

پیش‌بینی بار معلق رودخانه‌ای با استفاده از شبکه عصبی مصنوعی و الگوریتم ژنتیک مرتب‌سازی غیرغالب

میکائیل حسینی^۱، محمد همتی^{۲*}، مهدی یاسی^۳

(تاریخ دریافت: ۱۴۰۰/۰۴/۰۵ تاریخ پذیرش: ۱۴۰۰/۰۷/۱۵)

چکیده

اطلاع از میزان فرسایش خاک و تولید رسوب، ویژگی‌های هواشناسی، ویژگی‌های هیدرولوژیکی رودخانه همانند دبی و همچنین عوامل انسانی، غالباً بسیار پیچیده، غیرقطعی و غیرخطی می‌باشند. لذا بکارگیری الگوریتم‌های هوش ماشینی (نظیر الگوریتم‌های یادگیری ماشین) گزینه مناسبی در شبیه‌سازی و پیش‌بینی متغیرهای کیفی آب رودخانه نظیر بار معلق تلقی می‌شود. هدف پژوهش حاضر، ارائه یک روش پیشنهادی بر مبنای شبکه عصبی مصنوعی پرسپترون چندلایه و الگوریتم ژنتیک مرتب‌سازی غیرغالب برای پیش‌بینی بار معلق رودخانه‌ای می‌باشد. در روش پیشنهادی به منظور آموزش شبکه عصبی مصنوعی پرسپترون چندلایه از روش پس‌انتشار خطا و تعیین وزن بهینه برای نرون‌ها از الگوریتم ژنتیک مرتب‌سازی غیرغالب استفاده شد. در این مطالعه از بار معلق ایستگاه تیل‌آباد واقع در رودخانه گرگان‌رود طی سال‌های ۹۴-۱۳۶۱ به عنوان مطالعه موردی استفاده شد. نتایج نشان داد که روش پیشنهادی در مقایسه با شبکه عصبی مصنوعی چندلایه دارای ضریب همبستگی بالاتری است و مقدار R^2 به ترتیب برابر با ۰/۶۷۲۸ و ۰/۴۳۷۲ بدست آمد. مقدار RMSE در روش پیشنهادی و شبکه عصبی مصنوعی چندلایه بر مبنای الگوریتم پس‌انتشار به ترتیب برابر با ۴/۷۲۲۵ و ۸/۰۵۴۸ بدست آمده است. مقدار NSE نیز در روش پیشنهادی و شبکه عصبی مصنوعی چندلایه بر مبنای الگوریتم پس‌انتشار به ترتیب برابر با ۰/۴۳۲۱ و ۰/۲۹۴۱ بدست آمده است. لذا در روش پیشنهادی، الگوریتم ژنتیک مرتب‌سازی غیرغالب باعث شده که شبکه عصبی مصنوعی چندلایه بهبود خوبی داشته باشد. نتایج حاصله نشان داد که روش پیشنهادی دارای دقت خوبی در پیش‌بینی بار معلق بوده است. روش پیشنهادی با الگوریتم آموزشی پس‌انتشار دارای عملکرد بهتری در مقایسه با الگوریتم آموزشی گرادیان نزولی و بیزین بوده است.

واژه‌های کلیدی: منحنی سنج رسوب، الگوریتم ژنتیک مرتب‌سازی غیرغالب، گرگان‌رود، بار معلق

حسینی م، همتی م، یاسی م. ۱۴۰۱. پیش‌بینی بار معلق رودخانه‌ای با استفاده از شبکه عصبی مصنوعی و الگوریتم ژنتیک مرتب‌سازی غیرغالب. تحقیقات کاربردی خاک. جلد ۱۰، شماره ۴. صفحه: ۴۵-۶۰.

۱- دانشجوی دکتری آبیاری و زهکشی، گروه مهندسی آب، دانشکده کشاورزی دانشگاه ارومیه

۲- دانشیار گروه مهندسی آب، دانشکده کشاورزی دانشگاه ارومیه

۳- دانشیار گروه مهندسی آبیاری و آبادانی، دانشکده مهندسی و فناوری کشاورزی، دانشگاه تهران، کرج، ایران

* پست الکترونیک: m.hemmati@urmia.ac.ir

مقدمه

یکی از بزرگ‌ترین و پیچیده‌ترین مسائل در مهندسی رودخانه‌ها، معضلاتی همانند توزیع غلظت رسوب، فرسایش و میزان رسوب در رودخانه‌ها می‌باشد (Panahi & Emami, 2021). انتقال رسوب، مضرات خاصی بر روی فاکتورهای کیفی آب، کنش کف بستر و کناره‌های رودخانه‌ها و ریخت شناسی رودخانه‌ها دارد. همچنین بار معلق، صدمات جبران‌ناپذیری به طرح‌ها و پروژه‌های عمرانی آب وارد می‌کند و حتی طراحی سازه‌های هیدرولیکی را تحت تأثیر قرار می‌دهد (Banadkooki et al., 2020). انتقال رسوب، مشکلاتی همانند ایجاد جزایر رسوبی در مسیر رودخانه و در نتیجه کاهش ظرفیت انتقال جریان‌های سیلابی، خوردگی تأسیسات سازه‌های رودخانه‌ای، کاهش عمر مفید سدها و ظرفیت ذخیره مخازن، وارد شدن خسارات به ابنیه آبی و مزارع، رسوب‌گذاری در کف کانال را ایجاد می‌کند. از طرفی، رسوب انتقال یافته توسط یک رودخانه به مخازن، ظرفیت ذخیره آن‌ها را کاهش داده و منجر به کاهش کمی و کیفی آب قابل دسترس برای نیروگاه‌های برق، آبیاری و کاربردهای صنعتی و خانگی می‌شود (Gupta et al., 2021).

سرعت تسریع فرسایش خاک به یک تهدید جهانی برای عملکرد هیدرولوژیکی و اکوسیستم تبدیل شده است. بیش‌تر این خاک فرسایش یافته از طریق سیستم‌های رودخانه‌ای به مخازن سدها منتقل می‌شود و بنابراین رسوب‌گذاری به یک تهدید اساسی برای طول عمر و کارکرد مخازن سدها تبدیل شده است. به دلیل فعالیت‌های انسانی، انتقال رسوب رودخانه از طریق فرسایش خاک در مقیاس جهانی سالانه $2/3 \pm 0/6$ میلیارد میلیارد تن در سال افزایش می‌یابد (Zhao et al., 2020). براساس تحقیقات انجام شده، به دلیل ته‌نشین شدن رسوبات، کاهش سالیانه سدهای جهان در ذخیره‌سازی آب حدود $0/5$ تا یک درصد بوده که در اکثر سدهای جهان این مقدار بیش‌تر از چهار تا پنج درصد می‌باشد و در نتیجه اغلب سدها، قسمت اصلی توانایی ذخیره آب خود را در طول ۲۵ تا ۳۰ سال از دست می‌دهند (Rahmani et al., 2018). جریان رسوب سنگین در بسیاری از نقاط جهان به یک مسئله رایج تبدیل شده است، که باعث کاهش ظرفیت حمل‌ونقل

شده و خطر سیل را بسیار تشدید می‌کند. در کشور ایران آثار و نشانه‌های فرسایش و رسوب در اکثر نقاط مشاهده می‌شود و طبق برخی برآوردها، سالانه بیش از یک میلیارد تن از خاک ارزشمند زمینی به دریاها، دریاچه‌ها و یا داخل مخازن سدها روانه می‌شود (Rajaei et al., 2010). بررسی‌های انجام شده از مخازن سدها بیانگر این است که طول عمر مفید برخی از سدها به دلیل حجم رسوب به کمتر از نصف میزان پیش‌بینی اولیه کاهش یافته است (Nikkami & Shadfar, 2021). برآورد دقیق پیش‌بینی بارمعلق یک موضوع مهم در تحقیقات هیدرولوژی و هیدرولیک است. رسوب باعث کاهش ظرفیت کانال و ذخیره سدها می‌شود. همچنین رسوبات بر کیفیت آب تأثیر می‌گذارد. بنابراین، پیش‌بینی بارمعلق یک کار کلیدی است. تغییرات زمانی و مکانی پیش‌بینی بارمعلق به پارامترهای مختلف آب و هوایی مانند بارندگی و دما بستگی دارد. آلودگی رسوبی مسئله مهمی در دشت‌های سیلاب است. در نتیجه، مدل‌های مختلفی برای پیش‌بینی بار معلق وجود دارد. اگرچه از مدل‌های تجربی برای پیش‌بینی بارمعلق استفاده می‌شود، اما از توانایی بالایی در پیش‌بینی بارمعلق برخوردار نیستند.

