

## پیش بینی ضریب رواناب رگبار با استفاده از شبکه عصبی مصنوعی در حوزه آبخیز بار اریه

### نیشابور

مینا جعفری<sup>۱</sup>، مهدی وفاخواه<sup>۲</sup>، هیراد عبقری<sup>۳</sup>، احد توسلی<sup>۴</sup>  
تاریخ دریافت: ۱۳۹۰/۴/۱۶ تاریخ پذیرش: ۱۳۹۰/۱۲/۱۷

### چکیده

از دیرباز معادله‌های متنوعی برای تعیین رواناب به منظور مدیریت منابع آب توسط پژوهش‌گران ارائه شده که کاربرد گسترده‌ای در علوم هیدرولوژی دارند. در پژوهش حاضر با بهره‌گیری از داده‌های مشاهده‌ای کاربرد شبکه عصبی مصنوعی در برآورد ضریب رواناب بررسی شد. منطقه مورد مطالعه حوزه آبخیز بار اریه نیشابور بود. داده‌های مربوط به ۳۳ واقعه بارش-رواناب اتفاق افتاده در بین سال-های آماری ۱۳۳۱ تا ۱۳۸۵ جمع آوری گردید. از جمله خصوصیات که از باران‌نمودها به عنوان متغیرهای مستقل ورودی مدل استخراج شد شامل شدت متوسط بارش، مقدار متوسط بارش، چارک-های اول تا چهارم مقدار بارش، چارک‌های اول تا چهارم شدت بارش، مجموع بارش پنج روز قبل و شاخص فی بود. با استفاده از این پارامترها و ترکیبات مختلف آن‌ها در لایه ورودی، شبکه‌های مختلف اجرا شد. شبکه عصبی مصنوعی مورد استفاده با الگوریتم یادگیری لونیگ مارکوارت و تابع انتقال تانژانت هیپربولیک آموزش دیده و با ورودی‌های مختلف اجرا شد. نتایج نشان داد که شبکه با ورودی چارک‌های اول تا چهارم شدت بارندگی، مدت و مقدار بارندگی، شاخص (Φ) و بارش پنج روز قبل با تابع انتقال تانژانت هیپربولیک می‌تواند ضریب رواناب رگبار را با ضریب تبیین تست ۰/۹۸ و جذر میانگین مربعات خطای ۰/۰۳۳۷ و متوسط قدر مطلق خطا ۰/۰۲۷۵ پیش‌بینی کند.

**واژه‌های کلیدی:** حوزه آبخیز بار اریه نیشابور، تابع تانژانت هیپربولیک، شبکه عصبی مصنوعی، ضریب رواناب.

<sup>۱</sup> دانش‌آموخته کارشناسی ارشد آبخیزداری، دانشکده منابع طبیعی دانشگاه تربیت مدرس

<sup>۲</sup> استادیار گروه مهندسی آبخیزداری، دانشکده منابع طبیعی دانشگاه تربیت مدرس، Vafakhah@modares.ac.ir

<sup>۳</sup> استادیار گروه مهندسی آبخیزداری، دانشکده منابع طبیعی دانشگاه ارومیه

<sup>۴</sup> دانش‌آموخته کارشناسی ارشد، دانشکده منابع طبیعی دانشگاه تربیت مدرس

## مقدمه

(پنهان) که عمل پردازش اطلاعات را بر عهده دارند و لایه خروجی که علاوه بر پردازش به ازای بردار ورودی شبکه، خروجی آن را نشان می‌دهد [۶].

Tokar و Johnson (۱۹۹۹)، به منظور بررسی حساسیت دقت پیش‌بینی مدل شبکه عصبی مصنوعی به حجم داده و طول آموزش، از بارش متاثر از بارش روزانه، دما و ذوب برف استفاده نموده‌اند. همچنین مقایسه‌ای بین نتایج ANN و روش‌های کلاسیک صورت گرفت و نشان داد در شرایط یکسان، شبکه عصبی با کاهش طول داده‌ها و صرف زمان کمتر مقادیر واقعی‌تری را پیش‌بینی می‌کند [۲۶]. Tokar و Markus (۲۰۰۰) شبکه عصبی مصنوعی و یک مدل مفهومی را برای پیش‌بینی رواناب در حوضه‌هایی با ویژگی‌های فیزیکی و اقلیمی متفاوت به‌کار بستند. از مقایسه نتایج دو روش مشخص شد که در همه موارد شبکه دقت و سرعت بیشتر و زمان تمام شده کمتری دارد، و در شبیه‌سازی بارش-رواناب با بازه‌های زمانی متفاوت توانا تر از روش مفهومی است [۲۷]. Elshorbagy و همکاران (۲۰۰۰)، در تحقیقی پنج پارامتر شاخص بارندگی پیشین، شاخص ذوب برف، بارندگی زمستانه، بارندگی بهاره و زمان را در توسعه هیدروگراف واحد به عنوان ورودی‌های شبکه پیشخور با الگوریتم پس انتشار خطا در رودخانه سرخ ایالات مانیتوبای کانادا در نظر گرفتند. نتایج نشان داد که درصد خطا بین مقادیر تخمینی و مشاهده‌ای مربوط به جریان حداکثر و زمان حداکثر به ترتیب ۶ و ۳/۶ درصد است و همبستگی بین این مقادیر به

