

مقاله علمی-پژوهشی

مدل‌سازی کیفیت و رسوب رودخانه با استفاده از روش‌های ناپارامتری و غیرخطی

محبوبه شادابی بجنده^۱، ابراهیم امیری^{۲*}، علی مقیمی کندلوسی^۳، ناصر محمدیان روشن^۴

تاریخ دریافت: ۱۴۰۲/۰۷/۱۴ تاریخ پذیرش: ۱۴۰۲/۰۶/۲۵

چکیده

فرسایش و انتقال رسوب ناشی از آن بر کیفیت آب‌های سطحی اثرگذار است و برآورد میزان رسوب و کیفیت جریان نقش مهمی در مدیریت منابع آب ایفا می‌نماید. در پژوهش حاضر مدل‌سازی شاخص‌های کیفیت و بار رسوب جریان و ارائه روابط جهت پیش‌بینی مقدار رسوب جریان رودخانه‌های خراسان رضوی در ۶ ایستگاه و دوره آماری ۱۳۶۵ تا ۱۳۹۵ با روش‌های ناپارامتری و غیرخطی شبکه واحد بازگشتی دروازه‌دار (GRU) و الگوریتم جنگل تصادفی (RF) انجام گرفت. با به‌کارگیری روش بگینگ مدل‌سازی شاخص‌های دبی، رسوب و مجموع آنیون و کاتیون جریان در هر دو شبکه مدل گردید. شاخص‌های آماری MAE، MAPE، RMSE جهت ارزیابی عملکرد مدل و ضریب R^2 جهت ارزیابی صحت تقسیم‌بندی داده‌ها استفاده شدند. نتایج مربوط به مقدار میانگین شاخص‌های MAE، MAPE، RMSE داده‌های کیفیت آب (مجموع آنیون و کاتیون) ایستگاه‌های موردبررسی در شبکه GRU به ترتیب برابر با ۰/۰۶، ۲۸۶/۱۶ و ۱۶۸۵/۳۴ (meq/L) و در شبکه RF به ترتیب برابر با ۰/۰۸، ۳۱۷/۴۰ و ۱۹۵۴/۱۱ (meq/L) و داده‌های بار رسوب در شبکه GRU به ترتیب برابر با ۲۰/۹۵، ۰/۵۵ و ۱۴۳۴/۴۴ (ton/day) و در شبکه RF به ترتیب برابر با ۵۲۹۲۱/۸۴، ۰/۹۰ و ۱۵۴۴/۲۹ (ton/day). برتری مدل GRU نسبت به مدل RF در مدل‌سازی رسوب و شاخص‌های کیفی آب رودخانه‌های خراسان رضوی را نشان داد.

واژه‌های کلیدی: بار رسوب، خراسان رضوی، روش بگینگ، شاخص‌های کیفیت

مقدمه

دقت بیشتر می‌باشد (Khalili., 2021). در زمینه شبیه‌سازی کیفیت آب، مدل‌های زیادی گسترش یافته که نیازمند پارامترهای ورودی بسیاری چون داده‌های هیدرولوژی، هواشناسی و غیره است که دسترسی به آن‌ها نیازمند صرف هزینه و زمان است (Georganos, 2021). با گسترش روزافزون رایانه، استفاده از هوش مصنوعی و روش‌های شبکه عصبی مصنوعی به‌طور گسترده در تخمین پارامترهای کیفی مورد استفاده قرار گرفته است (Urbina, 2022). در علم رسوب‌شناسی، انتقال رسوب در رودخانه پدیده‌ای غیرخطی است؛ و در زمان سیلاب انتقال رسوب، هم از نظر مکان و هم از نظر زمان بسیار فعال‌تر می‌شود، همچنین پارامترهای زمین‌شناسی، هیدرولوژی و مورفولوژیکی حوزه نیز بر میزان انتقال رسوب در رودخانه پیامدهای قابل توجهی دارند (Khan et al., 2019). ذونعمت کرمانی (۲۰۱۶) عنوان داشت که رسوب معلق در مقایسه با رسوب بستر رفتار پیچیده‌تری دارد و مهم‌ترین بخش از بار رسوب رودخانه در نظر گرفته می‌شود. در مهندسی هیدرولیک، قبل از احداث سازه‌ها مانند سدها و مخازن، مطالعه و برآورد حجم رسوب انتقالی موضوع مهمی است و اهمیت خاصی در مدیریت و تصمیم‌گیری نهایی دارد (Khan et al., 2019; Kisi et al., 2004). در سال‌های اخیر پژوهشگران متعددی مطالعات قابل توجهی در زمینه مدل کمی و کیفی آب‌های سطحی

بسیاری از تهدیدات مهم برای منابع آبی، از جمله آلودگی، تغییرات اقلیمی، شهرسازی و تغییرات مناظر طبیعی که هر کدام از آن‌ها اغلب به‌صورت مستقیم بر روی منابع آبی و اکوسیستم تأثیر می‌گذارند از فعالیت‌های انسانی ناشی می‌شود (ONU., 2020). شناسایی مشکلات کمی و کیفی موجود در سیستم‌های پایش منابع آب یکی از مهم‌ترین گام‌های تدوین ساختار طرح‌های مدیریت سیستم‌های منابع آب و اجرای طرح‌های زیست‌محیطی کاهش آلودگی می‌باشد (Liu., 2022). استفاده از برخی روش‌های غیرمستقیم برای شبیه‌سازی پارامترهای کیفی در حجم بالا به‌منظور کاهش هزینه، نیازمند زمان و

۱- دانشجوی دکتری، گروه علوم مهندسی آب، واحد لاهیجان، دانشگاه آزاد اسلامی، لاهیجان، ایران
۲- استاد، گروه مهندسی آب، واحد لاهیجان، دانشگاه آزاد اسلامی، لاهیجان، ایران
۳- استادیار، گروه زمین‌شناسی، واحد لاهیجان، دانشگاه آزاد اسلامی، لاهیجان، ایران
۴- استادیار، گروه کشاورزی، واحد لاهیجان، دانشگاه آزاد اسلامی، لاهیجان، ایران
(* نویسنده مسئول: Email: eamiri57@yahoo.com)

روش طبقه‌بندی تکرار شونده (ICO) به‌عنوان یک تکنیک بهینه جهت گسترش استفاده از مدل‌های RF و PR به‌منظور استفاده در مسائل پیش‌بینی را نشان داد. همچنین نتایج نشان داد که بهینه‌سازی روش RF با ICO عملکرد مدل را تا ۲۷ درصد افزایش می‌دهد.

رودخانه‌های چپ‌چپه، کشف رود، کارده، ارداک و طرق در استان خراسان رضوی که عموماً از مناطق کوهستانی سرچشمه می‌گیرند، بار رسوبی فراوانی را با خود حمل می‌کنند و منجر به انباشت مواد رسوبی در پایین دست رودخانه‌ها می‌گردد. از این رو، هدف از ارائه این پژوهش، مدل‌سازی کیفیت آب و کمیت رسوب و ارائه روابطی جهت پیش‌بینی مقدار آورد رسوب، آنیون و کاتیون رودخانه‌های استان خراسان رضوی با استفاده از دو روش نا پارامتری و غیرخطی GRU، RF و همچنین مقایسه نتایج آن‌ها با یکدیگر می‌باشد.

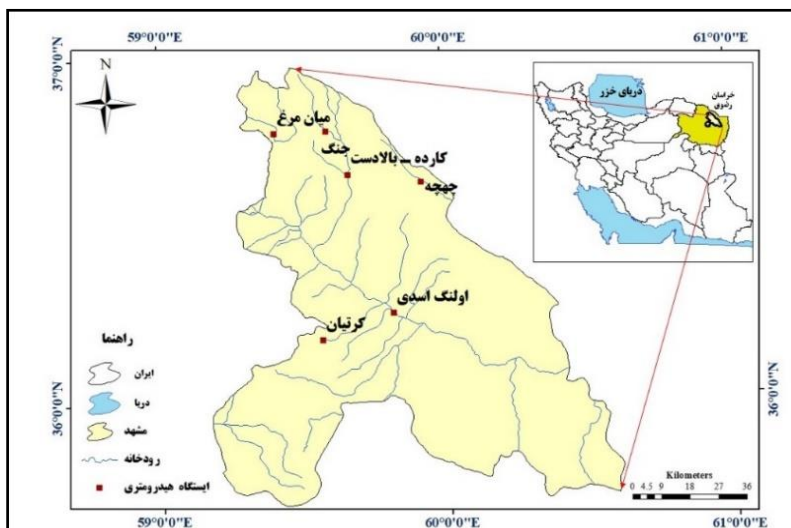
مواد و روش‌ها

معرفی منطقه مورد مطالعه: شهرستان مشهد یکی از زیر حوزه‌های آبریز قره قوم با وسعت $2333/3$ کیلومتر مربع بین طول جغرافیایی 59 درجه و 10 دقیقه و 60 درجه و 34 دقیقه و عرض جغرافیایی 35 درجه و 42 دقیقه و 36 درجه و 58 دقیقه واقع شده است. متوسط ارتفاع شهرستان مشهد 990 متر از سطح دریا می‌باشد. ایستگاه‌های هیدرومتری مورد مطالعه در این شهرستان عبارت‌اند از چپچه (ایستگاه چپچه طبق اطلاعات اخذ شده از شرکت سهامی آب منطقه‌ای خراسان رضوی با مختصات 40.58374 و 76.1414) در محدوده شهرستان مشهد و بر روی رودخانه چپچه واقع شده است. لازم به ذکر است که ایستگاه هیدرومتری چپچه در فاصله 45 کیلومتری از روستای چپچه که در محدوده شهرستان کلات نادری و مرز کشورهای ایران و ترکمنستان واقع شده است، قرار دارد. جنگ، کرتیان، کارده بالادست، میان مرغ و اولنگ‌اسدی که برای دوره آماری سی ساله از سال 1365 تا سال 1395 در نظر گرفته شده است. موقعیت قرارگیری این شش ایستگاه در شکل ۱ مشخص شده است. داده‌های اخذ شده برای هر یک از ایستگاه‌ها به‌صورت ماهانه اندازه‌گیری شده‌اند که در پژوهش حاضر از مقادیر مینیمم، ماکسیمم و میانگین 12 ماهه استفاده گردیده است. در جدول (۱) مقادیر مینیمم، ماکسیمم و میانگین سالانه رسوب معلق و دبی ذکر گردیده است. برای انجام فرآیند مدل‌سازی از دو شبکه واحد بازگشتی دروازه‌دار (GRU) و الگوریتم جنگل تصادفی (RF) استفاده شده است. در بخش اول اقدام به مدل‌سازی داده‌های کیفیت منابع آب و مقدار رسوب در شش ایستگاه مورد مطالعه با استفاده از شبکه عصبی بازگشتی GRU و در بخش دوم هم اقدام به مدل‌سازی با شبکه RF اقدام گردیده است. لازم به ذکر است که به دلیل آماربرداری غیر خودکار و عدم رعایت زمان‌بندی مناسب جهت آماربرداری، همواره در بررسی و

