

## پیش‌بینی میزان دبی متوسط ماهیانه رودخانه کارون با استفاده از روش ترکیبی GRU-LSTM

پویا احمدی<sup>۱</sup>، حسین عارفی<sup>۲</sup>، نازیلا کاردان<sup>۳</sup>

۱. دانشجوی کارشناسی ارشد گروه مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران، تهران

۲. دانشیار، گروه مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران، تهران

۳. استادیار، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه شهید مدنی آذربایجان، تبریز، ایران

(تاریخ دریافت ۱۳۹۸/۱۲/۱۲؛ تاریخ تصویب ۱۳۹۹/۰۳/۰۳)

## چکیده

مدل‌سازی دبی رودخانه در مدیریت منابع آب و مدیریت ریسک اهمیت زیادی دارد. این امر در مناطق کوهستانی اهمیت بیشتری پیدا می‌کند، زیرا بیشتر جمعیت‌های پایین‌دست منطقه، وابستگی زیادی به کشاورزی و فعالیت‌های تجاری مانند تولید برق دارند. در این زمینه، طی سال‌های اخیر، مدل‌های یادگیری ماشینی به دلیل دقت زیاد در پیش‌بینی از طریق یادگیری به صورت جعبه‌سیاه مورد توجه زیادی قرار گرفته‌اند. از این‌رو در مطالعه حاضر، نوعی رویکرد ترکیبی برای پیش‌بینی دبی متوسط ماهیانه رودخانه کارون پیشنهاد شده است که در آن از ترکیب شبکه‌های عصبی LSTM و GRU استفاده می‌شود. LSTM نوعی شبکه عصبی یادگیری عمیق است که توانایی اضافه کردن مفهوم زمان به مدل‌سازی را دارد؛ از این‌رو در پژوهش حاضر به دلیل ماهیت سری زمانی داده‌ها، این روش مورد توجه قرار گرفته است. این شبکه به دلیل داشتن دروازه‌های زیاد، بسیار کند عمل می‌کند که برای جبران آن، از لایه‌های GRU که نمونه دیگری از شبکه‌های یادگیری عمیق هستند، استفاده می‌شود. به منظور پیش‌بینی دبی متوسط ماهیانه رودخانه کارون از داده‌های آماری ایستگاه ملاثانی برای دوره ۲۱ ساله از یکم فروردین ۱۳۷۴ تا ۲۹ اسفند ۱۳۹۴ استفاده شده و مدل‌سازی براساس پنج ترکیب ورودی با مقادیر دبی رودخانه با تأخیر یک‌ماهه انجام شده است. رویکرد پیشنهادی با سایر روش‌های موجود مانند ماشین بردار پشتیبان، سیستم استنتاج فازی-عصبی تطبیقی و مدل رگرسیون خطی چندگانه مورد مقایسه قرار گرفت و نشان داده شد که رویکرد پیشنهادی نسبت به سایر روش‌های مقایسه‌شده دقت بسیار زیادی دارد.

**کلیدواژگان:** پیش‌بینی، دبی ماهیانه، روش ماشین بردار پشتیبان، روش GRU-LSTM، رودخانه کارون.

## مقدمه

برآورد دبی رودخانه‌ها به خصوص دبی اوج تأثیر زیادی بر برنامه‌ریزی و مدیریت حوضه رودخانه‌ها، ارزیابی ریسک، کنترل سیلاب و خشکسالی و همچنین، توسعه و مدیریت منابع آبی خواهد داشت [۱]. دبی رودخانه‌ها متأثر از عوامل محیطی زیادی همچون میزان بارش، شیب، ارتفاع، کاربری اراضی، پوشش گیاهی و مشخصات مورفولوژی و نیز رفتار هیدرولیکی رودخانه همانند زبری و تعامل بین میزان جریان آب و کانال اصلی هستند. این موضوع سبب شده است مدل‌سازی دبی رودخانه به یک رابطه غیرخطی پیچیده تبدیل شود و استفاده از مدل‌های قدیمی که برای مدل‌سازی دبی رودخانه‌ها از روابط خطی استفاده می‌شود، منجر به حصول نتایج دقیقی نشود. بر اساس تحقیقی که در ارتباط با شکست سدها انجام شد، مشخص شد که عدم بررسی و شناخت کافی از دبی پیک سیلاب‌ها، به شکست سدها منجر می‌شود [۲]. به همین دلیل، مدل‌سازی دقیق دبی پیک رودخانه‌ها به پیشگیری و موفقیت در کارهای اجرایی منجر خواهد شد. در سال ۲۰۰۰ گوویندراجو مدل‌های هیدرولوژی موجود برای برآورد دبی سیلاب را در سه دسته مدل‌های ریاضی-فیزیکی، مدل‌های ژئومورفولوژیکی و مدل‌های تجربی تقسیم کرد [۳]. در مدل‌های دسته اول، با استفاده از معادلات دیفرانسیل ویژگی‌های فیزیکی سیستم هیدرولوژیکی بیان می‌شود. در دسته دوم خصوصیات ژئومورفولوژیکی سیستم بیان شده و در دسته سوم، با استفاده از مدل‌های تجربی معروف به مدل جعبه‌سیاه سعی می‌شود بدون توجه به خصوصیات فیزیکی سیستم رابطه‌ای بین ورودی و خروجی‌های آن ایجاد شود. به این منظور، تلاش پژوهشگران بر آن بوده است تا با استفاده از مدل‌های تجربی که کمتر مسائل فیزیکی را در نظر می‌گیرند، به دقت زیادی در تخمین دبی رودخانه‌ها دست یابند.

در سال‌های اخیر تکنیک‌های هوش مصنوعی که به صورت جعبه‌سیاه عمل می‌کنند، مانند شبکه‌های عصبی مصنوعی<sup>۱</sup>، ماشین‌های بردار پشتیبان<sup>۲</sup>، منطق فازی<sup>۳</sup> و الگوریتم ژنتیک به طور گسترده در مباحث هیدرولوژی استفاده شده‌اند [۳]. پیش‌بینی سیلاب ساعتی رودخانه لان

یانگ در کشور تایوان با استفاده از روش ماشین بردار پشتیبان انجام شد و نشان داده شد این روش برای پیش‌بینی سیلاب یک‌ساعته دقت زیادی دارد [۴]. Yu و همکاران در مطالعه‌ای دیگر با استفاده از روش ماشین بردار پشتیبان سیل ساعتی رودخانه لان یانگ در تایوان را پیش‌بینی کرده و بیان کردند که روش یادشده در پیش‌بینی رویدادهای سیل در ۱ تا ۶ ساعت آینده دقت مناسب و قابل قبولی دارد [۵]. Wang و همکاران طی پژوهشی مدل‌سازی دبی رودخانه را با استفاده از مدل‌های ماشین بردار پشتیبان، الگوریتم ژنتیک، سیستم استنتاج عصبی و تطبیقی فازی انجام دادند. آنها نشان دادند بهترین عملکرد به ازای داده‌های استفاده‌شده در مراحل آموزش و آزمون، به ترتیب به مدل‌های سیستم استنتاج عصبی-تطبیقی فازی، ژنتیک و ماشین بردار پشتیبان اختصاص دارد. قربانی و علی‌نژاد طی مطالعه‌ای سیلاب رودخانه قزلایرماق ترکیه را با استفاده از مدل‌های شبکه عصبی مصنوعی، الگوریتم ژنتیک و نروفازی پیش‌بینی کردند [۷]. نتایج پژوهش آنها نشان داد هیدروگراف شبیه‌سازی‌شده بیانگر دقت زیاد الگوریتم ژنتیک است. Zahiri & Azamathulla در پژوهشی دبی جریان را به وسیله روش ژنتیک و مدل درختی M5 مدل‌سازی کردند [۸]. نتایج پژوهش آنها بیانگر زیاد بودن دقت روش ژنتیک بود.

He و همکاران در مطالعه‌ای برای پیش‌بینی جریان رودخانه‌ای در چین، از ماشین بردار پشتیبان استفاده کردند و دریافتند این مدل عملکرد مناسب‌تری نسبت به شبکه عصبی مصنوعی و سیستم استنتاج فازی دارد [۹]. حسن‌پور و همکاران طی پژوهشی به منظور شبیه‌سازی فرایند بارش-رواناب در حوضه آبریز ناورود از مدل ولترای مرتبه محدود و شبکه عصبی مصنوعی بهره گرفتند [۱۰]. به این منظور، به ترتیب ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد آنها برای آزمون مدل به کار برده شدند. نتایج پژوهش آنها نشان داد مدل هوشمند شبکه عصبی مصنوعی توانایی بیشتری نسبت به مدل ولترا در پیش‌بینی رواناب حوضه آبریز ناورود دارد. دربندی و پورحسینی طی پژوهشی از روش پرسپترون چند لایه ترکیبی برای پیش‌بینی جریان ماهیانه رودخانه استفاده کردند و نتیجه گرفتند عملکرد روش پرسپترون چند لایه ترکیبی برای پیش‌بینی جریان رودخانه بسیار رضایت‌بخش است [۱۱]. Ghose در پژوهشی برای

1. Artificial Neural Network (ANN)  
2. Support Vector Machine (SVM)  
3. Fuzzy Logic

داد رویکرد RF بهترین دقت در مدل‌سازی جریان را داشته است.

