

ترکیب‌های بهینه متغیرهای هیدرولوژی برای مدل‌سازی بار رسوب معلق روزانه در حوزه آبخیز کرج

عاده علی‌جانپور شلمانی^{۱*}، علی‌رضا واعظی^۲ و محمودرضا طباطبایی^۳

^۱ دانشجوی دکتری، دانشکده کشاورزی، دانشگاه زنجان، استاد، دانشکده کشاورزی، دانشگاه زنجان و ^۲ استادیار، پژوهشکده حفاظت خاک و آبخیزداری، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران

تاریخ پذیرش: ۱۳۹۷/۱۲/۰۸

تاریخ دریافت: ۱۳۹۶/۱۲/۱۵

چکیده

تحلیل داده‌های بار رسوب معلق در رودخانه‌ها اساس شناخت روند فرسایش و رسوب در بحث مدیریت و برنامه‌ریزی منابع آب و خاک است. به دلیل عدم دسترسی به داده‌های بار رسوب معلق روزانه با اندازه‌گیری مستقیم، استفاده از روش‌هایی برای مدل‌سازی و برآورد آن در حوزه‌های آبخیز حائز اهمیت است. یکی از روش‌های مناسب مورد استفاده در این زمینه، به‌کارگیری شبکه‌های عصبی مصنوعی است. برای مدل‌سازی بار رسوب معلق روزانه، ایستگاه هیدرومتری سیرا در حوزه آبخیز رودخانه کرج مورد مطالعه قرار گرفت. تعداد داده مورد استفاده در این پژوهش، ۶۲۴ داده با طول دوره آماری ۳۱ سال (از سال ۱۳۶۰ تا ۱۳۹۰) است. متغیرهای ورودی به مدل‌های شبکه عصبی مصنوعی شامل دبی لحظه‌ای، متوسط دبی روزانه، متوسط دبی روزانه با تاخیر سه روزه، متوسط بارش روزانه و متوسط بارش روزانه با تاخیر سه روزه و متغیر خروجی به مدل‌ها بار رسوب معلق روزانه است. برای تعیین متغیرهای بهینه و بهترین ترکیب متغیرها برای ورود به مدل از آزمون گاما و الگوریتم ژنتیک استفاده شد. سپس، این ترکیب‌ها به همراه برخی از ترکیب متغیرهای حاصل از آزمون و خطا، وارد مدل‌های شبکه‌های عصبی مصنوعی شد. از شبکه عصبی نگاشت خودسازمان‌ده برای خوشه‌بندی داده‌ها استفاده و داده‌ها به سه گروه همگن، شامل ۷۰ درصد برای آموزش، ۱۵ درصد برای اعتبارسنجی و ۱۵ درصدی برای آزمون جدا شد. در ادامه، ترکیب متغیرها وارد مدل‌های شبکه عصبی با توابع فعال‌سازی لوگ سیگموئید و تانژانت سیگموئید شد. نتایج نشان داد، در بین تمام ترکیب‌های ورودی به مدل‌های شبکه عصبی، مدل با تابع فعال‌سازی تانژانت سیگموئید با ترکیب متغیرهای ورودی شامل دبی لحظه‌ای (Q)، دبی متوسط روزانه (Q_i)، دبی متوسط روزانه دو روز قبل (Q_{i-2})، دبی متوسط روزانه سه روز قبل (Q_{i-3})، بارندگی متوسط روزانه (P_i)، بارندگی متوسط روزانه دو روز قبل (P_{i-2}) و بارندگی متوسط روزانه سه روز قبل (P_{i-3}) مدل مناسب برای برآورد بار رسوب معلق روزانه شد. این مدل کمترین مقدار خطا (MAE=۵۰۰/۰۵ (tonday⁻¹))، RMSE=۱۹۹۵/۳۳ (tonday⁻¹) و بالاترین دقت (R²=۰/۹۶)، بالاترین کارایی مدل (NSE=۰/۹۶) و کمترین انحراف استاندارد عمومی (GSD=۰/۹۷) را در مقایسه با سایر مدل‌ها دارد. این مدل، بهترین ترکیب با تاثیرگذارترین متغیرهای ورودی به دست آمده از آزمون گاما و الگوریتم ژنتیک برای برآورد SSL است.

واژه‌های کلیدی: آزمون گاما، تانژانت سیگموئید، خوشه‌بندی، شبکه عصبی مصنوعی، نگاشت خودسازمان‌ده

مقدمه

تحلیل بار رسوب معلق^۱ (SSL) اساس شناخت روند فرسایش و رسوب رودخانه و حوزه آبخیز است. تشدید فرسایش، منجر به از دست دادن خاک حاصلخیز کشاورزی به همراه مواد غذایی مفید مانند رس و مواد آلی شده که این مواد در رسوبات به همراه عناصر و فلزات سنگین حمل شده و باعث آلودگی آب خواهند شد (Chen و Chau، ۲۰۱۶؛ Kisi و همکاران، ۲۰۱۲). فرسایش خاک به دو صورت طبیعی و تشدید (در اغلب موارد عامل ایجاد فرسایش تشدید انسان است) ایجاد می‌شود و شامل فرایندهای غیرخطی و پیچیده است. در نظر گرفتن تمامی عوامل تاثیرگذار بر روی فرسایش و در نتیجه، اندازه‌گیری و برآورد رسوب بسیار دشوار است (White، ۲۰۰۴؛ Azamathulla، ۲۰۱۳). بنابراین، با توجه به عدم اطمینان در شناخت فرایندهای موثر بر فرسایش و رسوبدهی در مدل‌سازی SSL یک حوزه آبخیز، به جای تمرکز برای ارائه رابطه‌ای کمی، توجه به پاسخ حوزه آبخیز در مقابل عوامل ورودی به آن (نظیر متغیر دینامیک حوزه آبخیز مانند بارش) حائز اهمیت است (Tayfur، ۲۰۱۲).

داده‌های بار رسوب معلق، از نظر کمیت و کیفیت دچار مشکل هستند. مشکلات در دسترس نبودن داده‌های بار رسوب معلق، مربوط به تعداد کم اندازه‌گیری‌ها، با توجه به هزینه زیاد، خرابی تجهیزات موجود در ایستگاه‌های آب‌سنجی و یا کمبود نیروی متخصص و مشکلات کیفی در ارتباط با دقت پایین اندازه‌گیری‌های انجام شده (به‌ویژه در دبی پایین) است. در صورتی که حجم زیادی از رسوب در دبی بالا حمل می‌شود (Tayfur، ۲۰۱۲). به دلیل مشکلات کمی و کیفی داده‌ها در اندازه‌گیری مستقیم، از روش‌های مدل‌سازی و برآورد آن در حوزه‌های آبخیز استفاده می‌شود. یکی از این روش‌ها، روش‌های هوشمند پردازش داده‌ها با استفاده از شبکه‌های عصبی مصنوعی است که به دلیل تحلیل اطلاعات با روشی مشابه مغز انسان، داشتن قدرت تعمیم‌دهی، عدم نیاز به یک مدل ریاضی از پیش تعیین شده و

توانایی آموزش و یادگیری می‌تواند در تخمین بار رسوب معلق مورد استفاده قرار گیرد. مدل‌های توسعه یافته از این شبکه‌ها قادرند، در شرایطی که داده‌ها از کیفیت و کمیت مناسبی برخوردار نیستند، هنوز هم کارآمد و دارای قدرت تعمیم‌دهی باشند.

تلاش‌های زیادی به‌وسیله پژوهشگران برای برآورد بار رسوب معلق، انجام شده است. برآورد رسوب معلق روزانه با متغیرهای ورودی دبی و رسوب به‌وسیله Ulke و همکاران (۲۰۰۹). در رودخانه گدیز در ترکیه انجام شد. نتایج به‌دست آمده از دو روش شبکه عصبی و رگرسیون چند متغیره نشان داد که روش شبکه عصبی برآورد دقیق‌تری از مقدار بار رسوب معلق را داشته است. در پژوهشی مشابه، نتایج مطالعات Wolfs و همکاران (۲۰۱۴) در برآورد بار رسوب معلق در رودخانه‌های مارک و دندر در بلژیک نشان داد که تمام مدل‌های شبکه عصبی مصنوعی دارای قدرت برآورد با دقت بالا (مقدار خطای کم و ضریب تبیین بالا) در مقایسه با روش منحنی سنجه رسوب است. Boukhrissa و همکاران (۲۰۱۳)، بار رسوب معلق را با استفاده از منحنی سنجه رسوب و شبکه عصبی مصنوعی در حوزه آبخیز الکبیر در الجزایر با داده‌های ورودی دبی و بار رسوب معلق روزانه، برآورد کردند. نتایج نشان داد که مدل‌های شبکه عصبی مصنوعی دارای کمترین خطای برآورد بار رسوب معلق روزانه بودند.

Abbaspour و همکاران (۲۰۱۵)، برای برآورد بار رسوب معلق در ایستگاه هیدرومتری چم انجیر در لرستان، روش‌های شبکه عصبی مصنوعی و منحنی سنجه رسوب را با داده‌های دبی روزانه و دبی رسوب روزانه مورد مقایسه قرار دادند. نتایج نشان داد که مدل شبکه عصبی دارای قدرت بیشتری در برآورد دبی رسوب با میانگین مربعات خطای پایین‌تر (۰/۰۱۸۷) در مقایسه با منحنی سنجه رسوب بود. Tfwalla و Wang (۲۰۱۶)، برای برآورد دقیق‌تر بار رسوب در رودخانه شیون تایوان به مقایسه دو مدل منحنی سنجه رسوب و شبکه عصبی مصنوعی پرداختند. این پژوهشگران از ۱۷۰ داده رسوب معلق و دبی جریان برای برآورد بار رسوب استفاده کردند. نتایج نشان داد که مدل شبکه عصبی مصنوعی با

¹ Suspended Sediment Load

انتخاب بهترین ترکیب از آزمون گاما استفاده شد. همچنین، برخلاف پژوهش‌های قبلی از تاثیر متغیر دینامیک حوزه آبخیز (بارش) در برآورد SSL در این پژوهش استفاده شده است. از این‌رو در این پژوهش به‌منظور بررسی مقدار بار رسوب معلق، از روش‌های شبکه عصبی مصنوعی نگاشت خودسازمان‌ده، شبکه‌های عصبی مصنوعی با توابع فعال‌سازی لوگ سیگموئید و تانژانت سیگموئید و آزمون گاما، در حوزه آبخیز کرج استفاده شد.

