

مدل سازی پیشی بینی میزان رسوب رودخانه قلعه رودخان با استفاده از شبکه

عصبی LSTM

محبوبه شادابی بجد^{۱*}

mahbobeh3408@gmail.com

ابراهیم امیری^۲

تاریخ پذیرش: ۱۴۰۰/۶/۲

تاریخ دریافت: ۹۹/۹/۲۱

چکیده

زمینه و هدف: برآورد مناسب از میزان رسوب جاری شده در رودخانه‌ها به عنوان مبنای داده‌ای برای بسیاری از طرح‌ها و فرآیندهای مهندسی رودخانه دارای اهمیت است. رودخانه قلعه رودخان یکی از حوزه‌های آبی بسیار مهم در غرب استان گیلان می باشد. رودخانه قلعه رودخان از دو شاخه (حیدرآلات) و (نظر آلات) تشکیل شده است. از همین رو، هدف از انجام این پژوهش، مدل سازی پیشی بینی میزان رسوب رودخانه قلعه رودخان با استفاده از شبکه عصبی حافظه طولانی کوتاه مدت (LSTM) است.

روش بررسی: در این تحقیق از آمار دبی - رسوب ثبت شده مربوط به دوره آماری سال ۱۳۸۱ تا ۱۳۹۵ استفاده شده است. این آمار شامل دبی لحظه ای روزانه به مترمکعب بر ثانیه و رسوب روزانه لحظه ای به تن در روز است که همزمان اندازه گیری شده اند. متغیرهای تحت بررسی در مدل سازی پیش بینی مستلزم ایجاد یک شبکه عصبی مصنوعی، وجود یک سری داده، به منظور مدل سازی در این شبکه می باشد. **یافته ها:** دقت پیش بینی های انجام شده با سه معیار خطا بررسی شد. سه معیار مورد بررسی به ترتیب AFE، FFE و n-AFE هستند. **بحث و نتیجه گیری:** نتایج به دست آمده نشان داد که از میان معیارهای مورد بررسی معیار FFE همبستگی میان خروجی مدل و داده های اندازه گیری شده رسوب مناسب می باشد. در نتیجه مدل LSTM دارای دقت مناسب برای پیش بینی مقدار رسوب دو رودخانه قلعه رودخان می باشد.

واژه های کلیدی: استان گیلان، رسوب لحظه ای، رودخانه قلعه رودخان، شبکه های عصبی بازگشتی، LSTM.

۱ - دانشجوی دکتری گروه مهندسی آب، واحد لاهیجان، دانشگاه آزاد اسلامی، لاهیجان، ایران. * (مسئول مکاتبات)

۲ - استاد گروه مهندسی آب، واحد لاهیجان، دانشگاه آزاد اسلامی، لاهیجان، ایران.

Modeling of Qaleh Rudkhan river sediment rate prediction, using LSTM neural network

Mahbobeh Shadabi Bejand^{1*}

mahbobeh3408@gmail.com

Ebrahim Amiri²

Admission Date: August 24, 2021

Date Received: September 11, 2020

Abstract

Background and Objective: Proper estimation of the amount of sediment flowing in rivers is important as a data base for many river engineering designs and processes. Qaleh Rudkhan River is one of the most important water basins in the west of Gilan province. The most important branches of the basin are two branches named Gasht Rudkhan and Ghaleh Rudkhan. The river (Qaleh Rudkhan) is made up of two branches (Heydaralat) and (Nazaralat). Therefore, the purpose of this study was to model the prediction of sediment rate in Qaleh Rudkhan River using long short-term memory neural network (LSTM).

Material and Methodology: In this research, the recorded Debi-sediment statistics related to the statistical period of 1381 to 1395 has been used. These statistics include daily instantaneous Debi in cubic meter per second and daily instantaneous sediment in ton per day, which are measured simultaneously. The data used to model the artificial neural network are Debi-sediment values the accuracy of the predictions was evaluated with three error criteria.

Findings: The three criteria considered are AFE, FFE and n-AFE, respectively.

Discussion and Conclusion: Among these criteria, the FFE criterion showed that the correlation between the model output and the measured sediment data is appropriate. As a result, the LSTM model has the appropriate accuracy to predict the amount of sediment in the two rivers of Qala-e-Rudkhan.

Keywords: Guilan province, instantaneous sediment, Qaleh Rudkhan River, recurrent neural networks, LSTM.

1- Phd student, Department of Water Engineering, Lahijan Branch, Islamic Azad University, Lahijan, Iran.
*(Corresponding Author)

2- Prof, Department of Water Engineering, Lahijan Branch, Islamic Azad University, Lahijan, Iran.

مقدمه

و احتمالات فروان مواجه ساخته است. با وجود این، پیش بینی رسوب امری ضروری و اجتناب ناپذیر می باشد. مهندسان هیدرولیک و زمین شناسان طی دو قرن گذشته حرکت مواد رسوبی در رودخانه ها را مورد بررسی قرار داده اند چرا که رفتار مواد رسوبی در هیدرولیک رودخانه و تغییر مورفولوژی آن دارای اهمیت است. طبیعت پیچیده انتقال رسوب و وابستگی آن به شرایط طبیعی، علم انتقال رسوب را به رشته ای تجربی و یا حداقل نیمه تجربی تبدیل کرده است (۲).