سلطانی و همکاران در پژوهشی جریان روزانه رودخانه ليقوان را با استفاده از دو روش شبکه عصبی مصنوعی و الگوریتم ژنتیک مدل‌سازی کرده و بهترین عملکرد آنها را با توجه به معیارهای مختلف ارزیابی کردند. نتایج پژوهش آنها نشان داد الگوریتم ژنتیک دقت بیشتری نسبت به روش شبکه عصبی مصنوعی دارد. خسروی و همکاران در مطالعه‌ای برای تعیین بهترین تابع فعال‌سازی لایه خروجی در شبکه عصبی به منظور پیش‌بینی دبی اوج در دو حوضه آبخیز گتهد و گلینک در طالقان، به این نتیجه رسیده‌اند که تابع خطی با داشتن کمترین RMSE برای لایه خروجی مناسب است [۱۸]. نوری و همکاران در تحقیقی دبی رودخانه‌ای را توسط مدل ماشین بردار پشتیبان پیش‌بینی کردند [۱۹]. نتایج پژوهش آنها نشان داد با استفاده از آنالیز مؤلفه اصلی (PCA) تعداد متغیرهای ورودی به ماشین بردار پشتیبان از ۱۸ متغیر به ۵ متغیر کاهش یافته است. پورحقی و همکاران در پژوهشی مدل‌سازی هوشمند سری زمانی جریان ماهانه از یک دوره آماری ۲۶ ساله برای حوضه رودخانه شور را انجام دادند و برای بهینه‌سازی وزن‌های اتصال در بین لایه‌های مختلف شبکه عصبی مصنوعی از الگوریتم ژنتیک استفاده کردند [۲۰]. نتایج پژوهش آنها با توجه به ضریب همبستگی ۰/۸۴ دقت زیاد شبکه عصبی مصنوعی در برآورد و تخمین جریان ماهانه رودخانه یادشده را نشان داد. حقی‌زاده و همکاران در مطالعه‌ای مدل‌سازی بارش-رواناب حوضه خرم‌آباد را با استفاده از رویکرد ANN و ANFIS و روش رگرسیون چندمتغیره MLR انجام دادند [۲۱]. نتایج پژوهش آنها نشان داد مدل ANFIS روش مناسب‌تری است. سپهری و همکاران در پژوهشی با استفاده از ترکیب شبکه عصبی پرسپترون چندلایه و الگوریتم ژنتیک، دبی حداکثر رودخانه یلفان را برآورد کردند [۲۲]. نتایج پژوهش آنها برتری نتایج به‌دست‌آمده از مدل ترکیبی شبکه عصبی پرسپترون چند لایه و الگوریتم ژنتیک نسبت به مدل شبکه عصبی را نشان داد.

از بررسی پژوهش‌های مختلف چنین برمی‌آید که برای مدل‌سازی دقیق دبی رودخانه که یکی از چالش‌های مهم در فرایند مدیریت و مهندسی منابع آب است، روش‌های بسیار زیادی وجود دارد که هر یک ایرادها و معایب خاص

مدل‌سازی جریان رودخانه از رویکرد شبکه عصبی بازگشتی برای به‌دست آوردن رابطه بین دبی و عمق جریان استفاده کرد [۱۲]. به این منظور، مدل پیش‌بینی جریان روزانه با استفاده از سطح آب و دبی با دوره‌های مختلف تأخیر به عنوان ورودی و جریان به عنوان خروجی به‌دست آمد. به‌تازگی Petty & Dhingra از شبکه‌های LSTM برای پیش‌بینی دبی جریان از طریق مدل‌سازی بارش-رواناب استفاده کردند [۱۳]. در پژوهشی یک مدل ترکیبی برای پیش‌بینی دبی جریان ارائه شده و عملکرد نسبی آن با مدل‌های LSTM و GRU و با استفاده از مجموعه داده‌های اطلاعاتی سازمان زمین‌شناسی ایالات متحده (USGS) مقایسه شده است [۱۴]. در پژوهش یادشده داده ۳۵ سال آبی از ۱۰ حوضه رودخانه MOPEX با حوضه‌های مختلف از مناطق مختلف آب‌وهوایی متفاوت به‌عنوان مطالعه موردی استفاده شد. نتایج پژوهش یادشده نشان داد عملکرد مدل ترکیبی تقریباً با GRU در پیش‌بینی دبی جریان یکسان بود، ولی مدل GRU تا حدودی نتایج بهتری در ۶ حوضه داشت. همچنین، مشخص شد برخی مدل‌ها ممکن است فقط برای انواع خاصی از مجموعه داده‌ها مناسب‌تر باشند. Dou و همکاران در تحقیقی به ارزیابی روش‌های موجود برای برآورد دبی رودخانه شایینگ چین<sup>۱</sup> بر اساس روش‌های شبکه عصبی مصنوعی و رگرسیونی پرداختند [۱۵]. به این منظور، آنها با بررسی مزایا و معایب روش‌های موجود، نشان دادند روش پرسپترون چندلایه و پلی‌نومیل‌های درجه ۳ نسبت به سایر روش‌های موجود برتری دارند. Hussain & Khan در پژوهشی جریان ماهیانه رودخانه هونزا واقع در پاکستان<sup>۲</sup> را بر اساس روش‌های یادگیری ماشینی با ارائه روش‌های RF<sup>۳</sup>، SVR<sup>۴</sup> و MLP<sup>۵</sup> مدل‌سازی کردند [۱۶]. به این منظور، آنها برای تهیه یک مدل پیش‌بینی دقیق، داده‌های جریان ماهانه رودخانه بر اساس تابع همبستگی (ACF) و تابع همبستگی جزئی (PACF<sup>۷</sup>) با مقادیر پیشین جریان رودخانه برای شناسایی پیش‌بینی‌های مناسب را بررسی و مقایسه کردند. نتایج پژوهش آنها نشان

1. Shaying River, China
2. Hunza River, Pakistan
3. Random Forest (RF)
4. Support Vector Regression (SVR)
5. Multi-Layer Perceptron (MLP)
6. Auto Correlation (ACF)
7. Partial Auto-Correlation (PACF)

آب ونک، آب کیار و بازفت تشکیل شده است و از ارتفاعات مختلفی همچون ارتفاعات شمالی اردکان فارس و جنوب و غرب بروجن سرچشمه می‌گیرد. رود کارون در شمال شوشتر به دو شاخه تقسیم می‌شود که در جنوب شوشتر با یکدیگر پیوند می‌یابند. مهم‌ترین شاخه فرعی کارون، رود دز است که در شمال شهر اهواز به کارون می‌پیوندد. رود کارون با ورود به اهواز، شهر را به دو بخش شرقی و غربی تقسیم می‌کند که بخش اعظم آب آشامیدنی این شهر توسط رودخانه کارون تأمین می‌شود. شکل ۱ موقعیت محدوده مطالعاتی در حوضه کارون بزرگ را نشان می‌دهد.

ایستگاه‌های هیدرومتری زیادی همچون ملاثانی، فارسیات، اهواز، بامدژ و گتوند در طول مسیر رود کارون وجود دارند که در این تحقیق از اطلاعات آماری دبی رودخانه در ایستگاه هیدرومتری ملاثانی با کد ۳۰۷-۲۱ در ارتفاع ۱۸ متر از سطح دریا در بازه زمانی ۱۳۷۴/۱/۱ تا ۱۳۹۴/۱۲/۱ (۲۵۲ ماه) استفاده شده که در جدول ۱ و اطلاعات آماری این ایستگاه ارائه شده است. شکل ۲ موقعیت ایستگاه هیدرومتری ملاثانی را نشان می‌دهد.

خود را دارند. در مطالعه حاضر برای رفع نواقص و معایب روش‌های استفاده شده پیشین، سعی بر ارائه نوعی مدل ترکیبی جدید از شبکه‌های عصبی بازگشتی و مقایسه نتایج آن با روش‌های ANFIS، MLR و SVM بوده است.

