

# تخمین تراوش سدخاکی با استفاده از مدل ترکیبی یادگیری عمیق و تبدیل موجک

آیدا حسینی بقانام<sup>۱\*</sup>، وحید نورانی<sup>۲</sup>، الناز شرقی<sup>۳</sup>، زهرا داداش پور<sup>۴</sup>

۱- دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران

۲- دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران

۳- دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران

۴- دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران

## چکیده

پیش‌بینی تراوش یکی از ابزارهای مهم در پیشگیری از فرسایش و تخریب سدهای خاکی است. در سال‌های اخیر با توجه به عدم قطعیت، پیچیدگی و غیرخطی بودن روابط حاکم بر تراوش، استفاده از روش‌های هوش مصنوعی برای تخمین و پیش‌بینی این پدیده مورد توجه قرار گرفته است. هدف از این پژوهش تخمین تراوش سدخاکی ستارخان است. این سد در شمال غربی ایران قرار دارد. برای دستیابی به این هدف، در این پژوهش از شبکه حافظه بلند - کوتاه مدت و مدل ترکیبی موجک - شبکه عمیق در دو سناریو متفاوت استفاده شده است و نتایج به دست آمده از این مدل‌ها با شبکه عصبی پیشرو مقایسه شده است. نتایج به دست آمده نشان داد که شبکه‌های بازگشتی عمیق در مدل‌سازی پدیده تراوش، به دلیل ارتباط بازگشتی خروجی با ورودی در هر گام زمانی و توانایی یادگیری وابستگی‌ها در دنباله‌ای از زمان‌های قبل، نسبت به شبکه‌های عصبی پیشرو دقت تخمین بالاتری دارند به طوری که باعث افزایش دقت مدل‌سازی تا ۷٪ شده است. هم‌چنین مدل ترکیبی موجک - شبکه عمیق نسبت به سایر مدل‌ها عملکرد بهتری دارد به طوری که دقت مدل‌سازی را تا ۱۰٪ افزایش داده است. در نهایت می‌توان نتیجه گرفت که استفاده از شبکه‌های بازگشتی عمیق و مدل ترکیبی موجک - شبکه عمیق در مدل‌سازی تراوش، توانایی بهبود دقت تخمین در پیش‌بینی این پدیده را دارند.

## کلمات کلیدی

تراوش سد خاکی، شبکه عصبی مصنوعی، شبکه حافظه بلند - کوتاه مدت (LSTM)، تبدیل موجک، سد خاکی ستارخان.

با توجه به محدود بودن منابع آب استفاده از سدسازی در مناطق مختلف جهان برای کنترل، ذخیره و انتقال آب از کهن‌ترین فعالیت‌های مهندسی عمران به شمار می‌رود. یکی از انواع سد جهت ذخیره‌سازی آب، سد خاکی می‌باشد. این نوع سدها از مصالح خاکی ساخته می‌شوند، بنابراین بروز تراوش در سدهای خاکی امری اجتناب‌ناپذیر است [۲]. سدهای خاکی با مشکلات متعددی نظیر تراوش، ناپایداری شیب‌ها، پوسته‌پوسته شدن و... مواجه‌اند. بدترین مشکل در این‌گونه سدها مسئله تراوش و عواقب آن است. چنانچه در ابتدای بروز تراوش از این پدیده جلوگیری نگردد، منجر به خرابی سد می‌گردد [۳]. بنابراین جهت پیش‌بینی مقدار تراوش در آینده داشتن یک مدل بهینه ضروری به نظر می‌رسد. با توجه به اهمیت تراوش، از مدل‌های جعبه سیاه و سفید مختلفی برای مدل‌سازی آن استفاده شده است. به عنوان مثالی از مدل‌های جعبه سفید می‌توان به تحلیل تراوش بر اساس معادلات ریچارد [۴] اشاره کرد. در استفاده از مدل‌های جعبه سفید، علاوه بر شرایط مرزی و اولیه به پارامترهای محیط مانند هدایت هیدرولیکی بدنه سد خاکی، به‌عنوان ورودی نیاز می‌باشد. این پارامترها پس از اجرای پروژه دچار تغییرات می‌شوند؛ بنابراین نتیجه حاصل از مدل‌های ریاضی در مقایسه با واقعیت دارای خطای قابل توجه می‌شود [۱]. با توجه به وجود عدم قطعیت‌های بارز و پیچیدگی‌ها در مسئله تراوش، استفاده از مدل‌های جعبه سیاه که توسط ورودی‌ها و خروجی‌های مشاهده شده فرایند مورد نظر را تخمین می‌زنند، می‌تواند موجب تسهیل مدل‌سازی این پدیده باشد [۵]. تاکنون برای بسیاری از مسائل هیدرولوژی و هیدرولیک، مدل‌های جعبه سیاه مانند ابزار محاسبات نرم و هوش مصنوعی بکار گرفته شده‌اند [۶]. هوش مصنوعی به معنای استخراج هوش، دانش، الگوریتم یا نگاهت از درون محاسبات عددی بر اساس بررسی داده‌های عددی است. مروری بر تاریخچه کاربرد محاسبات نرم، نشان می‌دهد که استفاده از محاسبات نرم در تعدادی از مسائل تراوش سد خاکی منجر به نتایج مطلوبی شده است [۵]. علت انتخاب مدل‌های هوشمند در این تحقیق به دلیل توانایی آن‌ها در پردازش داده‌های پیچیده و غیرخطی، به‌ویژه در مدل‌سازی سری‌های زمانی هیدرولوژیکی مانند تراوش است. مدل‌های هوشمند، مانند شبکه‌های عصبی بازگشتی و LSTM، به دلیل قابلیت یادگیری الگوهای بلندمدت و شناسایی ارتباطات پیچیده در داده‌ها، می‌توانند پیش‌بینی‌های دقیقی در مورد رفتارهای دینامیکی سیستم‌های هیدرولوژیکی ارائه دهند. در حالی که روش‌های سنتی ممکن است نتوانند به‌خوبی از عهده مدل‌سازی داده‌های پرنوسان و ناپایستا برآیند، مدل‌های هوشمند با ساختارهای خاص خود مانند LSTM می‌توانند با مشکلاتی نظیر محوشدگی یا انفجار گرادیان مقابله کرده و دقت پیش‌بینی‌ها را به طور قابل‌توجهی افزایش دهند. انتخاب این مدل‌ها به دلیل انعطاف‌پذیری و کارایی بالای آن‌ها در مواجهه با پیچیدگی‌های داده‌های هیدرولوژیکی و نیاز به پیش‌بینی‌های دقیق و قابل‌اعتماد در مدیریت منابع آبی بوده است.

تایفور و همکاران [۶] در سال ۲۰۰۵ در کنار مدل عددی FEM (Finite Element Method) از یک مدل شبکه عصبی مصنوعی برای پیش‌بینی تراوش در سد خاکی استفاده کردند. آن‌ها از تراز سطح آب در بالادست و پایین‌دست سد به‌عنوان متغیرهای ورودی استفاده کردند و تراز آب در پیژومترهای نصب شده در سد، به‌عنوان خروجی مدل شبکه عصبی مصنوعی در نظر گرفته شده بود. آن‌ها به این نتیجه رسیدند که استفاده از شبکه عصبی مصنوعی همانند روش FEM دارای دقت مناسبی می‌باشد. ارساین [۷] با استفاده از شبکه‌های عصبی مصنوعی پدیده تراوش در سد خاکی را مدل‌سازی کرده و برای آموزش و آزمون مدل پیشنهادی از اطلاعات به دست آمده توسط کلکتورها و پیژومترها استفاده شده است. از داده‌های مربوط به تراز سطح آب در بالادست و پایین‌دست سد به‌عنوان ورودی‌های مدل و دبی جمع‌آوری شده توسط کلکتورها و فشار پیژومتری درون سد به‌عنوان خروجی مدل استفاده شده است. ارساین در پژوهش خود به این نتیجه رسیده است که شبکه عصبی دارای عملکرد مناسبی در تخمین فشار پیژومترها و تراوش سد دارد. میائو و همکاران [۸] به پیش‌بینی دبی تراوش در سد خاکی دیالی در چین با استفاده از مدل شبکه عصبی بهینه شده توسط الگوریتم فرا ابتکاری وراثتی پرداختند. آن‌ها از ۳۸۱ داده اندازه‌گیری شده توسط ابزار دقیق در مدل‌سازی‌های خود استفاده کردند و عملکرد مدل خود را رضایت‌بخش ارزیابی نمودند. نورانی و همکاران [۱] در سال ۲۰۱۲ یک مدل واحد جعبه سیاه با استفاده از داده‌های تراز آب بالادست و پایین‌دست سد برای آنالیز تراوش از سد خاکی ستارخان ارائه کردند و به این نتیجه رسیدند که مدل ANN (Artificial Neural Network) می‌تواند جایگزین نسبتاً مناسبی برای مدل عددی FEM باشد. بررسی‌های اخیر نشان می‌دهد که در بیش از ۹۰٪ کاربردهای شبکه‌های عصبی مصنوعی برای مدل‌سازی متغیرهای منابع آب، از شبکه‌های عصبی پیش‌خور استاندارد (FNN) استفاده شده است [۹]. ساختار روبه‌جلوی این شبکه‌ها، استفاده از آنها را در شناسایی و کنترل سیستم‌های دینامیکی محدود کرده است؛ بنابراین، شبکه‌های عصبی

