

مقاله علمی-پژوهشی

توسعه جعبه‌ابزار مدل‌سازی سیلاب با استفاده از فرامدل‌های هیبریدی دوگانه هوش مصنوعی (مطالعه موردی: حوزه آبخیز کرج)

سبحان حسین‌نژاد سلیمی^۱، محمد انصاری قوجقار^{۲*}، آرش ملکیان^۳، مهرنوش قدیمی^۴

تاریخ دریافت: ۱۴۰۵/۰۲/۰۹ تاریخ پذیرش: ۱۴۰۵/۰۲/۱۹

چکیده

پژوهش حاضر، باهدف توسعه یک جعبه‌ابزار جامع مدل‌سازی سیلاب مبتنی بر فرامدل‌های هیبریدی دوگانه هوش مصنوعی، شش مدل شامل دو مدل انفرادی (FCMR و GRNN) و چهار مدل هیبریدی دوگانه (FCMR-ACOR، FCMR-NARX، GRNN-ACOR و GRNN-NARX) در پنج ایستگاه هیدرومتری حوزه آبخیز کرج (گچسر، سیرا کلوان، سیرا کرج، نشتارود و مورود) طی دوره‌ای ۳۰ ساله، از ابتدای سال آبی ۱۳۶۹ تا پایان سال آبی ۱۳۹۷ مورد ارزیابی قرار گرفتند. نتایج مبتنی بر معیارهای آماری (MAE، RMSE، NSE، R) نشان داد که مدل‌های هیبریدی مبتنی بر FCMR (به‌ویژه FCMR-ACOR و FCMR-NARX) از بالاترین دقت برخوردارند. بااین‌حال، آزمون‌های آماری تفاوت معناداری بین دقت این مدل‌ها و مدل انفرادی GRNN نشان نداد. ازسوی دیگر، هیبریدسازی مدل GRNN با کاتالیزورهای NARX و ACOR به دلیل ناسازگاری ساختاری، موجب کاهش دقت آن شد. باتوجه به پیچیدگی محاسباتی، زمان آموزش طولانی و هزینه‌های اجرایی بالاتر مدل‌های هیبریدی، مدل انفرادی GRNN به‌عنوان گزینه‌ای بهینه با توجه اقتصادی و عملیاتی برای کاربرد در سامانه‌های هشدار سیل و مدیریت منابع آب در حوزه‌های مشابه پیشنهاد می‌شود. این مطالعه بر ضرورت هماهنگی بین ساختار مدل پایه و روش هیبریدسازی برای دستیابی به بهبود مؤثر عملکرد تأکید می‌کند.

واژه‌های کلیدی: پیش‌بینی سیلاب، شبکه عصبی مصنوعی، مدل انفرادی، GRNN، FCMR

مقدمه

سیلاب ضروری است (Brunner et al., 2021).

شبکه‌های عصبی بر اساس نوع کاربرد، معماری و توابع محاسباتی خود دارای ساختارهای متنوعی هستند. یکی از این انواع، شبکه عصبی GRNN است که در مقایسه با سایر شبکه‌های عصبی، از توانایی بالاتری در برون‌یابی برخوردار است. ساختار شبکه عصبی معمولاً از سه لایه اصلی تشکیل می‌شود: لایه ورودی، لایه مخفی و لایه خروجی. لایه ورودی به‌عنوان رابط اولیه عمل کرده و داده‌ها را برای پردازش آماده می‌کند. لایه مخفی که از گره (نورون‌های) پردازشگر تشکیل شده است، وظیفه پردازش داده‌ها و استخراج ویژگی‌های مهم را بر عهده دارد. در نهایت، لایه خروجی نتایج پیش‌بینی‌شده توسط شبکه را به‌صورت خروجی نهایی ارائه می‌دهد. شبکه‌های عصبی مصنوعی به‌عنوان سامانه‌های هوشمند و دینامیکی پیشرفته شناخته می‌شوند که از طریق پردازش داده‌های تجربی، توانایی شناسایی و استخراج الگوها و روابط پنهان موجود در داده‌ها را دارند و این اطلاعات را به ساختار شبکه منتقل می‌کنند (انصاری قوجقار، ۱۳۹۹، Tokar and Johnson, 1999; Araghinejad, 2014).

دقت مدل‌های سیلاب به کیفیت و دسترسی به داده‌ها وابسته است، بااین‌حال مدل‌سازی سیلاب با چالش‌هایی نظیر کمبود و کیفیت پایین داده‌ها، پیچیدگی فرایندهای هیدرولوژیکی، عدم قطعیت ذاتی مدل‌ها و دشواری نمایش تأثیرات انسانی و تغییرات اقلیمی مواجه است. ازاین‌رو، توسعه رویکردهای ترکیبی و بهبود تعامل میان داده، مدل و تصمیم‌گیری برای ارتقای قابلیت اعتماد پیش‌بینی

۱- دانش‌آموخته مقطع کارشناسی ارشد، رشته علوم و مهندسی آبخیز، دانشگاه تهران، ایران

۲- استادیار گروه احیا مناطق خشک و کوهستانی، دانشکده کشاورزی و منابع طبیعی، دانشگاه تهران، ایران

۳- استاد گروه احیا مناطق خشک و کوهستانی، دانشکده کشاورزی و منابع طبیعی، دانشگاه تهران، ایران

۴- دانشیار گروه جغرافیا، دانشکده جغرافیا، دانشگاه تهران، ایران

(*)- نویسنده مسئول: Ansari.ghojghar@ut.ac.ir

DOI: [10.22034/ijid.2026.579909.2680](https://doi.org/10.22034/ijid.2026.579909.2680)

عملکرد مدل مستقل و منفرد شبکه‌های عصبی مصنوعی در تعیین ضرایب وزنی بهینه، از چهار الگوریتم بهینه‌سازی فراابتکاری استفاده کردند. یافته‌ها نشان داد که مدل‌های هیبریدی عملکرد مطلوبی در بهبود قابلیت برآورد مدل شبکه عصبی مصنوعی ارائه می‌دهند. مدل‌های هیبریدی هوش مصنوعی در برآورد دبی سیلابی عملکرد بهتری نسبت به مدل‌های منفرد دارند. نتایج نشان داد که مدل ترکیبی شبکه عصبی مصنوعی - تفنگ‌دار خلاق از دقت بالاتری برخوردار بوده و خطای کمتری نسبت به سایر مدل‌ها دارد. در مجموع، یافته‌ها تأیید می‌کنند که استفاده از مدل‌های هیبریدی هوش مصنوعی در برآورد دبی سیلابی مؤثر بوده و می‌تواند به‌عنوان یک راهکار مناسب و سریع برای مدیریت منابع آب مورد استفاده قرار گیرد. معروفی نیا و همکاران (۱۴۰۲) در پژوهش خود، برای پیش‌بینی جریان رودخانه کورکورسر نوشهر از دو دسته مدل‌های منفرد و هیبریدی هوش مصنوعی استفاده کردند. ارزیابی کیفی نتایج نشان داد که تمامی مدل‌ها عملکرد بسیار خوبی در پیش‌بینی جریان رودخانه داشته‌اند. در این میان، مدل ترکیبی ANN-AIG بالاترین دقت و بهترین عملکرد را در پیش‌بینی ارائه کرده است.

خرمی پور و همکاران (۱۴۰۳) در مطالعه خود، یک روش هیبریدی جدید برای مدل‌سازی هیدروگراف جریان رودخانه ارائه دادند. در این مطالعه، الگوریتم RVM با الگوریتم بهینه‌ساز CMAES برای پیش‌بینی سیل در ملائانی اهواز ترکیب شدند. این روش‌ها می‌توانند در رودخانه‌ها با شرایط مختلف مورد استفاده قرار گیرند و در صورتی که داده‌های ورودی و خروجی هدف باکیفیت و کافی باشند، انتظار می‌رود که عملکرد مطلوبی داشته باشند. الگوریتم هیبریدی RVM-CMAES نسبت به سایر الگوریتم‌ها از برتری برخوردار بود.

فیل و استینر با استفاده از میانگین دبی روزانه روزی که دبی پیک در آن اتفاق افتاده و میانگین دبی روزانه روز قبل و بعد از آن روز رابطه‌ای خطی را برای برآورد دبی پیک با استفاده از آمار دبی روزانه به دست آوردند (Fill and Steiner, 2003).

هوانگ و همکاران بیان داشتند که شبکه‌های عصبی از روش‌های پرکاربرد در پیش‌بینی‌های اقلیمی به شمار می‌روند. به‌عنوان نمونه، در پیش‌بینی پدیده گردوغبار در شمال غرب چین از این روش استفاده شده است که نتایج آن نشان داد میزان اطمینان حاصل از این مدل در پیش‌بینی گردوغبار، ۶/۷۱ درصد است (Huang et al., 2006).

ایبارا براستگی و همکاران در پژوهشی، پیش‌بینی آلودگی هوای شهر بیلپائو با استفاده از شبکه‌های عصبی مصنوعی مورد بررسی قرار دادند. در این مطالعه از سه نوع شبکه شامل MLP, RBF و شبکه عصبی رگرسیونی تعمیم‌یافته (GRNN) برای پیش‌بینی آلودگی هوا و طراحی سنجنده‌های هشداردهنده آلودگی استفاده شد. نتایج نشان داد

الگوریتم‌های فرا کاوشی هوش مصنوعی به‌عنوان یکی از ابزارهای نوین مدیریت، از اهمیت فراوانی برخوردار هستند. الگوریتم‌های فرا کاوشی هوش مصنوعی با تحلیل داده‌های تاریخی و عوامل محیطی قادرند میزان تقاضای آب را پیش‌بینی کنند. این پیش‌بینی‌ها به مدیران کمک می‌کند تا برنامه‌ریزی دقیق‌تری برای تأمین منابع آب انجام داده و از اتلاف آن جلوگیری نمایند (رحیمی بندرآبادی و همکاران، ۱۴۰۲؛ انصاری قوجقار و همکاران، ۱۳۹۹).

مدل‌های انفرادی شبکه عصبی مصنوعی، به‌عنوان ابزارهایی هوشمند و دقیق، به دلیل ماهیت آزمون و خطا در تعیین عامل‌های شبکه (وزن‌ها و بایاس‌ها)، معمولاً با خطاهایی همراه است. با این وجود، زمانی که این مدل‌ها با الگوریتم‌ها یا روش‌های فرا کاوشی، نظیر الگوریتم‌های بهینه‌سازی، ترکیب می‌شوند، دقت پیش‌بینی آن‌ها در مقادیر بیشینه به طور قابل توجهی افزایش می‌یابد (اعلمی و همکاران، ۱۴۰۳؛ رستمی و همکاران، ۱۴۰۰).

الگوریتم‌های ترکیبی حاصل ادغام دو یا چند الگوریتم باهدف افزایش دقت و سرعت دستیابی به پاسخ‌ها هستند. به طور معمول، یکی از الگوریتم‌ها به‌عنوان الگوریتم پایه انتخاب می‌شود و از عملگرها یا ویژگی‌های سایر الگوریتم‌ها برای بهبود عملکرد الگوریتم پایه بهره گرفته می‌شود (چوکان، ۱۳۹۷).