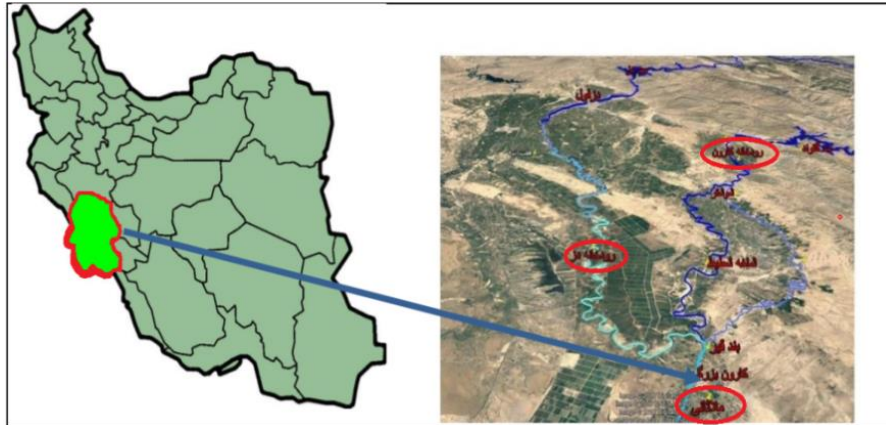
## مواد و روش‌ها

### منطقه مطالعه شده

رودخانه کارون با طول ۹۵۰ کیلومتر، بزرگ‌ترین و پرآب‌ترین رودخانه ایران است که از شمال شرقی به جنوب غربی استان خوزستان جاری است. حوضه آبریز کارون بزرگ با مساحت ۶۸۴۸۱ کیلومترمربع در محدوده جغرافیایی  $30^{\circ} 48' 52''$  طول شرقی و  $30^{\circ} 05' 34''$  عرض شمالی قرار دارد که ۲۳۲۶۰ کیلومترمربع آن مربوط به حوضه دز و ۴۵۲۲۱ کیلومترمربع آن مربوط به حوضه کارون است. این حوضه یکی از حوضه‌های مهم آبریز کشور به‌شمار می‌رود که در مسیر خود تأمین آب شرب مورد نیاز کشاورزی و صنعت ۱۶ شهر و ده‌ها روستا و هزاران هکتار اراضی کشاورزی، تولید انرژی برق‌آبی، طرح‌های پرورش ماهی و کارخانه‌های صنعتی را به عهده دارد. رودخانه کارون از چهار شاخه اصلی خراسان،



شکل ۱. موقعیت حوضه آبریز کارون بزرگ



شکل ۲. ایستگاه آب‌سنجی ملاثانی روی رودخانه کارون

با دقت بیشتری انجام شود. به این منظور، از روش نرمال‌سازی Min-Max استفاده شده است. در این روش با استفاده از رابطه ۱ نرمال‌سازی داده انجام می‌شود [۲۳]:

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

در این رابطه  $X_n$  معرف داده‌های نرمال‌شده،  $X_i$  معرف داده‌های مشاهداتی و  $X_{\max}$  و  $X_{\min}$  به ترتیب معرف داده‌های حداکثر و حداقل است.

مقادیر دبی رودخانه برحسب مترمکعب بر ثانیه طی بازه زمانی ۲۱ سال آبی در تمامی ماه‌های سال در ایستگاه ملاثانی به صورت فایل اکسل از شرکت مادر تخصصی مدیریت منابع ایران اخذ شده است. با توجه به اینکه داده‌های ورودی دبی رودخانه محدوده عددی متفاوتی دارند، فرایند نرمال‌سازی داده‌ها برای اطمینان از عملکرد یکسان تمام پارامترهای مدل، انجام می‌شود تا تمام اعداد در محدوده یکسان صفر و یک قرار گیرند و فرایند تحلیل

جدول ۱. مشخصات آماری دبی رودخانه در ایستگاه ملاثانی (شرکت مادر تخصصی مدیریت منابع ایران، ۱۳۹۸)

انحراف معیار	MAX (مترمکعب بر ثانیه)	MIN (مترمکعب بر ثانیه)	میانگین دبی (مترمکعب بر ثانیه)	تعداد داده‌ها (ماه)	بازه زمانی	تقسیم‌بندی
۲۸۳	۵۶۰۰	۱۱۰	۶۵۰	۲۰۴	فروردین ۱۳۷۴ تا اسفند ۱۳۹۰	آموزش
۲۹۰	۶۱۰۰	۱۳۰	۶۹۷	۴۸	فروردین ۱۳۹۱ تا اسفند ۱۳۹۴	تست
۳۱۲	۵۴۰۰	۹۷	۵۱۳	۲۵۲	فروردین ۱۳۷۴ تا اسفند ۱۳۹۴	کل

روش‌های مقایسه‌ای  $C_1, \dots, C_n$  از قبل ناشناخته‌اند که مقادیر این ضرایب بیانگر رفتار محلی تابع هستند و از طریق روش کمترین مربعات<sup>۱</sup> و روش‌های رگرسیونی تخمین زده می‌شوند [۲۴].

• روش سیستم استنتاج فازی-عصبی تطبیقی (ANFIS<sup>۲</sup>)

سیستم استنتاج فازی-عصبی تطبیقی (ANFIS)، رویکردی برای تلفیق شبکه‌های عصبی و منطق فازی است که به

روش‌های مقایسه‌ای

• روش **Multiple Linear Regression (MLR)**

مدل MLR مدل رگرسیون خطی چندگانه است که از تعداد متغیرهای پیش‌بینی زیادی در فرایند مدل‌سازی استفاده می‌کند. فرم کلی مدل MLR به صورت رابطه ۲ است:

$$y = c_0 + c_1x_1 + c_2x_2 + \dots + c_nx_n \quad (2)$$

که در آن  $y$  مقدار مورد انتظار به‌عنوان تابعی از  $n$  متغیر مستقل  $x_0$  نشان داده شده است. مقادیر ضرایب  $c_0$

1. Least Square

2. Adaptive-Neuro Fuzzy Inference System

جدول ۲. روابط کرنل‌ها

نوع تابع	تابع کرنل
تانژانت هایپربولیک	$(x_i, x_j) = \tanh(\gamma x_i^T \cdot x_j + c)k$
چندجمله‌ای	$(x_i, x_j) = (\gamma x_i^T \cdot x_j + c)^d k$
خطی	$(x_i, x_j) = x_i^T \cdot x_j k$
گوسی	$k(x_i, x_j) = e^{-\frac{\ x_i - x_j\ ^2}{\delta^2}}$

دو مرحله اصلی در استفاده از مدل ماشین بردار پشتیبان، انتخاب کرنل مناسب و بهینه کردن پارامترهای مدل است. با توجه به مطالعات گذشته [۳۱ و ۳۲] بهترین کرنل، کرنل گوسی است. در تحقیق حاضر نیز از کرنل گوسی استفاده شده است. معادله ۳ مربوط به کرنل گوسی است که هنگام آموزش باید پارامترهای  $C$ ،  $\epsilon$  و  $\sigma$  در مدل بهینه شوند:

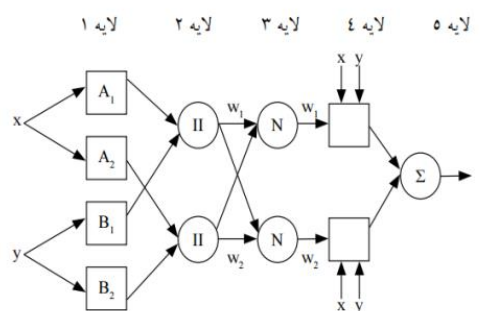
$$(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{\delta^2}\right)k \quad (3)$$

#### روش پیشنهادی: ترکیب شبکه LSTM و GRU

به منظور دستیابی به نتایج دقیق‌تر و کامل‌تر در مدل‌سازی دبی رودخانه‌ها، باید روش‌های خطی و غیرخطی با یکدیگر ادغام شوند. به‌تازگی رویکردهای مبتنی بر شبکه‌های عصبی بازگشتی و یادگیری عمیق برای این منظور پیشنهاد شده است. در میان نتایج برگرفته از روش‌های مبتنی بر شبکه‌های عصبی بازگشتی، عملکرد روش LSTM نسبت به سایر روش‌ها بهتر بوده است. LSTM نسخه بهبودیافته شبکه‌های بازگشتی است و به‌تازگی الگوریتم GRU برای بهبود این شبکه‌ها پیشنهاد شده است. با توجه به کارایی مناسب شبکه‌های GRU، در تحقیق حاضر سعی شده است با ترکیب شبکه‌های LSTM و GRU دقت پیش‌بینی این مدل بهبود داده شود. در فرایند ترکیب، خروجی لایه GRU به لایه LSTM ارسال می‌شود و خروجی لایه LSTM پس از ادغام به لایه‌های تمام‌متصل می‌رسد. خروجی لایه‌های تمام‌متصل نیز به لایه رگرسیون فرستاده می‌شود تا فرایند پیش‌بینی انجام گیرد. شکل ۴ کلیات روش پیشنهادی را نشان می‌دهد.

