



## مدیریت آب و آبیاری

دوره ۱۱ ■ شماره ۴ ■ زمستان ۱۴۰۰

صفحه‌های ۷۵۳-۷۶۷

DOI: 10.22059/jwim.2022.328451.909

مقاله پژوهشی:

### استفاده از رویکرد یادگیری عمیق به منظور تخمین سیل براساس الگوی بارش منطقه

حسن احمدی<sup>۱\*</sup>، حمیدرضا رحیمی<sup>۲</sup>

۱. استادیار، دانشگاه آزاد اسلامی، واحد رودهن، تهران، ایران.

۲. دانشجوی دکتری، دانشگاه آزاد اسلامی، واحد رودهن، تهران، ایران.

تاریخ پذیرش مقاله: ۱۴۰۰/۱۰/۱۶

تاریخ دریافت مقاله: ۱۴۰۰/۰۵/۱۶

#### چکیده

در سال‌های اخیر به دلیل بروز خشکسالی در کشور، مسأله مدیریت منابع آب موجود از اهمیت فوق‌العاده‌ای برخوردار است و این توجه هرچه بیشتر به مدیریت مخازن و پیش‌بینی میزان حجم آب به‌منظور ارایه سیاست‌های مناسب بهره‌برداری می‌باشد. پیش‌بینی مناسب جریان‌های آب و میزان موجودی‌های مخزن منجر به استفاده از منحنی‌های فرمان برای استفاده بهینه از سدها و سیستم‌های مخزنی می‌شود. این موضوع در کشور ما از اهمیت بالایی برخوردار است. لذا با پیش‌بینی‌های دقیق و انتخاب سیاست‌های مناسب می‌توان تصمیم‌گیری مناسبی در شرایط وقوع جریان‌های سطحی نظیر سیلاب در بستر رودخانه‌ها انجام داد. در این مقاله، با توجه به اهمیت موضوع، از یک مدل مبتنی بر یادگیری عمیق و آزمون تجربی من-کندال جهت تخمین میزان سیلاب در منطقه کن-سولقان استفاده شد. نتایج نشان داد میزان اختلاف پیش‌بینی سیلاب منطقه به تفکیک ماهیانه برای شبکه عصبی کانولوشن (CNN) برابر با ۰/۰۰۶۵۴ و برای روش من-کندال، ۰/۱۹۵۳۲ می‌باشد. هم‌چنین میزان خطاهای MSE، RMSE، MAPE و MPE برای شبکه عصبی به‌ترتیب برابر با ۰/۰۰۱۹، ۰/۰۴۳۹، ۰/۰۲۳۹ و ۰/۰۱۵۹ به‌دست آمد که نشان از دقت بالای این روش در تخمین میزان سیلاب منطقه است.

**کلیدواژه‌ها:** پیش‌بینی، رواناب، سیل، شبکه عصبی، یادگیری عمیق.

### Using a deep learning approach to estimate floods based on area precipitation pattern

Hassan Ahmadi<sup>1\*</sup>, Hamidreza Rahimi<sup>2</sup>

1. Assistant Professor, Islamic Azad University, Roudehen Branch, Tehran, Iran.

2. Ph. D. Candidate, Islamic Azad University, Roudehen Branch, Tehran, Iran.

Received: August, 07, 2021

Accepted: January, 06, 2022

#### Abstract

In recent years, due to drought in the country, the issue of managing existing water resources is extremely important, and this attention is increasingly to the management of reservoirs and forecasting the volume of water in order to provide appropriate exploitation policies. Proper forecasting of water flows and reservoir inventories leads to the use of control curves for the optimal use of dams and reservoir systems. This issue is of great importance in our country, so with accurate forecasts and selection of appropriate policies, a good decision can be made in the event of surface currents such as floods in the riverbed. In this paper, due to the importance of the subject, a model based on deep learning and Mann-Kendall experimental test was used to estimate the flood rate in the Kan-Sulqan area. The results showed that the monthly difference in regional flood prediction for convolution neural network (CNN1) was 0.00654 and for Men Kendall method was 0.19532. Also, the errors of 2MSE, 3RMSE, MAPE4 and MPE5 for the neural network were equal to 0.0019, 0.0439, 0.0239, and 0.0159, respectively, which shows the high accuracy of this method in estimating the flood rate in the region.

**Keywords:** Deep Learning, Flood, Neural Network, Prediction, Runoff.

## مقدمه

سیستم‌های مخزنی می‌شود. این موضوع در کشور ما از اهمیت بالایی برخوردار است. لذا با پیش‌بینی‌های دقیق و انتخاب سیاست‌های مناسب می‌توان تصمیم‌گیری مناسبی در مورد رهاسازی‌های آینده اتخاذ کرد. بر این اساس در این پژوهش تلاش می‌شود تا با بهره‌گیری از داده‌های سری زمانی مربوط به اطلاعات هیدرولوژیکی منطقه کن-سولقان طی ۴۰ سال گذشته از بازه زمانی ۱۳۵۸ تا ۱۳۹۸ به صورت ماهانه، با بهره‌گیری از روش یادگیری عمیق به بررسی میزان سیل و رواناب احتمالی در منطقه طی ۱۰ سال آینده پردازیم. به منظور بررسی صحت مدل، از آزمون‌های عددی رایج نظیر رابطه تجربی من-کندال نیز استفاده خواهیم نمود. به عبارتی، در این مقاله تلاش می‌شود تا به این سؤال پاسخ داده شود که استفاده از روش یادگیری عمیق تا چه میزان می‌تواند سبب بهبود عملکرد پیش‌بینی سیل بر اساس الگوهای بارش در منطقه مورد مطالعه (حوضه آبریز کن-سولقان) شود؟

تاکنون پژوهش‌های مختلفی در حوزه تخمین و پیش‌بینی سیلاب انجام شده است. Ghaffari et al. (2013) به مدل‌سازی فرایند غیرخطی بارش-رواناب با استفاده از مدل خطی ولترا با شبکه عصبی پرسپترون چند لایه پرداختند. Sadeghi & Vafakhah (2016) به بررسی عملکرد شبکه‌های عصبی مصنوعی (ANN) و ماشین بردار پشتیبان (SVM) (رگرسیون نوع ۱ و رگرسیون نوع ۲) به منظور شبیه‌سازی روند بارش باران تحت تأثیر معادل آب برف (SWE) در حوضه آبخیز رودک، استان تهران پرداختند. Rahman et al. (2017) داده‌های ماهانه بارندگی ۶۰ ساله بنگلادش را برای شناسایی روند سیلاب مورد تجزیه و تحلیل قرار دادند در این مقاله آزمون‌های من کندال اصلاح شده، آزمون Rho و آزمون اسپیرمن و برآوردگرهای شیب سنی برای به دست آوردن بلندمدت سالانه، سال‌های خشک و روند بارش ماهانه استفاده شده

پیش‌بینی عبارت است از تصور و طراحی وضعیت مطلوب در آینده و یافتن و پیش‌بینی کردن راه‌ها و وسایلی که رسیدن به آن را فراهم کند. پیش‌بینی‌های بلندمدت هیدرولوژیکی دارای افق زمانی از یک ماه تا یک سال می‌باشند و برای مدیریت منابع آب مانند تخصیص آب برای آبیاری، قراردادهای بلندمدت فروش آب و انرژی برقابی و آمادگی مقابله با خشکسالی به کار می‌روند. افزایش دانش پژوهش‌گران در سال‌های اخیر در مورد ارتباط چرخه عمومی اقیانوس-جو و میزان بارندگی و رواناب در نواحی مختلف دنیا، توجه زیادی را معطوف به انجام پیش‌بینی‌های بلندمدت نموده است. با افزایش افق زمانی پیش‌بینی، عدم قطعیت‌های آن افزایش می‌یابد و این مهم‌ترین چالش در مدل‌سازی برای پیش‌بینی‌های بلندمدت می‌باشد. به علت خطاهای ناشی از طبیعت تصادفی فرایندهای طبیعی و تخمین شرایط اقلیمی در بلندمدت، محدوده‌ای از پیش‌بینی‌های بلندمدت به جای یک پیش‌بینی قطعی ترجیح داده می‌شود. مهم‌ترین مزیت این امر امکان تصمیم‌گیری بر مبنای ریسک برای برنامه‌ریزی و مدیریت منابع آب است (Mosavi et al., 2018).

