



## The conjunction of the feature extraction method with AI-based ensemble statistical downscaling models

Z. Razzaghzadeh, V. Nourani\* , N. Behfar

Department of Water Resources Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran.

**ABSTRACT:** In this study, two general circulation models (GCMs) (Can-ESM2, BNU-ESM) were used to simulate the future precipitation of Tabriz city. The weakness of GCMs is the coarse resolution of climate variables in which the different methods of downscaling is about to solve this deficiency. In this study, the Artificial Intelligence (AI) models, i.e., Artificial Neural Network (ANN) and Adaptive neuro-fuzzy inference system (ANFIS), were used to statistically downscale the climate variables of GCMs. Without any doubt, the most important step during the use of these models is selecting the dominant inputs among huge large-scale GCM data. So in this study for the selection of dominant inputs, decision tree, and mutual information (MI) feature extraction methods were used. Also, the ensemble techniques were used to evaluate the efficiency of downscaling models and to decrease the uncertainties. A comparison of the result of downscaling models indicated that the ensemble technique (i.e., hybrid of ANN and ANFIS) with dominant inputs based on decision tree feature extraction methods presents better performance. In both GCMs, the application of the downscaling ensemble couple with dominant predictors based on a decision tree model in precipitation downscaling showed 10%-38% increase in DC in versus the individual ANN and ANFIS downscaling models. The projection precipitation of Tabriz synoptic station for future (2020-2060) by proposed ensemble AI-based model indicated 30%-40% precipitation decreases under RCP4.5 and RCP8.5 scenarios.

### Review History:

Received: 9/15/2018  
Revised: 10/1/2018  
Accepted: 10/29/2018  
Available Online: 12/15/2018

### Keywords:

General Circulation Models (GCMs)  
Adaptive neuro-fuzzy inference system (ANFIS)  
Artificial Neural Network (ANN)  
Mutual Information (MI)  
Statistical Downscaling

## 1- INTRODUCTION

Water resources are extremely influenced by climate change. The negative effects of climate change on a different component of water resources such as; agriculture, industry, and so on have caused concern in human societies. Therefore, the survey of precipitation changes as the major component of the hydrologic cycle seems necessary. General circulation models (GCMs) can be considered as reliable tools in the prediction of precipitation. GCMs use physical-based equations on various processes of the atmosphere so, have widely used in various sciences [1]. The outputs of GCMs developed in coarse spatial resolutions may lead to their poor applicability as the input to local-scale hydrologic models. Downscaling is a technique to catch local-scale climate data from large scale GCMs [2]. Therefore, the current study proposes a novel statistical downscaling methodology by ensembling AI-based models (i.e., ANN and ANFIS). Plenty of data sets available by GCMs are the most challenging issue in AI-based modeling. In this case, the application of feature extraction methods as a pre-processing technique can largely increase the efficiency of the AI-based downscaling model. Multilinear and non-linear feature extraction methods i.e., decision tree and mutual information, respectively, are used in the current study. Finally, the proposed novel predictor

screening method is incorporated into AI-based statistical downscaling methods to achieve the optimal model for projection of monthly precipitation of Tabriz station.

## 2- MATERIAL AND METHODS

### 2-1- Study Area and Data

Tabriz City (latitude: 38°08'N, longitude: 46° 29'E38), the capital city of East Azerbaijan province, located in the northwest of Iran (Fig. 1). The monthly precipitation data of the Tabriz station during the base period (1951-2017) prepared by the Meteorological Organization of East Azerbaijan were utilized in the current study. To develop the proposed downscaling model, large-scale GCMs data in the base period (1951-200) and forecasting period (2020-2060) were from Can-ESM2 and BNU-ESM GCMs developed respectively in research centers of Canada and China. Future climate variables were extracted under RCP4.5 and RCP8.5 scenarios. Predictors on four grid points around the study area (i.e., 1, 2, 3, 4) were adopted in the current study (Fig. 1).

### 2-2- Proposed Methodology

In order to downscale GCM data, the ensemble AI-based models (i.e., ANN and ANFIS) was used, and to increase the efficiency of the AI-based downscaling model, pre-processing on variables of GCMs over the four nearest grid points to

\*Corresponding author's email: vahid.nourani96@gmail.com






Fig. 1. Study area with the grid points of BNU-ESM and Can-ESM2

study area was performed. The proposed methodology includes three steps. The first step is a data pre-processing step, where the important GCMs for study area are determined and then, dominant predictors of selected GCMs are identified by two feature extraction methods (i.e., MI, decision tree). The second step is training an AI-based statistical downscaling model with the inputs obtained from the first step, and finally, the third step is the projection of future precipitation of Tabriz station according to ensemble AI-based model under RCPs 4.5 and 8.5.

The following subsections briefly describe the utilized mathematical tools in the proposed methodology.

2-3-Mutual Information (MI)

The entropy and information content has been mathematically formulated and measured using the distribution of data probability. It has been introduced as a measurement criterion of disorder, turbulence, and uncertainty [3]. In general, the theory of Shannon’s information content is used in the discrete or continuous form based on the data and problem nature. MI between two random variables of  $X$  and  $Y$  is computed by the following equation [4]:

$$MI(X, Y) = H(X) + H(Y) - H(X, Y) \tag{1}$$

Where  $H(X)$  and  $H(Y)$  are the entropies of  $X$  and  $Y$  respectively and  $H(X, Y)$  is the common entropy of  $X$  and  $Y$  which is calculated by equation (2 and 3) [5, 6]:

$$H(X) = -\sum_{i=1}^N P(X_i) \log[P(X_i)] \tag{2}$$

$$H(X, Y) = -\sum_{i=1}^N \sum_{j=1}^N P(X_i, Y_j) \log[P(X_i, Y_j)] \tag{3}$$

2-4-Decision Tree

The decision tree method with a supervised learning approach is a powerful tool to perform classification and prediction in the data mining field. Generally, the structure of a tree is composed of four parts, including root, branch, node, and leaf. The root (i.e., the first node) locates at the upper level while the end chain of branches and nodes are leaves (i.e., end node). The root of the tree is the best node

for the classification, and other variables in the lower nodes of the decision tree catch less importance. The M5 model tree as a decision tree method is maximizing the reduction of the standard deviation of each class of data that has been acquired in each node. The reduction of standard deviation is computed as [7]:

$$sd(T) = \sum \frac{|T_i|}{|T|} sd(T_i) \tag{4}$$

2-5-Artificial Neural Network (ANN)

For statistical downscaling of GCM outputs in the current study, the three-layer Feed-Forward Neural Network (FFNN) structure is utilized. The previous studies indicated that FFNN with backpropagation algorithm could lead to reliable outcomes in predicting and simulation of hydro-climatologic variables [8]. For more information about the mathematical basis of neural networks, the readers are referred to [9].