مواد و روش‌ها

منطقه مورد پژوهش: حوزه آبخیز کرج در مختصات جغرافیایی $35^{\circ} 35'$ تا $51^{\circ} 3'$ طول شرقی و $36^{\circ} 11'$ تا $53^{\circ} 53'$ عرض شمالی در فاصله ۳۰ تا ۶۰ کیلومتری شمال و شمال غرب استان تهران واقع است. این حوزه دارای مساحت ۸۲۱ کیلومتر مربع و محیط ۲۷۴ کیلومتر، با ارتفاع متوسط ۲۹۹۳ متر از سطح دریا است. طول آبراهه اصلی این حوزه، ۴۷ کیلومتر و شیب متوسط رودخانه ۳۷/۴ درصد است. ضریب گراویلیوس و ضریب شکل این حوزه به ترتیب، ۲/۶۸ و ۲/۶۹ است. حوزه آبخیز کرج از شمال به حوزه آبخیز چالوس، هراز، طالقان رود، از غرب به حوزه آبخیز کردان و از شرق به حوضه‌های رودخانه‌های منتهی به تهران و رودخانه جاجرود محدود می‌شود. از نظر سامانه رودخانه‌ای از پرآب‌ترین رودخانه‌های فلات مرکزی است. ایستگاه هیدرومتری مورد مطالعه ایستگاه سیرا از نوع درجه یک می‌باشد و دوره داده‌های آماری قابل استفاده از آن با توجه به داده‌های دینامیک حوزه آبخیز ۳۱ سال از سال ۱۳۶۰ تا ۱۳۹۰ است. متوسط بارندگی سالیانه این ایستگاه ۶۳۶/۸ میلی‌متر و متوسط دمای سالیانه، ۸/۶۴ درجه سانتی‌گراد است. خاک حوزه آبخیز عمق چندانی ندارد و پوشش گیاهی منطقه تنک است. اقلیم منطقه بر اساس روش دومارتن از نوع مرطوب است (شکل ۱). مشخصات آماری داده‌های مورد استفاده در این مطالعه در جدول ۱ نشان داده شده است.

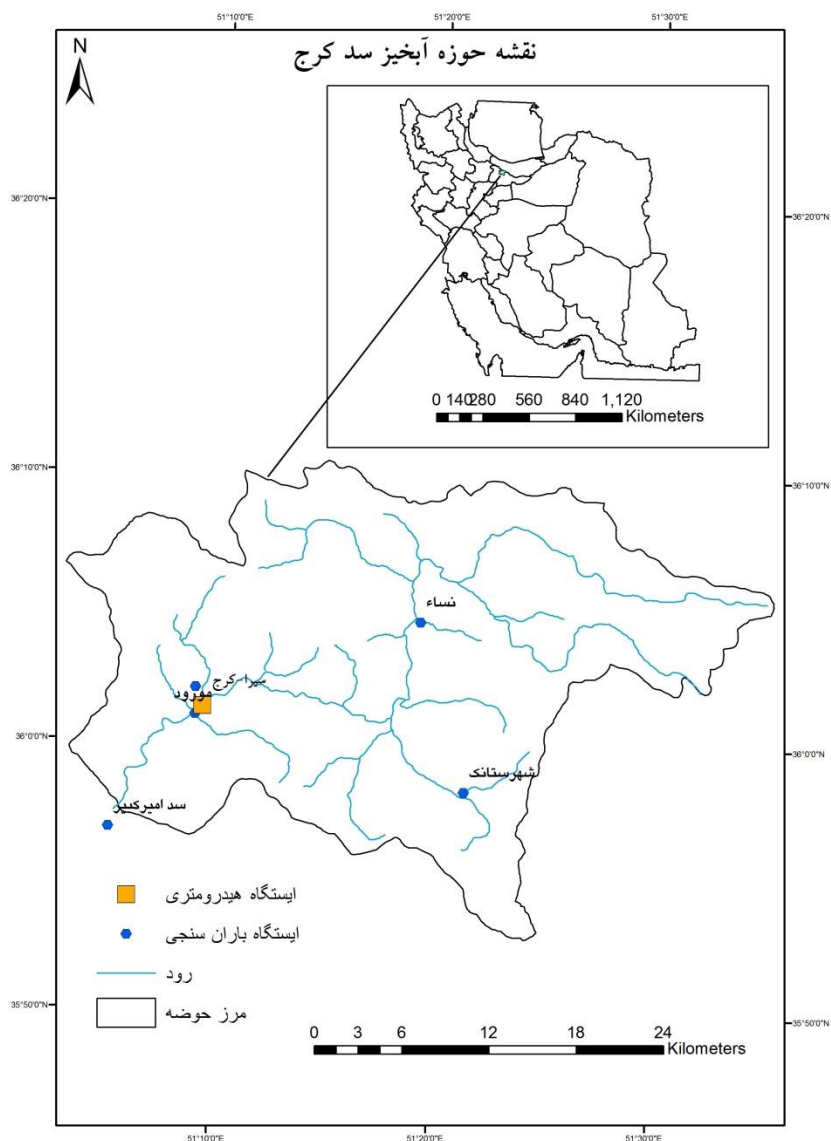
ضریب تبیین برابر با ۰/۸ دارای قدرت بیشتری در تخمین بار رسوب معلق نسبت به منحنی سنجه رسوب با ضریب تبیین برابر با ۰/۶۵ بود. Joshi و همکاران (۲۰۱۶)، غلظت رسوب معلق در یخچال‌های طبیعی کنگتری در هیمالیا را مورد بررسی قرار دادند. رابطه بین غلظت رسوب معلق با دبی با استفاده از شبکه عصبی مصنوعی پیشرو با الگوریتم پس انتشار خطا مورد بررسی قرار گرفت. داده‌ها طی یک دوره ۱۱ ساله از سال ۱۹۹۹ تا ۲۰۰۹ جمع‌آوری شد. نتایج نشان داد که مدل شبکه عصبی مصنوعی برآورد دقیق‌تری از غلظت رسوب معلق نسبت به منحنی سنجه رسوب داشت.

Ozkan و Kisi (۲۰۱۷)، برای مدل‌سازی رسوب معلق در رودخانه ال در کالیفرنیا، داده‌های دو ایستگاه در سال‌های ۱۹۶۶ تا ۱۹۷۷ را مورد بررسی قرار دادند. روش رگرسیون خطی وزن‌دار مکانی (LWLR)، شبکه عصبی مصنوعی (ANN) و منحنی سنجه رسوب (SRC) مورد مقایسه قرار گرفتند. نتایج نشان داد که روش شبکه عصبی مصنوعی ۳۹ درصد در مقایسه با سایر مدل‌ها برآورد دقیق‌تری از رسوب معلق را داشت.

همان‌طور که مشاهده شد، قابلیت روش‌های مختلف از جمله منحنی سنجه رسوب و روش‌های هوش مصنوعی در بحث رسوب در ایستگاه سیرا و در سایر حوضه‌ها مورد بررسی قرار گرفت. در مقالات مورد مطالعه، کمتر به بحث همگن‌سازی داده‌ها توجه شده است. همگن‌سازی باعث می‌شود تا داده‌های مورد استفاده در هر سه مجموعه داده‌های آموزش، اعتبارسنجی و آزمون برای متغیرهای مختلف، نماینده‌ای از داده‌های جمعیت آماری در طول دوره باشد. به‌همین دلیل، نقش مهمی در کارایی و قدرت برآورد دقیق مدل‌ها خواهند داشت (Tokar و Johnson، ۱۹۹۹). بدین منظور، از شبکه عصبی نگاشت خودسازمان‌ده (SOM)^۱ و خوشه‌بندی^۲ داده‌ها (Zhu، ۲۰۰۷) در این بررسی استفاده شد. انتخاب بهترین ترکیب متغیر ورودی به مدل در بسیاری از مطالعات در نظر گرفته نشده است. بنابراین، برای

¹ Self-Organizing Map

² Clustering



شکل ۱- موقعیت حوزه آبخیز کرج

جدول ۱- مشخصات آماری داده‌های مورد استفاده حوزه آبخیز کرج

چولگی	ضریب تغییرات	میانگین	بیشینه	کمینه	نوع داده
۲/۲۳	۰/۹۹	۱۷/۳۱	۱۳۶/۱۷	۲/۶۳	دبی لحظه‌ای Q (m^3s^{-1})
۱/۷۸	۰/۹۴	۱۶/۵۲	۸۷/۹۵	۲/۰۵	دبی متوسط روزانه Q_i (m^3s^{-1})
۱/۴۷	۰/۸۶	۱۴/۷۴	۸۷/۱۶	۱/۹۵	دبی متوسط روزانه یک روز قبل Q_{i-1} (m^3s^{-1})
۱/۷۲	۰/۸۹	۱۴/۳۲	۸۷/۱۶	۱/۹۵	دبی متوسط روزانه دو روز قبل Q_{i-2} (m^3s^{-1})
۱/۵۷	۰/۸۷	۱۴/۰۴	۸۷/۹۵	۲/۱۴	دبی متوسط روزانه سه روز قبل Q_{i-3} (m^3s^{-1})
۲/۸۰	۲/۰۷	۴/۹۲	۷۲/۲۸	۰/۰۰	بارندگی متوسط روزانه P_i (mm)
۳/۳۴	۲/۱۹	۲/۸۶	۵۲/۵۴	۰/۰۰	بارندگی متوسط روزانه یک روز قبل P_{i-1} (mm)
۵/۴۱	۲/۷۳	۲/۳۰	۷۲/۲۸	۰/۰۰	بارندگی متوسط روزانه دو روز قبل P_{i-2} (mm)
۳/۶۳	۲/۶۱	۱/۹۰	۳۶/۰۴	۰/۰۰	بارندگی متوسط روزانه سه روز قبل P_{i-3} (mm)
۶/۵۹	۳/۴۵	۱۶۲۰/۲۵	۶۲۹۵۸/۹۱	۰/۷۴	بار رسوب معلق روزانه SSL ($tonday^{-1}$)

که در آن، r متغیر تصادفی است. آزمون گاما برآورد واریانس خروجی یک مدل غیرهموار است، آزمون گاما بر اساس $N[i, k]$ ، است که حاوی یک لیست از همسایگان ($1 \leq k \leq p$) برای هر بردار X_i ($1 \leq i \leq M$) است.