فرایند بارش-رواناب یک پدیده به‌طور کامل پیچیده و غیرخطی در آب شناختی می‌باشد. مدل‌های مفهومی به‌طور وسیعی برای مدل‌سازی بارش-رواناب به کار برده می‌شوند. با این وجود، این مدل‌ها نیازمند تعداد زیادی اطلاعات جزئی بوده و کاربرد آن‌ها صرفاً محدود به مقیاس منطقه مورد مطالعه می‌باشد (Mu et al., 2020). از این رو عدم تدوین سیاست مناسب بهره‌برداری به‌ویژه در شرایط خشکسالی می‌تواند خسارت‌های زیادی را به بخش‌های مصرف‌کننده آب وارد کند. پیش‌بینی مناسب جریان‌های رواناب و میزان موجودی‌های مخزن منجر به استفاده از منحنی‌های فرمان برای استفاده بهینه از سدها و

عملکرد مدل‌های مستقل GAM، MARS و BRT را بهبود بخشیده‌اند. هم‌چنین مشخص شد که مدل‌های مستقل در مقایسه با الگوریتم RS عملکرد بهتری نسبت به الگوریتم BT دارند. مدل BT-GAM از نظر معیارهای ارزیابی دارای  $AUC=0/98$ ،  $TSS=0/93$ ،  $COR=0/91$  می‌باشد و پس از آن الگوریتم BT-MARS با  $AUC=0/97$ ،  $TSS=0/91$ ،  $COR=0/91$  و در نهایت مدل BT-BRT با  $AUC=0/95$ ،  $TSS=0/79$  و  $COR=0/79$  قرار دارند. Sankaranarayanan *et al.* (2020) در مقاله خود با استفاده از مدل‌های مختلف یادگیری ماشین یعنی شبکه عصبی عمیق، ماشین بردار پشتیبان، K-نزدیک‌ترین همسایه و نایویزین به پیش‌بینی سیل با استفاده از داده‌های هیدرولوژیکی چند شهر هندوستان پرداختند. نتایج این مقاله نشان می‌دهد که دقت پیش‌بینی الگوریتم‌های یادگیری ماشین، ماشین بردار پشتیبان، نایویزین و K-نزدیک‌ترین همسایه به ترتیب برابر با  $91/18$  درصد،  $85/57$  درصد،  $87/01$  درصد و  $85/73$  درصد می‌باشد. El-Haddad *et al.* (2021) با استفاده از الگوریتم‌های XGBoost<sup>۱</sup> و K-نزدیک‌ترین همسایه (KNN)<sup>۲</sup> به بررسی و ارزیابی پیش‌بینی سیلاب در مصر پرداختند. نتایج نشان داد که دقت پیش‌بینی هر یک از الگوریتم‌های XGBoost و KNN به ترتیب برابر با  $90/2$  و  $80/7$  درصد می‌باشد.

با توجه به بررسی‌های انجام‌شده در مقالات فارسی و لاتین مشخص شد که تاکنون در پژوهش به بررسی و مقایسه الگوریتم‌های شبکه عصبی عمیق، شبکه عصبی MLP و استفاده از آزمون آماری من-کندال به‌طور همزمان بر روی داده‌های هواشناسی یک منطقه مورد بررسی قرار نگرفته که این مسأله بیانگر نوآوری این مقاله است. از طرفی، تعیین معماری‌های بهینه و توابع آموزش‌دهنده برای شبکه‌های عصبی عمیق و MLP نیز از مواردی است

است. Kan *et al.* (2018) مدل جدید هیبریدی با نام PBK را برای بهبود شبیه‌سازی بارش-رواناب مبتنی بر رویداد پیشنهاد دادند. این مدل برای حل مسائل سخت از نحوه اجرای شبیه‌سازی باران-رواناب بدون به‌روزرسانی با استفاده از مدل‌های داده کاوی پیشنهاد شده است. Wu *et al.* (2020) در مقاله خود به پیش‌بینی عمق سیل شهری تحت دوره‌های مختلف بازگشت باران با استفاده از روش‌های یادگیری عمیق و انبار داده‌ها پرداختند. Zhu *et al.* (2020) در مقاله خود به پیش‌بینی سیل با استفاده از الگوی باران-جریان در حوضه‌های آبخیز پراکنده داده‌ها پرداختند. Kim & Han (2020) در مقاله خود با استفاده از برقراری لینک بین مدل‌سازی هیدرولیک و رویکرد یادگیری ماشین به پیش‌بینی میزان و واکنش شدید سیلاب پرداختند. در این مقاله با به‌کارگیری مدل تحلیل عددی پویا (DAMBRK) و تکنیک رگرسیون جنگل تصادفی به پیش‌بینی سیلاب در شرایط مختلف سد رودخانه پرداخته شده که دقت حاصل از پیش‌بینی برابر با  $85/83$  درصد به‌دست آمده است. Dodangeh *et al.* (2020) در مقاله خود با استفاده از روش‌های مختلف یادگیری ماشین یکپارچه، به پیش‌بینی حساسیت سیل در منطقه اردبیل پرداختند. این مطالعه مدل‌های جدید پیش‌بینی حساسیت سیل مبتنی بر رویکردهای نمونه‌گیری چند زمانه، نمونه برداری تصادفی (RS) و بوت استرپینگ (BT) ادغام شده با مدل‌های یادگیری ماشین مدل افزودنی عمومی (GAM)، درخت رگرسیون تقویت‌شده (BTR) و چندمتغیره اسپلین رگرسیون تطبیقی (MARS) را به‌کار برده است. برای ارزیابی دقت پیش‌بینی مدل‌های پیشنهادی از معیارهای ناحیه تحت منحنی (AUC)، ویژگی عملکرد گیرنده (ROC)، آمار مهارت واقعی (TSS) و ضریب همبستگی (COR) استفاده شده است. نتایج نشان می‌دهد که الگوریتم‌های نمونه برداری

ابتدا به معرفی شبکه عصبی کانولوشن عمیق پرداخته و سپس روش تجربی "مین-کندال" معرفی می‌شود. در نهایت با معرفی منطقه مورد مطالعه و داده‌های مورد بررسی، مقدمات لازم برای ارائه نتایج را فراهم می‌کنیم. فلوجارت مراحل روش پیشنهادی مقاله به صورت شکل (۱) می‌باشد.

که سبب شده دقت عملکرد این روش‌ها نسبت به مدل‌های معمول، افزایش یابند.