پژوهش‌های متعددی با الگوریتم‌هایی از قبیل شبکه‌های عصبی مصنوعی، سیستم فازی و الگوریتم‌های فرا ابتکاری (Gharehchopogh & Gholizadeh, 2019) با هدف پیش‌بینی بارمعلق رودخانه‌ای انجام شده است. در این راستا، برزگری و دستورانی (Barzegari & Dastorani, 2016) مدل‌های سری زمانی از قبیل مارکوف، ARIMA و شبکه‌های عصبی مصنوعی را بر مبنای داده‌های روزانه ایستگاه قزاقلی واقع روی رودخانه گرگان‌رود برای پیش‌بینی رسوب معلق پیشنهاد داده‌اند. دستورانی و همکاران (Dastorani et al., 2012) از شبکه‌های عصبی مصنوعی برای پیش‌بینی رسوب معلق در ایستگاه هیدرومتری حیدرآباد بر روی رودخانه جامیشان استفاده کرده‌اند. مقدار R^2 که از شبکه عصبی مصنوعی چندلایه بدست آمده برابر با حدود $0/92$ و R^2 که از منحنی سنج رسوب بدست آمده برابر با حدود $0/83$ است. یوسفی و پورشرعیاتی (Yosefi & Poorshariaty, 2015) از الگوریتم شبکه عصبی پیشخور پس انتشار خطا برای برآورد رسوب، از داده‌های دبی،

بارش و رسوب رودخانه‌های کاکارضا، دهنو، چم انجیر استان لرستان به صورت ماهانه استفاده کرده‌اند. در مطالعه آن‌ها، شبکه Fitting در مقایسه با شبکه‌های عصبی مصنوعی دیگر دارای تشخیص بهتری بوده است. طباطبایی و همکاران (Tabatabaei et al., 2014) از روش شبکه عصبی پرسپترون چند لایه و داده‌های آب و هواشناسی (دبی و غلظت رسوب معلق روزانه جریان، متوسط بارش و دمای روزانه) حوزه آبخیز سد کرج در یک دوره زمانی ۳۰ ساله (۱۳۶۰ تا ۱۳۹۰) به منظور برآورد غلظت رسوب معلق روزانه ایستگاه هیدرومتری سیرا (واقع در رودخانه کرج) استفاده کرده‌اند. نتایج آن‌ها نشان داد که بکارگیری متغیرهای بارش و دمای روزانه، به همراه دبی جریان و تفکیک زمانی داده‌ها، نقش مهمی در افزایش دقت برآورد رسوب رودخانه داشته است. طباطبایی و همکاران (Tabatabaei et al., 2020) گزارش دادند که آموزش شبکه عصبی مصنوعی چند لایه با الگوریتم بهینه‌سازی ازدحام ذرات باعث کاهش خطای برآورد رسوب بوده است و دقت بالاتری در مقایسه با شبکه عصبی مصنوعی چند لایه با روش پس انتشار خطا داشته است.

خزایی موغانی و همکاران (Khazaei Moughani et al., 2013) به بررسی تغییرات مکانی و فصلی بار رسوبی در ایستگاه هیدرومتری تمر، حاجی-قوشان، قزاقلی، گنبد، سد وشمگیر، آق‌قلا و بصیرآباد واقع در شاخه اصلی رودخانه گرگان‌رود در استان گلستان پرداخته‌اند. با بررسی تغییرات فصلی مشخص شد، فصل بهار با حداقل ۵۰ درصد تا حداکثر ۷۰ درصد دارای بالاترین میزان حمل رسوب معلق در ایستگاه‌ها می‌باشد. کیا و همکاران (Kia et al., 2015) به منظور دستیابی به تخمینی نزدیک به واقعیت از میزان حمل رسوبات ایستگاه قرآن تالار بابل رود، از سیستم استنتاج فازی-عصبی تطبیقی استفاده کردند. نتایج نشان داد که مقدار مجموع مربعات خطا در سیستم استنتاج فازی و منحنی سنجه به ترتیب برابر با ۰/۰۸ و ۰/۱۶ بوده است. نتایج روانی و همکاران (Varvani et al., 2016) نشان داد متوسط شاخص صحت روش‌های نرو فازی و رگرسیون درختی در ایستگاه‌های منتخب به ترتیب در حدود ۱۵۱ و ۵۳۶ درصد بوده که در مقایسه با منحنی‌های سنجه رسوب کارایی پایینی را نشان داده است. یوسفی و برزگری

(Yousefi & Barzegari, 2014) گزارش دادند که در بیشتر ایستگاه‌های رودخانه‌های استان لرستان، منحنی سنجه کارایی بهتری از مدل درخت تصمیم‌گیری در برآورد بار معلق داشت. نتایج مطالعه اسدی و همکاران (Asadi et al., 2017) که به بررسی اثر مقیاس زمانی (روزانه، ماهانه و سالانه) در پیش‌بینی بار معلق پرداخته‌اند، نشان داد که پیش‌بینی داده‌های سالانه نسبت به ماهانه و روزانه از دقت بیشتری برخوردار بوده است. نتایج حاصله نشان داد که برای داده‌های روزانه، مقدار ریشه میانگین مربعات خطا در مدل k نزدیک‌ترین همسایه برابر با ۵/۲۸ و برای داده‌های ماهانه مقدار ریشه میانگین مربعات خطا در مدل فرآیند گوسی برابر با ۸/۷ بوده است. حلییان و همکاران (Halabian et al., 2017) دقت مدل درخت تصمیم‌گیر در پیش‌بینی بار معلق رودخانه میمه را تایید کردند. خیرقام و مکرم-کشتیبان (Kheirfam & Mokarram-Kashtiban, 2018) بر مبنای شبکه عصبی مصنوعی چند لایه و رگرسیون خطی چندگانه به پیش‌بینی بار معلق در منطقه جنگلی هیرکانی (در شمال ایران) با استفاده از ۱۴ پارامتر فیزیوگرافی، آب و هوایی و هیدرولوژیکی پرداختند. نتایج آن‌ها نشان داد که دقت شبکه عصبی مصنوعی چند لایه از رگرسیون خطی چندگانه بیشتر بوده است. روش برنامه‌ریزی بیان ژن توسط امامقلی‌زاده و همکاران (Imamgholizadeh et al., 2016) برای پیش‌بینی بار معلق ایستگاه‌های هیدرومتری جلوگیر و پای‌پل واقع در بالادست سد مخزنی کرخه پیشنهاد شده است. خورشیددوست و همکاران (Khorshiddoost et al., 2015)، حیات‌زاده و همکاران (Hayatzadeh & Dastorani, 2015)، رضوی‌زاده و همکاران (Razavizadeh et al., 2014)، علی‌جانپور شالمانی و همکاران (Alijanpour Shalmani et al., 2020) و خزایی‌پول و طالبی (Khazaie Poul & Talebi, 2013) از شبکه عصبی برای تخمین بار معلق استفاده کرده‌اند. کیهانی و همکاران (Keihani et al., 2021) از روش شبیه‌سازی مونت کارلو برای برآورد عدم قطعیت بار رسوبات معلق و بستر به علت عدم قطعیت در پارامترهای مدل ماشین بردار پشتیبان در حوضه سد کرج استفاده کرده‌اند. دهکردی و همکاران (Abdi Dehkordi et al., 2014) از الگوریتم خوشه‌بندی فازی در تخمین میزان

بارش و رسوب رودخانه‌های کاکارضا، دهنو، چم انجیر استان لرستان به صورت ماهانه استفاده کرده‌اند. در مطالعه آن‌ها، شبکه Fitting در مقایسه با شبکه‌های عصبی مصنوعی دیگر دارای تشخیص بهتری بوده است. طباطبایی و همکاران (Tabatabaei et al., 2014) از روش شبکه عصبی پرسپترون چند لایه و داده‌های آب و هواشناسی (دبی و غلظت رسوب معلق روزانه جریان، متوسط بارش و دمای روزانه) حوزه آبخیز سد کرج در یک دوره زمانی ۳۰ ساله (۱۳۶۰ تا ۱۳۹۰) به منظور برآورد غلظت رسوب معلق روزانه ایستگاه هیدرومتری سیرا (واقع در رودخانه کرج) استفاده کرده‌اند. نتایج آن‌ها نشان داد که بکارگیری متغیرهای بارش و دمای روزانه، به همراه دبی جریان و تفکیک زمانی داده‌ها، نقش مهمی در افزایش دقت برآورد رسوب رودخانه داشته است. طباطبایی و همکاران (Tabatabaei et al., 2020) گزارش دادند که آموزش شبکه عصبی مصنوعی چند لایه با الگوریتم بهینه‌سازی ازدحام ذرات باعث کاهش خطای برآورد رسوب بوده است و دقت بالاتری در مقایسه با شبکه عصبی مصنوعی چند لایه با روش پس انتشار خطا داشته است.

خزایی موغانی و همکاران (Khazaei Moughani et al., 2013) به بررسی تغییرات مکانی و فصلی بار رسوبی در ایستگاه هیدرومتری تمر، حاجی-قوشان، قزاقلی، گنبد، سد وشمگیر، آق‌قلا و بصیرآباد واقع در شاخه اصلی رودخانه گرگان‌رود در استان گلستان پرداخته‌اند. با بررسی تغییرات فصلی مشخص شد، فصل بهار با حداقل ۵۰ درصد تا حداکثر ۷۰ درصد دارای بالاترین میزان حمل رسوب معلق در ایستگاه‌ها می‌باشد. کیا و همکاران (Kia et al., 2015) به منظور دستیابی به تخمینی نزدیک به واقعیت از میزان حمل رسوبات ایستگاه قرآن تالار بابل رود، از سیستم استنتاج فازی-عصبی تطبیقی استفاده کردند. نتایج نشان داد که مقدار مجموع مربعات خطا در سیستم استنتاج فازی و منحنی سنجه به ترتیب برابر با ۰/۰۸ و ۰/۱۶ بوده است. نتایج روانی و همکاران (Varvani et al., 2016) نشان داد متوسط شاخص صحت روش‌های نرو فازی و رگرسیون درختی در ایستگاه‌های منتخب به ترتیب در حدود ۱۵۱ و ۵۳۶ درصد بوده که در مقایسه با منحنی‌های سنجه رسوب کارایی پایینی را نشان داده است. یوسفی و برزگری

اهداف اصلی روش پیشنهادی، افزایش دقت و ضریب همبستگی برای پیش‌بینی بار معلق می‌باشد.