امروزه مدیریت کمی و کیفی منابع آب به سبب افزایش نیازمندی ها و مصرف جوامع انسانی، بیش از پیش از اهمیت ویژه ای برخوردار است (۳). پدیده فرسایش خاک و انتقال رسوب از جمله فرآیندهای مهم هیدرودینامیک هستند (۵ و ۴) که به عنوان یکی از بزرگترین چالش های بهره برداری از منابع آب های سطحی در جهان شناخته می شوند (۶). ورود رسوبات معلق و مواد مغذی توسط رواناب به خروجی آبخیز یا سطوح اساس، یکی از مهمترین دلایل کاهش کیفیت سامانه های آبی است (۷). اطلاعات کافی در این زمینه به عنوان پایه ای برای پروژه های رودخانه ای مانند برداشتن قوس رودخانه ها، تنگ شدگی رودخانه، کشتیرانی، کنترل سیل، پس رفت آب و طراحی مخازن لازم است (۸). فرسایش و رسوب گذاری، فرآیندی است که به از دست رفتن خاک های حاصل خیز حوزه های آبخیز و همچنین ایجاد خسارات جبران ناپذیر به پروژه های عمرانی از جمله انباشته شدن رسوبات در پشت سدها و کاهش حجم مفید آن ها، تخریب سازه ها و غیره منجر می شود. از طرف دیگر، حمل رسوب روی شاخص های کیفیت آب از لحاظ شرب و کشاورزی نیز تأثیرگذار است. لذا برآورد حجم و مقدار نزدیک به واقعیت رسوبات حمل شده در پروژه های آبی، آبخیزداری و بهره برداری از منابع آب مورد نیاز است (۹). تعیین بار رسوبی رودخانه ها مستلزم تهیه داده های آماری و انجام اندازه گیری های میدانی و تهیه اطلاعات پایه ای مرتبط با سامانه رودخانه و حوضه آبریز آن می باشد. همچنین طراحی بهینه و عملکرد مناسب سازه های منابع آب، نظیر مخزن، سد و کانال نیازمند تخمین دقیق از بار رسوبی رودخانه است

برآورد دبی رودخانه ها به خصوص دبی اوج تأثیر زیادی بر برنامه ریزی و مدیریت حوضه رودخانه ها، ارزیابی ریسک، کنترل سیلاب و خشکسالی و همچنین، توسعه مدیریت منابع آبی خواهد داشت (۱). پیش بینی میزان رسوب رودخانه ها اهمیت بسزایی دارد و از دیرباز مورد توجه محققان قرار داشته است. با وجود پیشرفت های فراوانی که در این زمینه صورت گرفته به دلیل پیچیده بودن مسأله رسوب و وابستگی آن به شرایط طبیعی نتایج به دست آمده از پژوهش ها در این زمینه را با عدم قطعیت (۱۰). غلظت رسوب، متغیر بسیار مهمی است که نقش عمده ای در ارزیابی کیفیت منابع آب دارد (۱۱). شبکه عصبی مصنوعی روشی است که بر پایه شبیه سازی عملکرد مغز انسان برای حل مسایل متنوع ارایه و از لایه های نرون ورودی، خروجی و میانی و وزنه های مربوط به مقادیر ورودی و بایاس و تابع تحریک تشکیل شده است. از قابلیت های شبکه عصبی مصنوعی میتوان به مواردی مانند محاسبه یک تابع معلوم، تقریب یک نگاشت نامعلوم، شناسایی الگو، پردازش سیگنال و یادگیری اشاره کرد (۱۲). از معایب روش های شبکه عصبی نیز این است که تابعی در اختیار قرار نمی دهد که بتوان از آن به صورت صریح استفاده نمود. محققین در مورد پدیده فرسایش و انتقال رسوب در سال های اخیر توانسته اند با استفاده از روش های هوش مصنوعی به عنوان یک ابزار جدید، مقدار رسوبات معلق را محاسبه نموده اند. یوسفی و همکاران طی پژوهشی در استان لرستان با استفاده از شبکه عصبی مصنوعی به برآورد میزان رسوب پرداختند و به این نتیجه رسیدند که از بین الگوریتم های موجود، الگوریتم TRAINLM با ضریب همبستگی $R = 0.99$ و $RMSE = 0.10$ (ton/day)، بهترین الگوریتم است (۱۳). همچنین در پژوهشی دیگر طباطبایی و همکاران با استفاده از شبکه عصبی مصنوعی و خوشه بندی داده ها به برآورد غلظت رسوب معلق روزانه به این نتیجه رسیدند که استفاده از متغیرهای بارش و دمای روزانه به همراه دبی جریان و تفکیک زمانی داده ها، نقش مهمی در افزایش دقت برآورد رسوب رودخانه داشته است (۱۴). فلامکی و همکاران طی مطالعه ای به مدل سازی بار رسوب کل رودخانه ها با

آنها نشان داد که روش پرسپترون چندلایه و پلی نومیال های درجه ۳ نسبت به سایر روش های موجود برتری دارند (۲۱). مطالعات محققان نشان می دهد که بررسی های زیادی در راستای برآورد رسوب و مدل های شبکه عصبی مصنوعی انجام شده است ولی با استفاده از مدل LSTM تاکنون پیش بینی میزان رسوب رودخانه مدل سازی نشده است. هدف از ارائه این پژوهش مدلسازی پیش بینی میزان رسوب رودخانه قلعه رودخان با استفاده از شبکه عصبی LSTM می باشد.