## مواد و روش‌ها

در این بخش به بررسی روش‌های مورد بررسی و داده‌های مورد استفاده در پژوهش پرداخته می‌شود. برای این کار

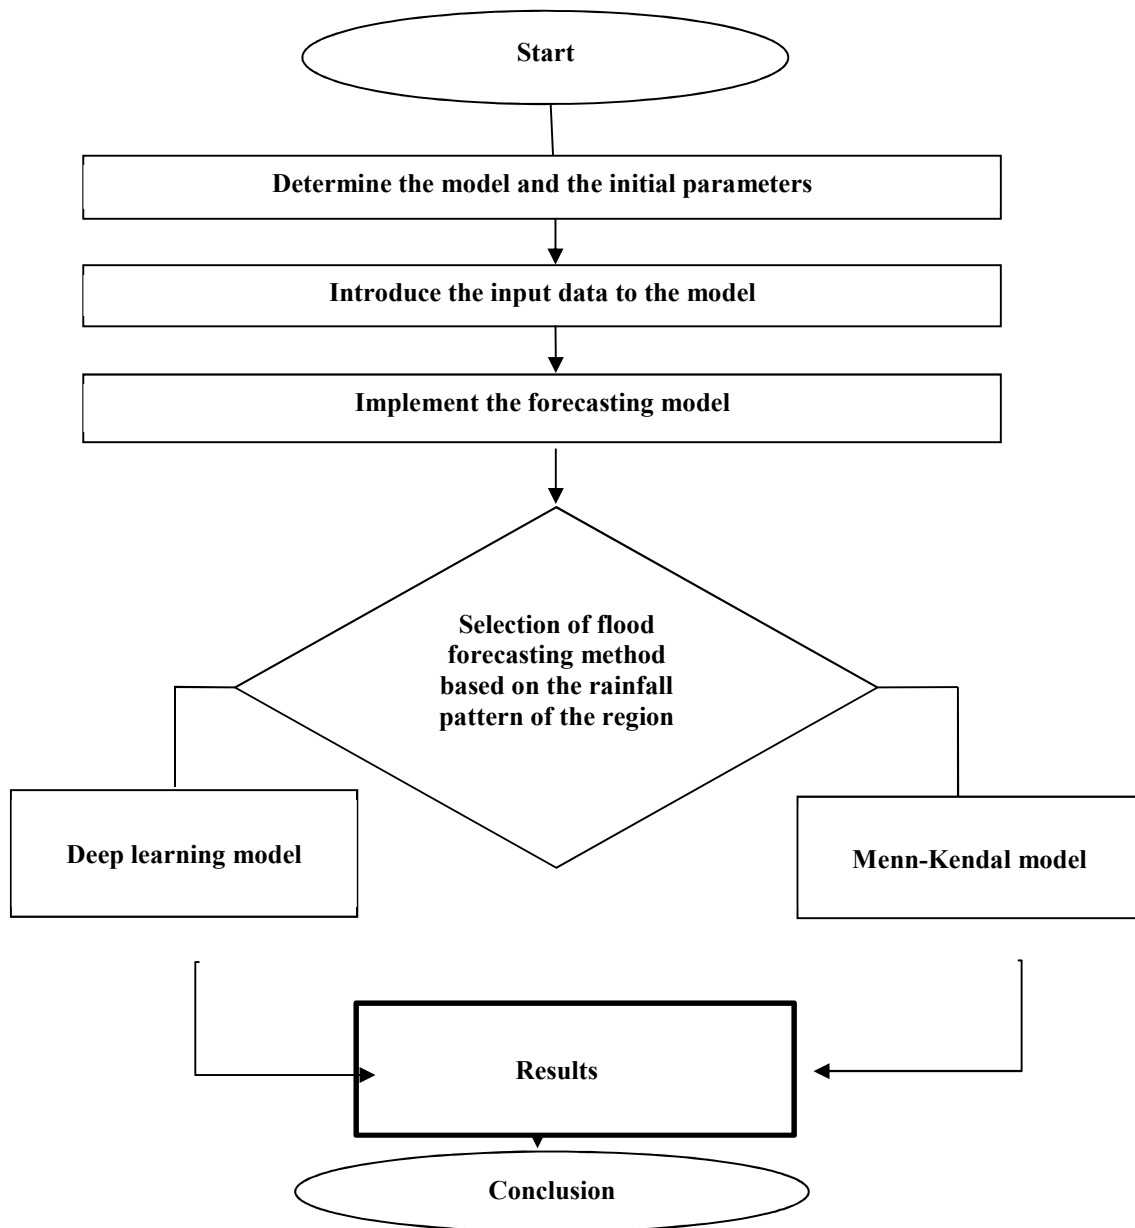


Figure 1. Flowchart of proposed study

### شبکه عصبی کانولوشن عمیق

شبکه‌های عصبی کانولوشن (CNN) یکی از مهم‌ترین روش‌های یادگیری عمیق هستند که در آن‌ها چندین لایه با روشی قدرتمند آموزش می‌بینند. این روش بسیار کارآمد بوده و یکی از رایج‌ترین روش‌ها در کاربردهای مختلف بینایی کامپیوتر است. به‌طور کلی، یک شبکه CNN از سه لایه اصلی تشکیل می‌شود که عبارتند از لایه کانولوشن، لایه Pooling و لایه تماماً متصل. لایه‌های مختلف وظایف مختلفی را انجام می‌دهد در هر شبکه عصبی کانولوشن دو مرحله برای آموزش وجود دارد مرحله تغذیه رو به جلو<sup>۸</sup> و مرحله پس‌انتشار<sup>۹</sup>.

در مرحله اول دیتای ورودی به شبکه تغذیه می‌شود و این عمل چیزی جز ضرب نقطه‌ای بین ورودی و پارامترهای هر نورون و در نهایت اعمال عملیات کانولوشن در هر لایه نیست. سپس خروجی شبکه محاسبه می‌شود. در اینجا به منظور تنظیم پارامترهای شبکه و یا به عبارت دیگر همان آموزش شبکه، از نتیجه خروجی جهت محاسبه میزان خطای شبکه استفاده می‌شود. برای این کار خروجی شبکه را با استفاده از یک تابع خطا<sup>۱۰</sup> با پاسخ صحیح مقایسه کرده و این‌طور میزان خطا محاسبه می‌شود. در مرحله بعدی براساس میزان خطای محاسبه‌شده مرحله پس انتشار آغاز می‌شود. در این مرحله مشتق هر پارامتر با توجه به قاعده زنجیره<sup>۱۱</sup> محاسبه می‌شود و تمامی پارامترها با توجه به تأثیری که بر خطای ایجادشده در شبکه دارند تغییر پیدا می‌کنند. بعد از به‌روزرسانی پارامترها مرحله بعدی، تغذیه رو به جلو شروع می‌شود. بعد از تکرار تعداد مناسبی از این مراحل آموزش شبکه پایان می‌یابد.

نقش هر کدام از لایه‌ها عبارت است از:

**لایه کانولوشن:** این لایه از تعدادی فیلتر تشکیل شده است که با پیچشی شدن<sup>۱۲</sup> در ورودی شبکه، نقشه‌های

ویژگی را می‌سازند. فرایند یادگیری شبکه عصبی عمیق، بروز رسانی مداوم عناصر فیلترها می‌باشد. یعنی وزن‌های شبکه عصبی، همان عناصر این فیلترها می‌باشند. برای شبیه‌سازی این لایه، ابتدا باید تعدادی فیلتر با سایزهای یکسان و مقادیر تصادفی درست کنیم.

**لایه Pooling:** لایه pooling معمولاً بعد از لایه کانولوشن قرار می‌گیرد و از آن برای کاهش اندازه نقشه‌های ویژگی و پارامترهای شبکه می‌توان استفاده کرد. همانند لایه‌های کانولوشنی، لایه‌های pooling به‌خاطر در نظر گرفتن پیکسل‌های همسایه در محاسبات خود، نسبت به تغییر مکان بی‌تغییر هستند. برای پیاده سازی این لایه دو روش رایج وجود دارد:

۱. Pooling Max ۲. Average pooling

آنچه در این لایه اتفاق می‌افتد، کاهش ابعاد است. به این صورت که نقشه‌های ویژگی استخراج‌شده از لایه قبل، به پنجره‌های مجزا از هم  $2 \times 2$  یا غیره تقسیم می‌شوند. بسته به نوع روش انتخاب‌شده، میانگین مقادیر موجود در هر کدام از پنجره‌ها<sup>۱۳</sup> یا بیش‌ترین مقدار<sup>۱۴</sup> موجود در این پنجره محاسبه شده و به‌عنوان مقدار در نقشه ویژگی جدید انتخاب می‌شود. در شکل (۲) نحوه اعمال این دو روش نمایش داده شده است.