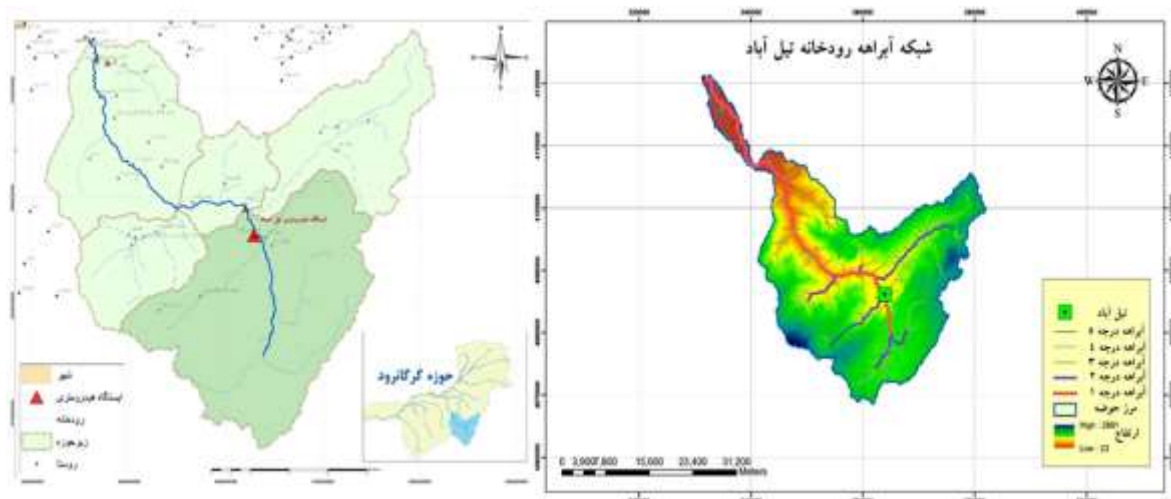
مواد و روش‌ها

منطقه مورد مطالعه

به‌منظور انجام این مطالعه از داده‌های رسوب معلق، متعلق به ایستگاه تیل‌آباد در حوزه آبخیز گرگان‌رود استفاده شد (شکل ۱). گرگان‌رود در استان گلستان واقع شده است و از ارتفاعات گلی داغ، پارک ملی گلستان، سرچشمه گرفته و پس از گذشتن از گنبد کاووس و آق‌قلا در غرب خواجه نفس به دریای خزر می‌ریزد. حوزه آبخیز گرگان‌رود، ۴۸ درصد سطح استان گلستان را با مساحتی حدود ۱۱۳۳۰ کیلومتر مربع دربر گرفته و در محدوده طول جغرافیایی $۱۰^{\circ} ۵۴'$ تا $۲۶^{\circ} ۵۶'$ و عرض جغرافیایی $۲۵^{\circ} ۳۶'$ تا $۱۵^{\circ} ۳۸'$ واقع شده است. حداکثر ارتفاع حوضه ۳۱۱۳ متر و حداقل ارتفاع آن ۱۲- متر از سطح دریا می‌باشد. طول رودخانه اصلی که در دشت گنبد و گرگان جریان دارد ۳۳۳ کیلومتر می‌باشد. این حوزه از نظر اقلیمی بسیار متنوع بوده و طبق طبقه‌بندی دومارتن دارای اقلیم‌های مرطوب، نیمه‌مرطوب، مدیترانه‌ای، نیمه خشک و خشک می‌باشد. رودخانه گرگان‌رود به دلیل موقعیت جغرافیایی، اقلیمی و زمین‌شناسی از رتبه‌ی خاصی در مطالعات رسوب معلق بهره‌مند است. رودخانه‌ی گرگان‌رود به دلیل سرعت جریان و دبی زیاد همراه با طغیان آب در ماه‌های پرآب سال که منجر به گل‌آلودگی شدید آن می‌شود، دارای تراکم بنتیک کمتری نسبت به سایر رودخانه‌ها می‌باشد. یکی از عوامل کاهش غنای گونه‌ای و تراکم و فراوانی کفزی‌های بزرگ در این رودخانه را می‌توان به عدم وجود پوشش گیاهی مناسب در طول رودخانه نسبت داد.

رسوبات بار معلق بر روی مجموعه دبی جریان و دبی رسوب ایستگاه ولیک‌بن در حوزه رودخانه کسلیان (مازندران) استفاده کرده‌اند. امامی و همکاران (Emami & Parsa, 2021) از سه الگوریتم فراابتکاری بهینه‌سازی شامل الگوریتم رقابت استعماری، الگوریتم گرگ خاکستری و الگوریتم انتخابات برای برآورد بار رسوبی معلق رودخانه‌ی زرینه‌رود استفاده کرده‌اند.

به دلیل وجود پیچیدگی‌های زیاد و روابط غیرخطی بین پارامترهای بار معلق رودخانه‌ای، پیش‌بینی دقیق مقدار بار معلق بسیار مشکل می‌باشد. در چنددهه اخیر، محققین از مدل‌های ساده و تجربی مانند منحنی سنجه رسوب برای پیش‌بینی و محاسبه بار معلق حوزه‌های آبخیز استفاده کرده‌اند. استفاده از این روش‌ها علی‌رغم سادگی، دارای خطای زیادی در پیش‌بینی می‌باشند و در بسیاری از حوزه‌ها نمی‌توان بر نتایج حاصل از آنها متکی و مقید بود. به همین علت، امروزه استفاده از روش‌های هوش مصنوعی برای پیش‌بینی بار معلق رواج یافته است. اخیراً از روش‌های مبتنی بر یادگیری ماشین برای مدل‌سازی بسیاری از پدیده‌های مهندسی استفاده شده است (Rahgoshay et al., 2019; Yilmaz et al., 2019). این روش‌ها همچنین می‌توانند برای مدل‌سازی بار معلق مورد استفاده قرار گیرند. این روش‌ها دارای مزایایی از جمله هزینه پایین، سرعت پردازش بالا و دقت مناسب در پدیده‌های مختلف هستند. در همین رابطه، یک روش جدید بر مبنای شبکه عصبی مصنوعی چندلایه و الگوریتم ژنتیک مرتب‌سازی غیرغالب برای پیش‌بینی بار معلق پیشنهاد شده است، که هدف آن کاهش خطا و پیش‌بینی دقیق بار معلق است. در روش پیشنهادی بهینه‌سازی وزن‌های شبکه عصبی مصنوعی چندلایه توسط الگوریتم ژنتیک مرتب‌سازی غالب انجام می‌شود.



شکل ۱- حوزه و ایستگاه تیل آباد واقع در استان گلستان

Figure 1. Location of Til-abad watershed and station in Golestan province

صفحه مختصات لگاریتمی منتقل می‌شوند و بهترین خط برازش بر مبنای روش حداقل مربعات از میان آن‌ها عبور داده می‌شود (Najafinejad *et al.*, 2011). روش فائو برای تعدیل ارقام و نزدیک کردن مقادیر محاسباتی به مقادیر مشاهده‌ای مطرح شده است (Najafinejad *et al.*, 2011). روش فائو، اصلاح شده روش USBR است که در آن شیب خط رگرسیون منحنی سنجه رسوب ثابت فرض می‌شود و عرض از مبدا افزایش می‌یابد تا به نوعی اثر دبی‌های سیلابی لحاظ گردد. در روش QMLE از یک ضریب تصحیح براساس مجذور خطای استاندارد باقیمانده رگرسیون استفاده شده است (Najafinejad *et al.*, 2011). روش Smearing با رد توزیع نرمال خطاهای باقیمانده، برای حذف اریبی داده‌ها استفاده می‌شود (Najafinejad *et al.*, 2011). روش MVUE برای هر یک از مقادیر دبی رسوب مشاهده‌ای، یک ضریب اصلاحی محاسبه می‌شود و میانگین آنها به عنوان ضریب اصلاحی غیر پارامتری مورد استفاده قرار می‌گیرد (Najafinejad *et al.*, 2011).