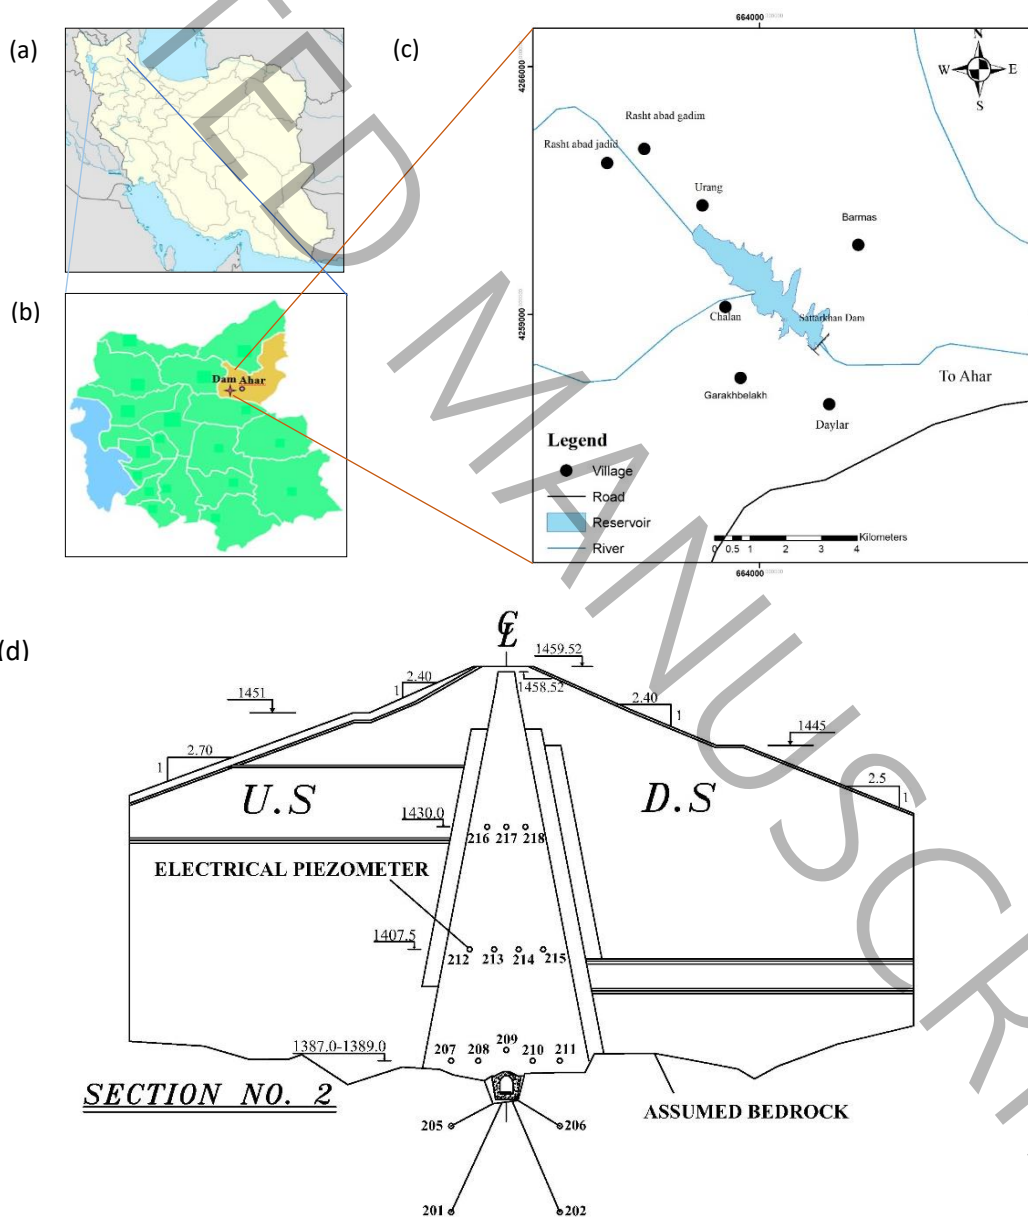
بازگشتی به عنوان ابزار یادگیری عمیق، جهت رفع این مشکل معرفی شدند [۱۰]. یادگیری عمیق یک شاخه پرکاربرد از یادگیری ماشین است و مجموعه‌ای از الگوریتم‌هایی است که ساختار سلسله‌مراتبی دارند و قابلیت بالایی در استخراج ویژگی از داده‌ها دارند. شبکه‌های بازگشتی عمیق در مدل‌سازی پدیده‌های وابسته به مقدار خود در زمان‌های قبل مانند تراوش، به دلیل ارتباط بازگشتی خروجی با ورودی در هرگام زمانی و توانایی یادگیری وابستگی‌ها در دنباله‌ای از زمان‌های قبل، دقت تخمین بالایی دارند [۱۱]. علت انتخاب مدل‌های هوشمند در این تحقیق به دلیل توانایی آن‌ها در پردازش داده‌های پیچیده و غیرخطی، به‌ویژه در مدل‌سازی سری‌های زمانی هیدرولوژیکی مانند تراوش است. مدل‌های هوشمند، مانند شبکه‌های عصبی بازگشتی و LSTM، به دلیل قابلیت یادگیری الگوهای بلندمدت و شناسایی ارتباطات پیچیده در داده‌ها، می‌توانند پیش‌بینی‌های دقیقی در مورد رفتارهای دینامیکی سیستم‌های هیدرولوژیکی ارائه دهند. در حالی که روش‌های سنتی ممکن است نتوانند به خوبی از عهده مدل‌سازی داده‌های پرنوسان و ناپایستا برآیند، مدل‌های هوشمند با ساختارهای خاص خود مانند LSTM می‌توانند با مشکلاتی نظیر محوشدگی یا انفجار گرادیان مقابله کرده و دقت پیش‌بینی‌ها را به طور قابل توجهی افزایش دهند. انتخاب این مدل‌ها به دلیل انعطاف‌پذیری و کارایی بالای آن‌ها در مواجهه با پیچیدگی‌های داده‌های هیدرولوژیکی و نیاز به پیش‌بینی‌های دقیق و قابل اعتماد در مدیریت منابع آبی بوده است. در سال‌های اخیر از مدل‌های یادگیری عمیق مانند LSTM برای مدل‌سازی پدیده‌های هیدرولوژیکی مختلفی مانند پیش‌بینی جریان [۱۲]، تخمین بار رسوب [۱۳]، پیش‌بینی سطح آب زیرزمینی [۱۴]، برآورد تبخیر و تعرق [۱۵] و ... استفاده شده است. همچنین در پژوهشی اشفقه و همکاران [۱۶]، از مدل‌های الگوریتم‌های یادگیری عمیق برای پیش‌بینی مقدار نفوذ یک سد در پاکستان استفاده کردند. هدف آنها استفاده از رویکرد RNN-LSTM برای پیش‌بینی تراوش سد با استفاده از داده‌های روزانه بود. با وجود انعطاف‌پذیری شبکه‌های عصبی در پیش‌بینی سری‌های زمانی هیدرولوژیکی، گاهی این شبکه‌ها در پیش‌بینی سری‌های زمانی به شدت ناپایستا و ناپایدار با مشکل مواجه می‌شوند. در این حالت استفاده از تبدیل‌های ریاضی مانند موجک با تجزیه سری زمانی به فرکانس‌های بالا و پایین، دقت مدل را تا حد قابل توجهی بالا می‌برد [۱۷]. موجک یک تبدیل ریاضی است که با اعمال آن بر یک سیگنال می‌توان اطلاعات اضافه‌ای به دست آورد که در سیگنال خام اولیه قابل دسترس نمی‌باشند. امروزه ابزارهای شناخته شده بسیاری در زمینه پردازش سیگنال وجود دارند که با توجه به نوع پردازش، ابزار مناسب از میان انواع مختلف آن به کار گرفته می‌شود. با استفاده از تبدیل یا آنالیز موجک می‌توان یک سیگنال یا سری زمانی مادر را به موجک‌هایی با سطح تفکیک و مقیاس‌های مختلف تجزیه کرد و سری‌های زمانی ناپایستا و گذرا را به صورت موضعی مورد تجزیه و تحلیل قرارداد و با وارد کردن آن‌ها به شبکه عصبی، قدرت شبکه را در امر پیش‌بینی بالا برد [۱۸، ۱۹]. به همین دلیل در سال‌های اخیر مدل‌های ترکیبی موجک-شبکه عصبی برای پیش‌بینی فرآیندهای هیدرولوژیکی مورد استفاده قرار گرفته اند [۲۰]. به عنوان نمونه برای استفاده از مدل‌های ترکیبی موجک-شبکه عصبی برای مدل‌سازی تراوش می‌توان به پژوهش روشنگر و همکاران [۲۱] در سال ۲۰۱۶ اشاره کرد. در این پژوهش به پیش‌بینی دبی نشت روزانه از سد خاکی زون با استفاده از ترکیب مدل موجک و روش رگرسیون فرایند گوسی پرداختند. نتایج تحقیقات آنها نشان می‌دهد مدل ترکیبی دارای دقت مناسبی در تخمین دبی نشت در سد خاکی زون است. در پژوهشی دیگر [۲۲]، از روش‌های نوآورانه‌ای مانند مدل‌های ترکیبی موجک-شبکه عصبی مصنوعی برای مدلسازی تراوش از سد خاکی استفاده شد. نتیجه این پژوهش نشان می‌دهد که مدل ترکیبی موجک-شبکه عصبی مصنوعی می‌تواند به عنوان یک روش دقیق برای پیش‌بینی تراوش در سدهای خاکی استفاده شود و دقیق‌تر از مدل شبکه عصبی مصنوعی است. همانطور که اشاره شد تاکنون برای بررسی تراوش سدخاکی از روش‌های مختلف مبتنی بر هوش مصنوعی و یادگیری عمیق و مدل‌های ترکیبی استفاده شده است. لیکن برای بررسی تراوش سد خاکی ستارخان در مرور ادبیات فنی مطالعه‌ای مبنی بر استفاده از مدل ترکیبی یادگیری عمیق و تبدیل موجک یافت نشد. از آنجاییکه سری زمانی فرایندهای هیدرولوژیکی بسیار پیچیده بوده بنابراین استفاده از تبدیل موجک و تجزیه سری زمانی به چند زیرسری موجب درک بهتر و درست‌تر از رفتار کوتاه و بلند مدت سری زمانی داده‌ها می‌شود. در این پژوهش برای مدل‌سازی تراوش از یادگیری عمیق استفاده شده است و از سوی دیگر جهت ارتقا نتایج مدل‌سازی استفاده از مدل ترکیبی موجک - شبکه عصبی [۱۳، ۲۳] برای مدل‌سازی تراوش سد خاکی در این پژوهش بکار گرفته شده است.

## ۲- مواد و روش‌ها

در این قسمت ابتدا به معرفی سد خاکی ستارخان، خصوصیات آماری داده‌های پیژومترهای مورد استفاده و سناریوهای تعیین شده برای انجام پژوهش پرداخته شده است. سپس ابزارهای استفاده شده معرفی شده و در آخر معیارهای ارزیابی برای صحت سنجی مدل‌ها ارائه شده است.

### ۱-۲ منطقه مورد مطالعه

سد خاکی ستارخان در ۱۱۰ کیلومتری شمال شرقی تبریز و در ۱۵ کیلومتری غرب شهر اهر بر روی رودخانه اهر چای احداث گردیده است. این رودخانه از جنوب شهر اهر عبور می‌کند و در ادامه مسیر خود به رودخانه ارس و در نهایت به دریای خزر می‌ریزد. با احداث این سد، جریان‌های سطحی رودخانه اهر چای کنترل شده و آب شرب شهرستان اهر، آب مورد نیاز حدود ۱۱۰۰۰ هکتار از اراضی کشاورزی پایین‌دست، آب صنعتی مس سونگون و سایر صنایع شهرستان تأمین می‌شود. شکل ۱ موقعیت سد ستارخان و مقطع شماره ۲ را نشان می‌دهد.