انجام داده‌اند. ابراهیمی و همکاران (۱۴۰۰) عنوان کردند که در مقایسه مدل‌های ماشین بردار و شبکه عصبی تابع شعاعی در پیش‌بینی کیفیت آب سیمینه‌رود، نتایج پژوهش نشان داد که مدل ماشین بردار پشتیبان و شبکه عصبی مصنوعی هر دو از سرعت محاسبه، قابلیت اجرای ساده و دقت بالا برخوردار هستند. محمدی و ابراهیمی (۲۰۱۸)، عنوان کردند که دو مدل شبکه عصبی و مدل‌های استنتاج مقایسه‌ای عصبی فازی دقت بسیار خوبی در شبیه‌سازی برآورد رسانش الکتریکی رودخانه اهر چای نشان دادند. عیسی زاده و همکاران (۱۳۹۸) عنوان کردند که مدل ماشین بردار پشتیبان عملکرد و دقت بیشتری را نسبت به مدل شبکه عصبی مصنوعی در تخمین پارامترهای کیفی آبخوان دشت گیلان نشان داد و همچنین آزمون گاما توانسته است به‌صورت دقیق در تعیین ترکیب ورودی‌های مؤثر مورد استفاده قرار گیرد. جوادی علی نژاد و همکاران (۱۳۹۷) عنوان کردند که در مدل‌سازی تصادفی بار رسوب با استفاده از جنگل تصادفی و رگرسیون چندک، نتایج حاصل نشان داد روش‌های رگرسیون چندک و جنگل تصادفی فقط بار رسوب را در دبی‌های مختلف پیش‌بینی نمی‌کنند بلکه مقدار احتمال آورد رسوب در یک دبی ثابت و عدم قطعیت مقدار بار رسوب شبیه‌سازی شده را پیش‌بینی می‌کنند. سلیمانی ساردوئی و همکاران (۱۴۰۰) عنوان کردند که روش طبقه‌بندی جنگل تصادفی (ضریب کاپا - $0/92$) نسبت به سایر الگوریتم‌ها عملکرد بهتری در استفاده از تصاویر سنیتل - جهت پایش خسارت سیلاب فروردین 1399 ، در جنوب استان کرمان را نشان داد. احمدی و همکاران سال (۱۳۹۹) عنوان کردند که در پیش‌بینی میزان دبی متوسط ماهانه رودخانه کارون با استفاده از روش ترکیبی شبکه عصبی بازگشتی بازنشانی شده و شبکه عصبی حافظه‌ی کوتاه‌مدت طولانی (GRU-LSTM)، رویکرد پیشنهادی در این پژوهش در مقایسه با سایر روش‌های موجود نظیر ماشین بردار پشتیبان، سیستم استنتاج فازی-عصبی تطبیقی و مدل رگرسیون خطی چندگانه نشان‌دهنده دقت بالاتری می‌باشد. سهرابی گشنیگانی و همکاران (۲۰۲۱) عنوان کردند که در مدل‌سازی بارش - رواناب با استفاده از مدل مفهومی بارش - رواناب (HBV)^۱ و الگوریتم جنگل تصادفی در حوضه آبخیز بازفت، نتایج نشان داد که هر دو مدل از عملکرد قابل قبولی در برآورد رواناب روزانه برخوردار بودند. مقایسه نتایج دو مدل نشان داد که مدل RF عملکرد بهتری نسبت به مدل HBV داشت و دقت مدل‌سازی با مدل RF حدود 21 درصد بیشتر از مدل HBV بود. مشرام و همکاران (۲۰۱۹) عنوان کردند که در پیش‌بینی بار رسوب معلق با استفاده از روش طبقه‌بندی تکرار شونده بهینه مبتنی بر روش‌های رگرسیون گام‌به‌گام و جنگل تصادفی در رودخانه سیونا هند، نتایج مدل مبنای رضایت‌بخشی را از به‌کارگیری

نواقصی بودند و از میان اطلاعات اخذشده فقط داده‌های رسوب، دبی، مجموع آنیون و مجموع کاتیون در دوره آماری موردبررسی شرایط کامل‌تری داشتند و در پژوهش مورد استفاده قرار گرفتند.

تحلیل داده‌های برداشت‌شده مشکلاتی از قبیل داده گمشده یا داده پرت وجود دارد و این پژوهش نیز از این قاعده مستثنی نیست. لذا دلیل استفاده از مجموع آنیون و کاتیون‌ها نیز همین موضوع می‌باشد به طوری که داده‌های جزئی هر کدام از پارامترهای کیفی دارای



شکل ۱- موقعیت ایستگاه‌های مورد مطالعه

جدول ۱- پارامترهای آماری ایستگاه‌های مورد مطالعه (شرکت آب منطقه‌ای استان خراسان رضوی)

ایستگاه	پارامتر آماری	دبی (m ³ /sec)	رسوب (ton/day)
	کمینه	۰/۰۰۲	۰/۰۰۶
چپچه	بیشینه	۴۹۳/۰۰	۷۲۵۲۹۸/۶۲
	میانگین	۱۱/۴۳	۲۶۵۸۹/۷۴
	کمینه	۰/۰۱۱	۰/۰۰۳
کرتیان	بیشینه	۷/۵۰	۹۲۵۸/۰۶
	میانگین	۱/۳۱	۲۹۵/۸۳
	کمینه	۰/۰۰۴	۰/۰۰
جنگ	بیشینه	۴۳۸/۰۰	۸۱۷۴/۱۳
	میانگین	۸/۳۲	۱۱۶/۷۲
	کمینه	۰/۰۱۵	۰/۰۰۲
کارده بالادست	بیشینه	۹/۱۳	۷۰۰۴۷/۴۹
	میانگین	۰/۷۹۹	۱۸۷۰/۳۳
	کمینه	۰/۰۰۱	۰/۰۰
میان مرغ	بیشینه	۴/۴۴	۶۷۳/۴۳
	میانگین	۱/۱۴۸	۹۶/۷۴
	کمینه	۰/۰۳۹	۰/۰۳۳
اولنگ اسدی	بیشینه	۶۶/۸۰	۴۸۷۷۴/۱۳
	میانگین	۷/۴۸	۲۴۴۳۰/۴۴

ساختار شبکه GRU مورد استفاده از دو لایه تشکیل شده است. لایه اول، لایه‌های داخلی شبکه GRU است که برابر با ۷ لایه

مدل‌سازی داده‌های کیفیت آب و رسوب با شبکه عصبی بازگشتی GRU

$$z_t = \sigma(W_z[h_{t-1}, x_t]) \quad (3)$$

$$h_t = z_t \hat{h}_t + (1 - z_t) \cdot h_{t-1} \quad (4)$$

در روابط فوق x_t ، h_t و r_t به ترتیب عبارت‌اند از بردار ورودی که در هر گام زمانی به شبکه داده می‌شود، بردار حالت شبکه در هر گام زمانی و سلول حالت. بردار z_t بردار حاصل از اعمال گیت‌های بازگشتی و به‌روزرسانی بر روی بردار ورودی x_t و حالت قبلی h_{t-1} است. بردار z_t نشان‌دهنده میزان حفظ یا حذف اطلاعات در حافظه شبکه در گام زمانی جاری است. W وزن مربوط به هر بردار و از توابع سیگموئید (σ) و تانژانت (\tanh) برای محاسبه ورودی‌هایی که به گیت‌ها و حافظه جدید داده می‌شود، استفاده می‌گردد (Chollet, 2018). مرحله اول در فرآیند مدل‌سازی با شبکه GRU در ایستگاه چپچه ایجاد یک دروازه به‌روزرسانی است. در ابتدا دروازه به‌روزرسانی z_t در زمان t و با استفاده از داده‌های کیفیت به دست آمد که رابطه شماره ۵ می‌باشد. دروازه به‌روزرسانی بر اساس ورودی x_t و حالت پنهان گذشته h_{t-1} تصمیم گرفت که چه اطلاعاتی باید دور ریخته و چه اطلاعات جدیدی را باید در خود جای دهد. هنگامی که x_t به شبکه وصل شد در وزن خود (W_z) ضرب شد. h_{t-1} نیز در وزن خودش (U_z) ضرب شده و این دو باهم جمع شدند. سپس تابع فعال‌ساز سیگموئید نتیجه بین ۰ تا ۱ را تولید می‌کند. دروازه به‌روزرسانی به مدل کمک می‌کند تا چه مقدار از اطلاعات به آینده منتقل شوند. این عمل سبب جلوگیری از مشکل محو‌گردان می‌شود چرا که مدل می‌تواند تصمیم بگیرد تا رونوشتی از همه اطلاعات گذشته داشته باشد. در مرحله دوم دروازه بازنشانی فراهم گردید. در این مرحله از سلول حالت r_t و ورودی x_t جهت تصمیم‌گیری این که چه مقدار از اطلاعات گذشته باید فراموش شوند، استفاده شد. معادله به‌دست‌آمده در این مرحله به شکل زیر است:

$$z_t = \sigma(W_z x_t + U_z h_{t-1}) \quad (5)$$

$$r_t = \sigma(W_r x_t + U_r h_{t-1}) \quad (6)$$

در مرحله سوم محتوای حافظه فعلی حفظ‌شده مشخص گردید که دروازه‌ها چگونه خروجی را تعیین می‌کنند، برای این کار ابتدا یک حافظه جدید که دروازه بازنشانی از آن برای ذخیره‌سازی اطلاعات مربوط به گذشته استفاده می‌کند و معادله به‌صورت رابطه ۷ محاسبه می‌شود. با این کار داده‌های غیرقابل استناد از مرحله قبلی حذف شد. در آخرین مرحله شبکه با محاسبه بردار h_{t-1} تصمیم گرفت که اطلاعات مربوط به حافظه فعلی را در خود نگه‌داشته و به شبکه منتقل کند برای این کار نیاز به دروازه به‌روزرسانی دارد تا تعیین کند که چه اطلاعاتی از محتوای حافظه فعلی h_t و چه چیزی از مرحله قبلی h_{t-1} جمع‌آوری شوند. معادله به‌دست‌آمده از این مرحله معادله شماره ۸ است.

