

Research Paper

Evaluation of the Artificial Neural Network Performance in Estimating Rainfall using Climatic and Geographical Data (Case study: Fars Province)Mehdi Bahrami^{1*} , Amir Salari² , Mohammad Javad Amiri³ , Amir Bahrami⁴ 

¹ Associate Professor, Department of Water Engineering, Faculty of Agriculture, Fasa University, Iran, bahrami@fasau.ac.ir

² Assistant Professor, Department of Water Science and Engineering, Minab higher education center, University of Hormozgan, Iran, salari.1361@yahoo.com

³ Associate Professor, Department of Water Engineering, Faculty of Agriculture, Fasa University, Iran, mj_amiri@fasau.ac.ir

⁴ Assistant Professor, Department of Soil Science, Faculty of Agriculture, Tarbiat Modares University, Iran. bahramisoil@gmail.com



10.22125/IWE.2023.168171

Received:

April 27, 2021

Accepted:

February 4, 2022

Available online:

April 18, 2023**Keywords:****Data Preprocessing, Artificial Neural Network, Rank Normalization****Abstract**

Precipitation forecasting is essential in maintaining, managing, allocating, and distributing water resources, determining the volume of water facilities, supplying the crops' water requirement, and determining the amount of erosion and sedimentation. This research aimed to investigate the performance of artificial neural networks in predicting monthly rainfall based on climatic and geographic information such as minimum and maximum temperature, minimum and maximum humidity, precipitation, latitude and longitude, and altitude above sea level in 23 stations of the Fars province. The results on levels 5, 10, and 18 of input data showed that the model accuracy in estimating the monthly rainfall increases with the increment in the number of inputs. The most accurate neural network model is in the rank normalization method with one hidden layer, and also, the best network structures are 5-25-1, 10-30-1, and 18-20-1, respectively. The results indicated that the neural network with 18 inputs has the smallest MSE=0.032 and the highest R=0.62. The best normalization method is the ranking method with an optimal neural network of one layer and 5-25-1 structure, the Levenberg-Marquardt training algorithm, and the sigmoid tangent stimulus function. Therefore, by using an artificial neural network (with 18 introduced inputs), it is possible to predict the amount and distribution of monthly rainfall in a wide area with acceptable accuracy. This issue plays a very decisive role in the management and planning of drinking and agricultural water resources; by taking into account these forecasts, future policies can be planned to optimize costs and maximum productivity facilities.

1. Introduction

Prediction of precipitation as one of the most important factors of the hydrological cycle plays a vital role in water resources management, reservoir volume determination, allocation and distribution of water resources, supply of plants water requirement as well as erosion and sedimentation. There are

* **Corresponding Author:** Mehdi Bahrami

Address: Department of Water Engineering, Fasa University, Fasa, Iran

Email: bahrami@fasau.ac.ir

Tel: 09176096561

several methods for predicting rainfall. Recently, intelligent systems based on empirical data, such as artificial neural networks, transfer knowledge or the law behind data to the network structure by processing the data. This study aimed to evaluate the performance of artificial neural networks in predicting monthly rainfall at 23 stations in Fars province using climatic and geographical information such as minimum temperature, maximum temperature, minimum humidity, and maximum humidity, rainfall of the previous month, two months before, and the same month of the last year, longitude, latitude, and altitude. In this regard, the activation functions and training algorithms in the artificial neural network Newff simulation function in the MATLAB environment were used for simulation.

2. Materials and Methods

The study area includes the counties of Shiraz, Kazerun, Marvdasht, Larestan, Jahrom, Fasa, Darab, Firoozabad, Noorabad Mamasani, Abadeh, Eghlid, Sepidan, Lamerd, Zarrin Dasht, Estahban, Qirokarzin, Bavanat, Farashband, Arsanjan, Izadkhast, Dorudzan, Safashahr, and Neyriz. To evaluate the performance of artificial neural networks in estimating rainfall in 23 synoptic stations of the province, daily meteorological data and geographical information of these stations were used. Initially, a correlation matrix was used to determine the relationship between temperature, relative humidity, pressure, sunshine hours, and precipitation (monthly) parameters and data preprocessing operations were performed for each station. After detecting the correlation between climatic parameters and rainfall, daily data were converted into monthly data, lost data were estimated, and outlier data were deleted. The data normalization process was performed using minimum-maximum, standard normal, and rank normalization methods. A perceptron with 1, 2, and 3 hidden layers was used for modeling, and finally, the best type of network was selected with the least error. After determining the inputs and outputs of the network, 80% of the data was used for network training and 20% for network testing. In this study, the Levenberg-Marquardt algorithm was used to train neural networks, due to having the fastest convergence. To determine the error that occurred in both steps of training and testing, the parameters of mean square error (MSE), mean absolute value of error (MAE), compliance index (d), and correlation coefficient (R) were calculated.

3. Results

The results at levels 5, 10, and 18 of the input data showed that the accuracy of the model in estimating the amount of monthly precipitation increases with increasing the number of inputs. The most accurate neural network model was obtained in the rank normalization method with one hidden layer, and the best network structures were obtained in the structure of 1-25-5, 1-30-10, and 1-20-18, respectively. Also, results indicated that the neural network with 18 inputs has the smallest MSE (0.032) and the highest R (0.62). The best normalization method was the ranking method with optimal single-layer neural network and structure 1-25-5, and Levenberg-Marquardt training algorithm and sigmoid tangent stimulus function.

4. Discussion and Conclusion

Adding geographical parameters, including latitude, longitude, and altitude for each station as network inputs, decreased the MSE value and increased the correlation coefficient and compliance index. In other words, by adding geographical features to the input parameters, the accuracy and efficiency of the artificial neural network model increased. Comparison of the results showed that the appropriate inputs for forecasting rainfall in Fars province are the parameters of the previous month, two months ago, geographical characteristics, and clustering of months into wet and dry months with cluster codes 1 and 2. Overall, using an artificial neural network (introduced with 18 inputs), the amount and distribution of monthly rainfall over a large area can be predicted with acceptable accuracy.

5. Six important references

1) Anochi, J.A., V.A. de Almeida and H.F. de Campos Velho. 2021. Machine Learning for Climate Precipitation Prediction Modeling over South America. *Remote Sens*, 13: 2468. <https://doi.org/10.3390/rs13132468>

2) Bahrami, M., and M.R. Mahmoudi. 2020. Rainfall modelling using backward generalized estimating equations: a case study for Fasa Plain, Iran. *Meteorology and Atmospheric Physics*, 132:1-9.

3) Bustami, R., N. Bessaih, C. Bong, and S. Suhaili. 2007. Artificial Neural Network for Precipitation and Water Level Predictions of Bedup River. *IAENG International Journal of Computer Science*, 34: 2-10.

4) Dahamsheh, A. and H. Aksoy. 2009. Artificial neural network models for forecasting monthly precipitation in Jordan. *Stochastic Environmental Research and Risk Assessment*, 23: 917 - 931

5) El-Shafie, A.H, A. El-Shafie, H.G. El. Mazoghi, A. Shehata, and M.R. Taha. 2011. Artificial Neural Network Technique for Rainfall Forecasting Applied to Alexandria." *International Journal of the Physical Sciences*, 6: 1306-1316.

6) Karen, A.L.S. 2010. Comparison of Adaptive Methods Using Multivariate Regression Splines (MARS) and Artificial Neural Networks Backpropagation (ANNB) for the Forecast of Rain and Temperatures in the Mantaro River Basin. *Hydrology Days*, pp: 58-68.

Conflict of Interest

Authors declared no conflict of interest.