تابع دلتا میانگین مجذور فاصله K امین همسایگی را محاسبه می‌کند (Durrant, ۲۰۰۱).

$$\delta_m(k) = \frac{1}{M} \sum_{i=1}^M |X_{N[i,k]} - X_i|^2 \quad (3)$$

که در آن، $|X_{N[i,k]} - X_i|$ نشان دهنده فاصله اقلیدسی است، تابع گاما مربوطه در معادله زیر نشان داده شده است (Durrant, ۲۰۰۱).

$$\gamma_m(k) = \frac{1}{2M} \sum_{i=1}^M |y_{N[i,k]} - y_i|^2 \quad (4)$$

که در آن، $y_{N[i,k]}$ مقدار متناظر با K امین همسایگی X_i در رابطه (۴) است. به منظور محاسبه Γ ، یک خطر گریسون خطی از P نقطه بر مقادیر $\delta_m(k)$ و $\gamma_m(k)$ برآزش داده می‌شود (Durrant, ۲۰۰۱).

$$\gamma = A\delta + \Gamma \quad (5)$$

عرض از مبدأ این خط ($\delta=0$)، مقدار Γ را نشان می‌دهد و $\gamma_m(k)$ برابر با واریانس خطاها است.

یکی دیگر از معیارهای مهم که می‌تواند با استفاده از آزمون گاما به دست آید، معیار بدون بعد معادله (V_{ratio}) است که مقدار آن بین صفر و یک تغییر می‌کند (Evans و Jones, ۲۰۰۲).

$$V_{ratio} = \frac{\Gamma}{\sigma^2(y)} \quad (6)$$

که در آن، $\sigma^2(y)$ واریانس خروجی از y است و مقدار آن به صفر نزدیک‌تر است، این نشان‌دهنده دقت بالا مدل برای یافتن خروجی‌های مطلوب ورودی است. در واقع، اگر مقدار v_{ratio} از عدد یک کم شود، مقدار ضریب تبیین به دست می‌آید (Jones, ۲۰۰۴؛ Moghaddamnia و همکاران، ۲۰۰۹). در این مطالعه، برای به دست آوردن بهترین ترکیب‌های ورودی به مدل شبکه عصبی مصنوعی، از آزمون گاما در نرم‌افزار WinGammaTM استفاده شد. همچنین، برای اطمینان از دقت ترکیب‌های ورودی به دست آمده از آزمون گاما، از روش الگوریتم ژنتیک در این نرم‌افزار استفاده شد.

شبکه عصبی مصنوعی SOM: یکی از روش‌های پیش‌پردازش قبل از فرایند آموزش در مدل‌ها، خوشه‌بندی داده‌ها و قرار دادن آن‌ها در گروه‌های

داده‌های مورد استفاده: در این پژوهش، متغیرهای ورودی مدل‌ها شامل دبی لحظه‌ای (Q)، متوسط دبی روزانه (Q_i) و متوسط بارش روزانه (P_i) و متغیر خروجی به مدل‌ها بار رسوب معلق روزانه (SSL) است. برای افزایش دقت مدل‌سازی بار رسوب معلق روزانه، علاوه بر متوسط دبی و بارش روزانه جاری، از داده‌های تا سه روز قبل نیز استفاده شد.

انتخاب متغیرهای بهینه و ترکیب آن‌ها در مدل‌های هوشمند: به منظور افزایش دقت و کاهش وقت در مدل‌سازی، یکی از مهمترین مراحل قبل از انجام مدل‌سازی، انتخاب بهینه و بهترین ترکیب متغیرهای ورودی به مدل‌ها است. اگر فرض شود، تعداد متغیرهای ورودی به مدل برابر m باشد، تعداد $2^m - 1$ حالت ترکیب از متغیرهای ورودی برای ورود به مدل وجود دارد. استفاده از همه ترکیبات ممکن، برای یافتن بهترین ترکیب‌های ورودی به مدل بسیار وقت‌گیر و مشکل است. با استفاده از روش‌های آزمون گاما و الگوریتم ژنتیک می‌توان از بین تمام حالات ممکن از ترکیبات، به بهینه و بهترین ترکیب‌های متغیرهای ورودی به مدل دست یافت. آزمون گاما با بررسی تمامی حالات ترکیبات ورودی در مدل‌سازی غیرخطی، کمینه میانگین مربعات خطا^۱ (MMSE) را در نظر گرفته و مقدار خطا برای هر ترکیب ورودی را محاسبه می‌کند و با ارائه مناسب‌ترین رابطه بین ورودی‌ها و خروجی، ترکیب متغیرهای ورودی بهینه را شناسایی می‌کند. در نهایت ترکیب‌هایی از داده‌ها که دارای کمترین میزان خطا و کمترین مقدار V_{ratio} و ضریب گاما هستند، به عنوان بهترین ترکیب‌های متغیری به مدل انتخاب می‌شوند (Lafdani-Kakaei و همکاران، ۲۰۱۳؛ Durrant, ۲۰۰۱). فرض کنید مجموعه‌ای از داده‌های مشاهده‌ای وجود دارد (Durrant, ۲۰۰۱).

$$((x_1 \dots x_m), y) = (X, y) \quad (1)$$

که در آن، $(x_1 \dots x_m)$ بردار ورودی در محدوده CER^m و y بردار خروجی است. اگر معادله (۲) بین اعضای جامعه وجود داشته باشد.

$$y = f(x_1 \dots x_m) + r \quad (2)$$

¹ Minimum Mean Square Error

که در آن، DB شاخص دیویس بولدین، n_c تعداد خوشه‌ها و R_i بالاترین شباهت بین خوشه‌ای است که با استفاده از معادله (۱۰) محاسبه می‌شود.

$$R_i = \max_{j=1, \dots, n_c, i \neq j} (R_{ij}), i=1, \dots, n_c \quad (10)$$

در نهایت، خوشه‌هایی ایجاد می‌شوند که داده‌ها در هر خوشه همگن و نماینده‌ای از کل داده‌ها هستند. هرچه مقدار این شاخص کمتر باشد، خوشه‌های بهتری تولید شده است (Bolboaca و همکاران، ۲۰۰۶). بنابراین، داده‌ها به سه گروه همگن آموزش، اعتبارسنجی و آزمون تقسیم می‌شوند که به ترتیب ۷۰ درصد داده برای آموزش، ۱۵ درصد برای داده‌های اعتبارسنجی و ۱۵ درصد برای داده‌های آزمون استفاده خواهد شد.

شبکه عصبی مصنوعی نظارت شده پرسپترون رو به جلو: شبکه عصبی مصنوعی پرسپترون از سه لایه ورودی، پنهان و خروجی تشکیل می‌شود. هر یک از لایه‌ها از تعدادی نورون (گره، سلول یا واحد) تشکیل شده است که هر نورون به کلیه نورون‌های لایه دیگر متصل است. نورون‌های لایه ورودی مکان قرار گرفتن پارامترهای ورودی است و تعداد نورون‌های لایه ورودی و خروجی به ترتیب برابر با تعداد متغیرهای ورودی و خروجی مدل است. تعداد نورون‌های لایه پنهان نیز با توجه به پیچیدگی مدل و متغیرهای خروجی، به وسیله طراح انتخاب می‌شود (He و همکاران، ۲۰۱۴). روند آموزش در شبکه‌های عصبی مصنوعی پرسپترون از قانون کلی دلتا^۲ یا قانون پس‌انتشار خطا (معادله ۱۱) تبعیت می‌کند که با جهت جریان داده، از لایه ورودی به سمت لایه پنهان و از لایه پنهان به سمت لایه خروجی است. شبکه عصبی مصنوعی پرسپترون، یک شبکه عصبی نظارت شده است که آموزش آن با ناظر انجام می‌شود. یعنی در طی فرایند آموزش، داده‌های ورودی به مدل، خروجی واقعی را می‌بیند و بر اساس آن آموزش داده می‌شوند (He و همکاران، ۲۰۱۴).

$$W_{ij}^{new} = W_{ij}^{old} - \eta \frac{\partial E}{\partial W_{ij}} \quad (11)$$

همگن است. انجام این فرایند قدرت تعمیم‌دهی و اعتماد به کارایی مدل‌ها را افزایش خواهد داد. بدین منظور، در این پژوهش از روش SOM که یک روش شبکه عصبی مصنوعی با یادگیری بدون نظارت است، استفاده شد. این شبکه دارای دو فاز نگاشت و آموزش است. فاز آموزش یک فاز رقابتی است که نگاشت را با استفاده از متغیرهای ورودی‌ها ایجاد می‌کند. روش SOM دارای ساختار دو لایه متشکل از لایه ورودی که محل قرار گرفتن نورون‌های ورودی و شبکه نورون خروجی در لایه خروجی است. بر اساس فاصله اقلیدوسی (معادله ۷) نورون‌های لایه ورودی با نورون‌های لایه خروجی و با جابه‌جایی شبکه، بیشترین هم‌پوشانی داده‌ها در خوشه‌ها صورت می‌گیرد (Chaudhary و همکاران، ۲۰۱۴).

$$j=1, 2, \dots, M$$

$$D_j = |x - w_j| = \sum_{i=1}^N [(x_i - w_{ji})^2]^{\frac{1}{2}} \quad (7)$$

که در آن، D_j فاصله نورون j ام لایه خروجی از بردار ورودی $x = (x_i; i=1, 2, 3, \dots, N) \in R^N$ ، N تعداد متغیرهای بردار ورودی، M تعداد نورون‌های لایه خروجی، W_{ji} وزن نورون خروجی j ام، $(W_{ji}; j=1, 2, \dots, M; i=1, 2, \dots, N)$ و علامت $|x - w_j|$ ، نشان‌دهنده فاصله است (Bowden، ۲۰۰۲).