تخمین و پیش‌بینی رواناب و دبی سیلاب یکی از عوامل مهم و موثر در مدیریت بهینه منابع آب است. یکی از پارامترهای اساسی در برآورد رواناب ضریب رواناب است. به سبب دشواری و پیچیدگی مسایل مربوط به این پدیده، از سوی متخصصان روش‌ها و الگوهای مختلفی ارائه شده است. شبکه‌های عصبی مصنوعی<sup>۱</sup> یکی از دستاوردهایی هستند که با الگوبرداری از شبکه عصبی مغز انسان، قادرند پدیده‌های پیچیده و ناشناخته را به خوبی بررسی نمایند [۶] [۷]. به باور بیشتر پژوهشگران شبکه عصبی مصنوعی به دو دلیل عمده در بررسی مسایل ناشناخته و پیچیده، عملکرد خوبی دارد: اول اینکه با برخورداری از قابلیت تشخیص الگو، رابطه خوبی بین ورودی و خروجی داده‌ها برقرار می‌کند. همچنین در قیاس با دیگر الگوها، حساسیت کمتری نسبت به وجود خطا در اطلاعات ورودی نشان می‌دهد [۶] [۱۴]. علت این امر پردازش توزیعی اطلاعات در آن است. به طوری که عمل پردازش موازی صورت می‌گیرد و به جای اینکه تمام بار محاسبه به یک واحد پردازشگر تحمیل شود، تعداد زیادی از واحدها همزمان وارد عمل شده و در صورت وجود خطا در یکی از آنها تأثیر منفی بسیاری در عملکرد شبکه و خروجی آن نخواهد داشت [۶].

ساختار کلی ANN از سه لایه با وظایف مجزا تشکیل شده است. لایه ورودی با نقش توزیع داده‌ها در شبکه، لایه یا لایه‌های میانی

<sup>1</sup> Artificial Neural Network (ANN)

زارع‌ایبانه و بیات‌ورکشی (۱۳۹۰)، در تحقیقی به ارزیابی مدل‌های هوشمند عصبی و تجربی در تخمین روان‌آب سالانه در حوزه زاینده‌رود پرداختند. پارامترهای ورودی شبکه عصبی مصنوعی شامل متوسط بارش سالانه، متوسط دمای هوا، دمای حداکثر و حداقل هوا بود. نتایج نشان داد شبکه عصبی مصنوعی و شبکه عصبی-فازی از دقت مناسبی در برآورد روان-آب نسبت به روش‌های تجربی دی‌سوزا، تورک و کوتاین برخوردار است [۵] هدف این پژوهش بررسی کارآمدی شبکه‌های عصبی مصنوعی در پیش‌بینی ضریب رواناب رگبار با استفاده از تابع تانژانت هیپربولیک است. به این منظور حوزه آبخیز بار اریه نیشابور انتخاب و داده‌های مربوط به ۳۳ واقعه جمع‌آوری شد.

