

## Research Paper

# An Evaluation of Neural Networks, IHACRES Models, and Linear Regressions in the Simulation of Runoff in the Tashk-Bakhtegan Basin

Alireza Pilpayeh<sup>1\*</sup>, Aydin Bakhtar<sup>2</sup>, Akbar Rahmati<sup>3</sup>, Afshin Shayeghi<sup>4</sup>

1. Assistant Professor, Department of Civil Engineering, Parsabad Moghan Branch, Islamic Azad University, Parsabad, Iran

2. Graduate M.Sc. student in Water Resources Management, Department of Water Engineering, Urmia University, Urmia, Iran

3. Graduate M.Sc. student in the field of water resources management, Faculty of Agriculture, University of Tehran, Tehran, Iran

4. Graduate M.Sc. student in the field of water resources management, engineering faculty, water engineering department, Imam Khomeini International University, Qazvin, Iran

Received: 2019/08/13

Revised: 2019/12/14

Accepted: 2021/10/01

Use your device to scan and read the article online



DOI:

10.30495/wej.2021.22332.2182

### Keywords:

Flood, rainfall-runoff model, artificial intelligence

### Abstract

**Introduction:** Simulating streamflow is an important element of hydrology and water resources. Forecasting runoff can determine the rate of flooding in future periods as well as the increasing or decreasing trend of river discharge. A variety of methods can be used to predict or simulate runoff rates, including statistical methods, rainfall-runoff models, and artificial intelligence.

**Methods:** The model chosen in this study consisted of a neural network, IHACRES and linear regression to estimate runoff in Tashk-Bakhtegan basin, which were evaluated based on correlation coefficient, coefficient of determination, and other error measures.

**Findings:** As results showed, runoff and precipitation have a nonlinear relationship; thus, the linear regression model cannot be trusted. The neural network model has good performance in estimating monthly runoff in the Tashk-Bakhtegan basin compared to the other two models due to the nonlinear relation between precipitation and runoff.

**Citation:** Pilpayeh A, Bakhtar A, Rahmati A, Shayeghi A. An Evaluation of Neural Networks, IHACRES Models, and Linear Regressions in the Simulation of Runoff in the Tashk-Bakhtegan Basin. Water Resources Engineering Journal. 2022; 15(53): 29- 40.

\*Corresponding author: Alireza Pilpayeh

**Address:** Assistant Professor of Civil Engineering Department, Parsabad Moghan Branch, Islamic Azad University, Parsabad, Iran

**Tell:** +989143523171

**Email:** a.pilpayeh54@yahoo.com

## Extended Abstract

### Introduction

Predicting river flow is one of the essential hydrological issues pertinent to flood management. In addition to providing helpful information for managing water resources, reliable forecasts of the daily discharge can also contribute to better planning for the effective exploitation of those resources. There has been a significant increase in population and economic activity in floodplains and on the banks of the main rivers, which makes this forecast more critical. Several methods are used to estimate river discharge values, including hydrological models. Hydrological models can be conceptual, empirical, or physically based. The appropriate model selection depends on factors such as the simulation of considered variables (surface runoff, groundwater, sediment load, etc.), the accuracy of the available data, and the spatial and temporal scale. Additionally, statistical methods and neural networks can be mentioned as other methods of runoff simulation. Any analysis should evaluate the performance of each of these models in the context of different climatic conditions and regions, as each has advantages and disadvantages. As it is of critical importance to estimate runoff using an efficient model, this study compares three methods comprised of neural networks, IHACRES and linear regression models to estimate monthly runoff in the Tashk-Bakhtegan basin. Even though the above models have been used in a number of studies to simulate runoff in different basins, they have not been investigated in the Tashk-Bakhtegan basin. As one of the main advantages of the methods used in this study, there is no computational complexity involved in the estimation of the amount of runoff. A comparison of the accuracy of these three models has been conducted in the present study in order to select the best model to be used in future studies.

### Materials and Methods

In this study, the data from Shiraz synoptic weather station and Pol Khan hydrometric station located in Tashk-Bakhtegan lakes were used

to investigate the relationship between runoff values and precipitation values for the Tashk-Bakhtegan watershed. The height of the Tashk-Bakhtegan lakes is approximately 1525 meters above sea level. As the second largest internal lake in the country, Tashk-Bakhtegan lakes cover an area of over 800 square kilometers. To begin this study, all the data from Pul-Khan Hydrometric Station and Shiraz Meteorological Station were collected. For the study area, we used data from 1981 to 2012 to investigate rainfall-runoff simulations. Three models comprised of neural networks, IHACRES and linear regression model have been used for the rainfall runoff simulation across the study region within the 1981 to 2012 time period. In addition, the Pearson correlation coefficient, coefficient of determination, and bias were used to evaluate models' accuracy.

### Findings

Based on the results of the IHACRES model for the Tashk-Bakhtegan basin, the  $R^2$  calculated in the calibration stage is 0.6 and the minimum relative error value is 0.06. In contrast, the  $R^2$  for the validation stage is 0.52, which is unacceptable since a  $R^2 > 0.6$  is considered reliable. As indicated by linear regression, temperature and rainfall only have a linear relationship, while rainfall and runoff do not have a linear relationship. In order to model runoff precipitation using an artificial neural network, 70% of the data were used as training data, 15% as validation data, and the remaining 15% as test data. Based on the results, the best network architecture is 2-18-1, which has a lower average relative error value than other modes (as seen in Table 3 and Fig. 13-14). To train and test neural networks, the neural network time series Tool Box with dynamic structure was used. This study indicates that the neural network has been able to estimate the amount of runoff in the Tashk-Bakhtegan basin with a reasonable degree of accuracy.

### Discussion

In this study, the IHACRES, ANN, and linear regression models were used to predict the runoff of the Tashk-Bakhtegan basin. In the

IHACRES hydrological model, the calibration R2 for Pul-khan station is 0.6, and the validation R2 is 0.51. In addition, the R2 value for ANN with network architecture 2-18-1 is on average equal to 0.80. It is clear from the comparison that the ANN provides a more accurate estimate of runoff using the flow value than the IHACRES model. It was found that rainfall and runoff data do not have a linear relationship, and this non-linear relationship accounts for the greater accuracy of the ANN model. The linear regression method cannot be used in this research to simulate runoff amounts because of the non-linear relationship between runoff and precipitation. There is a nonlinear relationship between different variables associated with water and meteorology. Thus, ANN can be utilized in future studies as an effective method of estimating the amount of runoff in the Tashk-Bakhtegan basin.

### **Conclusion**

It is concluded that ANN followed by IHACRES are well suited for the rainfall-runoff model over the basin. Furthermore, as there was no linear relationship between rainfall and runoff, regression model failed to capture rainfall runoff simulation across the Tashk-Bakhtegan basin.

### **Ethical Considerations compliance with ethical guidelines**

The cooperation of the participants in the present study was voluntary and accompanied by their consent.

### **Funding**

No funding.

### **Authors' contributions**

Design and conceptualization: Aydin Bakhtar, Alireza Pilpayeh.

Methodology and data analysis: Akbar Rahmati, Afshin Shayeghi, Aydin Bakhtar.

Supervision and final writing: Alireza Pilpayeh.

### **Conflicts of interest**

The authors declared no conflict of interest.