در واقع، روش پیشنهادی یک ساختار چهارلایه است. این چهار لایه عبارت‌اند از: Input layer، GRU، LSTM و Output. در لایه Input layer هریک از ویژگی‌های ورودی

منظور طراحی نگاشت غیرخطی بین پارامترهای ورودی و خروجی استفاده خواهد شد و در واقع این دو سیستم مکمل همدیگرند. رویکرد عصبی فازی از استراتژی قوانین یادگیری شبکه عصبی برای توسعه سیستم فازی استفاده می‌کند [۲۵]. ANFIS نوعی روش هوش مصنوعی است که هم‌اکنون در بسیاری از فرایندهای هیدرولوژیکی استفاده می‌شود. قابلیت شبکه عصبی برای یادگیری ساختار فازی با توجه به داده‌های ورودی-خروجی از جمله دلایل ترغیب محققان به استفاده از این مدل است [۲۶ و ۲۷]. الگوریتم یادگیری شبکه ANFIS نوعی الگوریتم ترکیبی است که با استفاده از الگوریتم گرادیان نزولی، ورودی‌های غیرخطی شبکه را به‌روزرسانی کرده و برای تنظیم کردن وزن‌های شبکه از تخمین حداقل مربعات بازگشتی استفاده می‌کند. ساختار مدل ANFIS در شکل ۳ نمایش داده شده است. این ساختار ۵ لایه دارد و هر لایه گره‌های مختلف دارد که هر گره در یک لایه ثابت یا تطبیقی است.



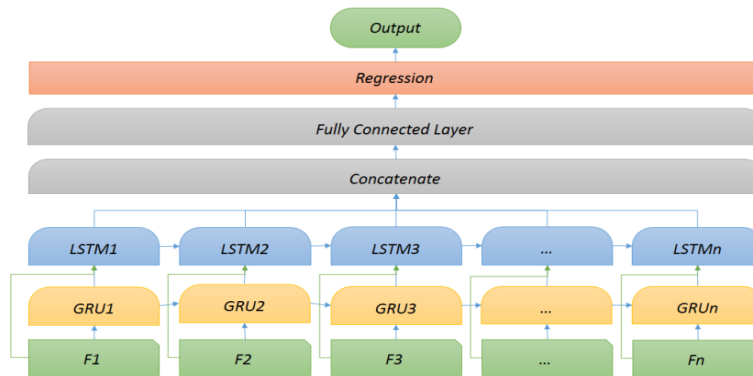
شکل ۳. ساختار شبکه ANFIS گره‌های ثابت و گره‌های تطبیقی هستند [۲۸]

#### • روش ماشین بردار پشتیبان (SVM)

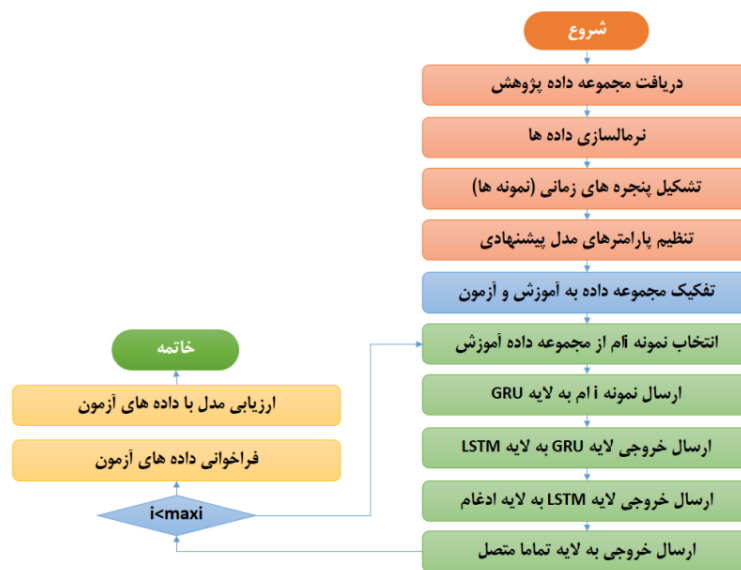
ماشین بردار پشتیبان براساس تئوری یادگیری آماری عمل می‌کند [۲۹] و یکی از انواع شبکه‌های عصبی است که عملکرد کلی آن توجه بیشتری به الگوهای طبقه‌بندی و تخمین رگرسیون غیرخطی دارد [۳۰]. ماشین‌های بردار پشتیبان از طریق انتقال فضای ورودی به فضایی با بعد بالاتر قابلیت حل مسائل غیرخطی را دارند که این کار از طریق توابع کرنل امکان‌پذیر است. کرنل‌های متفاوت زیادی همچون کرنل گوسی (RBF)، کرنل خطی، کرنل چندجمله‌ای و کرنل تانژانت هایپربولیک وجود دارند که روابط این کرنل‌ها در جدول ۲ آمده است.

بلوک GRU برای یادگیری نیاز خواهد بود. بلوک‌های GRU هم‌زمان وزن ویژگی و وزن ویژگی نسبت به ویژگی ماقبل را یاد می‌گیرند تا با بهره‌گیری از آن بتوانند نوسان‌های به‌وجودآمده برای دبی را پیش‌بینی کنند. در گام بعدی، خروجی لایه GRU به لایه LSTM می‌رسد و LSTM پس از پردازش روی داده‌های ورودی، نتیجه را به لایه تمام‌متصل ارسال می‌کند که تابع فعال‌ساز آن تابع سیگموئید است. این لایه وظیفه پیش‌بینی را به عهده دارد. لایه‌های تمام‌متصل همانند همتایان خود در شبکه‌های عصبی سنتی عمل می‌کنند و تقریب ۹۰ درصد از پارامترهای یک شبکه عمیق را شامل می‌شوند. لایه تمام‌متصل این امکان را فراهم می‌کند که خروجی شبکه در قالب یک بردار با اندازه مشخص ارائه شود. شکل ۵ بلوک دیاگرام کلی روش پیشنهادی را نشان می‌دهد.

که مربوط به یک پیش‌بینی هستند، به ورودی‌های GRU داده می‌شوند. در لایه GRU، ورودی لایه بردارهایی هستند که از لایه Input گرفته شده‌اند. در لایه LSTM ورودی لایه بردارهایی هستند که از لایه GRU گرفته شده‌اند. در لایه Output خروجی شبکه LSTM ابتدا Flatten می‌شود. در مدل پیشنهادی پس از دریافت مجموعه داده پژوهش، عملیات نرمال‌سازی داده‌ها انجام می‌شود. در ادامه، داده‌ها به دسته آموزش و آزمون تقسیم می‌شوند. پیشنهاد اولیه ۸۰ درصد برای داده‌های آموزش و ۲۰ درصد برای داده‌های آزمون است. سپس، فرایند یادگیری مدل با استفاده از شبکه ترکیبی GRU-LSTM شروع می‌شود. در این گام به ازای هر ویژگی از مجموعه داده پژوهش، یک بلوک GRU در نظر گرفته می‌شود. به طور مثال، اگر مجموعه داده شامل ۷ ویژگی باشد، تعداد ۷



شکل ۴. ساختار الگوریتم پیشنهادی



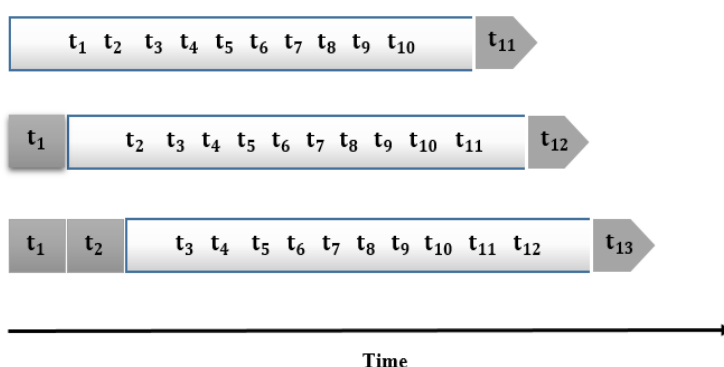
شکل ۵. بلوک دیاگرام روش پیشنهادی GRU-LSTM




گرفته می‌شوند. این عمل برای تمامی داده‌ها از جمله داده‌های آموزشی و آزمون استفاده می‌شود.

#### • ارسال ورودی به لایه GRU

پس از آنکه عملیات پیش‌پردازش روی مجموعه داده‌های پژوهشی انجام گرفت، پنجره‌های لغزان (زمانی) تشکیل شده و داده‌ها در قالب پنجره‌های لغزان و به‌عنوان ورودی به لایه GRU ارسال می‌شوند. در این گام، تعداد بلوک‌های لایه GRU به اندازه ویژگی‌های مجموعه داده‌های پژوهش خواهد بود. شکل ۷ چگونگی این فرایند را نشان می‌دهد.