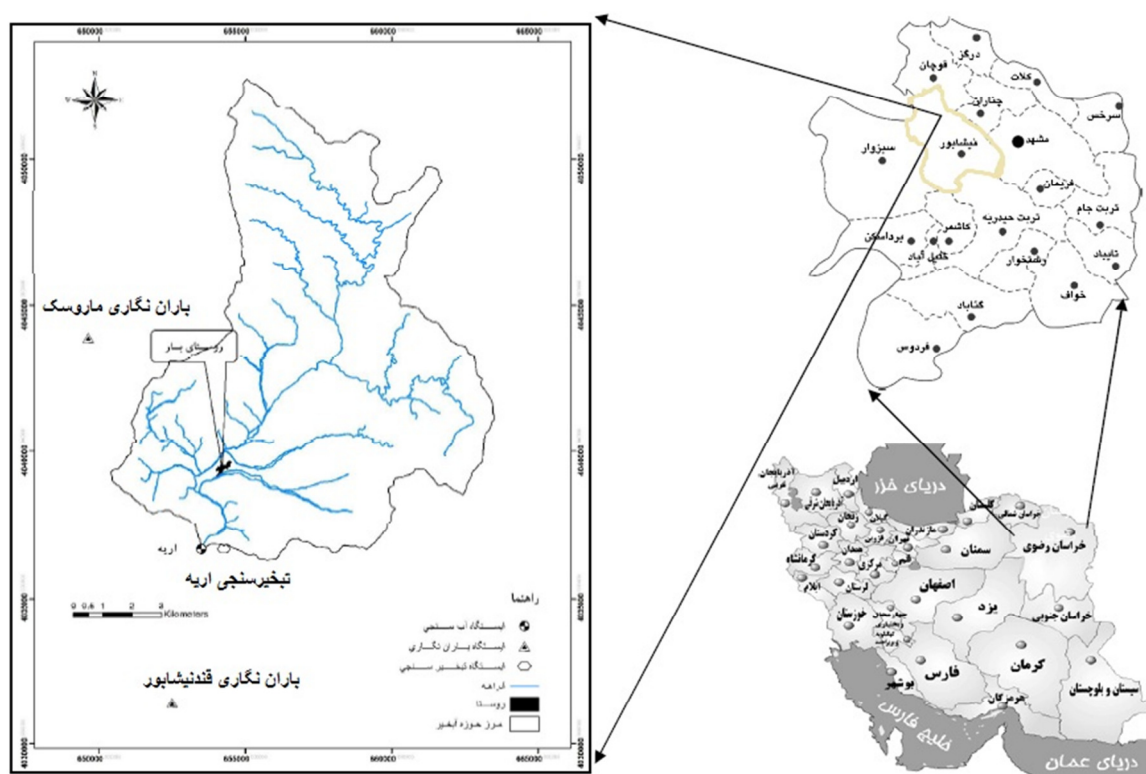
### مواد و روش‌ها

#### خصوصیات منطقه مورد مطالعه

حوزه آبخیز بار- اریه نیشابور به مساحت ۱۱۳۸۸ هکتار در جنوب غربی سلسله جبال بینالود در ۸۲ کیلومتری شمال غربی مشهد قرار گرفته است. این منطقه حد واسط ۳۸" ۲۷' ۳۶° تا ۳۲" ۳۶' ۳۶° عرض شمالی و ۴۶" ۴۰' ۵۸° تا ۳۱" ۴۹' ۵۸° طول شرقی قرار دارد. متوسط ارتفاع حوزه آبخیز بار ۲۲۲۶ متر و در محل ایستگاه هیدرومتری ۱۵۶۰ متر می‌باشد. محیط حوزه آبخیز ۵۴ کیلومتر و شیب متوسط آن ۱۱/۹ درصد محاسبه گردیده است. آب و هوای منطقه نیمه خشک و متوسط درجه حرارت آن ۵/۴ درجه سانتی‌گراد و میزان متوسط بارندگی سالانه آن

ترتیب ۰/۹۹ و ۰/۸۸ می‌باشد [۱۶]. Anctil و همکاران (۲۰۰۴)، با مقایسه نتایج ANN و یک مدل مفهومی در پیش‌بینی سیل، شبکه پرسپترون چند لایه را بهتر ارزیابی کردند [۱۰]. Maria و همکاران (۲۰۰۵)، برای پیش-بینی بارش در منطقه سائوپائولو در برزیل از شبکه عصبی مصنوعی پیشخور با الگوریتم یادگیری resilient و یک مدل رگرسیون خطی استفاده کردند. نتایج حاصل نشان داد که پیش‌بینی شبکه عصبی مصنوعی نسبت به آنچه که توسط مدل رگرسیون خطی به دست آمده بود برای مجموعه‌های عملیاتی مناسب‌تر است. [۲۰]. Solaimani (۲۰۰۹)، جهت پیش‌بینی و مدل‌سازی بارش-رواناب در حوزه-آبخیز جراحی واقع در منطقه نیمه خشک ایران از شبکه عصبی مصنوعی با پرسپترون چند لایه و کاربرد و مقایسه الگوریتم‌های مختلف استفاده کرد. نتایج حاصل از مطالعه نشان داد که روش شبکه عصبی مصنوعی برای پیش‌بینی رواناب مناسب‌تر و کاراتر از روش کلاسیک رگرسیونی است [۲۴]. Yilmaz و همکاران (۲۰۱۱)، به تخمین جریان رودخانه با استفاده از شبکه عصبی مصنوعی پرسپترون چند لایه در حوزه کوهستانی رودخانه فرات پرداختند. آن‌ها به منظور تعیین بهترین مجموعه از داده‌ها، ۴ مدل با ورودی‌های مختلف را اجرا کردند و در نهایت به این نتیجه رسیدند که مدل چهارم با ورودی‌های مقدار بارش، دمای هوا، سرعت باد و میزان رطوبت هوا دارای کم‌ترین میزان خطا و بیش‌ترین میزان ضریب تعیین ( $R^2$ ) در شبیه‌سازی روان-آب حاصل از ذوب برف داشته است [۲۹].

۳۳۰/۴ میلی متر است. متوسط دبی آن ۰/۶۶ متر مکعب بر ثانیه می باشد [۱].



شکل ۱- موقعیت منطقه مورد مطالعه در ایران و استان

بارش، شدت متوسط بارش، شاخص ( $\Phi$ )، بارش پنج روز قبل، بارش کل، چارکهای شدت بارش و چارکهای مقدار بارش از هیتوگرافها و ضریب رواناب رگبار از هیدروگراف استخراج گردید (جدول ۱).

