

## Comparison of the Performance of ANN and SVM Methods in Rainfall-Runoff Process Modeling (Case Study: North Karun Watershed)

S. H. Roshun<sup>1</sup>, K. Shahedi<sup>1\*</sup>, M. Habibnejad Roshan<sup>1</sup> and J. Chormanski<sup>2</sup>

(Received: April 22-2020; Accepted: September 28-2020)

### Abstract

The simulation of the rainfall-runoff process in the watershed has particular importance for a better understanding of hydrologic issues, water resources management, river engineering, flood control structures, and flood storage. In this study, to simulate the rainfall-runoff process, rainfall and discharge data were used in the period 1997-2017. After data qualitative control, rainfall, and discharge delays were determined using the coefficients of autocorrelation, partial autocorrelation, and cross-correlation in R Studio software. Then, the effective parameters and the optimum combination were determined by the Gamma test method and used to implement the model under three different scenarios in MATLAB software. Gamma test results showed that today's precipitation parameters, precipitation of the previous day, discharge of the previous day, and discharge of two days ago have the greatest effect on the outflow of the basin. Also, the  $P_t Q_{t-1}$  and  $P_t P_{t-1} Q_{t-1} Q_{t-2} Q_{t-3}$  combinations were selected as the most suitable input combinations for modeling. The results of the modeling showed that in the support vector machine model, the Radial Base kernel Function (RBF) has a better performance than multiple and linear kernels. Also, the performance of the Artificial Neural Network model (ANN) is better than the Support Vector Machine model (SVM) with Radial Base kernel Function (RBF).

**Keywords:** Gamma test, Optimum combination, Soft calculations, Artificial neural network, Support vector machine, North Karun watershed

1. Watershed Management Engineering, Sari Agricultural Sciences and Natural Resources University. Mazandaran, Iran.

2. Faculty of Civil and Environmental Engineering, Warsaw University of Life Sciences, Warsaw, Poland.

Corresponding author, Email: [kaka.shadehi@gmail.com](mailto:kaka.shadehi@gmail.com)

## مقایسه عملکرد روش‌های هوش مصنوعی ANN و SVM در مدل‌سازی فرایند بارش - رواناب (مطالعه موردی: حوضه آبخیز کارون شمالی)

سیدحسین روشان<sup>۱</sup>، کاکا شاهدهی<sup>۱\*</sup>، محمود حبیب‌نژاد روشن<sup>۱</sup> و یاروسلاو کرمانسکی<sup>۲</sup>

(تاریخ دریافت: ۱۳۹۹/۲/۳؛ تاریخ پذیرش: ۱۳۹۹/۷/۷)

### چکیده

شبیه‌سازی فرایند بارش - رواناب در حوضه آبخیز از نقطه نظر درک بهتر مسائل هیدرولوژیک، مدیریت منابع آب، مهندسی رودخانه، سازه‌های کنترل سیل و ذخیره سیلاب اهمیت ویژه‌ای دارد. در این تحقیق، به منظور شبیه‌سازی فرایند بارش - رواناب از داده‌های بارش و دبی جریان در دوره زمانی ۱۳۷۶-۱۳۹۶ استفاده شد. بعد از کنترل کیفی و صحت داده‌ها، تأخیر بارش و دبی با استفاده از ضرایب خودهمبستگی، خود همبستگی جزئی و همبستگی متقارن در نرم‌افزار R Studio مشخص شد. سپس پارامترهای مؤثر و ترکیب بهینه نیز به روش آزمون گاما تعیین و برای اجرای مدل تحت سه سناریوی مختلف در نرم‌افزار MATLAB مورد استفاده قرار گرفتند. نتایج آزمون گاما نشان داد که پارامترهای بارش روز جاری، بارش یک روز قبل، دبی روز قبل و دو روز قبل دارای بیشترین تأثیر در دبی خروجی حوضه هستند. همچنین ترکیب‌های Pt Pt-1 Qt-1 و Pt Qt-1 مناسب‌ترین ترکیب بهینه ورودی برای مدل‌سازی انتخاب شدند. نتایج مدل‌سازی نشان داد که در مدل ماشین بردار پشتیبان تابع کرنل پایه شعاعی (RBF) نسبت به کرنل‌های چندگانه و خطی دارای عملکرد بهتری است. همچنین کارایی مدل شبکه عصبی مصنوعی (ANN) نسبت به مدل ماشین بردار پشتیبان (SVM) با تابع کرنل پایه شعاعی (RBF) بهتر است.

واژه‌های کلیدی: آزمون گاما، ترکیب بهینه، محاسبات نرم، شبکه عصبی مصنوعی، ماشین بردار پشتیبان، حوضه آبخیز کارون شمالی

۱. گروه مهندسی آبخیزداری، دانشگاه علوم کشاورزی و منابع طبیعی ساری

۲. گروه مهندسی هیدرولیک، دانشگاه علوم زیستی ورشو

\*: مسئول مکاتبات: پست الکترونیکی: kaka.shadehi@gmail.com

## مقدمه

پیش‌بینی رواناب یک موضوع تحقیقی فعال و اجتناب‌ناپذیر در زمینه هیدرولوژی آب‌های سطحی بوده و همچنان به‌خاطر عدم قطعیت‌های موجود در پارامترهای هواشناسی و هیدرولوژی مسئله‌ای پابرجا است (۱۴). این مسئله یکی از نیازهای عمده در طراحی پروژه‌های آبخیزداری و منابع آب است که برای برآورد آن از روش‌های مختلف استفاده می‌شود (۶). فرایند بارش-رواناب از اساسی‌ترین و تأثیرگذارترین فرایندهای علم هیدرولوژی محسوب می‌شود و یکی از مهم‌ترین اجزای چرخه هیدرولوژی است (۲۲ و ۲۷)، با توجه به محدودیت منابع آب شیرین، پیش‌بینی و مدل‌سازی صحیح این فرایند برای مدیریت منابع آب و کاهش خسارات سیل ضروری است (۷، ۱۰ و ۲۵). بر اساس استفاده از روش‌های مختلف برای مدل‌سازی این فرایند مدل‌ها و نرم‌افزارهای مختلفی توسعه یافته و می‌یابند. در این راستا مدل‌های جعبه سیاه برای مدل‌سازی بارش-رواناب به‌طور گسترده‌ای مورد استفاده قرار می‌گیرند (۲۷). به‌دلیل پیچیده و غیرخطی بودن فرایند بارش-رواناب و تأثیر عوامل مختلف اقلیمی به‌همراه خصوصیات فیزیکی حوضه‌های آبخیز روی آن، تشریح آن با مدل‌های ساده و خطی به‌راحتی امکان‌پذیر نبوده و مدل‌سازی آن بسیار مشکل است (۳۱). از این‌رو، متخصصان همواره به‌دنبال روش‌های دقیق و نوین در مدل‌سازی فرایند بارش-رواناب هستند. امروزه استفاده از روش‌های نوین هوش مصنوعی برای شبیه‌سازی فرایندهای مختلف هیدرولوژیک مورد توجه قرار گرفته‌اند (۱۰) و به‌عنوان ابزارهای مدل‌سازی جعبه سیاه به‌خصوص در شبیه‌سازی بارش-رواناب کاربرد فراوانی دارند (۲۶). تحقیقات زیادی در زمینه شبیه‌سازی بارش-رواناب با به‌کارگیری روش‌های نوین هوش مصنوعی در دنیا انجام شده است که مهم‌ترین روش‌های استفاده شده شامل، مدل‌های سری زمانی و داده محور ARMA و ARIMA، شبکه عصبی مصنوعی (Artificial Neural Networks)، الگوریتم ژنتیک (Genetic Algorithms)، منطق فازی (Fuzzy Logic)، ماشین بردار پشتیبان (Support Vector