2-6- Adaptive Neuro-Fuzzy Inference System (ANFIS)

ANFIS, as a neuro-fuzzy model, combines the neural network and fuzzy logic concepts to enjoy the benefits of both within a unique framework. Any ANFIS consists of a five-layer neural network. The first layer is used for the input fuzzification. In the second layer, the fuzzy rule performance weight is calculated. The third layer is the normalization layer. In the fourth layer, the consequent rule values are calculated and multiplied by the respective rule performance weight and the fifth layer does the defuzzification (for more details see [10]).

2-7- Model Ensembling

It is well known that a combination of different predictors as a post-processing approach can improve overall predictions for a time series. In this sense, using combined predicts is safer and less risky than relying on a single method [11, 12].

2-8-Evaluation Criteria

Due to the adequacy of DC and RMSE in hydro-climatology prediction processes as evaluation criteria of models, in this study, to evaluate the performance of the downscaling model, in the training and validation process, two DC and RMSE criteria were used.

$$DC = 1 - \frac{\sum_{i=1}^n (O_i - Y_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \tag{5}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - Y_i)^2}{N}} \tag{6}$$

Where  $O_i$  and  $Y_i$  are predictand and predictors, respectively,  $\bar{O}$  is mean of predictand and  $N$  is the total number of observations.

3- RESULTS AND DISCUSSION

In the current study, to accurately assess the pattern of precipitation of Tabriz station in the future (2020-2060), GCM-based downscaling was applied. In this way, a robust

**Table 1. dominant predictors based on MI and decision tree**

Model	Feature extraction method	(Dominant predictors) <sup>a</sup>
BNU-ESM	MI	ua(850) <sup>(2)</sup> , ta(850) <sup>(1)</sup> , ua(200) <sup>(1)</sup> , ta(850) <sup>(3)</sup>
Can-ESM2		ta(500) <sup>(3)</sup> , ta(500) <sup>(1)</sup> , tas <sup>(3)</sup> , ua(200) <sup>(3)</sup>
BNU-ESM	Decision tree	ta(200) <sup>(3)</sup> , ts <sup>(3)</sup> , ta(1000) <sup>(2)</sup> , pr <sup>(1)</sup>
Can-ESM2		Prc <sup>(3)</sup> , hus(850) <sup>(3)</sup> , tas <sup>(2)</sup> , ta(500) <sup>(2)</sup>
Grid numbers based on Figure1 <sup>(a)</sup> (a=1, 2, 3, 4)		

**Table 2. downscaling results of precipitation**


GCMs	Feature extraction methods of Inputs	Downscaling model	training		testing	
			DC	N <sup>1</sup> -RMSE	DC	N <sup>1</sup> -RMSE
BNU-ESM	MI	ANN	0.65	0.11	0.61	0.10
		ANFIS	0.50	0.13	0.46	0.12
		Ensemble model	0.79	0.09	0.76	0.08
	Decision tree	ANN	0.79	0.09	0.77	0.08
		ANFIS	0.66	0.11	0.64	0.10
		Ensemble	0.88	0.06	0.84	0.07
Can-ESM2	MI	ANN	0.69	0.11	0.67	0.09
		ANFIS	0.54	0.13	0.51	0.11
		Ensemble model	0.85	0.07	0.83	0.07
	Decision tree	ANN	0.87	0.07	0.83	0.07
		ANFIS	0.72	0.10	0.66	0.10
		Ensemble model	0.94	0.05	0.91	0.05
N <sup>1</sup> -RMSE denotes normalized RMSE values.						

pre-processing method coupled with downscaling ensemble model resulted in predictand pattern recognition. Since the proposed methodology includes three steps, the results are presented and discussed in three steps as follow:

**3-1-Results of First Step (Input screening)**

The selection of the appropriate GCMs for the case study was performed based on MI calculation between monthly observed and GCM data from 1951-2005. Two GCMs i.e., Can-ESM2 and BNU-ESM with higher nonlinear relations based on MI were selected and utilized for the modeling. After assigning the important GCMs, dominant predictors of selected GCMs were determined by MI and decision tree feature extraction methods (see Table 1).

The dominant predictors obtained based on the MI method were zonal wind (a) and temperature-related variables (i.e., ta, tas and ts), which gained based on the nonlinear relation between observed precipitation with temperature and ua variables. The dominant predictors based on the decision were humidity and temperature-related predictors (i.e., hus,



**Fig. 2. Mean monthly observations and predicted precipitation for the future (2020-2060) under RCP4.5 and RCP8.5 scenarios.**

pr, prc, ts, ta, tas). Evaluation of dominant predictors selected by the decision tree method indicated that the decision tree model acted as an aggregation of CC and MI methods, due to selection of humidity and temperature-related variables like CC and MI, respectively.

**3-2-Results of Second Step (Downscaling)**

In both GCMs based on MI and decision tree, four dominant climatic variables were selected as inputs of the AI-based downscaling model in the first step. 75% of the dominant predictors and observed precipitation data were utilized for the training and the remaining 25% utilized for the validating purpose. The proper outcomes of precipitation downscaling according to DC and RMSE evaluation criteria, using ANN, ANFIS and ensemble models, are tabulated in Tables 2. The results of the ensemble methods indicated that ensemble models produced better outcomes concerning the single models in precipitation downscaling. So that, ensemble AI-based downscaling models methods increased the performance of AI-based modeling (according to the obtained DC values) up to 10%-65% in the verification step. The proper performance of the ensemble model compared to the single downscaling models indicated that the ensemble model covers the uncertainties in each model and lead to take advantage of both models for the AI-based downscaling models. According to Table 2, the decision tree as a multi-linear method, performs better than nonlinear MI method, because decision tree can accumulate and handle both linear and non-linear properties together in selecting the dominant predictors.