$$\hat{h}_t = \tan(w x_t + r_t \odot U h_{t-1}) \quad (7)$$

انتخاب شد و لایه دوم، لایه‌های مخفی است که تعداد آن برابر با ۱۲۸ لایه قرار داده شد. تعداد داده‌های آموزشی برابر با مقدار ۵۰ آموزش انتخاب شد. در تشریح دلایل انتخاب اعداد ۷، ۱۲۸ و ۵۰ باید بیان داشت که تعداد لایه‌ها، اندازه لایه‌های مخفی و تعداد داده‌های ورودی آموزشی بر اساس میزان دسترسی به داده‌ها، حجم داده‌ها و مدل ساخته‌شده تعیین می‌شود. دلیل انتخاب این سه عدد بهینه‌سازی مناسب و کاهش خطای تجربی مدل در ۷ لایه ورودی، ۱۲۸ لایه مخفی و ۵۰ داده آموزشی نسبت به سایر مقادیر است. طبق مجموعه داده‌های اولیه، ۲ ورودی از طریق کتابخانه متن‌باز یا همان تانسرفلو^۱ در نرم‌افزار پایتون با ابعاد 20×30 به مجموعه شبکه عصبی بازگشتی ورود کردند و خروجی‌های واقعی مدل هم یک تابع Softmax است. همچنین Dropout روشی برای منظم‌سازی است و خطای تعمیم‌پذیری را با کاهش گنجایش مدل کمتر می‌کند؛ بدین ترتیب که در هر دور آموزشی، به‌جای استفاده از همه نورون‌ها، تنها برخی از نورون‌ها فعال می‌شوند. باید بیان داشت که مقدار خطایی که شبکه‌های عصبی روی داده‌های آموزشی به دست می‌آورند بسیار کمتر از خطای آن‌ها روی داده‌های آزمایشی است. به همین دلیل در معرض بیش‌برازش قرار می‌گیرند. برای مقابله با این مسئله، از تکنیک منظم‌سازی استفاده گردید تا گنجایش مدل را کاهش دهد. بدین ترتیب تفاوت بین خطای آموزش و آزمایش کاهش‌یافته و مدل در مراحل آموزش و آزمایش، عملکرد مشابهی از خود نشان خواهد داد که این عمل با استفاده از Dropout انجام می‌شود و مقدار آن برای داده‌هایی با اندازه زیر ۱۰۰۰ برابر با ۰/۵ است (Liu et al., 2021). پارامترهای ورودی به مدل شبکه عصبی بازگشتی GRU برای ایستگاه‌های موردنظر شامل pH، دبی، سختی، شوری، کربنات، بی‌کربنات، کلر، سولفات، کلسیم، منیزیم، سدیم، پتاسیم، نیترات و نسبت جذب سدیم و مجموع کاتیون‌ها است. در این مدل از دو درجه به‌روزرسانی^۲ استفاده شده است. این دو دروازه در اصل دو بردار می‌باشند که با استفاده از آن‌ها تصمیم گرفته می‌شود چه اطلاعاتی از داده‌های کیفیت آب و رسوب به خروجی منتقل شده و چه اطلاعاتی منتقل نشود. دروازه بازنشانی در این مدل در اصل همانند سوپچی عمل می‌کند که شبکه با کمک آن می‌تواند مشخص کند چه میزان از اطلاعات گذشته در گام فعلی موردنیاز نیست (فراموش شود) و در گام فعلی از چه میزان از اطلاعات گام قبل استفاده شود. رابطه‌های موردنیاز در واحد تکراری دروازه‌ای در پژوهش حاضر به‌صورت زیر هستند:

$$\hat{h}_t = \tan(w \cdot [r_t, h_{t-1}, x_t]) \quad (1)$$

$$r_t = \sigma(W_r [h_{t-1}, x_t]) \quad (2)$$

1- TensorFlow

2- update gate

برای تبدیل امتیازها به احتمالات استفاده می‌شود. در شبکه GRU، تابع Softmax برای تبدیل امتیاز حاصل از آخرین لایه خروجی به احتمالات برای هر کلاس مورد استفاده قرار می‌گیرد.

برای انجام فرآیند مدل‌سازی با استفاده از شبکه عصبی بازگشتی GRU در مورد داده‌های مربوط به رسوب، داده‌های اندازه‌گیری شده در بازه زمانی سی‌ساله از سال ۱۳۶۵ تا ۱۳۹۵ استفاده شد. در این بخش هم با استفاده از چهار مرحله دروازه به‌روزرسانی، دروازه بازنشانی، محتوای حافظه فعلی و حافظه نهایی اقدام به مدل‌سازی شد. تابع فعال‌ساز، تانژانت هایپربولیک (Tanh) است. این تابع به تعدیل (Regulate) مقادیری که در طول شبکه در جریان هستند کمک می‌کند. تابع Tanh تمام مقادیر را به بازه -۱ تا ۱ می‌برد. در این فرآیند چیزی به‌نام حالت سلول (Cell State) وجود ندارد و برای انتقال اطلاعات از حالت نهان (Hidden State) استفاده شده است. با توجه به این موضوع که تعداد داده‌های رسوب از مقدار داده‌های کیفیت آب کمتر است، از ساختار زیر برای مدل‌سازی استفاده شد که در شکل ۳ نشان داده شده است.

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \hat{h}_t \quad (8)$$


در نتیجه معادله نهایی برای ایستگاه چهچه به شکل زیر حاصل گردید:

$$\hat{y}_t = \text{soft max} (Vx_t \times z_t h_{t-1} + \epsilon b) \quad (9)$$

به همین ترتیب و با اعمال مراحل تشریح شده بالا برای سایر ایستگاه‌های مورد بررسی، در جدول ۲ مدل نهایی به‌دست آمده برای داده‌های کیفیت آب ایستگاه جنگ، کارده بالادست، کرتیان، میان مرغ و اولنگ اسدی گزارش شده است. در جدول ۲ پارامتر st حالت نهان قبلی را نشان می‌دهد و در هر گام زمانی، حاوی اطلاعاتی از حالت‌های قبلی شبکه است که برای پیش‌بینی حالت بعدی استفاده می‌شود. پارامتر it گیت بازگشتی را نشان می‌دهد که به‌عنوان یک فیلتر برای حذف بخشی از حالت نهان قبلی که بی‌اهمیت است، عمل می‌کند. پارامترهای Uz و Wz وزن‌هایی که برای محاسبه گیت به‌روزرسانی استفاده می‌شود را نشان می‌دهند، گیت به‌روزرسانی تصمیم‌گیری می‌کند آیا اطلاعات جدیدی به حافظه قبلی اضافه شود یا خیر. تابع Softmax در شبکه‌های عصبی، به‌عنوان تابع فعال‌سازی

جدول ۲- مدل نهایی برای داده‌های کیفیت آب ایستگاه جنگ، کارده بالادست، کرتیان، میان مرغ و اولنگ اسدی

ایستگاه مورد مطالعه	مدل نهایی به‌دست آمده
چهچه	$\hat{y}_t = \text{softmax}(Vx_t \times z_t h_{t-1} + \epsilon b)$
جنگ	$\hat{y}_t = \text{softmax}(Wz_{t-1} \times z_t - 1 h_t \times \alpha Uz + \epsilon b)$
کرتیان	$\hat{y}_t = \text{softmax}(Wz \frac{\partial s_t}{\partial Uz} \times a z_t \times \tan(w x_t + r_t) + b r)$
کارده بالادست	$\hat{y}_t = \text{softmax}(Wz \int z_t \odot h_t \times \hat{h}_t \times \tan(z_t - 1) + s t)$
میان مرغ	$\hat{y}_t = \text{softmax}(h_{t-1} \times c t - 1 + z_t \beta 1 \frac{\partial r_t}{\partial r_{t-1}})$
اولنگ اسدی	$\hat{y}_t = \text{softmax}(\sigma (Wz (O_t \odot h_{t-1}) + Uz(st) + Uz(x_t))) + b)$



شکل ۳- ساختار مدل پیشنهادی شبکه GRU برای داده‌های رسوب

جدول ۳- مدل نهایی برای داده‌های رسوب ایستگاه جنگ، کارده بالادست، کرتیان، میان مرغ و اولنگ اسدی