Figure 2. Max pooling and Average pooling

عموماً از روش Max pooling استفاده می‌شود، زیرا می‌تواند باعث همگرایی سریع‌تر، تعمیم بهتر (بهبود تعمیم‌دهی) و انتخاب ویژگی‌های نامتغیر بسیار عالی شود. لایه دیگری که در شبکه‌های عصبی عمیق وجود دارد، لایه تماماً متصل است. لایه‌های تماماً متصل feature map‌های دو بُعدی حاصله از مرحله pooling را به feature vector یک بُعدی تبدیل می‌کند. لایه‌های تماماً متصل همانند هم‌تایان خود در شبکه‌های عصبی مصنوعی سنتی عمل می‌کنند و تقریباً ۹۰ درصد پارامترهای یک شبکه CNN را شامل می‌شوند. لایه تماماً متصل به ما اجازه می‌دهد تا نتیجه شبکه را در قالب یک بردار با اندازه مشخص ارائه کنیم. از این بردار می‌توان برای دسته‌بندی استفاده کرد و یا این‌که از آن جهت ادامه پردازش‌های بعدی بهره برد. مشکل بزرگ این نوع لایه‌ها این است که دارای تعداد بسیار زیادی پارامتر می‌باشند که نتیجه این امر هزینه پردازشی بسیار بالایی است که در زمان آموزش باید صرف شود. بنابراین روشی که معمولاً به‌کاربرده می‌شود و نتایج رضایت‌بخشی نیز دارد این است که یا کلاً این لایه‌ها حذف شوند و یا تعداد اتصالات در این لایه‌ها توسط روش‌هایی کاهش یابد.

### آزمون من-کندال

آزمون من-کندال به‌طور گسترده‌ای برای شناسایی روند سری‌های زمانی هیدرولوژیکی استفاده می‌شود، زیرا این یک آزمون غیر پارامتری است و به جهش‌های سری زمانی غیراستاتیالی حساس نیست. آمار (U) به‌صورت زیر ساخته شده است:

$$U = \frac{12K - 3N(N-1)}{\sqrt{2N(N-1)(2N+5)}} \quad (1)$$

$$K = \sum_{i=1}^{N-1} \sum_{j=i+1}^N K_{ij} \quad (2)$$

$$K_{ij} = \begin{cases} 1 & \text{if } X_j > X_i \\ 0 & \text{if } X_j \leq X_i \end{cases} \quad (3)$$

به‌طوری‌که:  $1 \leq i < j \leq N$

که در این روابط:

N برابر طول سری‌های هیدرولوژیکی است؛  $X_i (i = 1, 2, \dots, N)$  متغیر هیدرولوژیکی نام است (به‌عنوان مثال رواناب سالانه)؛  $k_{ij}$  مقدار زوج بین  $X_i$  و  $X_j$  است؛ و K مجموع تمام مقادیر زوج است. هنگامی که N به اندازه کافی بزرگ است ( $N \geq 10$ )، U تقریباً مطابق توزیع نرمال استاندارد است. فرضیه اصلی این است که سری زمانی هیدرولوژیکی هیچ روند مشخصی ندارد. سطح اهمیت  $\alpha$  قبل از آزمون روند انجام می‌گیرد. اگر  $|U| \leq U\alpha/2$ ، فرضیه اصلی عنوان‌شده، پذیرفته شده است. یعنی سری، هیچ روند مشخصی ندارد در غیر این‌صورت، فرضیه اصلی رد می‌شود، که نشان می‌دهد تمایل مشخصی در مجموعه وجود دارد که قابل پیش‌بینی می‌باشد. علاوه بر تجزیه و تحلیل‌های روند کلی، روند محلی نیز در تجزیه و تحلیل روند سری هیدرولوژیکی موردبررسی قرار می‌گیرد. نقاط چرخش و مراحل مختلف روند محلی با شاخص تنوع روند (T)، که به شرح زیر تعریف می‌شود، مشخص می‌شود:

$$T_\tau = |t_{\tau,1} - t_{\tau,2}| \quad (4)$$

که  $\tau (10 < \tau \leq N-10)$  نقطه تقسیم سری است؛  $t_{\tau,1}$  و  $t_{\tau,2}$  به ترتیب نشان‌دهنده شیب‌های خطی زیرمجموعه‌های قبلی و بعدی تقسیم شده توسط  $\tau$  می‌باشند.

در معادله (4) زمانی که  $t_\tau$  حداکثر مقدار را به‌دست می‌آورد، نقطه تقسیم  $\tau$  به‌عنوان یک نقطه تبدیل در نظر گرفته می‌شود که این امر، سری را به دو مرحله متفاوت از روندهای محلی تقسیم می‌کند. علاوه بر این، اگر یک سری زمان‌های هیدرولوژیکی دارای نقاط چرخشی  $l (l = 1, 2, \dots)$  باشد، در نتیجه دارای  $l+1$  مرحله روند مختلف خواهد بود (Liu & Xu, 2016).

### معیارهای ارزیابی

به‌منظور ارزیابی میزان خطا و عملکرد روش‌های سری

استفاده از رویکرد یادگیری عمیق به منظور تخمین سیل براساس الگوی بارش منطقه

سولقان رودی به طول ۳۳ کیلومتر است که از رشته کوه توچال سرچشمه گرفته، از تهران گذشته و در جنوب تهران خشک می‌شود. این رود امروزه پُرآب‌ترین رودی است که از تهران می‌گذرد. قرار است سالانه حدود پنج میلیون مترمکعب از آب این رودخانه را برای دریاچه چیتگر منطقه ۲۲ اختصاص دهند که در سال‌های ۱۳۹۲-۱۳۹۱ به بهره‌برداری می‌رسد. این رودخانه در حل فاصله عرض‌های جغرافیایی ۴۶' ۳۵° تا ۵۸' ۳۵° شمالی و طول امروزه با بده میانگین ۸۸ میلیون مترمکعب بر سال یا حدود ۲۷۰۰ لیتر بر ثانیه (ایستگاه سولقان) پرآب‌ترین رودهای جغرافیایی ۱۰' ۵۱° تا ۲۳' ۵۱° شرقی استان تهران است و حوزه آبخیز (حوزه زهکشی) آن به تنهایی بزرگ‌تر از همه حوزه‌های بیش از ۱۲ رودخانه دیگر این شهر، یعنی وردیج (وردآورد)، حصارک (کن)، فرحزاد (فرهزاد یا پونک یا وسک)، مسیل عبدالآباد، درکه، ولنجک، تجریش (دربند)، گلابدره، حصارک (جماران)، مسیل منظریه، دارآباد، سرخه‌حصار و ... می‌باشد. در شکل (۳) تصویر هوایی مسیر رودخانه کن در حوزه مورد مطالعه را نشان می‌دهد.

زمانی پیشنهادی، از چهار معیار MAE، RMSE، MSE و MAPE که به ترتیب در معادلات (۵) تا (۸) ارائه شده‌اند، استفاده می‌شود.

$$MSE = \frac{1}{n} \sum_{i=1}^n (O_i - Y_i)^2 \quad (5)$$

$$RMSE = \sqrt{MSE} \quad (6)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - Y_i| \quad (7)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|O_i - Y_i|}{|Y_i|} \quad (8)$$

که در معادلات فوق،  $O_i$  بیانگر مقدار سیلاب پیش‌بینی‌شده،  $Y_i$  بیانگر مقدار واقعی سیلاب، و  $n$  تعداد کل داده‌ها می‌باشد.