دستورانی (۱۳۸۵) به تحلیل و ارزیابی نقاط قوت و ضعف روش شبکه عصبی مصنوعی در مدل‌سازی جریان‌های رودخانه‌ای پرداخت. یافته‌های او بیانگر بهبود نتایج پیش‌بینی در اثر ترکیب مدل‌های شبکه عصبی مصنوعی با مدل‌های هیدرودینامیکی بود. همچنین، شبکه‌های عصبی مصنوعی از توانایی مناسبی جهت پیش‌بینی داده‌های مفقود برخوردار است.

نوری و همکاران (۱۳۹۷) در پژوهشی به مقایسه سه روش اصلی هوش مصنوعی برای برآورد دبی سیلاب رودخانه یلفان پرداختند. بر اساس یافته‌های آنان، مدل ترکیبی شبکه عصبی و الگوریتم ژنتیک در برآورد دبی سیلاب در حوزه یلفان، عملکرد بهتری نسبت به مدل شبکه عصبی و همچنین مدل ترکیب خوشه‌بندی کاهشی و ANFIS از خود نشان داده است.

دهقانی و همکاران (۱۴۰۰) در مطالعه خود، به بررسی عملکرد مدل‌هایی برای شبیه‌سازی جریان روزانه رودخانه‌های حوزه آبخیز دز با استفاده از داده‌های روزانه پرداختند. مدل‌های مورد استفاده شامل مدل هیبریدی ماشین بردار پشتیبان - گیاهان مصنوعی و ماشین بردار پشتیبان - موزیک بودند. نتایج نشان داد که در هر دو مدل بررسی‌شده، یعنی مدل هیبریدی ماشین بردار پشتیبان - گیاهان مصنوعی و ماشین بردار پشتیبان - موزیک، ساختاری متشکل از ۱ تا ۴ تأخیر زمانی نتایج بهتری نسبت به سایر ساختارها ارائه می‌دهد.

رستمی و همکاران (۱۴۰۰) در پژوهش خود، به منظور ارتقای

درحالی‌که چارچوب مشخصی برای مقایسه منسجم این مدل‌ها ارائه نشده است. این موضوع، ضرورت انجام پژوهشی با رویکرد مقایسه‌ای را نشان می‌دهد. هدف از این تحقیق، توسعه جعبه‌ابزار مدل‌سازی سیلاب با استفاده از فرامدل‌های هیبریدی دوگانه، ترکیب مدل‌های پایه FCMR و GRNN با کاتالیزورهای NARX و ACOR، ارزیابی عملکرد مدل‌های هیبریدی در مقابل مدل‌های انفرادی در حوزه آبخیز کرج و تأکید بر توجیه اقتصادی و کاربرد عملی مدل‌ها در شرایط منابع محدود.

مواد و روش‌ها

منطقه مورد مطالعه

حوزه آبخیز کرج در استان البرز و در محدوده جغرافیایی بین طول‌های شرقی ۵۱ درجه و ۵ دقیقه تا ۵۱ درجه و ۳۵ دقیقه و عرض‌های شمالی ۳۵ درجه و ۵۱ دقیقه تا ۳۶ درجه و ۱۳ دقیقه واقع شده است. این حوزه با مساحت حدود ۸۴۰ کیلومتر مربع در دامنه‌های جنوبی رشته‌کوه البرز مرکزی قرار دارد و دارای توپوگرافی کوهستانی با ارتفاع متغیر بین ۱۶۳۶ تا ۴۳۶۷ متر از سطح دریا و میانگین ارتفاع حدود ۲۹۹۳ متر می‌باشد. میانگین بارندگی سالانه حدود ۶۳۷ میلی‌متر بوده و اقلیم منطقه بر اساس طبقه‌بندی دوما رتن از نوع مرطوب است. طول آبراهه اصلی حوزه ۴۷ کیلومتر با شیب متوسط ۰.۴ درصد بوده و این حوزه از پرآب‌ترین رودخانه‌های فلات مرکزی ایران به شمار می‌رود. جزئیات منطقه مورد مطالعه در شکل ۳-۳ ارائه شده است.

مواد و روش‌ها

مدل‌سازی سری‌های زمانی

آماده‌سازی داده‌ها

آماده‌سازی داده‌ها یکی از مراحل اساسی و حیاتی در فرایند تحلیل داده‌های هیدرولوژیکی به شمار می‌رود و باهدف تضمین دقت، قابلیت اطمینان و کارایی تحلیل‌های آماری و مدل‌سازی انجام می‌شود. کیفیت داده‌های ورودی نقش تعیین‌کننده‌ای در عملکرد مدل‌های پیش‌بینی و اعتبار نتایج نهایی پژوهش دارد. در این تحقیق، داده‌های خام از شرکت مدیریت منابع آب ایران گردآوری شدند. این داده‌ها شامل مقادیر دبی‌های حداکثر روزانه در حوزه آبخیز کرج طی دوره‌ای ۳۰ ساله، از ابتدای سال آبی ۱۳۶۹ تا پایان سال آبی ۱۳۹۷ بودند. پس از پردازش اولیه، میانگین دبی حداکثر ماهانه هر ایستگاه محاسبه و به‌عنوان ورودی مدل‌ها مورد استفاده قرار گرفت.

بازسازی داده‌ها

بازسازی داده‌ها یکی از چالش‌های اساسی در تحلیل داده‌های

که به‌کارگیری این مدل‌ها می‌تواند شبکه پایش آلودگی هوای بیلپائو را که در ابتدا برای اهداف تشخیصی طراحی شده بود، به سیستمی باقابلیت پیش‌بینی کوتاه‌مدت و آنی تبدیل کند. همچنین عملکرد مدل‌ها در ایستگاه‌های مختلف منطقه متغیر بوده و ضریب همبستگی پیش‌بینی‌ها بین ۰.۸۸ تا ۰.۹۵ گزارش شد (Ibarra-Berastegi et al., 2008).

تی‌بن بوی و همکاران در مطالعه خود، یک روش هیبریدی هوش مصنوعی مبتنی بر مدل استنتاج فازی عصبی (ANFIS) و بهینه‌سازی فرا کاوشی را جهت مدل‌سازی سیل‌خیزی در ناحیه تحت نفوذ طوفان جنب‌حاره‌ای (سیکلون) به کار بردند. نتایج این تحقیق نشان داد که شیوه ابداعی، برتری قابل‌توجهی نسبت به متدهای شاخص پیشین دارد (Tien Bui et al., 2017).


قربانی و همکاران در بررسی عملکرد مدل‌های ترکیبی شبکه عصبی مصنوعی و ماشین بردار پشتیبان در تخمین دبی رودخانه زربینه‌رود نشان دادند که مدل ترکیبی شبکه عصبی مصنوعی نسبت به ماشین بردار پشتیبان از دقت بالاتری برخوردار است (Ghorbani et al., 2018).

گارسیا فئال و همکاران در مطالعه‌ای به پیش‌بینی جریان خروجی مخازن حوزه رودخانه Miño-Sil در شمال غرب اسپانیا پرداختند. در این تحقیق، از چهار مدل یادگیری ماشین شامل رگرسیون خطی چندمتغیره (MLR) و شبکه‌های عصبی مصنوعی (MLP، NARX و LSTM) استفاده شد و داده‌های روزانه حجم مخزن، جریان ورودی و جریان خروجی هشت مخزن طی دوره ۱۹ ساله (۲۰۰۰-۲۰۱۹) تحلیل گردید. نتایج نشان داد که همه مدل‌ها عملکرد بهتری نسبت به مدل پایه دارند و مدل NARX به‌طور میانگین بالاترین دقت را در پیش‌بینی جریان خروجی ۲۴ ساعته آینده ارائه کرد (García-Feal et al., 2022).

هوان در مطالعه‌ای به بررسی ناهمگونی جغرافیایی توابع فعال‌سازی در مدل‌های پیش‌بینی بلادرنگ سیلاب شهری پرداخت و چارچوب ترکیبی STL-TCN-GRU را ارائه کرد. داده‌های مورد استفاده شامل عمق آب سیستم زهکشی شهری در بلینگه اودنس دانمارک طی بازه ۳۱ روزه بود. مدل پیشنهادی با ۲۱ تابع فعال‌سازی مختلف و چهار معیار MAE، RMSE، MAPE و NSE ارزیابی شد و نتایج نشان داد که مدل ترکیبی با میانگین دقت NSE برابر ۰.۹۵۸۱، عملکرد بهتری نسبت به مدل‌های تکی دارد (Huan et al., 2024). اکثر مطالعات گذشته بر مدل‌های انفرادی (مانند ANN، GRNN، ANFIS) تمرکز داشتند. باوجود مطالعات متعدد در زمینه مدل‌سازی سیلاب با هوش مصنوعی، هنوز ابهاماتی در مورد کارایی واقعی مدل‌های هیبریدی وجود دارد. در بسیاری از پژوهش‌ها، فرض شده است که هیبریدسازی همواره منجر به بهبود عملکرد می‌شود،

دارای کمبود اطلاعات هستند؛ بنابراین، به منظور بازسازی داده‌های ناقص و تکمیل سری زمانی ایستگاه‌های مورد مطالعه، از روش رگرسیون خطی استفاده شد.

هیدرولوژیکی محسوب می‌شود، زیرا می‌تواند دقت مدل‌سازی و اعتبار نتایج پژوهش را به طور قابل توجهی تحت تأثیر قرار دهد. بررسی داده‌های هیدرولوژیکی در این پژوهش نشان داد که برخی ایستگاه‌ها



شکل ۱- منطقه مورد مطالعه

استفاده شد. میزان همبستگی بین یک ماه با ماه دیگر بیشتر از ۰/۶ مورد قبول واقع شد و بازسازی صورت گرفت و با استفاده از رگرسیون خطی داده‌ها با استفاده از ایستگاه‌های با دوره زمانی مشترک دارای داده (معلوم)، داده‌های مجهول پیش‌بینی و بازسازی شدند.