شکل ۱ - (a) موقعیت آذربایجان شرقی در ایران، (b) موقعیت شهرستان اهر در آذربایجان شرقی، (c) موقعیت سد ستارخان، (d) مقطع شماره ۲ سد ستارخان.

Figure 1 - (a) Location of East Azerbaijan in Iran, (b) Location of Ahar County in East Azerbaijan, (c) Location of the Sattar Khan Dam, (d) Cross-section 2 of the Sattar Khan Dam.

طول تاج سد ۳۴۰ متر (m)، ارتفاع سد از روی پی سنگی ۸۲ متر (m) و از روی بستر آبرفتی ۹۵ متر (m) است. مساحت حوزه آبریز رودخانه اهرچای در محل سد ۹۵۰ کیلومتر مربع (km<sup>2</sup>) و متوسط آورد سالانه آن ۹۲ میلیون متر مکعب (Mm<sup>3</sup>) است. عملیات اجرایی ساختمانی سد ستارخان در سال ۱۳۷۳ شروع و در سال ۱۳۸۳ به اتمام رسید. سد ستارخان، سدی از نوع خاکی است و حجم مخزن در تراز نرمال آب ۱۳۵ میلیون متر مکعب (Mm<sup>3</sup>) و حجم مفید آن ۱۲۰ میلیون متر مکعب (Mm<sup>3</sup>) است. طول دریاچه تشکیل شده از این سد در تراز عادی آب ۸ کیلومتر (km) و سطح این دریاچه ۲٫۷ کیلومتر مربع (km<sup>2</sup>) است. رقوم بستر رودخانه ۱۴۰۰ متر (m)، تراز سرریز ۱۴۵۱ متر (m) و تراز تاج سد ۱۴۵۹ متر (m) از سطح دریا قرار دارد. سیستم آب‌بندی بکار رفته در این سد، پرده تزریق است که در پی و تکیه‌گاه‌های سد اجرا شده است. این پرده تزریق در پی و جناحین سد حدود ۳۲،۰۰۰ متر مربع (m<sup>2</sup>) گستردگی دارد که از طریق ۱۵،۰۰۰ متر حفاری گمانه‌های به عمق تا ۸۵ متر (m) صورت می‌گیرد. در طول محور سد ۴ مقطع ابزاربندی در نظر گرفته شده است به صورتی که دو مقطع در محل ارتفاع میانگین سد بر روی تکیه‌گاه‌ها و دو مقطع در بخش میانی دره در نظر گرفته شده است [۲۴]. در این پژوهش از داده‌های پیزومترهای مقطع شماره ۲ سد ستارخان برای مدل‌سازی استفاده شده است. مقطع شماره ۲ سد و موقعیت پیزومترها در شکل ۱ قسمت d نشان داده شده‌اند. داده‌های پیزومتریک مورد استفاده، داده‌های قرائت شده از اول فروردین ۹۶ تا پایان سال ۹۸ شامل ۹۸۲ داده است که به صورت روزانه قرائت شده‌اند. مشخصات آماری داده‌های پیزومترهای ۲۱۲ و ۲۱۸ در **Error! Reference source not found.** ذکر شده است.

جدول ۱ - مشخصات آماری پیزومترهای استفاده شده از مقطع ۲.

-۲

Table 1 - Statistical characteristics of the piezometers used in Cross-section 2.

-۲

پیزومتر	بیشینه هد (متر)	کمینه هد (متر)	میانگین هد (متر)	انحراف معیار هد (متر)
۲۱۲	۱۳۳۰/۶۳	۱۲۸۶/۲۹	۱۲۹۵/۰۴	۲/۹۷
۲۱۸	۱۴۴۵/۰۴	۱۴۴۴/۳۰	۱۷۳۲/۷۹	۰/۲۱

سناریو ۱) مدل‌سازی تک پیزومتری

در سناریو اول برای تخمین ارتفاع پیزومتریک هر پیزومتر از داده‌های خود پیزومتر و تراز آب مخزن استفاده شود. تخمین ارتفاع پیزومتر  $i$  در زمان  $t$  بر اساس رابطه (۱) انجام می‌گیرد.

$$p_i(t) = f(L(t), P_i(t')) \quad (1)$$

در رابطه **Error! Reference source not found.** منظور از  $p_i(t)$  هد پیزومتر  $i$  در زمان  $t$  است و منظور از  $P_i(t')$  و  $L(t)$  به ترتیب هد پیزومتر  $i$  در زمان‌های قبل از  $t$  و تراز آب بالادست در زمان  $t$  و زمان‌های قبل از  $t$  است.

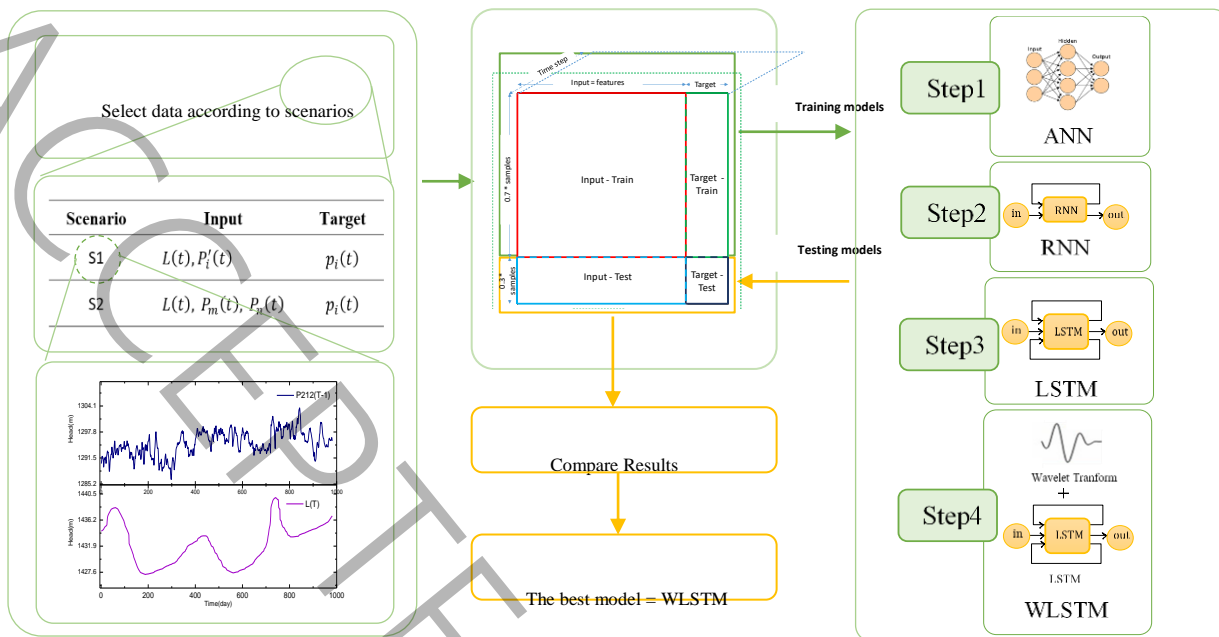
در این سناریو برای مدل‌سازی از داده‌های ۲ پیزومتر دیگر استفاده شده است. در سناریو ۲ ارتفاع پیزومتر ۱ تابعی از زیرسری‌های ۲ پیزومتر دیگر و تراز آب بالادست است. در این روش ارتفاع هر پیزومتر از رابطه **(Error! Reference source not found.)** به دست می‌آید.

$$p_i(t) = f(L(t), P_m(t), P_n(t)) \quad (2)$$

که در رابطه **(Error! Reference source not found.)**  $P_n$  و  $P_m$  به ترتیب، زیرسری‌های پیزومترهای  $m$  و  $n$  در زمان  $t$  و زمان‌های قبل از  $t$  هستند. در این سناریو از ضریب همبستگی برای تعیین ۲ پیزومتر مؤثر در مدل‌سازی استفاده شده است. باتوجه به اینکه در سناریو ۲ برای تخمین تراز آب هر پیزومتر بدون استفاده از مقادیر مشاهده شده خود پیزومتر در زمان‌های قبل، از پیزومترهای دیگری که همبستگی معناداری با پیزومتر موردنظر دارند، استفاده شده است.

#### ۲-۴- روش تحقیق

در این پژوهش برای مدل‌سازی تراوش ابتدا از شبکه عصبی پیشرو استفاده شده است این شبکه‌ها توسط لایه ورودی و یک لایه مخفی و در نهایت یک لایه خروجی قادر هستند هر نوع تابع غیرخطی را تقریب بزنند. در کنار این توانایی‌ها، شبکه‌های عصبی پیشرو دارای معایبی نیز هستند. ساختار روبه‌جلوی این شبکه‌ها، استفاده از آنها را در شناسایی و کنترل سیستم‌های دینامیکی محدود کرده است. هیچ‌گونه اتصال از خروجی به ورودی در شبکه‌های پیشرو وجود ندارد. به همین دلیل این شبکه‌ها برای تقریب‌زدن، شناسایی و یا کنترل سیستم‌های دینامیکی مناسب نیستند؛ بنابراین در گام بعدی از شبکه‌های عصبی بازگشتی برای مدل‌سازی استفاده شده است. نکته کلیدی شبکه‌های عصبی بازگشتی ارتباط بازگشتی است که حافظه‌ای از ورودی‌های قبلی را در هر گام به شبکه اعمال می‌کند که می‌تواند بر خروجی شبکه تأثیر بگذارد. شبکه‌های بازگشتی دارای مشکلاتی مانند محوشدگی گرادیان هستند که در ادامه توضیح داده شده است؛ بنابراین در گام بعدی از شبکه LSTM برای مدل‌سازی استفاده شد. از سویی دیگر پیش‌پردازش داده‌های ورودی یک مرحله مهم و پیچیده در مدل‌سازی سیستم‌های غیرخطی، جهت انتخاب ترکیبی مناسب از آنها است. پیش‌پردازش داده‌ها سبب کاهش تعداد مراحل سعی و خطا می‌شود و منجر به شناخت پارامترهای مهم و مؤثر بر پدیده مورد مطالعه جهت مدل‌سازی با استفاده از روش‌های هوشمند می‌گردد. به‌طور کلی می‌توان گفت منظور از پیش‌پردازش داده‌ها تبدیلاتی که بر روی داده‌های خام صورت می‌گیرد و آنها را به‌گونه‌ای تجزیه می‌کند که برای پردازش‌های بعدی مؤثرتر و ساده‌تر شوند [۲۵]. در این تحقیق برای تعریف مدل ترکیبی شبکه بازگشتی - موجک، از تبدیل موجک در پیش‌پردازش داده‌ها استفاده شده است. در شکل ۲ مراحل مدل‌سازی این پژوهش ارائه شده است.



شکل ۲ - مراحل مدل سازی پژوهش.