ارزیابی خوشه‌ها با روش شاخص دیویس بولدین: یکی از روش‌ها برای تعیین تعداد بهینه خوشه طی فرایند خوشه‌بندی استفاده از شاخص دیویس بولدین است. اساس کار این روش میانگین شباهت بین هر خوشه با شبیه‌ترین خوشه به آن (معادله ۸) است. در صورتی که خوشه‌های به دست آمده از این روش، کروی شکل و قابل تفکیک از هم باشند، تعداد خوشه‌ها بهینه است (Gan و همکاران، ۲۰۰۷).

$$R_{ij} = \frac{s_i + s_j}{d_{ij}} \quad (8)$$

که در آن، R_{ij} شباهت بین خوشه‌های i و j ، s_i و s_j پراکندگی خوشه‌های i و j و d_{ij} فاصله بین مراکز دو خوشه است.

شاخص دیویس بولدین از طریق رابطه زیر به دست می‌آید.

$$DB = \frac{1}{n_c} \sum_{i=1}^{n_c} R_i \quad (9)$$

² Feed Forward Multi Layer Perceptron (FFMLP)

³ DeltaRule, Back Propagation Rules

¹ Davies Bouldin Index

پراکنش^۷ داده‌های مشاهده‌ای با داده‌های محاسباتی نیز رسم شد.

$$R^2 = \left[\frac{\sum_{i=1}^n (s_o - \bar{s}_o)(s_p - \bar{s}_p)}{\sqrt{\sum_{i=1}^n (s_o - \bar{s}_o)^2 \sum_{i=1}^n (s_p - \bar{s}_p)^2}} \right]^2 \quad (15)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (s_p - s_o)^2} \quad (16)$$

$$MAE = \frac{\sum_{i=1}^n |s_o - s_p|}{n} \quad (17)$$

$$E_{rel} = \frac{(s_o - \bar{s}_o)}{\bar{s}_o} \quad (18)$$

$$GSD = \frac{RMSE}{\bar{s}_o} \quad (19)$$

$$NS = 1 - \frac{\sum_{i=1}^n (s_p - s_o)^2}{\sum_{i=1}^n (s_o - \bar{s}_o)^2} \quad (20)$$

که در آن‌ها، s_o و s_p به ترتیب بار رسوب معلق مشاهده‌ای و برآورد شده، \bar{s}_o میانگین بار رسوب معلق مشاهده‌ای، \bar{s}_p میانگین بار رسوب معلق برآورد شده و n تعداد داده‌ها است.

نتایج و بحث

نتایج خوشه‌بندی داده‌ها: برای انجام خوشه‌بندی داده‌ها از شبکه عصبی SOM استفاده شد. تعداد بهینه خوشه با استفاده از شاخص دیویس بولدین ۳۳ خوشه تعیین شد (شکل ۲). همان‌طور که در شکل ۲ مشاهده می‌شود، کمترین مقدار این شاخص (۱/۰۱) نشان‌دهنده تعداد خوشه بهینه است. پس از آن داده‌های حاصل از خوشه‌بندی به سه مجموعه ۷۰ درصدی داده‌های آموزش، ۱۵ درصدی داده‌های اعتبارسنجی و ۱۵ درصدی داده‌های آزمون تقسیم شد. نتایج آماری حاصل از خوشه‌بندی در سه مجموعه در جدول ۲ نشان داده شده است. مقایسه نتایج حاصل از سه مجموعه آموزش، اعتبارسنجی و آزمون در هر ۱۰ متغیر، نشان‌دهنده توزیع یکنواخت داده‌ها است. به عبارت دیگر، نتایج نشان داد که داده‌های حاصل از خوشه‌بندی در هر مجموعه که در نهایت در مدل استفاده خواهند شد، نماینده‌ای از کل دوره آماری هستند. این فرایند باعث افزایش قدرت تعمیم‌دهی مدل‌ها و همچنین، افزایش دقت برآورد بار رسوب معلق خواهد شد. Chaudhary و همکاران (۲۰۱۴)، در مطالعات خود به این نتیجه رسیدند که استفاده از خوشه‌بندی به روش SOM باعث

که در آن، W_{ij}^{new} و W_{ij}^{old} به ترتیب وزن بین نورون‌های i و j قبل و بعد از یک تکرار معین، η نرخ یادگیری و E تابع خطا است. آموزش شبکه زمانی تمام می‌شود که میزان خطا به کمترین میزان رسیده باشد (Kaufman, ۲۰۰۹). در طی فرایند آموزش شبکه عصبی، برای کاهش میزان خطا، از الگوریتم مارکوارت-لونبرگ استفاده شد. با سعی و خطا، تعداد یک لایه پنهان در شبکه‌های عصبی استفاده شد. توابع فعال‌سازی برای نورون‌های لایه پنهان و لایه خروجی به ترتیب لوگ سیگموئید یا تانژانت سیگموئید و خطی است.

استانداردسازی داده‌ها: به منظور بی‌بعد کردن داده‌ها در محاسبات ورود داده‌ها به نرم‌افزار WinGammaTM و یا به منظور جلوگیری از کوچک شدن بیش از حد وزن‌های تخصیص‌یافته به نورون‌ها در مدل‌های شبکه عصبی انجام می‌شود. در این مطالعه برای ورود داده‌ها به نرم‌افزار WinGammaTM استانداردسازی داده‌ها بین [۰ ۱] و به دلیل استفاده از توابع محرک سیگموئید و تانژانت هیپربولیک در شبکه‌های عصبی مصنوعی استاندارد سازی داده‌ها به ترتیب بین [۰/۱ ۰/۹] و [۰-/۹ ۰/۹] انجام شد.

$$Z = \frac{(X_i - X_{imin})}{(X_{imax} - X_{imin})} \quad (12)$$

$$Z = 0.1 + 0.8 \times \frac{(X_i - X_{imin})}{(X_{imax} - X_{imin})} \quad (13)$$

$$Z = \left(1.8 \times \frac{(X_i - X_{imin})}{(X_{imax} - X_{imin})} \right) - 0.9 \quad (14)$$

که در آن‌ها، Z متغیر استاندارد شده، X_i متغیر

اولیه، X_{imin} مقدار کمینه و X_{imax} مقدار بیشینه است.

ارزیابی کارایی مدل‌ها: برای ارزیابی صحت و اعتبار داده‌های محاسبه شده با استفاده از مدل‌ها در مقابل مقادیر مشاهده‌ای، از آماره‌های ضریب تبیین^۱ (R^2)، ریشه میانگین مربعات خطا^۲ (RMSE)، میانگین قدر مطلق خطا^۳ (MAE) (معادله ۱۷)، خطای نسبی^۴ (E_{rel})، انحراف استاندارد عمومی^۵ (GSD) و معیار نش-ساتکلiffe^۶ (NS) استفاده شد. همچنین، نمودار

¹ Coefficient of determination

² Root Mean Square Error

³ Mean Absolute Error

⁴ Relative error

⁵ General Standard Deviation

⁶ Nash-Sutcliffe

⁷ Scatter Plot

را افزایش دهد. در پژوهشی مشابه Liao و Shieh (۲۰۱۲) و Kohonen (۲۰۱۳) نیز به همین نتیجه رسیدند که با نتایج به‌دست آمده از این پژوهش مطابقت دارد.

همگن‌سازی داده‌ها خواهد شد و نتیجه در برآورد متغیرها دقیق‌تر از زمانی خواهد بود که خوشه‌بندی انجام نشده است. این پژوهشگران الگوریتم SOM را مورد بررسی قرار دادند و گزارش کردند که در بحث برآورد این روش قادر است تا قدرت تعمیم‌دهی مدل‌ها

جدول ۲- مشخصات آماری حاصل از خوشه‌بندی داده‌ها در سه مجموعه آموزش، اعتبارسنجی و آزمون