تحلیل داده‌ها

پیش از انجام هرگونه مدل‌سازی یا پیش‌بینی سری زمانی، انجام تحلیل توصیفی اولیه داده‌ها امری ضروری است. در این پژوهش، تحلیل مقدماتی بر روی داده‌های آموزشی انجام شد که شامل شناسایی ویژگی‌هایی مانند میزان همبستگی، الگوهای فصلی، نوسانات تودرتوی دوره‌ای در الگوهای فصلی، روندها، داده‌های پرت و سایر نوسانات قابل توجه بود. همچنین بررسی ایستایی داده‌ها نیز از مراحل ضروری محسوب می‌شود. ایستایی به معنای ثبات ویژگی‌های آماری اساسی مانند میانگین و واریانس در طول زمان است (Asplim et al., 2006). بیشتر مدل‌های پیش‌بینی فرض می‌کنند داده‌های

رگرسیون خطی

این روش به عنوان یک رویکرد پارامتری، از رابطه خطی میان متغیر وابسته و متغیرهای مستقل برای برآورد مقادیر گمشده بهره می‌گیرد. استفاده از این روش به‌ویژه برای سری‌های زمانی با الگوهای خطی یا در مواردی که همبستگی قوی میان ایستگاه‌ها وجود دارد، مناسب است (انصاری قوجقار، ۱۴۰۱). (رابطه‌ی کلی رگرسیون خطی ساده به صورت رابطه (۱) بیان می‌شود:

در این رابطه y مقدار گمشده، x متغیر پیش‌بینی کننده، a عرض از مبدأ و b شیب خط است.

$$y = a + bx \quad (1)$$

در روش رگرسیون خطی، بین هر ایستگاه و ایستگاه‌های مجاور آن، معادلات رگرسیونی بر اساس سال‌های مشترک داده تعریف شد. سپس با استفاده از بهترین معادله به دست آمده، مقادیر گمشده برای ایستگاه هدف تخمین و بازسازی گردید

در SPSS از همبستگی دومتغیره (bivariate correlation)

دست می آورد. خروجی این دو نورون در لایه جمع به صورت معادله (۳ و ۴) بیان می شود (Kisi و همکاران، ۲۰۱۵).

$$S = \sum_{i=1}^n Y_i \exp \left(-\frac{(X-X_i)^T (X-X_i)}{2\sigma^2} \right) \quad (3)$$

$$D = \sum_{i=1}^n \exp \left(-\frac{(X-X_i)^T (X-X_i)}{2\sigma^2} \right) \quad (4)$$

که در آن Y_i وزن اتصال نورون i ام در لایه الگو به لایه جمع و σ عامل هموارسازی^۸ است. به طور کلی، شبکه GRNN ابزاری قدرتمند برای تحلیل رگرسیون غیرخطی محسوب می شود. برای یک بردار ورودی X ، خروجی Y شبکه GRNN با استفاده از تابع (۵) محاسبه می شود.

$$Y(X) = \frac{S}{D} = \frac{\sum_{i=1}^n Y_i \exp \left(-\frac{(X-X_i)^T (X-X_i)}{2\sigma^2} \right)}{\sum_{i=1}^n \exp \left(-\frac{(X-X_i)^T (X-X_i)}{2\sigma^2} \right)} \quad (5)$$

الگوریتم بهینه سازی کلونی مورچگان پیوسته (ACOR)^۹

الگوریتم ACO متغیرهای تصمیم را به صورت گسسته در نظر می گیرد؛ اما در ACOR متغیرهای تصمیم به صورت پیوسته در نظر گرفته می شوند و از این رو کارایی آن به مراتب بالاتر از الگوریتم ACO است (Tahroudi و همکاران، ۲۰۲۱).

الگوریتم ACOR برای نخستین بار توسط سوشا و دوریگو (۲۰۰۸) به عنوان یک راه حل چندعامله^{۱۰} جهت حل مسائل بهینه سازی معرفی شد. ایده اصلی این الگوریتم، به کارگیری توزیع احتمال پیوسته از طریق یک تابع چگالی احتمال^{۱۱} است، به جای استفاده از توزیع احتمال گسسته. در این روش، از یک کرنل گوسی^{۱۲} به جای تابع گوسی منفرد بهره گرفته می شود که به صورت مجموعه ای وزندار از چندین تابع گوسی واحد g تعریف شده و به شکل رابطه (۶) بیان می گردد.

$$G^i(x) = \sum_{l=1}^k \omega_l g_l^i(x) = \sum_{l=1}^k \omega_l = \frac{1}{\sigma_l \sqrt{2\pi}} e^{-\frac{(x-\mu_l^i)^2}{2\sigma_l^2}} \quad (6)$$

در این رابطه، ω بردار وزن تابع گوسی، μ^i بردار میانگین، σ^i واریانس تابع گوسی و n پارامترهای مؤثر در حل مسئله هستند. چنین تابع چگالی احتمالی، اگرچه نمونه برداری را به صورت ساده تری ممکن می سازد، اما نسبت به یک تابع گوسی منفرد از انعطاف پذیری بیشتری برخوردار است (Martinez-Zeron و همکاران، ۲۰۱۴).

سری زمانی ایستا هستند، زیرا این فرض موجب کاهش پیچیدگی ریاضی مدل می شود، هرچند در عمل، داده های واقعی معمولاً چنین ویژگی ای ندارند.

مدل رگرسیون فازی (FCMR)^۱

مدل رگرسیون فازی (FCMR) یک رویکرد ترکیبی است که برای مدل سازی داده ها از ترکیب رگرسیون خطی و خوشه بندی فازی بهره می گیرد. این روش به ویژه زمانی کاربرد دارد که داده ها فاقد ساختار مشخص بوده و مرز میان خوشه ها به طور دقیق قابل تشخیص نباشد. مدل FCMR در واقع توسعه ای از روش میانگین های C در نظریه فازی است و به عنوان یکی از پرکاربردترین تکنیک های خوشه بندی شناخته می شود. این مدل توسط Hathaway^۶، Bezdek^۷ (1993) معرفی شد و توسط رابطه (۲) تعریف می گردد.

$$J_q(\mu, V, X) = \sum_{i=1}^c \sum_{j=1}^n (\mu_{i,j})^q D_{i,j}^2 \quad (2)$$

که در آن $(i \in \{1, \dots, c\})$ و $(j \in \{1, \dots, n\})$ هستند، به طوری که (n) تعداد داده ها، (c) تعداد خوشه ها، (μ) ماتریس عضویت فازی، (V) بردار مراکز خوشه ها، (q) یک عدد حقیقی مثبت، و $(D_{i,j})$ فاصله بین داده (i) و مرکز خوشه (j) است.

شبکه های تعمیمی رگرسیونی (GRNN)^۲

GRNN توسط دونالد اف. اسپکت در سال ۱۹۹۱ معرفی شد (Specht, 1991). این مدل مبتنی بر رگرسیون کرنل نادارایا – واتسون و تخمین چگالی احتمال پارزن – روزنبلات است. GRNN از چهار لایه تشکیل شده است: لایه ورودی^۳، لایه الگو^۴، لایه جمع^۵ و لایه خروجی. تعداد متغیرهای ورودی به تعداد داده های مشاهده شده در مرحله جمع آوری داده در لایه ورودی بستگی دارد. در این مرحله، لایه ورودی اطلاعات را جمع آوری کرده و به لایه الگو منتقل می کند.

لایه الگو برای انجام عمل خوشه بندی^۶ در فرایند آموزش به کار می رود. معمولاً تعداد نورون های این لایه برابر با تعداد مجموعه داده های آموزشی است. پس از آن، خروجی این لایه به لایه جمع منتقل می شود. لایه جمع تنها از دو نورون تشکیل شده است: نورون اول S-Summation و نورون دوم D-Summation نامیده می شود. نورون S مجموع خروجی های وزندار لایه الگو را محاسبه می کند. نورون D مجموع خروجی های بدون وزن نورون های لایه الگو را به

- 1- Fuzzy c-means clustering based regression
- 2- General Regression Neural Network
- 3- Input layer
- 4- Pattern Layer
- 5- Summation Layer
- 6- Output layer
- 7- Clustering


8- Smoothing factor

9- Ant colony optimization for continuous domains

10- Multi Agent

11- Probability Density Function

12- Gaussian Kernel



شکل ۲- نمای کلی GRNN

معیارهای ارزیابی

برای ارزیابی مدل‌ها و مقایسه نتایج روش‌های مختلف، از چهار شاخص آماری شامل ضریب همبستگی^۲ R ، ریشه میانگین مربعات خطا^۳ $RMSE$ ، میانگین قدرمطلق خطا^۴ MAE و ضریب کارایی نش-ساتکلیف^۵ NS استفاده گردید. فرمول‌های محاسبه‌ی هر یک از این معیارها به صورت روابط (۸ تا ۱۱) تعریف می‌شوند.

$$R = \frac{\frac{1}{n} \sum_{i=1}^n (O_i - \bar{O})(f_i - \bar{f})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - \bar{f})^2}} \quad (8)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - f_i)^2} \quad (9)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - f_i| \quad (10)$$

$$NS = 1 - \frac{\sum_{i=1}^n (O_i - f_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (11)$$

در این روابط O_i نشان‌دهنده‌ی مقادیر مشاهده‌شده در گام زمانی i ام، f_i مقادیر پیش‌بینی‌شده در همان گام، $\bar{O}$ میانگین مقادیر مشاهده‌شده، $\bar{f}$ میانگین مقادیر پیش‌بینی‌شده و n تعداد کل داده‌ها است. به‌طور کلی، مدلی مطلوب‌تر است که مقادیر R و NS بالاتر و در مقابل، مقادیر $RMSE$ و MAE پایین‌تری داشته باشد.

نتایج و بحث

تحلیل عملکرد مدل FCMR

در مقایسه با سایر مدل‌ها، FCMR انفرادی پایین‌ترین یا یکی از پایین‌ترین رتبه‌ها را از نظر دقت داشته است (رتبه ۴ از ۶ در مدل‌های مورد استفاده در پژوهش حاضر). این مسئله ناشی از عوامل مختلفی می‌تواند باشد. از جمله حساسیت به پارامترهای اولیه که در آن تعداد خوشه‌ها (c)، درجه فازی (m)، و مراکز اولیه اگر بهینه

مدل‌های خودرگرسیون غیرخطی با ورودی‌های برون‌زاد (NARX)^۱

شبکه‌های عصبی مصنوعی دینامیک NARX، یکی از دسته‌های مهم شبکه‌های عصبی بازگشتی غیرخطی هستند. برخلاف شبکه‌های انتشار مستقیم مانند پرسپترون چندلایه، در شبکه‌های بازگشتی نورون‌های لایه‌های میانی یا خروجی به لایه‌های قبلی یا همان لایه خودشان بازخورد دارند. این بازخورد معمولاً شامل یک واحد تأخیر زمانی است که امکان ایجاد حافظه در ساختار شبکه را فراهم می‌کند و شبکه‌های بازگشتی را به سامانه‌هایی پویا تبدیل می‌نماید. مدل NARX نمونه‌ای از سامانه‌های خودرگرستی غیرخطی گسسته در زمان است که علاوه بر ورودی‌های درون‌زاد، ورودی‌های برون‌زاد نیز دارد و با رابطه (۷) توصیف می‌شود (امیدوار و همکاران، ۱۳۹۴).

$$\hat{Y}(t+1) = f(y(t), \dots, y(t-D_y), u(t), \dots, u(t-D_u)) + \varepsilon_t \quad (7)$$


در این رابطه، $y(t)$ سری زمانی موردنظر است که باید پیش‌بینی شود و $u(t)$ سری زمانی دیگری است که مقادیر آن به طور متناظر با مقادیر $y(t)$ مرتبط هستند. مقادیر $u(t), \dots, u(t-D_u)$ و ورودی‌های برون‌زاد شبکه هستند که از طریق یک خط تأخیر با مرتبه D_u ایجاد می‌شوند. به طور مشابه، مقادیر $y(t), \dots, y(t-D_y)$ و ورودی‌های درون‌زاد را تشکیل می‌دهند و با یک خط تأخیر با مرتبه D_y ، خروجی شبکه NARX تولید می‌شود. تابع f یک تابع غیرخطی است که مقدار بعدی سری $y(t)$ را پیش‌بینی می‌کند و ε_t نویز تجمعی تخمین به شمار می‌آید. در شبکه NARX می‌توان با افزایش تعداد تأخیرها در خط تأخیر خروجی، پدیده میرایی گرادیان را به تعویق انداخت. مزیت شبکه NARX نسبت به سایر شبکه‌های بازگشتی این است که پس‌خوردها به طور مستقیم خروجی را به ورودی متصل می‌کنند (پهارلو، ۱۳۸۷).