### منطقه مورد مطالعه

داده‌های مورد مطالعه داده‌های ماهانه و سالانه بارش و دبی براساس مشخصات هیدرومتری ایستگاه‌های مربوط به رودخانه کن به‌عنوان پایگاه هواشناسی منطقه مورد مطالعه (کن-سولقان) برای سال‌های ۱۳۹۹-۱۳۵۰ می‌باشد. این داده‌ها شامل مشخصات بارندگی، تبخیر، دبی، دما و غیره می‌باشد. رودخانه کن یا رودخانه سولقان یا رود کن یا رود

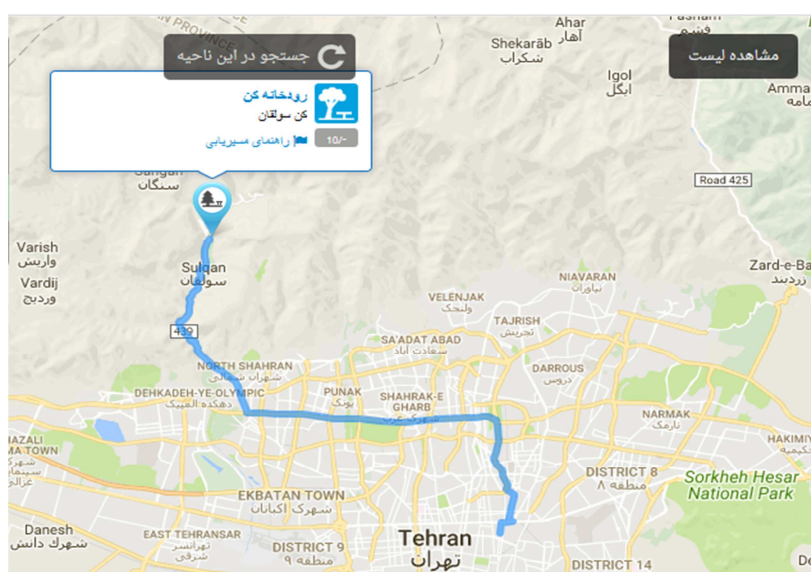


Figure 3. Aerial map of the Cannes River (google earth)

## مدیریت آب و آبیاری

دوره ۱۱ ■ شماره ۴ ■ زمستان ۱۴۰۰

کردیم، می‌توانیم داده‌ها را به راحتی در متلب بارگذاری کنیم. نکته قابل توجه در این بخش این است که ورودی تمام مدل‌ها که در مرحله پیش‌پردازش نرمال‌سازی می‌شوند، همان داده‌های سری زمانی جمع‌آوری شده از منطقه کن-سولقان می‌باشد. هم‌چنین در رابطه با اهمیت نرمال‌سازی در این مرحله می‌توان گفت که چون مقیاس داده‌ها باهم متفاوت است، بایستی آن‌ها را به فرم استاندارد تبدیل کنیم. فرم استاندارد به این صورت است که همه داده‌ها را با استفاده از فرمول زیر بین بازه  $d_1$  تا  $d_2$  قرار دهیم:

$$\bar{x} = \frac{(x - x_{min})(d_2 - d_1)}{x_{max} - x_{min}} + d_1 \quad (9)$$

با توجه به داده‌ها  $d_1 = 0$  و  $d_2 = +1$  انتخاب شده است. مشاهده می‌شود تمام داده‌ها در این بازه استاندارد یا به اصطلاح نرمال شده‌اند.

## نتایج و بحث

### شبکه عصبی عمیق

پس از آماده‌سازی داده‌ها برای پیش‌بینی سیلاب، مدل شبکه عصبی با سیستم آموزش ۷۰-۳۰ را انتخاب نموده‌ایم. لازم به توضیح است تمامی برنامه‌نویسی‌های مربوط به شبکه عصبی در نرم‌افزار متلب ورژن 2019a و بر روی سیستم با قدرت پردازنده پنج هسته‌ای و میزان رم هشت گیگابایت انجام شده است.

همان‌طور که پیش از این نیز عنوان شد، در این پژوهش از داده‌های هواشناسی ۵۰ سال گذشته به منظور ارزیابی و تخمین سیل استفاده شده است. بدین منظور از چهار ویژگی مربوط به بارندگی، میانگین دما، بیشینه دما و حداقل دما در منطقه که به صورت ماهانه جمع‌آوری شده‌اند استفاده شده تا در نهایت میزان دبی جریان آب سرازیر شده در منطقه مشخص شود. در جدول (۱)، بخشی از داده‌های جمع‌آوری شده به صورت ماهیانه برای شش ماه دوم سال براساس میزان بارش ارائه شده است.

از این‌رو، با استفاده از مجموع داده‌های جمع‌آوری شده، در بخش بعد به ارائه نتایج حاصل می‌پردازیم. پیش از ارائه نتایج، ابتدا لازم است پیش‌پردازش داده‌ها طی مراحل زیر صورت پذیرد.

### پیش‌پردازش داده‌ها

#### مرتب‌سازی داده‌ها

داده‌ها را باید طوری مرتب سازیم که برای نرم‌افزار متلب قابل فهم و قابل خواندن باشد. در این پژوهش تعداد سطرها بیان گر تعداد سال‌های مورد بررسی و تعداد ستون‌ها بیانگر عوامل مؤثر بر دبی جریان آب در منطقه به‌ازای هر ماه می‌باشد.

#### نرمال‌سازی داده‌ها

اکنون که همه آن‌ها را به متغیرهای عددی تبدیل

Table 1. The flow rate of the region on a monthly basis

Year	Water Year	Mehr	Aban	Azar	Dey	Bahman	Esfand
1350	49	1.233	3.093	1.542	1.577	1.327	1.693
1351	50	0.095	0.24	2.068	1.182	0.876	3.526
1352	51	0.054	0.269	0.713	0.791	0.861	1.665
1353	52	0.319	2.28	2.742	1.477	3.116	8.882
1354	53	0.285	0.354	0.616	0.989	2.222	7.134
1355	54	0.177	0.269	0.41	0.77	0.955	3.939
1356	55	0.094	0.242	0.398	0.954	1.184	1.559
1357	56	0.205	0.4	0.8	1.173	1.448	3.321
1358	57	0.3	0.56	0.7	0.817	1.316	5.151
1359	58	0.057	0.185	0.295	0.263	0.401	1.986
1360	59	0	0	0	0	1.403	4.259



اساس معماری‌های مختلفی که بخشی از آن‌ها در جدول (۳) ارائه شده است.

با توجه به نتایج ارائه شده در جدول (۲)، همان‌طور که اشاره شد، تابع آموزش Levenberg-Marquardt با ضریب همبستگی ۰/۹۶۷۴ دارای بهترین عملکرد و تابع BFGS quasi-Newton با ضریب همبستگی ۰/۷۴۶۳ دارای ضعیف‌ترین عملکرد می‌باشند. علت این اختلاف در این است که Levenberg-Marquardt توانایی حل مسأله در ابعاد مختلف را دارا می‌باشد و با افزایش ویژگی‌ها، قادر به تعیین روند تغییر داده‌ها می‌باشد.

همچنین با توجه به نتایج ارائه شده در جدول (۳)، مشخص می‌شود که تغییر تعداد لایه‌ها از ۱۰ به بالا و پایین در شرایطی که تعداد نوروها افزایش یابند سبب بهبود عملکرد و افزایش همبستگی میان داده‌ها می‌شود. از این رو، می‌توان نتیجه گرفت بهترین معماری برای شبکه عصبی پیشنهاد شده در راستای پیش‌بینی سیلاب برابر با ۱۰ لایه و ۲۰ نرون می‌باشد. حال که به مدل صحیحی دست یافتیم، نتایج مربوط به پیش‌بینی سیلاب را با ساختار مدل مطلوب (مناسب) در شرایط مختلف تقسیم داده‌ها ارائه می‌دهیم.