Machine)، شبکه فازی - عصبی تطبیقی (ANFIS)، رگرسیون خطی چندگانه (MLR) و انواع مدل‌های رگرسیونی هستند (۴، ۹، ۱۰، ۱۳، ۱۵ و ۲۹). پیچیدگی فرایند بارش-رواناب از یک سو و نیاز به اطلاعات زیاد برای محاسبه آن و مشکلات موجود در اندازه‌گیری این پارامترها از سوی دیگر، ضرورت استفاده از شبکه عصبی مصنوعی را در برآورد بارش-رواناب آشکار می‌سازد (۲۰). آخونی پورحسینی و دربندی (۱) برای مدل‌سازی جریان آب رودخانه صوفی‌چای در استان آذربایجان از مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان استفاده کردند. آنها برای تعیین ترکیب بهینه متغیرهای ورودی از آزمون گاما بهره گرفتند. نتایج تحقیق آنها نشان داد که از بین این دو مدل با ساختار ورودی یکسان، مدل ماشین بردار پشتیبان کارایی به‌نسبت بالایی نسبت به شبکه عصبی مصنوعی دارد. قربانی و همکاران (۱۳) به مقایسه عملکرد مدل ماشین بردار پشتیبان با توابع کرنل پایه شعاعی، چندجمله‌ای و خطی با مدل‌های شبکه بیزی با الگوریتم PC، شبکه عصبی مصنوعی و برنامه‌ریزی بیان ژن در شبیه‌سازی فرایند بارش-رواناب در حوضه سیمینه‌رود پرداختند. نتایج تحقیق آنها نشان داد که هر چهار مدل دارای عملکرد قابل قبولی بودند و مدل برنامه‌ریزی بیان ژن با بیشترین ضریب همبستگی و کمترین RMSE و ضریب ناش‌ساتکلایف نسبت به بقیه مدل‌ها عملکرد بهتری داشت. باتسیس و همکاران (۳) اقدام به مدل‌سازی فرایند بارش-رواناب با استفاده از ماشین بردار پشتیبان با سه تابع کرنل پایه شعاعی، خطی و چندجمله‌ای با شبکه عصبی مصنوعی کردند. نتایج آنها نشان داد که مدل ماشین بردار پشتیبان دارای عملکرد بهتری در شبیه‌سازی بارش-رواناب بوده است. میسرا و همکاران (۲۳) در تحقیقی به مقایسه مدل ماشین بردار پشتیبان با شبکه عصبی مصنوعی برای پیش‌بینی رواناب و بار رسوبی پرداختند. آنها در این تحقیق از داده‌های روزانه، هفتگی و ماهانه جریان و رسوب استفاده کردند. نتایج تحقیق آنها نشان داد که مدل ماشین بردار پشتیبان هم در پیش‌بینی رواناب و هم بار رسوب نسبت به مدل شبکه عصبی

مصنوعی عملکرد بهتری داشته است. هدف تحقیق حاضر مقایسه دو مدل شبکه عصبی مصنوعی و ماشین بردار پشتیبان در شبیه‌سازی بارش - رواناب در حوضه آبخیز کارون شمالی است.

## مواد و روش‌ها

### منطقه مورد مطالعه

حوضه آبخیز کارون بزرگ یکی از ۳۰ حوضه آبخیز درجه دو کشور و بخشی از حوضه آبخیز اصلی خلیج فارس است. حوضه آبخیز کارون شمالی بخشی از این حوضه بزرگ است که در استان‌های کهگیلویه و بویراحمد (۱۷/۰۶ درصد)، چهارمحال بختیاری (۵۷/۵۴ درصد)، اصفهان (۲۲/۳۴ درصد) و خوزستان (۱/۷۰) و بخشی از فارس (۱/۳۶ درصد) گستره دارد. از نظر موقعیت جغرافیایی نیز بین طول شرقی ۳۵° ۴۹' تا ۴۷° ۵۱' و عرض شمالی ۲۸° ۳۰' تا ۳۲° ۴۰' قرار گرفته است و دارای مساحتی حدود ۲۳۶۰۳/۶۶ کیلومتر مربع است. حوضه آبخیز کارون شمالی به دلیل توپوگرافی شدید (کمترین ارتفاع ۷۷۱ متر و بیشترین ارتفاع ۴۴۰۷ متر) و وجود مناطق برف‌گیر (رشته کوه‌های زاگرس از جمله کوه دنا) از پرآب‌ترین حوضه‌های آبخیز کشور محسوب می‌شود و در مدیریت منابع آب کشور از جایگاه ویژه‌ای برخوردار است. شکل ۱ موقعیت جغرافیایی این حوضه آبخیز را در کشورمان نشان می‌دهد.

### روش تحقیق

به منظور شبیه‌سازی فرایند بارش - رواناب داده‌های بارش و دبی جریان در مقیاس روزانه از سازمان هواشناسی کشور و شرکت مدیریت منابع آب اخذ شد. در ابتدا با انتخاب پایه زمانی مشترک (۱۳۹۶-۱۳۷۶) بین همه ایستگاه‌های موجود در حوضه (۲۸ ایستگاه باران‌سنجی، ۹ ایستگاه سینوپتیک و ۱۲ ایستگاه هیدرومتری) (شکل ۲)، رفع نواقص آماری با استفاده از روش همبستگی بین ایستگاه‌ها در محیط نرم‌افزار SPSS انجام شد. همچنین صحت و همگنی داده‌ها در هر ایستگاه با استفاده از

آزمون ران تست مورد بررسی قرار گرفت.

در ادامه به منظور اجرای مدل شبکه عصبی مصنوعی و ماشین بردار پشتیبان اقدام به تعیین ورودی‌های بهینه و ترکیب مناسب ورودی با استفاده از آزمون گاما در محیط نرم‌افزار WinGamma™ نسخه ۱/۹۸ شد و بر اساس مقدار گاما (Γ) و خطای استاندارد پارامترهای ورودی و ترکیب بهینه انتخاب شد. برای تعیین تعداد تأخیرهای بارش و دبی جریان نیز از توابع خودهمبستگی، خودهمبستگی جزئی و همبستگی متقاطع در محیط نرم‌افزار R Studio بهره گرفته شد.

### آزمون گاما

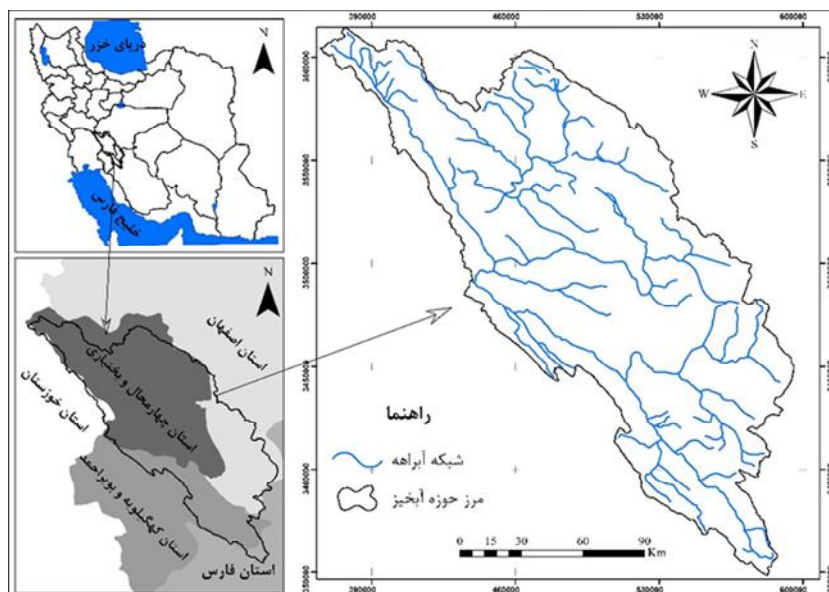
این آزمون اولین بار توسط کانکار (۲۱) در سال ۱۹۹۷ معرفی شد و پس از آن توسط تعداد زیادی از محققین همچون دورانت (۱۱)، توسی (۳۲) و جونز و همکاران (۱۶) جزئیات آن بحث شد و آزمون گاما را به عنوان ابزاری مناسب برای یافتن بهترین ترکیب از متغیرهای ورودی به مدل غیرخطی معرفی کردند. در این آزمون فرض می‌شود که مجموعه داده‌های مشاهداتی به صورت رابطه ۱ است (۱۸):