ایستگاه مورد مطالعه	مدل نهایی به دست آمده
چهچه	$\hat{y}_t = \text{softmax}(rtz_t - 1 \times \frac{\partial x_t}{\partial s_t} + it \odot st)$
جنگ	$\hat{y}_t = \text{softmax}(rt\hat{O}_t - 1 \times \sum_i^i h_{t-1} \times \frac{\partial h}{\partial h_t})$
کرتیان	$\hat{y}_t = \text{softmax}(rt Wz + h(zt \odot st, xt))$
کارده بالادست	$\hat{y}_t = \text{softmax}(W_z^t (st - 1 - ht) \odot zt \odot xt)$
میان مرغ	$\hat{y}_t = \text{softmax}(zt ht - 1(1 - zt) + W_z^t x_t + U_z h_{t-1})$
اولنگ اسدی	$\hat{y}_t = \text{softmax}(W_i x_t \odot r_t U_z \odot h_t + \alpha)$

ویژگی‌ها، از میان ویژگی‌های این زیرگروه بهترین ویژگی با بیشترین بهره اطلاعاتی برای رشد درخت انتخاب می‌شود. تعداد این ویژگی‌ها کمتر از تعداد ویژگی‌های اصلی است. هر درخت در جنگل تصادفی با استفاده از الگوریتم درخت تصمیم^۲ و با حداکثر اندازه و بدون هرس رشد می‌کند. در این پژوهش در هر گره از تعداد $[\log 2M] + 1$ استفاده کرده است که در آن M تعداد کل ویژگی‌های ورودی است. جنگل تصادفی یک طبقه‌بند مجموعه‌ای متشکل از طبقه‌بندهای درخت تصمیم است. هر طبقه‌بند برای هر نمونه ورودی به صورت $h(x, \theta_k)$ است که x یک نمونه ورودی و θ_k مجموعه آموزش برای درخت kام است. θ ها مستقل از یکدیگر ولی با توزیع یکسان هستند. برای هر نمونه x هر درخت یک پیش‌بینی برای رده نمونه x ارائه می‌دهد و در نهایت رده‌ای با بیشترین تعداد رأی درختان روی ورودی x به عنوان رده نمونه انتخاب می‌شود. با تشکیل طبقه‌بندی‌هایی از داده‌ها اقدام به تشکیل یک فرآیند تخمین داده‌ها از خارج کیسه (OOB)^۳ شده است. نمونه‌های آموزش در مجموعه داده آموزش اصلی که در مجموعه آموزش طبقه‌بندی k نیست، نمونه‌های خارج از کیسه طبقه‌بندی kام نامیده می‌شود که با استفاده از رابطه زیر حاصل شده است (Breiman, 2001):

$$y(x) = \arg \max_c \left(\frac{1}{k} \sum_{k=1}^k I(h_k(x) = c, x \in \text{OOB}_k) \right) \quad (10)$$

$$I(h_k(x) = c, x \in \text{OOB}_k) = \begin{cases} 1 & h_k(x) = c, x \in \text{OOB}_k \\ 0 & \text{otherwise} \end{cases}$$

که K تعداد درختان، c نشان‌دهنده رده $h_k(x)$ پیش‌بینی درخت kام روی نمونه x را نشان می‌دهند و OOB_k مجموعه نمونه‌های OOB درخت kام می‌باشند. رابطه بالا نشان می‌دهد که مقدار تابع شاخص ۱ خواهد بود اگر x در مجموعه نمونه‌های درخت kام قرار دارد (عضو مجموعه آموزش درخت kام نیست) و همچنین درخت kام نمونه x را به رده c طبقه‌بندی کند. در غیر این صورت، مقدار تابع شاخص صفر می‌شود. برای به دست آوردن تخمین نمونه‌های OOB

با اعمال مراحل تشریح شده برای داده‌های کیفیت آب و مدل‌های حاصل شده برای ایستگاه چهچه، مدل نهایی به دست آمده برای داده‌های رسوب ایستگاه‌های جنگ، کارده بالادست، کرتیان، میان مرغ و اولنگ اسدی به صورت زیر در جدول ۳ حاصل گردیده است.

مدل‌سازی داده‌های کیفیت آب و رسوب با الگوریتم جنگل تصادفی

الگوریتم جنگل تصادفی یک الگوریتم گروهی با مجموعه‌ای از درختان تصمیم است. دو ویژگی مهم در ساخت جنگل‌های تصادفی، روش بگینگ^۱ و انتخاب تصادفی در هر گره است. الگوریتم‌های گروهی در یادگیری ماشین، چند یادگیرنده ضعیف را ترکیب می‌کنند تا به یک یادگیرنده قوی دست یابند. این روش از بیش برآزش داده‌ها جلوگیری می‌کند. در بگینگ نتایج خوب زمانی تولید می‌شود که طبقه‌بندهای پایه جزء الگوریتم‌های یادگیری ناپایدار باشند (مانند درخت تصمیم‌گیری یا شبکه عصبی)، به طوری که تغییرات کوچک در داده‌های آموزشی منجر به تغییرات عمده‌ای در مدل ساخته شده توسط آن الگوریتم شود. یک مجموعه آموزش از داده‌های رسوب و کیفیت آب با نام D و به اندازه $m=50$ تشکیل شد. بگینگ با نمونه‌گیری یکنواخت و با جایگزینی نمونه‌ها از D، m مجموعه آموزشی جدید با اندازه اولیه m تولید می‌کند. نمونه‌گیری با جایگزینی این امکان را می‌دهد که در هر D_i بعضی از نمونه‌ها امکان تکرار داشته باشند. این نوع نمونه‌گیری به عنوان نمونه‌گیری خود راه‌انداز شناخته می‌شود. خروجی ترکیب n مدل با میانگین‌گیری برای رگرسیون و رأی‌گیری برای طبقه‌بندی به دست می‌آید؛ بنابراین با استفاده از نمونه‌گیری دوباره و تولید مجموعه داده‌های مختلف، تنوع مورد نیاز حاصل خواهد شد. در مرحله دوم اقدام به تشکیل و بررسی ویژگی‌های تصادفی شده است. خصوصیت ویژگی‌های تصادفی بدین صورت است که در هر گره از ساخت هر درخت به تصادف یک گروه کوچک از ویژگی‌های ورودی انتخاب می‌شود و برای تقسیم گره به جای جستجو از میان همه

2- Cart

3- Out Of Band

1- Bagging

درخت و برای تقسیم هر گره، یک زیرمجموعه از ویژگی‌های ورودی را به تصادف انتخاب کرده و برای به دست آوردن بهترین ویژگی در گره برای ایجاد شاخه، از معیار بهره اطلاعات استفاده شده است. هر درخت روی جنگل مجموعه نمونه OBB مخصوص به خود را دارد. دقت هر درخت را با استفاده از نمونه‌های OOB آن درخت به دست آورده و آن را به‌عنوان وزن آن درخت در نظر گرفته است. وزن هر درخت از رابطه زیر به دست می‌آید (breiman, 2001):

$$W_k = \frac{\sum_{i=1}^N I(h_k(x_i) = y_i; (x_i, y_i) \in OOB_k)}{\sum_{i=1}^N I((x_i, y_i) \in OOB_k)} \quad (16)$$

مرحله آخر در استفاده از الگوریتم جنگل تصادفی، مرحله آزمایش IRF است. در این مرحله برای ارزیابی الگوریتم از مجموعه داده آزمایشی استفاده شده است که رده نمونه‌های آزمایشی بر اساس وزن درختان جنگل پیش‌بینی می‌شود. برای به دست آوردن رده هر نمونه همه درختان جنگل شرکت دارند و از رابطه ۱۷ استفاده شده است که بر اساس وزن درختان به دست آمده در مرحله آموزش است. برای هر رده c مجموعه وزن درختانی که رده c را برای نمونه x پیش‌بینی می‌کنند به دست می‌آید و سپس رده‌ای با بیشترین میانگین وزن روی درختان به‌عنوان رده آزمایشی در نظر گرفته شده است. در رابطه زیر $y(x)$ رده پیش‌بینی شده توسط جنگل تصادفی بهبودیافته برای نمونه x است، K تعداد درختان و W_k وزن درخت kام است (breiman, 2001)

$$y(x) = \arg \max_c \left\{ \frac{1}{k} \sum_{k=1}^k W_k \cdot I(h_k(x) = c) \right\} \quad (17)$$

در شکل ۴ دیاگرام نحوه فعالیت الگوریتم جنگل تصادفی در مدل‌سازی داده‌های کیفیت آب و رسوب ایستگاه‌های موردبررسی نشان داده شده است (breiman, 2001).

ارزیابی آماری مدل‌ها

برای ارزیابی عملکرد مدل پیشنهادی، میانگین خطای مطلق^۳ (MAE)، درصد میانگین مطلق خطا^۴ (MAPE) و خطای میانگین مربع ریشه^۵ (RMSE) به کاررفته است. این خطاها در ادامه تشریح شده‌اند.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_L - y_L| \quad (18)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_L - y_L}{y_L} \right| \quad (19)$$

$$RMSE = \frac{1}{N} \sum_{i=1}^N (y_L - y_L)^2 \quad (20)$$

روی جنگل از $error_k(OOB)$ در رابطه زیر استفاده می‌شود که خطای طبقه‌بندی جنگل روی نمونه‌های OOB درخت kام می‌باشد (breiman, 2001):

$$I \left((y_i, x_i) \in OOB_k = \begin{cases} 1 & (x_i, y_i) \in OOB_k \\ 0 & (x_i, y_i) \notin OOB_k \end{cases} \right) \quad (11)$$

$$error_k(OOB) = \frac{\sum_{i=1}^N (y(x_i) = y_i; (x_i, y_i) \in OOB_k)}{\sum_{i=1}^N I((x_i, y_i) \in OOB_k)} \quad (12)$$