بررسی عملکرد شبکه عصبی مصنوعی در تخمین میزان بارش با استفاده از داده- های اقلیمی و جغرافیایی (مطالعه موردی: استان فارس)

مهدی بهرامی^۱، امیر سالاری^۲، محمدجواد امیری^۳، امیر بهرامی^۴

تاریخ ارسال: ۱۴۰۰/۰۷/۰۲

تاریخ پذیرش: ۱۴۰۰/۱۱/۱۵

مقاله پژوهشی

چکیده

پیش‌بینی بارش از نقش مهمی در حفظ، مدیریت، تخصیص و توزیع منابع آب، تعیین حجم تأسیسات آبی، تأمین نیاز آبی محصولات و همچنین تعیین مقدار فرسایش و رسوب برخوردار است. روش‌های مختلفی جهت پیش‌بینی بارش وجود دارد. این پژوهش با هدف بررسی عملکرد شبکه‌های عصبی مصنوعی در پیش‌بینی بارش ماهانه بر اساس اطلاعات اقلیمی و جغرافیایی نظیر دمای حداقل و حداکثر، رطوبت حداقل و حداکثر، بارش، طول و عرض جغرافیایی و ارتفاع از سطح دریا در سطح ۲۳ ایستگاه استان فارس اجرا گردید. نتایج در سطح ۵، ۱۰ و ۱۸ داده ورودی نشان داد با افزایش تعداد ورودی دقت مدل در تخمین میزان بارش ماهانه افزایش می‌یابد. دقیق‌ترین مدل شبکه عصبی در روش نرمال‌سازی رتبه‌ای با یک لایه مخفی و بهترین ساختارهای شبکه نیز به ترتیب در ساختار ۱-۲۵-۵، ۱-۳۰-۱۰ و ۱-۲۰-۱۸ می‌باشد. نتایج نشان داد که شبکه عصبی با ۱۸ ورودی دارای کوچک‌ترین $MSE=0.032$ و بالاترین $R=0.62$ می‌باشد. بهترین روش برای نرمال‌سازی، روش رتبه‌ای با شبکه عصبی بهینه یک لایه و ساختار ۱-۲۵-۵ و الگوریتم آموزش لوبزبرگ-مارکوارت و تابع محرک تانژانت سیگموئید می‌باشد. بنابراین با استفاده از شبکه عصبی مصنوعی (با ۱۸ ورودی معرفی شده) می‌توان مقدار و توزیع بارش ماهانه منطقه وسیعی را با دقت قابل قبولی پیش‌بینی نمود. این موضوع نقش بسیار تعیین‌کننده‌ای در مدیریت و برنامه‌ریزی منابع آب شرب و کشاورزی ایفا می‌کند؛ به طوری که می‌توان با در نظر گرفتن این پیش‌بینی‌ها، سیاست‌های آینده را در جهت بهینه‌سازی صرف هزینه‌ها و امکانات بهره‌وری حداکثر طرح‌ریزی کرد.

واژه‌های کلیدی: پیش‌پردازش داده‌ها، شبکه عصبی مصنوعی، نرمال‌سازی رتبه‌ای

^۱ دانشیار، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه فسا، ایران، ۰۹۱۷۶۰۹۶۵۶۱، bahrami@fasau.ac.ir (نویسنده مسئول)
^۲ استادیار، گروه مهندسی آب، دانشکده کشاورزی، مجتمع آموزش عالی میناب، دانشگاه هرمزگان، ایران، ۰۹۱۵۶۵۰۱۰۴۷، salari.1361@yahoo.com
^۳ دانشیار، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه فسا، ایران، ۰۹۱۷۳۱۵۷۶۸۸، mj_amiri@fasau.ac.ir
^۴ استادیار، گروه علوم خاک، دانشکده کشاورزی، دانشگاه تربیت مدرس، ایران، ۰۹۹۰۴۱۲۹۱۸۲، bahramisoil@gmail.com

مقدمه

بارش به‌عنوان یکی از مهمترین عوامل چرخه هیدرولوژیکی نقش بسزایی در مدیریت، برنامه‌ریزی و تدوین استراتژی‌ها و تخصیص و توزیع بهینه منابع آبی و همچنین کاهش ریسک خشکسالی و یا خطر وقوع سیلاب و مباحث مهم دیگری از جمله فرسایش و رسوب، تأمین نیاز آبی محصولات کشاورزی و بیلان منابع آب‌های زیرزمینی هر منطقه‌ای دارد (بهرامی و همکاران، ۱۳۹۴؛ Bahrami and Mahmoudi., 2020). هر چند ثبت بارش‌ها به‌طور منظم در ایستگاه‌های هواشناسی صورت می‌گیرد اهمیت پیش‌بینی بارش‌های آبی در بخش‌های مختلف از جمله حمل و نقل و ترابری و کشاورزی (جهت انجام عملیات کاشت، داشت و برداشت) و همچنین پراکندگی و توزیع مکانی این ایستگاه‌ها و نبود اطلاعات کامل در همه نقاط و همچنین نبود اطلاعات ثبتی قبل از ایجاد ایستگاه و خرابی دستگاه‌ها و یا قرائت اشتباه کاربر موجب می‌گردد تا با کمک سایر روش‌ها از جمله روش‌های شبکه عصبی مصنوعی به پیش‌بینی و ساخت داده‌های خام و ترسیم نقشه‌های توزیع مکانی بارش اقدام نمود. تحقیقات نشان می‌دهد که بارش قابلیت پیش‌بینی‌پذیری با استفاده از روش‌های مختلف از جمله شبکه‌های عصبی مصنوعی را دارد (ایلدرومی و همکاران، ۱۳۹۲؛ بهرامی و همکاران، ۱۳۹۶). ماهیت انعطاف‌پذیر پیش‌بینی پارامترهای غیرخطی و توسعه روزافزون مدل‌های شبکه عصبی مصنوعی، باعث استفاده گسترده از این مدل‌ها در موضوعات و علوم مختلف گردیده است. تعیین هیدروگراف خروجی حوضه (Half et al., 1993)، پیش‌بینی مقدار بیشینه بارندگی و رخداد سیل (Boderi and Cermak., 2000)، برآورد مکانی و زمانی میانگین داده‌های اقلیمی (Antonic et al., 2001؛ Karen, 2010) و میانگین بارندگی ماهانه (کارآموز و همکاران، ۱۳۸۵؛ مینافی و محمدی، ۱۳۸۲؛ Maria et al.,

2005; Hung et al., 2008; Dahamsheh and Aksoy., 2009) از جمله این موضوعات بوده است. نتایج مقایسه شبکه‌های عصبی مصنوعی و رگرسیون چندمتغیره توسط (El-Shafie et al. (2011) و Dahamsheh and Aksoy (2009) حاکی از برتری و دقت بالاتر شبکه‌های عصبی مصنوعی است. (Bustami et al. (2007) دقت مدل-های عصبی مصنوعی را در پیش‌بینی بارش ۹۶/۴ درصد به‌دست آوردند. یکی از علل درجه موفقیت شبکه‌های عصبی مصنوعی، تعیین درست تعداد و نوع ورودی‌های مدل بوده و با افزایش تعداد ورودی‌های کاربردی، دقت مدل‌های به‌کار رفته افزایش یافته است (قربانی‌دشتکی و همکاران، ۱۳۸۸). کاربرد ۵ متغیر ورودی توسط کریمی‌گوغری و اسلامی (۱۳۸۷)، ۷ متغیر توسط (Maria et al. (2005) و خلیلی و همکاران (۱۳۸۷) و ۱۲ متغیر توسط فلاح‌قاهری و همکاران (۱۳۸۷) نشان‌دهنده دقت مناسب این مدل‌ها در پیش‌بینی بارش می‌باشد. محمدی و همکاران (۱۴۰۰) برای برآورد رواناب ناشی از وقوع بارندگی در مناطق ساحلی نزدیک تنگه هرمز از روش‌های داده‌کاوی مختلفی شامل الگوریتم جنگل تصادفی، ماشین بردار پشتیبان، شبکه عصبی مصنوعی، مدل الگوریتم‌های ارتقای شدید گرادیان، مدل درختی M5، مدل اسپلاین چند متغیره رگرسیون انطباقی، مدل فرایند گوسی و مدل بیزی جمعی رگرسیون درختی استفاده کردند. پژوهش‌های روش‌ها و همکاران (۱۴۰۰) نشانگر کارایی بهتر مدل شبکه عصبی مصنوعی (ANN) نسبت به مدل ماشین بردار پشتیبان (SVM) با تابع کرنل پایه شعاعی (RBF) در مدل‌سازی فرایند بارش- رواناب در حوضه آبخیز کارون شمالی بود. حسینی و همکاران (۱۴۰۱) توانایی مدل‌های شبکه‌های عصبی مصنوعی (ANN) و رگرسیون کم‌انکلی تطبیقی چند متغیره (MARS) را در تخمین دمای نقطه شبنم با استفاده از پارامترهای هواشناسی در ایستگاه سینوپتیک خوی ارزیابی کردند. (Anochi et al. (2021)