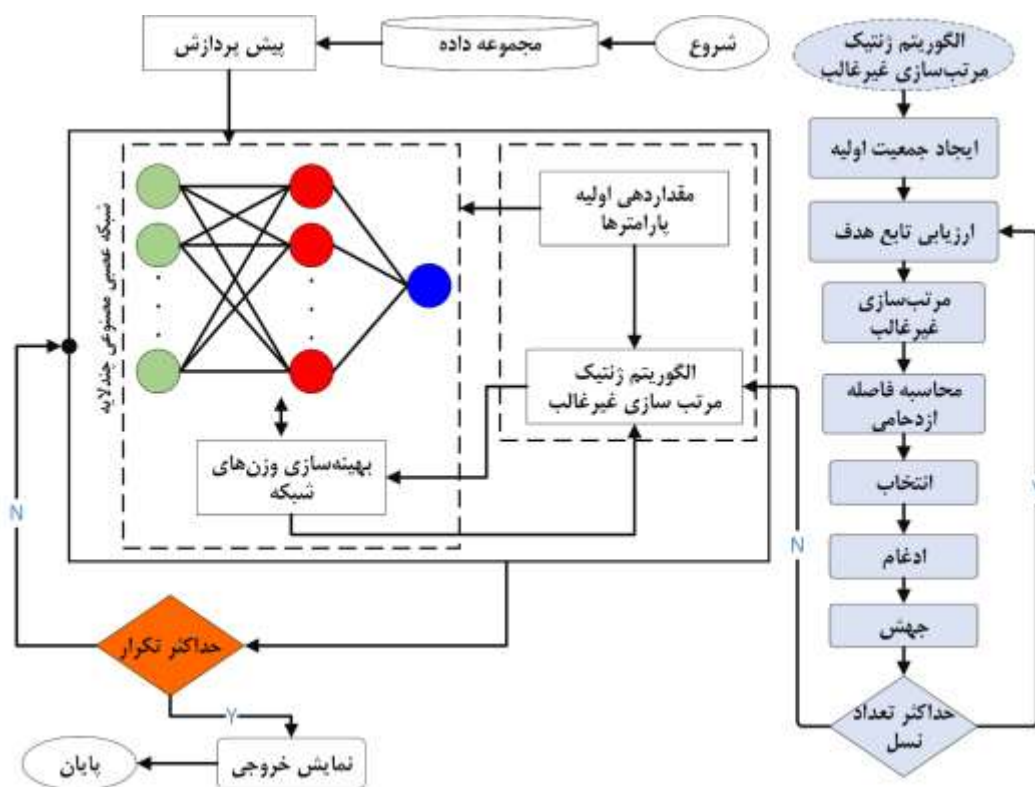
$$X_n = \frac{X_i - X_{max}}{X_{max} - X_{min}} \quad (1)$$

که در آن، X_n بیانگر داده‌های استاندارد شده، X_i بیانگر داده‌های مشاهده‌ای و X_{max} و X_{min} به ترتیب بیانگر داده‌های حداکثر و حداقل می‌باشند.

روش کار

در تحقیق حاضر، ابتدا داده‌های دبی روزانه و بار معلق (سال‌های ۱۳۶۱ تا ۱۳۶۵ و ۱۳۸۴ تا ۱۳۹۴) به عنوان داده‌های ورودی به روش پیشنهادی، پیش پردازش شدند و عملیات استانداردسازی مطابق رابطه ۱ بر روی آنها انجام گرفت. در نتیجه تمامی داده‌ها در محدوده [۰، ۱] استاندارد می‌شوند. در مرحله بعدی ارائه روش پیشنهادی است که چارچوبی برای آن مطابق شکل ۲ ارائه گردید. در پژوهش حاضر از روش‌های منحنی سنجه رسوب، ضرایب اصلاحی و روش پیشنهادی برای پیش‌بینی بار معلق رودخانه گردانرود استفاده شده است. منحنی سنجه رسوب به منظور برقراری ارتباط بین دبی رسوبات و دبی تجمعی رودخانه جهت پیش‌بینی میزان بار معلق استفاده شده است. در ترسیم منحنی سنجه رسوب از انواع روش‌های ترسیم منحنی سنجه شامل یک خطی، دو خطی و حد وسط دسته‌ها استفاده شد. همچنین به منظور کاهش اریب منحنی سنجه از ضرایب اصلاحی نظیر USBR، FAO، QMLE، Smearing و MVUE استفاده گردید (Najafinejad *et al.*, 2011). این ضرایب به منظور تعمیم منحنی سنجه رسوب استفاده شده‌اند.

در روش USBR یک رابطه ریاضی غیرخطی بین بار معلق و آبدی برقرار می‌شود. بر مبنای داده‌های دبی جریان و دبی رسوب متناظر با آن، هر دو سری داده به



شکل ۲- مراحل روش پیشنهادی
Figure 2. Steps of proposed method

چندلایه، دستیابی به بالاترین طبقه‌بندی، تقریب یا دقت پیش‌بینی برای هر نمونه‌های آموزشی و آزمایشی است. به‌عبارتی آرایش شبکه عصبی مصنوعی چندلایه با قانون یادگیری پس‌انتشار خطا تکمیل می‌شود. پیش از آغاز عملیات شبکه عصبی مصنوعی، مجموعه داده‌ها به دو دسته آموزشی و آزمون تقسیم می‌گردد. معمولاً تعداد نمونه‌های آموزشی به منظور یادگیری شبکه بالای ۸۰ درصد است.

در شبکه‌های عصبی مصنوعی، مقادیر اولیه وزن‌ها از اهمیت ویژه‌ای برخوردار است و قبل از شروع آموزش، همه مقادیر وزن‌ها به‌طور تصادفی و کوچک انتخاب می‌شوند. تعیین مقدار بهینه برای وزن‌ها منجر به افزایش دقت پیش‌بینی می‌گردد، که یافتن وزن بهینه بر مبنای الگوریتم ژنتیک مرتب‌سازی غیر غالب انجام شده است. با فرض اینکه تعداد گره‌های ورودی برابر با (N) ، تعداد گره‌های مخفی برابر با (H) و تعداد گره‌های خروجی (O) باشد، آنگاه خروجی لایه مخفی طبق رابطه ۲ تعریف می‌شود (Zare et al., 2013). در این پژوهش از تابع فعال‌سازی سیگموئید در لایه پنهان استفاده شده است. تابع سیگموئید، مقدار هر نرون را به یک مقدار از صفر تا

در تحقیق حاضر علاوه بر منحنی سنجه، از شبکه عصبی مصنوعی چندلایه و الگوریتم ژنتیک مرتب‌سازی غیر غالب برای پیش‌بینی بار معلق استفاده شده است که در ادامه به معرفی آنها پرداخته شده است.

شبکه‌های عصبی مصنوعی چندلایه

شبکه عصبی مصنوعی چندلایه، ابزاری قدرتمند و اثبات شده برای حل چالش‌هایی همانند پیش‌بینی و تخمین است. علاوه بر این، شبکه عصبی مصنوعی چندلایه دارای ساختاری انعطاف‌پذیر و قابل ارتقا است. در شبکه‌های عصبی مصنوعی چندلایه از یک لایه ورودی برای اعمال ورودی‌های مسئله، یک لایه مخفی برای پردازش و نهایتاً یک لایه خروجی برای پاسخ‌های مسئله استفاده می‌شود (Zare et al., 2013). شبکه عصبی مصنوعی چندلایه می‌تواند یک یا بیش‌تر از یک لایه مخفی داشته باشد. تعداد این لایه‌ها و تعداد گره‌ها در هر لایه به مجموعه داده‌ها و فرآیند یادگیری وابسته است و اغلب طی فرآیند آزمون و خطا تعیین می‌شوند (Zare et al., 2013). برای آموزش شبکه‌های عصبی مصنوعی چندلایه اغلب از قانون یادگیری پس‌انتشار خطا استفاده می‌شود. هدف از آموزش شبکه عصبی مصنوعی

آموزش داده شوند و چنانچه پارامترهای شبکه از قبیل تعداد نرون ها، وزن نرون ها و تعداد لایه ها به صورت صحیح، انتخاب شوند می توان انتظار داشت که جواب های منطقی و بهینه از شبکه تولید شوند (Zare et al., 2013). این شبکه یک روش مؤثر برای کشف روابط غیرخطی بین خروجی ها و ورودی ها است. در روش پیشنهادی، مقدار پارامترهای شبکه از قبیل تعداد دور برابر با ۱۰۰۰ و نرخ یادگیری برابر با ۰/۰۰۱۲ بود. روش پیشنهادی شامل یک لایه ورودی، سه لایه مخفی و یک لایه خروجی است. با توجه به اینکه تعداد نرون ها در لایه مخفی، نقش مهمی در عملکرد شبکه عصبی مصنوعی دارد (Zare et al., 2013)، لذا محدوده هشت تا ۳۰ نرون به منظور تعیین تعداد نرون برای لایه مخفی مورد آزمایش قرار گرفته اند. بر مبنای آزمایش های مختلف، تعداد هشت نرون دارای کارایی بهتری بوده و در عملکرد شبکه عصبی مصنوعی با تعداد نرون های بیش تر، تفاوت قابل توجهی حاصل نشد. لذا تعداد هشت نرون نهایی برای لایه مخفی شبکه عصبی مصنوعی انتخاب گردید.