N تعداد همه نمونه‌های مجموعه آموزش اصلی، x_i نمونه نام روی مجموعه آموزش اصلی، y_i رده واقعی $y(x_i)$ رده پیش‌بینی شده برای x_i است. در رابطه ۱۲ مقدار تابع I یک خواهد بود اگر نمونه (x_i, y_i) متعلق به مجموعه OOB درخت k باشد و در غیر این صورت، صفر است. در جنگل تصادفی برای خطای یک کران بالا در نظر گرفته می‌شود. دو پارامتر برای این کران بالا اندازه‌گیری می‌شود. پارامتر اول قدرت طبقه‌بندی فردی و پارامتر دوم، وابستگی بین درختان جنگل است.

$$PE^* \leq \rho(1 - S^2) / S^2 \quad (13)$$

در رابطه S قدرت طبقه‌بندی فردی در جنگل و ρ وابستگی بین درختان جنگل را نشان می‌دهد. بر اساس این رابطه برای خطای PE^* هرچه مقدار S بیشتر و مقدار ρ کمتر باشد میزان خطا نیز کمتر خواهد بود. نسبت $\frac{\rho}{S^2}$ برای جنگل تصادفی در درک عملکرد آن یک راهنمای مفید است. این نسبت تقسیم وابستگی بر مربع قدرت است و هر چه کوچک‌تر باشد عملکرد جنگل بهتر و خطا نیز کمتر است. در ساخت الگوریتم جنگل تصادفی در پژوهش حاضر از دو معیار بهره اطلاعات و مرحله آموزش استفاده شده است که روابط به دست آمده در ادامه تشریح شده است. بهره اطلاعات (IG)^۱ برای یک ویژگی نظیر A نسبت به مجموعه نمونه‌های S در رابطه ۱۴ تعریف می‌شود که در آن Values(A) مجموعه همه مقدار ویژگی های A بوده و SV زیرمجموعه‌ای از S است که برای آن ویژگی A دارای مقدار v است. $|S_v|$ تعداد نمونه‌ها با مقدار v روی ویژگی A در مجموعه S و $|S|$ تعداد کل نمونه‌ها روی مجموعه S است.

$$Information\ Gain(S, A) = Entropy(S) - \sum_{v \in Values(A)} \left[\frac{|S_v|}{|S|} Entropy(S) \right] \quad (14)$$

$$Entropy(S) = \sum_{i=1}^{numclass} -p_i \log_2 p_i \quad (15)$$

p_i نسبت نمونه‌ها در S که به رده نام تعلق دارد، می‌باشد. مرحله آموزش (IRF)^۲: در فرآیند ایجاد جنگل، در ساخت هر

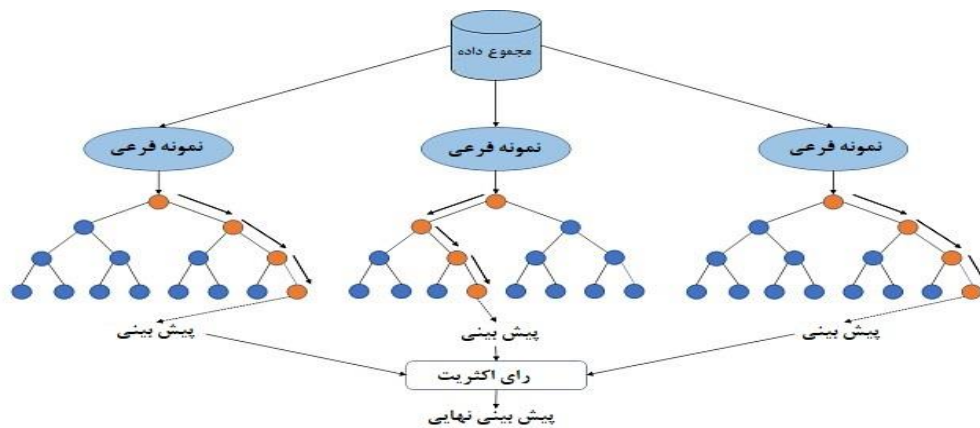
3- Mean Absolute Error

4- Mean Absolute Percentage Error

5- Root Mean Square Error

1- Information Gain

2- Iterative Random Forestes



شکل ۴- دیاگرام نحوه فعالیت الگوریتم جنگل تصادفی در مدل سازی داده های کیفیت آب و رسوب ایستگاه های مورد بررسی

پیش بینی بهتر است.

نتایج و بحث

در جدول ۴ نتایج به دست آمده برای میانگین خطای مطلق (MAE) مربوط به داده های کیفیت آب (مجموع آنیون و کاتیون) برای شبکه مورد بررسی نشان داده شده است. با توجه به اینکه مبنای محاسبه MAE، تفاوت مطلق بین مقادیر پیش بینی و واقعی است، بنابراین MAE همواره مقداری مثبت است. مقدار کمتر MAE به معنی دقت بیشتر الگوریتم پیش بینی می باشد (Salem, 2022). مقدار MAE برای ایستگاه های چهچه، جنگ، کرتیان، کارده بالادست، میان مرغ و اولنگ اسدی در شبکه GRU به ترتیب برابر با ۰/۰۲۵، ۰/۰۲۳، ۰/۰۱۱۴، ۰/۰۲۶۷، ۰/۰۰۳، ۰/۰۳۱۸، ۰/۰۴۴۹ و ۰/۰۲۸۷/۷۵۶ در الگوریتم RF به ترتیب برابر با ۰/۰۲۹۶، ۰/۰۳۶۱، ۰/۰۳۴۴، ۰/۰۳۲۸، ۰/۰۰۶۴، ۰/۰۳۶۷/۱۱۲ و ۰/۰۴۰۱/۰۹۶ حاصل شده است.

درصد میانگین مطلق خطا (MAPE) همانند MAE، یکی از معیارهای ارزیابی در مسائل پیش بینی و رگرسیون است، با این تفاوت که به جای مقدار مطلق خطا، درصد مطلق خطا را محاسبه می کند. MAPE برای اندازه گیری میزان تفاوت بین مقادیر پیش بینی شده و واقعی یک متغیر پیوسته درصدی استفاده می شود. مقدار کمتر MAPE به معنی دقت بیشتر الگوریتم در پیش بینی است (Salem, 2022). در جدول ۵ نتایج به دست آمده درصد میانگین مطلق خطا (MAPE) داده های کیفیت آب در شبکه مورد بررسی ارائه گردیده است مقدار MAPE برای ایستگاه های چهچه، جنگ، کرتیان، کارده بالادست، میان مرغ و اولنگ اسدی در شبکه GRU به ترتیب برابر با ۰/۰۶۲۰، ۰/۰۷۱۱، ۰/۰۵۹۷، ۰/۰۷۹۵، ۰/۰۶۶۴، ۰/۰۵۱۸ و ۰/۰۰۹۲۷، ۰/۰۷۷۲، ۰/۰۰۹۶۶، ۰/۰۰۸۶۴، ۰/۰۰۹۳۳ و ۰/۰۰۸۱۱ حاصل شده است.

که در آن N اندازه آموزش یا نمونه های آزمون است و y_1 و y_L به ترتیب مقدار پیش بینی شده و مقدار واقعی هستند. در این روابط، MAE میانگین خطاهای مطلق بین مقادیر پیش بینی شده و مقادیر واقعی است که نشان دهنده خطای واقعی مقدار پیش بینی شده است. MAPE همچنین نسبت بین خطا و مقدار واقعی را در نظر می گیرد. RMSE نشان دهنده انحراف استاندارد نمونه از تفاوت بین مقادیر پیش بینی شده و مقادیر مشاهده شده واقعی است. دامنه تغییرات MAE و RMSE بستگی به مجموعه داده هایی دارد که بر روی آن اعمال می شود و دامنه تغییرات MAPE بین صفر و یک است. هر چه مقادیر MAE، MAPE و RMSE کوچک تر باشد، عملکرد مدل ها در پیش بینی بهتر است. لازم به ذکر است که این سه شاخص بدون بعد هستند (Salem, 2022). آزمون و صحت سنجی شبکه های عصبی مصنوعی برای ارزیابی کیفیت و دقت پیش بینی شبکه های عصبی و همچنین بررسی خطای شبکه ها استفاده می شود. در این پژوهش برای آزمون و صحت سنجی شبکه های مورد استفاده از تقسیم داده ها به دو بخش آموزش و آزمایش استفاده شده است. در این روش، داده های موجود به دو بخش تقسیم می شوند، بخش اول برای آموزش شبکه و بخش دوم برای آزمایش و ارزیابی شبکه استفاده می شود. در این روش، بهتر است تعداد داده های موجود در بخش آزمایش به اندازه کافی بزرگ باشد تا دقت ارزیابی بهتر شود. در این پژوهش تقسیم داده ها به دو مجموعه آموزشی و آزمایشی، به نسبت ۷۰ به ۳۰ انجام شد. در این پژوهش برای ارزیابی صحت تقسیم داده ها، از مقادیر ضریب تعیین (R^2) استفاده شد که این مقدار در ارزیابی عملکرد مدل های پیش بینی شده و نشان دادن میزان تطابق بین داده های واقعی و پیش بینی شده توسط مدل استفاده می شود. مقدار R^2 بین ۰ تا ۱ قرار می گیرد. مقدار ۱ بیانگر تطابق کامل بین داده های واقعی و پیش بینی شده توسط مدل است، در حالی که مقدار صفر به معنی عدم تطابق است. هر چه مقدار R^2 به ۱ نزدیک تر باشد، دقت مدل در

جدول ۴- نتایج میانگین خطای مطلق (MAE) برای داده کیفیت آب در شش ایستگاه موردسنجش

RF	GRU	ایستگاه مورد مطالعه
۲۹۶/۱۱۹	۲۲۳/۰۲۵	چهچه
۳۶۱/۳۴۴	۳۱۹/۱۱۴	جنگ
۳۲۸/۰۶۴	۲۶۷/۴۴۲	کرتیان
۳۶۷/۱۱۲	۳۰۱/۰۰۳	کارده بالادست
۴۰۱/۰۹۶	۳۱۸/۶۴۹	میان مرغ
۳۴۴/۵۰۹	۲۸۷/۷۵۶	اولنگ اسدی