**3-3-Results of Third Step (precipitation projection for future)**

In the third step, monthly precipitation of Tabriz station was projected for the future (2020-2060) under RCP4.5 and RCP8.5 scenarios for Can-ESM2, BNU-ESM GCMs. According to the results of the second step, the downscaling ensemble model with inputs obtained via the decision tree method was selected as the benchmark model, and utilized in the projection step. To assess the projection results, the

predicted precipitation results for the period 2020-2060 under RCP4.5 and RCP8.5 scenarios are indicated versus the observed precipitation (1951-2005) (Fig. 2). As it is shown in Fig. 2, the study area in the future will experience both decrease and increase in precipitation values. It seems the precipitation decrease in the cold months of the year is due to the increase of pollutant density. The spread of particles and pollutions don't let the condensation of many minute vapor particles. So, it prevents the formation of raindrops.

#### 4- CONCLUSIONS

To assess the future precipitation of the Tabriz city AI-based ensemble model (i.e., ANN and ANFIS) was used for the downscaling of GCMs outputs. The dominant predictors were determined via the decision tree and MI feature extraction methods. The advantage of using the proposed predictor screening methodology was selecting the dominant predictors among huge data sets without considering the non-stationary effects of climate variables. The comparison of the ensemble AI-based downscaling models and single models indicated that ensemble models produced better approximation than the single downscaling models and model combination improved the modeling performance by up to 24%-65%. Also, feature extraction methods indicated that the decision tree could be more reliable than the MI in downscaling precipitation at the study station. Finally, the selected feature extraction methods incorporate with downscaling ensemble model indicated reliable results.

#### REFERENCES


- [1] Rezaei, M., Nahtani, M., Abkar, A., Rezaei, M. and Mirkazehi Rigi, M., 2013. "The survey of the efficiency of SDSM for predicting temperature parameters in two dry and superhero climates (Case study: Kerman and Bam)". *Watershed Management Research*, pp. 117-131. (In Persian).
- [2] Le Roux, R., Katurji, M., Zawar-Reza, P., Quéno, H., and Sturman, A., 2018. "Comparison of statistical and dynamical downscaling results from the WRF model" *Environmental Modelling & Software*, 100, pp. 67-73.
- [3] Shannon, C.E., 1948. "A mathematical theory of communications I and II" *Bell Labs Technical Journal*, 27, pp. 379-423.
- [4] Yang, H.H., Van Vuuren, S., Sharma, S., and Hermansky, H., 2000. "Relevance of time-frequency features for phonetic and speaker-channel classification" *Speech Communication*, 31(1), pp. 35-50.
- [5] Singh, V.P., 2011. "Hydrologic synthesis using entropy theory" *Journal of Hydrologic Engineering*, 16(5), pp. 421-433.
- [6] Gao, Z., Gu, B., and Lin, J., 2008. "Monomodal image registration using mutual information-based methods" *Image and Vision Computing*, 26(2), pp. 164-173.
- [7] Pal, M., and Deswal, S., 2009. "M5 model tree-based modeling of reference evapotranspiration" *Hydrological Processes: An International Journal*, 23(10), pp. 1437-1443.
- [8] Maier, H.R., and Dandy, G.C., 2000. "Neural networks for the prediction and forecasting of water resources variables: a review of modeling issues and applications" *Environmental Modelling & Software*, 15(1), pp. 101-124.
- [9] Haykin, S., 1994. *Neural Networks (Computer Science)*. MacMillan College Publishing Co, New York.
- [10] Jang, J.S.R., Sun, C.T., and Mizutani, E., 1997. *Neuro-Fuzzy and Soft Computing: a Computational Approach to Learning and Machine Intelligence*. Prentice-Hall.
- [11] Sharghi, E., Nourani, V., and Behfar, N., 2018. "Earthfall dam seepage analysis using ensemble artificial intelligence-based modeling" *Journal of Hydroinformatics*, 20(5), pp. 1071-1084.
- [12] Jang, J.S., 1993. "ANFIS: adaptive-network-based fuzzy inference system" *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3), pp. 665-685.

#### HOW TO CITE THIS ARTICLE

Z. Razzaghzadeh, V. Nourani, N. Behfar, *The conjunction of the feature extraction method with AI-based ensemble statistical downscaling models*, Amirkabir J. Civil Eng., 52(4) (2020) 219-222.

DOI: [10.22060/ceej.2018.14986.5806](https://doi.org/10.22060/ceej.2018.14986.5806)





## ترکیب روش استخراج مشخصه با ریزمقیاس نمایی آماری مبتنی بر ترکیب مدل های هوش مصنوعی

زهرا رزاق زاده<sup>۱</sup>، وحید نورانی<sup>۲\*</sup>، نازنین بهفر<sup>۱</sup>

<sup>۱</sup> کارشناسی ارشد، دانشکده عمران، دانشگاه تبریز، تبریز  
<sup>۲</sup> استاد، دانشکده عمران، دانشگاه تبریز، تبریز، ایران

**خلاصه:** در این پژوهش از دو مدل گردش عمومی جو (GCM) (Can-ESM2, BNU-ESM) برای شبیه سازی بارش دوره آبی در شهر تبریز، استفاده شده است. مهم ترین ضعف مدل های GCM، بزرگ بودن مقیاس مکانی متغیرهای اقلیمی شبیه سازی شده است که روش های مختلف ریزمقیاس نمایی درصدد رفع این نقیصه می باشند. در این مطالعه برای ریزمقیاس نمودن متغیرهای اقلیمی مدل های GCM، از مدل های هوش مصنوعی شبکه عصبی مصنوعی (ANN) و نروفازی (ANFIS)، بهره گرفته شده است. بدون شک اصلی ترین مرحله به هنگام استفاده از این مدل ها، انتخاب مناسب ترین ورودی از میان داده های بسیار متعدد ارائه شده توسط GCM ها می باشد. بنابراین در این مطالعه برای انتخاب پارامترهای ورودی مؤثر از روش های درخت تصمیم و تابع اطلاعات مشترک (MI) استفاده شده است. هم چنین روش ترکیب مدل برای کاهش عدم قطعیت در ریزمقیاس نمایی و افزایش دقت پیش بینی استفاده شده است. در این پژوهش مقایسه نتایج روش های ریزمقیاس نمایی نشان داد که، مدل ترکیبی با مؤثرترین ورودی های تعیین شده با درخت تصمیم نتایج مناسب تری ارائه می دهد. به طوریکه در هر دو مدل GCM، به کارگیری مدل ترکیبی با پیش بینی کننده های مبتنی بر درخت تصمیم نسبت به مدل های ANN و ANFIS در ریزمقیاس نمای سبب افزایش ۳۸٪-۱۰٪ در DC در مدل سازی بارش می گردد. پیش بینی بارش ایستگاه سینوپتیک تبریز با مدل ترکیبی نشان داد که بارش دوره آبی (۲۰۲۰-۲۰۶۰) تحت سناریوهای RCP۴,۵ و RCP۸,۵ تا ۴۰٪-۳۰٪ کاهش می یابد.