2 Correlation
3 Root Mean Square Error
4 Mean Absolute Error
5 Nash-Sutcliffe

1 Nonlinear AutoRegressive models with exogenous inputs

پیش‌بینی‌کننده جریان فعلی) را به‌خوبی مدیریت نمی‌کند. در حوزه کرج، تأخیر بارش-جریان (lag time) نقش کلیدی دارد که FCMR انفرادی آن را نادیده می‌گیرد.

انتخاب نشوند، مدل به بهینه محلی گیر می‌کند. همچنین عدم مدل‌سازی صریح دینامیک زمانی FCMR از دلایل دیگر عملکرد ضعیف این مدل می‌تواند باشد. از آنجایی که پایه استاتیک است و وابستگی‌های زمانی (مانند جریان قبلی رودخانه به‌عنوان



شکل ۳- نمای کلی NARX

جدول ۱- نتایج آماری داده‌های ورودی به مدل FCMR

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
گچسِر	۴	-۰/۷۷۹	۴/۵۲۷	۴/۴۸۳	-۰/۷۶۱	-۰/۷۵۵	۴/۶۴۹	۴/۵۰۴	-۰/۷۴۶
	۳	-۰/۷۷۳	۴/۵۲۹	۴/۴۸۷	-۰/۷۵۷	-۰/۷۵۱	۴/۶۵۱	۴/۵۰۹	-۰/۷۴۱
	۲	-۰/۷۶۶	۴/۵۳۴	۴/۴۹۱	-۰/۷۵۳	-۰/۷۴۷	۴/۶۵۳	۴/۵۱۱	-۰/۷۳۵
	۱	-۰/۷۶۱	۴/۵۳۸	۴/۴۹۳	-۰/۷۴۸	-۰/۷۴۲	۴/۶۵۵	۴/۵۱۳	-۰/۷۳۱
سیرا کلوان	۴	-۰/۷۷۸	۴/۵۴۲	۴/۴۹۷	-۰/۷۶۱	-۰/۷۵۵	۴/۶۵۷	۴/۵۱۷	-۰/۷۴۶
	۳	-۰/۷۷۱	۴/۵۴۹	۴/۴۹۹	-۰/۷۵۵	-۰/۷۴۹	۴/۶۵۹	۴/۵۱۹	-۰/۷۳۹
	۲	-۰/۷۶۵	۴/۵۶۱	۴/۵۰۱	-۰/۷۵۱	-۰/۷۴۶	۴/۶۶۲	۴/۵۲۳	-۰/۷۳۴
	۱	-۰/۷۵۸	۴/۵۷۳	۴/۵۰۴	-۰/۷۴۷	-۰/۷۴۲	۴/۶۶۷	۴/۵۲۴	-۰/۷۲۸
سیرا کرج	۴	-۰/۷۷۷	۳/۲۲۳	۳/۱۸۵	-۰/۷۵۹	-۰/۷۵۳	۳/۲۶۹	۳/۲۰۷	-۰/۷۴۵
	۳	-۰/۷۶۹	۳/۲۲۵	۳/۱۸۷	-۰/۷۵۴	-۰/۷۴۸	۳/۲۷۲	۳/۲۰۹	-۰/۷۳۸
	۲	-۰/۷۶۴	۳/۲۳۱	۳/۱۹۴	-۰/۷۴۹	-۰/۷۴۴	۳/۲۷۴	۳/۲۱۳	-۰/۷۳۳
	۱	-۰/۷۵۷	۳/۲۴۴	۳/۱۹۷	-۰/۷۴۶	-۰/۷۴۱	۳/۲۷۹	۳/۲۱۷	-۰/۷۲۶
نشتارود	۴	-۰/۷۷۵	-۰/۰۸۳	-۰/۰۴۹	-۰/۷۵۸	-۰/۷۵۱	-۰/۰۹۷	-۰/۰۶۷	-۰/۷۴۴
	۳	-۰/۷۶۸	-۰/۰۸۷	-۰/۰۵۲	-۰/۷۵۳	-۰/۷۴۷	-۰/۱۰۲	-۰/۰۶۹	-۰/۷۳۷
	۲	-۰/۷۶۳	-۰/۰۸۷	-۰/۰۵۳	-۰/۷۴۷	-۰/۷۴۲	-۰/۱۰۴	-۰/۰۷۲	-۰/۷۳۲
	۱	-۰/۷۵۴	-۰/۰۹۲	-۰/۰۵۵	-۰/۷۴۵	-۰/۷۳۸	-۰/۱۰۴	-۰/۰۷۴	-۰/۷۲۵
مورود	۴	-۰/۷۷۱	-۰/۰۹۴	-۰/۰۵۹	-۰/۷۵۸	-۰/۷۴۹	-۰/۱۰۷	-۰/۰۷۸	-۰/۷۴۳
	۳	-۰/۷۶۴	-۰/۰۹۷	-۰/۰۶۱	-۰/۷۵۱	-۰/۷۴۶	-۰/۱۰۹	-۰/۰۷۹	-۰/۷۳۶
	۲	-۰/۷۶۱	-۰/۱۰۲	-۰/۰۶۳	-۰/۷۴۶	-۰/۷۴۱	-۰/۱۱۳	-۰/۰۸۱	-۰/۷۳۱
	۱	-۰/۷۵۲	-۰/۱۰۴	-۰/۰۶۴	-۰/۷۴۱	-۰/۷۳۳	-۰/۱۱۴	-۰/۰۸۳	-۰/۷۲۴

دو مؤلفه اصلی استوار است: مدل پایه FCMR که مسئولیت مدیریت عدم قطعیت‌های موجود در داده‌های هیدرولوژیکی را بر عهده دارد و الگوریتم فراابتکاری ACOR که به‌عنوان کاتالیزور بهینه‌سازی عمل می‌کند.

به‌عنوان کاتالیزور، ACOR نقش تقویت‌کننده و اصلاح‌کننده

تحلیل عملکرد FCMR-ACOR

این مدل در رتبه‌بندی کلی دقت، جایگاه دوم را (پس از FCMR-NARX) به خود اختصاص داده و عملکرد آن بر اساس مجموعه نتایج مطالعه، به‌صورت زیر تحلیل می‌شود. مکانیسم عملکرد مدل هیبریدی FCMR-ACOR بر پایه ترکیب

شامل موارد مختلفی است. تعمیم‌پذیری بالا یکی از این موارد است. بهینه‌سازی جهانی ACOR مدل را برای شرایط متنوع حوزه کرج (بارش‌های رگباری فصلی، تغییرات پوشش گیاهی، توپوگرافی شیب‌دار) مقاوم‌تر می‌سازد. همچنین مدیریت عدم قطعیت از موارد دیگر است و ترکیب فازی FCMR با بهینه‌سازی ACOR، نوین داده‌های محدود یا ناقص (رایج در ایستگاه‌های هیدرومتری ایران) را به‌خوبی کنترل می‌کند.

ساختار FCMR را ایفا می‌کند؛ بدون تغییر ماهیت فازی مدل پایه، تنها با تنظیم دقیق پارامترهای آن، دقت، تعمیم‌پذیری و پایداری مدل را به طور معنی‌داری ارتقا می‌دهد. این نقش به‌ویژه در داده‌های پیچیده و غیرخطی حوزه کرج مؤثر است، جایی که تنظیم دستی یا روش‌های گرادیانی سنتی ناکارآمد هستند. در نتیجه، FCMR-ACOR به مدلی تبدیل می‌شود که ضمن حفظ قابلیت مدیریت عدم قطعیت فازی، از جستجوی جهانی و هوشمند ACOR برای دستیابی به عملکرد بهینه بهره می‌برد. نقاط قوت مدل FCMR-ACOR

جدول ۲- نتایج آماری داده‌های ورودی به مدل FCMR-ACOR

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
گچسر	۴	-۰/۹۵۸	۱/۵۳۸	۱/۴۹۵	-۰/۹۴۷	-۰/۹۳۶	۱/۵۴۹	۱/۵۱۲	-۰/۹۲۳
	۳	-۰/۹۵۳	۱/۵۳۹	۱/۴۹۶	-۰/۹۴۱	-۰/۹۳۲	۱/۵۵۱	۱/۵۱۴	-۰/۹۱۸
	۲	-۰/۹۴۸	۱/۵۴۱	۱/۴۹۷	-۰/۹۳۶	-۰/۹۲۷	۱/۵۵۳	۱/۵۱۶	-۰/۹۱۴
	۱	-۰/۹۴۴	۱/۵۴۱	۱/۴۹۷	-۰/۹۳۱	-۰/۹۲۱	۱/۵۵۳	۱/۵۱۷	-۰/۹۱۱
سیرا کلوان	۴	-۰/۹۵۷	۱/۵۴۳	۱/۵۰۱	-۰/۹۴۵	-۰/۹۳۶	۱/۵۵۴	۱/۵۱۷	-۰/۹۲۲
	۳	-۰/۹۵۳	۱/۵۴۷	۱/۵۰۴	-۰/۹۳۹	-۰/۹۳۱	۱/۵۵۷	۱/۵۲۱	-۰/۹۱۷
	۲	-۰/۹۴۵	۱/۵۴۹	۱/۵۰۴	-۰/۹۳۵	-۰/۹۲۵	۱/۵۶۱	۱/۵۲۲	-۰/۹۱۴
	۱	-۰/۹۴۱	۱/۵۵۳	۱/۵۰۷	-۰/۹۲۸	-۰/۹۱۹	۱/۵۶۳	۱/۵۲۵	-۰/۹۰۹
سیرا کرج	۴	-۰/۹۵۶	۱/۰۷۴	۱/۰۲۳	-۰/۹۴۴	-۰/۹۳۴	۱/۰۸۹	۱/۰۴۲	-۰/۹۲۱
	۳	-۰/۹۵۲	۱/۰۷۹	۱/۰۲۷	-۰/۹۳۸	-۰/۹۲۹	۱/۰۹۲	۱/۰۴۴	-۰/۹۱۷
	۲	-۰/۹۴۵	۱/۰۸۱	۱/۰۳۱	-۰/۹۳۵	-۰/۹۲۴	۱/۰۹۳	۱/۰۴۷	-۰/۹۱۳
	۱	-۰/۹۳۷	۱/۰۸۳	۱/۰۳۴	-۰/۹۲۷	-۰/۹۱۷	۱/۰۹۶	۱/۰۵۲	-۰/۹۰۷
نشتارود	۴	-۰/۹۵۳	-۰/۰۲۵	-۰/۰۰۹	-۰/۹۴۳	-۰/۹۳۱	-۰/۰۳۳	-۰/۰۱۵	-۰/۹۱۹
	۳	-۰/۹۴۹	-۰/۰۲۷	-۰/۰۱۱	-۰/۹۳۷	-۰/۹۲۹	-۰/۰۳۷	-۰/۰۱۷	-۰/۹۱۵
	۲	-۰/۹۴۳	-۰/۰۳۱	-۰/۰۱۱	-۰/۹۳۴	-۰/۹۲۲	-۰/۰۴۱	-۰/۰۱۹	-۰/۹۱۱
	۱	-۰/۹۳۴	-۰/۰۳۳	-۰/۰۱۲	-۰/۹۲۵	-۰/۹۱۵	-۰/۰۴۵	-۰/۰۱۹	-۰/۹۰۶
مورود	۴	-۰/۹۵۲	-۰/۰۳۴	-۰/۰۱۴	-۰/۹۴۱	-۰/۹۲۷	-۰/۰۴۷	-۰/۰۲۱	-۰/۹۱۶
	۳	-۰/۹۴۸	-۰/۰۳۶	-۰/۰۱۵	-۰/۹۳۵	-۰/۹۲۸	-۰/۰۵۱	-۰/۰۲۲	-۰/۹۱۴
	۲	-۰/۹۴۱	-۰/۰۳۷	-۰/۰۱۶	-۰/۹۳۳	-۰/۹۲۱	-۰/۰۵۳	-۰/۰۲۳	-۰/۹۰۹
	۱	-۰/۹۳۳	-۰/۰۴۱	-۰/۰۱۷	-۰/۹۲۴	-۰/۹۱۳	-۰/۰۵۴	-۰/۰۲۴	-۰/۹۰۵