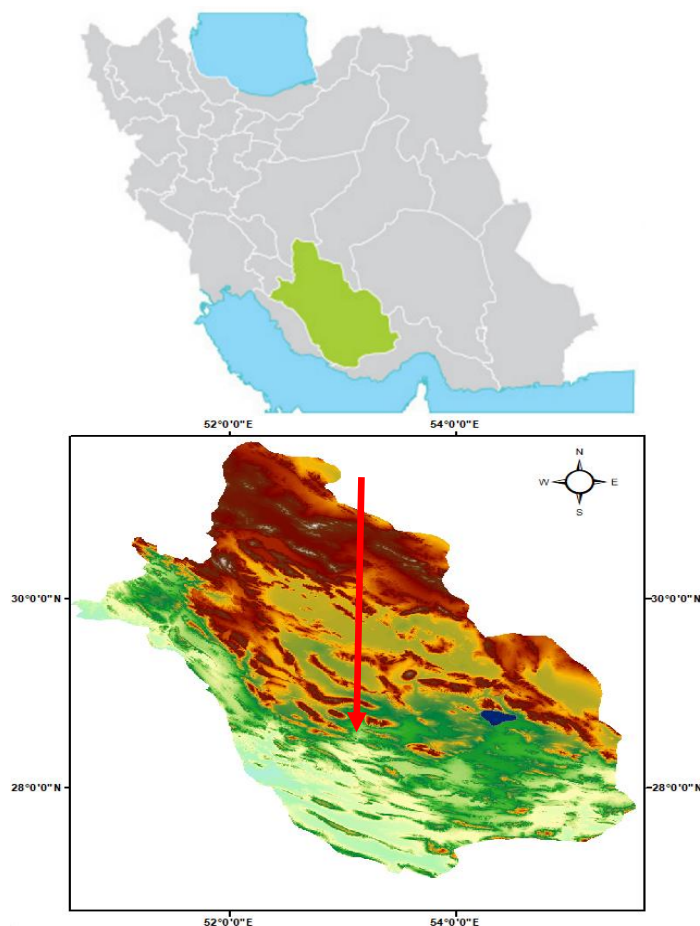


مواد و روش‌ها

منطقه مورد مطالعه شامل شهرستان‌های شیراز، کازرون، مرودشت، لارستان، جهرم، فسا، داراب، فیروزآباد، نورآباد ممسنی، آباده، اقلید، سپیدان، لامرد، زرین دشت، استهبان، قیر و کارزین، بوانات، فراشبند، ارسنجان، ایزدخواست، درودزن، صفاشهر و نی‌ریز می‌شود. موقعیت جغرافیایی منطقه مورد مطالعه بر روی نقشه ایران در شکل ۱ نشان داده شده است. استان فارس در جنوب و جنوب-غرب کشور بین طول‌های جغرافیایی ۳۶ درجه و ۵۰ دقیقه تا ۵۵ درجه و ۳۵ دقیقه شرقی و عرض‌های جغرافیایی ۲۷ درجه و ۳ دقیقه تا ۴۰ درجه و ۳ دقیقه شمالی قرار دارد.

قابلیت شبکه‌های عصبی مصنوعی را برای پیش‌بینی بارش فصلی در آمریکای جنوبی نشان دادند.

با توجه به مطالب ذکر شده در بالا، تحقیق حاضر با هدف ارزیابی دقت شبکه‌های عصبی مصنوعی انتشار برگشتی پیش‌خور در تخمین مقدار بارش ماهانه در ۲۳ ایستگاه واقع در استان فارس با استفاده از پارامترهای اقلیمی و جغرافیایی انجام شد. در این راستا، از توابع فعال-سازی و الگوریتم‌های آموزش موجود در تابع شبیه‌سازی Newff شبکه عصبی مصنوعی در محیط برنامه‌نویسی نرم-افزار Matlab برای شبیه‌سازی استفاده گردید.



شکل (۱): موقعیت جغرافیایی منطقه مورد مطالعه

روزانه هواشناسی و اطلاعات جغرافیایی این ایستگاه‌ها استفاده گردید. در ابتدا جهت تعیین ارتباط بین

برای بررسی عملکرد شبکه عصبی مصنوعی در تخمین میزان بارش در ۲۳ ایستگاه سینوپتیک استان، از داده‌های

جهت آموزش شبکه‌های عصبی چهار الگوریتم آموزشی مرسوم که بر اساس ساختار پرسپترون چند لایه می‌باشد، وجود دارد. معروف‌ترین این روش‌ها عبارتند از: انتشار خطا به عقب^۱، گرادیان مزدوج^۲ و لوبنبرگ-مارکوات^۳. در این پژوهش از الگوریتم لوبنبرگ-مارکوات که سریع‌ترین همگرایی را دارا می‌باشد، استفاده گردید. بعد از انتخاب الگوریتم مناسب برای آموزش شبکه می‌بایست تابع انتقال در هر لایه، تعداد لایه‌های پنهان، تعداد نرون‌های مورد نیاز، نرخ همگرایی، مقدار مومنتم، دوره‌های آموزشی و سایر پارامترها را نیز به شبکه معرفی نمود. برای انتقال خروجی-های هر لایه به لایه‌های بعدی معمولاً از توابع انتقال خطی، تانژانت هیپربولیک^۴ و سیگموئیدی^۵ استفاده می‌شود. جهت تدوین مدل‌های شبکه‌های عصبی در این پژوهش از آموزش الگو به الگو (اپاک) استفاده شد. عملیات تأیید عملکرد شبکه آموزش دیده با اندازه‌گیری خطاهای زیرمجموعه داده‌های آموزشی و فرآیند ارزیابی آن با اندازه-گیری خطاهای زیر مجموعه داده‌های آزمون صورت می‌گیرد. در این پژوهش، جهت تعیین خطای به‌دست آمده در هر دو مرحله آموزش و آزمون از پارامترهای میانگین مربعات خطا (MSE)، میانگین قدرمطلق خطا (MAE)، شاخص تطابق (d) و ضریب همبستگی (R) استفاده گردید که معادلات آنها به‌ترتیب به‌صورت زیر است:

$$MSE = \frac{1}{n} \sum_{i=1}^n (P_{sim} - P_{obs})^2 \quad (۴)$$

$$MAE = \frac{\sum_{i=1}^n |P_{sim} - P_{obs}|}{n} \quad (۵)$$

$$d = 1 - \frac{\sum_{i=1}^n (P_{sim} - P_{obs})^2}{\sum_{i=1}^n (|P_{sim} - P_{obs}| + |P_{obs} - P_{sim}|)^2} \quad (۶)$$

$$R = \frac{\sum_{i=1}^n [P_{obs} - \overline{P_{obs}}][P_{sim} - \overline{P_{sim}}]}{\sqrt{\sum_{i=1}^n [P_{obs} - \overline{P_{obs}}]^2} \sqrt{\sum_{i=1}^n [P_{sim} - \overline{P_{sim}}]^2}} \quad (۷)$$

پارامترهای دما، رطوبت نسبی، فشار، ساعات آفتابی و بارش (به صورت ماهانه) از ضریب همبستگی استفاده گردید و عملیات پیش‌پردازش داده‌ها در مورد هر ایستگاه صورت پذیرفت. پس از کشف میزان همبستگی بین پارامترهای اقلیمی و بارش، به‌ترتیب نسبت به تبدیل داده‌های روزانه به ماهانه، برآورد داده‌های از دست رفته و حذف داده‌های پرت اقدام گردید. فرآیند نرمال‌سازی داده‌ها با استفاده از روش-های مینیمم-ماکزیمم، نرمال استاندارد و نرمال‌سازی رتبه‌ای انجام گردید. این روش‌ها به‌ترتیب در معادلات ۱، ۲ و ۳ نشان داده شده است:

(۱)

$$Y_t = \frac{X_t - X_{min}}{X_{max} - X_{min}}$$

$$Y_t = \frac{X_t - \mu}{\sigma} \quad (۲)$$

$$Y_t = \frac{rank(X_i) - 1}{n - 1} \quad (۳)$$

که در این معادلات Y_t مقدار نرمال شده X_t (مقدار هریک از داده‌ها)، X_{min} حداقل مقدار داده‌ها و X_{max} حداکثر مقدار داده‌ها می‌باشد. زمانی که پارامترهای جمعیت (μ و σ) شناخته شده باشند، برای نرمال‌سازی داده‌ها از روش نرمال استاندارد استفاده می‌شود.