**تاریخچه داوری:**  
دریافت: ۱۳۹۷-۰۶-۲۴  
بازنگری: ۱۳۹۷-۰۷-۰۹  
پذیرش: ۱۳۹۷-۰۸-۰۷  
ارائه آنلاین: ۱۳۹۷-۰۹-۲۴

**کلمات کلیدی:**  
مدل گردش عمومی جو  
شبکه عصبی مصنوعی  
نروفازی  
تابع اطلاعات مشترک  
ریزمقیاس نمایی آماری

### ۱- مقدمه

کاربرد گسترده ای در علوم مختلف دارند [۱]. سری های زمانی حاصل از GCM که بر اساس سناریوهای از پیش تعریف شده تغییر اقلیم در اختیار کاربران قرار می گیرد، دارای مقیاس مکانی بزرگ هستند و برای منطقه ای کردن آن ها باید از روش های ریزمقیاس نمایی استفاده کرد [۲]. در حالت کلی روش های ریزمقیاس نمایی شامل دو روش ریزمقیاس نمایی دینامیکی و ریزمقیاس نمایی آماری می باشد. ریزمقیاس نمایی دینامیکی، یک روش استخراج اطلاعات اقلیمی در مقیاس منطقه ای، با به کار بردن مدل های منطقه ای با قدرت تفکیک مکانی بالا<sup>۲</sup> (RCM) می باشد که در آن داده های GCM که در مقیاس بزرگ هستند به عنوان شرایط مرزی استفاده

منابع آبی به شدت به نوسانات اقلیمی حساس هستند. تاثیر منفی این پدیده (تغییر اقلیم) بر سیستم های مختلف منابع آب از جمله کشاورزی، صنعت و دیگر موارد موجب نگرانی هایی برای جوامع بشری شده است. از این رو بررسی تغییرات بارش به عنوان عوامل مؤثر بر تشدید این پدیده، ضروری به نظر می رسد. یکی از معتبرترین ابزارهای پیش بینی بارش در اثر تغییر اقلیم استفاده از متغیرهای اقلیمی شبیه سازی شده توسط مدل های گردش عمومی جو<sup>۱</sup> (GCM) می باشد که به دلیل ساختار مبتنی بر فیزیک اتمسفر،

1 General Circulation Model

\* نویسنده عهده دار مکاتبات: vahid.nourani96@gmail.com

### 2 Regional Circulation Model

حقوق مؤلفین به نویسندگان و حقوق ناشر به انتشارات دانشگاه امیرکبیر داده شده است. این مقاله تحت لیسانس آفرینندگی مردمی (Creative Commons License) در دسترس شما قرار گرفته است. برای جزئیات این لیسانس، از آدرس <https://www.creativecommons.org/licenses/by-nc/4.0/legalcode> دیدن فرمائید.



می شوند. ریزمقیاس نمایی آماری، شامل ارتباط آماری بین متغیرهای بزرگ مقیاس اقلیمی (پیش‌بینی کننده) و داده‌های اقلیمی در مقیاس منطقه ای (پیش‌بینی شونده) می باشد به طوری که مدل ریزمقیاس نمایی آماری را می توان به عنوان مدل جعبه سیاه معرفی کرد [۳].

علیرغم اینکه مدل‌های ریزمقیاس نمایی دینامیکی دارای قدرت تفکیک مکانی بالا می باشند، از نظر محاسباتی پیچیده هستند و داده های شرایط مرزی برای بسیاری از مناطق و انواع مختلف مدل ها و سناریوها در دسترس نمی باشد. در مقایسه با این روش، روش های ریزمقیاس نمایی آماری ساده تر بوده و به زمان محاسباتی و منابع محدودتری نیاز دارند و برای خروجی های مختلف مدل های GCM در مناطق گوناگون قابل کاربرد می باشند [۴]. به علت راحتی در پیاده سازی و تفسیر نتایج، نوع آماری روش های ریزمقیاس نمایی را محققان گوناگونی توسعه داده اند و در این مورد از روش های متفاوتی شامل مدل ' LARS-WG [۵]، مدل رگرسیون خطی چندگانه (MLR) [۶]، مدل خطی<sup>۲</sup> SDSM [۷] ماشین بردار پشتیبان<sup>۴</sup> (SVM) [۸] و شبکه عصبی مصنوعی<sup>۵</sup> (ANN) [۹] به طور گسترده در مطالعات مختلف استفاده شده است. در دهه اخیر، از روش های هوش مصنوعی مانند ANN، SVM، ANFIS<sup>۶</sup> و دیگر موارد در زمینه ریزمقیاس نمایی با توجه به توانایی آن ها در به دست آوردن روابط غیرخطی بین پیش بینی کننده و پیش بینی شونده استفاده متنوعی شده است. از جمله دواک و همکارانش ریزمقیاس نمایی بارش را با استفاده از SVM و نزدیک ترین همسایگی K انجام دادند [۱۰]. چادویک و همکارانش برای پیش بینی بارش و دما از ANN برای ریزمقیاس کردن داده های GCM استفاده کردند [۱۱]. مهاسفر و همکارانش برای بررسی تاثیر تغییر اقلیم بر تراز سطح دریاچه ارومیه از مدل ANFIS برای ریزمقیاس کردن داده های GCM استفاده کردند [۱۲]. علی رغم وجود چنین طیف گسترده ای از مدل های ریزمقیاس نمایی، یک مدل واحد که در حالت کلی بهتر از سایر مدل های ریزمقیاس نمایی برای هر نوع حوضه و در هر شرایطی عمل کند ارائه نشده است. بنابراین با ترکیب مدل های ریزمقیاس نمایی، ممکن است بخش های مختلفی از اطلاعات

