

## بهبود کارایی مدل شبکه عصبی مصنوعی در شبیه‌سازی رسوب معلق با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات

محمودرضا طباطبایی<sup>۱\*</sup>، امین صالح پور جم<sup>۲</sup> و جمال مصفاei<sup>۳</sup>

<sup>۱،۲،۳</sup> استادیار پژوهشی پژوهشکده حفاظت خاک و آبخیزداری، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران

تاریخ پذیرش: ۱۳۹۸/۰۷/۳۰

تاریخ دریافت: ۱۳۹۸/۰۲/۲۶

### چکیده

برآورد صحیح مقدار رسوب معلق رودخانه‌ها، نقش مهمی در مطالعات فرسایش و رسوب، هیدرولوژی و مدیریت حوزه‌های آبخیز دارد. شبیه‌سازی رسوب معلق در سامانه‌های هیدرولوژیکی، دارای پیچیدگی‌های زیاد بوده، در عین حال درک و دانش پژوهشگران از اجزاء و فرایندهای درون آن‌ها همواره با عدم قطعیت روبرو است. این امر، سبب کاربرد فراوان مدل‌های هوشمند و از جمله شبکه‌های عصبی مصنوعی شده است. با این حال، استفاده از این مدل‌های هوشمند نیز با چالش روبرو است. تعیین ساختار مناسب شبکه، مستلزم بهینه‌کردن پارامترهای مورد استفاده در آن (نظیر تعداد بهینه نرون‌ها و لایه‌ها، وزن و بایاس و نوع توابع فعال‌سازی) بوده که واسنجی مناسب آن‌ها به روش آزمون و خطا، ضمن کارایی کم، منجر به صرف زمان زیاد می‌شود. در پژوهش حاضر، به منظور شبیه‌سازی بار رسوب معلق روزانه رودخانه نیرچای (در محل ایستگاه آب‌سنجی نیر در استان اردبیل)، از شبکه عصبی مصنوعی پرسپترون چندلایه استفاده شد. به منظور آموزش مدل شبکه عصبی، علاوه بر روش مرسوم پس انتشار خطا، از الگوریتم بهینه‌سازی ازدحام ذرات (PSO)، به منظور بهینه‌سازی مقادیر وزن و بایاس نرون‌های مدل‌های شبکه عصبی استفاده شد. همچنین، برای افزایش قدرت تعمیم‌دهی مدل‌ها، از خوشه‌بندی فازی استفاده شد. نتایج گرفته‌شده از پژوهش حاضر نشان داد که آموزش مدل‌های شبکه عصبی با الگوریتم PSO، با کاهش خطای برآورد رسوب (کاهش خطای برآورد کل و ریشه میانگین مربعات خطا به ترتیب تا ۰/۳ درصد و ۱۰/۴ تن در روز) کارایی بیشتری نسبت به مدل‌های شبکه عصبی که صرفاً از روش‌های پس انتشار خطا استفاده می‌کنند، داشته است. با توجه به این که در بهینه‌سازی پارامترهای شبکه عصبی، الگوریتم‌های تکاملی (نظیر الگوریتم PSO) قادر به ارائه راه‌حل‌های مناسبی هستند، لذا در شبیه‌سازی پدیده‌ها و متغیرهای پیچیده حوزه‌های آبخیز (نظیر رسوب معلق) می‌توان از این توانمندی استفاده کرد.

**واژه‌های کلیدی:** الگوریتم تکاملی، خوشه‌بندی فازی، رودخانه بالخلوچای، مدل هوشمند، مطالعات فرسایش و رسوب

### مقدمه

وابسته به داشتن برآوردی صحیح از میزان بار رسوب معلق حمل‌شده در رودخانه‌ها است (Partial و Cigizoglu, ۲۰۰۸). با توجه به اهمیت برآورد متغیرهای پایش‌پذیر حوزه‌های آبخیز (نظیر بارش، رواناب، رسوب و غیره) و شبیه‌سازی فرایندهای

برآورد صحیح مقدار بار رسوب معلق نقش مهمی در مطالعات فرسایش و رسوب، هیدرولوژی، منابع آب و به‌طور کلی مدیریت حوزه‌های آبخیز داشته، به‌نحوی که عمر بسیاری از سازه‌های آبی نظیر سدها و مخازن

عصبی، الگوریتم‌های تکاملی (نظیر الگوریتم PSO)<sup>۴</sup> می‌توانند راه‌حل‌های مناسبی ارائه دهند، لذا در شبیه‌سازی مسائل پیچیده می‌توان از این توانمندی استفاده کرد. در این رابطه، Wang و Guo (۲۰۱۰) بار رسوب معلق رودخانه زرد<sup>۵</sup> را با استفاده از شبکه عصبی تابع پایه شعاعی<sup>۶</sup> که پارامترهای آن به‌وسیله الگوریتم PSO بهینه شده بود، شبیه‌سازی کردند. در پژوهشی دیگر، Salehpour Jam و Tabatabaei (۲۰۱۷) با استفاده از الگوریتم‌های ژنتیک و PSO، ضرایب مدل منحنی سنج رسوب را برای رودخانه سلمان‌رود در استان گیلان بهینه کردند. نتایج این پژوهش نشان داد که کارایی مدل‌های بهینه‌شده با کمک این دو الگوریتم بهتر از روش‌های مشتق مینا (مشتقات جزئی) بوده که به‌طور معمول برای محاسبه ضرایب مدل‌های رگرسیونی نظیر مدل منحنی سنج رسوب و در فرایند واسنجی استفاده می‌شود. در پژوهش مشابه دیگری، Altunkaynak (۲۰۰۹) برای برآورد رسوب معلق رودخانه می‌سی‌سی‌پی ضرایب مدل منحنی سنج رسوب را با کمک الگوریتم ژنتیک بهینه‌سازی کرد. نتایج ارزیابی مدل‌ها (مدل منحنی سنج مرسوم و بهینه‌شده با الگوریتم ژنتیک) نشان داد که مدل بهینه‌شده با الگوریتم ژنتیک از کارایی بیشتری برخوردار است. همچنین، Sahoo و Swain (۲۰۱۷) به‌منظور پایش کیفی رودخانه Brahmani در شرق هند، از الگوریتم ژنتیک در بهینه‌سازی ضرایب مدل‌های رگرسیونی برای شبیه‌سازی سه پارامتر گل آلودگی، کل مواد جامد محلول و شش فلز سنگین (شامل آهن، روی، مس، کروم، سرب و کادمیوم) استفاده کردند. در پژوهشی دیگر، Cheng و همکاران (۲۰۰۲) به‌منظور واسنجی یک مدل بارش-رواناب در حوزه آبخیز Xinanjiang، از الگوریتم‌های فازی و ژنتیک با توابع چندهدفه (شامل زمان تا اوج، بیشینه دبی جریان و حجم کل رواناب) استفاده کردند. در کار دیگری، Hejazi و همکاران (۲۰۰۸) نیز با استفاده از الگوریتم ژنتیک چندهدفه، یک مدل توزیعی بارش-

پیچیده هیدرولوژیکی نظیر فرایندهای بارش-رواناب و فرسایش و رسوب، کاربرد مدل‌های هوشمند (نظیر شبکه‌های عصبی مصنوعی، فازی، نرو فازی و غیره) به سرعت رو به افزایش است. در این رابطه Lafdani و همکاران (۲۰۱۳)، به‌منظور برآورد رسوب معلق روزانه رودخانه دویرج در غرب کشور، از مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان (SVM) استفاده کردند. در این پژوهش، داده‌های دبی جریان، به‌عنوان ورودی و دبی رسوب به‌عنوان خروجی استفاده شد. همچنین، از الگوریتم ژنتیک و آزمون گاما به‌منظور تعیین بهترین ترکیب متغیرهای ورودی استفاده شد. نتایج، بیانگر برتری مدل‌های یادشده در برآورد رسوب روزانه نسبت به مدل‌های رگرسیونی بود. نتایج مشابه دیگری به‌وسیله Tfwala و Wang (۲۰۱۶) از رودخانه‌ی شیون تایوان گزارش شد. در پژوهشی، Kisi و Ozkan (۲۰۱۷) برای مدل‌سازی رسوب معلق رودخانه ال در کالیفرنیا، داده‌های دو ایستگاه هیدرومتری را در بازه زمانی ۱۹۶۶ تا ۱۹۷۷ مورد بررسی قرار دادند. در این پژوهش، مدل‌های رگرسیون خطی وزن‌دار مکانی (LWLR)، شبکه عصبی مصنوعی و منحنی سنج رسوب<sup>۱</sup> مورد مقایسه قرار گرفتند. نتایج نشان داد که مدل شبکه عصبی مصنوعی در مقایسه با سایر مدل‌ها، ۳۹ درصد برآورد دقیق‌تری از رسوب معلق (تن در روز) داشته است. در سال‌های اخیر، الگوریتم‌های تکاملی<sup>۲</sup> نقش مهمی در بهینه‌سازی و واسنجی بهینه پارامترهای مدل‌های هیدرولوژیکی و مدل‌های داده مینا<sup>۳</sup> (نظیر مدل‌های رگرسیون، شبکه عصبی و غیره) داشته‌اند. در اغلب موارد، به‌دلیل ضعف و نقائص الگوریتم‌های مشتق مینا در هم‌گرایی به‌سوی مقادیر بهینه، از الگوریتم‌های جستجوی تکاملی در واسنجی مدل‌ها استفاده می‌شود، خصوصاً در مواردی که تعداد متغیرهای مدل زیاد بوده، در عین حال این متغیرها، با خروجی مدل دارای روابط پیچیده و غیرخطی هستند (Tayfur, ۲۰۱۲). با توجه به آن‌که در بهینه‌سازی پارامترهای شبکه