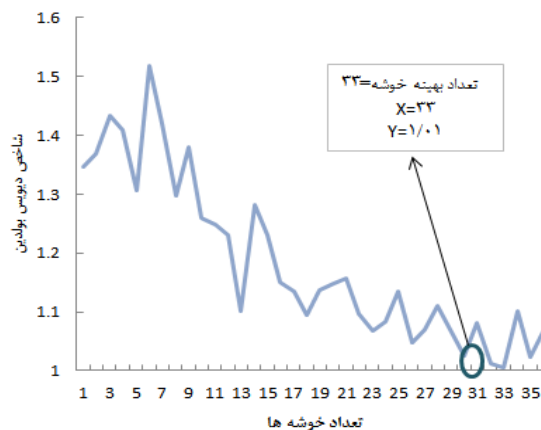
مجموعه داده	نوع داده	کمینه	بیشینه	میانگین	ضریب تغییرات	چولگی
دبی لحظه‌ای (m^3s^{-1}) Q_t	آموزش	۲/۶۳	۱۳۶/۱۷	۱۷/۱۹	۹۵/۲۵	۲/۱۹
	اعتبارسنجی	۲/۶۷	۱۰۹/۲۴	۱۸/۰۵	۱۰۹/۹۱	۲/۱۵
	آزمون	۲/۸۲	۱۰۲/۱۹	۱۶/۵۸	۱۰۹/۹۱	۲/۳۹
دبی متوسط روزانه (m^3s^{-1}) Q_t	آموزش	۲/۰۵	۸۴/۲۹	۱۶/۳۴	۹۱/۲۴	۱/۶۸
	اعتبارسنجی	۲/۷۵	۸۶/۷۸	۱۷/۹۲	۱۰۰/۴۲	۱/۶۱
	آزمون	۲/۹۰	۸۷/۹۵	۱۵/۳۲	۱۰۰/۴۲	۲/۲۱
دبی متوسط روزانه یک روز قبل (m^3s^{-1}) Q_{t-1}	آموزش	۱/۹۵	۸۷/۱۶	۱۴/۷۷	۸۵/۳۴	۱/۵۴
	اعتبارسنجی	۲/۷۶	۵۴/۶۰	۱۵/۳۴	۹۰/۶۸	۱/۱۸
	آزمون	۳/۰۸	۵۳/۸۸	۱۳/۹۰	۹۰/۶۸	۱/۵۰
دبی متوسط روزانه دو روز قبل (m^3s^{-1}) Q_{t-2}	آموزش	۱/۹۵	۸۷/۱۶	۱۴/۴۹	۹۰/۰۶	۱/۸۴
	اعتبارسنجی	۲/۷۶	۵۲/۶۰	۱۴/۵۴	۸۹/۰۵	۱/۱۳
	آزمون	۲/۹۲	۵۶/۲۷	۱۳/۲۵	۸۹/۰۵	۱/۵۳
دبی متوسط روزانه سه روز قبل (m^3s^{-1}) Q_{t-3}	آموزش	۲/۱۴	۸۷/۹۵	۱۴/۲۱	۸۷/۷۳	۱/۶۵
	اعتبارسنجی	۲/۷۶	۵۲/۲۰	۱۳/۹۹	۹۰/۱۹	۱/۲۳
	آزمون	۳/۱۶	۵۶/۲۷	۱۳/۳۰	۹۰/۱۹	۱/۴۸
بارندگی متوسط روزانه (mm) P_t	آموزش	۰/۰۰	۷۲/۲۸	۴/۸۸	۲۰۶/۹۳	۲/۷۸
	اعتبارسنجی	۰/۰۰	۵۷/۵۰	۵/۱۲	۲۰۵/۹۹	۲/۸۵
	آزمون	۰/۰۰	۵۲/۵۴	۴/۴۹	۲۰۵/۹۹	۲/۹۱
بارندگی متوسط روزانه یک روز قبل (mm) P_{t-1}	آموزش	۰/۰۰	۵۲/۵۴	۲/۹۳	۲۱۵/۲۲	۳/۳۰
	اعتبارسنجی	۰/۰۰	۳۹/۴۵	۲/۹۴	۲۳۰/۸۶	۳/۳۸
	آزمون	۰/۰۰	۳۱/۲۲	۲/۳۸	۲۳۰/۸۶	۳/۳۵
بارندگی متوسط روزانه دو روز قبل (mm) P_{t-2}	آموزش	۰/۰۰	۷۲/۲۸	۲/۳۶	۲۸۸/۴۸	۵/۶۱
	اعتبارسنجی	۰/۰۰	۲۲/۴۶	۲/۳۷	۲۲۳/۶۲	۲/۵۱
	آزمون	۰/۰۰	۲۵/۹۶	۱/۸۹	۲۲۳/۶۲	۳/۳۳
بارندگی متوسط روزانه سه روز قبل (mm) P_{t-3}	آموزش	۰/۰۰	۳۶/۰۴	۱/۹۵	۲۶۳/۹۰	۳/۶۲
	اعتبارسنجی	۰/۰۰	۲۹/۰۹	۲/۱۷	۲۴۱/۲۱	۲/۸۹
	آزمون	۰/۰۰	۲۷/۶۶	۱/۴۰	۲۴۱/۲۱	۴/۵۳
بار رسوب معلق روزانه ($today^{-1}$) SSL	آموزش	۱/۱۰	۶۲۹۵۸/۹۱	۱۵۴۸/۶۷	۳۵۸/۳۷	۷/۱۱
	اعتبارسنجی	۱/۴۱	۳۰۰۴۸/۵۲	۱۷۶۰/۵۷	۲۷۱/۰۴	۳/۹۰
	آزمون	۰/۷۴	۴۹۵۷۸/۹۹	۱۵۶۴/۱۷	۲۷۱/۰۴	۶/۶۵

گاما، خطای استاندارد و V_{ratio} ، برای ورود به شبکه - های عصبی مصنوعی انتخاب شد. جدول ۳، نتایج بهترین ترکیب‌های متغیرهای ورودی به مدل با آماره‌های گاما، خطای استاندارد و V_{ratio} را برای هر دو

نتایج آزمون گاما و الگوریتم ژنتیک: در این روش، تمامی ترکیبات ممکن بر اساس متغیرهای ورودی، در نرم‌افزار مورد تجزیه و تحلیل قرار گرفتند و در نهایت پنج گروه ترکیب متغیری با کمترین مقادیر آماره‌های

ورودی در عملکرد ماشین بردار پشتیبان برای برآورد حجم رسوب در رودخانه دویرج در ایلام استفاده کردند. در پژوهشی مشابه، Remesan و همکاران (۲۰۰۹) و Shamim و همکاران (۲۰۱۶) نیز از آزمون گاما برای انتخاب ترکیب بهینه متغیر در برآورد تابش خورشیدی روزانه و حجم روزانه مخزن استفاده کردند، نتایج نشان داد که استفاده از این ترکیبات به ترتیب با ضریب ضریب تبیین برابر ۰/۹۸، ۰/۸۸ و ۰/۹۰ برآورد دقیق از حجم رسوب، تابش خورشیدی روزانه و حجم روزانه مخزن دارد که نتایج حاصل از پژوهش یاد شده با نتایج به دست آمده از این پژوهش مطابقت دارد.

گروه آزمون گاما و الگوریتم ژنتیک نشان می‌دهد. همان‌طور که از جدول استنباط می‌شود، مدل ۱ با متغیرهای ورودی دبی لحظه‌ای، دبی متوسط روزانه، دبی متوسط روزانه دو روز قبل، بارندگی متوسط روزانه، سه روز قبل، بارندگی متوسط روزانه، بارندگی متوسط روزانه دو روز قبل و بارندگی متوسط روزانه سه روز قبل با کمترین مقدار آماره‌های گاما (۰/۰۰۰۲)، خطای استاندارد (۰/۰۰۰۳) و V_{ratio} (۰/۰۲۱۶) بهترین و ترکیب بهینه متغیرهای ورودی به مدل‌های هوشمند هستند. Kakaei Lafdani و همکاران (۲۰۱۳)، از روش آزمون گاما برای پیش پردازش متغیرهای



شکل ۲- نمودار شاخص دیویس بولدین برای تعیین تعداد بهینه خوشه

جدول ۳- نتایج حاصل از آزمون گاما و الگوریتم ژنتیک

شماره مدل	ترکیب‌های ورودی	V_{Ratio}	گاما	خطای استاندارد
۱	$Q_i, Q_{i-2}, Q_{i-3}, P_i, P_{i-2}, P_{i-3}$	۰/۰۲۱۶	۰/۰۰۰۲	۰/۰۰۰۳
۲	$Q_i, Q_{i-1}, P_i, P_{i-1}, P_{i-2}, P_{i-3}$	۰/۰۷۳۴	۰/۰۰۰۵	۰/۰۰۰۵
۳	$Q_i, Q_{i-2}, P_i, P_{i-2}, P_{i-3}$	۰/۱۰۱۲	۰/۰۰۰۷	۰/۰۰۰۶
۴	$Q_i, Q_{i-2}, P_i, P_{i-1}, P_{i-2}, P_{i-3}$	۰/۰۸۸۸	۰/۰۰۰۶	۰/۰۰۰۵
۵	$Q_i, Q_{i-1}, Q_{i-2}, P_i, P_{i-1}, P_{i-2}, P_{i-3}$	۰/۱۴۵۳	۰/۰۰۱۱	۰/۰۰۰۶

ساختار شبکه‌های عصبی و شاخص‌های ارزیابی کارایی برای مجموعه داده‌های آزمون برای هر مدل، در این جداول ارائه شده است. در این جداول، بر اساس تحلیل آماری انجام شده در نرم‌افزار SPSS22، تمامی ضرایب R^2 در سطح یک درصد معنی‌دار می‌باشند. همان‌طور که از جداول ۴ و ۵ استنباط می‌شود، پنج مدل اول وارد شده به مدل‌سازی شبکه عصبی با ترکیب‌های بهینه متغیر (به دست آمده از آزمون گاما و الگوریتم ژنتیک)، برآورد دقیق‌تر و صحیح‌تر از بار

نتایج مدل‌سازی: نتایج حاصل از مدل‌سازی شبکه‌های عصبی مصنوعی با دو تابع فعال‌سازی لوگ سیگموئید و تانژانت سیگموئید در مرحله آزمون به ترتیب در جداول ۴ و ۵ ارائه شده است. همان‌طور که در این جداول مشاهده می‌شود، مدل‌های یک تا پنج مربوط به ترکیب‌های بهینه متغیری حاصل از آزمون گاما و الگوریتم ژنتیک و مدل‌های شش تا ۱۰، مدل‌هایی است که به صورت دستی و آزمون و خطا وارد شبکه‌های عصبی مصنوعی شده‌اند. همچنین،

۱)، بارندگی متوسط روزانه دو روز قبل (P_{i-2}) و بارندگی متوسط روزانه سه روز قبل (P_{i-3})، با مقادیر آماره‌های ارزیابی شامل MAE برابر با ۰/۵۸۱، RMSE برابر با ۰/۴۲/۲۲۰۴، NSE برابر با ۰/۹۱ و ضریب تبیین برابر با ۰/۹۲، بهترین مدل برای برآورد بار رسوب معلق روزانه است. در بین ترکیب‌های ورودی به مدل‌های شبکه عصبی با تابع فعال‌سازی تانژانت سیگموئید، مدل با ترکیب بهینه متغیرهای ورودی دبی لحظه‌ای (Q)، دبی متوسط روزانه (Q_i)، دبی متوسط روزانه دو روز قبل (Q_{i-2})، دبی متوسط روزانه سه روز قبل (Q_{i-3})، بارندگی متوسط روزانه (P_i)، بارندگی متوسط روزانه دو روز قبل (P_{i-2}) و بارندگی متوسط روزانه سه روز قبل (P_{i-3}) بهترین مدل برای برآورد بار رسوب معلق روزانه شد.