الگوریتم ژنتیک مرتب سازی غیر غالب

الگوریتم ژنتیک مرتب سازی غیر غالب، بهبود یافته الگوریتم ژنتیک بوده که از مزایای این الگوریتم می توان به کاهش زمان محاسباتی و افزایش کارایی اشاره کرد (Ak et al., 2013). الگوریتم ژنتیک مرتب سازی غیر غالب در مقایسه با الگوریتم ژنتیک معمولی دارای راه حل سریع تری است. این الگوریتم از فاصله ازدحامی به منظور دست یافتن به جواب های بهینه و برآورد راه حل های بهینه حول جواب ها استفاده می نماید (Zare et al., 2013). از فاکتور فاصله ازدحامی برای انتخاب بهتر جواب ها از نظر پراکندگی بر روی یک جبهه استفاده می شود. طبق رابطه ۶ از الگوریتم ژنتیک مرتب سازی غیر غالب برای تعیین وزن بهینه نرون ها استفاده می شود (Zare et al., 2013).

$$0 \leq w_i \leq 1; \quad \sum_{i=1}^n w_i = 1 \quad (6)$$

روش پیشنهادی که ترکیبی از شبکه عصبی مصنوعی چند لایه و الگوریتم ژنتیک مرتب سازی غیر غالب است شامل مراحل زیر است: بعد از تولید جمعیت اولیه محاسبه تابع هدف شروع می شود که در این مرحله

یک نگاشت می کند و باعث می شود تا مجموع وزن نرون ها نرمال سازی شود. ورودی ها در بردار X_i به صورت $X_i = [x_1, x_2, x_3, x_n]$ و وزن ها در بردار $W_i = [w_1, w_2, w_3, w_n]$ در نهایت $S = [x_1 w_1 + x_2 w_2 + x_3 w_3 + x_n w_n + bias]$ به صورت $S_j = \sum_{i=1}^N w_{ij} \cdot x_i + b_j$ تعریف می شود (Zare et al., 2013).

$$S_j = \sum_{i=1}^N w_{ij} \cdot x_i + b_j \quad (7)$$

$$f(S_j) = Sigmoid(s_j) = \frac{1}{1 + e^{-(s_j)}}, \quad j = 1, 2, \dots, H$$

به طوری که n تعداد گره های ورودی، w_{ij} بیانگر وزن از گره i ام در لایه ورودی به گره j ام در لایه پنهان، b_j بایاس (آستانه) از گره مخفی j ام و x_i ورودی i ام است. در انتها، روند محاسبه لایه خروجی همانند لایه مخفی به صورت رابطه ۳ تعریف می شود. به طوریکه h تعداد گره های مخفی، w_{jk} بیانگر وزن از گره j ام در لایه مخفی به گره k ام در لایه خروجی، b_k بیانگر بایاس از k امین گره در لایه خروجی و بیانگر k امین داده خروجی است. در روند مرحله آموزش و بهینه سازی برای تعیین مقادیر بهینه برای وزن ها از خطای میانگین مربعات بر مبنای رابطه ۵ به منظور کاهش خطا استفاده می شود. به طوریکه t_k خروجی واقعی نمونه ورودی k و O_k خروجی پیش بینی شده نمونه ورودی k (رابطه ۴) و n تعداد نمونه ها است.

$$y_k = \sum_{j=1}^h w_{jk} \cdot f(S_j) + b_k, \quad k = 1, 2, \dots, O \quad (3)$$

$$O_k = sigmoid(y_k) = \frac{1}{(1 + \exp(-y_k))} \quad (4)$$

$$MSE = \frac{\sum_{k=1}^n (t_k - O_k)^2}{n} \quad (5)$$

در هر گام، خروجی شبکه محاسبه می شود و بر حسب میزان اختلاف آن با خروجی مطلوب، وزن ها تصحیح می گردند تا در نهایت مقدار خطا، حداقل شود (Zare et al., 2013). هدف خطای میانگین مربعات این است که اختلاف بین نتایج مدل ترکیبی و داده های واقعی به حداقل برسد.

ساختار شبکه های عصبی مصنوعی چند لایه به گونه ای است که در ابتدا باید توسط یک سری داده های واقعی،

برای ارزیابی دقت نتایج از معیارهای آماری ضریب تعیین^۱ (رابطه ۷) (R^2)، ریشه میانگین مربعات خطا^۲ (RMSE) (رابطه ۸)، میانگین قدر مطلق خطا^۳ (MAE) (رابطه ۹) و ناش-ساتکلیف^۴ (رابطه ۱۰) استفاده شد.

$$R^2 = \frac{\sum(O - \bar{O}) \times (P - \bar{P})}{\sqrt{(\sum(O - \bar{O})^2) \times (\sum(P - \bar{P})^2)}} \quad (7)$$

$$RMSE = \left(\frac{\sum_{i=1}^n (P - O)^2}{n} \right)^{1/2} \quad (8)$$

$$MAE = \frac{\sum |O - P|}{n} \quad (9)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (P - O)^2}{\sum_{i=1}^N (O - \bar{O})^2} \quad (10)$$

که در آن، O و P به ترتیب مقادیر مشاهده شده و برآورد شده، \bar{O} و \bar{P} میانگین مقادیر مشاهده شده و شبیه‌سازی شده و n تعداد نمونه‌ها می‌باشد (Halabian et al., 2017). اگر نرخ ضریب تعیین (R^2) بالاتر، نرخ ریشه میانگین مربعات خطا و میانگین قدر مطلق خطا کوچک‌تر باشد آنگاه روش پیشنهادی از اطمینان بیش‌تری به‌منظور پیش‌بینی بار معلق برخوردار است و کاربرد وسیع‌تری خواهد داشت.

نتایج و بحث

در شکل ۳ رابطه بین دبی رسوب و دبی جریان آب بر مبنای منحنی سنج رسوب یک خطی نشان داده شده است. در منحنی سنج رسوب یک خطی برای تمامی داده‌های دبی-رسوب، یک خط برازش وجود دارد. منحنی‌های سنج رسوب براساس اندازه‌گیری‌های انجام شده در رودخانه‌ها به‌دست می‌آیند؛ بدین صورت که متناظر با هر دبی در رودخانه غلظت مواد رسوبی حمل شده توسط آب اندازه‌گیری می‌شود و منحنی مربوطه ترسیم می‌شود. رابطه استخراجی برای منحنی سنج رسوب ایستگاه تیل‌آباد به صورت $y = 6.6341x^{1.476}$ تعیین گردید. که در آن y مقدار بار معلق و x مقدار دبی جریان در ایستگاه تیل‌آباد می‌باشد. منحنی لگاریتمی این رابطه بین داده‌ها در شکل ۳ قابل مشاهده است.

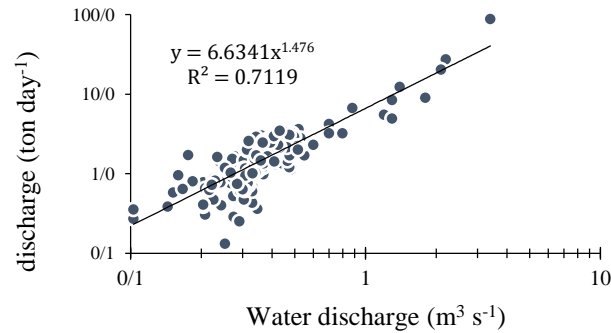
مقادیر توابع هدف برای همه افراد (کروموزوم‌ها) جمعیت محاسبه می‌شود. بعداً جمعیت بر مبنای شرط‌های غلبه کردن مرتب‌سازی می‌شود. پس از مرتب‌سازی پاسخ‌ها براساس غلبه، باید آنها را بر مبنای فاصله ازدحامی مرتب کرد که منجر به ایجاد نظم بیشتر در بین پاسخ‌های بهینه نیز می‌شود. سپس عملیات انتخاب انجام می‌شود که در این مطالعه، افرادی انتخاب می‌شوند که فاصله ازدحامی کمتری دارند. سپس ادغام و جهش برای تولید فرزند جدید انجام می‌شود. هدف از عملگر ادغام، جستجو در بخش‌های جدید و به‌ویژه سودمند فضای جستجو به وسیله جابجایی یک قسمت از مجموعه ژن‌ها بین دو کروموزوم می‌باشد. ورود نقاط جدید به جمعیت و همچنین جستجو در فضاهای کشف نشده مسئله توسط عملگر جهش انجام می‌شود. در این مطالعه به منظور اعمال جهش از عملگر جهش تصادفی استفاده شده است. در مرحله بعد، جمعیت اولیه برگرفته از عملیات ادغام و جهش می‌باشد و سپس عملیات ارزیابی تابع هدف انجام می‌شود. تمامی مراحل تا تعداد مشخصی از نسل‌ها تکرار می‌شود.

در این پژوهش از ترکیب شبکه عصبی مصنوعی چندلایه و الگوریتم ژنتیک مرتب‌سازی غیرغالب به عنوان روش مؤثر برای تخمین بار معلق استفاده می‌شود. در روش پیشنهادی از الگوریتم ژنتیک مرتب‌سازی غیرغالب (Shafaghat et al., 2008) برای بهینه‌سازی وزن نرون‌ها و از الگوریتم آموزشی پس‌انتشار برای آموزش شبکه عصبی مصنوعی چندلایه استفاده می‌شود. پژوهش براساس فرضیه‌ی پیش‌بینی بار معلق برای سال‌های آینده شکل گرفته است. برای مدلسازی از شبیه‌ساز متلب ۲۰۱۷ استفاده شده است که از ۸۰ درصد داده‌ها برای آموزش شبکه و ۲۰ درصد داده‌ها برای تست و ارزیابی شبکه استفاده شده است. تعداد داده‌های آموزش و اعتبار سنجی برابر با ۱۶۵ داده و تعداد داده‌های تست برابر با ۴۲ داده است.

معیارهای ارزیابی دقت پیش‌بینی‌ها

3. Mean Absolute Error (MAE)
4. Nash-Sutcliffe Efficiency (NSE)

1. Coefficient of Determination
2. Root Mean Square Error (RMSE)




شکل ۳- رابطه بین دبی رسوب-منحنی یک خطی

Figure 3. The relationship between sediment and discharge based on single-line curve

بین دبی‌ها در حالت جریان آب و رسوبات ملاحظه می‌گردد به طوری که ضریب تعیین (R^2) برابر 0.8903 به دست آمده است. همچنین پراکنش نقاط آبی در شکل ۴ زیاد بوده است و ارتباط مناسبی بین دبی‌ها در حالت جریان آب و رسوبات ملاحظه نمی‌گردد.