<sup>4</sup> Particle Swarm Optimization

<sup>5</sup> Yangtze River

<sup>6</sup> Radial Basis Function (RBF)

<sup>1</sup> Sediment Rating Curve (SRC)

<sup>2</sup> Evolutionary algorithms

<sup>3</sup> Data driven models

هیدرولوژیکی را برای شبیه‌سازی جریان‌های کم، کمتر حساس می‌کند (McCabe و Legates، ۱۹۹۹؛ Criss و Winston، ۲۰۰۸). بنابراین، پارامترهای این‌گونه مدل‌ها به‌نحوی واسنجی می‌شوند که بتوانند مقادیر بالای متغیرها را بهتر شبیه‌سازی کنند. در دیگر توابع اندازه‌گیری مقدار خطا نظیر میانگین مربعات خطا<sup>۵</sup> (MSE) یا ریشه میانگین مربعات خطا<sup>۶</sup> (RMSE) که یا به‌عنوان شاخص صحت‌سنجی و یا به‌عنوان توابع هدف (به‌ترتیب در ارزیابی و واسنجی مدل‌ها) به‌کار گرفته می‌شوند، شرایط مشابهی وجود داشته، در آن مربع باقی‌مانده به کمینه رسانده می‌شود. در مقایسه با توابع یادشده (NSE و RMSE) تابع میانگین قدر مطلق خطا<sup>۷</sup> (MAE) نسبت به مقادیر زیاد جریان حساسیت کمتری داشته و بر عکس نسبت به مقادیر کم جریان حساسیت بیشتری دارد و در نتیجه عملکرد مدل را یکنواخت‌تر می‌کند (Muleta، ۲۰۱۱). با توجه به نظر Muleta (۲۰۱۱) و Tabatabaei و همکاران (۲۰۱۹)، دقت واسنجی چندهدفه می‌تواند با استفاده از یک تابع هدف از هر گروه بهبود یابد. به‌عنوان مثال استفاده از تابع MAE، که حساس به جریان‌های کم بوده، توابع NSE یا RMSE که حساس به جریان‌های بالا هستند، می‌تواند ترکیب مناسبی باشد.

خوشه‌بندی داده‌ها و نمونه‌گیری از خوشه‌های حاصله، نقش مهمی در ساخت مجموعه داده‌های همگن و مشابه (نظیر مجموعه داده‌های واسنجی<sup>۸</sup> یا آموزش<sup>۹</sup>، اعتبارسنجی متقابل<sup>۱۰</sup> و آزمون<sup>۱۱</sup>) برای استفاده در مدل‌های داده‌مبنای<sup>۱۲</sup> (نظیر مدل‌های رگرسیون، شبکه‌های عصبی، نرو فازی) دارند. عدم استفاده از داده‌های مشابه و همگن در مجموعه‌های یادشده، تأثیرات بسیار مستقیم در میزان دقت و کارایی نهایی مدل‌های طراحی‌شده داشته، سبب کاهش قدرت تعمیم‌دهی آن‌ها خواهد شد (May و

رواناب را واسنجی کردند. در حوضه Sungai Bedup در کشور مالزی، Kuok و همکاران (۲۰۱۰) به‌منظور بهینه‌سازی یک مدل شبکه عصبی بارش-رواناب روزانه، از الگوریتم PSO استفاده کردند. آن‌ها نشان دادند که آموزش شبکه عصبی از طریق الگوریتم یادشده، موفقیت‌آمیز بوده است. در پژوهش دیگری، Kisi و همکاران (۲۰۱۷) به‌منظور بهینه‌سازی پارامترهای مدل‌های شبکه عصبی (به‌ترتیب مدل‌های ANN-PSO و ANN-DE) در شبیه‌سازی کیفیت آب زیرزمینی (SO<sub>4</sub> و SAR)، از الگوریتم‌های تکاملی PSO و DE<sup>۱</sup> استفاده کردند. در مطالعه دیگری PSO و Ebtehaj و Bonakdari (۲۰۱۶) از الگوریتم‌های PSO و رقابت استعماری<sup>۲</sup> در برآورد عدد فرود<sup>۳</sup> استفاده کردند. نتایج نشان داد که الگوریتم ICA، نتایج بهتری داشته است.

ارزیابی رفتار و عملکرد مدل‌های هیدرولوژیکی معمولاً از طریق مقایسه متغیرهای شبیه‌سازی‌شده و مشاهده‌شده انجام و گزارش می‌شود. در این بین، انتخاب و استفاده از معیارهای خاص ارزیابی مدل و تفسیر نتایج آن می‌تواند چالشی بزرگ حتی برای با تجربه‌ترین هیدرولوژیست‌ها باشد، زیرا هر معیار ارزیابی، از منظری خاص رفتار مدل را در شبیه‌سازی پدیده‌ها نشان می‌دهد (Krause و همکاران، ۲۰۰۵). در این رابطه، شاخص کارایی نش-ساتکلیف<sup>۴</sup> (NSE) که به‌وسیله Nash و Sutcliffe (۱۹۷۰) معرفی شد، یکی از محبوب‌ترین معیارهای اندازه‌گیری کارایی مدل‌ها است (Gupta و همکاران، ۱۹۹۹). با وجود محبوبیت آن، شاخص NSE دارای محدودیت‌هایی است (Moriasi و همکاران، ۲۰۰۷؛ Gupta و همکاران، ۲۰۰۹؛ Krause و همکاران، ۲۰۰۵). حساسیت زیاد این شاخص به مقادیر حدی و بالای یک متغیر (مثلاً مقادیر بزرگ متغیرهای دبی یا رسوب در شرایط سیلابی) سبب می‌شود تا میزان خطای حاصله از شبیه‌سازی متغیر در مقادیر زیاد آن (به‌دلیل استفاده از مربع انحرافات) بسیار زیاد شده، لذا مدل‌های

<sup>5</sup> Mean Square Error

<sup>6</sup> Root Mean Square Error (RMSE)

<sup>7</sup> Mean Absolute Error

<sup>8</sup> Calibration set

<sup>9</sup> Training

<sup>10</sup> Cross validation

<sup>11</sup> Test set

<sup>12</sup> Data driven

<sup>1</sup> Differential Evolution

<sup>2</sup> Imperialist Competitive Algorithm (ICA)

<sup>3</sup> Froude number

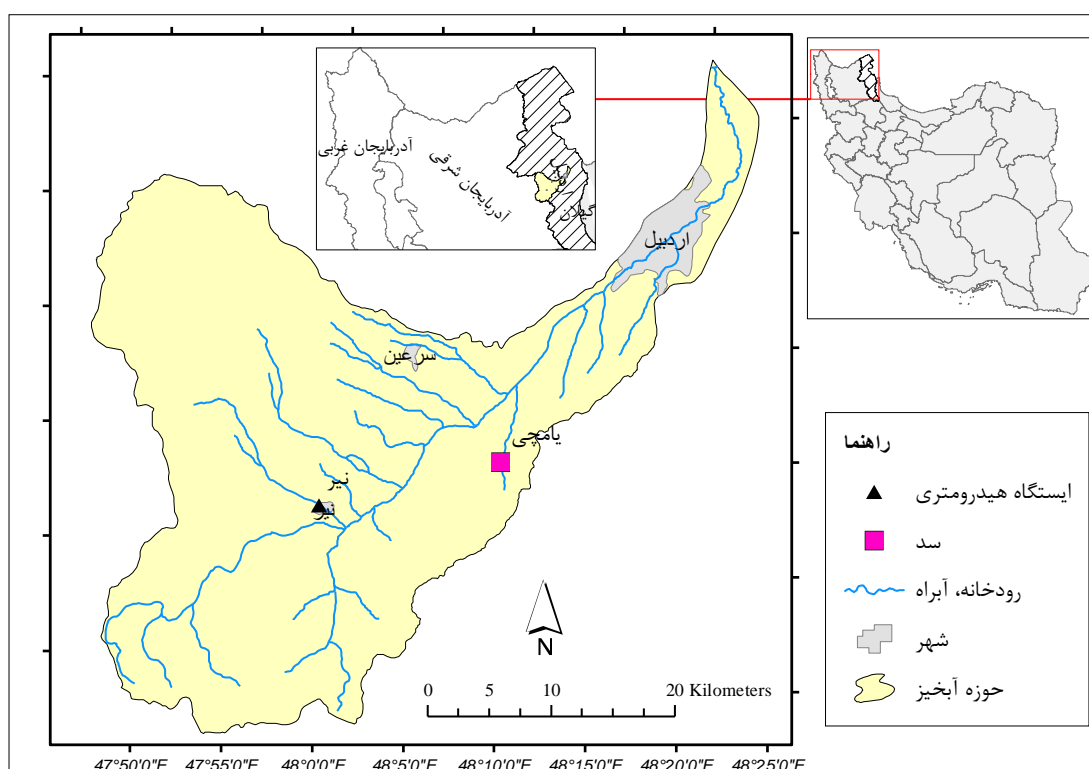
<sup>4</sup> Nash-Sutcliffe Efficiency (NSE)

مدل‌های شبکه عصبی از جمله نوآوری و ویژگی‌های مهم این پژوهش محسوب می‌شوند.