روش بررسی

منطقه مورد مطالعه، رودخانه قلعه رودخان به مساحت ۴۵۴/۲ کیلومتر مربع می باشد که بین طول های جغرافیایی ۴۹ درجه و ۳ دقیقه تا ۴۹ درجه و ۲۵ دقیقه شرقی و عرضهای جغرافیایی ۳۷ تا ۳۷ درجه و ۲۴ دقیقه شمالی واقع شده و از نظر تقسیمات کشوری در استان گیلان و شهرستان های فومن و صومعه سرا قرار می گیرد. رودخانه قلعه رودخان از دو شاخه (حیدرآلات) و (نظر آلات) تشکیل شده است. این شاخه از ارتفاعات ۲۶۵۲ متر جریان یافته و با عبور از جنگل برنا و الحاق شاخه های کوچک دیگری به آن، در جهت جنوب به شمال به مسیر خود ادامه می دهد و در نزدیکی فومن دو شاخه اصلی بهم متصل شده و رودخانه پیش رودبار یا شاخزر را به وجود می آورند. طول هر یک از دو شاخه اصلی تا محل الحاق به یکدیگر، بیش از ۳۰ کیلومتر بوده و از این محل تا تالاب نیز حدود ۲۵ کیلومتر می باشد. این رودخانه دائمی و پر آب و از مهمترین رودخانه های حوزه آبریز تالاب انزلی محسوب می گردد (۲۲). اطلاعات مورد استفاده در این پژوهش مربوط به دبی رسوب رودخانه قلعه رودخان برای دوره آماری ۱۳۸۱ تا ۱۳۹۵ از شرکت آب منطقه ای استان گیلان اخذ گردیده است. در جدول ۱، خصوصیات رودخانه شامل میانگین دبی و رسوب سال های ۸۰ تا ۹۵ گزارش شده است. بیشترین مقدار دبی طی سالهای مورد مطالعه مربوط به سال ۹۵ با ۵۴/۷۳ مترمکعب و کمترین مقدار دبی برای سال

استفاده از شبکه های عصبی مصنوعی پرداختند و به این نتیجه رسیدند که مدل های ارائه شده بر پایه شبکه های عصبی با مقادیر رسوب کل مشاهده شده، هم خوانی بیشتری دارند و به ویژه شبکه MLP میتواند مقدار رسوب را در نقاط پیک به خوبی برآورد نماید (۱۵). اکبری و همکاران به برآورد رسوبات معلق سد ایلام با استفاده از مدل درختان تصمیم گیری پرداختند. محققان به این نتیجه رسیدند که این مدل در مقایسه با روش مرسوم منحنی سنج رسوب، تطابق بسیار بیشتری با مقادیر اندازه گیری شده داشته است (۱۶). دستورانی و همکاران در مطالعه ای اقدام به برآورد رسوبات معلق با استفاده از شبکه عصبی مصنوعی در حوزه ابخیز جاشمیان نمودند. نتایج نشان داد که شبکه عصبی مصنوعی، نتایج قابل قبولی را جهت شبیه سازی بار معلق در ایستگاه حیدر آباد ارائه می کند (۱۷). طلوعی و همکاران به تخمین زمانی و مکانی بار معلق رودخانه آجی چای با استفاده از زمین آمار و شبکه عصبی مصنوعی پرداختند. نتایج نشان داد که، در تخمین رسوب معلق با استفاده از شبکه عصبی، نشان دهنده مناسب بودن شبکه عصبی و توانایی افزایش کارایی مدل با استفاده از اطلاعات کلیدی است (۱۸). کیسی و شیری به تخمین میزان رسوب در رودخانه شیوان در تایوان پرداختند. در این پژوهش مدل شبکه عصبی مصنوعی و روش منحنی سنج رسوب مورد استفاده قرار گرفت. نتایج نشان داد که مدل شبکه عصبی MLP توانست تخمین مناسبی از میزان رسوب با مقدار R برابر ۰/۹۷ ارائه دهد (۱۹). حسین و خان ادر سال ۲۰۲۰ به در پژوهشی جریان ماهیانه رودخانه هونزا واقع در پاکستان را بر اساس روش های یادگیری ماشینی با ارائه روش های RF، SVR و MLP مدل سازی کردند. نتایج پژوهش آنها نشان داد که رویکرد RF بهترین دقت در مدل سازی جریان را داشته است (۲۰). دوآو همکاران در سال ۲۰۲۰ به ارزیابی روش های موجود برای برآورد دبی رودخانه شایینگ چین لبر اساس روش های شبکه عصبی مصنوعی و رگرسیون پرداختند. نتایج پژوهش

- 5- Multi-Layer Perceptron (MLP)
- 6- Dou et al, 2020
- 7- Shaying River, China
- 8- Long Short-Term Memory (LSTM)

- 1- Hussain & Khan (2020)
- 2- Hunza River, Pakistan
- 3- Random Forest (RF)
- 4- Support Vector Regression (SVR)

۸۹ با ۲/۴۹ مترمکعب دبی میباشد. همچنین بیشترین مقدار رسوب برای سال ۸۲ یا ۵۲۴/۶۳ تن بر مترمکعب میباشد که مقادیر رسوب روندی کاهشی داشته است.