$$\{(x_i - y_i), 1 \leq i \leq M\} \quad (1)$$

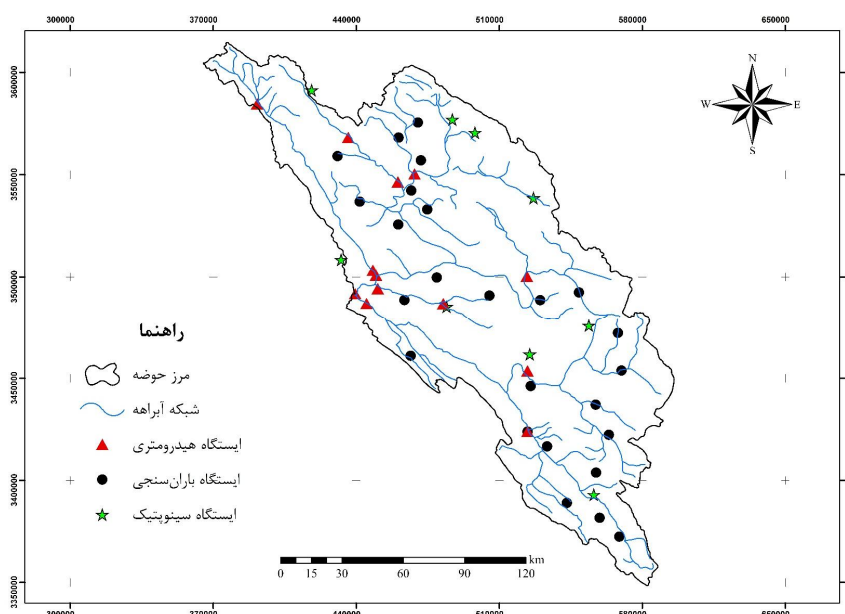
که در آن  $x_i$  بردار مشاهداتی ورودی (مانند رواناب، بارش، درجه حرارت هوا با تأخیرهای مختلف و هر متغیر مؤثر دیگر)،  $y_i$  خروجی مشاهداتی (مانند میانگین دبی رواناب روزانه) و  $M$  تعداد کل مشاهدات است. از بردار  $x_i$  (در فضای  $m$  بعدی) برای مدل‌سازی ( $y_i$  در فضای  $R$ ) استفاده می‌شود. بنابراین، با توجه به فرض فوق رابطه بین ورودی و خروجی به شرح زیر در نظر گرفته شد (رابطه ۲):

$$y = f(x) + r \quad (2)$$

که در آن  $f$  یک تابع هموار و  $r$  متغیر تصادفی نشان‌دهنده خطا است. فرض شد میانگین توزیعی که  $r$  از آن پیروی می‌کند صفر و واریانس خطا ( $\text{Var}(r)$ ) کران‌دار است. این خطا ممکن است به دلایل عدم دقت اندازه‌گیری‌ها و هموار نبودن ارتباط اساسی بین ورودی و خروجی به وجود آید. به این ترتیب، مدل



شکل ۱. موقعیت جغرافیایی حوزه آبخیز کارون شمالی در کشور




شکل ۲. موقعیت ایستگاه‌های مورد استفاده در حوزه مورد مطالعه

$$\Sigma_m = \frac{1}{m} \sum_i^m |x_{N[i,k]} - y_i|^2 \quad 1 \leq k \leq p \quad (3)$$

تابع مربوطه گاما برای هر خروجی  $y_i$  متناظر با بردار ورودی در رابطه (۱) بر اساس رابطه (۴) به دست می‌آید:

$$Y_M = \frac{1}{2M} \sum_I^M |y_{N[i,k]} - y_i|^2 \quad 1 \leq k \leq p \quad (4)$$

نشان داده شده با رابطه ۲ به مدلی هموار با مشتقات جزئی مرتبه اول محدود شد. آماره گاما ( $\Gamma$ ) واریانس بخشی از داده‌ها را که تابع  $f$  قادر به توجیه آن نیست نشان می‌دهد. مقدار  $\Gamma$  بر اساس  $k$  امین همسایه نزدیک  $x_{N\{I,k\}}$  برای هر بردار ورودی  $x_i$  است. آماره گاما از تابع دلتا مخصوص بردارهای ورودی به صورت رابطه (۳) به دست می‌آید:



شکل ۳. ساختار شبکه عصبی مصنوعی

استفاده از آزمون  $M$  می‌توان تعداد داده‌های مورد نیاز را برای بخش آموزش تعیین کرد. آزمون  $M$  با فرض آنکه  $M$  تعداد سری مجموعه مشاهده شده از پدیده مورد بررسی باشد، با استفاده از آزمون گاما می‌توان چگونگی تغییرات منحنی‌های مجانب گاما و خطای استاندارد را برای ترکیب منتخب با افزایش تعداد الگوهای ورودی  $M$  بررسی و تعداد الگوهای ورودی که مقدار این آماره‌ها را به حالت پایدار برای ایجاد مدل هموار می‌رساند، تعیین کرد (۲۸ و ۳۱).

### شبکه عصبی مصنوعی (ANN)

شبکه‌های عصبی مصنوعی، یکی از روش‌های محاسباتی است که به کمک فرایند یادگیری (Learning) و با استفاده از پردازشگرهایی بنام نرون تلاش می‌کند با شناخت روابط ذاتی بین داده‌ها، نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهد. هر شبکه عصبی مصنوعی از سه لایه ورودی، مخفی و خروجی تشکیل شده است. در هر لایه تعدادی پردازشگر به نام نرون وجود دارد. لایه یا لایه‌های مخفی، اطلاعات دریافت شده از لایه ورودی را پردازش کرده و در اختیار لایه خروجی قرار می‌دهند (شکل ۳).

که مقدار  $y$  معین برای  $k$  امین همسایه نزدیک بردار ورودی  $x_i$  در رابطه (۱) است. میزان  $p$  را می‌توان بین  $50-10$  انتخاب کرد (۱۱ و ۱۶). با ایجاد رابطه رگرسیونی خطی رابطه زیر حاصل می‌شود:

$$Y = A\sigma + \Gamma \quad (5)$$

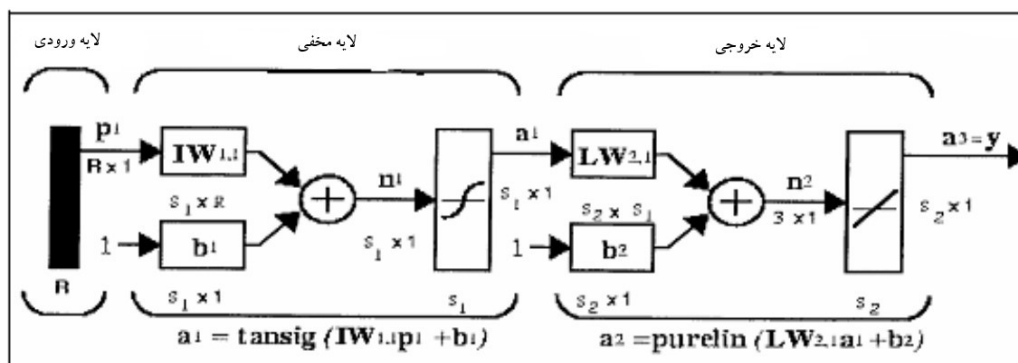
وقتی  $\sigma$  به سمت صفر میل کند مقدار آماره گاما به صورت زیر نشان داده می‌شود:

$$Y_M \rightarrow \text{VAR}(r)\sigma_M \rightarrow 0 \quad (6)$$

محاسبه شیب نیز به عنوان یک پارامتر بدون بعد هم می‌تواند اطلاعات مفیدی در رابطه با پیچیدگی مدل ارائه کند. نسبت  $v$  نیز بررسی شکلی را که وابسته به دامنه خروجی است میسر ساخته و خروجی مناسب برای توابع ساده را مدل‌سازی می‌کند که به صورت رابطه (۷) محاسبه می‌شود:

$$V_{\text{ratio}} = \frac{\Gamma}{\text{VAR}(Y)} \quad (7)$$

$\text{VAR}(Y)$  واریانس خروجی را نشان می‌دهد. این نسبت به صورت نرمال بین  $1-0$  تغییر می‌کند که هرچه میزان آن به صفر نزدیک‌تر باشد بیانگر برآوردی مناسب‌تر از خروجی  $Y$  است. در واقع  $1 - |V_{\text{ratio}}|$  مشابه با ضریب تعیین  $R^2$  است که تخمین می‌زند تا چه حد اطلاعات متناسب با مدل است (۱۷). با



شکل ۴. تصویر نمادین از شبکه‌های پرسپترون چندلایه (MLP)

شبکه عصبی مصنوعی یکی از دستاوردهایی است که با الگوبرداری از شبکه عصبی مغز انسان قادر است پدیده‌های پیچیده و ناشناخته را به خوبی بررسی کند و روابط پیچیده و غیرخطی که برای مدل کردن با روش‌های معمولی دشوار هستند را آموزش دهد (۲۴). شبکه‌های عصبی از لحاظ نوع شبکه نیز به دو گروه شبکه‌های پیشخور و پسخور تقسیم می‌شوند. یکی از مهم‌ترین انواع شبکه‌های عصبی، شبکه‌های پرسپترون چند لایه (MLP) است. این شبکه‌ها از چندین لایه تشکیل شده‌اند هر لایه تعدادی نرون در نظر گرفته می‌شود که به وسیله اتصالاتی به نرون‌های لایه‌های مجاور وصل می‌شوند. نرون‌های لایه اول، اطلاعات ورودی را گرفته و از طریق اتصالات مربوطه، به نرون‌های لایه مخفی منتقل می‌کنند (شکل ۴).

#### ماشین بردار پشتیبان (SVM)

الگوریتم ماشین بردار پشتیبان که توسط واپنیک (۱۹۹۵) ارائه شده، بر اساس نظریه ابعادی و تئوری یادگیری آماری بنا شده است و شامل یک مرحله آموزشی همراه با ورودی و ارزش‌های اهداف خروجی است. بر اساس این نظریه یادگیری آماری، می‌توان کران نرخ خطای ماشین یادگیری را برای داده‌های طبقه بندی نشده، به عنوان نرخ خطای تعمیم یافته، در نظر گرفت. این کران‌ها به عنوان تابعی از نرخ خطاهای آموزشی هستند که میزان پیچیدگی طبقه بندی کننده‌ها را نشان می‌دهند. به منظور کمینه کردن نرخ خطاهای تعمیم یافته، باید نرخ خطای آموزش و پیچیدگی طبقه بندی کننده کاهش یابد. این کار را می‌توان با بیشینه کردن حاشیه جداسازی انجام داد. مشابه سایر مسائل رگرسیونی فرض می‌شود که رابطه میان متغیرهای مستقل و وابسته با تابع جبری مانند  $f(x)$  به علاوه مقداری اغتشاش (خطای مجاز  $\epsilon$ ) مشخص می‌شود.

$$f(x) = W^T \cdot \phi(x) + b \quad (9)$$

$$y = f(x) + \text{noise} \quad (10)$$

چنانچه  $W$  (بردار ضرایب) و  $b$  (ثابت) مشخصه‌های تابع

در این شبکه‌ها ورودی مؤثر هر نرون، حاصل ضرب خروجی نرون‌های لایه قبل در وزن‌های میان آن نرون‌ها است.

$$\text{Net}_{pi} = \sum W_{ij} a_{pi} + b_i \quad (8)$$

در این رابطه،  $a_{pi}$  مقدار خروجی لایه قبلی و  $W_{ij}$  وزن‌های لایه مربوطه و  $b_i$  میزان اریبی (Bias) است. در واقع این رابطه یک رابطه خطی است. سپس مقدار  $F(\text{Net}_{pi})$  محاسبه می‌شود که  $F$ ، یک تابع محرک است. در لایه مخفی پس از محاسبه ورودی مؤثر در هر نرون، این ورودی از یک تابع محرک گذارنده می‌شود. برای این کار، توابع محرک مختلفی ارائه شده است. گرایش بیشتر پژوهشگران به استفاده از توابع محرک کراندار

سناریوی سوم: فقط داده‌های رواناب در نظر گرفته شدند تا داده‌های روزهای بعدی دبی بر اساس آمار روزهای قبل و روز جاری پیش‌بینی شوند. رابطه این سناریو را نیز می‌توان به صورت زیر در نظر گرفت:

$$Q_{t+1} = f(Q_{t-1}, Q_{t-2}, Q_{t-3}) \quad (13)$$

برای افزایش کارایی هر دو مدل، همه داده‌ها در محیط نرم‌افزار MATLAB استاندارد شدند. برای مقایسه داده‌های مشاهداتی و پیش‌بینی شده و ارزیابی کارایی مدل‌ها از شاخص‌های آماری ضریب تبیین ( $R^2$ )، ریشه متوسط مربعات خطا (RMSE) و ضریب نش ساتکلیف (NSE) استفاده شد که رابطه هر یک از شاخص‌های مذکور در زیر آمده است.

$$R^2 = \left[ \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \cdot \sum_{i=1}^N (y_i - \bar{y})^2}} \right]^2 \quad (14)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_i - y_i)^2}{N}} \quad (15)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{x})^2} \quad (16)$$

در روابط فوق  $x_i$ : مقدار دبی مشاهداتی،  $y_i$ : مقدار دبی پیش‌بینی شده و  $\bar{x}$  و  $\bar{y}$  به ترتیب میانگین داده‌های متناظر است. مدلی دارای بهترین نتیجه است که ضریب تبیین و ضریب نش ساتکلیف نزدیک به یک و RMSE نزدیک به صفر داشته باشد.

### نتایج و بحث

نتایج تعیین تعداد تأخیرهای بارش (P) و دبی جریان (Q) با استفاده از همبستگی جزئی (ACF)، خودهمبستگی جزئی (PACF) و همبستگی متقاطع (CCF) در محیط نرم‌افزار R Studio تا ۱۰ تأخیر به صورت زیر قابل مشاهده است (جدول ۱).

بر اساس جدول ۱ پارامترهای بارش روز جاری، بارش یک روز قبل و بارش دو روز قبل، همچنین دبی روز قبل، دو روز و سه روز

رگرسیون و  $\emptyset$  نیز تابع کرنل باشد، آنگاه هدف پیدا کردن فرم تابعی برای  $f(x)$  است. این مهم با آموزش مدل SVM توسط مجموعه‌ای از نمونه‌ها (مجموعه آموزش) محقق می‌شود.