### مواد و روش‌ها

منطقه مورد پژوهش و داده‌های مورد استفاده: پژوهش حاضر در محل ایستگاه آب‌سنجی نیر بر روی رودخانه نیرچای در حوزه آبخیز بالخلوچای در استان اردبیل انجام شده است. این حوضه در موقعیت  $37^{\circ}$  تا  $38^{\circ} 22'$  عرض شمالی و  $46^{\circ} 46'$  تا  $48^{\circ} 25'$  طول شرقی واقع است (شکل ۱).

همکاران، (۲۰۱۰). در پژوهش حاضر، برای ایجاد مجموعه داده‌های همگن و مشابه از خوشه‌بندی فازی استفاده شده است. در مجموع این پژوهش، با هدف ارائه یک راهکار مناسب در بهبود برآورد بار رسوب معلق روزانه رودخانه نیرچای با استفاده از ترکیب مدل شبکه عصبی مصنوعی و الگوریتم PSO تدوین شده است. تاکید بر استفاده از مجموعه داده‌های همگن و مشابه به هنگام آموزش و ارزیابی مدل‌ها (با بهره‌گیری از خوشه‌بندی فازی) و استفاده از الگوریتم بهینه‌سازی ازدحام ذرات (PSO) در بهینه‌کردن وزن و بایاس



شکل ۱- موقعیت حوزه آبخیز بالخلوچای و ایستگاه هیدرومتری نیر

نیرچای و امام‌چای است که به ترتیب از ارتفاعات سبلان و ارتفاعات گردنه صائین منشأ می‌گیرند. رودخانه بالخلوچای دارای آب دائم بوده، دوران پربابی آن در بهار و رژیم آبی آن برفی-بارانی است. در حوضه بالخلوچای مجموعه‌ای از سنگ‌های آتشفشانی، رسوبی، رسوبی-آتشفشانی و آبرفت‌های درشت‌دانه تا ریزدانه وجود دارد. بخش مرکزی حوضه در اثر فرسایش به صورت پهنه هموار درآمده است. سنگ‌های تشکیل‌دهنده آن مارن، ماسه‌سنگ قرمز به سن نئوژن

حوزه آبخیز بالخلوچای در جنوب شهر اردبیل قرار گرفته و از زیرحوضه‌های مهم قره‌سو محسوب می‌شود. مساحت حوضه  $120728$  هکتار، ارتفاع متوسط آن  $2020$  متر از سطح دریا و بارش متوسط حوضه  $303$  میلی‌متر برآورد شده است. این حوضه عمدتاً شامل نواحی مرتفع کوهستانی است و در حوالی شهر اردبیل، دشت محدودی را در بر می‌گیرد. رودخانه اصلی حوضه بالخلوچای بوده که طولی برابر با  $78$  کیلومتر دارد. سرچشمه رودخانه بالخلوچای، رودخانه‌های

جهت جریان داده، از لایه ورودی به سمت لایه پنهان و از لایه پنهان به سمت لایه خروجی بوده، از این نظر به آن‌ها شبکه‌های عصبی رو به جلو یا پیش‌خور گفته می‌شود. به‌منظور آموزش شبکه عصبی، مقدار خطا در جهت بیشترین شیب تابع خطا محاسبه‌شده و این مقدار، به لایه‌های قبل (لایه یا لایه‌های پنهان) فرستاده شده تا با تنظیم مجدد مقادیر وزن نرون‌ها، مقدار خطا را کاهش دهند (قانون دلتا) (Tayfur, 2012) رابطه (۱):

$$w_{ij}^{new} = w_{ij}^{old} - \eta \frac{\partial E}{\partial w_{ij}} \quad (1)$$

که در آن،  $w_{ij}^{old}$  و  $w_{ij}^{new}$  به ترتیب وزن بین نرون‌های  $i$  و  $j$  قبل و بعد از یک تکرار معین،  $\eta$  نرخ یادگیری و  $E$  تابع خطا است.

آموزش شبکه و کاهش خطا تا ایجاد همگرایی در شبکه ادامه می‌یابد. شبکه‌های عصبی می‌توانند دارای چندین لایه پنهان باشند، با این وجود، تحقیقات انجام‌شده نشان می‌دهد که شبکه‌های عصبی پیش‌خور، با دارا بودن یک لایه پنهان، قادر به تقریب زدن هر نوع تابع غیرخطی هستند (Hornik و همکاران، ۱۹۸۹). در این پژوهش، از یک شبکه عصبی پرسپترون سه لایه (یک لایه ورودی، یک لایه پنهان و یک لایه خروجی) استفاده شده و تعداد بهینه نرون‌ها با سعی و خطا تعیین شد. به‌منظور آموزش شبکه عصبی از روش لوبنبرگ مارکواردت<sup>۴</sup> به‌دلیل کارایی و همگرایی سریع‌تر در آموزش شبکه و اثبات کارآمدی آن در تخمین رسوب رودخانه‌ای (Shiri و Kisi, 2012) استفاده شد. توابع فعال‌سازی در نرون‌های لایه پنهان و لایه خروجی، به ترتیب سیگموئید یا لوگ-سیگموئید و خطی در نظر گرفته شد.

**الگوریتم بهینه‌سازی ازدحام ذرات<sup>۵</sup>:** الگوریتم بهینه‌سازی انبوه ذرات (PSO)، یک الگوریتم جستجوی اجتماعی است که از رفتار اجتماعی دسته پرندگان و ماهی‌ها، به‌هنگام جستجوی غذا الهام گرفته است. در این الگوریتم، هر راه‌حل (در این پژوهش وزن‌ها و بایاس‌های شبکه عصبی)، که به آن یک ذره نیز گفته می‌شود، معادل یک پرنده در الگوریتم

هستند که به‌شدت چین‌خورده بوده و توان فرسایش‌پذیری آن‌ها بسیار زیاد است. بر اساس پژوهش Nasserabadi و همکاران (2013)، فرسایش آبی غالب در زیرحوضه مورد مطالعه از نوع سطحی و شیاری بوده، بر اساس محاسبات انجام‌شده در مدل EPM، فرسایش منطقه در طبقه شدید قرار دارد.

داده‌های هیدرولوژیکی مورد استفاده در این پژوهش، شامل داده‌های آب‌سنجی ایستگاه هیدرومتری نیر شامل دبی لحظه‌ای ( $Q_w$ ) به‌عنوان متغیر ورودی و دبی رسوب معلق<sup>۱</sup> روزانه ( $Q_s$ ) به‌عنوان متغیر خروجی است. خصوصیات آماری این داده‌ها در جدول ۱ ارائه شده است.

همان‌طور که از اطلاعات آماری جدول ۱ استنباط می‌شود، دبی رسوب ایستگاه دارای چولگی و ضریب تغییرات زیاد بوده و تغییرات بین کمینه و بیشینه آن زیاد است. این موضوع به‌همراه سایر آماره‌های محاسبه‌شده، حکایت از پیچیدگی مدل‌سازی برآورد رسوب معلق رودخانه دارد.

**شبکه عصبی مصنوعی پرسپترون چند لایه رو به جلو<sup>۲</sup>:** در این پژوهش، از شبکه عصبی مصنوعی با ناظر (پرسپترون چند لایه رو به جلو) برای شبیه‌سازی رسوب معلق استفاده شده است که در ادامه به اختصار به آن اشاره می‌شود. این شبکه، از عناصر عملیاتی ساده‌ای به‌نام نرون ساخته شده که به‌صورت موازی در کنار هم، عمل می‌کنند. شبکه‌های عصبی چند لایه، از یک لایه ورودی (در ارتباط با داده‌های ورودی)، یک یا چند لایه پنهان (برای سازمان‌دهی نرون‌ها) و یک لایه خروجی (در رابطه با داده خروجی) تشکیل می‌شوند. عملکرد شبکه عصبی، از طریق نحوه اتصال بین اجزاء، با تنظیم مقادیر هر اتصال که به‌نام وزن اتصال بیان می‌شود، تعیین می‌شود. یکی از انواع شبکه‌های عصبی پرکاربرد در هیدرولوژی و منابع آب، شبکه‌های عصبی پرسپترون چند لایه رو به جلو با الگوی آموزش پس انتشار<sup>۳</sup> خطا است (Ulke و همکاران، 2009). در این نوع از شبکه‌های عصبی،

<sup>1</sup> Suspended sediment load

<sup>2</sup> Feed-Forward Multi-Layer Perceptron (FFMLP)

<sup>3</sup> Back propagation

<sup>4</sup> Levenberg-Marquardt algorithm

<sup>5</sup> Particle Swarm Optimization (PSO)

دانش دیگر ذرات همسایگانشان، رفته رفته به سمت نواحی موفق (راه‌حل‌های بهینه) میل می‌کنند. در مقایسه با دیگر الگوریتم‌های تکاملی (نظیر GAS)، الگوریتم PSO دارای ویژگی‌های جالبی نظیر همکاری سازنده و حافظه مشترک میان افراد است. بنابراین در این الگوریتم، حرکت به سمت نواحی در برگیرنده راه‌حل‌های بهتر، از شانس بیشتری برخوردار بوده، کشف راه‌حل‌های با کیفیت مطلوب، سریع‌تر انجام می‌شود. علاوه بر آن، این الگوریتم بسیار ساده، دارای سرعت بالا و حافظه‌ای کم هزینه است (Yar Kiani, 2009).