جدول ۵- نتایج میانگین خطای مطلق (MAPE) برای داده کیفیت آب

مربوط به شش ایستگاه موردسنجش		
RF	GRU	ایستگاه مورد مطالعه
۰/۰۸۶۴	۰/۰۶۲۰	چهچه
۰/۰۹۶۶	۰/۰۷۱۱	جنگ
۰/۰۷۷۲	۰/۰۵۹۷	کرتیان
۰/۰۹۲۷	۰/۰۷۹۵	کارده بالادست
۰/۰۸۱۱	۰/۰۶۶۴	میان مرغ
۰/۰۹۳۳	۰/۰۵۱۸	اولنگ اسدی

مقایسه مقادیر MAE, MAP, RMSE برای مدل‌سازی داده‌های کیفیت آب با استفاده از دو شبکه GRU و الگوریتم RF بر اساس نتایج ارائه شده در جداول ۴، ۵ و ۶ نشان می‌دهد که همواره مدل GRU نسبت به مدل RF از مقادیر کمتری برخوردار می‌باشد که این موضوع دقت بالاتر شبکه عصبی بازگشتی نسبت به الگوریتم جنگل تصادفی را در مدل‌سازی و پیش‌بینی مقادیر داده‌های کیفیت آب نشان می‌دهد. جدول ۷ نتایج به‌دست‌آمده MAE برای داده‌های رسوب توسط شبکه‌های موردبررسی را نشان داده است. مقدار MAE برای ایستگاه‌های چهچه، جنگ، کرتیان، کارده بالادست، میان مرغ و اولنگ اسدی در شبکه GRU به ترتیب برابر با ۱۹۶/۳۲۸، ۱۶۷/۲۰۸، ۲۰۶/۳۳۸، ۲۶۱/۰۸۹، ۱۷۵/۶۶۷ و ۲۴۴/۳۱۹، ۲۲۱/۰۳۴، ۲۷۱/۱۴۶، ۲۶۶/۰۷۹، ۳۱۶/۱۸۴ و ۲۴۶/۱۱۰ حاصل شده است.

جدول ۷- نتایج میانگین خطای مطلق (MAE) برای داده‌های رسوب

شش ایستگاه موردسنجش		
RF	GRU	ایستگاه مورد مطالعه
۲۶۶/۰۷۹	۱۹۶/۳۲۸	چهچه
۲۷۱/۱۴۶	۱۶۷/۲۰۸	جنگ
۲۲۱/۰۳۴	۲۰۶/۳۳۸	کرتیان
۲۴۴/۳۱۹	۱۷۵/۶۶۷	کارده بالادست
۳۱۶/۱۸۴	۲۶۱/۰۸۹	میان مرغ
۲۴۶/۱۱۰	۱۹۶/۰۷۹	اولنگ اسدی

نتایج درصد میانگین خطای مطلق (MAPE) برای داده‌های رسوب توسط شبکه‌های موردبررسی در جدول ۸ ارائه شده است. مقدار MAPE برای ایستگاه‌های چهچه، جنگ، کرتیان، کارده بالادست، میان مرغ و اولنگ اسدی در شبکه GRU به ترتیب برابر با ۰/۳۵۲، ۰/۴۴۲، ۰/۶۱۹، ۰/۷۵۱، ۰/۵۵۶ و ۰/۶۱۹ و برای شبکه الگوریتم RF به ترتیب برابر با ۰/۸۸۶، ۰/۸۹۴، ۰/۹۵۳، ۰/۹۴۷، ۰/۸۶۶ و ۰/۹۰۳ حاصل شده است.

RMSE نیز یکی از معیارهای متداول در مسائل پیش‌بینی و رگرسیون است. RMSE مشابه MAE است، با این تفاوت که به جای میانگین مطلق خطا، میانگین مربعات مطلق خطا را محاسبه می‌کند. RMSE به‌عنوان یکی از معیارهای پر استفاده در مسائل پیش‌بینی، بیشترین تأثیر را بر روی نمونه‌های پرت و دور از میانگین دارد. مقدار کمتر RMSE به معنی دقت بیشتر الگوریتم پیش‌بینی است (Salem, 2022). جدول ۶ نتایج به‌دست‌آمده میانگین خطای مربعات مطلق (RMSE) در مورد داده‌های کیفیت آب برای شبکه‌های موردبررسی را نشان داده است. مقدار RMSE برای ایستگاه‌های چهچه، جنگ، کرتیان، کارده بالادست، میان مرغ و اولنگ اسدی در شبکه GRU به ترتیب برابر با ۱۶۸۵/۵۱۹، ۱۵۵۶/۰۳۴، ۱۸۲۶/۱۶۴، ۱۶۳۷/۰۰۶، ۱۷۳۳/۲۷۴ و ۱۶۷۴/۰۹۷ و در الگوریتم RF به ترتیب برابر با ۲۰۱۶/۰۷۸۴، ۱۹۶۴/۸۶۴، ۱۹۶۳/۰۷۹، ۱۸۳۴/۱۷۷، ۱۹۸۳/۰۱۹ و ۱۹۶۳/۴۴۶ حاصل شده است.

جدول ۶- نتایج میانگین خطای مطلق (RMSE) برای داده‌های

کیفیت آب در شش ایستگاه موردسنجش		
RF	GRU	ایستگاه مورد مطالعه
۲۰۱۶/۰۷۸۴	۱۶۸۵/۵۱۹	چهچه
۱۹۶۴/۸۶۴	۱۵۵۶/۰۳۴	جنگ
۱۹۶۳/۰۷۹	۱۸۲۶/۱۶۴	کرتیان
۱۸۳۴/۱۷۷	۱۶۳۷/۰۰۶	کارده بالادست
۱۹۸۳/۰۱۹	۱۷۳۳/۲۷۴	میان مرغ
۱۹۶۳/۴۴۶	۱۶۷۴/۰۹۷	اولنگ اسدی

جدول ۸- نتایج درصد میانگین خطای مطلق (MAPE) برای داده‌های

ایستگاه مورد مطالعه	GRU	RF
چهچه	۰/۳۵۲	۰/۸۸۶
جنگ	۰/۴۴۲	۰/۸۹۴
کرتیان	۰/۶۱۹	۰/۹۵۳
کارده بالادست	۰/۷۵۱	۰/۹۴۷
میان مرغ	۰/۵۵۶	۰/۸۶۶
اولنگ اسدی	۰/۶۱۹	۰/۹۰۳

آنیون‌ها نشان داده شده است. در نمودارهای ذیل، محور افقی داده‌های واقعی اندازه‌گیری شده و محور عمودی داده‌های تخمین زده شده توسط شبکه عصبی GRU و RF برای شاخص رسوب و مجموع کاتیون‌ها و آنیون‌های مورد بررسی است.

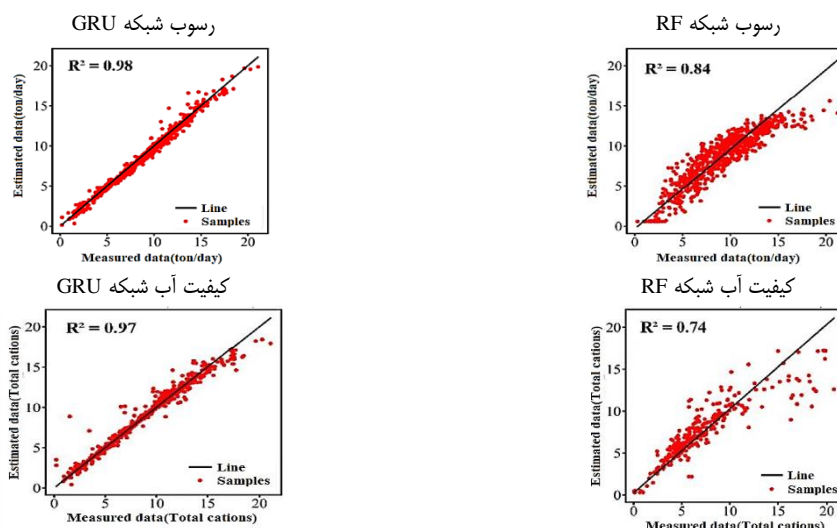
جدول ۹- نتایج میانگین خطای مطلق (RMSE) برای داده‌های

ایستگاه مورد مطالعه	GRU	RF
چهچه	۱۴۲۵/۰۶۴	۱۶۸۰/۱۶۶
جنگ	۱۳۹۶/۱۳۳	۱۴۲۱/۰۲۲
کرتیان	۱۳۸۵/۰۵۶	۱۴۲۳/۱۹۹
کارده بالادست	۱۵۵۲/۱۹۸	۱۷۴۲/۲۲۸
میان مرغ	۱۴۶۲/۱۲۸	۱۵۶۷/۰۳۱
اولنگ اسدی	۱۳۸۶/۰۹۹	۱۴۳۳/۱۱۸

نتایج به دست آمده نشان داده است که نمودار R^2 برای داده‌های مربوط به رسوب و کیفیت آب در شبکه عصبی GRU نسبت به الگوریتم RF مقادیر نزدیک تری به عدد ۱ دارند که این موضوع نشان دهنده دقت بالای شبکه عصبی GRU در پیش‌بینی مقادیر کیفیت و رسوب برای ایستگاه‌های مورد بررسی است. به‌طور کلی، شبکه عصبی GRU از وزن‌هایی که به‌صورت شبکه‌های عصبی کوچک درونی در بلوک تعریف شده‌اند برای یادگیری و به‌روزرسانی وزن‌ها استفاده می‌کند که همین امر باعث بالا رفتن میزان تحلیل داده‌های استفاده شده می‌شود.