هیدروگراف‌های سیلاب با پیک‌های ناگهانی) را به طور معنی‌داری ارتقا می‌دهد. این ترکیب اجازه می‌دهد تا عدم قطعیت‌های فازی با دینامیک‌های واقعی فرایندهای هیدرولوژیکی (مانند تأخیر جریان در رودخانه کرج) هم‌افزایی ایجاد کنند و مدل را به دقیق‌ترین گزینه در میان مدل‌های بررسی‌شده تبدیل نمایند. در نتیجه، FCMR-NARX به مدلی تبدیل می‌شود که ضمن حفظ قدرت مدیریت عدم قطعیت، از قابلیت پیش‌بینی پویا و هوشمند NARX برای دستیابی به بالاترین سطح دقت در مدل‌سازی سیلاب بهره می‌برد.

تحلیل عملکرد مدل FCMR-NARX

این مدل در رتبه‌بندی کلی دقت، جایگاه اول را به خود اختصاص داده و عملکرد آن بر اساس مجموعه نتایج مطالعه (مانند بهبود معنی‌دار دقت FCMR پایه، برتری نسبت به ACOR در FCMR، و عدم تفاوت معنی‌دار با GRNN انفرادی) به‌صورت زیر تحلیل می‌شود. به‌عنوان کاتالیزور، NARX نقش تقویت‌کننده و مکمل FCMR را ایفا می‌کند؛ بدون تغییر ماهیت فازی پایه، با تزریق بعد زمانی، توانایی مدل در پیش‌بینی‌های کوتاه‌مدت و میان‌مدت (به‌ویژه

جدول ۳- نتایج آماری داده‌های ورودی به مدل FCMR-NARX

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
گچسر	۴	۰/۹۷۶	۱/۳۵۶	۰/۹۶۳	۱/۳۹۷	۰/۹۴۷	۱/۳۸۲	۱/۳۱۷	۰/۹۳۹
	۳	۰/۹۷۱	۱/۳۶۱	۰/۹۵۹	۱/۳۰۴	۰/۹۴۵	۱/۳۸۷	۱/۳۲۴	۰/۹۳۵
	۲	۰/۹۶۷	۱/۳۶۴	۰/۹۵۶	۱/۳۰۹	۰/۹۴۲	۱/۳۹۴	۱/۳۳۱	۰/۹۳۱
	۱	۰/۹۶۵	۱/۶۳۷	۰/۹۵۱	۱/۳۱۴	۰/۹۳۸	۱/۴۰۳	۱/۳۳۵	۰/۹۲۷
سیرا کلوان	۴	۰/۹۷۴	۱/۳۷۱	۰/۹۶۳	۱/۳۱۷	۰/۹۴۶	۱/۴۰۹	۱/۳۳۷	۰/۹۳۸
	۳	۰/۹۶۹	۱/۳۷۲	۰/۹۵۸	۱/۳۱۹	۰/۹۴۴	۱/۴۱۳	۱/۳۴۱	۰/۹۳۳
	۲	۰/۹۶۶	۱/۳۷۴	۰/۹۵۴	۱/۳۲۲	۰/۹۴۱	۱/۴۲۳	۱/۳۴۴	۰/۹۲۹
	۱	۰/۹۶۴	۱/۳۸۱	۰/۹۴۸	۱/۳۲۵	۰/۹۳۷	۱/۴۲۵	۱/۳۴۹	۰/۹۲۴
سیرا کرج	۴	۰/۹۷۳	۰/۹۰۳	۰/۹۴۸	۰/۹۶۱	۰/۹۴۵	۰/۹۶۸	۰/۹۲۱	۰/۹۳۷
	۳	۰/۹۶۸	۰/۹۰۹	۰/۹۵۲	۰/۹۵۷	۰/۹۴۳	۰/۹۶۹	۰/۹۲۴	۰/۹۳۱
	۲	۰/۹۶۵	۰/۹۱۲	۰/۹۵۵	۰/۹۵۱	۰/۹۳۹	۰/۹۷۲	۰/۹۲۷	۰/۹۲۶
	۱	۰/۹۶۲	۰/۹۱۴	۰/۹۵۹	۰/۹۴۶	۰/۹۳۶	۰/۹۷۵	۰/۹۳۱	۰/۹۲۱
نشتارود	۴	۰/۹۷۲	۰/۰۱۸	۰/۰۰۳	۰/۹۵۹	۰/۹۴۳	۰/۰۲۸	۰/۰۰۹	۰/۹۳۵
	۳	۰/۹۶۷	۰/۰۱۸	۰/۰۰۳	۰/۹۵۶	۰/۹۴۲	۰/۰۳۱	۰/۰۰۹	۰/۹۲۹
	۲	۰/۹۶۴	۰/۰۲۱	۰/۰۰۴	۰/۹۴۸	۰/۹۳۸	۰/۰۳۴	۰/۰۱۱	۰/۹۲۴
	۱	۰/۹۵۹	۰/۰۲۳	۰/۰۰۷	۰/۹۴۴	۰/۹۳۴	۰/۰۳۷	۰/۰۱۲	۰/۹۱۹
مورود	۴	۰/۹۷۱	۰/۰۲۴	۰/۰۰۹	۰/۹۵۸	۰/۹۴۳	۰/۰۳۸	۰/۰۱۳	۰/۹۳۳
	۳	۰/۹۶۶	۰/۰۲۵	۰/۰۱۱	۰/۹۵۵	۰/۹۴۱	۰/۰۳۹	۰/۰۱۳	۰/۹۲۷
	۲	۰/۹۶۳	۰/۰۲۷	۰/۰۱۱	۰/۹۴۷	۰/۹۳۶	۰/۰۴۱	۰/۰۱۵	۰/۹۲۳
	۱	۰/۹۵۷	۰/۰۲۹	۰/۰۱۲	۰/۹۴۳	۰/۹۳۱	۰/۰۴۲	۰/۰۱۶	۰/۹۱۷

تحلیل عملکرد مدل GRNN

این مدل در رتبه‌بندی کلی دقت، جایگاه سوم را به خود اختصاص داد (پس از FCMR-NARX و FCMR-ACOR)، اما عملکرد آن از نظر اقتصادی و عملی برجسته است. تحلیل عملکرد GRNN بر اساس مجموعه نتایج مطالعه (برتری انفرادی نسبت به FCMR، تضعیف با هیبریدسازی، و عدم تفاوت معنی‌دار با هیبریدهای برتر) انجام می‌شود.

GRNN در داده‌های محدود، نویزی یا غیرخطی - مانند سری‌های زمانی هیدرولوژیکی حوزه کرج با بارش‌های رگباری و جریان‌های نوسانی - تعمیم‌پذیری خوبی دارد و بدون خطر گیر کردن در بهینه‌های محلی، پیش‌بینی‌های سریع و پایداری ارائه می‌دهد. در نتیجه، GRNN به عنوان یک مدل ساده اما قدرتمند، تخمین محلی هوشمندی از تابع رگرسیون ناشناخته انجام می‌دهد و عملکرد رقابتی بالایی در کاربردهای عملی مدل‌سازی سیلاب نشان می‌دهد.

تحلیل عملکرد مدل GRNN-NARX

این مدل در رتبه‌بندی کلی دقت، جایگاه آخر را (رتبه ۶) به خود اختصاص داد و عملکرد آن بر اساس مجموعه نتایج مطالعه (تضعیف معنی‌دار دقت GRNN پایه، ضعیف‌تر بودن نسبت به GRNN

ACOR، و پایین‌ترین دقت کلی) به صورت زیر تحلیل می‌شود.

نقش NARX به عنوان کاتالیزور در این ترکیب خاص، برخلاف انتظار، تقویت‌کننده مؤثری نبود و حتی منجر به تضعیف عملکرد شد. دلیل اصلی این امر ناسازگاری ساختاری بین GRNN غیرپارامتریک (که برای تخمین محلی و ساده بهینه شده) و NARX پارامتریک بازگشتی است؛ افزودن لایه زمانی پیچیدگی غیرضروری ایجاد می‌کند، حساسیت به نویز داده‌ها را افزایش می‌دهد و خطر overfit (بیش برازش) را در داده‌های محدود و نویزی کرج تشدید می‌نماید. در نتیجه، GRNN-NARX به جای بهره‌برداری از هم‌افزایی، به مدلی تبدیل می‌شود که دقت و پایداری GRNN پایه را از دست می‌دهد و پایین‌ترین عملکرد را در میان مدل‌های بررسی شده نشان می‌دهد. این تجربه نشان می‌دهد که نقش کاتالیزور NARX تنها زمانی مؤثر است که با ساختار پایه مدل (مانند مدل‌های فازی مانند FCMR) سازگار باشد و در غیر این صورت می‌تواند به عنوان یک عامل تضعیف‌کننده عمل کند. مدل GRNN-NARX یک هیبرید ناموفق است که تلاش برای افزودن دینامیک زمانی به GRNN پایه، منجر به افت معنی‌دار دقت و رتبه آخر شد. ناسازگاری ساختاری و پیچیدگی غیرضروری، این مدل را در حوزه کرج با داده‌های محدود و نویزی نامناسب می‌سازد. این نتیجه تأکید می‌کند که

هیبریدسازی همیشه مفید نیست و برای مدل‌های قوی مانند GRNN، رویکرد انفرادی ترجیحی است. GRNN-NARX می‌تواند درس‌آموزی برای انتخاب کاتالیزورهای مناسب باشد، اما در کاربردهای عملی اولویت ندارد.