حرکت جمعی پرندگان فرض شده و شایستگی آن به‌وسیله یک تابع هدف رابطه (۱۳) تعیین می‌شود. در الگوریتم PSO، ذرات برای رسیدن به یک هدف مشترک، با یکدیگر همکاری کرده، در نتیجه این روش مؤثرتر از هنگامی است که ذرات به‌طور جداگانه عمل می‌کنند (Shahriar Shahhoseini و همکاران، ۲۰۱۱). در الگوریتم PSO، رفتار جمعی فقط وابسته به رفتار فرد در اجتماع نیست بلکه به چگونگی تعامل میان افراد گروه نیز مربوط می‌شود. در این روش، ذرات در فضای جستجو گسترده شده، سپس به‌منظور رسیدن به بهترین راه‌حل‌ها، تحت تأثیر تجربه و دانش خود و

جدول ۱- ویژگی‌های آماری داده‌های آب‌سنجی ایستگاه هیدرومتری نیر

سال آماری و تعداد داده	نوع داده	میانگین	انحراف معیار	کمینه	بیشینه	چولگی	ضریب تغییرات (درصد)
۱۳۵۷-۱۳۹۵	دبی لحظه‌ای (مترمکعب بر ثانیه)	۱/۲۱	۰/۶۶	۰/۱۷	۳/۵۹	۰/۷۳	۵۴/۱۵
۳۹۳	دبی رسوب (تن در روز)	۱۱/۲۸	۱۹/۱۰	۰/۱۳	۱۸۸/۳۷	۵/۲۴	۱۶۹/۳۹

می‌کنند. مقدار این دو ضریب در بازه [۰ و ۲] تعیین می‌شود. ضریب  $\omega$ ، ضریب اینرسی بوده که به‌صورت خطی کاهش یافته و معمولاً در بازه [۰ و ۱] تعریف می‌شود. در مجموع به‌منظور استفاده از الگوریتم PSO در این پژوهش، تعداد ذرات اولیه ۳۰ عدد، ضریب اینرسی ۰/۹ و تعداد تولید نسل تا رسیدن به هم‌گرایی نهانی، ۱۰۰۰ نسل در نظر گرفته شد. لازم به ذکر است که در مدل‌های هیبرید شبکه عصبی (MLP) و الگوریتم بهینه‌سازی ازدحام ذرات (PSO)، مقادیر بهینه وزن و بایاس نرون‌های شبکه عصبی به‌وسیله الگوریتم PSO تعیین شده و سپس این مقادیر بهینه، جایگزین مقادیر اولیه در شبکه می‌شوند. در ادامه، به روش انجام کار اشاره می‌شود.

**به‌کارگیری الگوریتم PSO در بهینه‌سازی و آموزش شبکه‌های عصبی:** در آموزش یک شبکه عصبی، متغیرهای بهینه‌سازی شامل وزن‌ها و بایاس‌های آن شبکه هستند. اگر لایه  $m$  از یک شبکه عصبی فرضی متشکل از  $R$  ورودی و  $M$  نرون در نظر گرفته شود، آن‌گاه ماتریس وزن‌ها ( $W^n$ ) و بایاس‌های

روش کار این الگوریتم بدین‌صورت است که ابتدا تعدادی ذره با موقعیت و سرعت تصادفی ایجاد شده، سپس در هر تکرار، ذرات بر حسب بهترین موقعیت گذشته خود و همسایگانشان حرکت به سوی هدف را اصلاح می‌کنند. پس از تکرارهای متوالی، مسئله به جواب بهینه همگرا می‌شود. اصلاح سرعت و موقعیت هر ذره به‌ترتیب به‌وسیله روابط (۲) و (۳) انجام می‌شود.

$$V_i(t+1) = \omega V_i(t) + \quad (2)$$

$$C_1 \times rand_1(pbest_i(t) - x_i(t)) + C_2 \times rand_2(gbest_i(t) - x_i(t))$$

$$x_i(t+1) = x_i(t) + V_i(t+1) \quad (3)$$

که در آن‌ها،  $gbest$  نشان‌دهنده بهترین موقعیتی است که به‌وسیله جمعیت ذرات به‌دست آمده و  $pbest$  بهترین موقعیت خود ذره است که تا به حال آن را تجربه کرده است،  $t$  نمایانگر تعداد تکرار،  $c$  ثابت شتاب و  $rand_1$  و  $rand_2$  اعداد تصادفی در بازه [۰ و ۱] هستند. ضرایب  $C_1$  و  $C_2$  به‌ترتیب پارامتر شناختی (تجربه شخصی) و پارامتر اجتماعی (تجربه جمعی) بوده، شیب حرکت در جستجوی محلی را مشخص

به‌عنوان میزان برازندگی بردار متغیرهای آن شبکه در نظر گرفته می‌شود.

بردارهای موقعیت جدید با استفاده از روابط (۲) و (۳) تولید شده و این روند آن‌قدر تکرار می‌شود تا هم‌گرایی نهایی حاصل شود. منظور از هم‌گرایی نهایی، رسیدن به بردار موقعیت بهینه (مقادیر بهینه وزن‌ها و بایاس‌ها)، به‌نحوی است که خطای آموزش به ازای آن‌ها کمینه شود.

در پژوهش حاضر علاوه بر مدل‌های شبکه عصبی از روش‌های رگرسیونی منحنی سنج رسوب نیز برای شبیه‌سازی رسوب معلق و مقایسه نتایج آن‌ها با مدل‌های شبکه عصبی استفاده شده است که در ذیل به اختصار به آن‌ها اشاره می‌شود.

#### منحنی سنج رسوب

**الف- منحنی سنج یک خطی:** در این مدل، داده‌های غلظت یا دبی رسوب معلق و دبی جریان لحظه‌ای متناظر آن‌ها، به یک دستگاه مختصات تمام لگاریتمی منتقل شده، بهترین خط برازش با استفاده از روش کمینه مربعات خطا از میان نقاط عبور داده می‌شود. پس از محاسبه دبی رسوب، بایستی این مقدار مجدداً از قالب لگاریتمی به شکل اولیه خود (در شکل حسابی و ده دهی) تبدیل شوند<sup>۱</sup>، یا به عبارتی آنتی‌لوگ از آن‌ها گرفته شود (Jansson, ۱۹۹۶).

**ب- منحنی سنج حد وسط دسته‌ها:** در این روش که آن را Jansson (۱۹۹۶) پیشنهاد کرده است، دبی‌های جریان، با یک نمونه معین به تعدادی دسته تقسیم شده و برای دبی متوسط هر دسته، دبی رسوب متوسط همان دسته تعیین می‌شود. در آخر، ضرایب منحنی سنج رسوب مشابه با بند الف و با استفاده از روش کمینه مربعات خطا به‌دست می‌آید.

**تهیه داده‌های همگن و مشابه برای آموزش و آزمون مدل‌ها:** به‌منظور افزایش قدرت تعمیم‌دهی و ساخت هرچه دقیق‌تر مدل‌ها، لازم است داده‌های مورد استفاده در آموزش مدل‌ها، معرف و نماینده داده‌های کل دوره آماری باشند. به‌منظور آزمون و ارزیابی صحیح نتایج آن‌ها، لازم است داده‌های آزمون، مشابه

(B<sup>n</sup>) این لایه را می‌توان با رابطه (۴) به‌صورت زیر نمایش داد (Kashefi Kavyani و همکاران، ۲۰۰۷).

$$W^n = \begin{bmatrix} (W_1^n)^T \\ (W_2^n)^T \\ \vdots \\ (W_M^n)^T \end{bmatrix}, \quad B^n = \begin{bmatrix} b_1^n \\ b_2^n \\ \vdots \\ b_M^n \end{bmatrix} \quad (4)$$

که در آن،  $W^n = [W_{m,1}^n \ W_{m,2}^n \ \dots \ W_{m,R}^n]^T$  بردار وزن‌هایی است که نرون m را به ورودی‌های همان لایه مربوط می‌کند. بردار پارامترهای این لایه را نیز می‌توان با رابطه (۵) نشان داد.

$$X^n = \begin{bmatrix} W_1^n \\ \vdots \\ W_M^n \\ b_1^n \\ \vdots \\ b_M^n \end{bmatrix} \quad (5)$$

به همین ترتیب، به ازای هر لایه در شبکه عصبی، ماتریس‌های وزن و بایاس و بردار پارامترهای مربوطه تعریف می‌شود. با زیر هم قرار دادن بردار پارامترهای همه لایه‌های شبکه، بردار متغیرهای بهینه‌سازی موردنظر تشکیل می‌شود. نهایتاً برای یک شبکه با L لایه، بردار متغیرهای X را می‌توان از رابطه (۶) به‌دست آورد.

$$X = \begin{bmatrix} X^1 \\ X^2 \\ \vdots \\ X^L \end{bmatrix} \quad (6)$$

در واقع این بردار همان بردار موقعیت ذره (یا راه حل ذکرشده) در الگوریتم PSO است که مقدار بهینه آرگومان‌های آن با استفاده از این الگوریتم محاسبه می‌شود.