شکل ۱- موقعیت منطقه مورد مطالعه

Figure 1. Location of the study area

جدول ۱- خصوصیات کمی دبی رسوب رودخانه قلعه رودخان

Table 1. Quantitative characteristics of sediment discharge of Qaleh Rudkhan river

سال	دبی (m^3/s)	رسوب (ton/m^3)
۸۱	۳/۲۲	۴/۴۷
۸۲	۵/۲۹	۵۲۴/۶۳
۸۳	۷/۲۸	۱۶/۴۵
۸۴	۱/۹۳	۲/۹۵
۸۵	۲/۳	۵/۰۳
۸۶	۳/۸۴	۱۳۸/۱۵
۸۷	۴/۷۲	۳۸/۹۷
۸۸	۱۴/۵۴	۶/۶۵
۸۹	۲/۴۹	۵/۵۷
۹۰	۵/۹۳	۳۴۷/۹۷
۹۱	۶/۲۳	۲۴/۰۷
۹۲	۳/۳۹	۵/۷۱
۹۳	۲/۸۱	۲/۸۱
۹۴	۶/۵	۱۱۰/۶۵
۹۵	۵۴/۷۳	۲۰/۲۸


داده های مورد استفاده

به ایجاد یک شبکه مطمئن تر خواهد گردید. پارامترهای در نظر گرفته شده، مقادیر دبی و رسوب رودخانه که برای مدلسازی پیش بینی رسوب قلعه رودخان مورد استفاده قرار می گیرند. این متغیرها به دودسته از متغیرهای تاثیرگذار دسته بندی می شوند که عبارتند از میزان دبی و رسوب.

معرفی شبکه LSTM

معماری شبکه مورد استفاده در پژوهش در فلوجارت در شکل ۲ نشان داده شده است.

در این تحقیق از آمار دبی - رسوب ثبت شده مربوط به دوره آماری سال ۱۳۸۱ تا ۱۳۹۵ استفاده شده است. این آمار شامل دبی لحظه ای روزانه به مترمکعب بر ثانیه و رسوب روزانه لحظه ای به تن در روز است که هم زمان اندازه گیری شده اند. متغیرهای تحت بررسی در مدلسازی پیش بینی لازمه ایجاد یک شبکه عصبی مصنوعی، وجود یک سری داده، به منظور مدلسازی در این شبکه می باشد. از آنجاکه این داده ها مبنای کار شبکه مورد مطالعه است، لذا وجود داده های با دقت هرچه بیشتر منجر




شکل ۲- معماری شبکه مورد استفاده در پژوهش حاضر

Figure 2. Network architecture used in the present study

LSTM در شکل ۳ نشان داده شده است. نقاط آبی و زرد به ترتیب با مقادیر پاسخ کم و زیاد مطابقت دارند.

تجسم از ویژگی های کانوولوشنال (حالت ساختار پیچشی به منظور کمینه کردن پیش پردازش ها از گونه ای از لایه های شبکه استفاده میشود)، استخراج شده از لایه های مختلف شبکه




شکل ۳- تجسم از ویژگی های کانوولوشنال استخراج شده از لایه های مختلف شبکه LSTM

Figure 3. Visualization of convolutional features extracted from different layers of the LSTM network

مدلسازی با شبکه LSTM

حفظ وضعیت دراز مدت و انتقال اطلاعات حافظه از موقعیت اولیه دنباله به انتهای دنباله اقدام کند. ساختار خارجی LSTM با ساختار خارجی سایر شبکه‌های عصبی مشترک است اما این شبکه دارای ساختار داخلی متفاوت است.

یکی از مسائلی که در روند انتقال اطلاعات در شبکه LSTM با آن روبرو هستیم وجود لایه‌های مخفی به علت خاصیت گرادیانی است. LSTM بر اساس اصل حاکم بر خود برای اضافه کردن یک حالت که واحد حافظه C است، می تواند به طور منطقی



شکل ۴- ساختار داخلی و خارجی شبکه LSTM استفاده شده در این پژوهش

Figure 4. Internal and external structure of LSTM network used in this research

پارامترهای X و Y متغیرهای ورودی در بازه زمانی ۱ تا Tbos را مشخص می کند. توالی‌های کد شده برای هر دبی i که در اثر ورود پارامترهای ورودی به دست می‌آیند در معادله ۲ گزارش شده‌اند.

$$h_i = \{ h_1, \dots, h_T \} \quad (2)$$

در نتیجه داریم:

$$y_i = x_i \cdot h_i \quad (3)$$

تابعی که در اثر ورود پارامترها در دروازه فراموشی به دست می‌آیند در معادله ۴ نشان داده شده است.

$$f_t = \sigma (w_f^T * h_{t-1} + U_f^T * x_t + \alpha_f) \quad (4)$$

σ نشان دهنده تابع فعال سازی است، که معمولا در اینجا سیگموئید است. w_f^T ماتریس وزن دروازه فراموش کردن را نشان می دهد، U_f^T ماتریس وزن بین لایه ورودی و لایه پنهان دروازه فراموش شده است، α_f تکرارهای دروازه فراموش شده را نشان می دهد، در حالی که زیر خط f اولین حرف فراموش شده است،

C واحد حافظه‌ای است که برای ذخیره اطلاعات طولانی مدت استفاده می‌شود و LSTM چهار سوئیچ را برای کنترل موثر این واحد حافظه C طراحی کرده است.