شکل ۶. چگونگی ایجاد ورودی‌های مدل براساس ایده پنجره لغزان



شکل ۷. ارسال بردارهای تعبیه به لایه GRU

$$h_t = (1 - z)h_{t-1} + z_t h'_t$$

که در آن بردارهای به‌ترتیب گیت Update، گیت Rest، گیت شرطی و خروجی فعال است.  $[W_R, W_U, W_N, U_Z, U_R, U_N]$  به‌ترتیب ماتریس‌های قابل یادگیری، بایاس‌های قابل یادگیری، تابع فعال‌ساز و علامت ضرب نقطه‌ای بین عناصر هستند.

#### • ارسال خروجی لایه GRU به LSTM

گام بعدی در روش پیشنهادی برای پیش‌بینی دبی رودخانه، ارسال خروجی لایه GRU به عنوان ورودی به لایه LSTM است. شکل ۸ چگونگی این فرایند را نشان می‌دهد.

#### • تشکیل پنجره‌های لغزان

در این گام پنجره‌های لغزان برای پیش‌بینی میزان دبی تشکیل می‌شود. در شکل ۶ چگونگی این فرایند نمایش داده شده است. اساس پنجره‌های لغزان این است که برای پیش‌بینی گام  $n$ ام، از اطلاعات  $n-1$  گذشته استفاده می‌شود. برای نمونه، به منظور پیش‌بینی دبی زمانی  $t_{11}$  از تمامی مقادیر قبلی از زمان  $t_1$  تا  $t_{10}$  به عنوان ورودی استفاده شده و به همین ترتیب، برای پیش‌بینی  $t_{12}$  مقادیر قبلی از زمان  $t_2$  تا  $t_{11}$  به عنوان ورودی در نظر


در شکل ۷ لایه اول همان لایه ورودی و ویژگی‌ها و لایه دوم لایه GRU است. این شکل گویای ارسال نمونه‌ها با لایه GRU است. ورودی لایه GRU بردارهایی هستند که از لایه Input گرفته شده‌اند. این بردارها را به‌صورت  $Out_{embed} = [x_1, x_2, \dots, x_N]$  می‌توان نمایش داد. این بردارها با رابطه ۴ محاسبه می‌شوند:

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

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (۴)$$

$$h'_t = \sigma(W_h x_t + U_h (r_t \cdot h_{t-1}) + b_h)$$





شکل ۸. فرایند ارسال خروجی لایه LSTM به GRU

انتخاب بهترین روش مدل‌سازی، از معیارهای مختلفی از جمله جذر ریشه میانگین مربع خطا (RMSE)، ضریب تعیین ( $R^2$ ) و میانگین قدر مطلق خطا (MAE) استفاده می‌شود. توابع معیار و روابط ریاضی آنها به صورت روابط ۶ معرفی می‌شوند:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (T_i - Y_i)^2}{n}}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |T_i - Y_i| \quad (6)$$

$$R^2 = 1 - \frac{\sum [T_i - Y_i]}{\sum [Y - Y_i]}$$

در روابط یادشده  $T_i$  مقدار واقعی،  $Y_i$  مقدار پیش‌بینی شده،  $n$  تعداد داده‌ها، و  $Y$  میانگین مقادیر پیش‌بینی شده توسط مدل‌های پیش‌بینی کننده است.

### نتایج و بحث

در تحقیق حاضر برای مدل‌سازی دبی رودخانه کارون، از داده‌های دبی ماهیانه ۲۱ سال آماری (معادل ۲۵۲ ماه) این رودخانه استفاده شده که حدود ۲۰ درصد داده‌ها (معادل ۴۸ ماه) به عنوان داده‌های آزمون و ۸۰ درصد آن (معادل ۲۰۴ ماه) برای آموزش به کار برده شده است. برای پیش‌بینی میزان دبی  $Q(t)$ ، مجموعه‌ای از پنج الگوی ورودی در فاصله زمانی تأخیر ۱-۵ ماه استفاده شده است. هدف اصلی در این فرایند، استفاده از مقادیر ماه‌های قبل دبی رودخانه برای پیش‌بینی مقدار دبی ماه جاری است. یادآوری این نکته اهمیت دارد که پیش‌بینی یک ماه دبی رودخانه در حوضه کارون بزرگ برای مدیریت منابع آب استان بسیار حیاتی است، زیرا جریان این رودخانه، آب مورد نیاز زمین‌های کشاورزی اطراف را تأمین می‌کند. به همین دلیل، مجموعه‌ای از پنج ورودی با مدت زمان تأخیر تا ۵ ماه برای پیش‌بینی دبی رودخانه با بهره‌گیری از روش‌های SVM، MLR، و ANFIS و روش جدید که به صورت ترکیبی از شبکه GRU

ورودی LSTM در گام T بردار  $X \in R^E$  است که دنباله بردارهای مخفی<sup>۱</sup> در LSTM را نشان می‌دهد. این بردار از طریق رابطه ۵ محاسبه می‌شود:

$$i_t = \sigma(W_{i_t} [h_{t-1}, x_t] + b_{i_t})$$

$$f_t = \sigma(W_{f_t} [h_{t-1}, x_t] + b_{f_t})$$

$$g_t = \tanh(W_{g_t} [h_{t-1}, x_t] + b_{g_t}) \quad (5)$$

$$o_t = \sigma(W_{o_t} [h_{t-1}, x_t] + b_{o_t})$$

که در این روابط  $i_t$  گیت Input،  $f_t$  گیت Forget،  $g_t$  گیت Update و  $o_t$  گیت Output هستند. همچنین،  $W$  ماتریس‌های قابل یادگیری در شبکه عصبی،  $b$  بردارهای قابل یادگیری در شبکه عصبی،  $h_{t-1}$  مقدار Hidden State قبل و نیز  $x_t$  مقدار ورودی و  $\sigma$  تابع فعال‌سازی استفاده شده است. این لایه می‌تواند به صورت تک‌لایه یا به صورت پشته‌ای از لایه‌ها به کار گرفته شود. در حالت چند لایه به اصطلاح به آن LSTM عمیق یا پشته‌ای از LSTM ها گفته می‌شود.

### • ارسال خروجی به لایه تمام‌متصل

در آخرین لایه از روش پیشنهادی، لایه‌های تمام‌متصل وجود دارند که Feature Map های دوبعدی را به Feature Vector های یک‌بعدی برای ادامه فرایند نمایش ویژگی‌ها تبدیل می‌کنند. از سویی، این لایه وظیفه محاسبه امتیاز دسته‌های کلاس‌های اشیا را به عهده دارد. لایه‌های تمام‌متصل همانند همتایان خود در شبکه‌های عصبی سنتی عمل می‌کنند و تقریب ۹۰ درصد از پارامترهای یک شبکه عمیق باور را شامل می‌شوند. لایه تمام‌متصل این امکان را می‌دهد که خروجی شبکه در قالب یک بردار با اندازه مشخص ارائه شود. از این بردار برای رده‌بندی اشیا و یا ادامه فرایند پردازش نیز استفاده می‌شود.

### • معیارهای ارزیابی

در مطالعه حاضر، به منظور مقایسه دقت مدل‌سازی و

## نتایج مدل سازی با روش MLR

پیاده سازی مدل MLR برای به دست آوردن ضرایب رگرسیون، با استفاده از داده های آموزشی از طریق محیط برنامه نویسی MATLAB 2014 انجام شده است. در جدول ۴ نتایج مربوط به مدل سازی با روش MLR آورده شده است.

LSTM طراحی شده است، مورد استفاده قرار گرفته است. این الگوهای ورودی در جدول ۳ ارائه شده اند.  $Q(t)$  مقدار دبی پیش بینی شده رودخانه،  $Q(t-1)$  مقدار ورودی اول با تأخیر زمانی یک ماه،  $Q(t-1)$  و  $Q(t-2)$  مقدار ورودی دوم با تأخیر زمانی ۱ و ۲ ماه و به همین ترتیب است که از این طریق مقدار، دبی ماهیانه رودخانه پیش بینی شده است.