در شکل ۴ رابطه بین دبی رسوب و دبی جریان آب بر مبنای منحنی سنج رسوب دو خطی نشان داده شده است. نقاط قرمز رنگ بیانگر دبی جریان آب با بیش‌تر از نیم متر مکعب می‌باشند. در شکل ۴ پراکنش ابرنقاط (نقاط x و y) قرمز رنگ زیاد نیست و ارتباط مناسبی




شکل ۴- رابطه بین دبی رسوب-منحنی دو خطی

Figure 4. The relationship between sediment and discharge based on two-line curve

و شامل یک خط برازش از بین ابرنقاط (نقاط x و y) یعنی میانگین داده‌ها می‌باشد. در شکل ۵ مشخص شد که ابرنقاط پراکنش زیادی نداشته و برازش نسبتاً مناسبی صورت گرفته است.

در شکل ۵ نتایج مربوط به روش رگرسیون و منحنی سنج رسوب حد وسط دسته‌ها بین دبی-رسوب همراه با معادله رگرسیونی مرتبط با داده‌ها نشان داده شده است. در منحنی سنج رسوب حد وسط از میانگین دسته‌بندی داده‌های دبی-غلظت رسوب استفاده می‌شود



شکل ۵- رابطه بین دبی رسوب-منحنی حد وسط

Figure 5. Relationship between sediment and discharge mean curve

مناسبی برای منحنی یک خطی برخوردار هستند (جدول ۱). نتایج مربوط به رسوب برآوردی بر مبنای ضرایب اصلاحی برای منحنی دو خطی حاکی از آن است که روش‌های QMLE و FAO از دقت قابل قبولی در پیش‌بینی با رسوبی برخوردار هستند (جدول ۲). طبق نتایج جدول ۳ مشخص شد که روش FAO و USBR دارای دقت بهتری در پیش‌بینی بار رسوبی حوضه در مقایسه با رسوب مشاهداتی می‌باشند. با این اوصاف روش FAO در هر سه حالت منحنی از دقت مناسبی برخوردار می‌باشد.

طبق نتایج جدول ۱ مشخص است که روش USBR و FAO بر مبنای ضرایب اصلاحی برای منحنی یک خطی دارای دقت کم‌تری در مقایسه با رسوب مشاهداتی می‌باشند. متوسط در صد خطای پیش‌بینی بار رسوبی در روش‌های Smearing، QMLE، MVUE، FAO و USBR به ترتیب برابر ۱۸-، ۱-، ۲۷-، ۸- و ۲۱+ (مقادیر مثبت بیش برآورد و منفی کم برآورد) می‌باشد. این مقادیر برای منحنی دوخطی به ترتیب برابر با ۱۷-، ۶-، ۲۶-، ۱،۴ و ۱۷+ درصد و برای منحنی حد واسط به ترتیب برابر با ۳۰-، ۱۵-، ۲۹-، ۱،۵- و ۱۴+ درصد می‌باشد. بنابراین روش‌های QMLE و FAO از دقت

جدول ۱- رسوب برآوردی بر مبنای ضرایب اصلاحی برای منحنی یک خطی

Table 1. Estimated sediment based on correction coefficients for a single line curve

Qw (Water discharge- $m^3 s^{-1}$)	Observed sediment (ton day $^{-1}$)	Estimated sediment (cumulative values of sediment discharge (ton day $^{-1}$))				
		USBR	FAO	MVUE	QMLE	Smearing
0.103	0.352	0.23	0.30	0.38	0.28	0.34
0.27	0.99	0.70	0.92	1.17	0.85	1.03
0.492	1.72	1.41	1.86	2.36	1.72	2.09
0.792	3.66	2.53	3.32	4.22	3.08	3.74
1.182	5.63	4.17	5.48	6.97	5.09	6.17
1.582	7.73	5.88	7.73	9.82	7.17	8.70
1.992	10.05	7.65	10.06	12.78	9.33	11.32
2.412	12.23	9.49	12.47	15.84	11.57	14.04
2.832	15.21	11.32	14.88	18.90	13.81	16.75
3.322	18.42	13.63	17.91	22.75	16.62	20.17
3.822	21.33	16.00	21.03	26.72	19.52	23.68
4.362	23.64	18.66	24.53	31.17	22.77	27.62
5.062	27.14	22.57	29.67	37.69	27.54	33.41
6.262	32.64	32.25	41.08	52.19	38.12	46.25
7.562	37.54	41.02	53.92	68.50	50.04	60.71
8.965	49.84	51.92	68.25	86.71	63.34	76.84
10.762	58.84	67.74	89.04	113.12	82.64	100.25
12.862	79.14	87.60	115.16	146.30	106.88	129.65
15.062	106.34	108.89	143.13	181.84	132.84	161.15
Average error percentage		+21	-7.6	-27	-1	-18

پیشنهادی در پیش‌بینی بار معلق در هر تکرار به مقدار دقیق‌تر نزدیک‌تر شده است. روند اجرای روش پیشنهادی نشان می‌دهد که مقدار خطا در هر تکرار دارای روند نزولی است.

در شکل ۶ نمودار داده‌های آموزشی، تست و اعتبارسنجی بر مبنای روش پیشنهادی تحقیق حاضر نشان داده شده است. طبق شکل ۶ مشخص است که مقدار خطا در مرحله آموزش داده‌ها بسیار پایین است. روند کاهش خطا در نمودار شکل ۶ نشان می‌دهد که دقت روش

جدول ۲- رسوب برآوردی بر مبنای ضرایب اصلاحی برای منحنی دو خطی


Table 2. Estimated sediment based on correction coefficients for a two-line curve

Qw (Water Debi-m ³ /s)	Observational sediment (tons per day)	Estimated sediment (cumulative values of sediment discharge (tons per day))				
		USBR	FAO	MVUE	QMLE	Smearing
0.103	0.352	0.20	0.21	0.41	0.23	0.27
0.27	0.994	0.64	0.67	1.29	0.74	0.86
0.492	1.717	1.32	1.39	2.67	1.53	1.78
0.54	2.31	2.80	4.08	3.00	4.14	4.48
0.792	3.661	2.42	2.56	4.91	2.81	3.26
1.24	5.813	6.72	9.81	7.19	9.95	10.76
1.182	5.627	4.09	4.33	8.30	4.74	5.52
1.582	7.727	5.83	6.17	11.83	6.76	7.87
1.992	10.053	7.64	8.08	15.51	8.86	10.31
2.412	12.23	9.52	10.07	19.32	11.04	12.85
2.44	11.313	14.63	21.34	15.65	21.65	23.41
2.832	15.206	11.40	12.06	23.14	13.22	15.39
3.322	18.422	13.80	14.60	28.02	16.01	18.63
3.74	16.213	23.40	34.14	25.04	34.64	37.45
3.822	21.326	16.27	17.22	33.05	18.89	21.98
5.14	28.513	33.06	48.23	35.38	48.93	52.90
6.94	37.513	46.46	67.77	49.71	68.76	74.33
9.04	57.813	62.82	91.65	67.22	92.98	100.52
11.24	85.013	80.21	117.01	85.82	118.71	128.33
Average error percentage		16.9	+1.4	-26.5	-5.7	-17.5

جدول ۳- رسوب برآوردی بر مبنای ضرایب اصلاحی برای منحنی حد وسط

Table 3. Estimated sediment based on correction coefficients for a mean curve

Qw (Water Debi-m ³ /s)	Observational sediment (tons per day)	Estimated sediment (cumulative values of sediment discharge (tons per day))				
		USBR	FAO	MVUE	QMLE	Smearing
0.10	0.35	0.31	0.36	0.50	0.41	0.50
0.27	0.99	0.89	1.02	1.43	1.19	1.45
0.49	1.72	1.74	1.98	2.78	2.31	2.82
0.79	3.66	2.99	3.41	4.78	3.97	4.84
1.18	5.63	4.74	5.42	7.59	6.31	7.69
1.58	7.73	5.56	7.49	10.49	8.72	10.63
1.99	10.05	8.43	9.63	13.49	11.22	13.66
2.41	12.23	10.37	11.84	16.59	13.79	16.80
2.83	15.21	12.30	14.04	19.68	16.36	19.93
3.32	18.42	14.67	16.74	23.46	19.51	23.76
3.82	21.33	17.09	19.51	27.35	22.73	27.69
4.36	23.64	19.77	22.57	31.64	26.30	32.03
5.06	27.14	23.53	26.86	37.65	31.30	38.12
6.26	32.64	31.10	35.51	49.76	41.37	50.39
7.56	37.54	39.50	45.10	63.21	52.54	64.00
8.96	49.84	48.76	55.66	78.01	64.85	78.99
10.76	58.84	61.58	70.30	98.53	81.91	99.76
12.86	79.14	77.26	88.20	123.61	102.75	125.16
15.06	106.34	93.91	107.20	150.25	124.90	152.13
Average error percentage		13.8	-1.4	-29.5	-15	-30

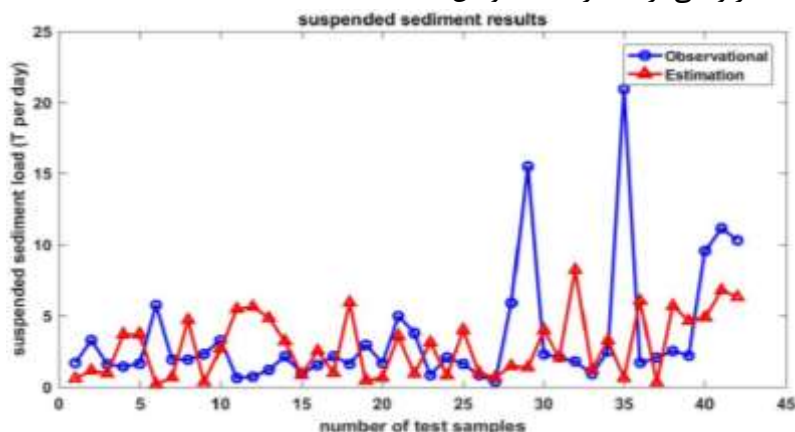


شکل ۶- نمودار فرآیند آموزش بر مبنای نرخ خطا با ۱۰۰۰ تکرار

Figure 6. Diagram of the training process based on error rate with 1000 iterations


بیاانگر کارایی روش پیشنهادی است. در شکل ۷ نمونه‌های پیش‌بینی شده دارای تعادل بهتری با نمونه‌های مشاهداتی هستند. اما در شکل ۸ اختلاف بین نمونه‌های تخمین شده و مشاهداتی بالا است و مشخص است که تخمین به درستی انجام نشده است.