از آنجایی‌که برای طبقه‌بندی الگوهای پیچیده در شبکه‌های عصبی مصنوعی از پرسپترون چند لایه یا MLP استفاده می‌شود (خوشحال‌دستجردی و قویدل‌رحیمی، ۱۳۸۷)، در این مطالعه برای مدل‌سازی از یک پرسپترون با ۱، ۲ و ۳ لایه مخفی استفاده شد و در نهایت بهترین نوع شبکه با توجه به کمترین خطا انتخاب گردید. پس از تعیین ورودی‌ها و خروجی‌های شبکه، ۸۰ درصد داده‌ها به‌منظور آموزش شبکه و ۲۰ درصد به‌منظور آزمون شبکه به‌کار برده شد (دزفولیان و اکبرپور شیرازی، ۱۳۹۰).

⁴ Tangent Hyperbolic

⁵ Sigmoid

¹ Back Propagation

² conjugate gradient

³ Levenberg-Marquardt



بررسی قرار گرفت. در این پژوهش از سه روش نرمال‌سازی مینیمم-ماکزیمم، نرمال‌سازی رتبه‌ای و نرمال استاندارد و الگوریتم آموزش لونبرگ-مارکوارت (TRAINLM)، تابع محرک تانژانت سیگموئید و دور آموزشی ۱۰۰۰ (Epoch) استفاده شد.

حالات مورد بررسی برای هر روش نرمال‌سازی عبارت است از: الف) شبکه عصبی تعیین‌کننده میزان بارش ماهانه با ۵ ورودی شامل پارامترهای دمای حداقل، دمای حداکثر، رطوبت حداقل، رطوبت حداکثر و بارش ماه قبل؛ ب) شبکه عصبی تعیین‌کننده میزان بارش ماهانه با ۱۰ ورودی شامل پارامترهای دمای حداقل، دمای حداکثر، رطوبت حداقل، رطوبت حداکثر و بارش در ماه قبل و دو ماه قبل؛ ج) شبکه عصبی تعیین‌کننده میزان بارش ماهانه با ۱۸ ورودی شامل پارامترهای دمای حداقل، دمای حداکثر، رطوبت حداقل، رطوبت حداکثر و بارش در ماه قبل، دو ماه قبل، ماه معادل از سال قبل و مشخصات جغرافیایی هر ایستگاه شامل طول و عرض جغرافیایی و ارتفاع از سطح آزاد دریا.

شبکه عصبی مصنوعی در سه سطح ۵، ۱۰ و ۱۸ داده ورودی در ۲۳ ایستگاه سینوپتیک اجرا گردید. در سناریوی ۵ داده ورودی شامل پارامترهای دمای حداقل، دمای حداکثر، رطوبت حداقل، رطوبت حداکثر و بارش ماه قبل، تعداد کل ورودی‌ها ۴۶۰۷ عدد بود که ۸۰ درصد این تعداد (۳۶۸۶ داده) جهت آموزش و ۲۰ درصد باقی‌مانده (۹۲۱ داده) در مرحله آزمون استفاده گردید. برای تعیین شبکه عصبی بهینه پیش‌بینی مقدار بارش ماهانه استان، آموزش تا سه لایه مخفی ادامه پیدا کرد. در حالت شبکه عصبی با یک لایه مخفی تعداد نرون‌های این لایه بین ۱۰ تا ۳۰ عدد با گام‌های ۵ تایی (۵ حالت)، در حالت شبکه عصبی با دو لایه مخفی تعداد نرون‌های هر لایه بین ۵ تا ۳۰ (۳۶ حالت) و در حالت شبکه عصبی با سه لایه مخفی تعداد نرون‌های هر لایه بین ۵ تا ۲۰ (۶۴ حالت) تغییر داده شد. تمام این حالات به‌طور جداگانه برای تابع انتقال تانژانت سیگموئید و الگوریتم آموزش لونبرگ-مارکوارت (LM) و نیز برای روش‌های نرمال‌سازی ذکر شده انجام گردید و مقایسه نتایج در هر مرحله با استفاده از آماره‌ها صورت گرفت.

که در این معادلات، P_{sim} مقدار بارندگی ماهانه شبیه-سازی شده توسط شبکه عصبی مصنوعی، P_{obs} مقدار بارندگی ماهانه واقعی (اندازه‌گیری شده در هر ایستگاه)، $\overline{P_{obs}}$ میانگین بارش مشاهده شده، $\overline{P_{stm}}$ میانگین بارش پیش‌بینی شده و n تعداد مشاهدات است.

پس از آموزش شبکه، تعمیم‌پذیری شبکه با ارائه زوج-های آموزشی جدید به شبکه که قبلاً در آموزش آن نقش نداشته‌اند اجرا گردید. شبکه عصبی مورد استفاده شامل سه لایه ورودی، مخفی و خروجی می‌باشد. دمای حداقل، دمای حداکثر، رطوبت حداقل، رطوبت حداکثر و بارش در هر ایستگاه در بازه‌های زمانی یک ماه قبل، دو ماه قبل، ماه معادل از سال قبل، مشخصات جغرافیایی (طول و عرض جغرافیایی و ارتفاع از سطح دریا) و کد خوشه مربوط به ماه‌های مرطوب و خشک و ترکیباتی از این داده‌ها با روش-های مختلف نرمال‌سازی به‌عنوان پارامترهای ورودی شبکه و میزان بارش ماهانه در استان فارس به‌عنوان پارامتر خروجی از شبکه در نظر گرفته شده و شبکه عصبی با ورودی‌های مختلف، برای تعیین مؤثرترین پارامترهای ورودی و تعیین بهترین روش نرمال‌سازی آموزش داده شد. برنامه به‌گونه‌ای طراحی شد که با هر بار اجرای آن پس از انجام مراحل آموزش و آزمون بر روی داده‌ها، به‌طور خودکار میزان خطای نسبی محاسبه گردید و با یک مقدار ایده‌آل کمینه پیش‌فرض مقایسه گردید. در صورتی که خطای حاصل از شبکه از مقدار ایده‌آل کمتر بود اصلاح ضرایب متوقف شده و شبکه به‌عنوان یک ساختار بهینه پیش‌بینی کننده ثبت گردید و تعداد نرون‌ها و لایه‌های بهینه برای هر روش نرمال‌سازی مشخص گردید. در غیر این صورت مشخصات شبکه تا زمان رسیدن به خطای کمینه با تعداد نرون‌های بهینه اصلاح گردید و پارامترهای آماری شامل MAE ، MSE ، d و R برای هر دو مرحله آموزش و آزمون محاسبه شده و به شکل یک ماتریس ارائه شد. همچنین خط برازش داده شده از مقادیر واقعی و شبیه‌سازی شده در هر دو مرحله آموزش و آزمون با یک خط یک به یک مقایسه و میزان تطابق آن با این خط از لحاظ آماری تحت احتمال ۹۵ درصد بررسی گردید. به‌منظور تعیین ساختار بهینه شبکه، تعداد نرون‌های مختلف در لایه‌های مخفی مورد

نتایج و بحث

نتایج آماری داده‌های خام و بدون پیش‌پردازش و همچنین ساختار بهینه با کمترین مقدار MSE برای این مرحله در جدول ۱ و نتایج آماری روش‌های نرمال‌سازی مینیمم-ماکزیمم، نرمال‌سازی رتبه‌ای و نرمال استاندارد به ترتیب در جداول ۲، ۳ و ۴ نشان داده شده است.