روند کار بدین‌ترتیب است که ابتدا N بردار موقعیت  $X_i$  ( $i=1,2,\dots,N$ ) که برابر با تعداد اعضای دسته ذرات (راه‌حل‌ها) است، به‌صورت تصادفی تولید می‌شود. جمعیت دسته نیز معمولاً چهار تا پنج برابر تعداد متغیرهای بهینه‌سازی انتخاب می‌شود. شبکه عصبی به ازای پارامترهایی برابر با متغیرهای این بردارها اجرا شده، خطای به‌دست آمده از هر اجرا

<sup>1</sup> Back-transformed

<sup>2</sup> Mean load method

فرایند تکرار، زمانی متوقف می‌شود که:

$$\max_{ij} \{|u_{ij}^{k+1} - u_{ij}^k|\} < \varepsilon \quad (10)$$

که در آن،  $\varepsilon$  معیار خاتمه و  $k$  نشان‌دهنده  $k$ مین مرحله از فرایند تکرار است.

**تحلیل آماری داده‌های حاصل از خوشه‌بندی:** به منظور تحلیل نتایج آماری حاصل از خوشه‌بندی داده‌ها، علاوه بر مقایسه پارامترهای آماری (میانگین، انحراف معیار، چولگی و غیره) از آزمون ناپارامتری دو نمونه‌ای کلموگروف-اسمیرنوف<sup>۶</sup> (KS) برای بررسی یکسان بودن توزیع داده‌های در سه مجموعه داده یادشده استفاده شده است (Mansourfar, 2009).

**استانداردسازی داده‌ها:** استاندارد کردن داده‌ها، به منظور بی‌بعد کردن آن‌ها در محاسبات فاصله (در عملیات خوشه‌بندی) و یا به منظور جلوگیری از کوچک شدن بیش از حد وزن‌های تخصیص یافته به نرون‌ها (در مدل‌های شبکه عصبی) است. در این پژوهش، با توجه به استفاده از توابع محرک سیگموئید و تانژانت هایپربولیک، به ترتیب از رابطه‌های (۱۱) و (۱۲) برای استاندارد کردن داده‌ها در بازه‌های  $[-0.9, 0.1]$  و  $[0, 1]$  استفاده شده است.

$$z = 0.1 + (0.8 * \frac{X_i - X_{imin}}{X_{imax} - X_{imin}}) \quad (11)$$

$$z = \left( \frac{1.8(X_i - X_{imin})}{X_{imax} - X_{imin}} \right) - 0.9 \quad (12)$$

که در آن‌ها،  $Z$  متغیر استاندارد شده،  $X_i$  متغیر اولیه،  $X_{imax}$  و  $X_{imin}$  به ترتیب مقادیر کمینه و بیشینه متغیر  $X_i$  است. در آموزش مدل‌های شبکه عصبی، از داده‌های دبی لحظه‌ای ( $Q_w$ ) به عنوان متغیر ورودی (تخمین‌گر مدل<sup>۷</sup>) و از بار رسوب معلق ( $Q_s$ ) به عنوان متغیر خروجی استفاده شده است.

**سناریوهای مدل‌سازی و اسامی مدل‌ها:** با توجه به آن‌که در پژوهش حاضر از دو الگوریتم لونیگ مارکواردت و PSO به ترتیب برای آموزش و بهینه‌سازی مدل‌های شبکه عصبی استفاده شده است و دو تابع سیگموئید و تانژانت هایپربولیک به عنوان توابع فعال‌سازی در این مدل‌ها به کار گرفته شده‌اند (مجموعاً چهار مدل)، لذا، به منظور تسهیل در مقایسه

داده‌های آموزش بوده، از توزیع یکسانی با آن‌ها برخوردار باشند. بدین منظور در پژوهش حاضر از خوشه‌بندی فازی، برای خوشه‌بندی داده‌ها و از روش تخصیص برابر<sup>۱</sup>، به منظور نمونه‌گیری از خوشه‌ها به نسبت ۷۰، ۱۵ و ۱۵ درصد به ترتیب برای ساخت سه مجموعه داده آموزش<sup>۲</sup>، اعتبارسنجی متقابل<sup>۳</sup> و آزمون<sup>۴</sup> استفاده شد (May و همکاران، ۲۰۱۰). در این راستا، تعیین تعداد خوشه‌های بهینه، به وسیله شاخص ارزیابی دیویس-بولدین<sup>۵</sup> انجام گرفته است (Kaufman و Rousseeuw, 2009). در ادامه به اختصار به الگوریتم خوشه‌بندی فازی اشاره می‌شود.

**خوشه‌بندی فازی:** در الگوریتم خوشه‌بندی فازی، درجه عضویت هر داده، با توجه به فاصله بین آن داده، مرکز خوشه‌ای که داده در آن قرار گرفته است، به دست می‌آید. هر چقدر داده به مرکز خوشه نزدیک‌تر باشد، از درجه عضویت بیشتری نسبت به آن خوشه برخوردار است. بنابراین، در این روش خوشه‌بندی، هدف، کمینه کردن تابع هدف رابطه (۷) و به عبارت دیگر، بیشینه نمودن درجه عضویت داده‌ها است (Yar Kiani, 2009).

$$J_m = \sum_{i=1}^N \sum_{j=1}^C U_{ij}^m \|x_i - c_j\|^2 \quad (7)$$

$$1 \leq m \leq \infty$$

که در آن،  $m$  هر عدد حقیقی بزرگ‌تر از یک،  $U_{ij}$  درجه عضویت  $x_i$  در خوشه  $j$ ،  $x_i$  داده  $i$ ام  $d$  بعدی،  $c_j$  مرکز  $d$  بعدی خوشه و علامت  $\|\cdot\|$  هر معیاری (نظیر فاصله اقلیدسی) است که بیان‌گر شباهت بین هر داده اندازه‌گیری شده، مرکز خوشه است. خوشه‌بندی فازی از طریق بهینه‌سازی مکرر تابع فوق انجام می‌شود. این فرایند با استفاده از به روزرسانی درجه عضویت  $u_{ij}$  و مرکز خوشه  $c_j$  از طریق روابط زیر انجام می‌شود (Zhou و Schaefer, 2009).

$$u_{ij} = \frac{1}{\sum_{k=1}^C \left( \frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{\frac{2}{m-1}}} \quad (8)$$

$$c_j = \frac{\sum_{i=1}^N u_{ij}^m x_i}{\sum_{i=1}^N u_{ij}^m} \quad (9)$$

<sup>1</sup> Proportional allocation

<sup>2</sup> Training set

<sup>3</sup> Cross validation set

<sup>4</sup> Test set

<sup>5</sup> Davies-Bouldin index

<sup>6</sup> Non parametric two-sample Kolmogorov-Smirnov (K-S) test

<sup>7</sup> Model predictor



که در آن‌ها،  $S_o$  و  $S_M$  به ترتیب دبی رسوب معلق مشاهده‌ای و برآورد شده،  $O$  که میانگین دبی رسوب مشاهده‌ای،  $\bar{S}_M$  میانگین دبی رسوب برآورد شده و  $n$  تعداد داده‌ها است. در این پژوهش، به منظور پیاده‌سازی مدل‌های شبکه عصبی و رگرسیونی، الگوریتم PSO و خوشه‌بندی داده‌ها و انجام تحلیل‌های آماری، از نرم‌افزار MATLAB نسخه R2015b استفاده شده است.

### نتایج و بحث

**نتایج خوشه‌بندی و تحلیل آماری داده‌ها:** با استفاده از الگوریتم خوشه‌بندی فازی و شاخص دیویس بولدین، تعداد خوشه‌های بهینه (K) برای داده‌های مورد مطالعه، ۴۲ خوشه تعیین شد (شکل ۲).

نتایج پارامترهای آماری (معیارهای مرکزیت و پراکندگی داده‌ها) و نتایج مربوط به مقایسه توزیع داده‌ها (نتایج آزمون KS) در سه مجموعه داده‌های آموزش، اعتبارسنجی متقاطع و آزمون برای ایستگاه هیدرومتری نیر در جداول ۲ و ۳ آمده است. لازم به ذکر است که مقادیر صفر برای شاخص  $h$  (شاخص به-کار رفته در آزمون KS در نرم‌افزار متلب) در جدول ۳، بیانگر یکسان بودن توزیع داده‌ها در دو مجموعه مورد بررسی است.

نتایج ساخت، آموزش (واسنجی در مدل‌های رگرسیونی) و ارزیابی مدل‌های مختلف شبکه عصبی و رگرسیونی در ایستگاه مورد مطالعه در جدول ۴ خلاصه شده است. در این جدول، بهترین ساختار شبکه عصبی و نوع توابع محرک آن‌ها، به همراه شاخص‌های ارزیابی صحت‌سنجی مدل بیان شده است. لازم به ذکر است که تعداد بهینه نرون‌های لایه پنهان در مدل‌های شبکه عصبی با الگوریتم آموزشی لونیبرگ مارکواردت، با آزمون و خطا و کمینه‌کردن خطای شبکه در تکرارهای زیاد تعیین شده، به منظور ارزیابی و مقایسه این نوع مدل‌ها با مدل‌های شبکه عصبی که با الگوریتم PSO آموزش دیده‌اند، عیناً از همین تعداد نرون در ساخت آن‌ها استفاده شد. در واسنجی مدل-های رگرسیونی منحنی سنج رسوب از مجموع داده-های آموزش و ارزیابی متقاطع (که در آموزش شبکه-

و ارزیابی نتایج مدل‌های مختلف شبکه عصبی، از اسامی ذیل استفاده شده است.