## مقاله پژوهشی

## بررسی مقایسه‌ای شبکه عصبی، مدل IHACRES و رگرسیون خطی در شبیه - سازی رواناب در حوضه آبخیز طشک - بختگان

علیرضا پیل‌پایه<sup>۱\*</sup>، آیدین باختر<sup>۲</sup>، اکبر رحمتی<sup>۳</sup>، افشین شایقی<sup>۴</sup>

۱. استادیار گروه مهندسی عمران، واحد پارس آباد مغان، دانشگاه آزاد اسلامی، پارس آباد، ایران

۲. دانش‌آموخته کارشناسی ارشد رشته مدیریت منابع آب، گروه مهندسی آب، دانشگاه ارومیه، ارومیه، ایران

۳. دانش‌آموخته کارشناسی ارشد رشته مدیریت منابع آب، دانشکده کشاورزی، دانشگاه تهران، تهران، ایران

۴. دانش‌آموخته کارشناسی ارشد رشته مدیریت منابع آب، دانشکده فنی و مهندسی، گروه مهندسی آب، دانشگاه بین‌المللی امام خمینی (ره) قزوین، قزوین، ایران

## چکیده

**مقدمه:** پیش‌بینی جریان رودخانه یکی از مسائل ضروری هیدرولوژیکی مرتبط با مدیریت سیل است. علاوه بر ارائه اطلاعات مفید برای مدیریت منابع آب، پیش‌بینی‌های قابل اعتماد دبی روزانه نیز می‌تواند به برنامه‌ریزی بهتر برای بهره‌برداری موثر از آن منابع کمک کند. افزایش قابل توجه جمعیت و فعالیت اقتصادی در دشت‌های سیلابی و سواحل رودخانه‌های اصلی وجود داشته است که این پیش‌بینی را بحرانی‌تر می‌کند. چندین روش برای تخمین مقادیر دبی رودخانه استفاده می‌شود، از جمله مدل‌های هیدرولوژیکی. مدل‌های هیدرولوژیکی می‌توانند مفهومی، تجربی یا فیزیکی باشند. انتخاب مدل مناسب به عواملی مانند شبیه‌سازی متغیرهای در نظر گرفته شده (رواناب سطحی، آب زیرزمینی، بار رسوب و غیره)، دقت داده‌های موجود و مقیاس مکانی و زمانی بستگی دارد. همچنین می‌توان از روش‌های آماری و شبکه‌های عصبی به عنوان روش‌های دیگر شبیه‌سازی رواناب نام برد. هر تحلیلی باید عملکرد هر یک از این مدل‌ها را در شرایط و مناطق مختلف اقلیمی ارزیابی کند، زیرا هر کدام دارای مزایا و معایبی هستند. از آنجایی که برآورد رواناب با استفاده از یک مدل کارآمد از اهمیت حیاتی برخوردار است، این مطالعه سه روش متشکل از شبکه‌های عصبی، مدل IHACRES و رگرسیون خطی را برای تخمین رواناب ماهانه در حوضه طشک - بختگان مقایسه می‌کند. اگرچه مدل‌های فوق در تعدادی از مطالعات برای شبیه‌سازی رواناب در حوضه‌های مختلف مورد استفاده قرار گرفته‌اند، اما در حوضه طشک - بختگان مورد بررسی قرار نگرفته‌اند. به عنوان یکی از مزایای اصلی روش‌های مورد استفاده در این مطالعه، عدم وجود پیچیدگی محاسباتی در تخمین مقدار رواناب است. مقایسه دقت این سه مدل در پژوهش حاضر به منظور انتخاب بهترین مدل برای استفاده در مطالعات آبی انجام شده است.

**روش:** در این تحقیق از داده‌های ایستگاه هواشناسی سینوپتیک شیراز و ایستگاه هیدرومتری پل خان واقع در دریاچه طشک - بختگان برای بررسی رابطه بین مقادیر رواناب و مقادیر بارش برای حوضه آبخیز طشک - بختگان استفاده شد. ارتفاع دریاچه‌های طشک - بختگان از سطح دریا تقریباً ۱۵۲۵ متر است. دریاچه طشک - بختگان به عنوان دومین دریاچه بزرگ داخلی کشور مساحتی بالغ بر ۸۰۰ کیلومتر مربع را در بر می‌گیرد. برای شروع این مطالعه، تمامی داده‌های ایستگاه هیدرومتری پلخان و ایستگاه هواشناسی شیراز جمع‌آوری شد. برای منطقه مورد مطالعه، از داده‌های ۱۹۸۱ تا ۲۰۱۲ برای بررسی شبیه‌سازی‌های بارش - رواناب استفاده کردیم. سه مدل متشکل از شبکه‌های عصبی، IHACRES و مدل رگرسیون خطی برای شبیه‌سازی رواناب بارندگی در منطقه مورد مطالعه در بازه زمانی ۱۹۸۱ تا ۲۰۱۲ استفاده شده است. علاوه بر این، از ضریب همبستگی پیرسون، ضریب تعیین و سوگیری برای ارزیابی دقت مدل‌ها استفاده شد.

**یافته‌ها:** بر اساس نتایج مدل IHACRES برای حوضه طشک - بختگان،  $R^2$  محاسبه شده در مرحله کالیبراسیون ۰.۶ و حداقل مقدار خطای نسبی ۰.۰۶ است. در مقابل،  $R^2$  برای مرحله اعتبار سنجی ۰.۵۲ است، که غیرقابل قبول است زیرا  $R^2 > 0.6$  قابل اعتماد در نظر گرفته می‌شود. همانطور که با رگرسیون خطی نشان می‌دهد، دما و بارندگی فقط یک رابطه خطی دارند، در حالی که بارندگی و رواناب رابطه خطی ندارند. به منظور مدل‌سازی بارش رواناب با استفاده از شبکه عصبی مصنوعی، ۷۰ درصد داده‌ها به‌عنوان داده آموزشی، ۱۵ درصد به‌عنوان داده اعتبارسنجی و ۱۵ درصد باقی‌مانده به‌عنوان داده‌های آزمایشی استفاده شد. بر اساس نتایج، بهترین معماری شبکه ۲-۱۸-۱ است که میانگین مقدار خطای نسبی کمتری نسبت به سایر حالت‌ها دارد (همانطور که در جدول ۳ و شکل ۱۳-۱۴ مشاهده می‌شود). برای آموزش و آزمایش شبکه‌های عصبی از سری زمانی شبکه عصبی جعبه ابزار با ساختار پویا استفاده شد. این مطالعه نشان می‌دهد که شبکه عصبی توانسته است میزان رواناب در حوضه طشک - بختگان را با دقت قابل قبولی تخمین بزند.

تاریخ دریافت: ۱۳۹۸/۰۵/۲۲

تاریخ داوری: ۱۳۹۸/۰۹/۲۳

تاریخ پذیرش: ۱۴۰۰/۰۷/۰۹

از دستگاه خود برای اسکن و خواندن مقاله به صورت آنلاین استفاده کنید



DOI: 10.30495/wej.2021.22332.2182

## واژه‌های کلیدی:

سیل، مدل بارش - رواناب، هوش مصنوعی.

**نتیجه گیری:** نتیجه گیری می شود که ANN به دنبال IHACRES برای مدل بارش-رواناب بر روی حوضه مناسب است. همچنین، از آنجایی که رابطه خطی بین بارندگی و رواناب وجود نداشت، مدل رگرسیون نتوانست شبیه سازی رواناب بارندگی را در حوضه طشک- بختگان نشان دهد.

\* نویسنده مسئول: علیرضا پیل پایه

نشانی: استادیار گروه عمران، واحد پارس آباد مغان، دانشگاه آزاد اسلامی، پارس آباد، ایران.

تلفن: ۰۹۱۴۳۵۲۳۱۷۱

پست الکترونیکی: a.pilpayeh54@yahoo.com

## مقدمه

در پژوهشی روی حوضه رودخانه سارادا دریافتند که شبکه عصبی برای پیش بینی دبی های پیک در حوضه های کوچک در مناطق نیمه خشک که دارای بارش های پراکنده و نامنظم می باشد مناسب هستند، با توجه به این که در برخی حوضه های آبخیز امکان اندازه گیری تمام کمیت های مورد نیاز جهت بررسی عکس العمل حوضه میسر نمی باشد، لذا انتخاب مدلی که بتواند با استفاده از حداقل اطلاعات ورودی مورد نیاز، پیش بینی قابل قبولی ارائه کند، اهمیت قابل توجهی دارد [12].

در پژوهشی تاثیر تغییر اقلیم بر روی حوضه های کشور تونس مورد بررسی قرار گرفت. در این پژوهش از سه مدل بارش رواناب HBV، IHACRES و GR4j در پنج حوضه در سطح کشور تونس استفاده شد. نتایج حاکی از این بود که با توجه به شاخص های آماری KGE و نش هر سه مدل بارش رواناب در مواقع انتقالی به دوره ترسالی دارای عملکرد مناسب و همچنین در مواقع انتقالی به یک دوره خشکسالی نیز دارای عملکرد ضعیفی بودند [4].