رسوب معلق روزانه را در مقابل مدل‌هایی دارد که به صورت دستی مورد استفاده قرار گرفته‌اند. مقادیر کمتر MAE، RMSE، E_{rel} و GSD و همچنین، مقادیر بیشتر NSE و ضریب تبیین در این ترکیبات نشان‌دهنده برتری مدل‌ها با ترکیب‌های بهینه متغیر می‌باشند. همچنین، در این جداول مشاهده شد، مدل‌هایی که در آن‌ها از بارندگی به همراه دبی استفاده شده، می‌تواند با دقت و صحت بالاتری بار رسوب معلق روزانه را برآورد کنند. در بین ترکیب‌های ورودی به مدل‌های شبکه عصبی با تابع فعال‌سازی لوگ سیگموئید، مدل با ترکیب بهینه متغیرهای ورودی دبی لحظه‌ای (Q)، دبی متوسط روزانه (Q_i)، دبی متوسط روزانه یک روز قبل (Q_{i-1})، بارندگی متوسط روزانه (P_i)، بارندگی متوسط روزانه یک روز قبل (P_{i-1})

جدول ۴- نتایج مدل‌های شبکه عصبی مصنوعی با تابع فعال‌سازی لوگ سیگموئید در برآورد بار رسوب معلق

شماره مدل	ترکیب‌های ورودی	ساختار شبکه	MAE	RMSE	E_{rel}	GSD	NSE	R^2
۱	$Q, Q_i, Q_{i-2}, Q_{i-3}, P_i, P_{i-2}, P_{i-3}$	۱:۸:۱	۱۰۲۰/۶۵	۳۰۹۳/۹۴	۲۲/۰۱	۰/۹۷	۰/۷۸	۰/۸۰
۲	$Q, Q_i, Q_{i-1}, P_i, P_{i-1}, P_{i-2}, P_{i-3}$	۱:۱۱:۱	۶۰۵/۸۱	۲۲۰۴/۴۲	۱۷/۴۶	۱/۳۲	۰/۹۱	۰/۹۲
۳	$Q, Q_i, Q_{i-2}, P_i, P_{i-2}, P_{i-3}$	۱:۱۱:۱	۹۸۴/۳۲	۲۵۹۶/۲۶	۱۹/۶۱	۱/۲۱	۰/۸۵	۰/۸۶
۴	$Q, Q_i, Q_{i-2}, P_i, P_{i-1}, P_{i-2}, P_{i-3}$	۱:۹:۱	۹۷۶/۰۵	۲۶۸۴/۸۷	۲۰/۶۱	۱/۳۰	۰/۸۴	۰/۸۶
۵	$Q_i, Q_{i-1}, Q_{i-2}, P_i, P_{i-1}, P_{i-2}, P_{i-3}$	۱:۱۱:۱	۱۱۴۶/۶۴	۳۴۱۱/۴۲	۲۵/۰۸	۱/۴۲	۰/۷۳	۰/۷۶
۶	Q, Q_i, Q_{i-1}	۱:۱۱:۱	۱۵۷۲/۰۲	۵۰۶۴/۹۳	۳۶/۷۱	۲/۴۹	۰/۴۱	۰/۶۱
۷	Q, Q_i, Q_{i-1}, Q_{i-2}	۱:۱۲:۱	۱۳۸۴/۱۹	۴۷۷۸/۹۵	۳۲/۸۰	۱/۹۲	۰/۴۸	۰/۶۲
۸	$Q, Q_i, Q_{i-1}, Q_{i-2}, Q_{i-3}$	۱:۱۲:۱	۱۳۲۳/۱۵	۴۲۶۵/۱۳	۲۷/۰۶	۲/۴۲	۰/۵۹	۰/۶۷
۹	$Q, Q_i, Q_{i-1}, Q_{i-2}, Q_{i-3}, P_i$	۱:۹:۱	۱۳۵۳/۳۱	۴۳۵۲/۳۴	۳۰/۳۷	۱/۸۰	۰/۶۰	۰/۷۲
۱۰	$Q, Q_i, Q_{i-1}, Q_{i-2}, Q_{i-3}, P_i, P_{i-1}$	۱:۱۱:۱	۱۵۴۰/۶۳	۴۸۱۳/۸۶	۳۱/۹۶	۱/۹۹	۰/۶۰	۰/۷۲

جدول ۵- نتایج مدل‌های شبکه عصبی مصنوعی با تابع فعال‌سازی تانژانت سیگموئید در برآورد بار رسوب معلق

شماره مدل	ترکیب‌های ورودی	ساختار شبکه	MAE	RMSE	E_{rel}	GSD	NSE	R^2
۱	$Q, Q_i, Q_{i-2}, Q_{i-3}, P_i, P_{i-2}, P_{i-3}$	۱:۱۱:۱	۵۰۰/۰۵	۱۹۹۵/۳۳	۷/۱۶	۱/۱۶	۰/۹۶	۰/۹۶
۲	$Q, Q_i, Q_{i-1}, P_i, P_{i-1}, P_{i-2}, P_{i-3}$	۱:۱۰:۱	۹۸۴/۴۱	۲۷۳۰/۷۳	۲۳/۸۱	۱/۴۲	۰/۸۳	۰/۸۸
۳	$Q, Q_i, Q_{i-2}, P_i, P_{i-2}, P_{i-3}$	۱:۱۱:۱	۹۵۷/۵۶	۲۴۹۹/۵۰	۱۴/۹۰	۱/۲۷	۰/۸۶	۰/۸۸
۴	$Q, Q_i, Q_{i-2}, P_i, P_{i-1}, P_{i-2}, P_{i-3}$	۱:۱۲:۱	۹۷۴/۸۳	۲۶۸۹/۳۶	۱۹/۶۰	۱/۲۱	۰/۸۴	۰/۸۹
۵	$Q_i, Q_{i-1}, Q_{i-2}, P_i, P_{i-1}, P_{i-2}, P_{i-3}$	۱:۱۱:۱	۸۱۰/۵۱	۲۹۱۷/۹۰	۲۳/۷۸	۱/۵۶	۰/۷۵	۰/۸۸
۶	Q, Q_i, Q_{i-1}	۱:۱۲:۱	۱۵۴۵/۸۰	۵۱۳۱/۳۶	۳۷/۹۱	۲/۰۱	۰/۴۰	۰/۶۷
۷	Q, Q_i, Q_{i-1}, Q_{i-2}	۱:۱۲:۱	۱۴۹۰/۰۵	۴۱۶۶/۱۱	۲۹/۹۸	۱/۹۶	۰/۶۴	۰/۶۹
۸	$Q, Q_i, Q_{i-1}, Q_{i-2}, Q_{i-3}$	۱:۱۴:۱	۱۴۹۹/۴۲	۴۹۹۷/۷۸	۳۵/۳۰	۱/۹۳	۰/۴۳	۰/۴۴
۹	$Q, Q_i, Q_{i-1}, Q_{i-2}, Q_{i-3}, P_i$	۱:۱۲:۱	۱۱۸۳/۳۲	۳۷۱۳/۹۴	۲۱/۴۷	۱/۸۷	۰/۶۹	۰/۷۲
۱۰	$Q, Q_i, Q_{i-1}, Q_{i-2}, Q_{i-3}, P_i, P_{i-1}$	۱:۱۱:۱	۱۳۸۹/۹۴	۴۱۱۰/۱۱	۲۲/۶۱	۱/۸۷	۰/۶۵	۰/۷۰

نزدیک بودن مقدار شیب خط این مدل به عدد یک، نشان‌دهنده این است که مقادیر مشاهداتی و برآورد شده بار رسوب معلق در تطابق زیاد با یکدیگر است و مدل توانسته است، برآورد دقیق از بار رسوب معلق روزانه را داشته باشد.

این مسئله بیانگر انتخاب مناسب متغیرهای ورودی با استفاده از روش الگوریتم ژنتیک و آزمون گاما برای برآورد بار رسوب معلق است. همچنین، در شکل ۳، مدل‌های ۹ و ۱۰ در مقایسه با مدل‌های ۶ تا ۸ دارای ضریب تبیین و شیب خط بالاتر است. با توجه به ترکیب متغیرهای ورودی در این مدل‌ها (جدول ۴) مشاهده شد که در مدل‌های ۹ و ۱۰، اضافه کردن متغیر بارندگی به دبی در برآورد بار رسوب معلق، دقت برآورد را افزایش داده است. این مسئله در مدل‌های شش تا ۱۰ در شکل ۵ نیز مشهود است. بنابراین، نتیجه گرفته می‌شود که متغیر بارندگی دارای نقش مؤثر در برآورد صحیح‌تر بار رسوب معلق و رسیدن به مدل کارآمدتر است. شکل‌های ۴ و ۶ به ترتیب، نمودار روند بهترین مدل حاصل از برآورد بار رسوب معلق روزانه به وسیله مدل شبکه عصبی مصنوعی با توابع فعال‌سازی لوگ سیگموئید و تانژانت سیگموئید در مقابل مقادیر مشاهداتی را نشان می‌دهد. نتایج روند مقادیر مشاهده‌ای و برآورد شده در این نمودارها نشان می‌دهد که استفاده از خوشه‌بندی داده‌ها و ترکیب بهینه متغیرها توانسته است تا بار رسوب معلق روزانه را در مقادیر کم و زیاد به خوبی برآورد کند و مقادیر مشاهداتی و برآورد شده در تطابق زیاد با هم هستند.