قبل از بررسی شبکه عصبی، انواع توابع آموزش شبکه عصبی استفاده می‌شود تا نشان دهد کدام تابع بهترین عملکرد را دارا می‌باشد. در جدول (۲)، نتایج همبستگی هر کدام از توابع آموزش شبکه عصبی می‌باشد. برای تعیین عملکرد بهترین تابع آموزش، تعداد لایه‌های پنهان را برابر با ۱۰ و تعداد نوروها را نیز برابر با ۱۰ عدد در نظر می‌گیریم. لازم به ذکر است که در این گام، ۷۰ درصد داده‌ها وارد مرحله آموزش، ۱۵ درصد داده‌ها وارد مرحله آزمایش و ۱۵ درصد داده‌ها وارد مرحله اعتبارسنجی (ارزیابی) شده‌اند. بر این اساس مقادیر مربوط به بهترین مقدار همبستگی را برای هر تابع آموزشی تعیین کرده تا بتوان بر اساس آن برای هر آزمایش به‌طور مجزا، میزان همبستگی مقادیر را تعیین نمود. مشاهده می‌شود که از میان توابع فوق، تابع trainlm دارای بیش‌ترین مقدار همبستگی می‌باشد. از این رو، از این تابع برای آموزش داده‌ها استفاده می‌شود. در مرحله بعد به بررسی و ساخت مدل شبکه براساس تعداد لایه‌ها و تعداد نوروها می‌پردازیم. نتایج این بررسی در جدول (۳) ارائه شده است. بر

**Table 2. Correlation results of different educational functions of neural network**

Row	Function	Definition	Correlaion
1	Trainlm	Levenberg-Marquardt	0.9674
2	Trainbr	Bayesian regularization	0.9041
3	Trainbfg	BFGS quasi-Newton	0.74463
4	Traincgb	Conjugate gradient backpropagation with Powell-Beale restarts	0.9406
5	Traincgp	Conjugate gradient backpropagation with Polak-Ribière updates	0.9247
6	Traingda	Gradient descent with adaptive learning rate	0.9259
7	Traingdm	Gradient descent with momentum	0.8530
8	Traingdx	Gradient descent with momentum and adaptive learning rate	0.9201
9	Trainoss	One-step secant	0.9204
10	Trainscg	Scaled conjugate gradient	0.8542

**Table 3. Investigation of different neural network architectures**

Correlation	Performance	Artichect	
		Neuron No.	Layer No.
0.9674	0.0018	10	10
0.9860	0.0015	20	10
0.9746	0.0021	10	20
0.9489	0.0037	15	15
0.9612	0.0033	5	5
0.8820	0.007	8	8
0.9786	0.0013	5	10
0.9080	0.007	10	5
0.8388	0.0083	8	12
0.9580	0.0030	15	10
0.9686	0.0019	25	9

### آزمون مین کندال

براساس روش انجام شده در آزمون کندال، پس از مرتب‌سازی داده‌ها، به ترتیب نتایج ارائه می‌شود. در مرحله اول، داده‌ها خلاصه‌سازی می‌شوند. جدول (۵) نتایج حاصل از خلاصه‌سازی داده‌های موردبررسی را نشان می‌دهد. حال نتایج پیش‌بینی شده براساس آزمون مین کندال را نسبت به مقدار P-Value در ۱۲ ماه را در جدول (۶) ارائه می‌دهیم.

همان‌طورکه در شکل (۴) مشاهده می‌شود، شبکه عصبی توانسته عملکرد مناسبی در راستای تخمین داده‌ها داشته باشد. از این‌رو، نتایج حاصل از پیش‌بینی در جدول (۴) ارائه شده است. با توجه به این جدول مشاهده می‌شود میزان دبی در هر ۱۲ ماه از سال با اختلاف اندکی نسبت به مقادیر واقعی، پیش‌بینی شده است که این امر نشان‌دهنده قابلیت بالای روش یادگیری عمیق در تعیین روند تغییر داده‌ها و سپس پیش‌بینی دبی می‌باشد.

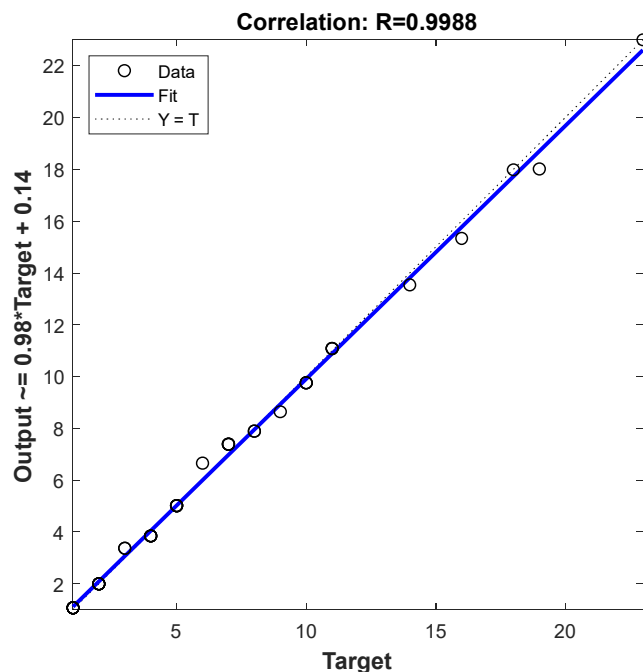


Figure 4. Neural network correlation diagram in flood estimation

Table 4. Actual and projected flow rate on a monthly basis using a deep neural network

Month	Actual average flood flow rate (mm)	Predicted average flood flow rate (mm)
Farvardin	9.558425	9.51023
Ordibehesht	7.3587	7.2256
Khordad	1.679225	1.6734
Tir	0.37505	0.3265
Mordad	0.194025	0.19233
Shahrivar	0.145475	0.14547
Mehr	0.173075	0.17254
Aban	1.1402	1.1454
Azar	1.310725	1.30365
Dey	1.2633	1.26745
Bahman	1.711375	1.70348
Esfand	4.4463375	4.42224

**Table 5. Data summarization by Men Kendall method**

Variable	Observation	Obs. with missing data	Obs. without missing data	Min.	Max.	Mean	Std. deviation
1.233	39	0	39	0.000	0.562	0.146	0.156
3.093	39	0	39	0.000	10.408	1.090	2.317
1.542	39	0	39	0.000	9.025	1.305	1.635
1.577	39	0	39	0.000	4.851	1.255	1.063
1.327	39	0	39	0.171	4.227	1.721	0.878
1.693	39	0	39	0.372	9.899	4.517	2.248
2.989	39	0	39	2.245	22.379	9.727	4.618
2.574	39	0	39	0.836	26.096	7.481	4.934
1.099	39	0	39	0.132	9.791	1.694	1.652
0.599	39	0	39	0.010	1.967	0.369	0.419
0.273	39	0	39	0.000	0.855	0.192	0.211
0.125	39	0	39	0.000	0.799	0.146	0.177

استفاده از هر دو روش در شکل (۵) ارائه شده تا بتوان ارزیابی دقیق و جامعی نسبت به هر دو روش در تخمین سیلاب داشت.