### روش تحقیق

به منظور تکمیل بانک اطلاعاتی کلیه هیدروگرافها و هیتوگرافها طی سالهای ۱۳۳۰ تا ۱۳۸۵ از سازمان آب منطقهای خراسان تهیه و در نهایت ۳۳ واقعه بارش- رواناب انتخاب گردید. سپس متغیرهای مدت

جدول ۱- مشخصه های آماری متغیرها

ردیف	نام متغیر	میانگین	انحراف معیار	حداکثر	حداقل
۱	چارک ۱ شدت بارندگی (میلی متر بر ساعت)	۲/۵۰۷	۲/۵۲۴	۱۲/۱	۰/۳
۲	چارک ۲ شدت بارندگی (میلی متر بر ساعت)	۱/۸۹۶	۱/۷۵۰	۸/۲	۰/۴
۳	چارک ۳ شدت بارندگی (میلی متر بر ساعت)	۱/۵۸۸	۱/۲۸۰	۵/۰	۰/۰
۴	چارک ۴ شدت بارندگی (میلی متر بر ساعت)	۱/۲۷۴	۱/۱۴۰	۶/۱	۰/۱
۵	شدت متوسط بارندگی کل (میلی متر بر ساعت)	۱/۷۹۰	۱/۱۴۹	۵/۵۵	۰/۱۷
۶	چارک ۱ مقدار بارندگی (میلی متر)	۳/۳۱۴	۳/۰۶۹	۱۵/۵	۰/۴
۷	چارک ۲ مقدار بارندگی (میلی متر)	۲/۵۲۱	۲/۳۲۲	۹/۴	۰/۴

۰/۰	۹/۵	۱/۸۷۸	۲/۰۹۴	چارک ۳ مقدار بارندگی (میلی متر)	۸
۰/۲	۵/۲	۱/۳۵۴	۱/۶۷۷	چارک ۴ مقدار بارندگی (میلی متر)	۹
۲/۳	۳۱/۴	۶/۱۷۴	۹/۶۰۶	مقدار متوسط بارندگی کل (میلی متر)	۱۰
۰/۸	۱۸/۶	۴/۲۲۲	۴/۶۹۸	شاخص $\Phi$ (میلی متر بر ساعت)	۱۱
۰/۰	۶۴/۲	۱۳/۵۰۳	۱۰/۲۵۱	بارش ۵ روز قبل (میلی متر)	۱۲
۰/۶	۴۵/۷۴	۹/۲۵۱	۱۰/۴۷۷	ضریب روان آب (درصد)	۱۳

مورد استفاده قرار گرفته‌اند، از نوع الگوریتم پس انتشار هستند [۱۲] [۱۳]. بنابراین در این تحقیق از شبکه عصبی پرسپترون چندلایه با یک لایه پنهان برای پیش‌بینی ضریب رواناب استفاده گردید.

### مرحله طراحی شبکه

**تقسیم‌بندی داده‌ها:** شبکه عصبی مصنوعی برای طراحی، نیازمند سه دسته داده آموزشی<sup>۱</sup>، صحت‌سنجی<sup>۲</sup> و آزمایش<sup>۳</sup> می‌باشد. در این تحقیق ۷۰ درصد داده‌ها برای آموزش شبکه، ۱۵ درصد برای صحت‌سنجی و ۱۵ درصد دیگر برای اعتبارسنجی در نظر گرفته شد. برای طراحی شبکه عصبی از روش اعتباردهی مقطعی بهره گرفته شد. در این تحقیق انتخاب تعداد مناسب نرون‌ها در لایه میانی و تعداد تکرار مطلوب براساس مقایسه شاخص‌های میانگین مربعات خطا<sup>۴</sup> (MSE) و ضریب تبیین<sup>۵</sup> در آزمون ترکیب‌های متفاوت صورت گرفت. در روش اعتبارسنجی متقاطع<sup>۶</sup> طراحی شبکه بر مبنای حداکثرسازی کارایی و

### شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی از انواع مدل‌های محاسباتی هستند که قادرند رابطه میان ورودی‌ها و خروجی‌های یک سیستم فیزیکی (هرچند پیچیده و غیر خطی) را توسط شبکه-ای از گره‌ها که همگی به هم متصل هستند، تعیین نمایند. از مهم‌ترین عوامل تعریف شبکه‌های عصبی مصنوعی به نحوه معماری آن می‌توان اشاره کرد. ساختار شبکه‌های عصبی مصنوعی که به آن معماری اطلاق می‌گردد، به شکلی است که نرون‌ها در دسته‌هایی که لایه نام دارند، مرتب می‌شوند. معماری معمول شبکه‌های عصبی مصنوعی متشکل از سه لایه است: لایه ورودی که داده‌ها را در شبکه توزیع می‌کند، لایه پنهان که داده‌ها را پردازش می‌کند و لایه خروجی که نتایج را به ازای ورودی‌های مشخص، استخراج می‌کند. یک شبکه می‌تواند چندین لایه پنهان داشته باشد. ولی تحقیقات تئوریک انجام گرفته در این زمینه نشان داده‌اند که یک لایه پنهان برای این‌گونه مدل‌ها می‌تواند هر تابع پیچیده و غیرخطی را تقریب زند [۱۵] [۱۷] [۳۰] همچنین نتایج تجربی و عملی نیز این موضوع را تایید می‌کنند [۳۰] [۱۸] [۸] براساس پژوهش‌های انجام شده، ۹۰ درصد شبکه‌های عصبی مصنوعی که در مسایل هیدرولوژی