نتایج پاسخ‌های بهینه شبکه پیش‌بینی میزان بارش ماهانه داده‌های خام نشان داد با افزایش تعداد ورودی‌ها از ۵ به ۱۸ ورودی، دقت پیش‌بینی‌ها ۴۸ درصد افزایش یافته

است (بر اساس آماره R در تعداد لایه مخفی برابر با یک). در تعداد ورودی‌های پایین (۵ و ۱۰ ورودی) با افزایش تعداد لایه‌های مخفی، از دقت پیش‌بینی کاسته گردیده، درحالی-که در تعداد ورودی بالا (۱۸ ورودی)، با افزایش تعداد لایه‌های مخفی، بر دقت مدل افزوده می‌شود. در شبکه‌هایی با تعداد ۵ و ۱۰ ورودی مقدار آماره R به ترتیب ۱۳ و ۴۳ درصد کاهش و در تعداد ۱۸ ورودی مقدار این آماره ۱۰ درصد افزایش یافته است. بنابراین جهت افزایش دقت پیش‌بینی‌ها بایستی تعداد ورودی‌ها و لایه‌های مخفی افزایش یابد (جدول ۱).

جدول (۱): پاسخ‌های بهینه شبکه پیش‌بینی‌کننده میزان بارش ماهانه داده‌های خام (پیش‌پردازش نشده) با ۵، ۱۰ و ۱۸ ورودی

تعداد لایه مخفی	۵ ورودی				۱۰ ورودی				۱۸ ورودی			
	d	R	MAE	MSE	d	R	MAE	MSE	d	R	MAE	MSE
۱	۰/۴۸	۰/۳۱	۰/۷۲	۱/۶۰	۰/۶۸	۰/۴۹	۰/۵۵	۱/۵۵	۰/۶۷	۰/۴۶	۰/۶۶	۱/۱۲
۲	۰/۵۵	۰/۳۱	۰/۸۷	۲/۵۱	۰/۵۴	۰/۳۰	۰/۹۵	۳/۱۴	۰/۷۲	۰/۶۴	۰/۶۶	۱/۲۰
۳	۰/۵۰	۰/۲۷	۰/۹۳	۲/۹۶	۰/۵۰	۰/۲۸	۰/۹۰	۳/۲۷	۰/۶۶	۰/۵۱	۰/۶۶	۱/۲۶

استفاده از روش نرمال‌سازی مینیمم-ماکزیمم جهت پیش‌بینی میزان بارش ماهانه نیز نشان داد که دقت پیش-بینی‌ها به تعداد ورودی‌ها واکنش مثبت نشان داده و با افزایش تعداد ورودی‌ها از ۵ به ۱۸ ورودی، مقدار دقت پیش‌بینی‌ها ۴۴ درصد افزایش یافته است. در این روش در تمامی تعداد ورودی‌ها، مقدار دقت پیش‌بینی‌ها با افزایش تعداد لایه مخفی رابطه معکوسی داشته و با افزایش تعداد

لایه مخفی از یک به سه لایه، در تعداد ورودی‌های ۵، ۱۰ و ۱۸ ورودی مقدار آماره R به ترتیب ۱۵، ۵۷ و ۴۰ درصد کاهش یافته است، به عبارتی، جهت افزایش دقت پیش-بینی‌ها با استفاده از روش نرمال‌سازی مینیمم-ماکزیمم، بایستی تعداد ورودی‌ها افزایش و تعداد لایه‌های مخفی کاهش یابد (جدول ۲).

جدول (۲): پاسخ‌های بهینه شبکه پیش‌بینی‌کننده میزان بارش ماهانه با ۵، ۱۰ و ۱۸ ورودی و با استفاده از روش نرمال‌سازی مینیمم-ماکزیمم

تعداد لایه مخفی	۵ ورودی				۱۰ ورودی				۱۸ ورودی			
	d	R	MAE	MSE	d	R	MAE	MSE	d	R	MAE	MSE
۱	۰/۳۴	۰/۱۰	۰/۴۲	۰/۵۵	۰/۶۲	۰/۴۹	۰/۱۱	۰/۳۷	۰/۸۹	۰/۴۹	۰/۰۶	۰/۳۲
۲	۰/۲۷	۰/۲۶	۰/۳۸	۰/۲۰	۰/۴۲	۰/۲۳	۰/۱۳	۰/۱۱۰	۰/۴۵	۰/۲۴	۰/۲۰	۰/۱۶۰
۳	۰/۲۹	۰/۱۷	۰/۱۸	۰/۳۱	۰/۴۳	۰/۲۱	۰/۱۴	۰/۱۲۰	۰/۴۶	۰/۲۹	۰/۱۴	۰/۱۰۰

پیش‌بینی بارش ماهانه با استفاده از روش نرمال‌سازی رتبه‌ای نشان داد در این روش نیز با افزایش تعداد ورودی‌ها، بر مقدار دقت پیش‌بینی‌ها افزوده شده، به طوری که با

افزایش تعداد ورودی‌ها از ۵ به ۱۸ ورودی، آماره R، ۳۶ درصد افزایش یافت. در این روش در تمامی تعداد ورودی-



۱۰ به ۱۸، از دقت پیش‌بینی‌ها کاسته می‌گردد و تعداد ورودی برابر با ۱۰ ورودی، دقیق‌ترین پیش‌بینی‌ها را باعث شده است. در این روش در تمامی تعداد ورودی‌های مورد آزمون، با افزایش تعداد لایه‌های مخفی، از دقت پیش‌بینی‌های مقدار بارش ماهانه، کاسته شد. با افزایش تعداد لایه مخفی از یک به سه لایه به ازای تعداد ورودی ۵، ۱۰ و ۱۸ ورودی، دقت پیش‌بینی‌ها به ترتیب ۴۳، ۱۴ و ۲۵ درصد کاهش یافت (جدول ۴).

های مورد آزمون، با افزایش تعداد لایه‌های مخفی، پیش‌بینی مقدار بارش ماهانه بهبود می‌یابد. با افزایش تعداد لایه مخفی از یک به سه لایه به ازای تعداد ورودی ۵، ۱۰ و ۱۸ ورودی، دقت پیش‌بینی‌ها به ترتیب ۴۲، ۱۴ و ۲۳ درصد افزایش یافت (جدول ۳).

پیش‌بینی بارش ماهانه با استفاده از روش نرمال‌سازی استاندارد نشان داد که با افزایش تعداد ورودی‌ها از ۵ به ۱۰ ورودی، بر مقدار دقت پیش‌بینی‌ها افزوده و بالعکس روش‌های مینیمم-ماکزیمم و رتبه‌ای با افزایش تعداد ورودی از

جدول (۳): پاسخ‌های بهینه شبکه پیش‌بینی‌کننده میزان بارش ماهانه با ۵، ۱۰ و ۱۸ ورودی و با استفاده از روش نرمال‌سازی رتبه‌ای

تعداد لایه مخفی	۱۸ ورودی				۱۰ ورودی				۵ ورودی			
	d	R	MAE	MSE	d	R	MAE	MSE	d	R	MAE	MSE
۱	۰/۸۷	۰/۶۱	۰/۱۳	۰/۰۳۲	۰/۸۳	۰/۵۲	۰/۱۵	۰/۰۴۰	۰/۸۰	۰/۴۵	۰/۱۶	۰/۰۴۵
۲	۰/۷۸	۰/۶۲	۰/۱۹	۰/۰۶۵	۰/۸۲	۰/۶۷	۰/۱۶	۰/۰۴۵	۰/۷۷	۰/۵۹	۰/۱۸	۰/۰۵۸
۳	۰/۸۵	۰/۷۵	۰/۱۴	۰/۰۳۴	۰/۷۷	۰/۵۹	۰/۱۸	۰/۰۶۹	۰/۷۹	۰/۶۴	۰/۱۷	۰/۰۴۹

جدول (۴): پاسخ‌های بهینه شبکه پیش‌بینی‌کننده میزان بارش ماهانه با ۵، ۱۰ و ۱۸ ورودی و با استفاده از روش نرمال‌سازی استاندارد