الف) دروازه فراموشی^۱

قدم اول در LSTM تصمیم در مورد اطلاعاتی است که می‌خواهیم آن‌ها را از سلول حالت پاک کنیم. این تصمیم توسط یک لایه سیگموئید به نام دروازه فراموشی انجام می‌شود. این دروازه با توجه به مقادیر h_{t-1} و x_t ، برای هر عدد، مقدار صفر یا یک را در سلول حالت C_{t-1} به خروجی می‌برد. مقدار یک یعنی به صورت کامل مقدار حال حاضر سلول حالت (C_{t-1}) را به C_t ببر و مقدار صفر یعنی به صورت کامل اطلاعات سلول حالت کنونی (C_{t-1}) را پاک کن و هیچ مقداری از آن را به C_t نبر. در یک چهارچوب مشخص سیستم یک توالی ورودی X را دریافت می‌کند و از آن یک توالی کد شده h تولید می‌کند. توالی ورودی برای دبی i در معادله ۱ داده شده است.

$$x_i = \{ x_1, y_1, \dots, x_{Tbos}, y_{Tbos} \} \quad (1)$$

1- Forgotten Gate

$$\alpha_{tj} = \frac{\exp(e_{tj})}{\sum_{k=1}^T \exp(e_{tk})} \quad (7)$$

$$e_{tj} = \alpha (s_{t-1}, h_j) \quad (8)$$

مدل ارائه شده در دروازه فراموشی یک شبکه عصبی رو به جلو برای آموزش مشترک با سایر اجزای سیستم است.

ب) دروازه ورودی^۱

قدم بعدی این است که تصمیم بگیریم چه اطلاعات جدیدی را می‌خواهیم در سلول حالت ذخیره کنیم. این تصمیم دو بخشی است. ابتدا یک لایه سیگموئید به نام دروازه ورودی (input gate) داریم که تصمیم می‌گیرد چه مقادیری به‌روز خواهند شد. مرحله بعدی یک لایه تانژانت هایپربولیک است که برداری از مقادیر به نام C^h می‌سازد که می‌توان آن‌ها را به سلول حالت اضافه کرد. در مرحله بعد، ما این دو مرحله را با هم ترکیب می‌کنیم تا مقدار سلول حالت را به‌روز کنیم. در شکل ۵ نحوه پردازش داده‌های داده شده توسط سیستم نشان داده شده است.


به ترتیب برای افزایش خوانایی تنها مقدار ft خروجی نزدیک به ۱ است، اطلاعات بیشتر حفظ می‌شود و برعکس، نزدیک به ۰، رزرو کمتر شده است. بردار محتوا وابسته به زمان را می‌توان به صورت زیر نشان داد. برای یک مورد کلی، s_{t-1} حالت پنهان رمزگذار در زمان t_1 و خروجی رمزگذار در همان زمان برابر با y_t است. C_t یک بردار زمینه در زمان t و تابع رمزگشایی است. خروجی رمزگشایی در زمان t توسط معادله ۵ داده می‌شود.

$$y_t = f(s_{t-1}, y_{t-1}, C_t) \quad (5)$$

با استفاده از بردارهای متمایز زمینه ما قادر به تمرکز مختلف درجه توجه به قسمت‌های مختلف توالی ورودی، هنگام پیش بینی توالی خروجی. محدوده بردار نرم توجه C_t^S را می‌توان به عنوان یک مجموع وزنی از حالت‌های پنهان محاسبه کرد.

$$C_t^S = \sum_{j=1}^{T_{obs}} \alpha_{tj} h_j \quad (6)$$

پارامتر α_{tj} که وزن متغیرهای ورودی را نشان می‌دهد از رابطه زیر می‌توان به دست آورد.



شکل ۵- دروازه ورودی داده‌ها برای پردازش اطلاعات

Figure 5. Data input gateway for information processing

$$C^h = \sum_{n=1}^N \sum_{j=1}^{Tobs} W_{(n,j)} \hat{h}_{(n,j)} \quad (12)$$

سپس یک لایه ورودی ساده برای ترکیب اطلاعات از تمامی پیش بینی‌ها استفاده می‌کنیم که اهمیت دبی و رسوب روی بردار محیط ترکیبی را نشان دهد. همچنین تابع فعال سازی توسط \tanh جایگزین شده است، که خروجی را به حالت نرمال بین -۱ و ۱ منتقل می‌کند که در رابطه ۱۳ نشان داده شده است.

$$C_t = f_t * c_{t-1} + c_t * i_t \quad (13)$$

ترکیبی از دروازه ورودی و دروازه منسجم شده یک واحد حافظه جدید را تولید می‌کند. دروازه فراموش شده، می‌تواند کنترل کند که اطلاعات قبلی ذخیره شده است. با توجه به دروازه ورودی، مجدداً از حافظه محتوای در حال حاضر بی اهمیت جلوگیری می‌کند.

(ت) دروازه خروجی^۲

در مرحله نهایی باید تصمیم گرفته شود که چه اطلاعاتی را به خروجی ببریم. این خروجی با در نظر گرفتن مقدار سلول حالت خواهد بود، ولی از فیلتر مشخصی عبور خواهد کرد. در ابتدا، یک لایه سیگموئید داریم که تصمیم می‌گیرد چه بخشی از سلول حالت قرار است به خروجی برده شود. سپس مقدار سلول حالت (پس از به‌روز شدن در مراحل قبلی) را به یک لایه تانژانت هایپر بولیک (تا مقادیر بین -۱ و +۱ باشند) می‌دهیم و مقدار آن را در خروجی لایه سیگموئید قبلی ضرب می‌کنیم تا تنها بخش‌هایی که مد نظرمان است به خروجی برود. بخش اول روش انجام مرحله نهایی که شامل به‌روز رسانی وضعیت داخلی حافظه می‌باشد در شکل ۶ نشان داده شده است.