در شکل‌های ۷ و ۸ مقادیر تخمین زده شده توسط روش پیشنهادی بر مبنای دو الگوریتم آموزشی پس‌انتشار و گرادیان نزولی نشان داده شده است. همانگونه که از شکل‌های ۷ و ۸ مشخص است نتایج حاصل از تخمین مقادیر رسوب توسط الگوریتم آموزشی پس‌انتشار نسبت به گرادیان نزولی به مقادیر واقعی نزدیک‌تر است و این



شکل ۷- میزان رسوب برآورد شده و مشاهداتی با روش پیشنهادی و تابع آموزشی پس‌انتشار

Figure 7. Estimated sedimentation rate and observations with the proposed method and back-propagation training function



شکل ۸- میزان رسوب برآورد شده و مشاهداتی با روش پیشنهادی و تابع آموزشی گرادیان نزولی

Figure 8. Estimated sedimentation rate and observations with the proposed method and descending gradient training function

جدول ۴ مشخص است که روش پیشنهادی در مقایسه با شبکه عصبی مصنوعی چندلایه دارای مقدار R^2 بیشتری است. مقدار R^2 در شبکه عصبی مصنوعی چندلایه بر مبنای الگوریتم پس‌انتشار، الگوریتم گرادیان نزولی و الگوریتم بیزین برتریب برابر با ۰/۴۳۷۲، ۰/۳۹۶۷ و ۰/۴۰۳۸ بدست آمده است. بر مبنای نتایج کسب شده، می‌توان بیان نمود نتایج حاصل از اجرای روش پیشنهادی در تخمین و مقادیر بار معلق رضایت بخش بوده است. بهبود روش پیشنهادی در مقایسه با شبکه عصبی مصنوعی چندلایه بر مبنای معیار R^2 در حدود ۵۳/۸۹ درصد بوده است. نتایج مطالعات (Halabian et al., 2017 ; Rahgoshay et al., 2019) حاکی از آن بود که شبکه عصبی مصنوعی چندلایه در مقایسه با مدل‌هایی همانند ماشین بردار پشتیبان، درختان تصمیم‌گیری و فازی دارای دقت بهتری در پیش‌بینی بار معلق بوده است.

در جدول ۴ نتایج روش پیشنهادی بر مبنای معیارهای R^2 ، RMSE، MAE و NSE نشان داده شده است. طبق نتایج جدول ۴ مشخص است که مقدار R^2 در الگوریتم پس‌انتشار بیش‌تر است. بنابراین می‌توان ادعا کرد که الگوریتم پس‌انتشار در مقایسه با الگوریتم‌های دیگر از قابلیت بالایی در برآورد بار معلق برخوردار است. الگوریتم یادگیری پس‌انتشار یکی از مهمترین رویکردهای سنتی برای آموزش شبکه عصبی مصنوعی چندلایه است. اما، الگوریتم آموزشی مبتنی بر گرادیان دارای مشکلاتی است که شامل همگرایی بسیار آهسته و گیر افتادن در حداقل‌های محلی است. همچنین مقدار RMSE در الگوریتم پس‌انتشار، الگوریتم گرادیان نزولی و الگوریتم بیزین برتریب برابر با ۴/۷۲۲۵، ۶/۷۹۶۶ و ۸/۴۰۱۵ تعیین شد. عمدتاً الگوریتم آموزش شبکه عصبی مصنوعی چندلایه مبتنی بر روش گرادیان می‌باشد که از تکنیک‌های جستجوی محلی استفاده می‌کند و لذا، خطر گیر افتادن در نقاط بهینه محلی را دارد. طبق نتایج

جدول ۴- نتایج روش پیشنهادی در پیش‌بینی بار معلق در ایستگاه تیل‌آباد

Table 4. Results of the proposed method in predicting suspended sediment load at Tilabad station

Methods	ANN training algorithms	NSE	MAE (ton day ⁻¹)	RMSE (ton day ⁻¹)	R ²
Proposed Method	Back propagation algorithm	0.4321	3.0168	4.7225	0.6728
	Descending gradient algorithm	0.3842	8.8024	6.7966	0.5161
	Bayesian algorithm	0.3326	8.2035	8.4015	0.4572
MLP-ANN	Back propagation algorithm	0.2941	7.1030	8.0542	0.4372
	Descending gradient algorithm	0.2602	9.0954	11.1232	0.3967
	Bayesian algorithm	0.2136	14.3584	16.5348	0.4038

مرسوم پیش‌بینی بار معلق، منحنی سنج رسوب است، اما طبق تحقیقات انجام شده، مشخص شده است که این روش مقدار بار معلق را کم‌تر از مقدار واقعی تخمین می‌زند. لذا یک روش مورد اطمینان برای پیش‌بینی بار معلق نیست. در این مطالعه بر مبنای شبکه عصبی مصنوعی چندلایه و الگوریتم ژنتیک مرتب‌سازی غیر غالب یک روش جدید برای پیش‌بینی بار معلق پیشنهاد شد. در روش پیشنهادی، الگوریتم ژنتیک مرتب‌سازی غیر غالب باعث شده که شبکه عصبی مصنوعی چندلایه دقت خوبی در پیش‌بینی رسوب بار معلق داشته باشد.

نتیجه‌گیری کلی

در روش پیشنهادی از الگوریتم پس‌انتشار برای آموزش شبکه عصبی مصنوعی چندلایه و از الگوریتم ژنتیک مرتب‌سازی غیر غالب برای بهینه‌سازی وزن‌ها استفاده شد. ارزیابی روش پیشنهادی بر روی مجموعه داده‌های ایستگاه تیل‌آباد-رودخانه گرگان‌رود انجام شد. یکی از مهمترین مسائل وارده به حوزه سدها، بار معلق است که منجر به مشکلاتی از قبیل تأثیرگذاری بر طول عمر و فرسایش سازه‌ها و مخازن آبی می‌گردد. وجود متغیرهای مختلف و پیچیده بار رسوب رودخانه‌ها منجر شده است که تخمین میزان رسوب وارد شده به مخازن برای تعیین عمر مخازن سدها با مشکل روبرو گردد. از تکنیک‌های