نتایج خطای مطلق (RMSE) برای مدل‌سازی داده‌های رسوب توسط شبکه‌های مورد بررسی در جدول ۹ نشان داده شده است. مقدار RMSE برای ایستگاه‌های چهچه، جنگ، کرتیان، کارده بالادست، میان مرغ و اولنگ اسدی در شبکه GRU به ترتیب برابر با ۱۴۲۵/۰۶۴، ۱۳۹۶/۱۳۳، ۱۳۸۵/۰۵۶، ۱۵۵۲/۱۹۸، ۱۴۶۲/۱۲۸ و ۱۳۸۶/۰۹۹ در الگوریتم RF به ترتیب برابر با ۱۶۸۰/۱۶۶، ۱۴۲۱/۰۲۲، ۱۴۲۳/۱۹۹، ۱۷۴۲/۲۲۸، ۱۵۶۷/۰۳۱ و ۱۴۳۳/۱۱۸ حاصل شده است.

نتایج مقایسه میان مقادیر عددی به دست آمده برای MAE، MAPE و RMSE در شبکه GRU نسبت به الگوریتم RF نشان می‌دهد که شبکه GRU از مقادیر کمتری برخوردار هستند که این موضوع دقت بالاتر این شبکه عصبی بازگشتی نسبت به الگوریتم جنگل تصادفی را در مدل‌سازی و پیش‌بینی مقادیر داده‌های رسوب نشان می‌دهد. در شکل ۵ نمودارهای به دست آمده برای مقادیر R^2 در داده‌های رسوب و کیفیت آب مربوط به شاخص مجموع کاتیون‌ها و



شکل ۵- نمودارهای همبستگی میان داده‌های رسوب و کیفیت آب با شبکه‌های عصبی GRU و RF

می‌گذارد. این میانبرها به همین صورت به خطای تولیدی اجازه می‌دهد تا بدون آنکه خیلی سریع محو شود به راحتی در فاز پس انتشار منتقل گردد و این‌طور معضلات مرتبط با گرادیان‌های محو شونده کاهش می‌یابد. در پژوهشی دیگر Liu و همکاران (۲۰۱۹) در پژوهش خود بر قدرت دو شبکه عصبی بازگشتی شامل LSTM و GRU در پیش‌بینی کیفیت منابع آبی تأکید داشتند که این نتیجه، با یافته‌های پژوهش حاضر مطابقت داشت. در دلیل این کارایی باید بیان داشت که شبکه می‌تواند به حالت مابینی و حتی به‌عکس این مهم دست پیدا کند که این فرآیند با فاصله گرفتن از اعداد منفی و گرایش به سمت ۱ و بیشتر انجام می‌شود. البته می‌توان با میل وزن‌ها به سمت صفر و بایاس به سمت منفی به همین مهم دست پیدا کرد. همچنین در پژوهشی دیگر، Zhou و همکاران (۲۰۲۲) بیان داشتند که شبکه GRU کارایی بسیار مناسبی در پیش‌بینی کیفیت آب و داده‌های رسوب در منطقه بیجینگ چین دارد.

نتیجه‌گیری

هدف از انجام این پژوهش مدل‌سازی داده‌های کیفیت آب رودخانه و مقدار رسوب در شش ایستگاه چپه‌چ، جنگ، کرتیان، کارده بالادست، میان مرغ و اولنگ اسدی استان خراسان رضوی بود. برای انجام فرآیند مدل‌سازی از دو شبکه واحد بازگشتی دروازه‌دار (GRU) و الگوریتم جنگل تصادفی (RF) استفاده شد. برای ارزیابی عملکرد مدل پیشنهادی، میانگین خطای مطلق (MAE)، درصد میانگین مطلق خطا (MAPE) و خطای میانگین مربع ریشه (RMSE) استفاده شد که نتایج به‌دست‌آمده نشان داد میزان دقت و کارایی شبکه عصبی GRU در پیش‌بینی میزان رسوب و کیفیت آب ایستگاه‌های موردبررسی بیشتر از الگوریتم RF است زیرا مقادیر به‌دست‌آمده برای شاخص‌های ارزیابی در شبکه عصبی GRU از مقادیر RF کمتر است. در این پژوهش برای آزمون و صحت‌سنجی شبکه‌های مورداستفاده از تقسیم داده‌ها به دو بخش آموزش و آزمایش استفاده شده است و تقسیم داده‌ها به دو مجموعه آموزشی و آزمایشی، به نسبت ۷۰ به ۳۰ انجام شد. در این پژوهش برای ارزیابی صحت تقسیم داده‌ها، از مقادیر ضریب تعیین (R^2) استفاده شد که نتایج نشان داد نمودار R^2 برای شبکه عصبی GRU نسبت به الگوریتم RF در داده‌های مربوط به رسوب و کیفیت آب دارای مقادیر نزدیک‌تری نسبت به ۱ است که این موضوع نشان‌دهنده دقت بالای شبکه عصبی GRU است. در نتیجه باید بیان داشت که شبکه GRU نسبت به الگوریتم RF، قابلیت یادگیری مدل‌های پیچیده‌تری را دارد. در واقع، شبکه GRU با استفاده از لایه‌های پنهان پیچیده، قابلیت یادگیری الگوهای پیچیده‌تری را دارد. همچنین این شبکه نسبت به الگوریتم RF، مقاومت به تغییرات زمانی بیشتری دارد. در واقع، شبکه GRU با

در شبکه GRU دروازه‌های به‌روزرسانی باعث می‌شود که خروجی نهایی تابع فعال‌سازی را تغییر دهد. نقش بایاس، مشابه نقش مقدار ثابت در تابع خطی است و مقدار نهایی تابع فعال‌سازی را در فضای برداری به چپ و راست منتقل می‌کند تا تابع نهایی بر روی داده‌ها بهتر منطبق شود و مدل در نهایت پیش‌بینی دقیق‌تری داشته باشد. دلیل قدرت بیشتر شبکه GRU نسبت به الگوریتم RF این است که شبکه عصبی GRU مکانیزمی جهت کنترل میزان اطلاعات منتقل‌شده از گام قبل را ندارد و همیشه حالت قبلی را به‌صورت کامل مورداستفاده قرار می‌دهد. این مسئله با ارائه دروازه جدید که منحصراً نقش این مکانیزم را ایفا می‌کند مرتفع شد. دروازه بازنشانی در اصل همانند سوئیچی عمل می‌کند که شبکه با کمک آن می‌تواند مشخص کند چه میزان از اطلاعات گذشته در گام فعلی موردنیاز نیست و در گام فعلی از چه میزان از اطلاعات گام قبل استفاده شود. به‌طور دقیق‌تر با صفر بودن این سوئیچ، دروازه در عمل شبکه را وادار می‌کند به‌گونه‌ای عمل کند که گویا در حال خواندن اولین بخش از دنباله ورودی است و این‌طور شبکه را قادر به فراموشی حالت محاسبه‌شده قبلی می‌کند و به همین صورت می‌تواند بافاصله گرفتن از صفر، حالت مابینی را فراهم آورد. با کمک این دو قابلیت شبکه عصبی GRU به راحتی می‌تواند نسبت به ذخیره‌سازی فیلتر کردن اطلاعات از گام‌های زمانی قبلی اقدام کرده و از دنباله‌های طولانی که الگوریتم‌های عصبی مثل RF در مواجهه با آن با مشکلات عدیده‌ای مواجه هستند، بهره‌برداری کند و کاستی‌های الگوریتم RF را مرتفع سازد (Chung et al., 2014). این نتایج با یافته‌های پژوهش Xu و همکاران (۲۰۲۱) مطابقت داشت. این محققین در پژوهش خود بیان داشتند که مدل واحد بازگشتی GRU به‌عنوان یک رمزگذار و رمزگشا و یک ماشین فاکتور سازی (FM) در مدل ادغام‌شده است تا مشکل پراکندگی بالا و تعامل ویژگی‌های ابعادی بالا در داده‌ها را حل کند که نتایج از قدرت شبکه بازگشتی GRU در پیش‌بینی مقادیر DO (اکسیژن محلول در آب) داشت. همچنین در پژوهشی دیگر Ye و همکاران (۲۰۱۹) در پژوهش خود به این نتیجه دست یافتند که شبکه‌های عصبی بازگشتی مانند GRU دارای قدرت بالایی در پیش‌بینی کیفیت منابع آب و داده‌های رسوب است. این محققین بیان داشتند که در شبکه‌های GRU استفاده از دروازه بازنشانی باعث می‌گردد که کارایی این شبکه توسعه پیدا کند. همچنین Wang و همکاران (۲۰۲۰) در پژوهش خود بیان داشتند که در شبکه‌های عصبی بازگشتی هر واحد می‌تواند وجود یک ویژگی خاص در جریان ورودی را برای گام‌های زمانی طولانی بعدی به یاد داشته باشد. هر ویژگی‌ای که توسط دروازه به‌روزرسانی GRU مهم تشخیص داده شود می‌تواند بدون اینکه رونویسی شده و از دست برود، حفظ شود. نکته دوم و شاید مهم‌تر اینکه این قابلیت جدید در عمل مسیرهای میانبری ایجاد می‌کند که چندین گام زمانی را ندید گرفته و پشت سر

Geophysica. 66(5): 1131-1150.

Abda, Z., Chettih, M. and Zerouali, B. 2021. Assessment of neuro-fuzzy approach based different wavelet families for daily flow rates forecasting. *Modeling Earth Systems and Environment*. 7(3): 1523-1538.

Bajirao, T. S., Kumar, P., Kumar, M., Elbeltagi, A. and Kuriqi, A. 2021. Superiority of hybrid soft computing models in daily suspended sediment estimation in highly dynamic rivers. *Sustainability*. 13(2): 542.

Breiman, L. 2001. Random forests. *Machine learning*. 45: 5-32.

Chollet, F. 2018. *Deep learning with Python*. Manning Publications.

Chung, J., Caglar, G., Cho, K. and Bengio, Y. 2014. Empirical evaluation of gated recurrent neural networks on sequence modeling. *ArXiv preprint: 1412.3555*.