مدل‌های ANN-LM-Tan و ANN-LM-Sig به ترتیب مدل‌های شبکه عصبی با الگوریتم آموزشی لونیبرگ مارکواردت (LM) با توابع فعال‌سازی سیگموئید و تانژانت هایپربولیک و مدل‌های ANN-PSO-Sig و PSO-Sig به ترتیب مدل‌های شبکه عصبی با الگوریتم بهینه‌سازی PSO و توابع فعال‌سازی سیگموئید و تانژانت هایپربولیک هستند. مدل‌های رگرسیونی منحنی سنج یک خطی و حد وسط دسته‌ها نیز به ترتیب با اسامی SRC و SRC-MeanLoad نام‌گذاری شده‌اند.

**ارزیابی کارایی مدل‌ها:** به منظور ارزیابی و مقایسه نتایج گرفته‌شده از مدل‌های شبکه عصبی و رگرسیونی و مقایسه آن‌ها با داده‌های رسوب مشاهداتی (داده‌های مجموعه آزمون)، اندازه‌گیری مقدار خطا و ترسیم گرافیکی انجام شد. به منظور صحت‌سنجی و بررسی میزان خطای محاسباتی مدل‌ها، از شاخص‌های ریشه میانگین مربعات خطا<sup>۱</sup> (RMSE)، میانگین قدر مطلق خطا<sup>۲</sup> (MAE)، معیار ناش-ساتکلیف<sup>۳</sup> (NS)، درصد بایاس<sup>۴</sup> (PBIAS) و ضریب تبیین<sup>۵</sup> ( $R^2$ ) و انحراف معیار ( $S_{xy}$ ) خط رگرسیون برازش یافته بین داده‌های مشاهده‌ای با داده‌های محاسباتی به ترتیب رابطه‌های (۱۳) تا (۲۰) استفاده شد.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (S_M - S_O)^2} \quad (13)$$

$$MAE = \frac{\sum_{i=1}^n |S_O - S_M|}{n} \quad (14)$$

$$NS = 1 - \frac{\sum_{i=1}^n (S_M - S_O)^2}{\sum_{i=1}^n (S_O - \bar{S}_O)^2} \quad (15)$$

$$PBIAS = \frac{\sum_{i=1}^n (S_O - S_M)}{\sum_{i=1}^n (S_O)} \times 100 \quad (16)$$

$$S_{XY} = \sqrt{\frac{\sum_{i=1}^n (S_M - S_O)^2}{n-2}} \quad (17)$$

$$R^2 = \left[ \frac{\sum_{i=1}^n (S_O - \bar{S}_O)(S_M - \bar{S}_M)}{\sqrt{\sum_{i=1}^n (S_O - \bar{S}_O)^2 \sum_{i=1}^n (S_M - \bar{S}_M)^2}} \right]^2 \quad (18)$$

<sup>1</sup> Root Mean Square Error

<sup>2</sup> Mean absolute error


<sup>3</sup> Nash-Sutcliffe

<sup>4</sup> Percent Bias (PBIAS)

<sup>5</sup> Coefficient of determination

های عصبی استفاده شده) استفاده شده و آزمون آن‌ها با داده‌های آزمون که در مدل‌های شبکه عصبی مورد

استفاده قرار گرفته‌اند، انجام شده است.



شکل ۲- تعیین تعداد بهینه خوشه‌ها با استفاده از خوشه‌بندی فازی و شاخص دیویس-بولدین در ایستگاه نیر

جدول ۲- پارامترهای آماری مجموعه داده‌های واسنجی، اعتبارسنجی متقاطع و آزمون ایستگاه هیدرومتری نیر

پارامترهای آماری						متغیرهای مدل و مجموعه داده‌ها
درصد ضریب تغییرات	چولگی	کمینه	بیشینه	انحراف معیار	میانگین	
دبی لحظه‌ای ( $Q_w$ ) ( $m^3 s^{-1}$ )						
۵۵/۵۸	۰/۷۵	۰/۱۶	۳/۵۹	۰/۶۶	۱/۱۹	مجموعه واسنجی
۵۰/۷۸	۰/۶۳	۰/۳۰	۳/۰۹	۰/۶۳	۱/۲۴	مجموعه اعتبارسنجی متقاطع
۵۲/۲۰	۰/۷۶	۰/۳۵	۳/۲۸	۰/۶۵	۱/۲۵	مجموعه آزمون
دبی رسوب معلق ( $Q_s$ ) ( $tonday^{-1}$ )						
۱۸۲/۲۹	۵/۴۰	۰/۱۳	۱۸۸/۳۷	۲۰/۷۸	۱۱/۳۹	مجموعه واسنجی
۱۴۳/۳۶	۳/۵۹	۰/۲۹	۱۰۵/۵۷	۱۶/۳۰	۱۱/۳۷	مجموعه اعتبارسنجی متقاطع
۱۲۸/۷۱	۲/۸۹	۰/۴۰	۸۰/۲۰	۱۳/۷۲	۱۰/۶۶	مجموعه آزمون

جدول ۳- نتایج آزمون ناپارامتری دو نمونه‌ای KS بر روی داده‌های سه مجموعه آموزش، اعتبارسنجی متقاطع و آزمون در ایستگاه

هیدرومتری نیر

متغیر	مجموعه‌های مورد مقایسه	P-value	آماره $D_c$ یا $k$ (محاسباتی)	شاخص نرم‌افزار (h)
دبی لحظه‌ای ( $Q_w$ ) ( $m^3 s^{-1}$ )	آموزش-اعتبارسنجی متقاطع	۰/۸۲۵	۰/۰۸۵**	.
دبی لحظه‌ای ( $Q_w$ ) ( $m^3 s^{-1}$ )	آموزش-آزمون	۰/۷۵۵	۰/۰۹**	.
دبی لحظه‌ای ( $Q_w$ ) ( $m^3 s^{-1}$ )	اعتبارسنجی متقاطع-آزمون	۰/۹۹	۰/۰۶۹**	.
دبی رسوب معلق ( $Q_s$ ) ( $tonday^{-1}$ )	آموزش-اعتبارسنجی متقاطع	۰/۸۵۹	۰/۰۸۲**	.
دبی رسوب معلق ( $Q_s$ ) ( $tonday^{-1}$ )	آموزش-آزمون	۰/۹۸	۰/۰۶**	.
دبی رسوب معلق ( $Q_s$ ) ( $tonday^{-1}$ )	اعتبارسنجی متقاطع-آزمون	۰/۹۹	۰/۰۶۴**	.

\*\* معنی‌داری در سطح خطا (یک درصد  $\alpha$ ) با اطمینان ۹۹ درصد

**جدول ۴- ساختار و نتایج ارزیابی مدل‌های مختلف شبکه عصبی و رگرسیونی در برآورد بار رسوب معلق داده‌های آزمون در ایستگاه هیدرومتری نیر**

شاخص‌های صحت‌سنجی مدل						
نام مدل	ساختار شبکه/مدل رگرسیون	MAE (تن در روز)	RMSE (تن در روز)	NSE	$S_{xy}$ (تن در روز)	$R^2$
ANN-LM-Sig	۱:۵:۱	۶/۴	۱۰/۹	۰/۳۵	۱۱/۰	۰/۳۹
ANN-PSO-Sig	۱:۵:۱	۶/۳	۱۰/۴	۰/۴	۱۰/۶	۰/۴۱
ANN-LM-Tan	۱:۲:۱	۶/۳	۱۱/۲	۰/۳۱	۱۱/۴	۰/۳۷
ANN-PSO-Tan	۱:۲:۱	۶/۲	۱۰/۵	۰/۴	۱۰/۷	۰/۴۲
SRC	$Q_s=5.4806Q_w^{1.1639}$	۶/۴	۱۱/۹	۰/۲۴	۱۲/۰	۰/۳۹
SRC-MeanLoad	$Q_s=8.9656Q_w^{1.4537}$	۷/۷	۱۰/۹	۰/۳۵	۱۱/۱۲	۰/۴۱

همان‌طور که در جدول ۴ نشان داده شده، استفاده از الگوریتم PSO در آموزش شبکه عصبی توانسته است، کارایی مدل‌های شبکه عصبی را بهبود ببخشد، به‌نحوی که اغلب مقادیر شاخص‌های صحت‌سنجی مدل‌ها بهبود یافته‌اند. به‌عنوان مثال، مقدار RMSE در مدل ANN-LM-Sig، ۱۰/۹ تن در روز است، در حالی که در همین مدل، ولی با آموزش PSO (ANN-LM-PSO) مقدار RMSE به ۱۰/۴ تن در روز تقلیل یافته است. این به آن معنا است که خطای مدل ANN-LM-PSO در برآورد رسوبات بالا، روزانه، ۵۰۰ کیلوگرم کمتر از مدل ANN-LM-Sig است. همچنین، در مقایسه مدل‌های ANN-LM-Tan و ANN-LM-PSO، نتایج نشان می‌دهد که خطای مدل ANN-LM-PSO در برآورد رسوبات بالا، ۷۰۰ کیلوگرم کمتر است.