همچنین به منظور مقایسه روش های ANN، MLR، KNN و ANFIS جهت برآورد میزان رواناب ماهانه در رودخانه St. Claire که بین آمریکا و کانادا قرار دارد پژوهش جامعی انجام پذیرفت. نتایج به دست آمده نتایج نشان داد که عملکرد سه مدل غیرخطی ANN، ANFIS و KNN بسیار رضایت بخش بوده و به طور کلی در بین این سه مدل، مدل ANFIS که از مزایای سیستم های استنتاج فازی و شبکه های عصبی بهره می برد، برتر می باشد، در حالی که مدل MLR که سعی در ایجاد رابطه خطی بین ورودی ها و خروجی ها دارد، قادر به برآورد جریان ماهانه به صورت مناسبی نمی باشد. همچنین از دیگر نتایج این پژوهش این بود که که استفاده از یک مدل موجه باعث بهبود میزان نتایج برآورد دبی در این منطقه می شود. به این صورت که میزان شاخص نش برای دو مدل ANN و MLR از ۰.۳ به میزان ۰.۹ رسید [5].

در سطح کشور نیز پژوهش های مختلفی در زمینه شبیه سازی میزان رواناب انجام پذیرفته که در ادامه به تعدادی از این پژوهش ها اشاره می شود؛ به عنوان مثال در پژوهشی به منظور شبیه سازی میزان رواناب روزانه در دریاچه پل رود و شالمان رود واقع در استان گیلان از مدل بارش رواناب IHACRES استفاده شد نتایج حاکی از این بود که مدل بارش- رواناب IHACRES در برآورد دبی در حوضه های مرطوب از عملکرد مناسبی با توجه به شاخص های آماری مورد استفاده برخوردار است [1].

همچنین به منظور بررسی تاثیر تغییر اقلیم بر روی میزان رواناب در رودخانه هابل رود در شمال ایران نیز پژوهشی انجام شد. در این پژوهش از مدل LARS-WG جهت کاهش مقیاس خروجی مدل HADCM3

پیش بینی دبی رودخانه یکی از مهم ترین مسائل هیدرولوژیکی است که برای مدیریت سیلاب اهمیت دارد. یک پیش بینی منطقی از دبی روزانه نه تنها اطلاعات مفیدی برای مدیریت منابع آب در اختیار قرار می دهد، بلکه به منظور برنامه ریزی دقیق تر جهت استحصال مناسب منابع آب نیز می تواند مورد استفاده قرار گیرد. با افزایش جمعیت و فعالیت های اقتصادی در دشت های سیلابی و حاشیه رودخانه های اصلی اهمیت این پیش بینی افزایش می یابد. مقادیر دبی رودخانه از روش های متعددی برآورد می گردد، یکی از این روش ها استفاده از مدل های هیدرولوژیکی می باشد. مدل های هیدرولوژیکی حوضه اعم از مدل های تجربی در برابر مدل های فیزیکی، مدل های رویدادگرا در برابر پیوسته و مدل های یکپارچه در مقابل مدل های توزیعی طبقه بندی می شوند [1]. از مدل های یکپارچه می توان به مدل IHACRES و از مدل های نیمه توزیعی به مدل های HBVlight و از مدل های توزیعی به مدل SWAT اشاره کرد. انتخاب یک مدل مناسب وابسته به فاکتورهایی از قبیل شبیه سازی متغیرهای طراحی (رواناب سطحی، آب های زیرزمینی، بار رسوب و غیره)، دقت داده های در دسترس و مقیاس مکانی و زمانی است [2]. همچنین از دیگر روش های شبیه سازی رواناب می توان به روش های آماری و شبکه عصبی اشاره کرد. هر کدام از این مدل ها و روش های اشاره شده دارای مزایا و معایبی می باشند، به همین دلیل ارزیابی توانایی هر کدام از این مدل ها در شرایط اقلیمی و مناطق مختلف از ملزومات هر پژوهشی می باشد.

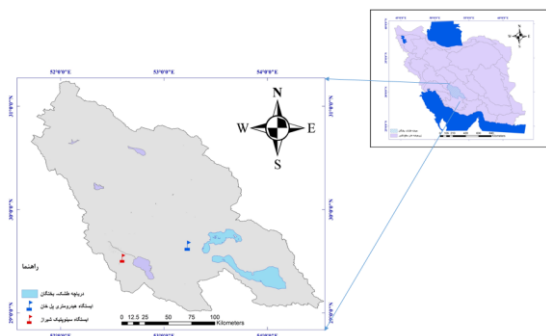
پژوهش های مختلفی در زمینه شبیه سازی رواناب با استفاده از شبکه های عصبی، مدل های بارش- رواناب و مدل های آماری انجام پذیرفته است که به تعدادی از پژوهش ها اشاره می شود. در پژوهشی که در آفریقای جنوبی در دو حوضه Lambrechtsbos (با مساحت ۳۱ هکتار) و Groot-Nylrivier (با مساحت ۷۴ کیلومتر مربع) انجام پذیرفت، توانایی مدل بارش رواناب IHACRES در این دو حوضه مورد بررسی قرار گرفت. نتایج حاکی از این بود که مدل IHACRES در حوضه Lambrechtsbos در هر دو دوره واسنجی و صحت سنجی از دقت بالایی برخوردار می باشد (ضریب تبیین بالای ۰.۸ برای هر دو دوره واسنجی و صحت سنجی). در حوضه Groot-Nylrivier نیز مدل IHACRES در تعدادی از سال ها دارای دقت مناسب بوده ولی در درازمدت به دلیل وجود سال های سیلابی توانایی مدل کاهش پیدا کرده است. نتیجه کلی این پژوهش این بود که در حوضه های کوچک مدل IHACRES نتایج به مراتب بهتری نسبت به حوضه های بزرگ ارائه می دهد [3].

اساسی عدم پیچیدگی محاسباتی و همچنین برآورد میزان رواناب با کمترین پارامترهای موجود اشاره کرد. در پروژه حاضر توانایی هر کدام از این سه مدل جهت برآورد میزان رواناب ماهانه مورد بررسی قرار گرفته تا مناسب‌ترین مدل جهت استفاده در مطالعات آبی انتخاب شود.

## مواد و روش‌ها

### منطقه مورد مطالعه

در این پژوهش از داده‌های ایستگاه هواشناسی سینوپتیک شیراز و ایستگاه هیدرومتری پل خان واقع در دریاچه‌های طشک-بختگان برای بررسی رابطه‌ی بین مقادیر رواناب و بارش حوضه آبخیز طشک-بختگان استفاده شده است. ارتفاع دریاچه‌های طشک-بختگان از سطح دریاهای آزاد ۱۵۲۵ متر است. دریاچه‌های طشک-بختگان با وسعتی بالغ بر ۸۰۰ کیلومتر مربع از نظر وسعت دومین دریاچه‌ی داخلی کشور شمرده می‌شوند [11]. این حوضه‌ی آبخیز بین  $51^{\circ}44'$  تا  $54^{\circ}30'$  طول شرقی و  $29^{\circ}07'$  تا  $31^{\circ}15'$  دقیقه عرض شمالی قرار دارد. شکل شماره ۱ موقعیت جغرافیایی آن را نشان می‌دهد.



شکل ۱- نقشه منطقه مطالعاتی حوضه طشک - بختگان

### جمع‌آوری آمار و اطلاعات

در این بررسی در آغاز کلیه آمار و داده‌های ایستگاه هیدرومتری پل خان و ایستگاه هواشناسی شیراز جمع‌آوری گردید. برای انجام محاسبات مربوط به ایستگاه دریاچه‌های طشک-بختگان از سال‌های آبی ۱۳۶۱ تا ۱۳۹۱ (مهر ۱۳۶۱ تا شهریور ۱۳۹۱) استفاده شده است. در واقع آمار استفاده شده از هر ایستگاه دارای ۳۶۰ داده است. داده‌های هواشناسی مورد استفاده در این پژوهش داده‌های دما و بارش مربوط به ایستگاه سینوپتیک شیراز و داده‌های دبی مشاهداتی از ایستگاه هیدرومتری پل-خان می‌باشد.