در این تحقیق برای اجرای مدل شبکه عصبی مصنوعی از شبکه پرسپترون چندلایه پیش‌خور (Multi-Layer Perceptrone) با قانون یادگیری پس انتشار خطا (Back Propagation Error) و برای تابع آموزش از الگوریتم بهینه‌سازی لونیبرگ - مارکوات (Levenberg-Marquardt) برای تابع آموزشی تطبیقی نیز از کاهش شیب با مومنتوم (Gradient descent with momentum) و برای تابع‌های انتقال نیز برای لایه اول تابع تانژانت هیپربولیک سیگوئید (tansing) و برای لایه دوم تابع خطی (pureline) در محیط نرم‌افزار MATLAB R2018b استفاده شد. در این تحقیق ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد بقیه برای بخش صحت‌سنجی برای هر دو مدل ماشین بردار پشتیبان و شبکه عصبی مصنوعی استفاده شد. در نهایت برای اجرای مدل‌ها از سه سناریو استفاده شد، سناریوی اول: داده‌های رواناب وارد مدل‌سازی نشدند تا بررسی شود که در صورت نبود داده‌های رواناب می‌توان با استفاده از داده‌های بارش رواناب روز جاری را پیش‌بینی کرد که می‌توان به صورت رابطه زیر، آن را بیان کرد:

$$Q_t = f(P_t, P_{t-1}) \quad (11)$$

که در آن:  $Q_t$ : دبی جریان روز جاری (خروجی مدل)،  $P_t$ : بارش روز جاری و  $P_{t-1}$ : بارش روز قبل (ورودی‌های مدل)

سناریوی دوم: رواناب نیز به‌عنوان ورودی به مدل داده شد. بنابراین داده‌های رواناب و بارش با هم وارد مدل شدند. بر اساس آزمون گاما در این تحقیق تا دو روز تأخیر برای بارش تا سه روز تأخیر برای دبی جریان معنی‌دار به دست آمد و در نظر گرفته شد. رابطه این سناریو را می‌توان به صورت زیر نوشت:

$$Q_t = f(P_t, P_{t-1}, P_{t-2}, Q_{t-1}, Q_{t-2}, Q_{t-3}) \quad (12)$$

که در آن:  $Q_t$ : دبی جریان روز جاری (خروجی مدل)،  $P_t$ ،  $P_{t-1}$ ،  $P_{t-2}$ ،  $Q_{t-1}$ ،  $Q_{t-2}$ ،  $Q_{t-3}$ : به ترتیب بارش روز جاری، بارش روز قبل، بارش دو روز قبل، دبی روز قبل، دبی دو روز قبل و دبی سه روز قبل (ورودی‌های مدل) هستند.



جدول ۱. نتایج تعیین تأخیرهای بارش و دبی جریان در حوضه آبخیز مورد مطالعه

t-10	t-9	t-8	t-7	t-6	t-5	t-4	t-3	t-2	t-1	(P)	(ACF)
۰/۱۳۰*	۰/۱۰۹*	۰/۱۰۵*	۰/۱۱۰*	۰/۱۰۴*	۰/۱۱۱*	۰/۱۲۱*	۰/۱۱۵*	۰/۱۶۲*	۰/۴۳۵*		
۰/۰۵۰*	۰/۰۵۱*	۰/۰۵۲*	۰/۰۵۳*	۰/۰۵۵*	۰/۰۵۶*	۰/۰۵۸*	۰/۰۶۱*	۰/۰۷۴*	۰/۰۷۵*		(Q)
۰/۰۶۲*	۰/۰۴۵ <sup>ns</sup>	۰/۰۳۳ <sup>ns</sup>	۰/۰۴۹ <sup>ns</sup>	۰/۰۴۲ <sup>ns</sup>	۰/۰۳۷ <sup>ns</sup>	۰/۰۶۱*	۰/۰۷۰*	-۰/۰۳۴	۰/۴۳۵*		(P)
۰/۰۳۰ <sup>ns</sup>	۰/۰۳۲ <sup>ns</sup>	۰/۰۳۴ <sup>ns</sup>	۰/۰۳۶ <sup>ns</sup>	۰/۰۳۹ <sup>ns</sup>	۰/۰۴۲ <sup>ns</sup>	۰/۰۴۶ <sup>ns</sup>	۰/۰۵۱*	۰/۰۶۹*	۰/۰۷۵*		(Q)
۰/۰۱۸ <sup>ns</sup>	۰/۰۱۸ <sup>ns</sup>	۰/۰۲۰ <sup>ns</sup>	۰/۰۵۴*	۰/۰۲۵ <sup>ns</sup>	۰/۰۲۱ <sup>ns</sup>	۰/۰۲۲ <sup>ns</sup>	۰/۰۲۷ <sup>ns</sup>	۰/۰۲۸ <sup>ns</sup>	۰/۰۴۳ <sup>ns</sup>	-	(CCF)
۰/۰۴۹*	۰/۰۵۳*	۰/۰۵۴*	۰/۰۹۱*	۰/۰۵۴*	۰/۰۶۴*	۰/۰۷۹*	۰/۱۲۲*	۰/۱۵۷*	۰/۱۱۸*	-	

\*: معنی داری در سطح ۵ درصد ns: عدم معنی داری در سطح ۵ درصد

جدول ۲. انتخاب پارامترهای مؤثر در مدل سازی بر اساس GT برای زیرحوضه ها

نام حوضه	ترکیب	ماسک	ضریب گاما	شیب	خطای استاندارد	نسبت V
	P	۰۱۱۱۱۱۱۱	۰/۹۵۲۵۶	-۰/۸۲۷۵۷	۰/۰۴۰۹۳۵	۳/۸۱۰۲
	Pt-1	۱۰۱۱۱۱۱۱	۰/۸۹۷۹۲	۱/۲۰۱۹	۰/۱۲۵۲۷	۳/۵۹۱۷
کارون شمالی	Qt-1	۱۱۱۱۱۰۱۱۱	۰/۴۲۲۸۸	-۰/۲۲۲۳۱	۰/۰۷۹۷۳۴	۱/۶۹۱۵
	Qt-2	۱۱۱۱۱۱۰۱۱	۰/۰۶۹۲۱۹	۰/۲۲۳۶۲	۰/۰۷۹۸۴۸	۰/۲۷۶۸۸
	Qt-4	۱۱۱۱۱۱۱۰	۰/۲۳۴۲۸	۰/۰۰۰۳۲۹۳۵	۰/۱۳۶۰۷	۰/۹۳۷۱۳

جدول ۳. انتخاب ترکیب مناسب در مدل سازی بر اساس GT

نام حوضه	متغیرهای ترکیبی	ماسک	ضریب گاما	شیب	خطای استاندارد	نسبت V
	Pt, Qt-1	۱۰۰۰۰۱۰۰۰	-۱/۸۸۵۷	۹/۷۶۸۹	۰/۱۱۲۲۶	-۷/۵۴۲۹
کارون شمالی	Pt, Pt-1, Qt-1, Qt-2, Qt-3	۱۱۰۰۰۱۱۱۰	-۱/۵۸۷۵	۲/۶۴۴۳	۰/۰۹۰۰۳	-۶/۳۵۰۱

گرفته شد. در نهایت با استفاده از آزمون گاما پارامتری‌هایی که دارای بیشترین میزان آماره گاما بودند به عنوان پارامتر ورودی بهینه انتخاب شدند (جدول ۲).

بر اساس جدول ۳ بارش روز جاری، بارش یک روز قبل دارای تأثیر بسزایی در خروجی هستند، همچنین دبی روز قبل و دو روز قبل دارای بیشترین تأثیر در دبی خروجی حوضه هستند (به دلیل تعیین ترکیب‌های زیاد و در کل تأثیر کم جریان چهار روز قبل در مدل سازی استفاده نشد). بر اساس آزمون گاما بهترین ترکیب که دارای کمترین مقدار آماره گاما و کمترین مقدار خطای استاندارد بود مشخص شد (جدول ۳).

مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان بر

قبل به عنوان مهم‌ترین پارامترها در تعیین ترکیب و ورودی مدل انتخاب می‌شوند. این نتیجه بیانگر این است که بارش بیشتر در حوضه به صورت اثر بر اشباع شدگی، کاهش نفوذپذیری خاک و افزایش رواناب تأثیر خود را نشان می‌دهد. همچنین دبی‌های با تأخیر سه روزه نشان‌دهنده اهمیت بالای دبی پایه و همچنین زمان تمرکز حوضه است. همبستگی متقابل بارش و دبی از تأخیر پنج روزه به بعد درصد سطح معنی داری کمتر دیده می‌شود. به دلیل حجم بالای محاسبات و داده‌ها برای انتخاب پارامترهای بهینه و مدل مناسب از ضرایب خودهمبستگی، خودهمبستگی جزئی و همبستگی متقاطع تا ۵ روز تأخیر برای بارش و دبی جریان استفاده شد. در مجموع برای تعیین ترکیب ورودی بهینه ۹ پارامتر در نظر

و ابزاری مناسب برای مطالعه فرایندهای هیدرولوژیک و ارزیابی منابع آب هستند. در این تحقیق از داده‌های بارندگی و دبی جریان برای شبیه‌سازی فرایند بارش-رواناب استفاده شد. بدین ترتیب، ابتدا تأخیرهای مناسب، پارامترهای مؤثر و ترکیب بهینه ورودی برای مدل‌سازی بارش-رواناب مشخص شد. سپس با استفاده از سناریوهای تعریف شده به مدل‌سازی با استفاده از دو مدل هوش مصنوعی شامل ANN و SVM اقدام شد و با استفاده از سه معیار  $R^2$ ، NSE و RMSE نتایج آنها مورد ارزیابی قرار گرفت. نتایج بیانگر آن بود که بر اساس ضرایب خودهمبستگی، خودهمبستگی جزئی و همبستگی متقابل، ۹ پارامتر بارش روز جاری ( $P_t$ )، بارش با تأخیر یک روز ( $P_{t-1}$ )، دو روز ( $P_{t-2}$ )، سه روز ( $P_{t-3}$ ) و چهار روز ( $P_{t-4}$ ) و همچنین دبی روز قبل ( $Q_{t-1}$ )، دبی با تأخیر دو روز ( $Q_{t-2}$ )، سه روز ( $Q_{t-3}$ ) و چهار روزه ( $Q_{t-4}$ ) دارای سطح معنی‌داری در سطح اطمینان ۵ درصد بودند و بیشترین تأثیر را روی دبی خروجی حوضه داشتند. نتایج آزمون گاما نیز نشان داد که بارش روز جاری ( $P_t$ )، بارش یک و دو روز قبل ( $P_{t-1}$ ،  $P_{t-2}$ ) و دبی روز قبل ( $Q_{t-1}$ ) و دو روز قبل ( $Q_{t-2}$ ) دارای بیشترین تأثیر در مدل‌سازی هستند که با پژوهش‌های انجام شده (۱۲، ۲۸ و ۳۱) مطابقت دارد. مبنای انتخاب ترکیب بهینه در این مطالعه، کمترین مقدار آماره گاما است که در حقیقت این آماره عرض از مبدأ عمودی خط رگرسیون است که در واقع واریانس خطاهای تخمین زده شده در مدل ایجاد شده برای داده‌هاست. از بین ۱۳۰ ترکیب آزمایش شده برای کل حوضه، ترکیب‌های  $P_t$ ،  $P_{t-1}$ ،  $Q_{t-1}$  و  $Q_{t-2}$  مناسب‌ترین ترکیب برای مدل‌سازی انتخاب شدند. بر اساس نتایج حاصل از WinGamma دبی روز قبل و بارش روز جاری دارای قوی‌ترین رابطه با رواناب به جریان آمده در رودخانه هستند. نتایج مدل‌سازی نیز نشان داد که ترکیب  $P_t$ ،  $P_{t-1}$ ،  $Q_{t-1}$  (بارش روز جاری، بارش روز قبل و دبی روز قبل) در هر دو مدل دارای نتایج بهتری است که بیانگر نقش رطوبت پیشین،

اساس سه سناریوی تعریف شده در محیط نرم‌افزار MATLAB R2018b اجرا شدند. نتایج ارزیابی مدل‌ها در سناریوهای مختلف در زیر آمده است (جدول ۴).

با توجه به جدول ۴ ترکیب‌هایی که بارش روز جاری و روز قبل و دبی روز قبل به‌عنوان ورودی مدل بودند دارای عملکرد بهتری هستند. در سناریوی اول، عملکرد ترکیب ۹ بهتر از ترکیب ۸ است که دلیل آن تأثیر بارش روز قبل بر روی رطوبت خاک، میزان نفوذپذیری و افزایش رواناب است. در سناریوی دوم، ترکیب ۳ عملکرد بهتری نسبت به ترکیب ۲ دارد که بیانگر اهمیت دبی روز قبل و بارش روز قبل و روز جاری که شرایط فعلی حوضه آبخیز هستند نقش مهمی در تولید رواناب دارند. در سناریوی سوم نیز عملکرد ترکیب ۱ از ترکیب ۲ بهتر بوده و بیانگر تأثیر بیشتر دبی روز یک روز قبل نسبت به دبی دو روز قبل است. در مجموع عملکرد ترکیب ۳ در بین همه سناریوها و ترکیب‌ها عملکرد بهتری داشته است (شکل ۵).


عملکرد مدل ماشین بردار پشتیبان با سه کرنل مختلف در مرحله آموزش و صحت‌سنجی در جدول ۵ مشاهده می‌شود. بر اساس جدول ۵ ترکیب‌های سناریوهای سه‌گانه مدل ماشین بردار پشتیبان با تابع کرنل پایه شعاعی (RBF) نسبت به کرنل‌های چندجمله‌ای و خطی دارای میزان  $R^2$  و NSE بهتری است. بنابراین می‌توان گفت که تخمین این کرنل نسبت به دو کرنل دیگر دقیق‌تر است. همچنین بین ترکیب‌های مختلف ترکیب ۳ دارای بهترین عملکرد نسبت به سایر ترکیب‌ها است. عملکرد این ترکیب و مقادیر شبیه‌سازی رواناب در شکل ۶ قابل ملاحظه است.