Figure 2 - Stages of the research modeling.


در این پژوهش به منظور آموزش و ارزیابی مدل های ساخته شده داده های مورد استفاده به دو قسمت داده های آموزش و صحت سنجی تقسیم شده است به طوری که از ۷۰٪ ابتدایی مجموعه داده ها برای آموزش و از ۳۰٪ انتهایی داده ها برای صحت سنجی مدل ها استفاده شده است. انتخاب ۷۰٪ از داده ها برای آموزش و ۳۰٪ برای صحت سنجی مدل بر اساس مطالعات و تجربیات گسترده در زمینه یادگیری ماشین و مدل سازی داده ها انجام شده است. این نسبت با توجه به پژوهش های قبلی در زمینه مدلسازی تراوش سدخاکی برای تقسیم بندی داده ها مورد استفاده قرار گرفته است [۵]، زیرا ۷۰٪ داده ها به اندازه کافی متنوع و گسترده هستند تا مدل را به خوبی آموزش دهند و ۳۰٪ باقیمانده نیز برای ارزیابی عملکرد مدل و بررسی توانایی آن در تعمیم دادن به داده های جدید مناسب است. آموزش شبکه توسط داده های آموزش صورت گرفته و از مقایسه خروجی مدل توسط داده های آموزش با داده های مشاهده ای برای تعیین بهتر پارامترهای شبکه مورد نظر استفاده شده است. در نهایت با استفاده از داده های صحت سنجی شبکه آموزش دیده، مورد ارزیابی قرار گرفته است.

## ۲-۵- شبکه عصبی مصنوعی پیشرو (Feed Forward Neural Network - FFNN)

شبکه های عصبی مصنوعی، سیستم ها و روش های محاسباتی نوینی برای یادگیری ماشین، یادگیری عمیق، نمایش دانش و در انتها اعمال دانش به دست آمده در جهت پیش بینی پاسخ های خروجی از سیستم های پیچیده هستند. از شبکه های عصبی مصنوعی می توان در هر موردی که نیاز به یادگیری نگاشت خطی و یا غیرخطی است، استفاده کرد. معروف ترین نوع شبکه های عصبی شبکه های عصبی روبه جلو (Feed Forward Neural Network - FFNN) هستند. شبکه های FFNN دارای سه لایه اصلی هستند. این شبکه ها توسط لایه ورودی و یک لایه مخفی و در نهایت یک لایه خروجی قادر هستند هر نوع تابع غیرخطی را تقریب بزنند [۲۶].

## ۲-۶- شبکه‌های عصبی بازگشتی (Recurrent Neural Network - RNN)

اگر شبکه دارای ارتباط چرخشی باشد آن را شبکه عصبی بازگشتی (Recurrent Neural Network - RNN) می‌گویند. در شبکه عصبی بازگشتی مطابق شکل ۳، لایه پنهان دارای ارتباط با خودش است. شبکه‌های عصبی بازگشتی را می‌توان به صورت چند واحد تکرارشونده یکسان از یک شبکه عصبی در نظر گرفت که هر کدام اطلاعاتش را به شبکه بعدی منتقل می‌کند [۲۷]. در شکل ۳ وضعیت شبکه عصبی بازگشتی در صورت باز کردن حلقه نمایش داده شده است. این شبکه‌ها از نظر معماری، ساختاری مانند یک شبکه عمیق کوتاه دارند؛ اما رفتار زمانی شبکه‌های بازگشتی مانند یک شبکه عمیق با لایه‌های نامحدود است؛ بنابراین شبکه‌های بازگشتی از نظر زمان به طور ذاتی عمیق هستند و حالت پنهان آن تابعی از حالت‌های پنهان در زمان‌های قبل است [۲۸، ۲۹].




شکل ۳ - شبکه عصبی بازگشتی [۳۰].

Figure 3 - Recurrent Neural Network [30].

یک سلول RNN ساده، توالی  $X = (X_1, X_2, \dots, X_t)$  با طول متغیر را به عنوان ورودی دریافت می‌کند و در هر گام زمانی، حالت مخفی خود را توسط معادله **Error! Reference source not found.** به روزرسانی می‌کند [۳۱].

$$h_t = \begin{cases} 0 & t=0 \\ \varphi(h_{t-1}, x_t) & \text{otherwise} \end{cases} \quad (3)$$

**Error! Reference source not found.** که در آن  $\varphi$  تابع غیرخطی مانند  $\tanh$ ،  $x_t$  ورودی در زمان  $t$  و  $h_{t-1}$  حالت مخفی در زمان قبلی است. **Error! Reference source not found.** یک سلول RNN ساده را با تابع فعالساز  $\tanh$  نشان می‌دهد.



شکل ۴ - سلول RNN ساده [۳۰].

Figure 4 - Simple RNN Cell [30].

در شبکه‌های عصبی FFNN، آموزش وزن‌ها از طریق الگوریتم پس انتشار (Back Propagation - BP) انجام می‌شود. این فرآیند شامل دو مسیر رفت و برگشت است: در مسیر رفت، ورودی به شبکه اعمال می‌شود و خروجی محاسبه می‌گردد، بدون تغییر در وزن‌ها. در مسیر برگشتی، خطا محاسبه شده و وزن‌ها با استفاده از انتشار خطا به سمت عقب تنظیم می‌شوند تا خطا به حداقل برسد. برای شبکه‌های عصبی بازگشتی (RNN)، از الگوریتم انتشار به عقب در طول زمان (BPTT) استفاده می‌شود که توسعه یافته الگوریتم BP




است. این الگوریتم با هدف کاهش خطا در طی دو مرحله جلو و عقب، مشابه BP عمل می‌کند. با افزایش لایه‌ها در RNN، مشکل محوشدگی یا انفجار گرادیان رخ می‌دهد که باعث کاهش دقت در یادگیری می‌شود. [۳۲-۳۴]. برای غلبه بر مسئله محوشدگی گرادیان که محدودیت اصلی در آموزش RNNها محسوب می‌شود، روش‌های مختلفی وجود دارد که می‌توان آنها را در چهار گروه بیان کرد [۳۵].

- استفاده از روش‌های غیر مبتنی بر گرادیان.
  - نگه داشتن گرادیان در حد بالا برای جلوگیری از محوشدگی سریع.
  - استفاده از شبکه‌های عصبی مرتبه بالاتر.
  - به‌کارگیری ساختارهای خاص مانند شبکه‌های حافظه بلند-کوتاه مدت.
- در ادامه به معرفی شبکه‌های بازگشتی حافظه بلند - کوتاه مدت (LSTM) پرداخته شده است.

#### ۷-۲- شبکه‌های بازگشتی حافظه بلند - کوتاه مدت (Long Short-Term Memory-LSTM)

شبکه‌های بازگشتی LSTM نوعی از شبکه‌های عصبی بازگشتی هستند که برای یادگیری وابستگی‌های بلندمدت طراحی شده‌اند و اولین بار در سال ۱۹۹۷ معرفی شدند. [۳۳]. LSTM دارای چهار دروازه می‌باشد. دروازه سلول (Cell state) که اطلاعات را از ابتدا تا انتهای LSTM حفظ می‌کند، دروازه فراموشی (Forget gate) که تعیین می‌کند چه اطلاعاتی حذف شود، دروازه ورودی (Input gate) که میزان استفاده از اطلاعات ورودی را مشخص می‌کند، و دروازه خروجی (Output gate) که خروجی نهایی و سلول حالت جدید را تولید می‌کند. سلول LSTM را می‌توان توسط شکل ۵ و معادلات (۴-۱) تا (۴-۶) توصیف کرد [۳۰].



شکل ۵ - سلول LSTM [۳۰]

Figure 5 - LSTM Cell [30]

$$f_t = \sigma(W_f [h_{t-1}, X_t] + b_f) \quad (۱-۴)$$

$$i_t = \sigma(W_i [h_{t-1}, X_t] + b_i) \quad (۴-۲)$$

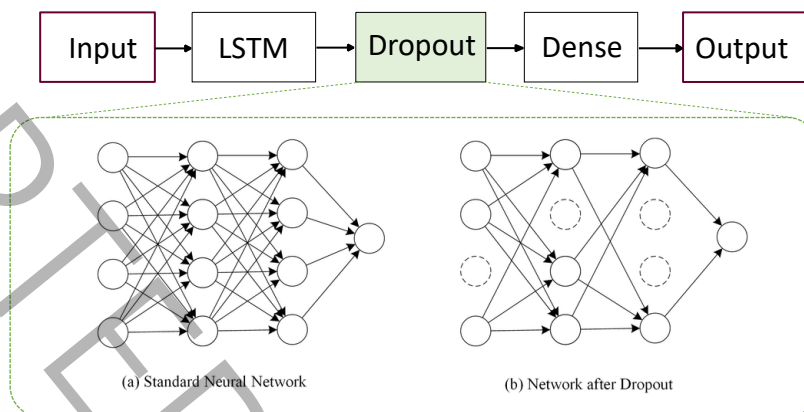
$$\bar{C}_t = \tanh(W_c [h_{t-1}, X_t] + b_c) \quad (۴-۳)$$

$$C_t = i_t * \bar{C}_t + f_t * C_{t-1} \quad (۴-۴)$$

$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \quad (۴-۵)$$

$$h_t = o_t * C_t \quad (۴-۶)$$

WO و WC، Wj، Wf ماتریس‌های وزنی قابل یادگیری bz، br، bh و bo بایاس، ft خروجی دروازه فراموشی، Ct خروجی دروازه ورودی، ot حاصل دروازه خروجی، Ct سلول حالت زمان t و ht خروجی نهایی شبکه است. در شکل ۶ مدل ساخته شده توسط شبکه LSTM نشان داده شده است که در آن لایه Dense یک‌لایه تماماً متصل است و برای جلوگیری از پدیده بیش برآزش از تکنیک حذف تصادفی (Dropout) استفاده شده است. در این روش، برخی از اتصالات بین لایه‌ها به صورت تصادفی در طول آموزش غیرفعال می‌شوند تا از یادگیری تنها یک مسیر خاص جلوگیری شود و شبکه مجبور به یادگیری ویژگی‌های متنوع‌تری شود. [۳۵، ۳۶].



شکل ۶ - معماری مدل LSTM

Figure 6 - Architecture of the LSTM Model.

در سال‌های اخیر شبکه‌های عمیق در زمینه یادگیری ماشین و یادگیری عمیق، بسیار مورد توجه قرار گرفته‌اند. شبکه‌های عمیق را می‌توان دنباله‌ای از لایه‌های پردازشی دانست که در آن هر لایه قبل از انتقال اطلاعات به لایه دیگر، اطلاعات را پردازش کرده و بخشی از مسئله را حل می‌کند تا زمانی که خروجی توسط آخرین لایه تولید شود؛ بنابراین هرچه قدر شبکه عمیق‌تر باشد و تعداد لایه‌های بیشتری داشته باشد، ویژگی‌های غیرخطی بیشتری استخراج می‌شود و مدل‌سازی با دقت بیشتری انجام شود [۳۴، ۳۶].