جدول ۳. الگوهای ورودی استفاده شده در مقیاس زمانی ماهیانه رود کارون

شماره ترکیب	ساختار الگو ورودی	خروجی
۱	$Q(t-1)$	$Q(t)$
۲	$Q(t-1), Q(t-2)$	$Q(t)$
۳	$Q(t-1), Q(t-2), Q(t-3)$	$Q(t)$
۴	$Q(t-1), Q(t-2), Q(t-3), Q(t-4)$	$Q(t)$
۵	$Q(t-1), Q(t-2), Q(t-3), Q(t-4), Q(t-5)$	$Q(t)$

جدول ۴. نتایج آماری الگوهای ورودی مدل MLR در پیش بینی دبی


آموزش			آزمون			شماره ترکیب
$R^2$	RMSE	MAE	$R^2$	RMSE	MAE	
۰/۸۶۵	۰/۳۱۹	۰/۱۴۳	۰/۷۹۳	۰/۴۱۹	۰/۳۱۱	۱
۰/۸۹۱	۰/۲۸۳	۰/۱۱۰	۰/۸۳۱	۰/۳۸۱	۰/۱۸۷	۲
۰/۹۱۱	۰/۲۶۵	۰/۱۰۹	۰/۸۶۵	۰/۳۷۷	۰/۱۷۳	۳
۰/۹۲۰	۰/۲۵۰	۰/۰۹۷	۰/۸۸۶	۰/۳۱۴	۰/۱۵۰	۴
۰/۹۲۳	۰/۲۴۱	۰/۰۹۱	۰/۸۹۰	۰/۳۰۵	۰/۱۴۰	۵

شکل ۹ رابطه معقول بین دبی مشاهداتی و پیش بینی شده برای داده های آزمون را با استفاده از مدل MLR نمایش می دهد، ولی باید به این نکته اشاره کرد که مدل MLR حاوی مقادیر منفی برای دبی پیش بینی شده است که از فرمولاسیون رگرسیون چندگانه نشئت می گیرد و باید از آنها صرف نظر کرد. همچنین، در این روش مقادیر پیک به علت Over-Estimated باید نادیده گرفته شوند، زیرا این روش در تخمین دبی های پیک ضعیف عمل می کند و موجب کاهش دقت نتایج می شود.

## نتایج مدل سازی با روش SVM

مدل SVM با استفاده از کدنویسی در محیط MATLAB انجام شده است. در این تحقیق از کرنل RBF با پارامترهای ( $\sigma=0.01$ ) برای مدل سازی دبی استفاده شد که طرح جست و جوی پارامترهای به کاررفته، الگوریتم تکامل پیچیده SCE-UA طبق پیشنهاد پژوهش های [۳۳] در آنالیزهای هیدرولوژی با موفقیت پیاده سازی شده است. جدول ۵ بیانگر نتایج مربوط به مدل SVM است.

در این جدول با توجه به معیارهای ارزیابی  $MAE=0.091$ ،  $RMSE=0.241$  و  $R^2=0.923$  برای داده های آزمون و  $MAE=0.140$ ،  $RMSE=0.305$  و  $R^2=0.890$  برای داده های آموزشی، ترکیب ۵ نسبت به سایر ترکیب ها به طور نسبی دارای نتایج بهتری است. این امر نشان می دهد در روش MLR، استفاده از سوابق دبی ماه های قبل رودخانه حتی تا ۵ ماه، موجب بهبود نتایج می شود به طوری که مقدار RMSE برای دوره آموزش، با اعمال دبی ۱ ماه قبل از مقدار  $0.419$  مترمکعب بر ثانیه به مقدار  $0.305$  مترمکعب بر ثانیه، معادل ۲۷ درصد کاهش یافته است. به نظر می رسد با توجه به تغییر شرایط آب و هوایی در منطقه اقلیمی ایران، تأثیر دبی ماه های قبل تا این میزان قابل قبول نباشد. همچنین، نکته درخور توجه در مورد این روش آن است که نتایج از دوره آموزشی تا دوره آزمون تا حدودی بهبود یافته اند، ولی تجربه نشان می دهد این امر یک اتفاق معمولی نیست. در شکل ۹ مقایسه دبی مشاهداتی و مدل سازی شده و همچنین، دیاگرام پراکنش ترکیب مناسب در مرحله ارزیابی به روش MLR نمایش داده شده است.




شکل ۹. (الف) مقایسه دبی مدل‌سازی و مشاهداتی (ب) دیاگرام پراکنش در مرحله آزمون به روش MLR

جدول ۵. نتایج آماری الگوهای ورودی مدل SVM و پارامترهای بهینه در پیش‌بینی دبی

پارامترهای بهینه			آزمون			آموزش			شماره ترکیب
$\epsilon$	$\sigma$	$C \cdot 10^5$	$R^2$	RMSE	MAE	$R^2$	RMSE	MAE	
۰/۰۳۰	۹/۰۰۰	۴۳/۷۰۰	۰/۹۴۷	۰/۲۷۶	۰/۰۳۸	۰/۹۵۱	۰/۲۵۱	۰/۰۷۹	۱
۰/۱۶۰	۱۵۳/۰۰۰	۶۲/۴۰۰	۰/۹۵۹	۰/۲۶۰	۰/۰۳۴	۰/۹۵۷	۰/۲۰۳	۰/۰۷۳	۲
۰/۲۰۰	۵/۵۰۰	۰/۳۰۰	۰/۹۵۴	۰/۱۶۹	۰/۰۳۱	۰/۹۶۹	۰/۱۸۱	۰/۰۶۹	۳
۰/۰۸۰	۶۰/۰۰۰	۰/۰۰۶	۰/۹۷۰	۰/۱۵۱	۰/۰۲۲	۰/۹۷۹	۰/۰۸۷	۰/۰۶۱	۴
۰/۴۰۰	۰/۰۱۰	۶/۰۰۰	۰/۹۵۸	۰/۱۷۴	۰/۰۲۴	۰/۹۶۰	۰/۱۵۱	۰/۰۶۵	۵

ماهیانه ۱ ماه قبل در مرحله آزمون برابر ۰/۲۷۶ مترمکعب بر ثانیه بوده است که با اعمال تأثیر دبی ۳ ماه قبل نیز، مقدار RMSE به ۰/۱۵۱ مترمکعب بر ثانیه، یعنی حدود ۴۵ درصد، کاهش یافته است. میزان بهبود خطا در پیش‌بینی دبی در این روش بسیار بیشتر از روش MLR است. شکل ۱۰ نتایج مربوط به دبی مشاهداتی و دبی پیش‌بینی شده و نیز دیاگرام پراکنش ترکیب مناسب در مرحله ارزیابی را با استفاده از روش SVM نشان می‌دهد.

برای به دست آوردن مقادیر مناسب پارامترهای  $(\sigma, \epsilon, C)$  معیار RMSE برای بهینه‌سازی پارامترها استفاده شده است. بهترین خروجی مربوط به پارامترهای  $\epsilon=0.08$  و  $C=6177$  و  $\sigma=15.7$  بوده که نسبت به سایر ترکیب‌ها بهترین نتیجه را داشته است. در این روش، نتایج با اعمال تأثیر دبی متوسط ماهیانه ۴ ماه قبل بهبود یافته و با اعمال تأثیر ماه پنجم، مقادیر خطا روند افزایشی یافته است. در ترکیب ۴، مقدار RMSE با اعمال تأثیر دبی متوسط



شکل ۱۰. (الف) مقایسه دبی مدل‌سازی و مشاهداتی (ب) دیاگرام پراکنش در مرحله آزمون با روش SVM

با توجه به شکل ۱۱ مدل ANFIS توانایی مدل‌سازی دبی متوسط ماهیانه با دقت بسیار زیاد را دارد که در مقایسه با SVM به علت استفاده از قوانین فازی به عنوان کنترل‌کننده پارامترهای ورودی، می‌تواند به عنوان یک ساختار بسیار بهینه در مدل‌سازی‌های هیدرولوژی استفاده شود، به‌ویژه اینکه مقادیر اوج پیش‌بینی شده<sup>۲</sup> و مشاهداتی بسیار به هم نزدیک‌اند.

### نتایج مدل‌سازی با شبکه ترکیبی GRU-LSTM

شبکه‌های GRU و LSTM معمولاً سه پارامتر اصلی برای تنظیم دارند؛ تعداد دوره‌ها، یا تعداد گذرهای کامل در مجموعه داده‌ها طی فاز آموزش، تعداد نرون‌ها در شبکه عصبی و طول پنجره (w). این پارامترها با بهینه‌سازی پیش‌بینی دبی مد نظر انتخاب می‌شوند. انتخاب تعداد نرون‌ها و تعداد دوره‌ها تأثیر چندانی روی نتایج نمی‌گذارد، بنابراین این دو پارامتر بررسی و صحت‌سنجی نمی‌شوند. در تحقیق حاضر یک نرون و یک هزار دوره انتخاب شده است؛ تعداد یک نرون به دلیل ماهیت مسئله که از نوع رگرسیونی است، انتخاب شده و تعداد یک هزار دوره توسط الگوریتم گرید سرچ<sup>۳</sup> انتخاب شده است. هرچه این دو پارامتر بزرگ‌تر باشند، زمان محاسبه نیز بزرگ‌تر می‌شود. علاوه بر موارد یادشده نوع تابع فعال‌ساز در لایه تمام‌متصل نیز می‌تواند جزء پارامترهای روش پیشنهادی باشد؛ چرا که انواع مختلفی برای آن وجود دارد و هر یک به صورت مستقل می‌تواند در خروجی نهایی تأثیرگذار باشد. در تحقیق حاضر از تابع فعال‌ساز سیگموئید استفاده شده است. در جدول ۷ نتایج مربوط به این مدل آورده شده است.