**Table 6. Actual and predicted flow rate on a monthly basis using the Men-Kendall test**

Month	P-Value	Actual average flood flow rate (mm)	Predicted average flood flow rate (mm)
Farvardin	0.36	9.558425	9.15268
Ordibehesht	0.651	7.3587	7.1758
Khordad	1	1.679225	1.46895
Tir	0.451	0.37505	0.3458
Mordad	0.451	0.194025	0.179859
Shahrivar	0.88	0.145475	0.12125
Mehr	0.291	0.173075	0.149386
Aban	0.451	1.1402	1.06349
Azar	0.651	1.310725	1.10298
Dey	0.291	1.2633	1.031284
Bahman	0.451	1.711375	1.49739
Esfand	0.76	4.4463375	4.003165

بر اساس نتایج ارائه شده در جدول (۷) که به مقایسه اختلاف پیش‌بینی روش‌های شبکه عصبی و آزمون من-کندال به تفکیک ماهینه پرداخته است، مشاهده می‌شود که میزان اختلاف پیش‌بینی به روش یادگیری عمیق برابر با ۰/۰۰۶۵۴ و با روش من-کندال برابر با ۰/۱۹۵۳۲ می‌باشد. به عبارتی الگوریتم یادگیری عمیق به میزان حدود ۹۵ درصد دارای خطا و اختلاف کم‌تری نسبت به روش من-کندال می‌باشد. به منظور ارزیابی دقیق‌تر این مسأله، همان‌طور که در بالا نیز توضیح داده شد، در جدول (۸) به بررسی معیارهای خطا در این دو روش پرداخته می‌شود.

با توجه به نتایج ارائه شده در جدول (۵)، مشاهده می‌شود که میزان انحراف استاندارد پیش‌بینی دبی نسبت به مقادیر اصلی در هر ۱۲ ماه دارای مقدار اندکی می‌باشد که این امر بیان‌کننده ارزیابی مناسب این روش به‌ازای ۳۹ بار مشاهده به‌ازای دبی در هر ماه می‌باشد. بدیهی است که انتظار می‌رود با توجه به انحراف استاندارد اندکی که در هر ماه به‌دست آمده، میزان تخمین دبی نیز با اختلاف کمی نسبت به مقادیر واقعی براساس روش من-کندال صورت پذیرد.

همان‌طور که در جدول (۶) نیز مشاهده می‌شود، براساس انتظار قبلی، میزان پیش‌بینی دبی دارای اختلاف قابل‌قبولی نسبت به مقادیر واقعی می‌باشد. از طرفی، با توجه به مقادیر به‌دست‌آمده برای P-Value برای هر ماه، تأیید می‌شود که تخمین دبی در هر ماه به ویژگی‌های مؤثر بر افزایش یا کاهش دبی وابسته بوده و ارتباط معناداری بین آن‌ها برقرار می‌باشد.

### ارزیابی

به‌منظور ارزیابی نتایج حاصل از هر دو مدل پیشنهادی، ابتدا در جدول (۷)، میزان اختلاف هر روش در پیش‌بینی مقادیر دبی نسبت به مقدار واقعی ارائه شده است. همچنین نتایج حاصل از معیار MAE، RMSE، MSE و MAPE برای هر دو روش در جدول (۸) ارائه شده و در نهایت نمودار مربوط به تخمین و پیش‌بینی سیلاب با

از معیارهای ارزیابی مبتنی بر ماتریس آشفتگی<sup>۱۵</sup> و بهره‌گیری از معیار دقت که رابطه آن در زیر آمده است، استفاده می‌نماییم. نتایج مقایسه نیز در جدول (۹) ارائه شده است.

$$ACC = \frac{TP+TN}{TP+TN+FP+FN} \quad (10)$$

براساس نتایج ارائه‌شده در جدول (۸)، الگوریتم یادگیری عمیق از نظر هر سه معیار MSE, RMSE, MAE و MPE دارای خطای کمتری نسبت به آزمون من-کندال در راستای تخمین دبی ماهیانه می‌باشد. هم‌چنین به منظور مقایسه عملکرد روش پیشنهادی شبکه عمیق استفاده‌شده در این مطالعه با مطالعه‌های اخیر،

**Table 7. Comparison of prediction differences between neural network methods and Mann-Kendall test**

Month	Actual average flood flow rate (mm)	Predicted average flood flow rate by deep neural network (mm)	Difference from the actual amount	Predicted average flood flow rate by Menn-Kendal (mm)	Difference from the actual amount
Farvardin	9.558425	9.51023	0.04819	9.15268	0.40575
Ordibehesht	7.3587	7.2256	0.13310	7.1758	0.18290
Khordad	1.679225	1.6734	0.00582	1.46895	0.21028
Tir	0.37505	0.3265	0.04855	0.3458	0.02925
Mordad	0.194025	0.19233	0.00170	0.179859	0.01417
Shahrivar	0.145475	0.14547	0.00001	0.12125	0.02423
Mehr	0.173075	0.17254	0.00054	0.149386	0.02369
Aban	1.1402	1.1454	0.00520	1.06349	0.07671
Azar	1.310725	1.30365	0.00707	1.10298	0.20775
Dey	1.2633	1.26745	0.00415	1.031284	0.23202
Bahman	1.711375	1.70348	0.00789	1.49739	0.21399
Esfand	<b>4.4463375</b>	<b>4.42224</b>	<b>0.02410</b>	<b>4.003165</b>	<b>0.44317</b>
Month	-	-	0.00654	-	0.19532

**Table 8. Evaluation of flood prediction performance using two methods of deep neural network and Men-Kendall test**

	Value	
	Deep Neural Network	Menn-Kendal
MSE	0.0019	0.0491
RMSE	0.0439	0.2217
MAE	0.0239	0.1720
MPE	0.0159	0.1068

**Table 9. Compare the accuracy of the proposed method and recent approaches**

Accuracy (%)	References	Method
90.49	Kashani <i>et al.</i> (2016)	MLP
89.93	Sadeghi and Wafakhah (2016)	MLP
88.12	Sadeghi and Wafakhah (2016)	SVM
91.26	Kan <i>et al.</i> (2018)	DT
90.79	Kan <i>et al.</i> (2018)	SVM
92.66	Kan <i>et al.</i> (2018)	KNN
95.79	Wu <i>et al.</i> (2020)	Deep Learning
85.63	Kim and Han (2020)	Random Forest
98.26	Dudangeh <i>et al.</i> (2020)	BT-GAM
97.02	Dudangeh <i>et al.</i> (2020)	BT-MARS
91.18	Sankaranarayanan <i>et al.</i> (2020)	Deep learning
85.87	Sankaranarayanan <i>et al.</i> (2020)	SVM
87.01	Sankaranarayanan <i>et al.</i> (2020)	Navie Baysian
85.73	Sankaranarayanan <i>et al.</i> (2020)	KNN
90.2	El-Haddad <i>et al.</i> (2021)	XGBoost
80.7	El-Haddad <i>et al.</i> (2021)	KNN
98.97	Proposed Study	Deep Learning

استفاده از رویکرد یادگیری عمیق به منظور تخمین سیل براساس الگوی بارش منطقه




Figure 5. Comparison of forecast value using the studied methods and the actual amount of flood

### نتیجه گیری

براساس پژوهش انجام یافته در خصوص مقایسه کارایی روش های مختلف هوش مصنوعی در تخمین پارامترهای هیدروژئولوژیکی، واضح است که توانایی این تکنیک ها با توجه به ساختارهای مختلف آن ها و نیز طبیعت مسأله مورد نظر، متفاوت است. با انتخاب نوع و تعداد مناسب ورودی ها و نیز استفاده از نوع مناسب و سازگار تکنیک های هوش مصنوعی، می توان گفت که این تکنیک ها ابزاری مناسب و کارا برای تخمین پارامترهای هیدروژئولوژیکی مانند هدایت هیدرولیکی می باشند. در اجرای مدل شبکه عصبی مصنوعی، تعیین تعداد نورون ها در لایه میانی از اهمیت ویژه ای برخوردار است. فرایند بارش- رواناب یک پدیده به طور کامل پیچیده و غیرخطی در آب شناختی می باشد. مدل های مفهومی به طور وسیعی برای مدل سازی بارش- رواناب به کار برده می شوند. با این وجود، این مدل ها نیازمند تعداد زیادی اطلاعات جزئی بوده و کاربرد آن ها صرفاً محدود به مقیاس منطقه مورد مطالعه می باشد. براساس گزارش سازمان ملل در آینده ای نزدیک، ۳۱ کشور جهان با کمبود آب مواجه خواهند شد و نام ایران به عنوان یکی از بحرانی ترین کشورهای درگیر کمبود آب در آینده برده می شود. از آنجا که بارندگی شدید و طغیان سیل شهری که با