<sup>1</sup> Training

<sup>2</sup> Validation

<sup>3</sup> Test

<sup>4</sup> Mean Squared Error

<sup>5</sup> Determination Coefficient

<sup>8</sup> Cross Validation

<sup>9</sup> Hyperbolic Tangent

<sup>10</sup> Root Mean Squared Error

$R^2$ ، کمترین مقدار مجذور میانگین مربعات  
خطا (RMSE)  $\hat{y}$  و متوسط قدر مطلق خطا  
(MAE)  $\hat{y}$  می باشد، که در زیر ارائه شده است:

$$R^2 = 1 - \frac{\sum_{i=0}^n (y_o - y_f)}{\sum_{i=0}^n y_o^2 - \frac{\sum y_f^2}{n}} \quad \dots (2)$$

$$MAE = \frac{\sum_{i=0}^n |y_o - y_f|}{n} \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{i=0}^n (y_o - y_f)^2}{n}} \quad (4)$$

در رابطه بالا  $y_o$  و  $y_f$  به ترتیب اندازه مشاهده  
ای و برآورد شده پارامتر مورد نظر با شبکه و  $n$   
تعداد کل داده های استفاده شده است.

### نتایج و بحث

به منظور بررسی عملکرد، شبکه مورد استفاده  
په ازای تعداد نرون های متفاوت در لایه میانی  
مورد ارزیابی قرار گرفت که مشخص گردید  
برای شبکه با تابع تانژانت هیپربولیک با تعداد  
۱۵ نرون در لایه میانی از کمترین مقدار  
میانگین مربعات خطا (۰/۰۰۸۰۸) برخوردار  
است (شکل ۲). البته این مرحله به ازای لایه  
های دوم و سوم میانی نیز به اجرا درآمد که  
بهبودی چشمگیری در عملکرد شبکه مشاهده  
نگردید.

عملکرد آن صورت می گیرد. آموزش، زمانی  
متوقف می شود که خطای صحت سنجی به  
حداقل میزان ممکن کاهش یابد. در این روش،  
به منظور کاهش بیشتر خطای صحت سنجی،  
داده هایی که نسبت به سایر داده ها پرت باشند  
با داده های آموزشی جابجا می شود. در این  
روش انتخاب اجزای فنی شبکه، بر مبنای  
کمترین خطا و بیشترین ضریب همبستگی در  
مرحله آزمون صورت می گیرد. اولین قدم در  
معماری یک شبکه، انتخاب قانون یادگیری  
مناسب می باشد که در این پژوهش از قوانین  
یادگیری Levenberg-Marqwart استفاده  
شده است [۱۹]. از این رو برای شبیه سازی  
ضریب رواناب شبکه پرسپترون چند لایه با  
الگوریتم پس انتشار خطا برگزیده شد که در  
محیط نرم افزار Matlab اجرا گردید. تابع  
غیرخطی تانژانت هیپربولیک به عنوان توابع  
انتقال شبکه مورد استفاده قرار گرفت.


### تابع تانژانت هیپربولیک<sup>۱</sup>

یک تابع فرد و نامتقارن است که تجربه نشان  
داده آموزش شبکه را زودتر به نتیجه می-  
رساند.

$$F(x) = a \times \tanh(bx) \quad \dots (1)$$

در رابطه بالا پارامتر  $a$  شیب است که با تغییر  
آن می توان تابع های مختلفی را بدست آورد. به  
طوری که با افزایش آن به تابع آستانه و با  
کاهش آن تا بی نهایت به تابع پله ای می رسد.  
مبنای تصمیم گیری برای انتخاب بهترین  
شبکه در هر بار اجرای برنامه، ضریب تبیین


<sup>11</sup>Mean Absolute Error



شکل ۲- مقدار خطای شبکه با تابع تانژانت هیپربولیک به ازای تعداد نرون لایه میانی

هم تابع تانژانت هیپربولیک نشان داد که شبکه با ۲۰۰ تکرار مناسب ترین پیش بینی را ارائه می دهد (شکل ۳).

برای تعیین اثر تعداد تکرارهای آموزش در عملکرد شبکه، کاربرد شبکه‌هایی با تکرارهای متفاوت هم برای تابع سیگموئید و



شکل ۳- مقدار خطای شبکه به ازای تعداد تکرارها در مرحله آموزش

مختلفی از ورودی‌ها با توجه به ماهیت و نقش هیدرولوژیکی آنها تعیین شده و بر اساس آن ساختارهای مختلف تعریف و شبکه‌ها اجرا شد. دو حالت از ترکیب‌های مختلف ورودی‌ها در جداول ۲ و ۳ قابل مشاهده است.

**تعیین ترکیب‌های مختلفی از ورودی‌ها برای ساخت شبکه**

از آنجایی که متغیرهای انتخاب شده با ترکیب‌های متفاوت در لایه ورودی منجر به تغییر در عملکرد شبکه می‌شود. لذا ترکیبات