#### ۸-۲- تبدیل موجک

تبدیل موجک یکی از بهترین روش‌های پردازش سیگنال است. به منظور ساده کردن بررسی سری زمانی اصلی، پس از تجزیه آن، هر کدام از دوره‌های تناوب به طور جداگانه مورد تحلیل قرار می‌گیرند. با توجه به ساختار گسسته سری‌های زمانی هیدرولوژیکی فرم گسسته تبدیل موجک (DWT) مورد استفاده واقع می‌شود. در تبدیل موجک گسسته پارامترهای انتقال و مقیاس به صورت غیرپیوسته و با به کارگیری از روند دودویی به صورت  $a = 2^m$  و  $b = 2^m$  انتخاب می‌شوند. به طوری که  $m$  و  $n$  اعداد صحیح هستند. برای سری گسسته  $x_i$  تبدیل دودویی موجک به صورت رابطه (۵) است [۳۷]:

$$T_{m,n} = 2^{-\frac{m}{n}} \sum_{i=0}^{N-1} \psi(2^{-m}i - n)x_i \quad (5)$$

در رابطه (۵)  $\psi(x)$  تابع موجک،  $N$  طول سری زمانی و  $T_{m,n}$  ضرب موجک برای  $a$  و  $b$  می‌باشد که با اعمال تبدیل موجک گسسته در هر مرحله، سیگنال به دو مؤلفه جزء و تقریب تجزیه می‌شود. یکی از قابلیت‌های اصلی تبدیل موجک گسسته، توانایی آن در تجزیه سری زمانی اصلی به چندین زیرسری زمانی است. هر یک از زیرسری‌های به دست آمده ویژگی خاصی دارند که نمایانگر فرکانس خاص یا دوره فصلی خاصی است. برای کاهش پیچیدگی سری زمانی اصلی، از تجزیه بر اساس موجک استفاده می‌شود تا ویژگی‌های فصلی زیرسری‌های به دست آمده به طور جداگانه تحلیل شوند. تجزیه سری زمانی اصلی به زیرسری‌ها باعث می‌شود که شبکه وزن‌های خاصی

به هر زیرسری اختصاص دهد و در واقع، با تجزیه سری زمانی، ویژگی‌های سری زمانی به‌طور مؤثری استخراج می‌شود و این می‌تواند به بهبود مرحله آموزش و در نتیجه افزایش دقت مدل‌سازی کمک کند [۱۳].

یکی از نکات حائز اهمیت در استفاده از این تبدیل، انتخاب موجک مادر می‌باشد. انتخاب موجک مناسب موضوعی مهم در مدل‌های ترکیبی موجک - شبکه عصبی است که می‌تواند تأثیر قابل توجهی در نتایج مدل‌سازی داشته باشد. ماهیت موجک مادر، کشف شباهت میان سری زمانی تحلیل شده و نمونه موجک استفاده شده می‌باشد [۳۸]. از آنجایی که سریهای زمانی مورد مطالعه تغییرات آرامی داشتند، در این مطالعه برای تجزیه داده‌ها از موجک هار استفاده شده است. تابع موجک هار از اولین و ساده‌ترین موجک‌ها بشمار می‌آید. موجک هار موجکی گسسته بوده و مشابه تابع پله‌ای است. موجک هار علیرغم سادگی از خواص مفیدی برخوردار می‌باشد [۳۹]. در روش پیشنهادی WLSTM، سری‌های زمانی ورودی ابتدا به زیرسیگنال‌های مختلف در مقیاس‌های مختلف تجزیه می‌شوند، به‌طوری که یک زیرسیگنال بزرگ‌مقیاس و چندین زیرسیگنال کوچک‌مقیاس برای به‌دست‌آوردن ویژگی‌های زمانی سیگنال ورودی استخراج می‌شود. اجزای سالانه یا فصلی به زیرسیگنال‌های بزرگ‌مقیاس و نوسانات روزانه، ماهانه و هفتگی به زیرسیگنال‌های کوچک‌مقیاس تجزیه می‌شوند. پس از تجزیه سری‌های زمانی با استفاده از تبدیل موجک، زیرسری‌های به‌دست‌آمده به عنوان ورودی به شبکه LSTM داده می‌شوند [۱۳].

## ۹-۲- معیارهای ارزیابی

در این پژوهش از شاخص‌های آماری متداول نظیر جذر میانگین مربعات خطا (Error Square Mean Root - RMSE)، ضریب تبیین (Determination Coefficient - DC) و خطای میانگین قدر مطلق (Mean Absolute Error - MAE) استفاده شده است. RMSE به دلیل توانایی در اندازه‌گیری دقیق خطاهای پیش‌بینی و DC به دلیل به دلیل قابلیت تشریح واریانس داده‌ها و MAE به دلیل ساده بودن و عدم حساسیت به مقادیر دورافتاده، برای ارزیابی عملکرد مدل‌های مورد استفاده در این تحقیق انتخاب شده‌اند. این معیارها کمک می‌کنند تا عملکرد مدل‌ها را به‌طور مؤثری در هر دو مرحله آموزش و صحت‌سنجی مورد ارزیابی قرار داد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - y_i)^2}{N}} \quad 0 < RMSE < \infty \quad (6)$$

$$DC = 1 - \frac{\sum_{i=1}^n (x_i - y_i)^2}{\sum_{i=1}^n (x_i - \bar{x}_i)^2} \quad -\infty < DC < 1 \quad (7)$$

$$MAE = \frac{1}{N} \sum_{i=1}^n |x_i - y_i| \quad 0 < MAE < \infty \quad (8)$$

در روابط (۶)، (۷) و (۸)،  $x_i$  داده‌های مشاهداتی و  $y_i$  داده‌های محاسباتی توسط مدل،  $n$  تعداد داده‌ها و  $\bar{x}_i$  میانگین داده‌های مشاهداتی است. در هر دو مرحله آموزش و صحت‌سنجی مقادیر RMSE، DC و MAE باید در محدوده مطلوب قرار گیرد. هرچه میزان RMSE و MAE به صفر نزدیک‌تر باشد، مدل خطای کمتری دارد و هرچه میزان DC به یک نزدیک‌تر باشد به این معنی است که مدل برای نمونه مورد نظر مناسب است.

## ۳- نتایج و بحث

برای انجام مدل‌سازی بعد از انتخاب داده‌های ورودی، ابتدا پیش‌پردازش داده‌ها انجام شد؛ سپس با تعریف نوع سلول بازگشتی و تعداد واحدهای حافظه معماری شبکه مورد نظر تعریف شد و با تعیین تابع هزینه و الگوریتم بهینه‌ساز، شبکه تعریف شده با توجه به تعداد تکرارها و دسته‌های تعیین شده برای هر تکرار، بروی داده‌های آموزشی برازش داده شد. برای تعیین بهینه پارامترها، مدل به‌وسیله داده‌های آموزشی مورد ارزیابی قرار گرفت. پس از اینکه مقدار بهینه پارامترها تعیین شد برای پیش‌بینی از داده‌های صحت‌سنجی استفاده شد و مدل‌های تعریف شده با استفاده از معیارهای ارزیابی تعیین شده صحت‌سنجی شدند. مقادیر DC و RMSE مدل‌سازی‌های انجام شده در سناریو ۱ برای هر دو پیرومتر در جدول ۲ نشان داده شده است.

جدول ۲ - نتایج مدل‌سازی سناریو ۱ با استفاده از شبکه‌های عصبی پیشرو و بازگشتی.

Table 2 - Results of Scenario 1 modeling using Feedforward and Recurrent Neural Networks.

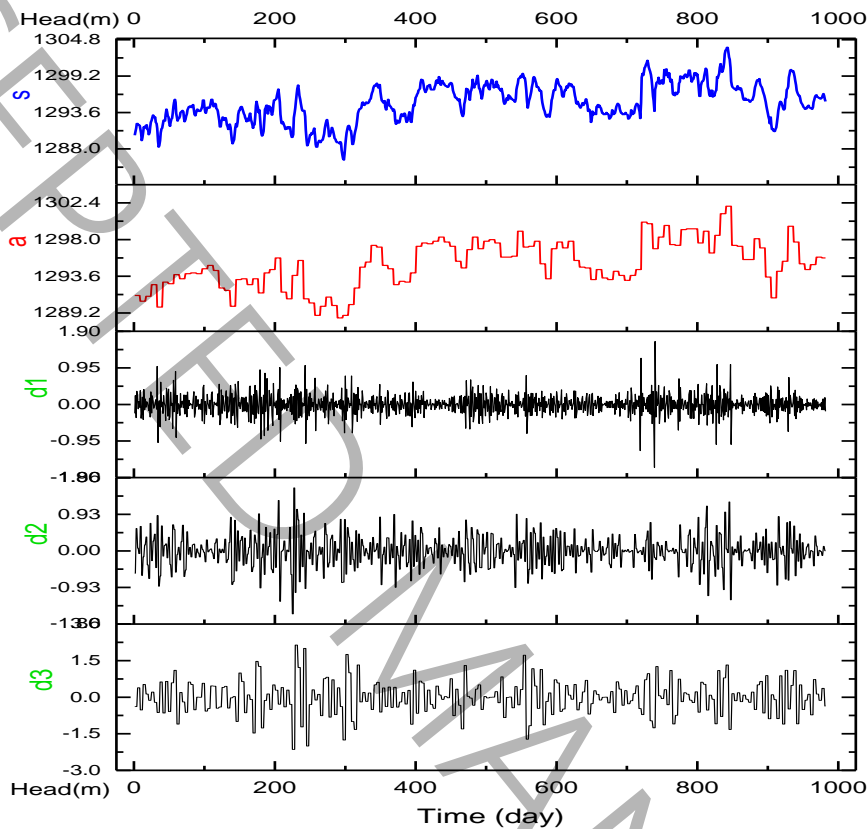
DC	MAE		RMSE		ساختار شبکه					پیزومتر
	آموزش	صحت سنجی	آموزش	صحت سنجی	گام زمانی	تعداد دسته‌ها	تعداد تکرار	واحد پنهان	شبکه	
صحت سنجی	۰/۹۴	۰/۰۳	۰/۰۴	۰/۷۸	۰/۶۵	-	۱۰۰	۵	FFNN	
	۰/۸۷	۰/۰۴	۰/۰۳	۰/۹۵	۰/۸۰	۵	۱۲	۱۰۰۰	Simple RNN	پیزومتر
	۰/۹۳	۰/۰۳	۰/۰۲	۰/۶۸	۰/۵۰	۸	۳۲	۱۰۰۰	LSTM	۲۱۲
	۰/۹۶	۰/۰۲	۰/۰۲	۰/۴۹	۰/۳۵	۸	۳۲	۱۰۰۰	WLSTM	
	۰/۸۲	۰/۰۳	۰/۰۱	۰/۰۳	۰/۰۱	-	۱۰۰	۵	FFNN	
	۰/۸۳	۰/۰۳	۰/۰۱	۰/۰۳	۰/۰۱	۸	۶۴	۵۰۰	Simple RNN	پیزومتر
	۰/۸۶	۰/۰۳	۰/۰۱	۰/۰۳	۰/۰۱	۸	۳۲	۵۰۰	LSTM	۲۱۸
	۰/۸۸	۰/۰۳	۰/۰۱	۰/۰۳	۰/۰۱	۸	۳۲	۵۰۰	WLSTM	