مدل ارائه شده در مرحله دوم ورود داده‌ها در رابطه ۹ ارائه شده است.

$$i_t = \sigma (W_i^T * h_{t-1} + U_i^T * x_t + b_i) \quad (9)$$

این رابطه مانند رابطه به دست آمده در مرحله اول است با این تفاوت که این رابطه برای فعال کردن تابع σ استفاده می‌شود. وزن مدل طراحی شده است تا مفهوم پیش بینی و برآورد میزان رسوب رودخانه قلعه رودخان را در مدل پیش بینی کند. دبی و رسوب رودخانه دارای وزن بالایی است و وزن بالاتر آن، موجب می‌شود که رسوب تاثیر بالایی بر رودخانه را داشته باشد که این وزن از مدل رابطه ۱۰ به دست می‌آید.

$$W_{(n,j)} = \frac{1}{dist(n,j)} \quad (10)$$

در این رابطه $dist(n,j)$ نزدیکی هر یک از متغیرهای مورد بررسی با میزان رسوب رودخانه قلعه رودخان است و $W_{(n,j)}$ وزن هر یک از متغیرهای تاثیرگذار بر میزان رسوب رودخانه قلعه رودخان را ارائه می‌کند. این مدل را می‌توان برای تولید بردار زمینه برای مدل توجه سخت افزاری توسعه داد.

(پ) داده‌های منسجم شده در دروازه^۱

حال زمان آن فرا رسیده است که سلول حالت قدیمی یعنی C_{t-1} را سلول حالت جدید یعنی C_t به‌روز کنیم. در مراحل قبلی تصمیم گرفته شد که چه کنیم و در حال حاضر تنها لازم است تصمیماتی را که گرفته شد عملی کنیم. ما مقدار قبلی سلول حالت را در f_t ضرب می‌کنیم که یعنی فراموش کردن اطلاعاتی که پیش‌تر تصمیم گرفتیم آن‌ها را فراموش کنیم. سپس $i_t * C_t$ را به آن اضافه می‌کنیم. در حال حاضر مقادیر جدید سلول حالت با توجه به تصمیماتی که پیش‌تر گرفته شده بود بدست آمده‌اند. مدل به دست آمده در این مرحله در رابطه ۱۱ نشان داده شده است.

$$C_t^{??} = \tanh (W_c^T * h_{t-1} + U_c^T * x_t + C^h) \quad (11)$$

برای به دست آوردن پارامتر C^h که نقش نزدیک کننده بین دبی و عمل را در پژوهش دارد از رابطه زیر استفاده می‌کنیم.

میزان رسوب رودخانه قلعه رودخان اشاره می‌شود. پیش بینی نهایی میزان رسوب اکنون می‌تواند از رابطه ۱۵ محاسبه شود.

$$y_t = LSTM(S_{t-1}, y_{t-1}, C_t^*) \quad (15)$$

۶- تجزیه و تحلیل نتایج

بررسی نتایج کمی

دقت پیش بینی های انجام شده با سه معیار خطا بررسی شد. برای این کار میزان رسوب و دبی در مسیر i برای زمان t^th که با متغیر $X_{(i,t)}^{pred}$ و متغیر $X_{(i,t)}^{obs}$ برای پارامترهای مربوط به رسوب پیش بینی شده می باشد. سه معیار خطای مورد بررسی عبارتند از:

۱- خطای متوسط پیش بینی (AFE)

مدل مربوط به این خطا در رابطه ۱۶ نشان داده شده است.

$$ADFE = \frac{\sum_{i=1}^n \sum_{t=T_{obs}+1}^{T_{pred}} (X_{i,t}^{pred} - X_{i,t}^{obs})^2}{n(T_{pred} - (T_{obs} + 1))} \quad (16)$$

۲- خطای نهایی پیش بینی (FFE)

مدل مربوط به این خطا در رابطه ۱۷ نشان داده شده است.



$$FFDE = \frac{\sum_{i=1}^n \sqrt{(X_{i,T_{pred}}^{pred} - X_{i,T_{pred}}^{obs})^2}}{n} \quad (17)$$

۳- خطای غیرخطی متوسط پیش بینی (n-AFE)

مدل مربوط به این خطا در رابطه ۱۸ نشان داده شده است.

$$n-AFE = \frac{\sum_{i=1}^n \sum_{t=T_{obs}+1}^{T_{pred}} I(X_{i,t}^{pred}) (X_{i,t}^{pred} - X_{i,t}^{obs})^2}{\sum_{i=1}^n \sum_{t=T_{obs}+1}^{T_{pred}} I(X_{i,t}^{pred})} \quad (18)$$

شاخص های آماری برای مدلسازی پارامترهای خروجی از مدل برای هر سه معیار کمی در جدول ۱ نشان داده شده است.



شکل ۶- به روز رسانی وضعیت داخلی حافظه مدل

Figure 6. Update the internal state of the model memory

در شکل ۷ نشان داده شده است که پس از اتمام به روز رسانی وضعیت داخلی حافظه، خروجی نهایی مدل ارائه می شود. مدل نهایی در رابطه ۱۴ ارائه شده است.