## نتیجه‌گیری

استفاده از روش‌های نوین هوش مصنوعی در شبیه‌سازی فرایند بارش-رواناب برای بررسی خصوصیات سیلاب‌ها قبل از زمان رسیدن به دبی و زمان وقوع اوج متداول شده است. این نوع شبیه‌سازی یکی از روش‌های تخمین رواناب

جدول ۴. نتایج ارزیابی مدل شبکه عصبی مصنوعی در سناریوهای مختلف شبیه‌سازی رواناب


صحت‌سنجی			آموزش			پارامترهای ورودی	تعداد نرون بهینه	تعداد تکرار	ترکیب
RMSE	NSE	R <sup>2</sup>	RMSE	NSE	R <sup>2</sup>				
۰/۰۱۱۴	۰/۷۲	۰/۸۳	۰/۰۱۲۵	۰/۷۸	۰/۸۵	Qt-1	۲۳	۱۳	۱
۰/۰۱۲۱	۰/۷۹	۰/۸۶	۰/۰۱۱۵	۰/۸۱	۰/۸۸	Pt ,Qt-1	۱۴	۱۰	۲
۰/۰۱۰۵	۰/۸۲	۰/۸۹	۰/۰۱۰۲	۰/۸۳	۰/۸۹	Pt ,Pt-1,Qt-1	۱۴	۱۳	۳
۰/۱۶۴	۰/۶۵	۰/۶۹	۰/۱۲۵	۰/۷۰	۰/۷۴	Qt-1 ,Qt-2	۱۲	۱۰	۴
۰/۵۲۱	۰/۶۳	۰/۷۰	۰/۲۱۶	۰/۶۹	۰/۷۲	Qt-1 ,Qt-2 ,Qt-3	۲۲	۲۰	۵
۰/۰۱۴۲	۰/۷۷	۰/۸۴	۰/۰۱۱۲	۰/۸۰	۰/۸۷	Pt ,Pt-1,Qt-1 ,Qt-2	۲۴	۱۲	۶
۰/۲۱۵	۰/۶۲	۰/۶۵	۰/۹۸۴	۰/۶۵	۰/۶۹	Pt ,Pt-1 Pt-2,Qt-1 ,Qt-2	۱۰	۷	۷
۰/۷۰۵	۰/۴۶	۰/۵۱	۰/۱۲۵	۰/۴۸	۰/۵۴	Pt	۱۳	۱۲	۸
۰/۸۱۲	۰/۴۹	۰/۵۳	۰/۵۰۲	۰/۵۱	۰/۵۶	Pt ,Pt-1	۱۲	۱۰	۹
۰/۷۰۱	۰/۵۰	۰/۵۵	۰/۲۸۰	۰/۵۳	۰/۵۹	Pt ,Pt-1 Pt-2,Qt-1 ,Qt-2 ,Qt-3	۲۰	۱۷	۱۰



شکل ۵. مقادیر مشاهداتی و محاسباتی میزان رواناب در حوضه آبخیز کارون شمالی با بهترین ترکیب شبکه عصبی مصنوعی

جدول ۵. نتایج ارزیابی کرنل‌های مختلف مدل ماشین بردار پشتیبان در سناریوهای مختلف شبیه‌سازی بارش - رواناب

ترکیب	کرنل	آموزش			صحت‌سنجی		
		RMSE	NSE	R <sup>2</sup>	RMSE	NSE	R <sup>2</sup>
۱	RBF	۰/۵۳	۰/۵۴	۰/۱۰۲	۰/۴۹	۰/۴۰	۰/۱۰۸
	چند جمله‌ای	۰/۴۰	۰/۴۱	۰/۵۰۳	۰/۳۸	۰/۳۶	۰/۶۱۲
	خطی	۰/۴۱	۰/۳۹	۰/۴۹۵	۰/۳۹	۰/۳۷	۰/۶۰۱
۲	RBF	۰/۷۸	۰/۷۳	۰/۱۲۴	۰/۷۴	۰/۷۰	۰/۲۰۵
	چند جمله‌ای	۰/۷۱	۰/۶۷	۰/۱۲۸	۰/۷۵	۰/۷۰	۰/۲۳۸
	خطی	۰/۶۵	۰/۶۱	۰/۱۳۵	۰/۶۹	۰/۶۸	۰/۲۶۳
۳	RBF	۰/۸۱	۰/۷۸	۰/۰۹۸	۰/۸۳	۰/۷۹	۰/۱۰۸
	چند جمله‌ای	۰/۷۵	۰/۷۳	۰/۰۹۹	۰/۷۶	۰/۷۶	۰/۱۱۶
	خطی	۰/۶۲	۰/۶۲	۰/۱۰۵	۰/۶۵	۰/۶۹	۰/۱۲۵
۴	RBF	۰/۵۱	۰/۴۹	۰/۱۲۰	۰/۴۹	۰/۴۵	۰/۱۸۹
	چند جمله‌ای	۰/۴۹	۰/۴۶	۰/۱۳۴	۰/۴۶	۰/۴۳	۰/۱۹۰
	خطی	۰/۴۴	۰/۴۲	۰/۱۵۶	۰/۴۱	۰/۳۹	۰/۲۰۱
۵	RBF	۰/۴۹	۰/۳۷	۰/۱۱۹	۰/۴۶	۰/۳۵	۰/۱۴۶
	چند جمله‌ای	۰/۴۳	۰/۳۶	۰/۱۱۲	۰/۴۰	۰/۳۴	۰/۱۳۵
	خطی	۰/۴۰	۰/۳۴	۰/۱۰۳	۰/۳۸	۰/۳۰	۰/۱۲۲
۶	RBF	۰/۶۵	۰/۶۱	۰/۰۹۸	۰/۶۲	۰/۵۹	۰/۱۱۹
	چند جمله‌ای	۰/۶۱	۰/۵۸	۰/۱۰۵	۰/۵۸	۰/۵۶	۰/۱۲۸
	خطی	۰/۵۸	۰/۵۰	۰/۱۲۱	۰/۵۶	۰/۴۹	۰/۱۵۱
۷	RBF	۰/۴۸	۰/۴۵	۰/۳۳۵	۰/۴۵	۰/۴۲	۰/۴۴۶
	چند جمله‌ای	۰/۴۵	۰/۴۲	۰/۳۶۸	۰/۴۰	۰/۳۹	۰/۴۸۳
	خطی	۰/۴۲	۰/۳۸	۰/۳۹۵	۰/۳۸	۰/۳۷	۰/۴۹۰
۸	RBF	۰/۴۴	۰/۴۰	۰/۴۴۷	۰/۴۲	۰/۳۷	۰/۴۷۶
	چند جمله‌ای	۰/۴۱	۰/۳۶	۰/۴۸۵	۰/۳۹	۰/۳۴	۰/۴۹۰
	خطی	۰/۳۹	۰/۳۳	۰/۴۹۸	۰/۳۶	۰/۳۲	۰/۵۱۰
۹	RBF	۰/۴۶	۰/۴۳	۰/۳۰۰	۰/۴۳	۰/۴۰	۰/۳۵۸
	چند جمله‌ای	۰/۴۳	۰/۴۰	۰/۳۲۴	۰/۴۰	۰/۳۷	۰/۳۶۵
	خطی	۰/۴۰	۰/۳۴	۰/۳۳۵	۰/۳۸	۰/۳۳	۰/۳۷۰
۱۰	RBF	۰/۴۲	۰/۳۹	۰/۴۷۰	۰/۴۰	۰/۳۶	۰/۴۸۵
	چند جمله‌ای	۰/۴۰	۰/۳۷	۰/۵۱۰	۰/۳۷	۰/۳۴	۰/۵۳۲
	خطی	۰/۳۶	۰/۳۳	۰/۵۸۶	۰/۳۳	۰/۳۰	۰/۶۰۱



شکل ۶. مقادیر مشاهداتی و محاسباتی میزان رواناب و عملکرد کرنل RBF مدل ماشین بردار پشتیبان

کارایی بهتر مدل شبکه عصبی مصنوعی نسبت به مدل ماشین بردار پشتیبان با تابع کرنل پایه شعاعی (RBF) است که با نتایج (۱، ۵ و ۳۳) مطابقت ندارد. نتایج این مطالعه می‌تواند در تصمیم‌گیرهای مدیریت صحیح منابع آب به‌خصوص جریان‌های سطحی، مطالعه مربوط به حساسیت سیلاب و هشدار سیل، انتخاب مدل بهینه برآورد رواناب ناشی از باران و مطالعات مربوط به مهندسی رودخانه و طراحی سازه‌ها به‌کار گرفته شود.