### مدل IHACRES

مدل بارش-رواناب IHACRES در سال ۱۹۹۳ ارائه شده است [9]. این مدل یک مدل مفهومی و یکپارچه است. اساس این روش از دو مدول غیرخطی کاهش<sup>1</sup> و مدول خطی هیدروگراف<sup>2</sup> تشکیل می‌شود. به این

برای میزان بارش و دما و از مدل بارش رواناب IHACRES جهت برآورد رواناب در منطقه مورد نظر در دوره آینده استفاده شد. نتایج حاکی از این بود که میزان رواناب به جز ماه‌های جولای، ژوئن و آگوست در دوره آینده حالت کاهشی خواهد داشت [6].

پژوهشی دیگر که جهت ارزیابی توانایی سه مدل بارش رواناب IHACRES، SWAT و ANN در شبیه‌سازی میزان رواناب در مقیاس-های زمانی روزانه، ماهانه و سالانه در حوضه کن انجام پذیرفت. در این پژوهش دوره کالیبراسیون از ۱۹۸۷ تا ۱۹۹۱ و برای دوره صحت سنجی از ۱۹۹۲ تا ۱۹۹۵ استفاده شد. در این پژوهش، میزان شاخص‌های  $R^2$  و NSE به ترتیب بیش از ۰.۵۷ و ۰.۵۸ مشاهده شده است. به طور کلی می‌توان گفت که هر سه مدل در شبیه‌سازی باران و رواناب عملکرد خوبی نشان دادند. مقدار NSE برای مدل‌های IHACRES، ANN و SWAT برای دوره کالیبراسیون به ترتیب ۰.۶۰۶، ۰.۸۷ و ۰.۷۷ و برای دوره صحت‌سنجی به ترتیب ۰.۵۷۷، ۰.۸۶ و ۰.۶۵ بود. نتایج حاصله حاکی از این بود که مدل ANN در تمامی مقیاس‌های زمانی دارای عملکرد مناسبی در برآورد میزان رواناب در حوضه کن می‌باشد همچنین مدل SWAT نسبت به مدل IHACRES از عملکرد مناسبی برخوردار می‌باشد [13].

در حوضه آبخیز لنبران عملکرد مدل بارش-رواناب IHACRES در شبیه‌سازی رواناب ارزیابی گردید. داده‌های ماهانه بارندگی و دمای ایستگاه ورزقان به عنوان متغیرهای ورودی برای شبیه‌سازی جریان و داده‌های مشاهداتی دبی در ایستگاه هیدرومتری کاسین برای سنجش دقت مدل IHACRES به کار گرفته شد. بر اساس سال‌های موجود، داده‌های سال ۲۰۰۰ تا ۲۰۰۲ برای سازگاری مدل و ۲۰۰۳-۲۰۱۲ برای واسنجی و ۲۰۱۳ تا ۲۰۱۶ برای اعتبارسنجی مورد استفاده قرار گرفتند. برای بررسی توانایی مدل IHACRES در شبیه‌سازی رواناب از معیار ضریب نش-سانتکلیف استفاده گردید. نتایج نشان داد که این ضریب به ترتیب برای مراحل واسنجی و اعتبارسنجی ۰.۷۱ و ۰.۷۴ بدست آمد. در نهایت با توجه به نتایج حاصل از ارزیابی مدل IHACRES با استفاده از معیارهای عملکردی مختلف و به دلیل کاربری آسان و ورودی‌های کمتر و کاهش صرف زمان می‌توان استفاده از این مدل را جهت شبیه‌سازی و پیش‌بینی رواناب در مقیاس ماهانه در حوضه‌ی آبخیز لنبران استفاده نمود [7].

همانطور که در پژوهش‌های اخیر ملاحظه شد برآورد رواناب با استفاده از یک مدل کارا از اهمیت به‌سزایی برخوردار می‌باشد به همین جهت هدف از این پژوهش بررسی مقایسه‌ای سه روش متشکل از شبکه عصبی، IHACRES و مدل رگرسیون خطی جهت برآورد رواناب ماهانه در سطح حوضه طشک-بختگان می‌باشد، هرچند در پژوهش‌های مختلفی از روش‌ها و مدل‌های یاد شده جهت شبیه‌سازی میزان رواناب در سطح حوضه‌های مختلف استفاده شده است با این وجود در سطح حوضه طشک-بختگان روش‌های یاد شده بررسی نشده‌اند. از مزیت-های اصلی روش‌های مورد استفاده در این پژوهش می‌توان به دو نکته

2 - Linear unit hydrograph module

1 - Non-linear loss module

باشد نتایج مدل ایده‌آل‌تر می‌باشد. مقادیر آماره Bias هم نشان‌دهنده بیشتر یا کمتر بودن جریان شبیه‌سازی شده توسط مدل نسبت به جریان مشاهداتی است. به عبارتی بایاس بیانگر این است که مدل جریان را بیش از واقعیت شبیه‌سازی نموده یا کمتر برآورد نموده است.

### مدل شبکه عصبی مصنوعی (ANN)

به‌طور کلی مراحل به‌کارگیری یک شبکه عصبی شامل موارد زیر است:

#### • تهیه‌ی زوج‌های آزمایشی

داده‌های مربوط به نرون‌های ورودی و خروجی موجود باید دسته‌بندی و بصورت زوج‌های آموزشی ارائه شوند.

#### • نرمالیزه کردن زوج‌های آموزشی

به‌دلیل استفاده از تابع محرک سیگموئید و مقایسه‌ی بهتر میزان خطا باید زوج‌های آموزشی نیز بین مقدار ۰ و ۱ نرمال شوند. تابع محرک سیگموئید از رابطه (۷) و عمل نرمال‌سازی از رابطه (۸) به‌دست می‌آید.

$$a = \frac{(e^n - e^{-n})}{(e^n + e^{-n})} \quad (7)$$

$$X_n = \frac{x - X_{min}}{X_{max} - X_{min}} \quad (8)$$

X معرف داده مشاهداتی، Xmax و Xmin: به ترتیب حداکثر و حداقل داده‌ها، Xn: داده‌ی نرمال شده

#### • پیدا کردن بهترین ساختار شبکه

تعداد لایه‌های پنهان و نرون‌های این لایه می‌توانند در محدوده‌ای مشخص تغییر کنند. برای پیدا کردن بهترین شبکه می‌توان با تغییر تعداد لایه‌های پنهان و تعداد نرون‌های آن‌ها شبکه‌های مختلفی را تعریف و سپس آزمایش نمود تا شبکه‌ای که دارای کمترین خطا است حاصل شود. نحوه آزمایش به این صورت است که شاخص‌های آماری متشکل از mse<sup>6</sup> و ضریب تبیین برای هر کدام از شبکه‌ها محاسبه می‌شود تا شبکه‌ای که میزان خطای کمتر و ضریب تبیین بالایی دارد مشخص شود.


#### • یادگیری شبکه عصبی

در این مرحله هر یک از داده‌ها در شبکه قرار گرفته و با انتشار آن خطا در خروجی محاسبه می‌شود. شبکه عصبی بصورت کاملاً تصادفی به تعدادی از داده‌ها (۷۰-۸۰ درصد داده‌ها) را به عنوان تست انتخاب می‌کند. پس از انجام این کار برای زوج‌ها خطا در خروجی به اندازه‌ی کافی کوچک می‌شود. هم‌چنین باید توجه کرد که تعداد زوج‌های ورودی- خروجی اهمیت زیادی در تربیت شبکه دارد. اگر اطلاعات کمی به شبکه داده شود خصوصیات مسئله برای شبکه به اندازه‌ی کافی مشخص نبوده و در نهایت منجر به کسب نتایج منطقی نمی‌گردد. آموزش شبکه تا رسیدن به خطای قابل قبول ادامه می‌یابد و برای خاتمه آموزش بسته به نوع مسئله یک مقدار خطا در نظر گرفته می‌شود.