نتیجه‌گیری


به‌طور کلی، نتایج این پژوهش نشان داد که استفاده از بارندگی که نقش مهمی در فرسایش و رسوب حوضه دارد، به همراه دبی می‌تواند برآورد دقیق و صحیح‌تری از بار رسوب معلق روزانه را انجام دهد. همچنین، تعداد نه متغیر ورودی (دبی لحظه‌ای، متوسط دبی روزانه، متوسط دبی روزانه یک روز قبل، متوسط دبی روزانه دو روز قبل، متوسط بارش سه روز قبل، متوسط بارش روزانه، متوسط بارش روزانه یک روز قبل، متوسط بارش روزانه سه روز قبل) در این مدل مورد

این مدل با مقادیر آماره‌ای MAE برابر با ۰/۰۵، RMSE برابر با ۱۹۹۵/۳۳، NSE برابر با ۰/۹۶ و ضریب تبیین برابر با ۰/۹۶ توانست بهترین برآورد بار رسوب معلق روزانه را در بین تمامی مدل‌های شبکه عصبی مصنوعی، در هر دو گروه توابع فعال‌سازی لوگ سیگموئید و تانژانت سیگموئید داشته باشد. همچنین، این مدل، بهترین و ترکیب بهینه متغیر حاصل از آزمون گاما و الگوریتم ژنتیک با کمترین مقدار آماره‌های گاما (۰/۰۰۰۲)، خطای استاندارد (۰/۰۰۰۳) و V_{ratio} (۰/۰۲۱۶) است. Shiri و Kisi (۲۰۱۲) و در پژوهش مشابه Kisi و Ozkan (۲۰۱۷)، برای مدل‌سازی رسوب معلق در رودخانه ال در کالیفرنیا و Zounemat-Kermani و همکاران (۲۰۱۶) در ایستگاه‌های هیدرومتری ایالت‌های آرکانساز، دلاوار و اوهایو در آمریکا به منظور برآورد غلظت رسوب معلق روزانه از متغیرهای بارش روزانه و دبی جریان روزانه برای مدل‌سازی غلظت رسوب معلق روزانه استفاده کردند. نتایج نشان داد که تاثیر بارش به همراه دبی در افزایش دقت برآورد بیشتر از زمانی است که دبی به تنهایی استفاده می‌شود که نتایج این محققان با نتایج به دست آمده در این پژوهش، در رابطه با اثر بارندگی به همراه دبی، در افزایش دقت و صحت برآورد بار رسوب معلق مطابقت دارد.


شکل‌های ۳ و ۵ به ترتیب، نمودار نقطه‌ای نتایج حاصل از برآورد بار رسوب معلق روزانه با استفاده از مدل‌های شبکه عصبی مصنوعی با توابع فعال‌سازی لوگ سیگموئید و تانژانت سیگموئید در مقابل مقادیر مشاهداتی برای مجموعه داده‌های آزمون را نشان می‌دهد. با توجه به معادلات رگرسیونی برای هر نمودار در شکل‌های ۳ و ۵، مشاهده شد که مدل‌های ۱ تا ۵ در هر دو گروه مدل‌های شبکه عصبی مصنوعی با تابع فعال‌سازی لوگ سیگموئید و تانژانت سیگموئید مربوط به ترکیبات ورودی حاصل از الگوریتم ژنتیک و آزمون گاما، دارای شیب خط نزدیک به یک و ضریب تبیین بالاتر در مقایسه با مدل‌های شش تا ۱۰، ترکیبات متغیر ورودی با آزمون و خطا است. به‌عنوان مثال، در شکل ۵، معادله خط مدل ۱ به صورت $(y=0.9851x-229.76)$ است. شیب خط این معادله برابر با ۰/۹۸۵۱ و ضریب تبیین آن برابر با ۰/۹۶ است.

مدل‌سازی شبکه عصبی بسیار سخت و خسته‌کننده است.

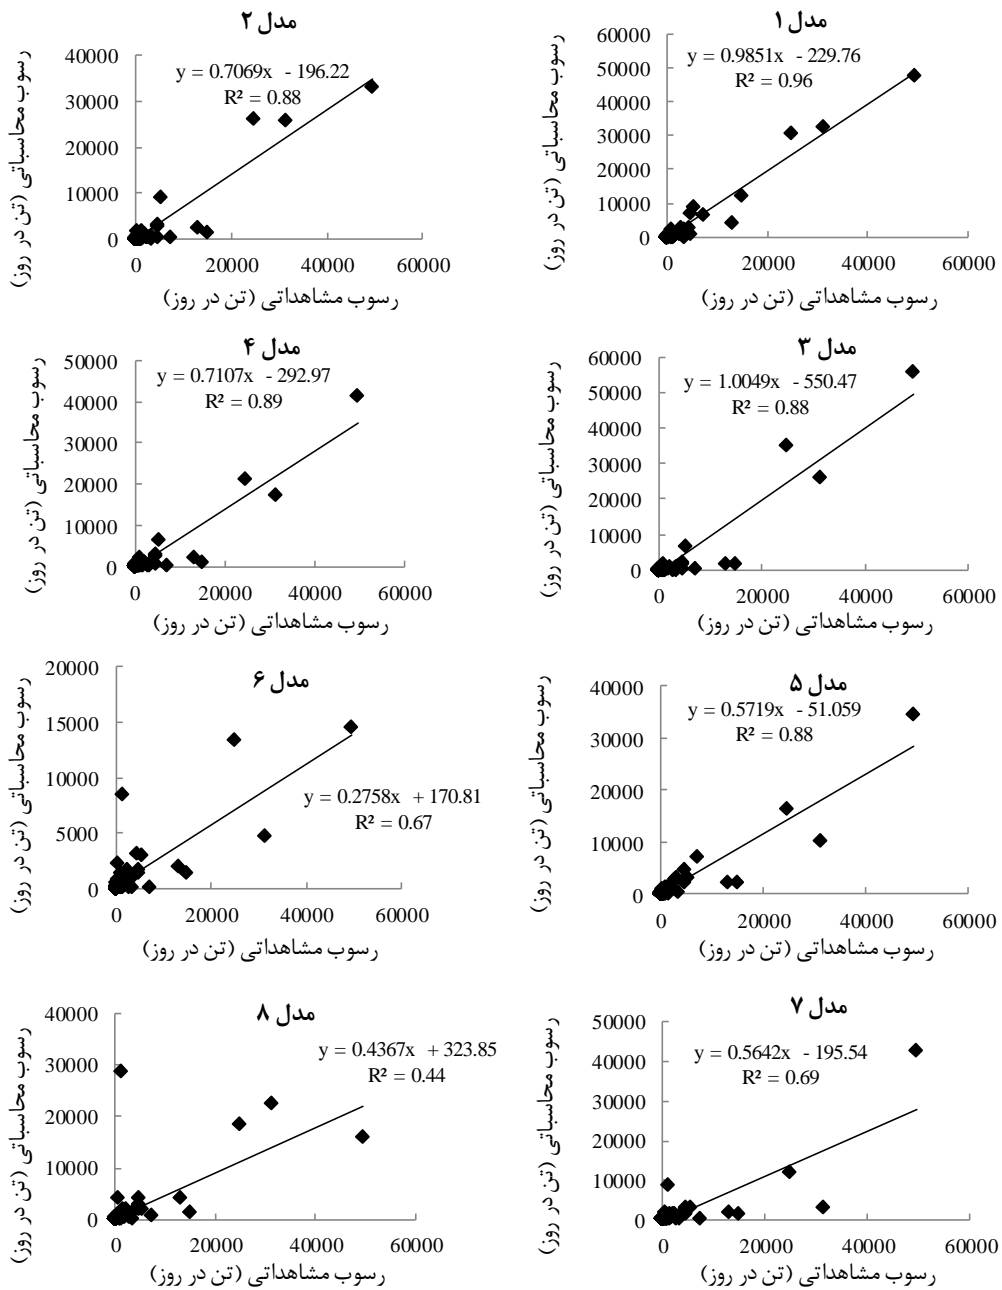
استفاده قرار گرفت و با توجه به این‌که استفاده از تمامی ترکیب متغیرهای ورودی ممکن برای



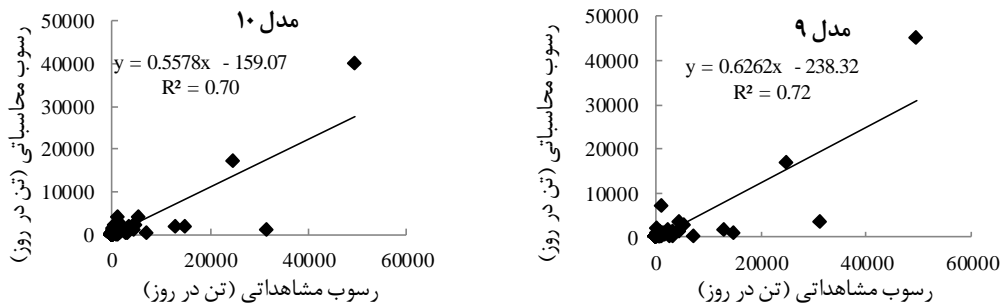
شکل ۳- نمودار نقطه‌ای نتایج حاصل از برآورد بار رسوب معلق روزانه با مدل شبکه عصبی مصنوعی با تابع فعال‌سازی لوگ سیگموئید در مقابل مقادیر مشاهداتی برای مجموعه داده‌های آزمون