شکل ۷- تصویر خروجی نهایی مدل

Figure 7. The final output image of the model

$$O_t = \sigma(W_o^T * h_{t-1} + U_o^T * x_t + C_t^*) \quad (14)$$

$$C_t^* = \tanh(Wc \{C_t^S ; C^h\})$$

$$h_t = O_t * \tanh(C_t)$$


تابع فعالسازی به دست آمده بر حسب تابع سیگموئید می‌باشد. تابع h_t نشان دهنده جریان خروجی و C_t حافظه بروز شده می باشد. همچنین WC به عنوان مجموعه‌ای از وزن برای پیوند میان

جدول ۲- شاخص های آماری برای مدلسازی پارامترهای خروجی از مدل برای هر سه معیار کمی به دست آمده

Table 1. Statistical indicators for modeling output parameters of the model for all three quantitative criteria

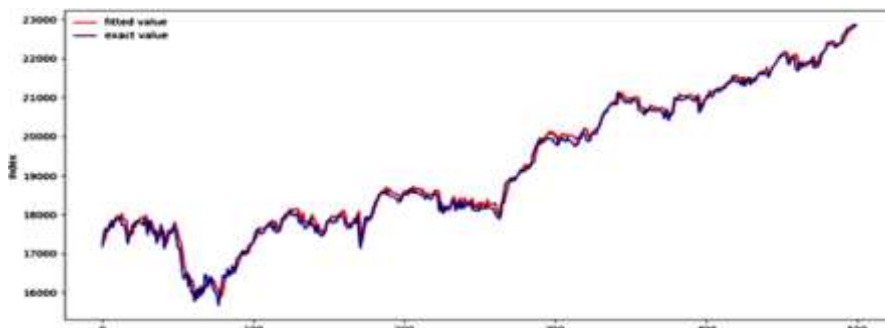
معیار	شاخص همبستگی LSTM	RMSE
AFE	۱/۵۵۰	۰/۸۹۰۵
FFE	۳/۸۱۵	۰/۹۴۳۲
n-AFE	۲/۶۲۵	۰/۹۰۱۱۴

در شکل های ۸، ۹ و ۱۰ به ترتیب شاخص های همبستگی مدل LSTM با معیارهای مربوطه نشان داده شده است.



شکل ۸- شاخص های همبستگی مدل LSTM با معیار AFE

Figure 8. Correlation indices of LSTM model with AFE criterion



شکل ۹- شاخص های همبستگی مدل LSTM با معیار FFE

Figure 9. Correlation indices of LSTM model with FFE criterion



شکل ۱۰- شاخص های همبستگی مدل LSTM با معیار n-AFE

Figure 10. Correlation indices of LSTM model with n-AFE criterion

- indices. *Expert Systems with Applications*, 2017; 73: 125-144.
- Batny N, Golmaee S.H, Zia Tabar Ahmadi M.Kh. 2015. The study of sediment transport and the changes of river bed using Gstars3 Mathematical model (Case study: Gaveh Roud River). *J. of Water and Soil Conservation*, Vol. 22(1), (in Persian).
 - Hezbavi, Z., Sadeghi, S.H.R. And Younesi H.A. 2012. Analysis and evaluation of the effectiveness of runoff components from the application of different levels of polyacrylamide. *Journal of Soil and Water Resources Protection*, 2 (2): 1-14. (In Persian)
 - Behzadfar, M., Sadeghi, S.H.R., Khanjani, M.J. And Hezbavi, Z. 1391. Influence of runoff production and sediment of soils under freezing-thaw cycle under rain simulation conditions. *Journal of Soil and Water Resources Protection*, 2 (1): 13-23. (In Persian)
 - Karami, A., Homaei, M., Neyshabouri, M.R., Afzalnia, S. and Basirat, S. 2012. Large scale evaluation of single storm and short/long term erosivity index models. *Turkish Journal of Agriculture and Forestry*, 36: 207-216.
 - Dehghani, A.A., Zanganeh, M.E., Mosaed, A., and Kohestani N. 2009. Comparison of Suspended Sediment Estimation by Artificial Neural Network and Sediment Rating Curve Methods (Case Study: Doogh River in Golestan Province). *J. Agric. Sci. Natur. Resour.*, Vol. 16 (Special issue 1-a), 2009. (In Persian)
 - Ebrahimi Mohammadi, SH., Sadeghi, S.H., and Chapi, K. 2012. Analysis of runoff, suspended sediment and nutrient yield from different tributaries to Zarivar lake in event and base flows. *Artery of water and soil protection*,

نتیجه گیری

استفاده از شبکه های یادگیری عمیق به دلیل دارا بودن حجم بالایی از دیتا دارای دقت و کارایی بیشتری نسبت به مدل های دیگر شبکه عصبی مصنوعی می باشد. در این پژوهش با استفاده از شبکه عصبی مصنوعی LSTM برای مدل سازی پیش بینی میزان رسوب رودخانه در رودخانه قلعه رودخان استفاده شد. به این منظور از داده های دبی رسوب ماهیانه ۱۴ ساله آماری استفاده شده که حدود ۲۰ درصد از داده ها به عنوان داده های آزمون و ۸۰ درصد از داده ها به عنوان آموزش به کار برده شده است. نکته مهم اینست که پیش بینی یک ماه دبی رسوب رودخانه قلعه رودخان برای مدیریت منابع آب استان گیلان از اهمیت بسزایی برخوردار است. به این دلیل که بیشتر اراضی کشاورزی اطراف رودخانه از جریان این رودخانه استفاده می کنند. در جدول ۲ با توجه به میزان RMSE معیارهای ارزیابی $AFE = 0/8905$ با شاخص همبستگی $1/550$ ، $0/9432$ و $n-AFE$ با شاخص همبستگی $3/815$ و معیار $FFE = 0/90114$ میزان خطا و شاخص همبستگی $2/625$ ، معیار FFE بیشترین همبستگی را میان خروجی مدل و داده های اندازه گیری شده رسوب را داراست. در کل شبکه عصبی مصنوعی LSTM عملکرد خوبی برای پیش بینی دبی رسوب رودخانه قلعه رودخان دارد که میتواند به این دلیل باشد که این روش به صورت خودکار بوده و دقت زیادی در مدل سازی دارد. نتایج این پژوهش با نتایج احمدی و همکاران (۲۳) مبنی بر بهتر بودن مدل انطباق دارد. همچنین میزان سنجش خطا در مدل LSTM استفاده شده نسبت به مقادیر سنجش شده $rmse$ در مدل شبکه عصبی که در پژوهش رضوی زاده و همکاران (۲۴) انجام شده است دارای مقادیر تقریباً یکسانی است که نشان از کارایی و دقت بالای مدل است.