#### • صحت‌سنجی شبکه عصبی

پس از آموزش شبکه می‌توان شبکه را برای اطلاعاتی که با آن آموزش داده شده و اطلاعاتی که به شبکه ارائه نشده امتحان نمود. برای صحت‌سنجی شبکه را برای اطلاعاتی که با آن آموزش داده شده اجرا نمود و دقت شبکه را با استفاده از داده‌های مشاهداتی موجود می‌توان مورد

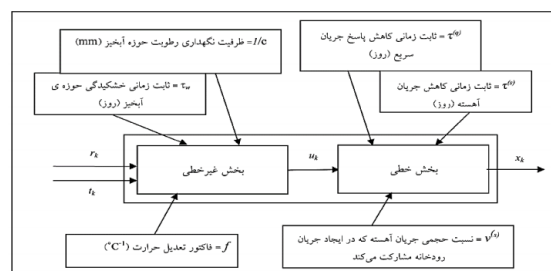
منظور، در ابتدا بارندگی (I<sub>k</sub>) و دما (t<sub>k</sub>) در هر گام زمانی k توسط مدول غیرخطی به بارندگی موثر u<sub>k</sub> تبدیل شده و سپس به‌وسیله مدول خطی هیدروگراف واحد به رواناب سطحی در همان گام تبدیل می‌شود (شکل ۲).



شکل ۲- چگونگی شبیه‌سازی بارش - رواناب همراه با

### مدول‌های خطی و غیرخطی

این مدل دارای شش پارامتر است که سه پارامتر آن مربوط به بخش تلفات غیرخطی شامل پارامتر f, c و t<sub>w</sub> (که به ترتیب مدت زمانی که طول می‌کشد تا حوضه خشک شود، فاکتور تعدیل دما و ظرفیت ذخیره رطوبت حوضه) و سه پارامتر مربوط به تابع تبدیل خطی شامل t<sup>s</sup>, t<sup>q</sup> که به ترتیب مدت زمانی که طول می‌کشد جریان سریع و آهسته کاهش یابد و v<sup>s</sup> حجمی از جریان آهسته که در ایجاد جریان رودخانه مشارکت دارد را نشان می‌دهد. شکل ۳ ساختار کلی مدل را نشان می‌دهد.



شکل ۳- ساختار کلی مدل IHACRES

در نهایت جهت تجزیه و تحلیل نتایج از روابط ۱، ۲ و ۳ استفاده شد (زارعی و همکاران، ۲۰۱۱).

$$D = \left[ 1 - \frac{\sum(Q_0 - Q_m)}{\sum(Q_0 - Q_0)} \right] \quad (1)$$

$$ARPE = \left[ \left( \frac{6a_1}{a_1} \right)^2 + \left( \frac{6a_2}{a_2} \right)^2 + \left( \frac{6b_0}{b_0} \right)^2 + \left( \frac{6b_1}{b_1} \right)^2 \right] / 4 \quad (2)$$

$$Bias = \frac{\sum(Q_0 - Q_m)}{n} \quad (3)$$

در روابط فوق D<sup>3</sup>: ضریب تشخیص کالیبراسیون مدل، Q<sub>0</sub>: جریان روزانه مشاهده شده، Q<sub>m</sub>: جریان روزانه شبیه‌سازی شده، متوسط جریان روزانه مشاهداتی، σ: انحراف معیار، ARPE<sup>4</sup>: میانگین خطای نسبی پارامترهای b<sub>0</sub>, b<sub>1</sub>, a<sub>1</sub>, a<sub>2</sub>: پارامترهای مرتبه دوم تابع انتقال هستند که بر اساس روابط ۴، ۵ و ۶ تعیین می‌شوند:

$$b_1 = b_0^{(q)} a_1^{(s)} + b_0^{(s)} a_1^{(q)} \quad (4)$$

$$a_1 = a_1^{(q)} + a_1^{(s)} \quad (-1 < a_2 < 0) \quad (5)$$

$$a_2 = a_1^{(q)} a_1^{(s)} \quad (-1 < a_2 < 0) \quad (6)$$

n: تعداد داده‌ها و Bias: خطای کل در حجم جریان (mm/month) می‌باشند.

آماره‌های D, APRE و Bias<sup>5</sup> توسط خود مدل مورد محاسبه قرار می‌گیرند، هر چه مقادیر D (ضریب تبیین) بیشتر و مقادیر APRE کمتر

<sup>5</sup> - Overall error in flow volume

<sup>6</sup> mean squared error

<sup>3</sup> Coefficient of determination

<sup>4</sup> Average relative parameter error

آمده از این آزمون داده تصادفی نبوده و بر روی یکدیگر تاثیر گذار هستند. بر روی داده‌ها از تبدیل‌های دیگر نیز زده شد اما در همه‌ی حالات مقادیر  $e$  تصادفی نیستند. این نشان دهنده‌ی غیر خطی بودن رابطه‌ی بین بارش و رواناب است.

### ب) فواصل اطمینان<sup>9</sup> برای متغیرهای $B_0$ و $B_1$ (مقادیر دبی و میانگین دبی):

فواصل اطمینان برای پارامترها نشان دهنده‌ی این هستند که این پارامترها را با چه صحتی می‌توان تخمین زد. فاصله اطمینان برای شیب  $B_1$  برابر است با:

$$[B_1 - \frac{t_{\alpha/2}}{\sqrt{SSX}} B_1 + \frac{t_{\alpha/2}}{\sqrt{SSX}}] \quad (10)$$

که در این رابطه  $t$  نقطه‌ای بر روی توزیع  $t$  با درجه آزادی  $n-2$  و سطح اطمینان  $\alpha/2$  است.  $SSX$  هم مجموع مربعات در راستای  $X$  می‌باشد. فاصله اطمینان برای عرض از مبدا  $B_0$  با کمک رابطه‌ی زیر محاسبه می‌شود:

$$\left[ B_0 - ts \sqrt{\frac{1}{n} + \frac{\bar{x}^2}{SSX}}, B_0 + ts \sqrt{\frac{1}{n} + \frac{\bar{x}^2}{SSX}} \right] \quad (11)$$

### فواصل اطمینان برای میانگین متغیر پاسخ

مقادیر بدست آمده از رابطه‌ی خطی بدست آمده به دلیل عدم قطعیت پارامترهای  $B_0$  و  $B_1$  دارای عدم قطعیتی است. فاصله‌ی اطمینان  $100*(1-\alpha)$  برای میانگین  $\bar{y}$  برابر است با:

$$\left[ \bar{y} - ts \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{SSX}}, B_0 + ts \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{SSX}} \right] \quad (12)$$

فاصله‌ی اطمینان  $100*(1-\alpha)$  برای  $\bar{y}$  برابر است با:

$$\left[ \bar{y} - ts \sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{SSX}}, B_0 + ts \sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{SSX}} \right] \quad (13)$$

### معیارهای داده پرت در راستای $x$

#### • Leverage

Leverage معیاری از "داده‌ی پرت" در راستای  $x$  بوده و تابعی از فاصله داده‌های مشاهداتی و میانگین مقادیر استفاده شده در رگرسیون می‌باشد [10].

$$hi = \frac{1}{n} + \frac{(xi - \bar{x})^2}{SSX} \quad (14)$$

### معیارهای داده‌های پرت در راستای $y$ :

باقی‌مانده استاندارد شده: یک معیار از داده‌ی پرت در راستای  $y$  است که این معیار نشان دهنده‌ی اعداد پرت است. یک داده‌ی پرت حداکثر داده‌ای است که  $|esi| > 3$  باشد [10].

$$esi = \frac{ei}{s\sqrt{1-hi}} \quad (15)$$

$esi$ : میانگین استاندارد شده،  $ei = yi - \hat{y}_i$  باقیمانده‌ی واقعی که استاندارد می‌شود.

#### • باقی‌مانده استیوننت شده:

$$si^2 = \frac{(n-p)s^2 - [e(i)^2 / (1-hi)]}{n-p-1}, e(i) = \frac{ei}{1-hi}, TRESID_i = \frac{ei}{s(i)\sqrt{1-hi}} \quad (16)$$

#### • معیارهای اثرگذاری:

ارزیابی قرار داد. سپس می‌توان شبکه را با اطلاعات جدیدی که آموزش با آن‌ها صورت نگرفته اجرا نمود، در صورت آموزش صحیح شبکه، نتایج حاصل معمولاً مناسب بوده و دقت جواب قابل قبول بودن آموزش شبکه را تأیید می‌نماید.