References

- Abdi Dehkordi M., Dehghani A.A., Meftah Halghi M., Kahe M., Hesam M., and Dehghani, N. 2014. Use of fuzzy clustering algorithm for estimating the daily suspended load (Case Study: Kasilain Basin). *Journal of Water and Soil Science*, 18(68): 121-131. (In Persian)
- Ak R., Li Y., Vitelli V., Zio E., Droguett E.L., Jacinto C.M.C. 2013. NSGA-II-trained neural network approach to the estimation of prediction intervals of scale deposition rate in oil & gas equipment. *Expert Systems with Applications*, 40(4): 1205-1212.
- Alijanpour Shalmani A., Vaezi A., and Tabatabaei M. 2020. Optimal combinations of hydrological variables for modeling of daily suspended sediment load in Karaj Watershed. *Watershed Engineering and Management*, 12(1): 228-243. (In Persian)
- Asadi M., Fathzadeh A., and Taghizadeh Mehrjerdi R. 2017. The effects of the daily, monthly, and annual time scales on the suspended sediment load prediction. *Hydrogeomorphology*, 4(10): 121-143. (In Persian)
- Banadkooki F.B., Ehteram M., Ahmed A.N., Teo F.Y., Ebrahimi M., Fai C.M., and El-Shafie, A. 2020. Suspended sediment load prediction using artificial neural network and ant lion optimization algorithm. *Environmental Science and Pollution Research*, 27(30): 38094-38116.
- Barzegari F., and Dastorani M.T. 2016. Suspended sediment prediction using time series and artificial neural networks models (Case Study: Ghazaghly Station in Gorganroud River). *Journal of Watershed Management Research*, 6(12), 216-225. (In Persian)
- Dastorani M.T., Azimi Fashi K., Talebi A., and Ekhtesasi M.R. 2012. Estimation of suspended sediment using artificial neural network (Case Study: Jamishan Watershed in Kermanshah). *Journal of Watershed Management Research*, 3(6): 61-74. (In Persian)
- Emami S., Choopan Y., and Parsa J. 2021. Comparising performance of meta-heuristic algorithms with the sediment rate curve (Case Study: Zarrineh Rood River). *Watershed Engineering and Management*, 13(1): 43-54. (In Persian)
- Gharehchopogh F.S., and Gholizadeh H. 2019. A comprehensive survey: Whale Optimization Algorithm and its applications. *Swarm and Evolutionary Computation*, 48: 1-24.
- Gupta D., Hazarika B.B., Berlin M., Sharma U.M., and Mishra K. 2021. Artificial intelligence for suspended sediment load prediction: a review. *Environmental Earth Sciences*, 80(9): 346.
- Halabian A., Javari M., Akbari Z., and Akbari G. 2017. Evaluating the performance of decision tree model in estimating the suspended sediments of river (A case study on the Basin of Meimeh River). *Geography And Development Iranian Journal*, 15(49): 81-96. (In Persian)
- Hayatzadeh M., Chezgi J., and Taghi Dastorani M. 2015. Evaluation of sediments using rating curve and artificial neural network methods by combining morphological parameters of basin (case study: bagh abbas basin). *Journal of Water and Soil Science*, 19(72): 217-228. (In Persian)
- Imamgholizadeh S., Karimi Demneh R., and Azhdari K. 2016. Comparison of conventional methods for estimation of suspended sediment load of karkheh river by gene expression programming approach. *Geography And Development Iranian Journal*, 14(45): 121-140. (In Persian)
- Keihani A., Akhondali A.M., and Fathian H. 2021. Uncertainty analysis of svm model parameters for estimating suspended and bed sediment load at sierra station in karaj by monte-carlo simulation method. *Iranian Journal of Soil and Water Research*, 52(1): 195-212. (In Persian)
- Khazaei Moughani S., Najafinejad A., Azimmohseni M., and Berdi Sheikh V. 2013. Spatial and seasonal variation of suspended sediment in different stations of gorganroud river. golestan province. *Journal of Watershed Management Research*, 4(7): 1-15. (In Persian)
- Khazaie Poul A., and Talebi A. 2013. Investigation of possibility of suspended sediment prediction using a combination of sediment rating curve and artificial neural network (case study: ghatorchai river, yazdakan bridge). *Quarterly Journal of Environmental Erosion Researches*, 3(1): 73-82. (In Persian)
- Kheirfam H., and Mokarram-Kashtiban S. 2018. A regional suspended load yield estimation model for ungauged watersheds. *Water Science and Engineering*, 11(4): 328-337
- Khorshidoost A., Feyzolahpour M., and Sadrafshary S. 2015. Assessing the capability of adaptive neuro fuzzy interference system (anfis) in estimating the amount of suspended sediment load and its comparison with two models of artificial neutral fuzzy inference system case study: zarine rood, south east basin of urmia lake. *Geography And Development Iranian Journal*, 13(41): 185-200. (In Persian)

- Kia E., Emadi A., and Fazlola R. 2015. Investigation for application of adaptive neuro-fuzzy inference system (anfis) in babolroud suspended sediment load estimation. *Journal of Watershed Management Research*, 6(11): 15-23. (In Persian)
- Najafinejad A., Mardian M., Varvani J., and Sheikh V.B. 2011. Performance evaluation of correction factors in optimization of sediment rating curve (case study: kamal saleh dam watershed, markazi province, iran). *Journal of Water and Soil Conservation*, 18(2): 105-122.
- Nikkami D., and Shadfar S. 2021. Soil erosion mapping in sediment gauged watersheds of Iran. *Watershed Engineering and Management*, 13(2): 479-496.
- Panahi F., Ehteram M., and Emami M. 2021. Suspended sediment load prediction based on soft computing models and Black Widow Optimization Algorithm using an enhanced gamma test. *Environmental Science and Pollution Research*, 28(35): 1-21.
- Rahgoshay M., Feiznia S., Arian M., and Hashemi S.A.A. 2019. Simulation of daily suspended sediment load using an improved model of support vector machine and genetic algorithms and particle swarm. *Arabian Journal of Geosciences*, 12(9): 277.
- Rahmani V., Kastens J. H., DeNoyelles F., Jakubauskas M.E., Martinko E.A., Huggins D.H., Blackwood A.J. 2018. Examining storage capacity loss and sedimentation rate of large reservoirs in the central u.s. great plains. *Water*, 10(2): 1-17
- Rajae T., Mirbagheri S. A., Nourani V., & Alikhani A. 2010. Prediction of daily suspended sediment load using wavelet and neurofuzzy combined model. *International Journal of Environmental Science & Technology*, 7(1): 93-110.
- Razavizadeh S., Kavian A., and Vafakhah M. 2014. Estimation of suspended sediment discharge by optimal structure of artificial neural network in taleghan watershed. *Journal of Water and Soil Science*, 18(68): 79-88. (In Persian)
- Shafaghat R., Hosseinalipour S., Mohammad Nouri N., and Lashgari I. 2008. Shape optimization of two-dimensional cavitators in supercavitating flows, using NSGA II algorithm. *Applied Ocean Research*, 30(4): 305-310.
- Tabatabaei M., Salehpour Jam A., and Mosaffaie J. 2020. Improvement of the efficiency of artificial neural network model in suspended sediment simulation using particle swarm optimization algorithm. *Watershed Engineering and Management*, 12(3): 756-770. (In Persian)
- Tabatabaei M.R., Solaimani K., Habibnejad Roshan M., and Kavian A. 2014. Estimation of daily suspended sediment concentration using artificial neural networks and data clustering by self-organizing map (case study: sierra hydrometry station- karaj dam watershed). *Journal of Watershed Management Research*, 5(10): 98-116. (In Persian)
- Varvani J., Gholi Ebrahimi N., Yosefi M., Shadmani A.R., and Nikche Farahani S. 2016. A performance evaluation of neuro-fuzzy and regression methods in estimation of sediment load of river. *Watershed Management Research (Pajouhesh & Sazandegi)*, 28(4): 104-113. (In Persian)
- Yilmaz B., Aras, E., Kankal M., and Nacar S. 2019. Prediction of suspended sediment loading by means of hybrid artificial intelligence approaches. *Acta Geophysica*, 67(6): 1693-1705.
- Yosefi M., and Poorshariaty R. 2015. Suspended sediment estimation using neural network and algorithms assessment (case study: lorestan province). *Journal of Watershed Management Research*, 5(10): 85-97. (In Persian)
- Yousefi M., and Barzegari F. 2014. Estimation of suspended sediment using decision tree method and comparison the results with rating curve method (Case study: Rivers in Lorestan Province). *Watershed Management Research (Pajouhesh & Sazandegi)*, 27(3): 187-195. (In Persian)
- Zare M., Pourghasemi H.R., Vafakhah M., and Pradhan B. 2013. Landslide susceptibility mapping at Vaz Watershed (Iran) using an artificial neural network model: a comparison between multilayer perceptron (MLP) and radial basic function (RBF) algorithms. *Arabian Journal of Geosciences*, 6(1): 2873-2888.
- Zhao G., Pang B., Xu Z., and Xu L. 2020. A hybrid machine learning framework for real-time water level prediction in high sediment load reaches. *Journal of Hydrology*, 581(1): 1-10.

Predicting River Suspended Load Using Artificial Neural Network and Non-Dominant Genetic Sorting Algorithm

Mikael Hosseini¹, Mohammad Hemmati^{2*}, Mehdi Yasi³

(Received: July 2021 Accepted: October 2021)

Abstract

Information on soil erosion and sediment production, meteorological features, hydrological features of rivers such as discharge, as well as human factors, are often very complex, indefinite, and nonlinear. Therefore, the use of machine intelligence algorithms (such as machine learning algorithms) is a good option in simulating and predicting river water quality variables such as suspended load. The aim of the present study is to present a proposed method based on Multilayer Perceptron Artificial Neural Network (MLP-ANN) and Non-Dominant Sorting Genetic Algorithm (NSGA) for predicting suspended river load. In the proposed method, the NSGA was used to train the MLP using the error propagation method and determining the optimal weight for the neurons. In this study, the suspended load of *Tilabad* station located in *Gorganrood* river during the 1982-2015 years was used as a case study. The results showed that the proposed method has a higher correlation coefficient compared to MLP and the value of R² was 0.6728 and 0.4372, respectively. The value of Root-Mean-Square Error (RMSE) in the proposed method and MLP based on back-propagation (BP) algorithm is 4.7225 and 8.548, respectively. Therefore, in the proposed method, the NSGA has caused a good improvement of the MLP. The NSE value in the proposed method and MLP based on BP algorithm is 0.4321 and 0.2941, respectively. The results showed that the proposed method had good accuracy in predicting the suspended load. The proposed method with BP training algorithm has a better performance compared to the descending and Bayesian gradient training algorithm.

Keywords: Sediment Rating Curve, Non-dominant Sorting Genetic Algorithm, Gorganrood, Suspended Load

Hosseini M., Hemmati M. and Yasi M. 2023. Predicting river suspended load using artificial neural network and non-dominant genetic sorting algorithm. *Applied Soil Research*, 10(4): 45-60.

1. PhD Student, Department of Water Engineering, Faculty of Agriculture, Urmia University

2. Associate Professor, Department of Water Engineering, Faculty of Agriculture, Urmia University

3. Associate Professor, Department of Irrigation and Reclamation Engineering, Faculty of Agricultural Engineering and Technology, University of Tehran, Karaj, Iran

* Corresponding Author Email: m.hemmati@urmia.ac.ir