با این‌که در ظاهر کاهش خطای ۵۰۰ یا ۷۰۰ کیلوگرمی چندان قابل‌توجه نیست، اما بایستی توجه شود که این میزان خطا در مقیاس روزانه بوده، نکته مهمتر آن‌که این میزان بهبود کارایی مدل و کاهش خطا در حوضه‌ای است که دبی متوسط آن ۱/۲ مترمکعب در ثانیه است. پر واضح است که با افزایش دبی جریان رودخانه یا افزایش رسوب‌دهی حوضه (در دیگر حوضه‌های کشور)، این بهبود کارایی مدل بیشتر نمود خواهد داشت. در مقایسه نتایج گرفته‌شده از مدل‌های منحنی سنج‌رسوب یک‌خطی (SRC) و حد وسط دسته‌ها (SRC-MeanLoad) نتایج نشان می‌دهد

که مدل حد وسط دسته‌ها در برآورد رسوبات بالا بهتر از مدل SRC عمل می‌کند (مقدار RMSE از ۱۱/۹ تن در روز در مدل SRC به ۱۰/۹ تن در روز در مدل حد وسط دسته‌ها تقلیل یافته است). با این حال عملکرد مدل SRC در برآورد رسوبات پائین بهتر از مدل حد وسط دسته‌ها بوده (مقدار RMSE از ۷/۷ تن در روز در مدل حد وسط دسته‌ها به ۶/۴ تن در روز در مدل SRC تقلیل یافته است).


همچنین، مقایسه مقدار شاخص NSE در مدل‌های ترکیبی شبکه عصبی با الگوریتم PSO نشان می‌دهد که مقدار این شاخص نیز بهبود یافته، هر چند که هنوز با نقطه ایده‌آل آن فاصله دارد. در رابطه با کم یا زیاد بودن مقدار این شاخص و کاربرد و تفسیر آن خصوصا در شبیه‌سازی متغیر رسوب معلق، لازم است، تصمیم‌گیری و قضاوت با احتیاط انجام شود. همان‌طور که پیشتر بیان شد، با وجود محبوبیت کاربرد این شاخص در ارزیابی مدل‌های هیدرولوژیکی در بین پژوهشگران، این شاخص دارای محدودیت‌های جدی نیز است که می‌بایست به آن‌ها توجه شود (Muleta, ۲۰۱۲؛ Moriasi و همکاران، ۲۰۰۷). یکی از مشکلات اصلی این شاخص، حساس بودن آن به مقادیر خطاهای (اختلاف بین مقادیر مشاهده‌ای و محاسبه‌ای) بزرگ است. از آنجا که برای محاسبه این شاخص، خطا به توان دو می‌رسد (رابطه ۱۵)، لذا، وزن خطاهای بزرگ (که عمدتاً مربوط به رسوبات در دبی‌های سیلابی حوضه است) در محاسبه این شاخص تأثیر زیادی

شاخص‌های صحت‌سنجی مدل که در جدول ۴ به آن‌ها پرداخته شد، مدل‌های مختلف شبکه عصبی و رگرسیونی از نظر مقدار برآورد کل رسوب معلق و میزان بیش‌برآوردی یا کم‌برآوردی (PBIAS) در دوره آزمون نیز با یکدیگر مورد مقایسه گرفتند که نتایج آن‌ها در جدول ۵ و شکل ۳ نشان داده شده است.

خواهند داشت. از سوی دیگر، استفاده از میانگین داده‌های مشاهداتی به‌عنوان معیار در محاسبه این شاخص (رابطه ۱۵) نیز یکی دیگر از مشکلات این معیار محسوب می‌شود. در این رابطه، در ایستگاه مورد مطالعه، داده‌های رسوب دارای چولگی بسیار زیاد بوده (جدول ۱)، لذا، شاخص میانگین نمی‌تواند مرکزیت داده‌های رسوب را به درستی نشان دهد. علاوه بر

جدول ۵- مجموع کل رسوب معلق مشاهده‌ای و برآورد شده به‌وسیله مدل‌های مختلف در دوره آزمون

مقدار کل رسوب معلق برآورد شده (تن)						
SRC-MeanLoad	SRC	ANN-PSO-Tan	ANN-LM-Tan	ANN-PSO-Sig	ANN-LM-Sig	مقدار کل رسوب معلق مشاهده‌ای (تن)
۸۴۳/۰۰	۴۵۴/۹۲	۶۲۴/۳۷	۵۲۶/۷۷	۶۵۸/۵۶	۵۱۲/۲۸	۶۶۰/۹۷
-۲۷/۵۴	۳۱/۱۷	۵/۵۳	۲۰/۳۰	۰/۳۶	۲۲/۵	PBIAS (درصد)



مدل‌های برآوردگر رسوب معلق

شکل ۳- نمودار مجموع رسوب معلق مشاهده‌ای و برآورد شده به‌وسیله مدل‌های مختلف برای مجموعه داده‌های آزمون

می‌دهد، مدل‌های شبکه عصبی که با الگوریتم PSO آموزش دیده‌اند (مدل‌های ANN-PSO-Sig و ANN-PSO-Tan) در مقایسه با مدل‌های شبکه عصبی پس انتشار خطا (ANN-LM-Sig، ANN-LM-Tan) و مدل‌های رگرسیونی منحنی سنجه‌رسوب، از مقدار خطای کمتری برخوردار هستند. همچنین، در مقایسه با مدل‌های رگرسیونی، مدل‌های شبکه عصبی با آموزش پس انتشار خطا، وضعیت بهتری داشته‌اند. در این میان بیشترین خطا مربوط به مدل‌های رگرسیونی

همان‌طور که در جدول ۵ آمده است، مجموع وزنی رسوب معلق مشاهده‌ای در ایستگاه هیدرومتری نیر برای داده‌های آزمون ۶۶۰/۹۷ تن است که این مقدار در مدل‌های ANN-PSO-Sig، ANN-LM-Sig، ANN-PSO-Tan، ANN-LM-Tan و SRC به‌ترتیب با ۲۲/۵، ۰/۳۶، ۲۰/۳، ۵/۵۳ و ۳۱/۱۷ درصد کم برآوردی مقادیر ۵۱۲/۲۸، ۶۵۸/۵۶، ۵۲۶/۷۷ و ۴۵۴/۹۲ تن و در مدل SRC-MeanLoad با ۲۷/۵۴ درصد بیش برآوردی، مقدار ۸۴۳ تن است. نتایج نشان

برخوردار هستند. از سوی دیگر، مقایسه شاخص PBIAS مدل‌ها نشان می‌دهد که برآورد کل رسوب معلق در مدل‌های شبکه عصبی آموزش‌یافته با الگوریتم PSO در مقایسه با سایر مدل‌ها وضعیت بهتری داشته که این مسئله در برنامه‌ریزی و مدیریت منابع آب و مدیریت سدها و مخازن بسیار حائز اهمیت است. از نکات دیگری که می‌توان به آن اشاره کرد آن است که داده‌های سری‌های زمانی دبی-رسوب در مقایسه با دیگر متغیرهای هیدرولوژیکی حوضه (نظیر بارش، دما، دبی و غیره) از کیفیت و کمیت کمتری برخوردار بوده، لذا در برخی از مواقع، تعداد این داده‌ها به اندازه کافی زیاد نیست تا بتوان از آن‌ها در بهینه‌سازی ماتریس‌های اوزان شبکه‌های عصبی استفاده کرد. در چنین مواقعی وجود یک الگوریتم کارآمد تکاملی (نظیر الگوریتم PSO) می‌تواند نقش مهمی در آموزش صحیح مدل‌های شبکه عصبی داشته باشد. نتایج پژوهش انجام‌شده در زمینه به‌کارگیری الگوریتم PSO در بهینه‌سازی ماتریس اوزان مدل‌های شبکه عصبی و نقش مثبت آن در بهبود نتایج شبیه‌سازی با کارهای Alizamir و Sobhanardakani (۲۰۱۸)، Zounemat-Kermani (۲۰۱۷) و Guo و Wang (۲۰۱۰) مطابقت می‌کند. با توجه به اهمیت برآورد هر چه صحیح‌تر رسوب معلق رودخانه‌ها، در ادامه پژوهش حاضر، استفاده از بهینه‌سازی چند هدفه (به‌کارگیری الگوریتم PSO و دیگر الگوریتم‌های تکاملی نظیر الگوریتم ژنتیک به همراه توابع چند هدفه) در آموزش مدل‌های شبکه‌های عصبی پیشنهاد می‌شود.

### سپاسگزاری

پژوهش انجام شده با حمایت مالی و معنوی پژوهشکده حفاظت خاک و آبخیزداری انجام شده است که بدین‌وسیله از کلیه حمایت‌ها و عزیزانی که ما را در این راه کمک کرده‌اند، تشکر می‌شود.

منحنی سنج رسوب است. در مجموع مدل ANN- PSO-Sig با کاهش خطای برآورد کل و ریشه میانگین مربعات خطا به ترتیب تا ۰/۳ درصد و ۱۰/۴ تن در روز عملکرد بهتری نسبت به مدل‌های شبکه عصبی (که صرفاً از روش‌های پس انتشار خطا استفاده می‌کنند) و دیگر مدل‌های رگرسیونی داشته است.