### روش رگرسیون خطی

بررسی رابطه خطی بین دو متغیر بارش و رواناب مدنظر است. هدف از این سنجش به‌دست آوردن یک رابطه برای پیش‌بینی روزهایی است که مقدار بارندگی اندازه گرفته شده است اما مقدار رواناب جریان اندازه-گیری نشده است. برای به‌دست آوردن این رابطه‌ی خطی باید مراحل زیر را انجام داد:

### آزمون‌های آماری متغیرهای $B_0$ و $B_1$

مقادیر  $p$ -value به‌دست آمده از آزمون‌های آماری نشان‌دهنده‌ی این است که بین این دو پارامتر رابطه‌ی خطی وجود دارد.

### بررسی Residual

در رابطه‌ی خطی به‌دست آمده یک مقدار مشخص خطا وجود دارد که معادله را بصورت رابطه ۹ تبدیل می‌کند. داده‌هایی که از اختلاف بین مقادیر دبی مشاهداتی و مقادیر بدست آمده از رابطه خطی به دست می‌آیند، باید دارای این ویژگی‌ها باشند: اولادارای واریانس ثابت باشند و ثانیاً توزیع این مقادیر باید نرمال باشد و ثالثاً این داده‌ها باید تصادفی باشند.

$$Q = B_0 + B_1 * P \quad (9)$$

### الف) بررسی نرمال بودن و تصادفی بودن مقادیر باقی‌مانده

برای نشان دادن نرمال بودن مقادیر باقی‌مانده باید از نمودار جعبه‌ای و همچنین از آزمون  $ppcc^7$  استفاده کرد. در این آزمون از دو فرض  $H_0$ : داده‌ها نرمال هستند و فرض  $H_1$ : داده‌ها نرمال نیستند استفاده می‌شود به این صورت که مقادیر همبستگی بین داده‌های مشاهداتی و مدل محاسبه شده و با همبستگی جدول  $r^*$  (این مقادیر در جداول آماری ارائه می‌شود) مقایسه می‌شوند در صورتی که  $r$  بزرگتر از  $r^*$  داده‌ها از توزیع نرمال پیروی خواهند کرد و در غیر این صورت داده‌ها از توزیع نرمال تبعیت نمی‌کنند [8].

برای نشان دادن تصادفی بودن مقادیر باقیمانده از آزمون دوربین واتسون<sup>8</sup> استفاده می‌شود، آزمون دوربین-واتسون یک آماره آزمون است که برای بررسی وجود خود همبستگی در بین باقی‌مانده‌ها در رگرسیون به کار برده می‌شود. مقدار این آماره همواره بین ۰ تا ۴ قرار می‌گیرد. در تحلیل رگرسیون بخصوص زمانی که متغیرها در طول یک فاصله زمانی مورد مطالعه قرار می‌گیرند ممکن است تغییر داده‌ها در طول زمان از الگوی خاصی پیروی کند برای تشخیص این الگو از آزمون دوربین واتسون استفاده می‌شود. اگر بین باقیمانده‌ها همبستگی متوالی وجود نداشته باشد، مقدار این آماره باید به ۲ نزدیک باشد. اگر به صفر نزدیک باشد نشان دهنده همبستگی مثبت و اگر به ۴ نزدیک باشد نشان دهنده همبستگی منفی است [10]. با توجه به نتایج به‌دست

<sup>8</sup> Durbin-Watson test

<sup>9</sup> Confidence Intervals

<sup>7</sup> Probability plot correlation coefficient



The following non linear module parameters have been set for calibration period 1.

mass balance term (c)	0.000833
drying rate at reference temperature (tw)	10.000000
temperature dependence of drying rate (f)	3.900000
reference temperature (tref)	20.000000
moisture threshold for producing flow (l)	0.000000
power on soil moisture (p)	1.000000


The following linear module parameters have been set for calibration period 1.

Recession rate 1 ( $\alpha^{(s)}$ )	-0.770	Time constant 1 ( $\tau^{(s)}$ )	3.824
Peak response 1 ( $\beta^{(s)}$ )	0.230	Volume proportion 1 ( $\lambda^{(s)}$ )	1.000


شکل ۶- ضرایب ثابت محاسبه شده ایستگاه طشک-بختگان

### رابطه‌ی خطی بین داده‌های بارش و رواناب(SLR):

با توجه به شکل ۷ مشخص است که تغییرات دبی در راستای محور X یک مقدار ثابت ندارد. برای حل این دو مشکل باید از تبدیل‌های مختلف استفاده کرده و در نهایت شکلی انتخاب می‌شود که دارای بهترین حالت و بیشترین ضریب رگرسیون باشد(شکل ۸).



شکل ۷- رابطه دبی- بارش



شکل ۸- بهترین تبدیل استفاده شده برای بارش-رواناب رابطه‌ی خطی به‌دست آمده بین داده‌ها  $y = 2.4529x + 20.915$  و ضریب رگرسیون اندازه‌گیری شده  $R^2 = 0.0682$  است. و  $s = 35.13$ .

جدول ۲- ضرایب مقادیر به‌دست آمده از رابطه‌ی خطی محاسبه شده

	مقدار	SE(B)	t-value	Pvalue
B0	20.92	2.46	43.63	0.00
B1	2.45	0.48	5.12	0.00

جدول ۳- مقادیر به‌دست آمده رابطه خطی محاسبه شده

	SSX	SSY	S2	s	Sxy	ave x	avey
	5370.83	474111.18	1234.07	35.13	13174.16	3.38	29.20

دو معیار برای نشان دادن اثرگذار بودن داده‌های leverage هستند که بصورت زیر هستند:

### معیار D کوک:

اگر  $D_i$  بیشتر از  $f(p+1, n-p)$  باشد اثر آن داده زیاد است و مقدار بحرانی برای بیش از ۳۰ داده و برای یک رابطه‌ی خطی برابر با ۲.۴ است [10].

$$D_i = \frac{e(i)^2 \hat{\sigma}_i}{ps^2} \quad (17)$$

در رابطه فوق  $h_i$  برابر است با leverage که در بخش ۲-۷ توضیح داده شد،  $s^2$  میانگین مربعات خطای مدل رگرسیون،  $e(i)$  باقی مانده  $i$  ام و  $p$  تعداد پارامترها می‌باشد.

### معیار DFFITS:

اگر این مقدار بیشتر از  $2\sqrt{\frac{p}{n}}$  باشد، Leverage تاثیر گذار است [10].

$$DFFITS = t_{i(i)} \sqrt{\frac{\hat{\sigma}_i}{1 - \hat{\sigma}_i}} \quad (18)$$

تمامی پارامترهای مورد نظر در بخش‌های قبلی توضیح داده شده است.


## نتایج

### نتایج مربوط به مدل بارش رواناب IHACRES


برای حوضه‌ی طشک-بختگان ضریب تبیین محاسبه شده در مرحله واسنجی ۰.۶ و کمترین مقدار خطای نسبی ۰.۰۶ در این مرحله است. میزان ضریب تبیین برای مرحله صحت سنجی ۰.۵۲ می‌باشد در صورتی که مقدار قابل قبول برای ضریب تبیین در مرحله کالیبراسیون و شبیه‌سازی مقادیر بیش از ۰.۶ است. همچنین ضرایب ثابت محاسبه شده از مدل IHACRES مربوط به حوضه به ترتیب در شکل‌های ۴ تا ۶ نشان داده شده است.

### جدول ۱- نتایج عملکرد مرحله واسنجی برای مدل IHACRES در حوضه طشک - بختگان

نام ایستگاه	(tw)	(f)	(tref)	(l)	Bias (mm/yr)	R Squared	R2_sqrt	ARPE
طشک-بختگان	10.00	3.90	20.00	0.00	2.07	0.60	0.70	0.06




### شکل ۴- جریان مشاهداتی و شبیه‌سازی شده برای دوره صحت سنجی ایستگاه پل‌خان.



### شکل ۵- شکل خطی مربوط به مرحله صحت سنجی حوضه طشک-بختگان

با رسم شکل جعبه‌ای هر کدام از ماه‌ها مقادیر  $e$  باید میانگین همه‌ی شکل‌های جعبه‌ای صفر باشد در صورتیکه با توجه به شکل ۱۲ مقادیر ماه‌های مهر، آبان، آذر، دی و بهمن کمتر از مقادیر واقعی تخمین زده شده و در ماه‌های فروردین و اسفند مقدار دی بیشتر از مقادیر واقعی تخمین زده شده است.