در مرحله اول ارتفاع پیزومترهای ۲۱۲ و ۲۱۸ توسط شبکه عصبی پیشرو با الگوریتم آموزش پس انتشار تخمین زده شدند. در مدل‌سازی توسط شبکه عصبی پیشرو برای تعیین ورودی‌های مؤثر از ضریب همبستگی استفاده شد و در نهایت از ارتفاع پیزومتر ۱ در یک‌زمان قبل و تراز آب بالادست سد در زمان  $t$  و  $t-1$  استفاده شد. برای به‌دست‌آوردن ساختار بهینه، تعداد نرون‌ها در لایه میانی و تعداد تکرار مرحله آموزش متغیر در نظر گرفته شده و در نهایت ساختار بهینه انتخاب شد. باتوجه به نتایج در مدل‌سازی با شبکه‌های عصبی پیشرو مقدار DC برای پیزومتر ۲۱۲ و ۲۱۸ در سناریو ۱ به ترتیب ۰/۹۱ و ۰/۸۲ به دست آمد.

در مرحله بعد مدل‌سازی با شبکه‌های عصبی بازگشتی RNN و LSTM و الگوریتم بهینه‌ساز BBTT با گام‌های زمانی مختلف، تعداد تکرار و دسته متفاوت انجام شد که برای هر دو مدل گام زمانی ۸، تعداد تکرار ۱۰۰۰ و ۵۰۰، اندازه دسته ۳۲، ۱۲ و ۶۴ نتایج بهتری ارائه دادند. در مدل‌سازی با روش‌های هوش مصنوعی خروجی مدل، علاوه بر داده‌های ورودی به درست تنظیم نمودن پارامترها نیز وابسته است؛ برای این منظور، با استفاده از آزمون و خطا پارامترهای سیستم به‌دست‌آمده است. در این پژوهش، پارامترهای گام زمانی، تعداد تکرار، دسته‌های تکرار و واحدهای پنهان با استفاده از روش سعی و خطا انتخاب شد. ساخت دنباله ورودی توسط پارامتر گام زمانی انجام شده و مقدار بهینه آن توسط آزمون و خطا انتخاب شد بطوریکه در مدل‌های بازگشتی مورد استفاده با افزایش گام زمانی ابتدا دقت مدل افزایش یافته است ولی با بیشتر شدن گام زمانی و در نتیجه افزایش طول دنباله ورودی از کارایی مدل کاسته می‌شود. در نهایت برای هر دو پیزومتر گام زمانی ۵ و ۸ انتخاب شد. روند آموزش شبکه در تکرارها و دسته‌های مشخص انجام می‌شود. مقدار این تکرارها و دسته‌ها می‌تواند هر مقدار دلخواهی باشد. برای تعیین مقدار بهینه آن‌ها نیز از روش آزمون و خطا استفاده شده است. مقدار بهینه هر پارامتر، مقدار یست که بیشترین DC و کمترین MAE و RMSE را داشته باشد. مقایسه خطای داده‌های آموزش و تست برای تکرارهای متفاوت، نشان داد که با افزایش تعداد تکرارها شبکه کم‌کم قدرت تعمیم خود را از دست می‌دهد و دچار بیش‌برازش می‌شود. در نهایت تعداد ۵۰۰ و ۱۰۰۰ تکرار برای آموزش مدل‌های مورد استفاده انتخاب شد. با افزایش تعداد واحدهای پنهان، ظرفیت شبکه بازگشتی افزایش پیدا می‌کند و شبکه پیچیده‌تر می‌شود. برای انتخاب مقدار مناسب این پارامتر همانند پارامترهای قبلی مطابق جدول (۲)، از روش آزمون و خطا استفاده شد. باتوجه به نتایج در مدل‌سازی با شبکه بازگشتی ساده مقدار DC برای پیزومتر ۲۱۲ و ۲۱۸ در سناریو ۱ به ترتیب ۰/۸۷ و ۰/۸۳ به دست آمد. همچنین در مدل‌سازی با شبکه LSTM نیز در حالت بهینه مقدار DC برای پیزومتر ۲۱۲ و ۲۱۸ در سناریو ۱ به ترتیب ۰/۹۳ و ۰/۸۶ به دست آمد.

در گام بعدی مدل‌سازی توسط مدل ترکیبی موجک - شبکه عمیق استفاده شد. بدین منظور ابتدا سری‌های زمانی توسط تبدیل موجک گسسته به زیرسری‌هایی تجزیه شدند. باتوجه به اینکه که سری‌های زمانی مورد مطالعه تغییرات آرامی داشتند، در این مطالعه برای تجزیه داده‌ها از موجک هار استفاده شد. از تجزیه یک سیگنال توسط تبدیل موجک گسسته ضرایب جزئی تقریب حاصل می‌شوند.

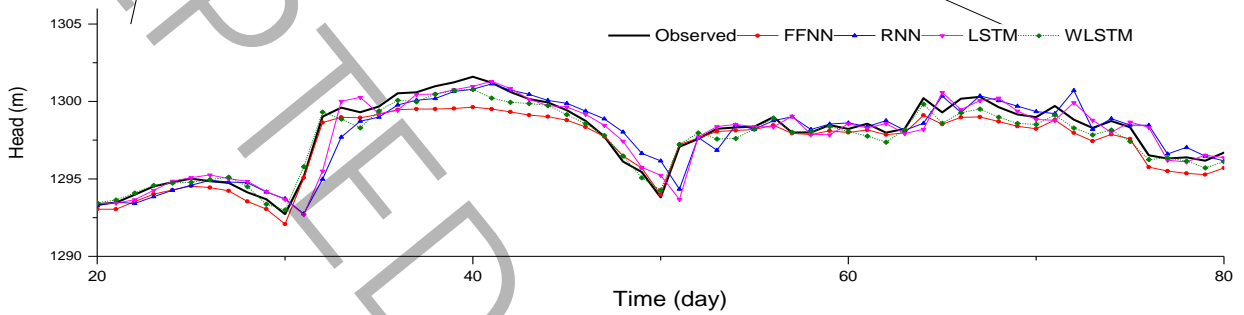
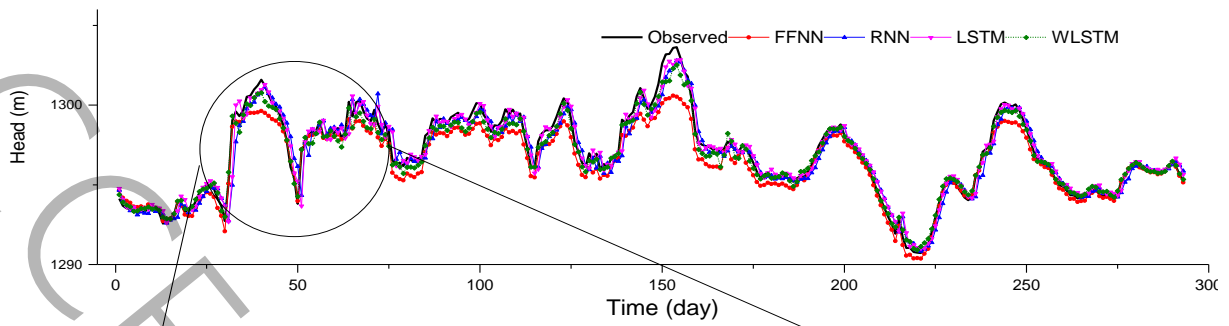
به‌عنوان نمونه شکل ۷ تجزیه سری زمانی ارتفاع پیزومتریک مربوط به پیزومتر ۲۱۲ را نشان می‌دهد ضرایب تقریب (a) نشانگر ضرایب تبدیل موجک با وضوح درشت هستند که روندهای صاف و هموار را در سری نشان می‌دهند و Di ضرایب جزء هستند که اطلاعات جزئی از روندها و تناوب‌های خاصی از سری زمانی را ارائه می‌کنند.



شکل ۷ - زیرسری‌های تجزیه شده سری زمانی پیزومتر ۲۱۲ توسط موجک هار درجه سه.


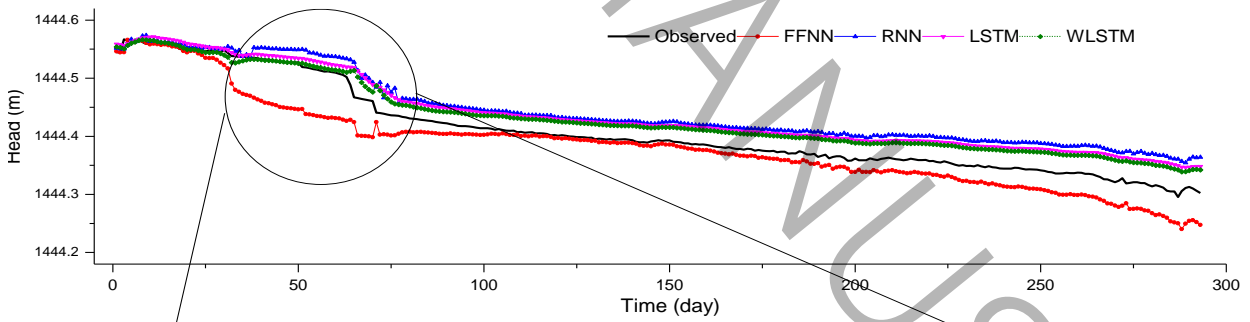
Figure 7 - Decomposed subseries of piezometer 212 time series using third-order Haar wavelet.