جدول ۲ - ترکیب ورودی‌های مختلف برای شبکه، حالت اول

شماره شبکه	ورودی شبکه	شماره شبکه	ورودی شبکه	شماره شبکه	ورودی شبکه	شماره شبکه	
۱	شدت متوسط بارش	۵	چارک‌های شدت بارش	۹	مقدار متوسط بارش	۱۳	چارک‌های مقدار بارش
۲	شدت متوسط بارش شاخص فی	۶	چارک‌های شدت بارش شاخص فی	۱۰	مقدار متوسط بارش شاخص فی	۱۴	چارک‌های مقدار بارش شاخص فی
۳	شدت متوسط بارش شاخص فی بارش ۵ روز قبل	۷	چارک‌های شدت بارش شاخص فی بارش ۵ روز قبل	۱۱	مقدار متوسط بارش شاخص فی بارش ۵ روز قبل	۱۵	چارک‌های مقدار بارش شاخص فی بارش ۵ روز قبل
۴	شدت متوسط بارش بارش ۵ روز قبل	۸	چارک‌های شدت بارش بارش ۵ روز قبل	۱۲	مقدار متوسط بارش بارش ۵ روز قبل	۱۶	چارک‌های مقدار بارش بارش ۵ روز قبل

جدول ۳ - ترکیب ورودی‌های مختلف برای شبکه حالت دوم


شماره شبکه	ورودی شبکه	شماره شبکه	ورودی شبکه	شماره شبکه	ورودی شبکه	شماره شبکه	
۱۷	چارک‌های شدت بارش شاخص فی مقدار متوسط بارش	۱۹	چارک‌های شدت بارش مدت بارش شاخص فی مقدار متوسط بارش	۲۱	چارک‌های مقدار بارش شدت متوسط بارش بارش ۵ روز قبل شاخص فی	۲۳	شدت متوسط بارش شاخص فی بارش ۵ روز قبل مدت بارش
۱۸	چارک‌های مقدار بارش بارش ۵ روز قبل شاخص فی شدت متوسط بارش مدت بارش	۲۰	مدت بارش شاخص فی مقدار متوسط بارش شدت متوسط بارش بارش ۵ روز قبل	۲۲	چارک‌های شدت بارش مدت بارش شاخص فی مقدار متوسط بارش بارش ۵ روز قبل	۲۴	چارک‌های شدت بارش مدت بارش شاخص فی بارش ۵ روز قبل چارک‌های مقدار بارش

### معیارهای ارزیابی

برای مقایسه نتایج خروجی، ۳ معیار آماری متداول استفاده شد که عبارتند از: ضریب تبیین ( $R^2$ )، جذر میانگین مربعات خطا (RMSE)، متوسط قدر مطلق خطا (MAE). بهترین عملکرد مدل بر اساس معیار  $R^2$ ، مقدار یک و بر اساس سایر معیارها مقدار صفر را به

همراه دارد که نشان‌دهنده نزدیکتر بودن مقادیر مشاهده شده و پیش‌بینی شده به یکدیگر و دقیق‌تر بودن جواب‌ها در هر مرحله است. مقایسه کل شبکه‌های اجرا شده بر اساس مقدار RMSE در شکل ۴ نشان داده شده است.





شکل ۴- مقایسه شبکه‌های اجرا شده با تابع تانژانت هیپربولیک از نظر مقدار RMSE در مرحله آزمایش

سنجی و آزمایش با متغیرهای لایه ورودی شبکه در جدول ۴ آمده است.


مطابق با شکل ۴ شبکه شماره ۲۲ دارای حداقل مقدار RMSE است. ارزیابی عملکرد این شبکه برای هر سه مرحله آموزش، صحت-

جدول ۴- عملکرد شبکه عصبی مصنوعی برتر در هر سه مرحله آموزش، صحت‌سنجی و آزمایش

آموزش		صحت‌سنجی		آزمایش			متغیرهای ورودی	معماری شبکه	شماره شبکه
RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	MAE	RMSE	R <sup>2</sup>			
۰/۰۰۸۲۸	۰/۹۹	۰/۰۰۲۳۶	۰/۹۹	۰/۰۲۷۵	۰/۰۳۳۷	۰/۹۸	چارک‌های شدت بارش	۸-۱۵-۱	۲۲
							بارش ۵ روز قبل		
							شاخص فی		
							مدت بارش		
							مقدار متوسط بارش		

شد. در شکل ۵ مشاهده می‌شود که شبکه شماره ۲۲ ضریب رواناب را به‌خوبی شبیه‌سازی کرده و پیش‌بینی‌های شبکه بسیار شبیه داده‌های مشاهداتی است.

ارزیابی عملکرد شبکه‌ها بر مبنای مقایسه ضریب رواناب پیش‌بینی شده با شبکه و اندازه‌های مشاهده‌ای در نظر گرفته شد که تفاوت کمتر بین آن‌ها مناسب‌تر تشخیص داده



شکل ۵- برازش داده‌های مشاهده‌ای و برآوردی شبکه با تابع تانژانت هیپربولیک در مرحله آموزش و آزمایش و صحت‌سنجی