موجود در فرآیند مدل سازی دقیق تر شناسایی گردد. مفهوم چنین ترکیبی از مدل در زمینه های مختلف مهندسی استفاده شده است [۱۳-۱۵]. در این مطالعه تحت یک رویکرد نو، روش ترکیب مدل های هوش مصنوعی برای ریزمقیاس نمایی داده های GCM در مطالعات اقلیمی مورد استفاده قرار گرفته است. در مدل های هوش مصنوعی از جمله ANN و ANFIS که مدل هایی داده محور هستند، انتخاب داده های ورودی مناسب و موثر برای جلوگیری از بیش برآزش مدل ها و صرفه جویی در زمان و هزینه امری بسیار مهم و اساسی است [۱۶]. از این رو در سال های اخیر، در مطالعات اقلیمی محققین مختلفی که برای ریزمقیاس نمایی داده های GCM از مدل های هوش مصنوعی استفاده نمودند از روش های مختلف انتخاب موثرترین پارامترهای ورودی استفاده کردند [۱۷ و ۱۸]. استفاده از روش ضریب همبستگی خطی در تعیین پارامترهای مؤثر ورودی به مدل های هوش مصنوعی به دلیل ذات غیرخطی مدل عملکرد مناسبی را نشان نمی دهد چرا که ضریب همبستگی ارتباط خطی بین دو پارامتر را نشان می دهد در حالی که ممکن است بین دو متغیر پیش بینی کننده و پیش بینی شونده ارتباط چندخطی یا غیرخطی قوی وجود داشته باشد. MI<sup>۷</sup> بیانگر محتوی اطلاعاتی مشترک بین دو سری زمانی می باشد و این بدین معناست که MI ارتباط پیچیده تر و غیرخطی بین دو متغیر را می تواند شناسایی کند. از این رو در مدل های غیر خطی مانند ANN و ANFIS پیشنهاد می گردد از روش های چندخطی یا غیر خطی مانند درخت تصمیم و MI جهت تعیین مؤثرترین ورودی استفاده شود [۱۹ و ۲۰]. با توجه به تعدد پارامترهای مدل های GCM، در این مطالعه روش های درخت تصمیم و MI برای انتخاب داده های ورودی مؤثر مورد استفاده قرار گرفته است. بنابراین برای دستیابی به مدل بهینه به منظور پیش بینی دقیق بارش دوره آبی تحت تاثیر تغییر اقلیم، ریزمقیاس نمایی آماری مبتنی بر ترکیب مدل های هوش مصنوعی با انتخاب مؤثرترین پیش بینی کننده ها با روش های درخت تصمیم و MI ضروری به نظر می رسد.


## ۲- مواد و روش ها

### ۲-۱- داده ها و منطقه مورد مطالعه

شهر تبریز ( عرض جغرافیایی ۳۸°۰۸' ، طول جغرافیایی ۴۶°۲۹'

- 1 Long Ashton Research Station-Weather Generator
- 2 Multi Linear Regression
- 3 Statistical Down Scaling Model
- 4 Support vector machine
- 5 Artificial Neural Network
- 6 Adaptive Neuro Fuzzy Inference System

7 Mutual Information




شکل ۱. موقعیت جغرافیایی منطقه مطالعاتی با نقاط شبکه‌ای مدل‌های BNU-ESM و Can-ESM2

Fig. 1. Study area with the grid points of BNU-ESM and Can-ESM2

دارد، دارای زمستان‌های طولانی و سرد و تابستان گرم و خشک است. میانگین بارندگی سالیانه تبریز حدود ۳۳۰ میلی‌متر در سال می‌باشد. معمولاً در طول فصل تابستان، میزان بارندگی بسیار ناچیز بوده و به ندرت بارش رخ می‌دهد. میانگین بارش تبریز در زمستان ۱۱۳/۳ میلی‌متر، در بهار ۱۲۱/۸ میلی‌متر، در تابستان ۲۰/۷ میلی‌متر و در پاییز ۷۴/۳ میلی‌متر است. نوسان بارندگی سالانه از ۵۱۳/۳ میلی‌متر در سال‌های پر بارش تا حداقل ۱۹۲/۴ میلی‌متر در سال‌های کم بارش گزارش شده است.

به منظور ریزمقیاس کردن خروجی‌های بزرگ مقیاس مدل‌های GCM و استفاده در مقیاس منطقه، داده بارش ماهانه مشاهداتی

(با مساحت  $1781 \text{ KM}^2$  در غرب استان آذربایجان شرقی و در منتهی‌الیه شرق و جنوب شرق جلگه تبریز قرار گرفته است (شکل ۱). این شهر از سمت شمال به کوه‌های پکه چین و عون بن علی، از سمت شمال شرق به گردنه پایان و از سمت جنوب به دامنه‌های کوه سهند محدود شده است. نتایج تجزیه تحلیل‌های آماری صورت گرفته بر روی داده‌های متوسط سرعت باد و جهت باد نشان می‌دهد که این شهر همواره تحت تاثیر بادهای سرد شمالی و سیبری و بادهای مرطوب دریای سیاه و مدیترانه و اقیانوس اطلس قرار گرفته است [۲۱]. شهر تبریز یک منطقه سردسیر و کوهستانی است و دارای آب و هوای اقلیمی و کم رطوبت است و در اثر ارتفاعی که از سطح دریا



شکل ۲. توزیع بارش ماهانه ایستگاه سینوپتیک تبریز

Fig. 2. Monthly precipitation distribution of Tabriz synoptic station

جدول ۱. مشخصات مدل های GCM بررسی شده در این مطالعه  
Table 1. Characteristics of GCM models investigated in this study