در جدول ۷ با توجه به معیارهای ارزیابی  $MAE=0.011$ ،  $RMSE=0.023$  و  $R^2=0.991$  برای داده‌های آزمون  $MAE=0.009$ ،  $MSE=0.020$  و  $R^2=0.993$  برای داده‌های آموزشی، ترکیب ۴ نسبت به سایر ترکیب‌ها به طور نسبی نتایج بهتری دارد. همان‌طور که در جدول ۷ مشهود است، مقدار خطا به ازای تمام ترکیب‌ها نسبت به سایر روش‌ها تغییر محسوسی داشته است. به طور نمونه، مقدار  $RMSE$  در مرحله آزمون برای ترکیب ۱ از مقدار  $0.276$  به مقدار  $0.41$  مترمکعب بر ثانیه و برای ترکیب ۴ از مقدار  $0.151$  به مقدار  $0.23$

شکل ۱۰ نشان‌دهنده دبی مشاهداتی و پیش‌بینی‌شده با استفاده از مدل SVM است و بیان می‌کند در این روش دقت مدل روش در پیش‌بینی دبی متوسط ماهیانه از نظر کاهش پراکندگی بیشتر از روش قبل است.

### نتایج مدل‌سازی ANFIS

پیاده‌سازی الگوریتم ANFIS نیز مشابه سایر روش‌ها در محیط MATLAB 2014 انجام شده که مشابه تهیه مدل شبکه عصبی مصنوعی ANN است. مهم‌ترین مزیت مدل ANFIS در مقابل شبکه‌های عصبی در آن است که طراحی ساختار مدل وابسته به اختصاص دادن تعداد توابع عضویت به پارامترهای ورودی است و این عمل براساس تأثیر آن روی پارامترهای خروجی انجام می‌شود. عملکرد تابع‌های عضویت مختلف مبتنی بر فرایند آزمایش و خطا است که در مقاله حاضر از تابع گوسی برای تابع عضویت و نیز از روش میانگین وزنی<sup>۱</sup> برای Defuzzification استفاده شده است. براساس مدل‌های قبل بهترین ترکیب (ترکیب ۴ در روش SVM) به عنوان ورودی به مدل معرفی شده و با توجه به معیارهای ارزیابی برای داده‌های آزمون و آموزش، مدل ANFIS نتایج خوبی در مدل‌سازی دبی رودخانه ارائه داده است. در جدول ۶ نتایج مربوط به مدل‌سازی ANFIS آورده شده است.

در جدول ۶ با توجه به معیارهای ارزیابی  $MAE=0.061$ ،  $R^2=0.979$  و  $RMSE=0.087$  برای داده‌های آزمون و  $MAE=0.022$ ،  $R^2=0.97$  و  $RMSE=0.0151$  برای داده‌های آموزشی، ترکیب ۴ نسبت به سایر ترکیب‌ها به طور نسبی نتایج بهتری دارد. در این روش نیز مشابه روش SVM، با اعمال تأثیر دبی متوسط ماهیانه ۴ ماه قبل، نتایج بهبود یافته ولی با اعمال تأثیر ماه پنجم، مقادیر خطا روند افزایشی نشان داده است. در ترکیب ۴، مقدار  $RMSE$  با اعمال تأثیر دبی متوسط ماهیانه ۱ ماه قبل در مرحله آزمون برابر  $0.197$  مترمکعب بر ثانیه بوده است که با اعمال تأثیر دبی ۳ ماه قبل نیز، مقدار  $RMSE$  به  $0.68$  مترمکعب بر ثانیه، یعنی حدود ۶۵ درصد، کاهش یافته است. همچنین، در ترکیب ۴ مقدار  $RMSE$  در مقایسه با سایر روش‌های بررسی‌شده قبل، به طور چشم‌گیری کاهش یافته است. شکل ۱۰ مقایسه دبی مشاهداتی و مدل‌سازی‌شده و نیز دیاگرام پراکنش ترکیب مناسب در مرحله ارزیابی به روش ANFIS را نشان می‌دهد.

2. Predicted Peak  
3. Grid Search


1. Weight Average

مناسب در مرحله ارزیابی به روش GRU-LSTM نمایش داده شده است. این مدل نیز مشابه روش ANFIS در نقاط پیک بسیار خوب عمل کرده و دبی متوسط ماهیانه را با دقت زیادی مدل‌سازی می‌کند.


مترمکعب بر ثانیه کاهش یافته است که اختلاف بسیار محسوسی دارد و نشان می‌دهد دقت این روش در مقایسه با سایر روش‌ها بسیار زیاد است. در شکل ۱۲، مقایسه دبی مشاهداتی و مدل‌سازی شده و نیز دیاگرام پراکنش ترکیب

جدول ۶. نتایج آماری الگوهای ورودی مدل ANFIS در پیش‌بینی دبی

آزمون			آموزش			شماره ترکیب
R <sup>2</sup>	RMSE	MAE	R <sup>2</sup>	RMSE	MAE	
۰/۹۵۱	۰/۱۹۷	۰/۰۵۱	۰/۹۴۸	۰/۲۴۳	۰/۰۳۰	۱
۰/۹۶۲	۰/۱۸۹	۰/۰۴۹	۰/۹۵۹	۰/۲۰۱	۰/۰۲۷	۲
۰/۹۶۵	۰/۱۱۳	۰/۰۴۱	۰/۹۶۰	۰/۱۵۸	۰/۰۲۲	۳
۰/۹۷۴	۰/۰۶۸	۰/۰۳۵	۰/۹۷۱	۰/۱۱۲	۰/۰۱۸	۴
۰/۹۷۱	۰/۰۹۲	۰/۰۴۲	۰/۹۶۳	۰/۱۴۰	۰/۰۱۹	۵



(ب)




(الف)


شکل ۱۱. (الف) مقایسه دبی مدل‌سازی و مشاهداتی (ب) دیاگرام پراکنش در مرحله آزمون با مدل ANFIS

جدول ۷. نتایج آماری الگوهای ورودی مدل ترکیبی شبکه GRU-LSTM در پیش‌بینی دبی متوسط ماهیانه

آزمون			آموزش			شماره ترکیب
R <sup>2</sup>	RMSE	MAE	R <sup>2</sup>	RMSE	MAE	
۰/۹۷۰	۰/۰۴۱	۰/۰۲۸	۰/۹۷۱	۰/۰۲۹	۰/۰۲۱	۱
۰/۹۷۳	۰/۰۳۶	۰/۰۲۲	۰/۹۷۴	۰/۰۳۱	۰/۰۱۸	۲
۰/۹۷۱	۰/۰۳۱	۰/۰۱۷	۰/۹۸۲	۰/۰۲۶	۰/۰۱۲	۳
۰/۹۹۱	۰/۰۲۳	۰/۰۱۱	۰/۹۹۳	۰/۰۲۰	۰/۰۰۹	۴
۰/۹۷۹	۰/۰۲۹	۰/۰۱۹	۰/۹۸۷	۰/۰۱۹	۰/۰۱۷	۵



(ب)



(الف)

شکل ۱۲. مقایسه دبی مدل‌سازی و مشاهداتی و دیاگرام پراکنش در مرحله صحت‌سنجی روش GRU-LSTM

volume and survey sentiment indices. *Expert Systems with Applications*, 2017; 73: 125-144.

- [2]. Borujeni SC. Modeling flood occurrences using soft computing technique in southern strip of Caspian Sea watershed, 2012.
- [3]. Kisi Ö, Çobaner M. Modeling river stage-discharge relationships using different neural network computing techniques. *CLEAN-Soil, Air, Water*, 2009; 37(2): 160-169.
- [4]. Liong SH, Chandrasekaran S. Flood stage forecasting with support vector machines. *JAWRA Journal of the American Water Resources Association*, 2007; 38(1):173 - 186
- [5]. Yu PS, Chen ST, Chang IF. Support vector regression for real-time flood stage forecasting. *Journal of Hydrology*, 2006; 328(3-4): 704-716.
- [6]. Wang WC, Chau KW, Cheng CT, Qiu L. A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *Journal of Hydrology*, 2009; 374: 294-306.
- [7]. Ghorbani MA, Kisi O, Aalinezhad M. 2010. A probe into the chaotic nature of daily streamflow time series by correlation dimension and largest Lyapunov methods. *Applied Mathematical Modelling*, 2010; 34: 4050-4057.
- [8]. Zahiri A, Azamathulla HM. Comparison between linear genetic programming and M5 tree models to predict flow discharge in compound channels. *Neural Computing and Applications*, 2014; 24(2): 413-420
- [9]. He Z, Wen X, Liu H, Du J. A comparative study of artificial neural network, adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region. *Journal of Hydrology*, 2014; 509: 379-386.
- [10]. Hasanpour Kashani M, Ghorbani MA, Dinpazhouh Y, Shahmorad S. Rainfall-Runoff simulation in the Navrood river basin using truncated volterra model and artificial neural networks. *Journal of Watershed Management Research*, 2011; 6(12): 1-10 (In Persian).
- [11]. Darbandi S, Pourhosseini FA. River flow simulation using a multilayer perceptron-firefly algorithm model. *Applied Water Science*, 2018; 8(3):1-9.
- [12]. Ghose DK. Measuring Discharge Using Back-Propagation Neural Network: A Case Study on Brahmani River Basin. In: Bhateja V., Coello Coello C., Satapathy S., Pattnaik P. (eds) *Intelligent Engineering Informatics. Advances in Intelligent Systems and Computing*, vol 695. Springer, Singapore, 2018.