تعداد لایه مخفی	۱۸ ورودی				۱۰ ورودی				۵ ورودی			
	d	R	MAE	MSE	d	R	MAE	MSE	d	R	MAE	MSE
۱	۰/۷۲	۰/۵۶	۰/۵۵	۱/۰۲	۰/۷۳	۰/۵۷	۰/۶۹	۱/۳۶	۰/۵۷	۰/۴۲	۰/۵۷	۱/۵۰
۲	۰/۵۲	۰/۳۳	۰/۶۷	۲/۰۰	۰/۵۴	۰/۳۹	۰/۷۲	۲/۵۴	۰/۴۴	۰/۱۹	۰/۹۴	۲/۵۴
۳	۰/۶۲	۰/۴۲	۰/۶۵	۱/۴۹	۰/۶۷	۰/۴۹	۰/۵۰	۲/۲۰	۰/۴۵	۰/۲۴	۰/۶۹	۲/۲۰

تعداد ورودی بر عملکرد شبکه می‌باشد (جدول ۵). نتایج به دست آمده با یافته‌های قلی‌زاده و دارند (۱۳۸۹) و ایلدرمی و همکاران (۱۳۹۲) مطابقت دارد که از شبکه عصبی مصنوعی برای پیش‌بینی بارش در تهران، شیراز، مشهد و کرمان استفاده کردند.

مقایسه نتایج روش‌های مختلف نرمال‌سازی نشان داد بهترین روش برای نرمال‌سازی، روش رتبه‌ای است. در این روش با ۵، ۱۰ و ۱۸ ورودی، با افزایش تعداد ورودی‌ها، مقدار MSE کمتر شده و مقدار ضریب همبستگی و شاخص تطابق افزایش یافت که نشان‌دهنده تأثیر مثبت افزایش


جدول (۵): بهترین نتایج آماری مرحله آموزش و آزمون هر چهار حالت مربوط به تخمین بارش ماهانه با استفاده از ۵، ۱۰ و ۱۸ ورودی

روش پیش‌پردازش داده	۱۸ ورودی				۱۰ ورودی				۵ ورودی			
	d	R	MAE	MSE	d	R	MAE	MSE	d	R	MAE	MSE
داده خام	۰/۶۷	۰/۴۶	۰/۶۶	۱/۱۲	۰/۶۸	۰/۴۹	۰/۵۵	۱/۵۵	۰/۴۸	۰/۳۱	۰/۷۲	۱/۶۰۰
رتبه‌ای	۰/۸۷	۰/۶۱	۰/۱۳	۰/۰۳	۰/۸۳	۰/۵۲	۰/۱۵	۰/۰۴	۰/۸۰	۰/۴۵	۰/۱۶	۰/۰۴۵
مینیمم-ماکزیمم	۰/۸۹	۰/۴۸	۰/۰۶	۰/۰۳	۰/۶۲	۰/۴۹	۰/۱۱	۰/۰۴	۰/۵۵	۰/۳۴	۰/۱۰	۰/۰۴۰
نرمال استاندارد	۰/۷۲	۰/۵۶	۰/۵۵	۱/۰۲	۰/۷۳	۰/۵۷	۰/۶۹	۱/۳۶	۰/۵۷	۰/۴۲	۰/۵۷	۱/۵۰۰


ماکزیمم پیش‌بینی‌ها دقیق‌تر شده است. مقدار آماره R پیش‌بینی‌ها به دلیل نرمال‌سازی داده‌ها با استفاده از روش-های رتبه‌ای، استاندارد و مینیمم-ماکزیمم نسبت به داده‌های خام به ترتیب ۴۱، ۳۱ و ۹ درصد افزایش یافت (شکل ۲). مقایسه نتایج رگرسیون خطی بین مقادیر بارش ماهانه اندازه‌گیری شده و پیش‌بینی شده با تعداد ۵ و ۱۰ ورودی نشان داد که با افزایش تعداد ورودی‌ها از ۵ به ۱۰ ورودی، دقت پیش‌بینی‌ها افزایش می‌یابد. تأثیر نرمال‌سازی داده‌ها در سطح تعداد ۱۰ داده ورودی به اندازه ۵ داده ورودی نبوده و در این تعداد داده ورودی (۱۰ ورودی)، به ترتیب روش‌های نرمال‌سازی استاندارد ($R=0.57$) و رتبه‌ای ($R=0.53$) از بیشترین دقت پیش‌بینی برخوردار بوده و این روش‌ها باعث بهبود دقت پیش‌بینی‌ها شده، در حالی که روش نرمال‌سازی مینیمم-ماکزیمم تأثیری بر افزایش دقت پیش‌بینی‌ها نداشته است. مقدار آماره R پیش‌بینی‌ها به دلیل نرمال‌سازی داده‌ها با استفاده از روش‌های استاندارد و رتبه‌ای نسبت به داده‌های خام به ترتیب ۱۴ و ۶ درصد افزایش یافت (شکل ۳).

با مقایسه نتایج حاصل از پیش‌بینی بارش با استفاده از شبکه عصبی و انتخاب روش نرمال‌سازی رتبه‌ای به عنوان بهترین روش نرمال‌سازی با ۵، ۱۰ و ۱۸ ورودی مشخص گردید با افزودن پارامترهای جغرافیایی شامل طول و عرض جغرافیایی و ارتفاع از سطح دریا برای هر ایستگاه به عنوان ورودی‌های شبکه، مقدار MSE کاهش و مقدار ضریب همبستگی و شاخص تطابق افزایش یافته‌اند. به عبارتی با افزودن مشخصات جغرافیایی به پارامترهای ورودی، دقت و کارایی مدل شبکه عصبی مصنوعی افزایش یافت (جدول ۵).


نتایج رگرسیون خطی بین مقادیر بارش ماهانه اندازه‌گیری شده و تخمین زده شده توسط شبکه عصبی برای مرحله آزمون در تعداد ۵ ورودی نشان داد که به ترتیب روش‌های نرمال‌سازی رتبه‌ای ($R=0.45$)، استاندارد ($R=0.42$) و مینیمم-ماکزیمم ($R=0.35$) از بیشترین دقت پیش‌بینی برخوردار بوده و با نرمال‌سازی داده‌های ماهانه بارش با استفاده از روش‌های رتبه‌ای، استاندارد و مینیمم-




(الف)



(ب)




(ج)




(د)


شکل (۲): رگرسیون خطی بین مقادیر بارش ماهانه اندازه گیری شده و تخمین زده شده توسط شبکه عصبی با ۵ ورودی برای مرحله آزمون و چهار حالت الف: داده های خام، ب: نرمال سازی مینیمم- ماکزیمم، ج: نرمال سازی رتبه ای، د: نرمال استاندارد




(الف)



(ب)



(ج)




(د)


شکل (۳): رگرسیون خطی بین مقادیر بارش ماهانه اندازه گیری شده و تخمین زده شده توسط شبکه عصبی با ۱۰ ورودی برای مرحله آزمون و چهار حالت الف: داده‌های خام، ب: نرمال‌سازی مینیمم-ماکزیمم، ج: نرمال‌سازی رتبه‌ای، د: نرمال استاندارد

استاندارد ($R=0.58$) و مینیمم-ماکزیمم ($R=0.49$) به-ترتیب از بیشترین دقت پیش‌بینی برخوردار بوده‌اند. مقدار آماره R پیش‌بینی‌ها به‌دلیل نرمال‌سازی داده‌ها با استفاده از روش‌های رتبه‌ای، استاندارد و مینیمم-ماکزیمم نسبت به داده‌های خام به‌ترتیب ۳۵، ۲۶ و ۷ درصد افزایش یافت (شکل ۴).