پارامترهای مهم در ارتباط با بارش مازاد یا به عبارت دیگر مقدار بارشی است که به روان‌آب تبدیل می‌شود، تأثیر محسوسی در برآورد ضریب روان‌آب دارد. همچنین شبکه با تابع تانژانت هیپربولیک با ورودی‌های بیشتر و جزئی‌تر برای تخمین ضریب روان‌آب، منجر به پاسخ بهتری خواهد شد. در واقع مدل به ورودی‌هایی که مرتبط با هدررفت اولیه هستند حساس بوده و نقش قابل توجهی در خروجی دارند و با توجه به نیمه خشک بودن منطقه مورد مطالعه و غالبیت بارش‌های کوتاه مدت با شدت بالا، وزن بالای چارک‌های شدت و به تبع آن مقدار و مدت بارش توانسته در مقایسه با دیگر ورودی‌ها تأثیر محسوس‌تری را بر خروجی مدل داشته باشد. این مطلب علاوه بر تاکید بر اهمیت و نقش این متغیرها در پیش‌بینی ضریب روان‌آب رگبار، عملکرد مناسب شبکه پرسپترون چند لایه در مسائل هیدرولوژیکی را مطابق با مطالعات سایر محققان [۲۰] [۹] [۲۳] [۲۸] [۱۱] [۲۸]

برازش داده‌های مشاهده‌ای و برآورد شده، عملکرد بهتر شبکه با تابع تانژانت هیپربولیک و ضریب تبیین اعتبارسنجی ۰/۹۸ با ورودی-های چارک‌های شدت بارندگی، مقدار و مدت بارش، شاخص فی و بارش پنج روز قبل را نشان می‌دهد.

نتایج حاصل بیانگر این است که از میان ۱۲ متغیر هیدرولوژیکی مورد بررسی در این تحقیق، مقادیر چارک‌های شدت بارش، شاخص فی، مقدار و مدت بارش و بارش پنج روز قبل در مقیاس رگبار با استفاده از شبکه عصبی مصنوعی با تابع تانژانت هیپربولیک بیشترین تأثیر را در برآورد ضریب روان‌آب دارند. این قضیه را از نظر هیدرولوژی می‌توان این گونه توضیح داد که متغیر شدت بارش با اعمال دو متغیر مقدار و مدت بارش ارتباط بیشتری را با مقادیر ضریب روان‌آب برقرار می‌کند که با مطالعه Parida و همکاران در سال ۲۰۰۶ و توسلی ۱۳۸۷ نیز مطابقت دارد [۲۲] [۱]. همچنین شاخص فی که یکی از

با توجه به تأثیر چشمگیری که ویژگی‌های فیزیکی و وضعیت رطوبتی حوضه قبل از بارش بر اندازه ضریب روان آب دارند پیشنهاد می‌شود که اطلاعات مربوط به این ویژگی‌ها را در بردار ورودی شبکه در نظر گرفت و تأثیر آن‌ها بررسی شوند.

[۲][۴][۳][۲۱][۲۵][۲۴]مورد تایید قرار می‌دهد. افزون بر ویژگی‌های بارش، عوامل دیگری نیز در فرآیند تبدیل بارش به روان آب نقش دارند که بیشتر مربوط به حوضه هستند. در این بررسی به سبب نبود این اطلاعات در آمار سال‌های گزینش شده، به جز شاخص فی سایر ویژگی‌ها مورد استفاده قرار نگرفت.

### منابع

- ۱-توسلی، ا.، ۱۳۸۷: دینامیک ضریب روان آب در مقیاس رگبار در حوزه آبخیز بار نیشابور. پایان‌نامه کارشناسی ارشد آبخیزداری، دانشگاه تربیت مدرس، ۸۵ص.
- ۲-جهانگیر، ع.، رائینی سرجاز، م.، ضیاتبارا احمدی، م.خ.، ۱۳۸۷: شبیه‌سازی فرآیند بارش-رواناب با شبکه عصبی مصنوعی (ANN) و مقایسه با مدل HEC-HMS در حوضه معرف کارده، مجله آب و خاک علوم و صنایع کشاورزی، ۲۲(۲)، ۷۲-۸۴.
- ۳-رادمان، ر.، علی محمدی، س. و جباری، ا. ۱۳۸۳: مقایسه مدل‌های کلاسیک و شبکه‌های عصبی مصنوعی در پیش‌بینی جریان رودخانه، مجموعه مقالات اولین کنفرانس سالانه منابع آب ایران، انجمن علوم و مهندسی منابع آب ایران، دانشکده فنی دانشگاه تهران.
- ۴-رضایی، ع. ۱۳۸۴: مدل‌سازی دبی اوج با استفاده از شبکه عصبی مصنوعی، مجموعه مقالات دومین کنفرانس سراسری آبخیزداری و مدیریت منابع آب و خاک، دانشگاه شهید باهنر کرمان، ص ۲۳۴۳-۲۳۵۳.
- ۵-زارع‌ابیانه، ح. و بیات‌ورکشی، م. ۱۳۹۰: ارزیابی مدل‌های هوشمند عصبی و تجربی در تخمین روان آب سالانه، نشریه آب و خاک (علوم و صنایع کشاورزی)، ۲۵(۲): ۳۶۵-۳۷۹.
- ۶-منهاج، م. ب. ۱۳۸۱. مبانی شبکه‌های عصبی. جلد او هوش محاسباتی. مرکز نشر دانشگاه صنعتی امیر کبیر. ۹۸۶ص.
- ۷-میثاقی، ف. ۱۳۸۱. شبیه‌سازی بارش - رواناب و روندیابی در رودخانه با استفاده از شبکه عصبی. ۴۵۵ - مصنوعی، مجموعه مقالات ششمین سمینار بین المللی مهندسی رودخانه. اهواز. ص ۴۶.
- ۸-نوری، ر.، اشرافی، خ.، ازدرپور، ا. ۱۳۸۷: مقایسه کاربرد روش‌های شبکه عصبی مصنوعی و رگرسیون خطی چند متغیره بر اساس تحلیل مولفه‌های اصلی برای پیش‌بینی غلظت میانگین روزانه مونوکسیدکربن: مطالعه موردی شهر تهران، مجله علمی پژوهشی فیزیک زمین و فضا، ۳۴، ۱۳۵-۱۵۲.
- 9-Ahmat Nor, N.I.B. 2005. Rainfall-runoff modelling using artificial neural networks method, Doctor of Philosophy Dissertation, Faculty of Civil Engineering, Malaysia Technology University.
- 10-Anctil, F., C.H. Perrin and V. Andreassian. 2004. Impact of the length of observed records on the performance of ANN and of conceptual parsimonious rainfall-runoff forecasting models. Environmental Modeling and Software. 19: 357-368.