جدول ۴ - نتایج آماری داده‌های ورودی به مدل GRNN

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
گچسر	۴	۰/۹۱۲	۲/۵۵۷	۲/۴۹۸	۰/۸۸۹	۰/۸۸۱	۲/۵۸۳	۲/۵۳۱	۰/۸۷۴
	۳	۰/۹۰۸	۲/۵۶۱	۲/۴۹۹	۰/۸۸۵	۰/۸۷۸	۲/۵۸۴	۲/۵۳۴	۰/۸۷۱
	۲	۰/۹۰۳	۲/۵۶۲	۲/۵۰۱	۰/۸۸۱	۰/۸۷۵	۲/۵۸۷	۲/۵۳۵	۰/۸۶۶
	۱	۰/۸۹۷	۲/۵۶۴	۲/۵۰۳	۰/۸۷۶	۰/۸۷۱	۲/۵۹۱	۲/۵۳۸	۰/۸۶۱
سیرا کلوان	۴	۰/۹۰۷	۲/۵۶۷	۲/۵۰۳	۰/۸۸۷	۰/۸۸۱	۲/۵۹۳	۲/۵۴۱	۰/۸۷۴
	۳	۰/۹۰۴	۲/۵۷۱	۲/۵۰۷	۰/۸۸۴	۰/۸۷۶	۲/۵۹۳	۲/۵۴۳	۰/۸۶۹
	۲	۰/۹۰۳	۲/۵۷۴	۲/۵۱۱	۰/۸۷۹	۰/۸۷۳	۲/۵۹۵	۲/۵۴۵	۰/۸۶۵
	۱	۰/۸۹۶	۲/۵۸۱	۲/۵۱۷	۰/۸۷۴	۰/۸۶۹	۲/۵۹۸	۲/۵۴۷	۰/۸۵۹
سیرا کرج	۴	۰/۹۰۷	۱/۸۰۲	۱/۶۹۴	۰/۸۸۶	۰/۸۷۹	۱/۸۱۶	۱/۷۱۴	۰/۸۷۳
	۳	۰/۹۰۲	۱/۸۰۴	۱/۶۹۷	۰/۸۸۲	۰/۸۷۵	۱/۸۱۹	۱/۷۲۱	۰/۸۶۸
	۲	۰/۹۰۱	۱/۸۰۹	۱/۷۰۳	۰/۸۷۵	۰/۸۷۳	۱/۸۲۱	۱/۷۲۵	۰/۸۶۴
	۱	۰/۸۹۵	۱/۸۱۳	۱/۷۰۹	۰/۸۷۱	۰/۸۶۸	۱/۸۲۴	۱/۷۲۹	۰/۸۵۸
نشتارود	۴	۰/۹۰۴	۰/۰۴۵	۰/۰۱۸	۰/۸۸۳	۰/۸۷۷	۰/۰۵۴	۰/۰۲۵	۰/۸۳۷
	۳	۰/۹۰۱	۰/۰۴۷	۰/۰۱۹	۰/۸۸۲	۰/۸۷۴	۰/۰۵۷	۰/۰۲۷	۰/۸۶۷
	۲	۰/۸۹۹	۰/۰۴۹	۰/۰۲۱	۰/۸۷۳	۰/۸۶۸	۰/۰۶۱	۰/۰۲۹	۰/۸۶۳
	۱	۰/۸۹۳	۰/۰۵۱	۰/۰۲۲	۰/۸۶۹	۰/۸۶۶	۰/۰۶۳	۰/۰۳۲	۰/۸۵۶
مورود	۴	۰/۹۰۳	۰/۰۵۲	۰/۰۲۴	۰/۸۸۲	۰/۸۷۴	۰/۰۶۵	۰/۰۳۳	۰/۸۷۲
	۳	۰/۹۰۱	۰/۰۵۴	۰/۰۲۷	۰/۸۸۱	۰/۸۷۱	۰/۰۶۶	۰/۰۳۴	۰/۸۶۶
	۲	۰/۸۹۸	۰/۰۵۷	۰/۰۲۹	۰/۸۷۱	۰/۸۶۵	۰/۰۶۷	۰/۰۳۶	۰/۸۶۱
	۱	۰/۸۹۱	۰/۰۶۱	۰/۰۳۱	۰/۸۶۶	۰/۸۶۱	۰/۰۶۹	۰/۰۳۸	۰/۸۵۲

تحلیل عملکرد مدل GRNN-ACOR

این مدل در رتبه‌بندی کلی دقت، جایگاه پنجم را (رتبه ۵) به خود اختصاص داد (بالاتر از GRNN-NARX اما پایین‌تر از GRNN انفرادی) و عملکرد آن بر اساس مجموعه نتایج مطالعه (تضعیف معنی‌دار دقت GRNN پایه، بهتر بودن نسبت به NARX در GRNN، و پایین‌ترین دقت در میان هیبریدهای GRNN) به‌صورت زیر تحلیل می‌شود.

مکانیسم عملکرد مدل هیبریدی GRNN-ACOR بر پایه ترکیب مدل پایه GRNN با الگوریتم فراابتکاری ACOR به‌عنوان کاتالیزور بهینه‌سازی شکل گرفته است.

به‌عنوان کاتالیزور، ACOR نقش اصلاح‌کننده و تنظیم‌کننده دقیق GRNN را ایفا می‌کند و بدون تغییر ساختار اصلی غیرپارامتریک مدل پایه، تنها با بهینه‌سازی پارامترهای آن، تلاش می‌کند تا تعمیم‌پذیری و پایداری پیش‌بینی‌ها را در شرایط متنوع

هیدرولوژیکی (مانند بارش‌های رگباری یا تغییرات فصلی در کرج) افزایش دهد. با این حال، در عمل این نقش تقویت‌کننده مؤثر نبود و حتی منجر به تضعیف عملکرد شد، زیرا GRNN پایه ذاتاً ساده و بهینه است و بهینه‌سازی گسترده ACOR می‌تواند over-optimization ایجاد کند، پارامترها را به سمت مقادیری سوق دهد که در داده‌های نویزی حساسیت بیش از حد تولید کنند یا تعادل طبیعی مدل را برهم زنند. در نتیجه، GRNN-ACOR به‌جای بهره‌برداری از هم‌افزایی، به مدلی تبدیل می‌شود که دقت و کارایی GRNN انفرادی را از دست می‌دهد و عملکرد ضعیف‌تری نسبت به مدل پایه نشان می‌دهد؛ این تجربه تأکید می‌کند که نقش کاتالیزور ACOR تنها زمانی مفید است که مدل پایه نیاز واقعی به بهینه‌سازی جهانی داشته باشد (مانند مدل‌های فازی حساس به پارامترها) و در غیر این صورت می‌تواند به‌عنوان عامل پیچیدگی غیرضروری و تضعیف‌کننده عمل کند.

جدول ۵- نتایج آماری داده‌های ورودی به مدل GRNN-NARX

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
گچسار	۴	۰/۶۵۲	۷/۳۵۶	۷/۰۹۷	۰/۶۲۴	۰/۵۹۷	۷/۴۰۴	۷/۱۵۸	۰/۵۸۳
	۳	۰/۶۴۳	۷/۳۶۱	۷/۰۹۹	۰/۶۱۳	۰/۵۸۶	۷/۴۰۶	۷/۱۶۳	۰/۵۷۲
	۲	۰/۶۳۶	۷/۳۶۴	۷/۱۰۳	۰/۶۰۸	۰/۵۷۴	۷/۴۱۱	۷/۱۷۴	۰/۵۶۶
	۱	۰/۶۲۸	۷/۳۶۸	۷/۱۱۱	۰/۵۹۸	۰/۵۶۵	۷/۴۱۳	۷/۱۸۳	۰/۵۵۹
سیرا کلوان	۴	۰/۶۵۱	۷/۳۷۱	۷/۱۱۴	۰/۶۲۳	۰/۵۹۷	۷/۴۱۸	۷/۱۸۷	۰/۵۸۳
	۳	۰/۶۴۲	۷/۳۷۹	۷/۱۱۸	۰/۶۱۳	۰/۵۸۴	۷/۴۲۳	۷/۱۹۳	۰/۵۷۱
	۲	۰/۶۳۴	۷/۳۸۴	۷/۱۲۳	۰/۶۰۴	۰/۵۷۳	۷/۴۳۱	۷/۲۰۳	۰/۵۶۵
	۱	۰/۶۲۸	۷/۳۹۲	۷/۱۲۵	۰/۵۹۱	۰/۵۶۵	۷/۴۳۸	۷/۲۰۸	۰/۵۵۴
سیرا کرج	۴	۰/۶۴۹	۵/۱۵۶	۵/۰۴۷	۰/۶۲۲	۰/۵۹۵	۵/۲۰۷	۵/۱۲۴	۰/۵۸۱
	۳	۰/۶۴۱	۵/۱۶۳	۵/۰۵۳	۰/۶۱۱	۰/۵۸۱	۵/۲۱۳	۵/۱۲۸	۰/۵۶۹
	۲	۰/۶۳۳	۵/۱۶۸	۵/۰۵۹	۰/۶۰۱	۰/۵۷۲	۵/۲۱۷	۵/۱۳۲	۰/۵۶۵
	۱	۰/۶۲۷	۵/۱۶۹	۵/۰۶۳	۰/۵۸۷	۰/۵۶۴	۵/۲۲۳	۵/۱۳۴	۰/۵۵۳
نشتارود	۴	۰/۶۴۶	۰/۱۴۴	۰/۰۹۷	۰/۶۲۱	۰/۵۹۴	۰/۱۵۶	۰/۱۲۳	۰/۵۷۹
	۳	۰/۶۳۹	۰/۱۴۶	۰/۱۰۲	۰/۶۰۹	۰/۵۷۹	۰/۱۵۷	۰/۱۲۵	۰/۵۶۸
	۲	۰/۶۳۱	۰/۱۵۱	۰/۱۰۳	۰/۵۹۹	۰/۵۷۱	۰/۱۶۳	۰/۱۲۹	۰/۵۶۲
	۱	۰/۶۲۵	۰/۱۵۴	۰/۱۰۷	۰/۵۸۶	۰/۵۶۳	۰/۱۶۷	۰/۱۲۹	۰/۵۵۱
مورود	۴	۰/۶۴۴	۰/۱۵۵	۰/۱۱۳	۰/۶۱۸	۰/۵۹۱	۰/۱۷۲	۰/۱۳۱	۰/۵۷۵
	۳	۰/۶۳۸	۰/۱۵۵	۰/۱۱۴	۰/۶۰۳	۰/۵۷۷	۰/۱۷۳	۰/۱۳۴	۰/۵۶۴
	۲	۰/۶۲۹	۰/۱۵۹	۰/۱۱۷	۰/۵۹۱	۰/۵۶۹	۰/۱۷۶	۰/۱۳۷	۰/۵۶۱
	۱	۰/۶۲۳	۰/۱۶۳	۰/۱۲۳	۰/۵۸۳	۰/۵۵۹	۰/۱۸۲	۰/۱۴۱	۰/۵۴۸