نتایج رگرسیون خطی بین مقادیر بارش ماهانه اندازه-گیری شده و تخمین زده شده توسط شبکه عصبی برای مرحله آزمون در تعداد ۱۸ ورودی نشان داد که با نرمال-سازی داده‌های بارش ماهانه بارش با استفاده از روش‌های رتبه‌ای، استاندارد و مینیمم-ماکزیمم دقت پیش‌بینی‌ها افزایش یافته و روش‌های نرمال‌سازی رتبه‌ای ($R=0.62$),




(الف)



(ب)



(ج)



(د)


شکل (۴): رگرسیون خطی بین مقادیر بارش ماهانه اندازه گیری شده و تخمین زده شده توسط شبکه عصبی با ۱۸ ورودی برای مرحله آزمون و چهار حالت الف: داده های خام، ب: نرمال سازی مینیمم-ماکزیمم، ج: نرمال سازی رتبه ای، د: نرمال استاندارد

همانطور که از معادله ۵ استنباط می گردد مقدار بارش پیش بینی شده توسط شبکه عصبی ۱۲ درصد کمتر از مقدار واقعی، بارش ماهانه را تخمین زده است که نسبت به مرحله قبل به میزان ۱ درصد بهبود یافته است. نتایج مقایسه بین مقادیر بارش ماهانه تخمین زده شده توسط شبکه عصبی و مقادیر اندازه گیری شده نیز در شکل های ۵، ۶ و ۷ نشان داده است. نتایج مشابهی توسط حلبیان و دارند (۱۳۹۱) در پیش بینی بارش اصفهان با استفاده از شبکه عصبی مصنوعی گزارش گردید


مقدار بارش ماهانه تخمین زده شده توسط شبکه عصبی مصنوعی بر حسب مقدار بارش ماهانه اندازه گیری شده با عرض از مبدأ و بدون عرض از مبدأ در مرحله آزمون برای روش نرمال سازی رتبه ای که بهترین روش نرمال سازی با ساختار بهینه شبکه عصبی در این مرحله نیز می باشد به ترتیب با معادلات ۴ ($R=0.52$) و ۵ ($R=0.93$) نشان داده شد:

$$P_{sim} = 0.59 P_{obs} + 0.2 \quad (۴)$$


$$P_{sim} = 0.88 P_{obs} \quad (۵)$$




(الف)



(ب)




(ج)




(د)


شکل (۵): مقایسه بین مقادیر بارش ماهانه اندازه گیری شده و تخمین زده شده توسط شبکه عصبی با ۵ ورودی برای مرحله آزمون (محور افقی: اندیس یا شماره مربوط به بارش و محور عمودی: مقدار بارش شبیه سازی شده و واقعی) برای چهار حالت الف: داده های خام، ب: نرمال سازی مینیمم_ماکزیمم، ج: نرمال سازی رتبه ای، د: نرمال استاندارد




(الف)



(ب)




(ج)




(د)


شکل (۶): مقایسه بین مقادیر بارش ماهانه اندازه گیری شده و تخمین زده شده توسط شبکه عصبی با ۱۰ ورودی برای مرحله آزمون (محور افقی: اندیس یا شماره مربوط به بارش و محور عمودی: مقدار بارش شبیه سازی شده و واقعی) برای چهار حالت الف: داده های خام، ب: نرمال سازی مینیمم_ماکزیمم، ج: نرمال سازی رتبه ای، د: نرمال استاندارد




(الف)



(ب)



(ج)



(د)

شکل (۷): مقایسه بین مقادیر بارش ماهانه اندازه گیری شده و تخمین زده شده توسط شبکه عصبی با ۱۸ ورودی برای مرحله آزمون (محور افقی: اندیس یا شماره مربوط به بارش و محور عمودی: مقدار بارش شبیه سازی شده و واقعی) برای چهار حالت الف: داده های خام، ب: نرمال سازی مینیمم- ماکزیمم، ج: نرمال سازی رتبه ای، د: نرمال استاندارد

نتیجه گیری

پیش بینی بارش استان فارس پارامترهای ماه قبل، دو ماه قبل، مشخصات جغرافیایی و خوشه بندی ماهها به ماههای مرطوب و خشک با کد خوشه ۱ و ۲ می باشد. در مجموع می توان بیان داشت که مدل شبکه عصبی با فراگیری رفتار غیرخطی اطلاعات آموزشی و انجام عملیاتی موازی در تعداد زیادی از سلول های عصبی، قادر به پردازش اطلاعات آزمون و برقراری ارتباط بین اطلاعات ورودی و خروجی برای پیش بینی است. نتیجه کلی این است که متغیرهای وارد شده به مدل، توانسته اند به خوبی و با دقت مناسبی الگوی پراکندگی و نحوه توزیع بارش در ماه های مورد مطالعه را پیش بینی نموده و به طور موفقیت آمیزی بارش ماهانه را پیش بینی نمایند. این موضوع نقش بسیار تعیین کننده ای در مدیریت و برنامه ریزی منابع آب شرب و کشاورزی ایفا

از آنجایی که تخمین میزان بارش می تواند در مدیریت مخازن آب و برنامه ریزی جهت تامین آب و کنترل سیلاب و غیره مورد استفاده قرار گیرد، در این پژوهش پیش بینی میزان ماهانه بارش با استفاده از پارامترهای هواشناسی و جغرافیایی به کمک روش شبکه های عصبی مصنوعی و سه روش نرمال سازی مینیمم- ماکزیمم، رتبه ای و استاندارد در سطح استان فارس مورد ارزیابی قرار گرفت. نتایج نشان داد نرمال سازی داده ها تا حد زیادی باعث بهبود عملکرد شبکه شده و بهترین روش برای نرمال سازی، روش رتبه ای با شبکه عصبی بهینه یک لایه و ساختار ۱-۲۵-۵ و الگوریتم آموزش لونیگ- مارکوارت و تابع محرک تانژانت سیگموئید می باشد. مقایسه نتایج نشان داد ورودی های مناسب برای



می‌کند و می‌توان با در نظر گرفتن این پیش‌بینی‌ها، سیاست‌های آینده را در جهت بهینه‌سازی صرف هزینه‌ها و امکانات با بهره‌وری حداکثر طرح‌ریزی کرد.