### نتیجه‌گیری

پیچیده بودن سامانه‌های هیدرولوژیکی و حاکم بودن روابط غیرخطی نامشخص بین مجموعه داده‌های ورودی و خروجی از یک سو و وجود عدم قطعیت در درک و دانش محققین از اجزاء و فرایندهای درون آن‌ها از سوی دیگر، سبب شده است تا کاربرد مدل‌های هوشمند (نظیر مدل‌های شبکه عصبی مصنوعی) در شبیه‌سازی و پایش متغیرهای محیطی به‌خصوص مقدار رسوب معلق رودخانه‌ها بسیار رایج شود. با وجود کارایی مدل‌های شبکه عصبی در برآورد متغیرهای موردنظر، وجود مشکلاتی در زمینه آموزش این شبکه‌ها پژوهشگران را بر آن داشته است که از الگوریتم‌های جانشین دیگری برای آموزش این شبکه‌ها استفاده کنند. به‌طور معمول الگوریتم‌های آموزشی پایه در شبکه‌های عصبی، عمدتاً مبتنی بر روش گرادیان بوده که از تکنیک‌های جستجوی محلی استفاده می‌کنند و لذا، همواره در معرض خطر گیر-افتادن در نقاط بهینه محلی قرار دارند. برخی از انواع این الگوریتم‌ها مانند الگوریتم LM به حافظه زیادی برای محاسبات نیازمند هستند. برای رفع این مشکلات، در پژوهش حاضر که با هدف شبیه‌سازی بار رسوب معلق روزانه انجام شد، از الگوریتم فراابتکاری PSO به‌منظور آموزش مدل‌های شبکه عصبی استفاده شد و نتایج به‌دست آمده نشان داد که این روش آموزش، نسبت به الگوریتم‌های مبتنی بر گرادیان برتری داشته، مدل‌های شبکه عصبی حاصل از آن، از کارایی بیشتری در برآورد بار رسوب معلق

### منابع مورد استفاده

1. Alizamir, M. and S. Sobhanardakani. 2018. An Artificial Neural Network-Particle Swarm Optimization (ANN-PSO) approach to predict heavy metals contamination in groundwater resources. Jundishapur Journal of Health Sciences, 10(2): e67544. doi: 10.5812/jjhs.67544.

2. Altunkaynak, A. 2009. Sediment load prediction by genetic algorithms. *Advances in Engineering Software*, 40: 928-934.
3. Cheng, C.T., C.P. Ou and K.W. Chau. 2002. Combining a fuzzy optimal model with a genetic algorithm to solve multi-objective rainfall-runoff model calibration. *Journal of Hydrology*, 268: 72-86.
4. Criss, R.E. and W.E. Winston. 2008. Do Nash values have value? discussion and alternate proposals. *Hydrological Processes*, 22(14): 2723-2738.
5. Ebtehaj, I. and H. Bonakdari. 2016. Assessment of evolutionary algorithms in predicting non-deposition sediment transport. *Urban Water Journal*, 13: 499-510.
6. Guo, W. and H. Wang. 2010. August PSO optimizing neural network for the Yangtze River sediment entering estuary prediction. In 2010 6th International Conference on Natural Computation, 4: 1769-1772.
7. Gupta, H.V., S. Sorooshian and P.O. Yapo. 1999. Status of automatic calibration for hydrologic models: comparison with multilevel expert calibration. *Journal of Hydrologic Engineering*, 4(2): 135-143.
8. Gupta, H.V., H. Kling, K.K. Yilmaz and G.F. Martinez. 2009. Decomposition of the mean squared error and NSE performance criteria: implications for improving hydrological modeling. *Journal of Hydrology (Amsterdam)*, 377(1-2): 80-91.
9. Hejazi, M.I., X. Cai and D.K. Borah. 2008. Calibrating a watershed simulation model involving human interference: an application of multi-objective genetic algorithms. *Journal of Hydroinformatics*, 10: 97-111.
10. Hornik, K., M. Stinchcombe and H. White. 1989. Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5): 359-366.
11. Jansson, M.B. 1996. Estimating a sediment rating curve of the Reventazon River at Palomo using logged mean loads within discharge classes. *Journal of Hydrology*, 183(3-4): 227-241.
12. Kashefi Kavyani, A., S.A. Pourmosavi Kani and A. Jahanbani Adrakani. 2007. The training of multi-layer neural networks using PSO algorithm. First Joint Congress of Fuzzy Systems and Intelligent System, Mashhad, Ferdowsi University of Mashhad. Available online at: [https://www.civilica.com/Paper-FJCFIS01-FJCFIS01\\_229.html](https://www.civilica.com/Paper-FJCFIS01-FJCFIS01_229.html).
13. Kaufman, L. and P.J. Rousseeuw. 2009. Finding groups in data: an introduction to cluster analysis (Vol. 344). John Wiley and Sons, New Jersey, USA, 342 pages.
14. Kisi, O. and J. Shiri. 2012. River suspended sediment estimation by climatic variables implication: Comparative study among soft computing techniques. *Computers and Geosciences*, 43: 73-82.
15. Kisi, O., A. Keshavarzi, J. Shiri, M. Zounemat-Kermani and E.S.E. Omran. 2017. Groundwater quality modeling using neuro-particle swarm optimization and neuro-differential evolution techniques. *Hydrology Research*, 48(2017): 1508-1519.
16. Kisi, O. and C. Ozkan. 2017. A new approach for modeling sediment-discharge relationship: local weighted linear regression. *Water Resources Management*, 30(2): 1-23.
17. Krause, P., D.P. Boyle and F. Bäse. 2005. Comparison of different efficiency criteria for hydrological model assessment. *Advances in Geosciences*, 5: 89-97.
18. Kuok, K.K., S. Harun and S.M. Shamsuddin. 2010. Particle swarm optimization feedforward neural network for modeling runoff. *International Journal of Environmental Science and Technology*, 7: 67-78.
19. Lafdani, E.K., A.M. Nia and A. Ahmadi. 2013. Daily suspended sediment load prediction using artificial neural networks and support vector machines. *Journal of Hydrology*, 478: 50-62.
20. Legates, D.R. and G.J. McCabe. 1999. Evaluating the use of "goodness-of-fit" measures in hydrologic and hydroclimatic model validation. *Water Resources Research*, 35(1): 233-241.
21. May, R.J., H.R. Maier and G.C. Dandy. 2010. Data splitting for artificial neural networks using SOM-based stratified sampling. *Neural Networks*, 23: 283-294.
22. Mansourfar, K. 2009. Advanced statistical methods using applied software. University of Tehran Press, Tehran, Iran, 480 pages (in Persian).
23. Moriasi, D.N. and J.G. Arnold, M.W. Liew Van, R.L. Bingner, R.D. Harmel and T.L. Veith. 2007. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50(3): 885-900.
24. Muleta, M.K. 2011. Model performance sensitivity to objective function during automated calibrations. *Journal of Hydrologic Engineering*, 17(6): 756-767.
25. 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.
26. Nasserabadi, F., A. Esmaali Ouri and S. Tolabi. 2013. Estimation of soil erosion potential and sediment yield using EPM model and GIS technique, case study: Balkhlochai River Basin. The First

- National Conference on Planning, Conservation and Sustainable Development, Hamedan, Hegmatane Environment Evaluators Association, available online at: [https://www.civilica.com/Paper-PCEPSD01-PCEPSD01\\_157.html](https://www.civilica.com/Paper-PCEPSD01-PCEPSD01_157.html).
27. Partal, T. and H.K. Cigizoglu. 2008. Estimation and forecasting of daily suspended sediment data using wavelet–neural networks. *Journal of Hydrology*, 358(3-4): 317-331.
  28. Shahriar Shahhoseini, H., M. Moosavi and M. Mollajafari. 2011. *Evolutionary algorithms-fundamentals, applications, implementation*. Tehran Press Center, Iran University of Science and Technology, Tehran, 590 pages (in Persian).
  29. Swain, R. and B. Sahoo. 2017. Mapping of heavy metal pollution in river water at daily time-scale using spatio-temporal fusion of MODIS-aqua and Landsat satellite imageries. *Journal of Environmental Management*, 192: 1-14.
  30. Tabatabaei, M. and A. Salehpour Jam. 2017. Optimization of sediment rating curve coefficients using evolutionary algorithms and unsupervised artificial neural network. *Caspian Journal of Environmental Sciences*, 15(4): 387-401.
  31. Tabatabaei, M., A. Salehpour Jam and S.A. Hosseini. 2019. Suspended sediment load prediction using non-dominated sorting genetic algorithm II. *International Soil and Water Conservation Research*, 7(2): 119-129.
  32. Tayfur, G. 2012. *Soft computing in water resources engineering: artificial neural networks, fuzzy logic and genetic algorithms*. WIT Press, Dorset, UK, 288 pages.
  33. Tfwala, S.S. and Y.M. Wang. 2016. Estimating sediment discharge using sediment rating curves and artificial neural networks in the Shiwen River, Taiwan. *Water*, 8(53): 1-15.
  34. Ulke, A., G. Tayfur and S. Ozkul. 2009. Predicting suspended sediment loads and missing data for Gediz River, Turkey. *Journal of Hydrologic Engineering*, 14: 954-965.
  35. Yar Kiani, A. 2009. *Intelligent systems*. Press Center of Poyesh Andisheh, Tehran, Iran, 260 pages (in Persian).
  36. Zhou, H. and G. Schaefer. 2009. An overview of fuzzy C-Means based image clustering algorithms. *Foundations of Computational Intelligence*, 2: 295-310.
  37. Zounemat-Kermani, M. 2017. Assessment of several nonlinear methods in forecasting suspended sediment concentration in streams. *Hydrology Research*, 48(5): 1240-1252.