باتوجه به شکل ۷ مشاهده می‌شود که اجزای بالاتر دارای فرکانس پایین (دوره تناوب بلند) هستند که نشان‌دهنده تغییرات آرام و اجزای پایین‌تر دارای فرکانس بالا (دوره تناوب کوتاه) هستند که نشان‌دهنده تغییرات سریع هستند. باتوجه به نتایج جدول ۲ بعد از انتخاب ساختار بهینه توسط آزمون و خطا برای مدل WLSTM مقدار DC برای پیزومتر ۲۱۲ و ۲۱۸ در سناریو ۱ به ترتیب ۰/۹۶ و ۰/۸۸ به دست آمد. مقادیر مشاهده و محاسبه شده در مرحله صحت سنجی توسط مدل‌ها بر اساس سناریو ۱ برای پیزومتر ۲۱۲ در شکل ۸ و برای پیزومتر ۲۱۸ در شکل ۹ نشان داده شده است باتوجه به شکل‌های ۸ و ۹ در هر دو پیزومتر شبکه‌های بازگشتی به دلیل داشتن ساختار بازگشتی، در شناسایی و تخمین پدیده تراوش که وابسته به زمان است نسبت به شبکه‌های پیشرو عملکرد بهتری دارند.



شکل ۸ - مقادیر مشاهده و محاسبه شده مرحله صحت سنجی پیزومتر ۲۱۲.


Figure 8 - Observed and computed values for the validation stage of piezometer 212.



شکل ۹ - مقادیر مشاهده و محاسبه شده مرحله صحت سنجی پیزومتر ۲۱۸.

Figure 9 - Observed and computed values for the validation stage of piezometer 218.

در سناریو دوم از ضریب همبستگی برای تعیین ۲ پیزومتر مؤثر در مدل سازی استفاده شد. نمودار راداری **source not found.** ضریب همبستگی پیزومترهای ۲۱۲ و ۲۱۸ را با سایر پیزومترهای موجود در بدنه سد ستارخان را نشان می دهد که در آن پیزومتر ۲۱۲ با پیزومتر ۲۱۱ و ۲۱۳ و پیزومتر ۲۱۸ با دو پیزومتر ۲۱۵ و ۲۱۷ بیشترین همبستگی را دارد. بعد از تعیین ورودی ها در سناریو ۲ مراحل مدل سازی مانند سناریو ۱ انجام شد. نتایج مدل سازی سناریو ۲ با شبکه های عصبی پیشرو و بازگشتی برای هر دو پیزومتر در جدول ۳ نشان داده شده است.



شکل ۱۰ - ضریب همبستگی پیزومترهای ۲۱۲ و ۲۱۸ با سایر پیزومترها.

Figure 10 - Correlation coefficient of piezometers 212 and 218 with other piezometers.

جدول ۳ - نتایج مدل سازی سناریو ۲ با استفاده از شبکه های عصبی پیشرو و بازگشتی.

Table 3 - Results of Scenario 2 modeling using Feedforward and Recurrent Neural Network.

DC	MAE		RMSE		ساختار شبکه				پیزومتر
	آموزش	صحت سنجی	آموزش	صحت سنجی	گام زمانی	تعداد دسته ها	تعداد تکرار	واحد پنهان	
صحت سنجی	۰/۹۵	۰/۰۳	۰/۰۳	۰/۷۸	-	-	۱۰۰	۴	FFNN
پیزومتر ۲۱۲	۰/۹۶	۰/۰۲	۰/۰۱	۰/۵۵	۵	۱۲	۱۰۰۰	۱۰	Simple RNN
	۰/۹۷	۰/۰۲	۰/۰۱	۰/۴۴	۸	۳۲	۱۰۰۰	۵	LSTM
	۰/۹۸	۰/۰۲	۰/۰۱	۰/۳۶	۸	۳۲	۱۰۰۰	۵	WLSTM
پیزومتر ۲۱۸	۰/۷۰	۰/۰۳	۰/۰۱	۰/۰۴	-	-	۱۰۰	۵	FFNN
	۰/۷۱	۰/۰۲	۰/۰۱	۰/۰۴	۸	۳۲	۵۰۰	۱۰	Simple RNN
	۰/۷۴	۰/۰۲	۰/۰۱	۰/۰۴	۸	۳۲	۵۰۰	۱۰	LSTM
	۰/۷۷	۰/۰۲	۰/۰۱	۰/۰۴	۵	۳۲	۵۰۰	۵	WLSTM

در مرحله اول سناریو ۲ در مدل سازی با شبکه های عصبی پیشرو مقدار DC برای پیژومتر ۲۱۲ و ۲۱۸ به ترتیب ۰/۹۱ و ۰/۷۰ به دست آمده است. در مدل سازی با شبکه های عصبی بازگشتی RNN و LSTM و الگوریتم بهینه ساز BBTT برای هر دو مدل تعداد تکرار ۵۰۰ و اندازه دسته ۳۲ و ۱۲ نتایج بهتری ارائه دادند. در مدل سازی با شبکه RNN مقدار DC برای پیژومتر ۲۱۲ و ۲۱۸ در سناریو ۲ به ترتیب ۰/۹۶ و ۰/۷۱ و در مدل سازی با شبکه LSTM مقدار DC برای پیژومتر ۲۱۲ و ۲۱۸ در سناریو ۲ به ترتیب ۰/۹۷ و ۰/۷۴ به دست آمد. در گام بعدی و مدل سازی توسط مدل ترکیبی موجک - شبکه عمیق ارتفاع پیژومتر یک پیژومترهای ۲۱۲ و ۲۱۸ با دقت ۰/۹۸ و ۰/۷۷ تخمین زده شد.

باتوجه به نتایج به دست آمده در مدل سازی سری های زمانی هیدرولوژی مانند تراوش شبکه های بازگشتی نسبت به شبکه های پیشرو دقت تخمین بالاتری دارند و برای پیش بینی سیستم های دینامیکی مناسب هستند. استفاده از شبکه های با ساختار خاص مانند LSTM با غلبه بر مشکل محوشدگی گرادیان، دقت بیشتری نسبت به شبکه بازگشتی ساده دارند. اگرچه استفاده از انواع مختلف شبکه های عصبی مصنوعی در مدل سازی های غیرخطی مسائل هیدرولیکی و هیدرولوژیکی کاربرد فراوانی دارد، در مدل سازی سری های زمانی که دارای تغییرات شدید بوده و یا نا ایستا باشند بازده مدل های شبکه عصبی مصنوعی کم خواهد شد و استفاده از تبدیل موجک به عنوان پیش پردازش زمانی داده ها باعث رفع این نقصان و افزایش دقت مدل سازی می شود. با توجه به نتایج استفاده از مدل ترکیبی شبکه بازگشتی - موجک باعث افزایش عملکرد مدل سازی شده به طوری که دقت مدل سازی در پیژومتر ۲۱۲ و ۲۱۸ به ترتیب ۳ و ۴٪ نسبت به مدل سازی با شبکه های بازگشتی عمیق و به ترتیب ۸ و ۱۰٪ نسبت به شبکه عصبی پیشرو افزایش یافت. برای پیژومتر ۲۱۲ نتایج دقیق تری نسبت به پیژومتر ۲۱۸ به دست آمده است؛ چون پیژومتر ۲۱۲ به بالادست سد نزدیک تر است در نتیجه همبستگی بیشتری با سری زمانی ارتفاع آب بالادست دارد. در مقابل پیژومتر ۲۱۸ فاصله بیشتری با بالادست سد دارد و به علت اینکه حرکت آب در خاک آهسته است و عبور آب از خاک باعث کاهش نوسانات موجود در بالادست سد می شود، از این رو سری زمانی پیژومتر ۲۱۸ همبستگی کمتری با سری زمانی بالادست سد دارد. به علت استفاده از سری های زمانی بالادست سد و خود پیژومتر در مدل سازی ها در نهایت نتایج بهتری برای پیژومتر ۲۱۲ به دست آمده است. با اینکه که در سناریو ۲ از خود پیژومتر در مدل سازی استفاده نشده؛ ولی نتایج حاصل از سناریو ۲ مانند سناریو ۱ دارای دقت بالایی است. این امر به این دلیل است که از داده های هم زمان با داده های هدف و همین طور از ۲ پیژومتر برای مدل سازی استفاده شده است. روش پیشنهادی در این تحقیق با بهبود دقت پیش بینی تراز آب و تراوش در پیژومترها نسبت به روش های سنتی و شبکه های عصبی پیشرو، به مدیران سدها امکان می دهد تا تصمیم گیری های دقیق تری انجام دهند و در مواقع بحرانی مانند خشکسالی یا بارندگی های شدید، از وقوع بحران های جدی جلوگیری کنند. همچنین، این مدل به دلیل توانایی استفاده از داده های پیژومترهای همبسته به جای داده های معیوب، در شرایط خرابی یا نقص فنی تجهیزات، همچنان دقت پیش بینی ها را حفظ کرده و عملکرد مطمئن سد را تضمین می کند. علاوه بر این، روش ترکیبی شبکه بازگشتی - موجک با قابلیت تشخیص تغییرات بلندمدت و پیچیده در تراوش و سایر پارامترهای هیدرولوژیکی، به برنامه ریزی و مدیریت بلندمدت سد کمک می کند و می تواند استراتژی های بهینه تری برای تنظیم جریان آب و افزایش عمر مفید سد ارائه دهد. همچنین این مدل قادر است الگوهای غیرعادی یا ناگهانی در تراوش را که ممکن است نشان دهنده مشکلات ساختاری یا عملکردی در سد باشند، شناسایی کند. از آنجا که در سناریوی دوم این تحقیق، تراز آب پیژومترها بدون استفاده از مقادیر مشاهده شده قبلی و با بهره گیری از داده های پیژومترهای دیگر تخمین زده شده است، این مدل در شرایط بحرانی و از کارافتادگی پیژومترها نیز بسیار مفید خواهد بود. این ویژگی، به ویژه زمانی که تجهیزات پایش سد دچار نقص شده اند، از طریق استفاده از داده های جایگزین، به حفظ دقت و قابلیت اطمینان پیش بینی ها کمک می کند.

