. ۲۱۶-۲۲۵.
- دهقانی، امیر احمد؛ زنگانه، محمد ابراهیم؛ مساعدی، ابوالفضل؛ کوهستانی، نسرين؛ ۱۳۸۸، مقایسه تخمین بار معلق به دو روش منحنی سنج رسوب و شبکه عصبی مصنوعی (مطالعه موردی رودخانه دوغ استان گلستان)، مجله علوم کشاورزی و منابع طبیعی، صص. ۱-۱۶ الف.

- رضایی بنفشه، مجید؛ فیض ا. پور، مهدی؛ صدر افشاری، سحر؛ ۱۳۹۲، استفاده از سیستم استنتاجی فازی عصبی در تخمین بار رسوبی و مقایسه آن با مدل‌های *MLR* و *SRC* در حوضه رودخانه قرانقو، پژوهش‌های جغرافیای طبیعی، سال ۴۵، شماره ۲، صص. ۷۷-۹۰.
- طهمورث، محمد؛ احمدی، حسن؛ تقوی، نفیسه؛ محمد عسکری، حسین؛ ۱۳۸۸، مقایسه دقت مدل‌های شبکه عصبی مصنوعی ژنومورفولوژی (*GANNs*) و رگرسیون (*RM*) در برآورد رسوب طالقان رود، پژوهش و سازندگی، شماره ۸۴، صص. ۱۹-۲۷.
- عقیفی، ابراهیم؛ یمانی، مجتبی؛ حسن زاده، یاسر؛ ۱۳۹۱، هیدروژنومورفولوژی حوضه آبریز دشت گرو (استان هرمزگان)، فصلنامه جغرافیای سرزمین، سال ۹، شماره ۳۵، صص. ۶۱-۷۶.
- Asselman, N.E.M., 2000. Fitting and interpretation of sediment rating curves. *J. Hydro.* 23(4), pp. 228-248.
- Firat, M., Güngör, M., 2007. River flow estimation using adaptive neuro fuzzy inference system. *Mathematics and Computers in Simulation*, 75(3-4). pp. 87-96.
- Hosseini, SM., Borhani, R., 2009. The application of artificial neural network in estimating the river yield by minimum temperature and discharge (case study: Hamoon basin). *The First International Conference of Water Crisis, 10-12 March. Zabol University.*
- Imrie, C.E., Durucan, S., Korre, A., 2000. River flow prediction using artificial neural networks :generalisation beyond the calibration range. *Journal of Hydrology*, 233, pp. 138-153.
- Jang, J.R., 1993. ANFIS: Adaptive-network-based fuzzy inference system, *IEEE Transactions on systems, Man, and Cybernetics*, 23(3), pp. 665-685.
- Kaveh, M., DucBui, M., Rutschmann, P., 2017. A comparative study of three different learning algorithms applied to ANFIS for predicting daily suspended sediment concentration, *International Journal of Sediment Research*,
- KhorshidDoost, A.M., Feyzolahpoor, M., SadrAfshari, S., 2015. Evaluation of Artificial neural fuzzy inference system and estimation of suspended sediment and comparison of two types of artificial neural network models (case study: zarineh rood river), *Journal of Geography and Development*, 41, pp.185-200.
- Kisi, O., Zounemat-Kermani, M., 2016. Suspended Sediment Modeling Using Neuro-Fuzzy Embedded Fuzzy c-Means Clustering Technique, *Journal of Water Resour Manage*, 30, pp. 3979-3994.
- Kisi, O., Haktanir, T., Ardiclioglu, M., Ozturk, O., Yalcin, E., Uludag, S., 2009. Adaptive neuro-fuzzy computing technique for suspended sediment estimation. *Advances in Engineering Software*, 40(6), pp. 438-444.
- Lopez, L.V., Efolliott, F.P., Baker, B.M., 2001. Impacts of Vegetative Practices on Suspended Sediment from Basin of Arizona, *Journal of Water Resources Planning and Management*, 127(1), pp. 41-47.
- McBean, E.A., Al-Nassri, S., 1988. Uncertainty in Suspended Sediment Transport Curves, *Journal of Hydraulic Engineering*, 114(1), pp. 63-73.
- Nakato, T., 1990. Test of Selected Sediment-Transport Formulas, *J. of Hydr. Engrg ASCE*, 116(3), pp. 362-379.
- Riad, S., Mania, J., Bouchaou, L., Najjar, Y., 2004. Predicting catchment flow in asemi-arid region via an artificial neural network technique. *Hydrological Processes Journal*, 18(13), pp. 2387-2393.

- Vafakhah, M., 2012. Application of artificial neural networks and adaptive neuro-fuzzy inference system models to short-term streamflow forecasting. *Canadian Journal of Civil Engineering*, 39(4), pp. 402-414.
- Zounemat-Kermani, M., Kisi, O., Adamowski, J., Ramezani-Charmahineh, A., 2016. Evaluation of data driven models for river suspended sediment concentration modeling, *Journal of Hydrology*, 535, pp. 457-472

Archive of SID