پارامترهای مدل GCM	قدرت تفکیک پذیری	مرکز تحقیقاتی	مدل
pr: بارندگی prc: بارش همرفتی prw: آب قابل بارش	$2/8^{\circ} \times 2/8^{\circ}$	Canadian Centre for Climate Modelling and Analysis	Can-ESM2
hfls: شار حرارتی evspsbl: بخار آب ts: دمای سطح دریا ps: فشار هوای سطحی	$1/9^{\circ} \times 1/9^{\circ}$	Commonwealth Scientific and Industrial Research Organization	CSIRO-MK3.6.0
psl: فشار سطح دریا hurs: رطوبت نسبی سطحی vas: سرعت باد نصف النهاری سطحی	$1/9^{\circ} \times 1/2^{\circ}$	Commonwealth Scientific and Industrial Research Organization	ACCESS1.0
uas: سرعت باد منطقه‌ای سطحی tas: دمای هوای سطحی huss: رطوبت مخصوص سطحی tasmin: دمای حداقل	$2/5^{\circ} \times 2^{\circ}$	NASA/GISS (Goddard Institute for Space Studies)	GISS--E2-R-CC
tasmax: دمای حداکثر tauu: تنش باد در جهت شرقی-غربی tauv: تنش باد در جهت شمالی-جنوبی	$2/8^{\circ} \times 2/8^{\circ}$	The First Institute of Oceanography, SOA	FIO-ESM
sfewind: سرعت باد (b)hus: رطوبت مخصوص	$1/9^{\circ} \times 1/2^{\circ}$	National Institute of Meteorological Research	HadGEM2-AO
(b)ta: دمای هوا (b)zg: ارتفاع ژئوپتانسیل (b)ua: باد منطقه‌ای (b)va: باد نصف النهاری	$2/7^{\circ} \times 1/9^{\circ}$	Institute Pierre Simon Laplace	IPSL-CM5B-LR
(b)hur: رطوبت نسبی	$2/8^{\circ} \times 2/8^{\circ}$	Beijing Normal University	BNU-ESM

(b) بیانگر سطوح مختلف فشار می‌باشد.

(b) 100hpa, 200hpa, 300hpa, 500hpa, 700 hpa, 850 hpa, 1000 hpa, 7000hpa, 85000 hpa

IPCC انتخاب شده‌است. مراکز تحقیقاتی مدل‌ها، قدرت تفکیک مدل‌ها هم چنین متغیرهای اقلیمی ماهانه بررسی شده در جدول ۱ آورده شده‌است. از میان ۸ مدل GCM، دو مدل Can-ESM2 و BNU-ESM بر اساس بالاترین مقدار MI بین بارش ماهانه مدل GCM و بارش ماهانه مشاهداتی منطقه انتخاب شده‌است. مطالعات مختلف نشان داده استفاده از چندین نقطه از شبکه GCM در اطراف منطقه

ایستگاه تبریز برای دوره ۲۰۱۷-۱۹۵۱ از سازمان هواشناسی تبریز تهیه گردیده‌است. شکل ۲ توزیع بارش ماهانه تبریز در دوره (۲۰۱۷-۱۹۵۱) را نشان می‌دهد که بیشترین مقدار بارندگی در فصل بهار و کمترین مقدار بارش در فصل تابستان رخ داده‌است.

در این تحقیق ۸ مدل GCM از مجموعه مدل‌های گزارش پنجم



GCM اطراف شهر تبریز استفاده شده است. در شکل ۳ مراحل انجام کار به صورت شماتیک نشان داده شده است. در گام اول مناسب ترین مدل GCM برای منطقه مورد مطالعه انتخاب گردیده و سپس موثرترین متغیرهای مدل GCM با استفاده از روش های استخراج مشخصه درخت تصمیم و MI تعیین شده است. گام دوم استفاده از مدل های مبتنی بر هوش مصنوعی برای ریزمقیاس کردن موثرترین پارامترهای تعیین شده در گام اول می باشد هم چنین برای ارزیابی و انتخاب مدل ریزمقیاس نمایی مناسب از ترکیب روش های مبتنی بر هوش مصنوعی برای ریزمقیاس کردن استفاده شده است. گام آخر پیش بینی بارش ایستگاه سینوپتیک تبریز برای آینده تحت سناریوهای RCP4.5 و RCP8.5 می باشد. در ادامه جزییات روش پیشنهادی به صورت گام به گام ارائه شده است:

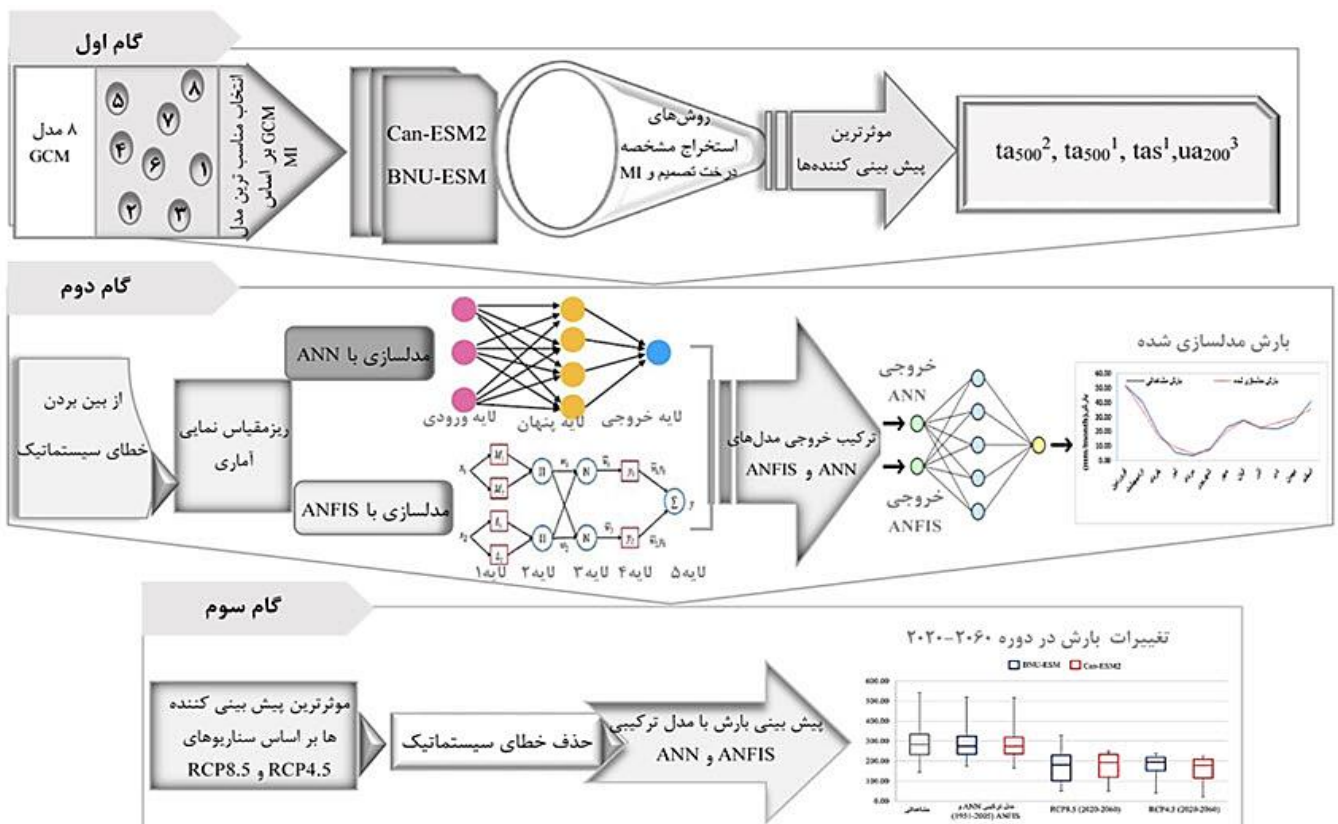
### ۲-۲-۱- گام اول (تعیین موثرترین متغیر GCM)