References

- Oliveira N, Cortez P, Areal N. The impact of microblogging data for stock market prediction: Using Twitter to predict returns, volatility, trading volume and survey sentiment

14. Tabatabaei, M., K. Solaimani, M. Habibnejad Roshan and A. Kavian. 2014. Estimation of Daily Suspended Sediment Concentration Using Artificial Neural Networks and Data Clustering by Self Organizing Map (Case Study: Sierra Hydrometry Station- Karaj Dam Watershed). *Journal of Watershed Management*, 5: 98-116. (In Persian)
15. Falamaki, A., M. Eskandari, A. Baghlani and A. Ahmadi. 2013. Modeling Total Sediment Load in Rivers Using Artificial Neural Networks. *Journal of Water and Soil Conservation*, 2: 13-26. (In Persian)
16. Akbari, Z. and A. Talebi. 2010. Estimation of Suspended Sediment Using Regression Decision Trees Method (Case Study Ilam Dam Basin Science and Technology of Agriculture and Natural Resources Journal, 17: 109-121. (In Persian)
17. [17]. Dastorani, M., Kh. Azimi Fashi, A. Talebi and M. Ekhtesasi. 2012. Suspended Sediment Estimation Using Artificial Neural Network (Case Study: Jamyshan watershed in Kermanshah). *Journal of Watershed Management*, 3: 61-74. (In Persian)
18. Toloie, S., D. Hossenzadeh, M. Ghorbani, A. Fakhrefard and F. salmasi. 2011. Estimate Temporal and Spatial Suspended load river AJICHAJ with Use from Geostatistics and Artificial neural Network. *Issue Science Water and Soil*, 21: 12-25. (In Persian)
19. Kisi, O. and Shiri, J. 2012. River Suspended Sediment Estimation by Climate Variables Implication: Comparative Study among Soft second year, first issue, autumn 1. (In Persian)
8. Vali, A., Ramesht, M.H., Seif, A., and Ghazavi, R. 2011. Comparison of the efficiency of artificial neural network and regression models for prediction Sediment load during a case study of Samandgan watershed. *Journal of Geography and Environmental Planning*, Volume 22, Number 44, Issue 4, Winter 2011. (In Persian)
9. Eshghi, P., Farzadmehr, J., Dastoran, M.T., and Arabasadi, Z. 2016. The Effectiveness of Intelligent Models in Estimating the River Suspended Sediments (Case Study: Babaaman Basin, Northern Khorasan). *Journal of Watershed Management Research Vol. 7, No. 14, Autumn and Winter 2016*. (In Persian)
10. Kakaei Lafdani, E., Moghaddam Nia, A. and Ahmadi, A. 2013. Daily suspended sediment load prediction using artificial neural networks and support vector machines. *Hydrology*, 478: 50-62. (In Persian)
11. Khanchoul, K., Altschul, R., and Assassi, F. 2010. Estimating suspended sediment yield , sedimentation controls and impacts in the Mellah Catchment of Northern Algeria. *Arab. J. Geosci.* 2: 3. 257-271.
12. Platt, J. 2000. Fast Training Support Vector Machine Using Sequential Minimal Optimization. http://www.research.microsoft.com/_jplatt. 41-65.
13. Yosefi, M., A. Talebi and R. Poorshariaty. 2014. Application of Artificial Intelligence in Water and Soil Sciences. Yazd University publication, Yazd, Iran, 516 pp. (In Persian)

- Conference on Civil Engineering, Architecture and Urban Planning in the Third Millennium. Tehran - July 2015. (In Persian)
23. Ahmadi P, Arefee H, Kardan N. 2020. Prediction of average monthly discharge of Karun river using GRU-LSTM combined method. Journal of Echo Hydrology, Volume 7. Issue 3. Fall 1399. Page 633-619.
24. Razavizadeh S, Kaviani A.A, Vafakhah M. 2014, Estimation of suspended sediment discharge flow using the best network structure Artificial neural network in Taleghan watershed Journal of Agricultural Science and Technology and Natural Resources, Soil and Water Sciences / Year 18 / Issue Sixty-Eight / Summer 1 (In Persian)
- Computing Techniques. Computer and Geosciences, 43: 73-82.
20. 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.
21. 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.
22. Amiri, E., Naderi Dyzgahi, M.f., and Baygan, A. 2015. Investigation of discharge changes and water quality of Rudkhan Castle. National Association of Architects of Iran. International