تغییر آب و هوا و شهرنشینی تشدید شده، منجر به خسارت های جانی و مالی زیادی شده است، به موضوع مهمی در زمینه مدیریت منابع آب تبدیل شده اند. کشور ایران از نظر جغرافیایی در منطقه گرم و نیمه خشک واقع شده است. در این منطقه به دلیل توزیع غیریکنواخت منابع آب، پراکندگی جمعیت و میزان مصارف، نیاز به ذخیره آب برای تأمین مصارف در فصول مختلف سال نیازی ضروری و اساسی می باشد. در سال های اخیر به دلیل بروز خشکسالی در کشور مدیریت منابع موجود از اهمیت فوق العاده ای برخوردار است و این توجه هرچه بیشتر به مدیریت مخازن و پیش بینی میزان حجم آب به منظور ارایه سیاست های مناسب بهره برداری می باشد. در این پژوهش ابتدا با بررسی مقاله ها و نتایج آزمایشگاهی وقوع سیل در منطقه، به بررسی پارامترهای مؤثر بر وقوع سیل نظیر دما، رطوبت، بارش باران، بارش برف، کاربری زمین، نفوذپذیری خاک، شیب حوضه آبریز و ... پرداخته شده و با مراجعه به سازمان هواشناسی منطقه، اطلاعات مربوطه در بازه زمانی ۵۰ سال اخیر رابه صورت روزانه و ماهانه برای حوضه مورد مطالعاتی (کن-سولقان) دریافت نمودیم. سپس به بررسی ساختار مطلوب در تعیین روش شبکه عصبی کانولوشن که یکی از روش های پرکاربرد شبکه های عمیق می باشد پرداخته شد.

- A.H., & El-Khashab, M. H. (2021). Flood susceptibility prediction using four machine learning techniques and comparison of their performance at Wadi Qena Basin, Egypt. *Natural Hazards*, 105(1), 83-114.
3. Ghaffari, Gh. A., & Vafakhahat, M. (2013). Simulation of rainfall-runoff process using artificial neural network and fuzzy-adaptive neural system (Case study: Haji Ghoshan watershed). *Watershed Management Research Journal*, 8, 120-136. [In Persian]
  4. Kashani, M. H., Ghorbani, M. A., Dinpashoh, Y., & Shahmorad, S. (2016). Integration of Volterra model with artificial neural networks for rainfall-runoff simulation in forested catchment of northern Iran. *Journal of Hydrology*, 540, 340-354.
  5. Kan, G., Li, J., Zhang, X., Ding, L., He, X., Liang, K., ... & Zhang, Z. (2018). A new hybrid data-driven model for event-based rainfall-runoff simulation. *Neural Computing and Applications*, 28(9), 2519-2534.
  6. Kim, H. I., & Han, K. Y. (2020). Linking Hydraulic Modeling with a Machine Learning Approach for Extreme Flood Prediction and Response. *Atmosphere*, 11(9), 987.
  7. Liu, L., & Xu, Z. X. (2016). Regionalization of precipitation and the spatiotemporal distribution of extreme precipitation in southwestern China. *Natural Hazards*, 80(2), 1195-1211.
  8. Mosavi, A., Ozturk, P., & Chau, K. W. (2018). Flood prediction using machine learning models: Literature review. *Water*, 10(11), 1536.
  9. Mu, D., Luo, P., Lyu, J., Zhou, M., Huo, A., Duan, W., ... & Zhao, X. (2020). Impact of temporal rainfall patterns on flash floods in Hue City, Vietnam. *Journal of Flood Risk Management*, e12668, 280, 458-496.
  10. Parisa, Normand, Behreza. (2016) Rainfall-runoff model of Sufi Chay catchment using artificial neural networks. National Conference on Technology and Engineering in Civil Engineering, Architecture, *Electrical and Mechanical Engineering*. [In Persian].
  11. Rahman, M. A., Yunsheng, L., & Sultana, N. (2017). Analysis and prediction of rainfall trends over Bangladesh using Mann-Kendall, Spearman's rho tests and ARIMA model. *Meteorology and Atmospheric Physics*, 129(4), 409-424.
  12. Sedighi, F., Vafakhah, M., & Javadi, M. R. (2016). Rainfall-runoff modeling using support vector machine in snow-affected watershed. *Arabian Journal for Science and Engineering*, 41(10), 4065-4076.

به منظور ارزیابی روش پیشنهادی، از آزمون تجربی من-کندال در راستای تخمین و ارزیابی میزان سیلاب جاری در منطقه استفاده شد. نتایج نشان داد که روش‌های به کاررفته دارای دقت مناسبی در راستای تخمین و ارزیابی میزان سیلاب منطقه دارند. به طور خاص، میزان اختلاف پیش‌بینی سیلاب منطقه به تفکیک ماهیانه برای شبکه عصبی کانولوشن برابر با ۰/۰۰۶۵۴ و برای روش من-کندال، ۰/۱۹۵۳۲ حاصل شد. همچنین میزان خطاهای MAPE، RMSE، MSE و MAE برای شبکه عصبی به ترتیب برابر با ۰/۰۰۱۹، ۰/۰۰۴۳۹، ۰/۰۲۳۹ و ۰/۰۱۵۹ به دست آمد که نشان از دقت بالای این روش در تخمین میزان سیلاب منطقه است.

#### پی‌نوشت‌ها

1. Convolutional Neural Network
2. Mean Squared Error
3. Root Mean Square Error
4. Mean Absolute Error
5. Mean Absolute Percentage Error
6. Extreme gradient boosting
7. K-Nearest Neighbor
8. Feed forward
9. Backpropagation
10. Loss function
11. Chain rule
12. Covolu
13. Average pooling
14. Max pooling
15. Confusion Matrix

#### تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد.

#### منابع

1. Dodangeh, E., Choubin, B., Eigdir, A. N., Nabipour, N., Panahi, M., Shamshirband, S., & Mosavi, A. (2020). Integrated machine learning methods with resampling algorithms for flood susceptibility prediction. *Science of the Total Environment*, 705, 135983.
2. El-Haddad, B.A., Youssef, A.M., Pourghasemi, H.R., Pradhan, B., El-Shater,

13. Sankaranarayanan, S., Prabhakar, M., Satish, S., Jain, P., Ramprasad, A., & Krishnan, A. (2020). Flood prediction based on weather parameters using deep learning. *Journal of Water and Climate Change*, 11(4), 1766-1783.
14. Wu, Z., Zhou, Y., Wang, H., & Jiang, Z. (2020). Depth prediction of urban flood under different rainfall return periods based on deep learning and data warehouse. *Science of The Total Environment*, 716, 137077.
15. Wu, Z., Zhou, Y., Wang, H., & Jiang, Z. (2020). Depth prediction of urban flood under different rainfall return periods based on deep learning and data warehouse. *Science of The Total Environment*, 716, 137077.
16. Zhu, Y., Feng, J., Yan, L., Guo, T., & Li, X. (2020). Flood Prediction Using Rainfall-Flow Pattern in Data-Sparse Watersheds. *IEEE Access*, 8, 39713-39724.