مدل های GCM مختلف دارای قدرت تفکیک پذیری متفاوتی می باشند. از این رو یکی از عوامل موثر در دقت پیش بینی

مطالعه نتایج مناسب تری ارائه می دهد [۲۲ و ۲۳]. بنابراین در این مطالعه پیش بینی کننده ها در چهار نقطه از شبکه GCM اطراف منطقه مطالعه در نظر گرفته شده است. همان گونه در شکل ۱ نشان داده شده است در دو مدل انتخاب شده، موقعیت نزدیک ترین نقاط چهارگانه شبکه GCM به تبریز (۱،۲،۳،۴) یکسان می باشد. داده های مدل GCM از مرکز توزیع داده IPCC (<https://www.dkrz.de/daten/wdccc>) برای دوره ۱۹۵۱-۲۰۶۰ تهیه شده است. در این مطالعه متغیرهای اقلیمی برای دوره آتی (۲۰۲۰-۲۰۶۰) تحت دو سناریوی RCP4.5 و RCP8.5 در نظر گرفته شده اند.

### ۲-۲-۲- روش تحقیق

در این مطالعه به منظور ریزمقیاس کردن داده های مدل GCM از ریزمقیاس نمایی آماری مبتنی بر ترکیب مدل های هوش مصنوعی (ANN و ANFIS) استفاده شده است. هم چنین به منظور افزایش دقت مدل ریزمقیاس نمایی از روش استخراج مشخصه برای پیش پردازش متغیرهای GCM در نزدیک ترین نقاط چهارگانه شبکه



شکل ۳. شکل شماتیک مراحل انجام تحقیق  
Fig. 3. Schematic of research steps

پیش‌بینی کننده و پیش‌بینی شونده محاسبه شده و پارامترهایی که بیشترین مقدار MI را داشتند به‌عنوان موثرترین ورودی انتخاب شدند. در نهایت موثرترین پارامترهای تعیین‌شده با روش‌های درخت تصمیم و MI، در گام دوم به‌عنوان ورودی به مدل‌های ریزمقیاس‌نمایی استفاده شده‌است.

### ۲-۲-۲- گام دوم (ریزمقیاس‌نمایی)

در گام دوم، مدل‌های مبتنی بر هوش مصنوعی (مدل ANN و مدل ANFIS) برای ریزمقیاس‌کردن استفاده شده‌است. برای این منظور موثرترین پیش‌بینی کننده‌های تعیین‌شده در گام اول برای آموزش و صحت‌سنجی کردن مدل‌های ANN و ANFIS استفاده شده‌است. در ادامه برای بهبود عملکرد مدل‌های ریزمقیاس‌نمایی و کاهش عدم قطعیت مدل‌ها، خروجی مدل‌های ANN و ANFIS ترکیب شده‌اند. به‌عبارت دیگر در ترکیب مدل‌های هوش مصنوعی خروجی هر کدام از مدل‌های ANN و ANFIS مجدداً به‌عنوان ورودی مدل هوش مصنوعی (مدل ANN و مدل ANFIS) وارد می‌گردند. در نهایت مدل ترکیبی ایجادشده، برای پیش‌بینی بارش تبریز در گام سوم مورد استفاده قرار می‌گیرد.

لازم‌به ذکر است که به‌علت وجود خطای سیستماتیک بین داده‌های مدل GCM و داده‌های مشاهداتی، قبل از ریزمقیاس‌نمایی حذف خطای سیستماتیک از داده‌های GCM ضروری به‌نظر می‌رسد [۲۵]. استاندارد کردن (تفریق میانگین از داده‌ها و تقسیم بر انحراف استاندارد) یک روش متداول برای حذف خطای سیستماتیک از داده‌های GCM می‌باشد. استانداردسازی پیش‌بینی کننده‌ها مقادیر داده‌های پیش‌بینی کننده را به یک مقیاس یکنواختی کاهش می‌دهد و واحدهای متغیر را حذف می‌کند [۲۶].

### ۲-۲-۳- گام سوم (مدل پیش‌بینی)

گام آخر، پیش‌بینی بارش شهر تبریز در دوره ۲۰۲۰-۲۰۶۰ تحت سناریوهای RP4.5 و RCP8.5 می‌باشد. در این راستا برای پیش‌بینی بارش، موثرترین پیش‌بینی کننده‌های تعیین‌شده در گام اول تحت سناریوهای RCP4.5 و RCP8.5 با استفاده از بهترین مدل ریزمقیاس‌نمایی که در گام دوم تعیین شده‌است، ریزمقیاس می‌شوند.

پارامترهای اقلیمی بستگی به عملکرد مدل‌های GCM دارد. بنابراین ارزیابی مدل‌های GCM مختلف و انتخاب مناسب‌ترین مدل GCM ضروری است [۲۴]. برای انتخاب مناسب‌ترین مدل GCM برای منطقه مورد مطالعه، MI بین بارش ماهانه ایستگاه تبریز و بارش ماهانه چندین مدل GCM که در جدول ۱ آورده شده‌است در دوره ۲۰۰۵-۱۹۵۱ محاسبه گردید و از میان این مدل‌ها دو مدل Can-ESM2 و BNU-ESM به‌عنوان مدل‌های مورد استفاده در این تحقیق انتخاب شدند. سپس روش درخت تصمیم و معیار مبتنی بر آنتروپی شانون یعنی MI برای تعیین موثرترین پیش‌بینی کننده‌های مدل‌های GCM که همان پارامترهای ورودی به مدل ریزمقیاس‌نمایی می‌باشد استفاده گردید.