اشباع‌شدگی خاک و در نتیجه تأثیر روی نفوذپذیری و ایجاد رواناب است. همچنین با در نظر گرفتن بارش و دبی جریان در این ترکیب می‌توان نتیجه گرفت که با لحاظ کردن دبی روز قبل در ترکیب ورودی ویژگی مارکوفی و اتورگرسیو رواناب به‌طور دقیقی در نظر گرفته شده است که با نتایج (۸، ۱۲ و ۲۶) مطابقت دارد. در مجموع در مدل ماشین بردار پشتیبان تابع کرنل پایه شعاعی (RBF) نسبت به کرنل‌های چندگانه و خطی دارای عملکرد بهتری است. نتایج ارزیابی در دو مدل نیز بیانگر

### منابع مورد استفاده

1. Akhoni Pourhosseini, F. and S. Darbandi. 2018. Sofichay river runoff modeling using support vector machine and artificial neural network. *Journal of Watershed Management Research* 9(17): 57-66. (In Farsi).
2. ASCE Task Committee. 2000. Artificial neural networks in hydrology, II: Hydrology application. *Journal of Hydrologic Engineering* 5: 124-137.
3. Botsis, D., P. Latinopoulos and K. Diamantaras. 2011. Rainfall-runoff modeling using support vector regression and artificial neural networks. 12th International Conference on Environmental Science and Technology (CEST2011), Rhodes, Greece, 8-10 September.
4. Chandwani, V., S. K. Vyas, V. Agrawal and G. Sharma. 2015. Soft computing approach for rainfall-runoff modelling: A review. *Aquatic Procedia* 4: 1054-1061.
5. Choubey, V., S. Mishra and S. K. Pandey. 2014. Time series data mining in real time surface runoff forecasting through support vector machine. *International Journal of Computer Applications* 98(3): 23-30.
6. Chua, L. H. C. and T. S. W. Wong. 2010. Improving event-based rainfall-runoff modeling using a combined artificial neural network-kinematic wave approach. *Journal of Hydrology* 390: 92-107.
7. Cristianini, N. and J. Shawe-Taylor. 2000. An Introduction to Support Vector Machines. Cambridge University Press, New York.
8. Dastorani, M. T., H. Sharifi Darani, A. Talebi and A. Moghadamnia. 2011. Evaluation of the application of artificial

- neural networks and adaptive neuro-fuzzy inference systems for rainfall-runoff modelling in zayandehrood dam basin. *Journal of Water and Wastewater* 4: 114-125. (In Farsi).
9. Dawson, C. W. and R. L. Wilby. 2001. Hydrological modelling using artificial neural networks. *Progress in Physical Geography* 25(1): 80-108.
  10. Dehghani, N., M. Vafakhah and A. Bahremand. 2016. Rainfall-runoff modeling using artificial neural network and neuro-fuzzy inference system in Kasilian watershed. *Journal of Watershed Management Research* 7(13): 128-137. (In Farsi).
  11. Durrant P. J. 2001. Win-GammaTM: A non-linear data analysis and modeling tool with applications to flood prediction. Ph.D. Thesis, Department of Computer Science, Cardiff University, Wales, UK.
  12. Ghaderi, K., B. Motamedvaziri and P. Mahmudi. 2016. Simulation of rainfall-runoff process using artificial neural network in Kurkursar watershed, Nowshahr. First International Comprehensive Competition Conference on Engineering Sciences in Iran. September, 2016, Anzali-Iran, 1-13. (In Farsi).
  13. Ghorbani, M. A., A. Azani and L. Naghipour. 2016. Comparison of the performance of support vector machine with other intelligent techniques to simulate rainfall-runoff process. *Journal of Watershed Management Research* 7(13): 92-103. (In Farsi).
  14. Harun, S., N. I. Ahmat and A. H. M. Kassim. 2002. Artificial neural network model for rainfall runoff relationship. *Journal Technology* 37(B): 1-12.
  15. Hosseini, S. M. and N. Mahjouri. 2016. Integrating support vector regression and a geomorphologic artificial neural network for daily rainfall-runoff modeling. *Applied Soft Computing* 38: 329-345.
  16. Jones, A. J., A. Tsui and A. G. De Oliveira. 2002. Neural models of arbitrary chaotic systems: construction and the role of time delayed feedback in control and synchronization. *Complexity International* 9: 1-9.
  17. Jones, A. J., S. Margetts and P. Durrant. 2001. The WinGamma User Guide. University of Wales, Cardiff.
  18. Kemp, S. E., I. D. Wilson and J. A. Ware. 2004. A Tutorial on the Gamma test. *International Journal of Simulation: Systems, Science and Technology* 6(1-2): 67-75.
  19. Kerem, H. 2006a. Generalized regression neural network in modeling river sediment yield. *Advance in Engineering Software* 37: 63-68.
  20. Khoshhal, J., S. M. Hoseini and F. Fateminia. 2013. Simulation of rainfall-runoff using artificial neural networks (ANNs) (Case study: Faridan watershed). *Geography and Environmental Planning Journal* 51(3): 25-40. (In Farsi).
  21. Koncar, N. 1997. Optimisation methodologies for direct inverse neurocontrol. Ph.D. Thesis, Department of Computing, University of London, London, England.
  22. Kumari, P., P. Kumar and P. V. Singh. 2018. Rainfall-runoff modelling using artificial neural network and adaptive neuro-fuzzy inference system. *Indian Journal of Ecology* 45(2): 281-285.
  23. Misra, D., T. Oommen, A. Agarwal and S. K. Mishra. 2009. Application and analysis of support vector machine based simulation for runoff and sediment yield. *Biosystems Engineering* 103: 527-535.
  24. Mollaei, Z., J. Zahiri, S. Jalili, M. R. Ansari and A. Taghizadeh. 2018. Estimating suspended sediment concentration using remote sensing and artificial neural network (case study: Karun river). *Journal of Water and Soil Science (Science and Technology of Agriculture and Natural Resources)* 22(2): 249-259. (In Farsi).
  25. Nourani, V. 2017. An emotional ANN (EANN) approach to modeling rainfall-runoff process. *Journal of Hydrology* 544: 267-277.
  26. Nourani, V. and M. Komasi. 2013. A geomorphology-based ANFIS model for multi-station modeling of rainfall-runoff process. *Journal of Hydrology* 490: 41-55.
  27. Partovyan, A., V. Nourani and M. T. Alami. 2018. Noise injection- denoising techniques to improve artificial intelligence-based rainfall- runoff modeling. *Water Engineering* 11(36): 81-94. (In Farsi).
  28. Sharifi, A. R., Y. Dinpashoh, A. Fakheri-Fard and A. R. Moghaddamnia. 2013. Optimum combination of variables for runoff simulation in Amameh watershed using gamma test. *Water and Soil Science* 23(4): 59-72. (In Farsi).
  29. Shrif Garmdareh, E., M. Vafakhah and S. Eslamian. 2019. Assessment the performance of support vector machine and artificial neural network systems for regional flood frequency analysis (A case study: Namak lake watershed). *Journal of Water and Soil Science (Science and Technology of Agriculture and Natural Resources)* 23(1): 351-366. (In Farsi).
  30. Simonovic, S. P. and S. Ahmad. 2005. An artificial neural network model for generating hydrograph from hydro-meteorological parameters. *Journal of Hydrology* 315: 236-251.
  31. Singh, V. K., P. Kumar and B. P. Singh. 2016. Rainfall-runoff modeling using artificial neural networks (ANNs) and multiple linear regression (MLR) techniques. *Indian Journal of Ecology* 43(2): 436-442.
  32. Tsui, A. P. M. 1999. Smooth data modelling and stimulus-response via stabilization of neural chaos, Ph.D. Thesis, Department of Computing, University of London, London, England.
  33. Yu, P. S., S. T. Chen and I. F. Chang. 2006. Support vector regression for real-time flood stage forecasting. *Journal of Hydrology* 328: 704-716.