شکل ۱۲- شکل جعبه‌ای مقادیر باقی‌مانده به تفکیک ماه-های مختلف

با توجه به نتایج به دست آمده از این آزمون داده‌ها تصادفی نبوده و بر روی یکدیگر تاثیرگذار هستند. در این پژوهش از تبدیل‌های دیگر نیز استفاده شد اما در همه‌ی حالات مقادیر  $e$  تصادفی نبوده و این نشان دهنده‌ی غیر خطی بودن رابطه‌ی بین بارش و رواناب است. با توجه به جدول ۳ مشاهده می‌شود که در ۱۱ نقطه داده‌ها در راستای  $x$  و چهار داده در راستای  $y$  دارای leverage هستند، زیرا مقدار  $3p/n$  برابر با  $0.16$  است و مقادیر  $h_i$  برای این داده‌ها بیش از این مقدار است. برای تعیین اثرگذار بودن این leverage ها از معیار  $D$  کوک و  $DFFITs$  استفاده شده است. برای استفاده از معیار  $D$  کوک باید  $f(p+1, n-p)$  از جدول مربوطه به  $F$  فیشر محاسبه شود اما چون تعداد داده‌ها بیش از ۳۰ عدد است باید با مقدار  $2.4$  مقایسه شود، همانطور که مشاهده می‌شود هیچ یک از داده‌های Leverage با توجه به معیار  $D$  کوک دارای leverage تاثیرگذاری نیستند. و برای بررسی این داده‌ها با معیار  $DFFITs$  باید مقادیر به دست آمده با مقدار  $2\sqrt{\frac{p}{n}}$  (برابر با  $0.15$ ) مقایسه شود، اگر این مقادیر از مقدار  $DFFITs$  بزرگتر باشند این نشان دهنده‌ی تاثیرگذاری آن نقطه است. با توجه به جدول ۳ و همچنین مقادیر محاسباتی leverage محاسبه شده تاثیرگذار نمی‌باشد.


جدول ۳- آماره‌های رگرسیونی داده‌ها

راستا	$D_i$	$DFFITs$	$e$ استیوننت	$e$ استاندارد	$e(i)$	$h_i$	$el$	$e(i)^2$	$e(i)$
x	0.00000	0.0002	0.00	0.04	0.04	0.03	1.31	1237.52	35.18
x	0.00001	-0.0045	-0.03	-1.12	1.14	0.02	-38.87	1237.52	35.18
x	0.00000	0.0001	0.00	0.03	0.03	0.02	1.15	1237.52	35.18
x	0.00004	0.0087	0.06	2.24	2.28	0.02	77.92	1237.51	35.18
x	0.00001	-0.0039	-0.03	-1.04	1.06	0.02	-36.28	1237.52	35.18
x	0.00001	-0.0034	-0.02	-0.79	0.81	0.02	-27.59	1237.52	35.18
x	0.00001	-0.0039	-0.03	-1.06	1.08	0.02	-37.08	1237.52	35.18
x	0.00001	-0.0043	-0.03	-1.17	1.19	0.02	-40.71	1237.52	35.18
x	0.00001	0.0045	0.03	0.93	0.95	0.03	32.12	1237.52	35.18
x	0.00000	0.0013	0.01	0.23	0.24	0.04	8.11	1237.52	35.18
y	0.00002	0.0063	0.08	2.64	2.66	0.01	92.31	1237.50	35.18
y	0.00049	0.0312	0.28	9.80	9.92	0.01	342.15	1237.25	35.17
y	0.00005	0.0101	0.19	6.66	6.68	0.00	233.65	1237.40	35.18
y	0.00008	0.0122	0.16	5.45	5.48	0.01	190.70	1237.44	35.18
x	0.00000	0.0019	0.01	0.47	0.48	0.02	16.42	1237.52	35.18

### نتایج شبکه عصبی

در این پژوهش لایه‌ی ورودی شبکه‌ی مصنوعی دارای دو نرون بوده

با توجه به مقادیر  $p$ -value به دست آمده از آزمون‌های آماری نشان- دهنده‌ی این است که بین دو پارامتر بارش و دما رابطه‌ی خطی وجود دارد.




شکل ۹- پراکندگی مقادیر باقی‌مانده


با توجه به شکل ۹ واریانس‌های مقادیر  $e$  ثابت نیستند. این مرحله برای تبدیل‌های دیگر نیز بررسی شده است که نشان می‌دهد در تبدیل‌های دیگر نیز رابطه‌ی خطی بین رواناب و بارش وجود ندارد و عوامل موثر دیگری نیز وجود دارند که در محاسبات بررسی نشده‌اند و رابطه‌ی بین آن‌ها غیر خطی است.

به منظور بررسی نرمال بودن داده‌ها از دو روش آزمون PPCC و نمودار جعبه‌ای استفاده شده است. نتایج حاصل از بررسی آزمون PPC به این صورت می‌باشد که میزان همبستگی محاسباتی  $r$  با  $0.82$  بوده که این مقدار از همبستگی جدول  $r^*$  که برابر است با  $0.98$  کمتر می‌باشد. در این حالت داده‌ها از توزیع نرمال پیروی نکرده و فرض صفر رد می‌شود. همچنین با توجه به نمودار جعبه‌ای هر چند نمودار و خطوط متقارن می‌باشند با این حال تعداد زیاد داده‌های پرت و خیلی پرت باعث انحراف در توزیع داده‌ها شده است. به همین دلیل شکل ۱۰ نیز بیان‌گر این مساله بوده که داده‌ها نرمال نمی‌باشند. در صورتیکه آزمون‌های  $B_0$  و  $B_1$  با فرض نرمال بودن مقادیر  $e$  انجام شد حال آنکه  $e$  نرمال نیست و نمی‌توان از این آزمون‌ها استفاده کرد.

شکل ۱۱ روند موجود در داده‌ها را نشان می‌دهد (خط برازش داده شده بیان‌گر وجود روند در داده‌های ترسیم شده می‌باشد) با توجه به این شکل می‌توان گفت که مقدار  $e$  دارای روند می‌باشد. همانگونه که مشخص است داده‌های فصول مختلف بر روی این مقادیر تاثیرگذار است و این نشان دهنده‌ی تصادفی نبودن داده‌هاست.




شکل ۱۰- نمودار جعبه‌ای مقادیر e

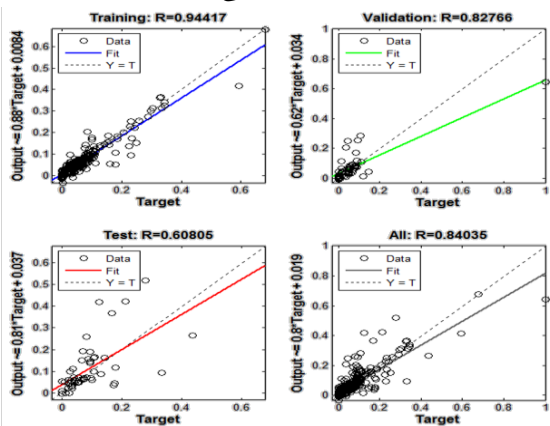


شکل ۱۱- تاثیر زمان بر مقادیر باقی‌مانده و تصادفی نبودن داده‌ها

توانسته میزان رواناب را در حوضه طشک-بختگان با دقت مناسبی برآورد کند.



شکل ۱۳- خطای بین داده‌های مشاهده‌ای و محاسبه شده شبکه عصبی



شکل ۱۴- ضریب همبستگی در مراحل مختلف شبکه عصبی

رواناب و بارش عملا روش رگرسیون خطی در این پژوهش جهت شبیه‌سازی میزان رواناب نمی‌تواند مورد استفاده قرار گیرد با این حال به دلیل این که شبکه عصبی توانایی برقراری رابطه غیر خطی بین متغیرهای مختلف آب و هواشناسی را دارد از این حیث می‌توان به عنوان یک روش کارا از شبکه عصبی در پژوهش‌های آتی به منظور برآورد میزان رواناب در سطح حوضه طشک-بختگان بهره برد.

### پیشنهادها

پیشنهادهای مربوط به ادامه این تحقیق در طول بخش‌های مختلف مقاله ارائه گردیده است تا خوانندگان در هر بخش از پیشنهادها موجود مطلع گردیده و در صورت نیاز آنها را دنبال کنند.