#### ۴- نتیجه گیری

در این تحقیق، تراوش سد ستارخان با استفاده از شبکه های عصبی پیشرو و بازگشتی در دو سناریو مدل سازی شد. نتایج نشان داد که شبکه های بازگشتی نسبت به شبکه های عصبی پیشرو در مدل سازی پدیده های وابسته به زمان مانند تراوش، دقت بالاتری دارند. دارند به طوری که باعث افزایش دقت مدل سازی تا ۷٪ شده است. در ادامه، برای افزایش کارایی مدل سازی، از تبدیل موجک در پیش پردازش داده ها استفاده شد. این پیش پردازش داده ها منجر به بهبود نتایج مدل سازی شد، به طوری که در مدل ترکیبی شبکه



عصبی بازگشتی - موجک، دقت مدل نسبت به مدل‌های بدون استفاده از تبدیل موجک به میزان تا ۱۰٪ افزایش داده است. همچنین، مقایسه نتایج دو سناریو نشان داد که استفاده از داده‌های هم‌زمان با داده‌های هدف در مدل‌سازی، دقت مدل‌سازی را به میزان ۴۱٪ در پی‌زومتر ۲۱۸ افزایش داده است. این نتیجه‌گیری حاکی از آن است که در صورت خرابی یک پی‌زومتر، می‌توان از داده‌های پی‌زومترهایی که همبستگی بالایی با پی‌زومتر مورد نظر دارند استفاده کرد. همچنین، در مدل‌سازی پی‌زومتر نزدیک‌تر به بالادست سد، به دلیل همبستگی بیشتر با سری زمانی بالادست، نتایج دقیق‌تری به دست آمد. پیشنهاد می‌شود برای سایر کمیت‌های سد مثل تراوش از پی اقدام به مدل‌سازی مشابه شود. باتوجه به تعداد و اهمیت تنظیم هایپر پارامترهای شبکه‌های عمیق و چالش‌های استفاده از روش آزمون و خطا پیشنهاد می‌شود برای تعیین مقدار این پارامترها از روش‌ها و الگوریتم‌های هوشمند استفاده شود. در مدل‌سازی با استفاده از شبکه‌های عمیق، استفاده از الگوریتم‌های هوشمند می‌تواند به کاهش زمان مورد نیاز برای تنظیم هایپر پارامترها، افزایش دقت پیش‌بینی‌ها، و بهبود عملکرد کلی مدل کمک کند.

#### ۵- منابع

- [1] V. Nourani, E. Sharghi, M.H. Aminfar, Integrated ANN model for earthfill dams seepage analysis: Sattarkhan Dam in Iran, *Artif. Intell. Res.*, 1(2) (2012) 22-37.
- [2] A. Pourghasemzadeh, M. Mahdavi Adeli, A comparison of the construction of cut-off wall and grouting curtain in the foundation of Gotvand Aliya Dam from an economic and scheduling perspective, in: 5th international Congress on civil engineering, architecture and urban development, 2017. (in Persian)
- [3] B. Nemati, H. Shafiee, Numerical modeling of seepage in earth dams using numerical methods, in: Fourth Conference on New Research in Science and Technology, 2015. (in Persian)
- [4] L.N. Reddi, *Seepage in soils: principles and applications*, John Wiley & Sons, 2003.
- [5] E. Sharghi, V. Nourani, N. Behfar, Evaluation and Application of Ensemble AI-based Models for Estimating Piezometric Heads of Earth Fill Dam, *Iran-Water Resources Research*, 14(4) (2018) 160-169. (in Persian)
- [6] G. Tayfur, D. Swiatek, A. Wita, V.P. Singh, Case study: Finite element method and artificial neural network models for flow through Jeziorsko earthfill dam in Poland, *Journal of Hydraulic Engineering*, 131(6) (2005) 431-440.
- [7] D. Ersayın, *Studying seepage in a body of earth-fill dam by (Artificial Neural Networks) ANNs*, Izmir Institute of Technology, 2006.
- [8] X.Y. Miao, J.K. Chu, J. Qiao, L.H. Zhang, Predicting seepage of earth dams using neural network and genetic algorithm, in: *Advanced Materials Research*, Trans Tech Publ, 2012, pp. 3081-3085.
- [9] P. Coulibaly, C.K. Baldwin, Nonstationary hydrological time series forecasting using nonlinear dynamic methods, *Journal of Hydrology*, 307(1-4) (2005) 164-174.
- [10] S.J. Yoo, J.B. Park, Y.H. Choi, Stable predictive control of chaotic systems using self-recurrent wavelet neural network, *international journal of control, automation, and systems*, 3(1) (2005) 43-55.
- [11] S. Mirabedini, A review on deep learning, in: *Third National Conference on Electrical and Computer Engineering*, 2018. (in Persian)
- [12] A.U. Muhammad, X. Li, J. Feng, Using LSTM GRU and hybrid models for streamflow forecasting, in: *International Conference on Machine Learning and Intelligent Communications*, Springer, 2019, pp. 510-524.
- [13] V. Nourani, N. Behfar, Multi-station runoff-sediment modeling using seasonal LSTM models, *Journal of Hydrology*, 601 (2021) 126672.

- [14] C. Park, I.-M. Chung, Evaluating the groundwater prediction using LSTM model, *Journal of Korea Water Resources Association*, 53(4) (2020) 273-283.
- [15] h. siasar, T. honar, Comparison of Performance of GLM, RF and DL Models in Estimation of Reference Evapotranspiration in Zabol Synoptic Station, *journal of watershed management research*, 11(22) (2020) 210-219.
- [16] M. Ishfaqe, Q. Dai, N.u. Haq, K. Jadoon, S.M. Shahzad, H.T. Janjuhah, Use of recurrent neural network with long short-term memory for seepage prediction at Tarbela Dam, KP, Pakistan, *Energies*, 15(9) (2022) 3123.
- [17] N. Farboudfam, V. Nourani, B. Aminnejad, Spatial-temporal disaggregation of rainfall time series using wavelet-artificial neural network hybrid model, *Iran-Water Resources Research*, 14(5) (2019) 490-495. (in Persian)
- [18] D.M. Hawkins, The problem of overfitting, *Journal of chemical information and computer sciences*, 44(1) (2004) 1-12.
- [19] B. Cannas, A. Fanni, G. Sias, S. Tronci, M. Zedda, River flow forecasting using neural networks and wavelet analysis, in: *Geophys. Res. Abstr*, 2005, pp. 08651.
- [20] V. Nourani, A.H. Baghanam, J. Adamowski, O. Kisi, Applications of hybrid wavelet–artificial intelligence models in hydrology: a review, *Journal of Hydrology*, 514 (2014) 358-377.
- [21] K. Roushangar, V. Nourani, M. Dolatshahi, Investigation and trend identification of groundwater level variations using discrete wavelet transform and non-parametric tests (case study: Azarshahr plain), *Iran-Water Resources Research*, 16(1) (2020) 102-115. (in Persian)
- [22] B. Fatehi-Nobarian, S. Fard Moradinia, Wavelet-ANN hybrid model evaluation in seepage prediction in nonhomogeneous earth dams, *Water Practice & Technology*, (2024) wpt2024152.
- [23] M.G. Zamani, M.R. Nikoo, F. Niknazar, G. Al-Rawas, M. Al-Wardy, A.H. Gandomi, A multi-model data fusion methodology for reservoir water quality based on machine learning algorithms and bayesian maximum entropy, *Journal of Cleaner Production*, 416 (2023) 137885.
- [24] Behavior monitoring report of the Sattar Khan dam project, in: *B.C. Engineers (Ed.)*, 2003. (in Persian)
- [25] M. Ghabaei Sough, A. Mosaedi, M. Hesam, A. Hezarjaribi, Evaluation Effect of Input Parameters Preprocessing in Artificial Neural Networks (Anns) by Using Stepwise Regression and Gamma Test Techniques for Fast Estimation of Daily Evapotranspiration, *Water and Soil*, 24(3) (2010) -. (in Persian)
- [26] V. Nourani, *Fundamentals of hydroinformatics*, University of Tabriz, 2015. (in Persian)
- [27] A. Graves, Supervised sequence labelling, in: *Supervised sequence labelling with recurrent neural networks*, Springer, 2012, pp. 5-13.
- [28] J. Brownlee, Long short-term memory networks with python: develop sequence prediction models with deep learning, *Machine Learning Mastery*, 2017.
- [29] A. Graves, A.-r. Mohamed, G. Hinton, Speech recognition with deep recurrent neural networks, in: *2013 IEEE international conference on acoustics, speech and signal processing*, Ieee, 2013, pp. 6645-6649.
- [30] C. Olah, Understanding lstm networks–colah’s blog, Colah. github. io, (2015).
- [31] J. Chung, C. Gulcehre, K. Cho, Y. Bengio, Empirical evaluation of gated recurrent neural networks on sequence modeling, *arXiv preprint arXiv:1412.3555*, (2014).
- [32] Y. Bengio, P. Simard, P. Frasconi, Learning long-term dependencies with gradient descent is difficult, *IEEE transactions on neural networks*, 5(2) (1994) 157-166.
- [33] S. Hochreiter, J. Schmidhuber, Long short-term memory, *Neural computation*, 9(8) (1997) 1735-1780.
- [34] R. Pascanu, C. Gulcehre, K. Cho, Y. Bengio, How to construct deep recurrent neural networks, *arXiv preprint arXiv:1312.6026*, (2013).

- [35] S. Hochreiter, Recurrent neural net learning and vanishing gradient, *International Journal Of Uncertainty, Fuzziness and Knowledge-Based Systems*, 6(2) (1998) 107-116.
- [36] M. Hermans, B. Schrauwen, Training and analysing deep recurrent neural networks, *Advances in neural information processing systems*, 26 (2013) 190-198.
- [37] F. Daneshvar Vousoughi, R. Shaker, Assessment of Trend in Groundwater Level using Hybrid Mann-Kendall and Wavelet Transform Method (Case Study: Ardabil Plain), *Environment and Water Engineering*, 4(3) (2018) 241-251. (in Persian)
- [38] J. Adamowski, H.F. Chan, A wavelet neural network conjunction model for groundwater level forecasting, *Journal of Hydrology*, 407(1-4) (2011) 28-40.
- [39] O.S. Jahromi, B.A. Francis, R.H. Kwong, Algebraic theory of optimal filterbanks, *IEEE transactions on signal processing*, 51(2) (2003) 442-457.

## **Estimation of seepage in earth fill dams using deep learning and wavelet transform**

### **ABSTRACT**

Seepage prediction is one of the important tools in preventing erosion and destruction earth fill dams. In recent years, due to the uncertainty, complexity, and nonlinearity of seepage relationships, the use of artificial

intelligence methods for estimation and prediction of this phenomenon has gained attention. The objective of this research is to estimate seepage in the Starakhan earth fill dam located in northwest Iran. To achieve this objective, in this research, the long-short-term memory network and the wavelet-deep network hybrid model have been used in two different scenarios, and the results obtained from these models have been compared with the feed forward neural network. The results obtained indicated that deep recurrent networks, in the modeling of the seepage phenomenon, outperformed the forward neural networks in terms of estimation accuracy. This can be attributed to their recursive connection between the output and input at each time step, as well as their ability to learn dependencies from previous time sequences. The modeling accuracy was improved by up to 7% as a result. Furthermore, the combined wavelet-deep network model demonstrated superior performance compared to other models, resulting in a 10% increase in modeling accuracy. In conclusion, the utilization of deep recurrent networks and the combined wavelet-deep network model in seepage modeling holds the potential to enhance estimation accuracy when predicting this phenomenon.

#### **KEYWORDS**

Earth fill dam seepage, artificial neural network, long short-term memory (LSTM) network, wavelet transform, Sattarkhan earth fill dam