- 11-Anmala, J., Zhang, B. and Govindaraju, R.S. 2000. Comparison of ANNs and empirical approaches for predicting watershed runoff, *Journal of Water Resources, Planning and Managment, ASCE*, vol. 126, no 3, pp. 156–166
- 12-ASCE Task Committee. 2000. Artificial neural networks in hydrology, II: Hydrology application. *Journal of Hydrology Engineering*, 5: 124-137.
- 13-Braddock, R.D., M.L. Kremmer and L. Sanzogni. 1998. Feedforward artificial neural network model for forecasting rainfall-runoff. *Environmental Sciences*, 9: 419-432.
- 14-Coulibaly, P., F. Anctil and B. Bobee. 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *Journal of Hydrology*, 230: 244-257.
- 15-Cybenko, G. (1989). "Approximation by superposition of a sigmoidal function." *Math. Control Signals Syst.*, 2, 303-314.
- 16-Elshorbagy, A., Simonovic, S.P., 2000. Performance evaluation of artificial neural networks for runoff prediction *Journal of Hydrologic Engineering, ASCE* 3(3), 203-209
- 17-Hornik, K., Stinchcombe, M., and White, H. (1989). "Multilayer feedforward networks are universal approximators." *Neural Networks*, 2 (5), 359-366.
- 18-Jalili-Ghazizade, M., and Noori, R. (2008). "Prediction of municipal solid waste generation by use of artificial neural network: a case study of Mashhad." *Int. J. Environ. Res*, 2 (1), 13-22.
- 19-Kisi, O., 2008, River Flow Forecasting and Estimation using Different Artificial Neural Network Techniques, *Hydrology Research*, 39(1):27-40..
- 20-Maria C.V. R., Haroldo F.C. V., and Nelson J. F., 2005. Artificial neural network technique for rainfall forecasting applied to the São Paulo region, *Journal of Hydrology*, 301(1-4), 146-162.
- 21-Nourani, V., Kisi, O. and Komasi, M. 2011. Two hybrid artificial intelligence approaches for modeling rainfall–runoff process, *Journal of Hydrology*, vol. 402, pp. 41–59.
- 22-Parida, B.P., Moalafhi, D.B. and Kenabatho P.K. 2006. Forecasting runoff coefficients using ANN for water resources management, The case of Notwane catchment in Eastern Botswana, *Physics and Chemistry of the Earth*, vol. 31, pp. 928–934.
- 23-Riad, S., Mania, J., Bouchaou, L. and Najjar, Y., 2004. Predicting catchment flow in a semi-arid region via an artificial neural network technique, *Hydrological Processes Journal*, vol. 18, no. 13, pp. 2387–2393.
- 24-Solaimani, k 2009: Rainfall-Runoff Prediction Based on Artificial Neural Network *American – Eurasian J.Agric & Environ.Sci*, 5(6):856-865.
- 25-Tao, W., Kailin, Y. and Yongxin, G. 2008. Application of artificial neural networks to forecasting ice conditions of the Yellow River in the Inner Mongolia reach. *Journal of Hydrology*, vol. 13. no. 9, pp. 811–816.
- 26-Tokar Sezin A. and Johnson Peggy A. 1999 :Rainfall-Runoff Modeling Using Artificial Neural Networks, *Journal of Hydrologic Engineering*, 4(3), 232-240.
- 27-Tokar, A.S. and M. Markus. 2000. Precipitation-runoff modeling using artificial neural networks and conceptual models. *Journal of Hydrology Engineering*, 45: 156-161.
- 28-Wu, C.L. and Chau, K.W. 2011. Rainfall–runoff modeling using artificial neural network coupled with singular spectrum analysis, *Journal of Hydrology*, vol. 399, no. (3-4), pp. 394–409.

29-Yilmaz, A.G., Imteaz, M.A. and Jenkins, G. 2011. Catchment flow estimation using Artificial Neural Networks in the mountainous Euphrates Basin, Journal of Hydrology, vol. 410, pp. 134–140.

30-Zhang, G., Patuwo, B.E., and Hu, M.Y. (1998). “Forecasting with artificial neural networks: the state of the art.” Int. J. Forecasting, 14 (1), 35-62.

Archive of SID