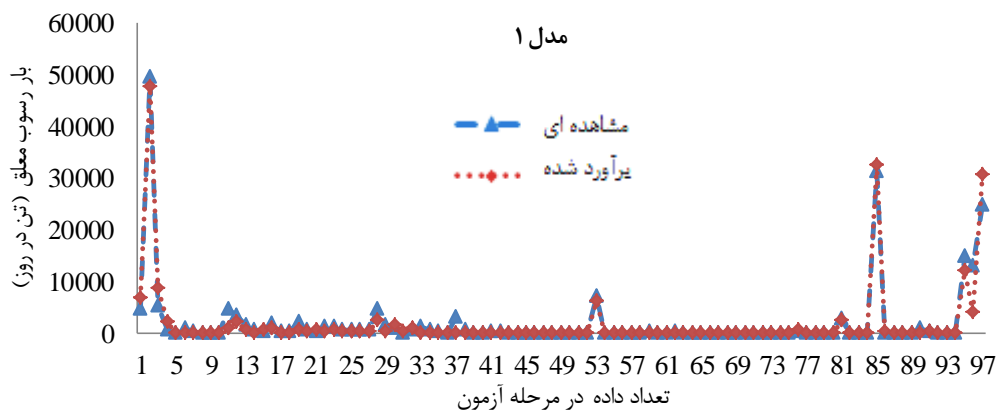
شکل ۴- نمودار روند مدل مناسب حاصل از برآورد بار رسوب معلق روزانه با مدل شبکه عصبی مصنوعی با توابع فعال سازی لوگ سیگموئید در مقابل مقادیر مشاهداتی



شکل ۵- نمودار نقطه‌ای نتایج حاصل از برآورد بار رسوب معلق روزانه با مدل شبکه عصبی مصنوعی با تابع فعال سازی تانژانت سیگموئید در مقابل مقادیر مشاهداتی برای مجموعه داده‌های آزمون



ادامه شکل ۵- نمودار نقطه‌ای نتایج حاصل از برآورد بار رسوب معلق روزانه با مدل شبکه عصبی مصنوعی با تابع فعال‌سازی تانژانت - سیگموئید در مقابل مقادیر مشاهداتی برای مجموعه داده‌های آزمون



شکل ۶- نمودار روند مدل مناسب حاصل از برآورد بار رسوب معلق روزانه با مدل شبکه عصبی مصنوعی با توابع فعال‌سازی تانژانت سیگموئید در مقابل مقادیر مشاهداتی

همچنین، در این پژوهش از شبکه‌های عصبی مصنوعی با دو تابع فعال‌سازی لوگ سیگموئید و تانژانت سیگموئید استفاده شد و در نهایت بهترین مدل در برآورد بار رسوب معلق مربوط به مدل شبکه عصبی مصنوعی با تابع فعال‌سازی تانژانت سیگموئید (بهینه‌ترین ترکیب متغیر ورودی حاصل از آزمون گاما و الگوریتم ژنتیک)، با ترکیب متغیرهای ورودی دبی لحظه‌ای (Q)، دبی متوسط روزانه (Q_i)، دبی متوسط روزانه دو روز قبل (Q_{i-2})، دبی متوسط روزانه سه روز قبل (Q_{i-3})، بارندگی متوسط روزانه (P_i)، بارندگی متوسط روزانه دو روز قبل (P_{i-2}) و بارندگی متوسط روزانه سه روز قبل (P_{i-3}) به دست آمد. پیشنهاد می‌شود که از ساختار مدل شبکه عصبی به دست آمده در این پژوهش به عنوان الگویی در برآورد تبخیر و تعرق، نیترات و سولفات موجود در آب رودخانه و سایر متغیرهای دیرپافت در حوزه‌های آبخیز استفاده شود.

از روش آزمون گاما و الگوریتم ژنتیک برای تعیین بهترین ترکیب‌های متغیر ورودی به مدل استفاده شد. نتایج نشان داد که بهترین ترکیب متغیر ورودی حاصل از آزمون گاما و الگوریتم ژنتیک، بهترین مدل شبکه عصبی مصنوعی در برآورد دقیق بار رسوب معلق نیز بود. بنابراین، استفاده از روش آزمون گاما و الگوریتم ژنتیک با انتخاب ترکیب متغیرهای تاثیرگذار و مهم در برآورد بار رسوب معلق، کارایی مدل‌سازی را افزایش و زمان مدل‌سازی را کاهش می‌دهد. استفاده از روش شبکه عصبی SOM در این پژوهش برای خوشه‌بندی داده‌ها، باعث ایجاد همگن شدن داده‌ها در سه مجموعه داده‌های آموزش، اعتبارسنجی و آزمون برای ورود به شبکه‌های عصبی مصنوعی شد و این کار موجب شد تا قدرت تعمیم‌دهی مدل افزایش یافته و دقت برآورد بار رسوب معلق افزایش یابد.

منابع مورد استفاده

1. Abbaspour, B. and A.H. Haghiabi. 2015. Comparing the estimation of suspended load using two methods of sediments rating curve and artificial neural network, a case study: Cham Anjir Station, Lorestan Province. *Journal of Environmental Treatment Techniques*, 3(4): 215-222.
2. Azamathulla, H.M., Y.C. Cuan, A.A. Ghani and C.K. Chang. 2013. Suspended sediment load prediction of river systems: GEP approach. *Arabian Journal of Geosciences*, 6(9): 3469-3480.
3. Bolboaca, S.D. and L. Jantschi. 2006. Pearson versus Spearman, Kendall's tau correlation analysis on structure-activity relationships of biologic active compounds. *Leonardo Journal of Sciences*, 5(9): 179-200.
4. Boukhrissa Z.A., K. Khanchoul, Y. Le Bissonnais and M. Tourki. 2013. Prediction of sediment load by sediment rating curve and neural network (ANN) in El Kebir Catchment, Algeria. *Journal of Earth System Science*, 122(5): 1303-1312.
5. Bowden, G.J., H.R. Maier and G.C. Dandy. 2002. Optimal division of data for neural network models in water resources applications. *Water Resources Research*, 38(2): 1-12.
6. Chaudhary, V., R.S. Bhatia and A. Ahlawat. 2014. The selforganizing map learning algorithm with inactive and relative winning frequency of active neurons. *Journal HKIE Transactions*, 21(1): 62-67.
7. Chen, X.Y. and K.W. Chau. 2016. A hybrid double feed forward neural network for suspended sediment load estimation. *Water Resources Management*, 30: 2179-2194.
8. Durrant, P.J. 2001. WinGamma: a non-linear data analysis and modelling tool with applications to flood prediction. PhD Thesis, Department of Computer Science, Cardiff University, Wales, UK, 265 pages.
9. Evans, D. and A.J. Jones. 2002. A proof of the gamma test. *Proceedings of the Royal Society of London Series*, 458: 2759-2799.
10. Gan, G., M. Chaoqun and W. Jianhong. 2007. Density-based clustering algorithms, in data clustering: theory, algorithms and applications. *Society for Industrial and Applied Mathematics*, 20: 219-226.
11. He, Z., X. Wen, H. Liu and J. Du. 2014. A comparative study of artificial neural network, adaptive euro fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region. *Journal of Hydrology*, 509(4): 379-386.
12. Jones, A.J. 2004. New tools in non-linear modeling and prediction. *Computational Management Science*, 1: 109-149.
13. Joshi, R., K. Kumar and V. Pal Singh Adhikari. 2016. Modelling suspended sediment concentration using artificial neural networks for Gangotri glacier. *Hydrological Processes*, 30: 1354-1366.
14. Kakaei Lafdani, E., A. Moghaddam Nia and A. Ahmadi. 2013. Daily suspended sediment load prediction using artificial neural networks and support vector machines. *Journal of Hydrology*, 478(4): 25-50.
15. Kaufman, L. and P.J. Rousseeuw. 2009. *Finding groups in data: an introduction to cluster analysis*. Hoboken, New Jersey, John Wiley and Sons, 342 pages.
16. Kişi, O. 2012. Modeling discharge-suspended sediment relationship using least square support vector machine. *Journal of Hydrology*, 456(5): 110-120.
17. 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.
18. Kisi, O. and J. Shiri. 2012. River suspended sediment estimation by climatic variables implication: comparative study among soft computing techniques. *Computers and Geosciences*, 43(2): 73-82.
19. Kohonen, T. 2013. *Essentials of the self-organizing map*. *Neural Networks*, 37: 52-65.
20. Moghaddamnia, A., M. Ghafari Gousheh, J. Piri, S. Amin and D. Han. 2009. Evaporation estimation using artificial neural networks and adaptive neurofuzzy inference system techniques. *Advance Water Resources*, 32: 88-97.
21. Remesan, R., M.A. Shamim, D. Han and J. Mathew. 2009. Runoff prediction using an integrated hybrid modelling scheme. *Journal of Hydrology*, 372: 48-60.
22. Shamim, M.A., M. Hassan, S. Ahmad and M. Zeeshan. 2016. A comparison of Artificial Neural Networks (ANN) and Local Linear Regression (LLR) techniques for predicting monthly reservoir levels. *KSCE Journal of Civil Engineering*, 20(2): 971-977.
23. Shieh, S.L. and I. Liao. 2012. A new approach for data clustering and visualization using self-organizing maps. *Expert Systems with Applications*, 39: 11924-11933.
24. Tayfur, G. 2012. *Soft computing in water resources engineering, artificial neural networks, fuzzy logic and genetic algorithms*. WIT Press, Southampton, England, UK, 267 pages.
25. Tokar, A. and P. Johnson. 1999. Rainfall-runoff modeling using artificial neural networks. *Journal of Hydrologic Engineering*, 4(3): 232-239.

26. 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.
27. Ulke, A., G. Tayfur and S. Ozku. 2009. Predicting suspended sediment loads and missing data for Gediz River, Turkey. *Journal of Hydrologic Engineering*, 14(9): 954-965.
28. White, S.M. 2004. Sediment supply and transfer. In: *Neural Networks for Hydrological Modeling*. Published June 15th 2012 by Taylor and Francis, 316 pages.
29. Wolfs, V. and P. Willems. 2014. Development of discharge-stage curves affected by hysteresis using time varying models, model trees and neural networks. *Environmental Modeling and Software*, 55(4): 107-119.
30. Zhu, Y.M., X.X. Lua and Y. Zhoub. 2007. Suspended sediment flux modeling with artificial neural network: an example of the Longchuanjiang River in the Upper Yangtze Catchment, China. *Geomorphology*, 84(2): 111-125.
31. Zounemat-Kermani, M., O. Kişi, J. Adamowski and A. Ramezani-Charmahineh. 2016. Evaluation of data driven models for river suspended sediment concentration modeling. *Journal of Hydrology*, 16(2): 1-40.