جدول ۶- نتایج آماری داده‌های ورودی به مدل GRNN-ACOR

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
گچسار	۴	۰/۶۹۸	۶/۳۰۳	۶/۲۳۷	۰/۶۸۲	۰/۶۷۷	۶/۳۷۱	۶/۲۷۴	۰/۶۵۲
	۳	۰/۶۸۶	۶/۳۰۹	۶/۲۴۱	۰/۶۷۴	۰/۶۷۱	۶/۳۷۴	۶/۲۷۷	۰/۶۴۴
	۲	۰/۶۸۱	۶/۳۱۱	۶/۲۵۳	۰/۶۶۳	۰/۶۶۲	۶/۳۷۵	۶/۲۷۹	۰/۶۳۷
	۱	۰/۶۷۳	۶/۳۱۷	۶/۲۵۹	۰/۶۵۵	۰/۶۵۳	۶/۳۷۹	۶/۲۸۳	۰/۶۳۱
سیرا کلوان	۴	۰/۶۹۵	۶/۳۱۸	۶/۲۶۱	۰/۶۸۱	۰/۶۷۷	۶/۳۸۱	۶/۲۸۷	۰/۶۵۲
	۳	۰/۶۸۴	۶/۳۲۱	۶/۲۶۷	۰/۶۷۴	۰/۶۶۹	۶/۳۸۹	۶/۲۹۳	۰/۶۴۳
	۲	۰/۶۸۱	۶/۳۲۴	۶/۲۷۲	۰/۶۶۱	۰/۶۶۱	۶/۳۹۱	۶/۲۹۵	۰/۶۳۵
	۱	۰/۶۷۲	۶/۳۲۷	۶/۲۸۳	۰/۶۵۴	۰/۶۵۲	۶/۳۹۳	۶/۲۹۷	۰/۶۲۹
سیرا کرج	۴	۰/۶۹۴	۴/۴۵۶	۴/۲۴۸	۰/۶۷۹	۰/۶۷۵	۴/۴۸۲	۴/۳۳۳	۰/۶۵۱
	۳	۰/۶۸۳	۴/۴۵۷	۴/۲۳۳	۰/۶۷۳	۰/۶۶۸	۴/۴۸۷	۴/۳۳۷	۰/۶۴۲
	۲	۰/۶۷۹	۴/۴۶۳	۴/۲۳۹	۰/۶۵۹	۰/۶۶۱	۴/۴۸۹	۴/۳۲۹	۰/۶۳۴
	۱	۰/۶۷۱	۴/۴۷۴	۴/۲۴۳	۰/۶۵۱	۰/۶۵۲	۴/۴۹۳	۴/۳۳۲	۰/۶۲۷
نشتارود	۴	۰/۶۹۳	۰/۱۲۱	۰/۰۷۸	۰/۶۷۷	۰/۶۷۳	۰/۱۳۳	۰/۰۹۴	۰/۶۴۹
	۳	۰/۶۸۲	۰/۱۲۴	۰/۰۷۹	۰/۶۷۱	۰/۶۶۶	۰/۱۳۵	۰/۰۹۷	۰/۶۴۱
	۲	۰/۶۷۷	۰/۱۲۴	۰/۰۸۳	۰/۶۵۸	۰/۶۵۹	۰/۱۳۷	۰/۰۹۷	۰/۶۳۳
	۱	۰/۶۶۹	۰/۱۲۷	۰/۰۸۳	۰/۶۴۸	۰/۶۵۱	۰/۱۴۲	۰/۰۹۹	۰/۶۲۵
مورود	۴	۰/۶۹۲	۰/۱۳۱	۰/۰۸۷	۰/۶۷۳	۰/۶۷۱	۰/۱۴۴	۰/۱۰۲	۰/۶۴۷
	۳	۰/۶۸۱	۰/۱۳۲	۰/۰۸۹	۰/۶۶۹	۰/۶۶۴	۰/۱۴۷	۰/۱۳۰	۰/۶۳۹
	۲	۰/۶۷۵	۰/۱۳۵	۰/۰۹۲	۰/۶۵۵	۰/۶۵۷	۰/۱۵۱	۰/۱۰۴	۰/۶۳۲
	۱	۰/۶۶۴	۰/۱۳۶	۰/۰۹۴	۰/۶۴۴	۰/۶۴۹	۰/۱۵۴	۰/۱۰۶	۰/۶۲۱

مقایسه تمامی مدل‌های مورد استفاده در پژوهش

همان‌طور که بیان شد، نتایج مدل‌سازی سیلاب، بیانگر عملکرد بسیار مناسب مدل هیبریدی FCMR-NARX در ایستگاه‌های مورد مطالعه است. علاوه بر این، مدل ذکر شده با دارا بودن بیشترین مقدار R و ضریب NS و کمترین مقدار MAE و RMSE، بهترین مدل برای پیش‌بینی در منطقه مورد مطالعه می‌باشد. مدل FCMR-ACOR نیز پس از مدل FCMR-NARX، با اختلاف پایینی، بهترین عملکرد را داشته است. با توجه به اینکه این دو مدل هیبریدی، نتایج بسیار نزدیکی به مدل انفرادی GRNN در منطقه مورد مطالعه ارائه می‌دهند، و با در نظر گرفتن فاکتورهای عملیاتی مانند پیچیدگی محاسباتی، زمان مورد نیاز برای آموزش مدل و هزینه‌های اجرایی، انتخاب مدل GRNN می‌تواند به عنوان یک گزینه بهینه و مقرون به صرفه برای پیش‌بینی سیلاب در منطقه مورد مطالعه مطرح گردد. در حالی که FCMR-NARX بالاترین دقت را نشان می‌دهد،

اما تفاوت جزئی در عملکرد ممکن است توجیه‌کننده افزایش قابل توجه در هزینه‌ها و پیچیدگی‌های پیاده‌سازی مدل سه‌گانه نباشد. این یافته بر اهمیت ارزیابی جامع مدل‌ها، نه تنها از منظر دقت، بلکه از دیدگاه کارایی و قابلیت پیاده‌سازی در مقیاس‌های عملیاتی تأکید دارد. در بسیاری از کاربردهای عملی، مدلی که اندکی دقت کمتری دارد؛ اما به مراتب ساده‌تر، سریع‌تر و ارزان‌تر است، می‌تواند گزینه ارجح باشد. در شکل (۴)، رابطه بین مقادیر مشاهده شده و پیش‌بینی شده ترکیب ۴ (که دقیق‌ترین نتیجه‌ها از آن‌ها به دست آمده است) برای نمونه در ایستگاه گچسر که دارای بالاترین دبی بود، با نیمساز ۴۵ درجه ارزیابی گردید. مدل GRNN-NARX با کمترین دقت و بیشترین پراکندگی نسبت به سایر مدل‌ها، بیشترین اختلاف و فاصله را با نیمساز ربع اول و سوم دارد. مدل تلفیقی FCMR-NARX نیز با بیشترین تطابق نسبت به نیمساز ربع اول و سوم، بیشترین بازدهی و کارایی را در بین مدل‌های بررسی شده به همراه دارد.



شکل ۴- مقایسه مقادیر مشاهده شده و پیش‌بینی شده دبی سیلاب با استفاده از مدل‌های مورد مطالعه

GRNN عمل کردند.

مدل‌های FCMR-NARX و FCMR-ACOR به ترتیب رتبه‌های اول و دوم دقت را کسب کردند و هر دو کاتالیزور NARX و ACOR دقت مدل پایه FCMR را به طور معنی‌داری افزایش دادند. این بهبود به دلیل سازگاری بالای کاتالیزورهای دینامیک زمانی (NARX) و بهینه‌سازی جهانی (ACOR) با ساختار فازی FCMR است که امکان مدیریت بهتر عدم قطعیت‌های هیدرولوژیکی و وابستگی‌های زمانی در داده‌های پیچیده حوزه کرج را فراهم می‌آورد. در مقابل، مدل انفرادی GRNN عملکرد بهتری نسبت به FCMR انفرادی نشان داد، اما افزودن کاتالیزورهای NARX و ACOR به GRNN منجر به کاهش معنی‌دار دقت شد که ناشی از ناسازگاری ساختاری و ایجاد پیچیدگی غیرضروری در یک مدل ذاتاً ساده و کارآمد است.

نتیجه‌گیری

در این پژوهش، باهدف توسعه یک جعبه‌ابزار جامع مدل‌سازی سیلاب مبتنی بر فرامدل‌های هیبریدی دوگانه هوش مصنوعی، شش مدل شامل دو مدل انفرادی (FCMR و GRNN) و چهار مدل هیبریدی دوگانه (FCMR-NARX، FCMR-ACOR، GRNN-NARX و GRNN-ACOR) در پنج ایستگاه هیدرومتری حوزه آبخیز کرج (گچسر، سیرا کلوان، سیرا کرج، نشتارود و مورود) طی دوره‌ای ۳۰ ساله، از ابتدای سال آبی ۱۳۶۹ تا پایان سال آبی ۱۳۹۷ مورد ارزیابی قرار گرفتند. نتایج حاصل از مقایسه عملکرد مدل‌ها بر اساس معیارهای استاندارد دقت پیش‌بینی (مانند NSE، RMSE و MAE) و آزمون‌های آماری نشان داد که مدل‌های هیبریدی مبتنی بر پایه FCMR به طور چشمگیری برتر از مدل‌های مبتنی بر

غرب کشور. دانشگاه تهران.

بهارلو، ر. ۱۳۸۷. پیش‌بینی سری زمانی با وابستگی‌های درازمدت با استفاده از شبکه عصبی بازگشتی نارکس. دوازدهمین کنفرانس دانشجویی مهندسی برق ایران.

<https://civilica.com/doc/69215/certificate/print>

خرمی‌پور، ز.، ولیخان‌انارکی، م. و فرزین، س. ۱۴۰۳. رویکردی جدید در روندیابی سیلاب بر مبنای تلفیق نظریه بیز، ماشین بردار پشتیبان و الگوریتم بهینه‌سازی فراابتکاری. نشریه آبیاری و زهکشی ایران. ۱۸(۳): ۴۰۹-۴۲۰.

https://idj.iaid.ir/article_198946.html

رحیمی‌بندرآبادی، س.، رضیعی، ط. و ثقفیان، ب. ۱۴۰۲. پایش خشکسالی هیدرولوژیکی در حوزه آبخیز دریای خزر. مهندسی و مدیریت آبخیز. ۱۵(۴): ۵۷۰-۵۸۷.

<https://doi.org/10.22092/IJWMSE.2023.123012.1533>

رستمی، س.، شاهی‌نژاد، ب.، یونسی، ح.، ترابی‌پوده، ح. و دهقانی، ر. ۱۴۰۰. تحلیل مدل‌های هوش مصنوعی هیبریدی نوین در برآورد دبی سیلابی: مطالعه موردی: حوضه آبریز کشکان. هیدروژئومورفولوژی. ۱۸(۲۹): ۱۸۷-۲۰۱.

<https://doi.org/10.22034/HYD.2022.49807.1620>

معروفی‌نیا، ا.، شرافتی، ا.، عبقری، ه. و حسن‌زاده، ی. ۱۴۰۲. پیش‌بینی جریان رودخانه کورکورسر نوشهر با استفاده از مدل‌های هیبریدی هوش مصنوعی. مدل‌سازی و مدیریت آب و خاک. ۳(۱): ۱۸۱-۱۹۹.