Fu, R., Zhang, Z. and Li, L. 2017. Using LSTM and GRU neural network methods for traffic flow prediction. In: *Youth Academic Conference of Chinese Association of Automation*.

Georganos, S., Grippa, T., Gadiaga, A. N., Linard, C., Lennert, M., Vanhuyse, S., Mboga, N., Wolff, E. and Kalogirou, S. 2021. Geographical Random Forests: A Spatial Extension of the Random Forest Algorithm to Address Spatial Heterogeneity in Remote Sensing and Population Modelling. *Geocarto International*. 36(2): 121-136.

Khalili, R., Montaseri, H. and Motaghi, H. 2021. Evaluation of Water Quality in the Chalus River Using the Statistical Analysis and Water Quality Index (WQI). *Water and Soil Management and Modelling. Water and Soil Management and Modelling*. 1(3): 38-52.

Khan, M. Y. A., Tian, F., Hasan, F. and Chakrapani, G. J. 2019. Artificial neural network simulation for prediction of suspended sediment concentration in the River Ramganga, Ganges Basin, India. *International journal of sediment research*. 34(2): 95-107.

Liu, B., Fu, C., Bielefield, A. and Liu, Y. Q. 2021. Forecasting of Chinese Primary Energy Consumption in 2021 with GRU Artificial Neural Network. *Energies*. 10(100): 1453-2017.

Liu, Y., Lei W., G.U, K. and Li, M. 2022. Artificial Neural Network (ANN)-Bayesian Probability Framework (BPF) Based Method of Dynamic Force Reconstruction under Multi-Source Uncertainties. *Knowledge-Based Systems*. 237:107796.

Liu, P., Wang, J., Sangaiah, A.K., Xie, Y. and Yin, X.

استفاده از حافظه بازگشتی خود، قابلیت فهم تاریخچه دنباله و تأثیر آن بر توانایی پیش‌بینی را دارد. همچنین شبکه GRU نسبت به الگوریتم RF، قابلیت پیش‌بینی در زمان واقعی بیشتری را دارد. شبکه GRU با استفاده از حافظه بازگشتی خود، قابلیت پیش‌بینی به‌صورت پویا و در زمان واقعی را نیز دارد.

منابع

احمدی، پ.، عارفی، ح. و کاردان، ن. ۱۳۹۹. پیش‌بینی میزان دبی متوسط ماهیانه رودخانه کارون با استفاده از روش ترکیبی GRU-LSTM. *نشریه اکو هیدرولوژی*. ۷ (۳): ۶۳۳-۶۱۹.

جوادی علی نژادی، م.، سیدیان، م.، روحانی، ح. و فتح‌آبادی، ا. ۱۳۹۶. مدل‌سازی تصادفی بار رسوب با استفاده از جنگل تصادفی و رگرسیون چندک. *نشریه پژوهش‌های حفاظت آب‌و‌خاک*. ۲۴ (۴): ۱۰۳-۱۲۲.

حسین پناهی، ب.، نیک مهر، س. و ابراهیمی، ک. ۱۴۰۰. مقایسه مدل‌های ماشین بردار و شبکه عصبی تابع پایه شعاعی در پیش‌بینی کیفیت آب سیمینه‌رود. *نشریه مدیریت آب و آبیاری*. ۱۱ (۳): ۴۰۹-۴۱۱.

سلیمانی ساردو، ف.، رفیعی ساردوئی، ا.، مصباح زاده، ط. و آذر، ع. ۱۴۰۰. استفاده از تصاویر سنتینل ۱- جهت پایش خسارت سیلاب فروردین ۱۳۹۹، جنوب استان کرمان بر اساس الگوریتم جنگل تصادفی. *مجله علوم و مهندسی آبخیزداری ایران*. ۱۵ (۵۳): ۳۳-۳۲.

سهرابی گشنیگانی، ف.، میرعباسی نجف‌آبادی، ر. و گلابی، م. ۱۴۰۰. مدل‌سازی بارش - رواناب با استفاده از مدل HBV و الگوریتم جنگل تصادفی در حوضه آبخیز بازفت. *نشریه علمی پژوهشی تحقیقات آب‌و‌خاک ایران*. ۵۲ (۵): ۱۴۰۷-۱۳۹۵.

عیسی زاده، م.، بی‌آزار، س. م.، اشرف زاده، ا. و خانجانی، ر. ۱۳۹۸. تخمین پارامترهای کیفی آبخوان دشت گیلان با استفاده از آزمون گاما و مدل‌های ماشین بردار پشتیبان و شبکه عصبی مصنوعی. *نشریه علوم و تکنولوژی محیط‌زیست*. ۲۱ (۲): ۲۱-۱.

محمدی، پ. و ابراهیمی، ک. ۱۳۹۷. تخمین هدایت الکتریکی رودخانه اهر چای با استفاده از مدل‌های شبکه عصبی و استنتاج فازی - عصبی تطبیقی. *هفدهمین کنفرانس هیدرولیک ایران*. شهریور ماه. دانشگاه شهرکرد.

Abda, Z. and Chettih, M. 2018. Forecasting daily flow rate-based intelligent hybrid models combining wavelet and Hilbert-Huang transforms in the mediterranean basin in northern Algeria. *Acta*

2022. Dual Use of Artificial-Intelligence-Powered Drug Discovery. *Nature Machine Intelligence*. 4(3):189–91.
- Wang, R., Peng, C., Gao, J., Gao, Z. and Jiang, H. 2020. A dilated convolution network-based LSTM model for multi-step prediction of chaotic time series. *Computational and Applied Mathematics*. 39: 30.
- Xu, J., Wang, K., Lin, C., Xiao, L., Huang, X. and Zhang Y. 2020. FM--GRU: A Time Series Prediction Method for Water Quality Based on seq2seq Framework. *Water*. 13(8): 1031.
- Ye, Q., Yang, X., Chen, C. and Wang, J. River Water Quality Parameters Prediction Method Based on LSTM-RNN Model. In Proceedings of the 2019 Chinese Control In addition, Decision Conference (CCDC), Nanchang, China, 3–5 June 2019; pp. 3024–3028.
- Zounemat-Kermani, M., Kişi, Ö., Adamowski, J. and Ramezani-Charmahineh, A. 2016. Evaluation of data driven models for river suspended sediment concentration modeling. *Journal of Hydrology*. 535: 457-472.
- Zhou, S., Song, C., Zhang, J., Chang, W., Hou, W. and Yang, L. 2022. A Hybrid Prediction Framework for Water Quality with Integrated W-ARIMA-GRU and LightGBM Methods. *Water*. 14(9): 1322
2019. Analysis and Prediction of Water Quality Using LSTM Deep Neural Networks in IoT Environment. *Sustainability*. 11(7): 2058.
- Meshram, S. G., Ghorbani, M. A., Deo, R. C., Kashani, M. H., Meshram, C. and Karimi, V. 2019. New approach for sediment yield forecasting with a two-phase feedforward neuron network-particle swarm optimization model integrated with the gravitational search algorithm. *Water Resources Management*. 33: 2335-2356.
- ONU. 2020. Available online: www.greenfacts.org/fr/ressources-eau/ (accessed on 2 March 2020).
- Remini, B., Bensafia, D. and Mekhatri, A. 2018. Sidi M'hamed Ben Aouda's Dam (Algeria): Acceleration to the silting. *LARHYSS Journal P-ISSN 1112-3680/E-ISSN 2521-9782*. 33: 221-252.
- Salem F.M. 2022. *Recurrent Neural Networks: From Simple to Gated Architectures*. Springer Cham.
- Toumi, A., & Remini, B. 2018. Perte de la capacité de stockage d'eau au barrage de Beni Haroun, Algérie Loss of water storage capacity at the Beni Haroun dam, Algeria. *Systèmes Agraires et Environnement*. 2(1): 80-97.
- Urbina, F., Lentzos, F., Invernizzi, C. and Ekins, S.

Modeling the Quality and Sedimentation of River Using Non-Parametric and Non-Linear methods

M. Shadabi Bejand¹, E. Amiri^{2*}, A Moghimi³, N Mohammadian Roshan⁴

Received: Jul.08, 2023

Accepted: Sep.16, 2023

Abstract

The erosion and transfer of sediment caused by it affects the quality of surface water, and the estimation of sediment and flow quality plays an important role in the management of Water Resources. In the present study, modeling of quality and load indicators of flow sedimentation and providing relationships to predict the amount of flow sedimentation of Khorasan Razavi Rivers in 6 stations and statistical period 1986 to 2016 with non-parametric and nonlinear methods of the gated recursive unit Network (GRU) and random forest algorithm (RF) were carried out. By using the bagging method, modeling of flow, sedimentation and total anion and Cation flow in both networks was modeled. MAE, MAPE and RMSE statistical indicators were used to evaluate the performance of the model and the R^2 coefficient were used to evaluate the accuracy of data segmentation. Results of the average value of MAE, MAPE and RMSE indicators the water quality data of the stations examined in the GRU network is equal to 286.16, 0.06 and 1685.34 respectively and in the RF network is equal to 317.4, 0.08 and 1954.11 respectively and the sediment load data in the GRU network is equal to 200.95, 0.55 and 1434.44 respectively and in the RF network respectively equal to 52921.84, 0.90 and 1544.29 showed the superiority of the GRU model over the RF model in the modeling of sediment and water quality indicators of the Khorasan Razavi rivers.

Keywords: Baginig method, Khurasan Razavi, Quality indicators, Sediment load

1- PhD student, Department of Water Engineering, Lahijan Branch, Islamic Azad University, Lahijan, Iran
2- Professor, Department of Water Engineering, Lahijan Branch, Islamic Azad University, Lahijan, Iran
3- Assistant Professor, Department of Geology, Lahijan Branch, Islamic Azad University, Lahijan, Iran
4- Assistant Professor, Department of Agriculture, Lahijan Branch, Islamic Azad University, Lahijan, Iran
(*- Corresponding Author Email: eamiri57@yahoo.com)