منابع

- ادب، ح.، غ. فلاح‌قاهره، و ر. میرزابیاتی. ۱۳۸۷. ارزیابی روش‌های میان‌یابی کریجینگ و رگرسیون خطی بر پایه DEM در تهیه نقشه همبارش سالانه در استان خراسان رضوی، همایش ژئوماتیک ۱۳۸۷.
- ایلدرومی، ع.، ر. ح. زارع‌ایبانه، و م. بیات‌ورکشی. ۱۳۹۲. برآورد بارش به کمک شبکه عصبی مصنوعی با داده‌های هواشناسی غیربارشی در سه منطقه شیراز، مشهد و کرمان. نشریه علمی پژوهشی جغرافیا و برنامه‌ریزی. ۱۷(۴۳): ۲۱-۴۰.
- بهرامی، م.، ج. امیری، ف. رضایی‌مه‌ارلویی، و ک. غفاری. ۱۳۹۶. اثر پیش‌پردازش داده بر عملکرد شبکه عصبی مصنوعی به‌منظور پیش‌بینی بارش ماهانه (مطالعه موردی: شهرستان آباد). اکوهیدرولوژی. ۱: ۲۹-۳۷.
- بهرامی، م.، م. توکل‌صدرآبادی، و ع. ا. زارعی. ۱۳۹۴. تحلیل شدت-مدت-فراوانی خشکسالی و روند تغییر بارش در شیراز. مجله علمی-پژوهشی مهندسی آبیاری و آب. ۲۱: ۵۹-۷۴.
- حسینی، س.، ف. ج. بهمنش، و. رضوردی نژاد، و ن. خان محمدی. ۱۴۰۱. ارزیابی عملکرد مدل‌های هوشمند در تخمین دمای نقطه شبنم با استفاده از پارامترهای هواشناسی. دانش آب و خاک 10.22034/ws.2021.30995.2211 *doi*:
- حلبیان، ا. ح.، و م. دارند. ۱۳۹۱. پیش‌بینی بارش اصفهان با استفاده از شبکه‌های عصبی مصنوعی. نشریه تحقیقات کاربردی علوم جغرافیایی ۱۲ (۲۶): ۴۷-۶۳.
- خلیلی، ن.، س. ر. خداشناس، ک. داوری، و م. موسوی‌بایگی. ۱۳۸۷. پیش‌بینی بارش ماهانه با استفاده از شبکه‌های عصبی-مصنوعی (مطالعه موردی: ایستگاه سینوپتیک مشهد). مجله علوم و صنایع کشاورزی (ویژه آب و خاک). ۲۲(۱): ۸۹-۹۸.
- خوشحال‌دستجردی، ج. و ی. قویدل‌رحیمی. ۱۳۸۷. بررسی رابطه تغییرات بارش سالیانه تبریز با ناهنجاری‌های دمایی کره زمین و شبیه‌سازی عددی آن با استفاده از شبکه عصبی مصنوعی، فصلنامه مدرس علوم انسانی. ۱۲(۲): ۲۹-۵۱.
- روشان، س. ح.، ک. شاهدی، و م. حبیب‌نژاد روشن. ۱۴۰۰. مقایسه عملکرد روش‌های هوش مصنوعی ANN و SVM در مدل‌سازی فرایند بارش-رواناب (مطالعه موردی: حوضه آبخیز کارون شمالی). مجله علوم آب و خاک. ۲۵(۲): ۹۰-۷۷.
- فلاح‌قاهره، غ. ح.، م. موسوی‌بایگی، و م. حبیبی‌نوخندان. ۱۳۸۷. پیش‌بینی بارش فصلی فصلی بر اساس الگوهای سینوپتیکی با استفاده از سیستم استنباط فازی عصبی تطبیق (ANFIS). پژوهش‌های جغرافیای طبیعی. ۶۶: ۱۲۱-۱۳۹.
- قربانی‌دشتکی، ش.، م. همایی، و م. ج. مهدیان. ۱۳۸۸. برآورد پارامترهای نفوذ آب به خاک با استفاده از شبکه‌های عصبی-مصنوعی. مجله آب و خاک (علوم و صنایع کشاورزی). ۲۳(۱): ۱۸۵-۱۹۸.
- قلی‌زاده، م.، و م. دارند. ۱۳۸۹. پیش‌بینی بارش ماهانه با استفاده از شبکه‌های عصبی مصنوعی (مورد: تهران). پژوهش‌های جغرافیای طبیعی (پژوهش‌های جغرافیایی). ۴۲(۷۱): ۵۱-۶۳.
- کارآموز، م.، ف. رضانی، و س. رضوی. ۱۳۸۵. پیش‌بینی بلندمدت بارش با استفاده از سیگنال‌های هواشناسی: کاربرد شبکه‌های عصبی مصنوعی. هفتمین کنگره بین‌المللی مهندسی عمران، تهران، ایران.
- کریمی‌گوغری، ش.، و ا. اسلامی. ۱۳۸۷. پیش‌بینی بارندگی سالانه در استان کرمان با استفاده از شبکه‌های عصبی مصنوعی. مجله آبیاری و زهکشی ایران. ۲(۲): ۱۲۳-۱۳۲.



محمدی، م.، ح. وقارفر، ر. مهدوی نجف آبادی، پ. دانشکارآراسته، و س. ناظم السادات. ۱۴۰۰. مدل سازی بارش رواناب
آبخیزهای مناطق ساحلی در نزدیکی تنگه هرمز با استفاده از روش های داده کاوی. تحقیقات آب و خاک ایران (علوم کشاورزی
ایران)، ۵۲(۲): ۳۲۷-۳۱۳.

Anochi, J.A., V.A. de Almeida and H.F. de Campos Velho. 2021. Machine Learning for Climate
Precipitation Prediction Modeling over South America. *Remote Sens*, 13: 2468.
<https://doi.org/10.3390/rs13132468>

Antonic, O., J. Krizan, A. Marki and D. Bukovec. 2001. Spatio- temporal interpolation of climatic
variables over large region of complex terrain using neural networks. *Ecological modeling*, 138: 255-
263.

Bahrami, M. and M.R. Mahmoudi. 2020. Rainfall modelling using backward generalized estimating
equations: a case study for Fasa Plain, Iran. *Meteorology and Atmospheric Physics*, 132:1-9.

Boderi, L. and V. Cermak. 2000. Predicting of extreme precipitation using a neural network:
(Application to summer flood occurrence in Moravia). *Advances in engineering software*, 31: 311- 321.

Bustami, R., N. Bessaih, C. Bong and S. Suhaili. 2007. Artificial Neural Network for Precipitation
and Water Level Predictions of Bedup River. *IAENG International Journal of Computer Science*, 34: 2-
10.

Dahamsheh, A. and H. Aksoy. 2009. Artificial neural network models for forecasting monthly
precipitation in Jordan. *Stochastic Environmental Research and Risk Assessment*, 23: 917-931

El-Shafie, A.H, A. El-Shafie, H.G. El. Mazoghi, A. Shehata and M.R. Taha. 2011. Artificial Neural
Network Technique for Rainfall Forecasting Applied to Alexandria." *International Journal of the
Physical Sciences*, 6: 1306-1316.

Halff, A.H., M. Henry and M. Azmoodeh. 1993. Predicting runoff from rainfall using artificial neural
network model. ASCE. New York. Pp. 760- 766.

Hung, N.Q., M.S. Babel, S. Weesakul and N.K. Tripathi. 2008. An Artificial Neural Network Model
for Rainfall Forecasting in Bangkok, Thailand. *Hydrology and Earth Sciences Discussion*, 5: 183-218.

Karen, A.L.S. 2010. Comparison of Adaptive Methods Using Multivariate Regression Splines
(MARS) and Artificial Neural Networks Backpropagation (ANNB) for the Forecast of Rain and
Temperatures in the Mantaro River Basin. *Hydrology Days*, pp: 58-68.

Maria, C., F. Haroldo and N. Ferreira. 2005. Artificial Neural Network Technique for Rainfall
Forecasting Applied to the Sao Paulo Region. *Journal of Hydrology*, 301: 146-162.



Evaluation of the Artificial Neural Network Performance in Estimating Rainfall using Climatic and Geographical Data (Case study: Fars Province)

Mehdi Bahrami¹, Amir Salari², Mohammad Javad Amiri³, Amir Bahrami⁴

Abstract

Precipitation forecasting is essential in maintaining, managing, allocating, and distributing water resources, determining the volume of water facilities, supplying the crops' water requirement, and determining the amount of erosion and sedimentation. This research aimed to investigate the performance of artificial neural networks in predicting monthly rainfall based on climatic and geographic information such as minimum and maximum temperature, minimum and maximum humidity, precipitation, latitude and longitude, and altitude above sea level in 23 stations of the Fars province. The results on levels 5, 10, and 18 of input data showed that the model accuracy in estimating the monthly rainfall increases with the increment in the number of inputs. The most accurate neural network model is in the rank normalization method with one hidden layer, and also, the best network structures are 5-25-1, 10-30-1, and 18-20-1, respectively. The results indicated that the neural network with 18 inputs has the smallest MSE=0.032 and the highest R=0.62. The best normalization method is the ranking method with an optimal neural network of one layer and 5-25-1 structure, the Levenberg-Marquardt training algorithm, and the sigmoid tangent stimulus function. Therefore, by using an artificial neural network (with 18 introduced inputs), it is possible to predict the amount and distribution of monthly rainfall in a wide area with acceptable accuracy. This issue plays a very decisive role in the management and planning of drinking and agricultural water resources; by taking into account these forecasts, future policies can be planned to optimize costs and maximum productivity facilities.

Keywords: Data Preprocessing, Artificial Neural Network, Rank Normalization.

¹ Associate Professor, Department of Water Engineering, Faculty of Agriculture, Fasa University, Iran. bahrami@fasau.ac.ir (Corresponding author)

² Assistant Professor, Department of Water Science and Engineering, Minab higher education center, University of Hormozgan, Iran. salari.1361@yahoo.com

³ Associate Professor, Department of Water Engineering, Faculty of Agriculture, Fasa University, Iran. mj_amiri@fasau.ac.ir

⁴ Assistant Professor, Department of Soil Science, Faculty of Agriculture, Tarbiat Modares University, Iran. bahramisoil@gmail.com