<https://doi.org/10.22098/MMWS.2022.11657.1150>

Araghinejad, S. 2014. Data-Driven Modeling: Using MATLAB® in Water Resources and Environmental Engineering. Springer. <https://doi.org/10.1007/978-94-007-7506-0>

Asif, M., Kuglitsch, M. M., Pelivan, I. and Albano, R. 2025. Review and Intercomparison of Machine Learning Applications for Short-term Flood Forecasting. Water Resources Management. 39(5): 1971-1991. <https://doi.org/10.1007/S11269-025-04093-X/FIGURES/6>

Asplin, B. R., Flottemesch, T. J. and Gordon, B. D. 2006. Developing models for patient flow and daily surge capacity research. Academic Emergency Medicine. 13(11): 1109-1113. <https://doi.org/10.1197/J.AEM.2006.07.004>

Brunner, M. I., Slater, L., Tallaksen, L. M. and Clark, M. 2021. Challenges in modeling and predicting floods and droughts: A review. Wiley

هرچند مدل‌های هیبریدی FCMR-NARX و FCMR-ACOR بالاترین دقت را داشتند، اما آزمون‌های آماری نشان داد که تفاوت دقت آن‌ها با مدل انفرادی GRNN از نظر آماری معنی‌دار نیست. به‌طور کلی نتایج حاصل از این پژوهش، با یافته‌های رستمی و همکاران (۱۴۰۰) و Huan (2024) همخوانی دارد. با توجه به هزینه‌های محاسباتی بالا، زمان آموزش طولانی‌تر و نیاز به منابع سخت‌افزاری و تخصصی بیشتر در مدل‌های هیبریدی، به‌ویژه در شرایط عملیاتی با منابع محدود، مدل انفرادی GRNN به‌عنوان گزینه‌ای با توجه اقتصادی برتر برای کاربردهای عملی در حوزه آبخیز کرج پیشنهاد می‌شود. این مدل با حفظ دقت رقابتی، سادگی پیاده‌سازی و سرعت بالای پیش‌بینی، برای استفاده در سیستم‌های هشدار زودرس سیلاب و مدیریت منابع آب در مقیاس محلی مناسب‌تر است.

در مجموع، این پژوهش موفق به توسعه یک جعبه‌ابزار منعطف مدل‌سازی سیلاب شد که قابلیت انتخاب مدل مناسب بر اساس نیازهای دقت و محدودیت‌های عملیاتی را فراهم می‌آورد. نتایج تأکید می‌کنند که هیبریدسازی همیشه به بهبود عملکرد منجر نمی‌شود و انتخاب کاتالیزور باید با ساختار مدل پایه و ویژگی‌های داده‌ای حوزه هماهنگ باشد. مدل‌های هیبریدی FCMR می‌توانند در مطالعات تحقیقاتی پیشرفته یا حوزه‌هایی با داده‌های غنی‌تر به کار گرفته شوند، درحالی‌که GRNN انفرادی گزینه‌ای عملی و اقتصادی برای مدیریت ریسک سیلاب در حوزه‌های مشابه کرج است.

منابع

اعلمی، م.، اردستانی، م. و ملک محمدی، ب. ۱۴۰۳. مدل‌سازی توان سیل خیزی در آبخیز زرينه‌رود با استفاده از مدل‌های هوش مصنوعی. پژوهش‌های آبخیزداری. ۳۷(۱): ۲-۱۷. <https://doi.org/10.22092/WMRJ.2023.360973.1513>

امیدوار، ک.، نبوی‌زاده، م. و ثمره‌قاسم، م. ۱۳۹۴. ارزیابی دقت شبکه عصبی مصنوعی بازگشتی نارکس در پیش‌بینی بارش روزانه در استان کرمان. جغرافیای طبیعی. ۲۷(۸): ۵۷-۷۴. <http://noo.rs/tOJPq>

انصاری‌قوجقار، م. ۱۳۹۹. توسعه جعبه‌ابزار پیش‌بینی عملکرد محصول استراتژیک گندم با استفاده از الگوریتم‌های یادگیری ماشین به‌منظور کاهش مخاطرات امنیت غذایی (مطالعه موردی: استان البرز). تحقیقات آب و خاک ایران. ۵۳(۱۰): ۲۲۷۷-۲۲۹۴. <https://doi.org/10.22059/IJSWR.2022.342638.669260>

انصاری‌قوجقار، م. ۱۴۰۱. مدل‌سازی و پیش‌بینی طوفان‌های گردوغبار با استفاده از مدل‌های هیبریدی یادگیری ماشین در غرب و جنوب

- networks: Influence of spatial variability. *WIT Transactions on Ecology and the Environment*. 116: 409–417. <https://doi.org/10.2495/AIR080411>
- Kisi, O., Tombul, M. and Kermani, M. Z. 2015. Modeling soil temperatures at different depths by using three different neural computing techniques. *Theoretical and Applied Climatology*. 121(1–2): 377–387. <https://doi.org/10.1007/S00704-014-1232-X/FIGURES/15>
- Martinez-Zeron, E., Aceves-Fernandez, M. A., Gorrostieta-Hurtado, E., Sotomayor-Olmedo, A. and Ramos-Arreguín, J. M. 2014. Method to Improve Airborne Pollution Forecasting by Using Ant Colony Optimization and Neuro-Fuzzy Algorithms. *International Journal of Intelligence Science*. 4(4): 81–90. <https://doi.org/10.4236/IJIS.2014.44010>
- Socha, K. and Dorigo, M. 2008. Ant colony optimization for continuous domains. *European Journal of Operational Research*. 185: 1155–1173.
- Specht, D. F. 1991. A General Regression Neural Network. *IEEE Transactions on Neural Networks*. 2(6): 568–576. <https://doi.org/10.1109/72.97934>
- Tahroudi, M. N., Ramezani, Y., de Michele, C. and Mirabbasi, R. 2021. Flood routing via a copula-based approach. *Hydrology Research*. 52(6): 1294–1308. <https://doi.org/10.2166/NH.2021.008>
- Tien Bui, D., Bui, Q. T., Nguyen, Q. P., Pradhan, B., Nampak, H. and Trinh, P. T. 2017. A hybrid artificial intelligence approach using GIS-based neural-fuzzy inference system and particle swarm optimization for forest fire susceptibility modeling at a tropical area. *Agricultural and Forest Meteorology*. 233: 32–44. <https://doi.org/10.1016/j.agrformet.2016.11.002>
- Tokar, A. S. and Johnson, P. A. 1999. Rainfall-Runoff Modeling Using Artificial Neural Networks. *Journal of Hydrologic Engineering*. 4(3): 232–239. [https://doi.org/10.1061/\(ASCE\)1084-0699\(1999\)4:3\(232\)](https://doi.org/10.1061/(ASCE)1084-0699(1999)4:3(232))
- Interdisciplinary Reviews: Water. 8(3): e1520. <https://doi.org/10.1002/WAT2.1520>
- Fill, H. D. and Steiner, A. A. 2003. Estimating Instantaneous Peak Flow from Mean Daily Flow Data. *Journal of Hydrologic Engineering*. 8(6): 365–369. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2003\)8:6\(365\)](https://doi.org/10.1061/(ASCE)1084-0699(2003)8:6(365))
- García-Feal, O., González-Cao, J., Fernández-Nóvoa, D., Astray Dopazo, G. and Gómez-Gesteira, M. 2022. Comparison of machine learning techniques for reservoir outflow forecasting. *Natural Hazards and Earth System Sciences*. 22(12): 3859–3874. <https://doi.org/10.5194/NHESS-22-3859-2022>
- Ghorbani, M. A., Khatibi, R., Karimi, V., Yaseen, Z. M. and Zounemat-Kermani, M. 2018. Learning from Multiple Models Using Artificial Intelligence to Improve Model Prediction Accuracies: Application to River Flows. *Water Resources Management*. 32(13): 4201–4215. <https://doi.org/10.1007/S11269-018-2038-X>
- Hathaway, R. J. and Bezdek, J. C. 1993. Switching Regression Models and Fuzzy Clustering. *IEEE Transactions on Fuzzy Systems*. 1(3): 195–204. <https://doi.org/10.1109/91.236552>
- Huan, S. 2024. Geographic heterogeneity of activation functions in urban real-time flood forecasting: Based on seasonal trend decomposition using Loess-Temporal Convolutional Network-Gated Recurrent Unit model. *Journal of Hydrology*. 636: 131279. <https://doi.org/10.1016/J.JHYDROL.2024.131279>
- Huang, X. C., Lin, Y. Y., Zhang, J. P. and Chen, X. M. 2006. Ligand-directed strategy for zeolite-type metal-organic frameworks: zinc(II) imidazoles with unusual zeolitic topologies. *Angewandte Chemie (International Ed. in English)*. 45(10): 1557–1559. <https://doi.org/10.1002/ANIE.200503778>
- Ibarra-Berastegi, G., Elias, A., Barona, A., Senz, J., Ezcurra, A. and Diaz De Argandona, J. 2008. Prediction of air pollution levels using neural

Development of a Flood Modeling Toolbox Based on Dual Hybrid Artificial Intelligence Metamodels: A Case Study of the Karaj Watershed

S. Hoseinnejad Salimi¹, M. Ansari Ghojghar^{*2}, A. Malekian³, M. Ghadimi⁴

Recived: Apr.29, 2026

Accepted: May.09, 2026

Abstract

The present research aimed at developing a comprehensive flood modeling toolkit based on hybrid dual-AI frameworks evaluated six models including two individual models (FCMR and GRNN) and four hybrid dual models (FCMR-NARX, FCMR-ACOR, GRNN-NARX, and GRNN-ACOR) at five hydrometric stations in the Karaj watershed (Gachsar, Sira-kalvan, Sira-karaj, Neshatarud and Morud) over a 30-year period from the beginning of the water year 1990 to the end of the water year 2018. The results, based on statistical criteria (R, NSE, RMSE, MAE), indicated that hybrid models based on FCMR (particularly FCMR-NARX and FCMR-ACOR) have the highest accuracy. However, statistical tests did not show a significant difference in accuracy between these models and the individual GRNN model. On the other hand, hybridizing the GRNN model with NARX and ACOR catalysts due to structural incompatibilities reduced its accuracy. Considering the computational complexity, long training time and higher implementation costs of hybrid models, the individual GRNN model is proposed as an optimized option with economic and operational justification for use in flood warning systems and water resource management in similar watersheds. This study emphasizes the necessity of coordination between the base model structure and the hybridization method to achieve effective performance improvement.

Keywords: FCMR (Fuzzy Cognitive Map-based Regression), Flood prediction, GRNN (Generalized Regression Neural Network), Individual Model, Neural Network

1- M.Sc. Graduate in Watershed Management, Faculty of Natural Resources, University of Tehran, Karaj, Iran

2- Assistant Professor, Department of Reclamation of Arid and Mountainous Regions, University of Tehran, Tehran, Iran

3- Professor of Department of Reclamation of Arid and Mountainous Regions, University of Tehran, Tehran, Iran

4- Associate Professor, Faculty of Geography, University of Tehran, Tehran, Iran

(*- Corresponding Author Email: ansari.ghojghar@ut.ac.ir)