### ملاحظات اخلاقی پیروی از اصول اخلاق پژوهش

همکاری مشارکت‌کنندگان در تحقیق حاضر به صورت داوطلبانه و با رضایت آنان بوده است.

که این ورودی‌ها شامل بارش و دما هستند، و لایه‌ی خروجی دارای یک نرون (Node) است، به ازای معماری‌های مختلف (تعداد نرون‌های لایه پنهان) میزان خطای نسبی و ضریب رگرسیون‌ها محاسبه شده است. ضریب رگرسیون‌ها و خطاهای نسبی محاسبه شده برای کم شدن خطا به ازای هر کدام از معماری‌ها، سه بار اجرا شده و میانگین آن‌ها گزارش شده است. از ۷۰ درصد از داده‌های آموزش شبکه و از ۱۵ درصد از داده‌ها برای اعتبار سنجی و از ۱۵ درصد باقی‌مانده از داده‌ها برای تست استفاده شد. الگوریتم یادگیری مورد استفاده الگوریتم انتشار خطا به سمت عقب<sup>۱۰</sup> بود. با توجه به جدول ۴ بهترین معماری شبکه ۲.۱۸.۱ است که دارای مقدار خطای نسبی میانگین کمتری نسبت به حالت‌های مختلف است. در این پژوهش برای آموزش و تست شبکه‌ی عصبی از Tool Box سری زمانی شبکه عصبی و با ساختار پویا استفاده شده است. شکل ۱۳ نشان دهنده خطای بین داده‌های مشاهده‌ای و محاسبه شده شبکه عصبی است.

### جدول ۴- معماری‌های مختلف شبکه عصبی

معماری شبکه	mse T	mse vali	mse Test	R T	R Vali	R Test	Rave
2.8.1	0.0066	0.0073	0.0064	0.61	0.83	0.55	0.66
2.10.1	0.005	0.0054	0.0042	0.81	0.72	0.93	0.82
2.12.1	0.0028	0.0038	0.011	0.86	0.76	0.57	0.73
2.14.1	0.0019	0.0036	0.0017	0.87	0.86	0.88	0.87
2.16.1	0.0031	0.003	0.0036	0.83	0.75	0.67	0.75
2.18.1	0.0017	0.001	0.0096	0.91	0.83	0.67	0.80
2.20.1	0.00078	0.0057	0.0085	0.94	0.82	0.6	0.79

در شکل ۱۴ نیز میزان شاخص‌های آماری مربوط به شبکه عصبی در مراحل مختلف یادگیری و صحت‌سنجی مشاهده می‌شود. با توجه به شکل ۱۴ می‌توان گفت که شبکه عصبی تا حدودی

### بحث و نتیجه‌گیری

در این پژوهش از مدل هیدرولوژیکی IHACRES برای شبیه‌سازی جریان ماهانه و محاسبه میزان بارشی که به جریان رودخانه می‌پیوندد، و از شبکه عصبی برای پیش‌بینی رواناب حوضه طشک-بختگان استفاده شد. همچنین وجود رابطه‌ی خطی بین مقادیر بارش و رواناب نیز بررسی شد. نتایج مدل هیدرولوژیکی IHACRES نشان داد که مقدار ضریب تبیین واسنجی برای ایستگاه پل‌خان ۰.۶ ضریب تبیین صحت‌سنجی ۰.۵۱ است. همچنین مقدار ضریب تبیین در شبکه‌ی عصبی با معماری شبکه ۱-۱۸-۲ بطور میانگین برابر با ۰.۸۰ است. مقایسه‌ی بین این دو روش نشان می‌دهد شبکه‌ی عصبی دارای دقت بیشتری برای تخمین رواناب با استفاده از مقدار جریان نسبت به مدل IHACRES است. با استفاده از بررسی رابطه‌ی خطی بین داده‌های بارش و رواناب نشان داده شد که رابطه‌ی بین این دو پارامتر خطی نیست و دلیل دقت بیشتر مدل شبکه عصبی برقراری یک رابطه‌ی غیر خطی بین داده‌ها است. در حالت کلی می‌توان گفت که به دلیل رابطه غیرخطی بین میزان

<sup>10</sup> Error back propagation

هزینه تحقیق حاضر توسط نویسندگان مقاله تامین شده است.

بنابر اظهار نویسندگان، مقاله حاضر فاقد هرگونه تعارض منافع بوده است.

### مشارکت نویسندگان

طراحی و ایده پردازی: آیدین باختر، علیرضا پیل پایه؛ روش شناسی و تحلیل داده‌ها: اکبر رحمتی، افشین شایقی، آیدین باختر؛ نظارت و نگارش نهایی: علیرضا پیل پایه.

### References

- Mengistu, K.T. Watershed Hydrological Responses to Changes in Land Use and Land Cover, and Management Practices at Hare Watershed, Ethiopia. 2009.
- Te Linde, A.H.; Aerts, J.; Hurkmans, R.; Eberle, M. Comparing Model Performance of Two Rainfall-Runoff Models in the Rhine Basin Using Different Atmospheric Forcing Data Sets. *Hydrol. Earth Syst. Sci.* 2008, 12, 943–957.
- Dye, P.J.; Croke, B.F.W. Evaluation of Streamflow Predictions by the IHACRES Rainfall-Runoff Model in Two South African Catchments. *Environ. Model. Softw.* 2003, 18, 705–712.
- Dakhlou, H.; Ruelland, D.; Trambly, Y.; Bargaoui, Z. Evaluating the Robustness of Conceptual Rainfall-Runoff Models under Climate Variability in Northern Tunisia. *J. Hydrol.* 2017, 550, 201–217.
- Khazaee Poul, A.; Shourian, M.; Ebrahimi, H. A Comparative Study of MLR, KNN, ANN and ANFIS Models with Wavelet Transform in Monthly Stream Flow Prediction. *Water Resour. Manag.* 2019, 33, 2907–2923.
- Lotfirad, M.; Salehpoor Laghani, J.; Ashrafzadeh, A. Using the IHACRES Model to Investigate the Impacts of Changing Climate on Streamflow in a Semi-Arid Basin in North-Central Iran. *J. Hydraul. Struct.* 2019, 5, 27–41.
- Ahmadi, M.; Moeini, A.; Ahmadi, H.; Motamedvaziri, B.; Zehtabiyani, G.R. Comparison of the Performance of SWAT, IHACRES and Artificial Neural Networks Models in Rainfall-Runoff Simulation (case Study: Kan Watershed, Iran). *Phys. Chem. Earth, Parts A/B/C* 2019, 111, 65–77.
- Abolverdi, J.; Khalili, D. Probabilistic Analysis of Extreme Regional Meteorological Droughts by L-Moments in a Semi-Arid Environment. *Theor. Appl. Climatol.* 2010, 102, 351–366.
- Jakeman, A.J.; Hornberger, G.M. How Much Complexity Is Warranted in a Rainfall-runoff Model? *Water Resour. Res.* 1993, 29, 2637–2649.
- Helsel, D.R.; Hirsch, R.M. *Statistical Methods in Water Resources*; Elsevier, 1992; Vol. 49; ISBN 0444885285.
- Bal, P.K.; Ramachandran, A.; Geetha, R.; Bhaskaran, B.; Thirumurugan, P.; Indumathi, J.; Jayanthi, N. Climate Change Projections for Tamil Nadu, India: Deriving High-Resolution Climate Data by a Downscaling Approach Using PRECIS. *Theor. Appl. Climatol.* 2016, 123, 523–535.
- فعالان: روشن، ح.ن.؛ روشن، ح.ن.؛ شاهی، شاهی؛ قنبرپور؛ قنبرپور کالیبراسیون و ارزیابی مدل هیدرولوژیکی IHACRES به منظور شبیه سازی جریان روزانه. آب و خاک ۲۰۱۱، ۲۵.
- مقدم، ر.؛ حجازی؛ میراسدالله؛ بهبودی؛ عبدالله واسنجی و ارزیابی عملکرد مدل IHACRES در شبیه سازی رواناب در زیرحوضه ی آبریز لنبران، اهرچای. هیدروژئومورفولوژی ۲۰۱۹، ۶، ۱۸۷–۲۰۴.