## نتیجه‌گیری کلی

در تحقیق حاضر عملکرد ۴ روش مدل‌سازی برای پیش‌بینی مقادیر دبی متوسط ماهیانه رودخانه کارون بررسی شد. تکنیک‌های مطالعه‌شده شامل رگرسیون خطی چندگانه (MLR)، سیستم استنتاج فازی-عصبی تطبیقی (ANFIS)، ماشین‌های بردار پشتیبان (SVM) و ترکیبی از شبکه‌های LSTM و GRU بودند. در مطالعه حاضر از داده‌های سری زمانی مقادیر دبی ماهیانه ۲۱ سال آماری مربوط به دوره ۱۳۷۴-۱۳۹۴ در ایستگاه ملاثانی برای پیش‌بینی دبی به‌عنوان داده‌های ورودی اصلی استفاده شده است. معیارهای ارزیابی MAE،  $R^2$  و RMSE روی مجموعه داده‌های ورودی اعمال شد. نتایج نشان داد مدل ANFIS، SVM و ترکیب LSTM و GRU دقت کمتری در پیش‌بینی مقادیر دبی دارد که این امر ناشی از فرمولاسیون خطی و ناتوانی آن در مدل‌سازی پیچیدگی‌های غیرخطی مسئله است. مدل ANFIS از نظر عملکردی بهتر از MLR و SVM است که علت آن ترکیب دو مدل فازی و عصبی است که با استفاده از یک تابع عضویت خاص و یک سری قوانین فازی، پیچیدگی و غیرخطی بودن مسئله را مدل‌سازی و مقدار جریان را برآورد می‌کند، به‌ویژه اینکه در این مدل مقادیر دبی اوج پیش‌بینی شده و مشاهداتی بسیار به هم نزدیک هستند. با توجه به نتایج می‌توان به این نکته اشاره کرد که اگرچه دقت روش ANFIS نسبت به روش ماشین بردار پشتیبان اندکی بیشتر بود، اما روش SVM به‌مراتب ساده‌تر از روش ANFIS است و می‌تواند به‌عنوان یک روش کاربردی برای پیش‌بینی دبی متوسط ماهیانه رودخانه به کار گرفته شود. البته، انتخاب پارامترهای بهینه در این مدل بسیار اهمیت دارد. به‌طور کلی، ترکیب شبکه‌های LSTM و GRU بهترین عملکرد برای پیش‌بینی دبی متوسط ماهیانه رودخانه کارون را دارد که این امر به علت انتخاب ویژگی‌های این روش به‌صورت خودکار است که توانسته دقت زیادی را در این مدل‌سازی سبب شود. به دلیل ماهیت مسئله که به‌صورت سری زمانی است، این رویکرد ترکیبی می‌تواند جایگزینی مناسب برای مدل‌های موجود باشد.

## منابع

- [1]. Oliveira N, Cortez P, Areal N. The impact of microblogging data for stock market prediction: Using Twitter to predict returns, volatility, trading

- [13]. Petty T, Dhingra P. Streamflow hydrology estimate using machine learning (SHEM). JAWRA Journal of the American Water Resources Association, 2018; 54(1): 55-68.
- [14]. Muhammad AU, Li X, Feng J. Using LSTM GRU and Hybrid Models for Streamflow Forecasting. In: Zhai X., Chen B., Zhu K. (eds) Machine Learning and Intelligent Communications. MLICOM 2019. Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering, vol 294. Springer, Cham.
- [15]. Dou M, Qin C, Li G, Wang C. Research on Calculation Method of Free flow Discharge Based on Artificial Neural Network and Regression Analysis. Flow Measurement and Instrumentation, 2020; 72: 102-123.
- [16]. Hussain D, Khan AA. Machine learning techniques for monthly river flow forecasting of Hunza River, Pakistan. Earth Science Informatics, 2020; DOI: 10.1007/s12145-020-00450-z.
- [17]. Soltani A, Gorbani M, Fakheri Fard A, Darbandi S, Farsadzadeh D. Genetic Programming and Its Application in Rainfall-Runoff Modeling. Water and Soil Science, 2011; 20(4), 62-71 (In Persian).
- [18]. Khosravi M, Salajegheh A, Mahdavi M, Mohseni Saravi M. Determination of the Best Output Layer Activation Function in Neural Network for Forecasting Peak Discharge. Iranian Journal of Watershed Management Science and Engineering, 2010; 4(12): 61-64 (In Persian).
- [19]. Noori R, Karbassi A, Farokhnia A, Dehghani M. Predicting the longitudinal dispersion coefficient using support vector machine and adaptive neuro-fuzzy inference system techniques. Environmental Engineering Science, 2009; 26(10): 1503-1510.
- [20]. Pourhaghi A, Solgi A, Radmanesh F, Shehni darabi M. Hybrid Usage of The Wavelet transform and Intelligent to Simulation River Flow (Case Study: KaKa Reza and Sarab seyed Ali rivers). Irrigation and Water Engineering, 2018; 8(4): 1-17 (In Persian).
- [21]. Haghizadeh A, Mohammadlou M, Noori F. Simulation of Rainfall-Runoff Process using multilayer perceptron and Adaptive Neuro-Fuzzy Interface System and multiple regression (Case Study: Khorramabd Watershed). Iranian journal of Eco hydrology, 2015; 2(2), 233-243 (In Persian).
- [22]. Sepehri M, Ildoromi AR, Hosseini SZ, Nouri H, Mohammadzade F, Artimani MM. The combination of neural networks and genetic algorithms is a way to estimate the Peak flood. Iranian Journal of Watershed Management Science and Engineering, 2018; 11(39): 23-32 (In Persian).
- [23]. Jain YK, Bhandare SK. Min max normalization based data perturbation method for privacy protection. International Journal of Computer and Communication Technology, 2011; 2(8): 45-50.
- [24]. Kisi Ö, Çobaner M. Modeling river stage-discharge relationships using different neural network computing techniques. CLEAN-Soil, Air, Water, 2009; 37(2): 160-169.
- [25]. Dixon B. Applicability of neuro-fuzzy techniques in predicting ground-water vulnerability: a GIS-based sensitivity analysis. Journal of hydrology, 2005; 309(1-4): 17-38.
- [26]. Nadiri AA, Gharekhani M, Khatibi R. Mapping aquifer vulnerability indices using Artificial Intelligence-running Multiple Frameworks (AIMF) with supervised and unsupervised learning. Water Resources Management, 2018; 32: 3023-3040.
- [27]. Nadiri AA, Fijani E, Tsai F, Asghari Moghaddam A. Supervised committee machine with artificial intelligence for prediction of fluoride concentration. Journal of Hydroinformatics, 2013; 15(4): 1474-1490.
- [28]. Granata R, Saroli M, Marinis GD, Gargano R. Machine learning models for spring discharge forecasting. Geofluids, 2018; 2018: 1-13.
- [29]. Wang W, Men C, Lu W. Online prediction model based on support vector machine. Neurocomputing, 2008; 71(4-6): 550-558.
- [30]. Cao LJ, Tay FEH. Support vector machine with adaptive parameters in financial time series forecasting. IEEE Transactions on neural networks, 2003; 14(6): 1506-1518.
- [31]. Marsooli R, Aalami MT. Evaluation of total load sediment transport formulas using ANN. International Journal of Sediment Research, 2009; 24(3): 274-286.
- [32]. Yu PS, Chen ST, Chang IF. Flood stage forecasting using support vector machines. Geophysical Research Abstracts, 2005; 7: 41-76.
- [33]. Khan MS, Coulibaly P. Application of support vector machine in Lake water level prediction. Journal of Hydrologic Engineering, 2006; 11(3): 199-205.