با توجه به این‌که هیچ منطقه‌ای از نظر اقلیمی مستقل نیست، بلکه الگوی اقلیمی غالب در هر منطقه، منطقه دیگر را نیز تحت تاثیر خود قرار می‌دهد، بنابراین در این مطالعه پیش‌بینی کننده‌ها در نزدیک‌ترین نقاط چهارگانه شبکه GCM اطراف منطقه مورد مطالعه استخراج گردید. نزدیک‌ترین نقاط چهارگانه شبکه GCM به ایستگاه سینوپتیک تبریز در شکل ۱ با اعداد ۱، ۲، ۳ و ۴ نشان داده شده‌است. همان‌طور که در شکل ۱ نشان داده شده‌است در این مطالعه موقعیت نقاط شبکه GCM در هر دو مدل (CAN-ESM2، BNU-ESM) یکسان می‌باشد. تعداد متغیرهای پیش‌بینی کننده در هر دو مدل GCM، ۱۲۵ پارامتر می‌باشد. بنابراین در مدل‌های BNU-ESM و Can-ESM2، ۴×۱۲۵ پیش‌بینی کننده در فرآیند ریزمقیاس‌نمایی مورد ارزیابی قرار می‌گیرد. بدون شک به‌دلیل زیاد بودن متغیرهای پیش‌بینی کننده کارایی مدل‌های مبتنی بر هوش مصنوعی که برای ریزمقیاس‌نمایی استفاده می‌شود کاهش می‌یابد. برای حل این مشکل مؤثرترین پارامترها به‌عنوان ورودی به مدل ریزمقیاس‌نمایی با استفاده از دو روش استخراج مشخصه درخت تصمیم و MI تعیین شده‌است. در روش استخراج مشخصه درخت تصمیم برای تعیین موثرترین پیش‌بینی کننده، میزان ارتباط چندخطی بین متغیرهای پیش‌بینی کننده (پارامترهای GCM) و پیش‌بینی شونده (بارش مشاهداتی) محاسبه شده و پارامترهایی که بیشترین ارتباط چندخطی را داشتند یا به‌عبارت دیگر پارامترهایی که در گره‌های بالای درخت قرار داشتند به‌عنوان موثرترین ورودی انتخاب شدند. در روش استخراج مشخصه MI میزان ارتباط غیر خطی بین پارامترهای

دسته‌بندی و پیش‌بینی داده‌ها با رویکرد یادگیری نظارت‌شده می‌باشد. در حالت کلی ساختار درخت از چهار بخش تشکیل شده است که شامل ریشه، شاخه، گره و برگ می‌باشد. در درخت تصمیم، گره فوقانی، یعنی ریشه درخت، بهترین گره برای دسته‌بندی است و پارامترهای دیگر در گره‌های پایینی درخت تصمیم به ترتیب ارزش و اهمیت کمتری پیدا می‌کنند. هر چه امتیاز شاخه‌ای بیشتر باشد، پارامتر نظیر آن شاخه از اهمیت بیش‌تری برخوردار بوده و می‌تواند به‌عنوان مؤثرترین پارامتر ورودی برای سیستم مورد مطالعه، استفاده شود. برای ساخت درخت تصمیم روش‌های مختلفی وجود دارد که الگوریتم M5 درخت تصمیم می‌تواند به‌طور مؤثر برای طبقه‌بندی کردن پارامترها مورد استفاده قرار گیرد [۳۱]. اولین بار مدل درختی M5 را [۳۲] بر اساس روش طبقه‌بندی درختی برای ایجاد رابطه بین متغیرهای مستقل و وابسته ارائه کرد. در مدل M5 از هر گره ریشه دو شاخه منشعب می‌شود. معیار انشعاب در مدل M5 بیشینه‌سازی کاهش انحراف معیار داده‌ها در گره برگ است. زمانی که امکان کاهش انحراف معیار داده‌های گره برگ میسر نباشد گره ریشه آن منشعب نمی‌شود و به گره پایانی یا برگ نمی‌رسد. کاهش انحراف معیار با رابطه ۴ بیان می‌شود [۳۳]: برای جزئیات بیشتر در مورد

$$SDR = sd(T) - \sum \frac{|T_i|}{|T|} sd(T_i) \quad (4)$$

ساختار مدل درختی M5 به مرجع [۲۰] مراجعه شود.

در این مطالعه برای تعیین مؤثرترین پیش‌بینی‌کننده بر اساس میزان ارتباط چندخطی بین پارامترهای پیش‌بینی‌کننده (پارامترهای مدل GCM) و پارامتر پیش‌بینی شونده (بارش تبریز) روش مدل درختی M5 استفاده شد.

#### ۲-۵- شبکه عصبی مصنوعی (ANN)

برای ریزمقیاس کردن متغیرهای GCM در این مطالعه از مدل ANN با ساختار پیشرو استفاده شده است (لایه ورودی، لایه پنهان و لایه خروجی). مطالعات اخیر نشان می‌دهد که ANN پیشرو با الگوریتم انتشار برگشتی که در اکثر مدل‌سازی‌های سری زمانی مورد استفاده قرار می‌گیرد و یک الگوی کلی برای نگاشت غیر خطی

در ادامه توضیحات مختصری در مورد ابزارهایی که در این بررسی مورد استفاده قرار گرفته، ارائه شده است.

#### ۲-۳- تابع اطلاعات مشترک (MI)

انترپی و محتوای اطلاعاتی به‌صورت ریاضی و با استفاده از توزیع احتمالاتی داده‌ها فرمول‌بندی شده و به‌عنوان معیار سنجش بی‌نظمی، آشفتگی و عدم قطعیت معرفی شده است این نوع از انترپی به‌عنوان انترپی شانون شناخته می‌شود [۲۷]. براساس ماهیت داده‌ها و مساله در حالت کلی نظریه محتوای اطلاعاتی شانون به‌صورت پیوسته یا گسسته می‌تواند مورد استفاده قرار گیرد. با توجه به این که داده‌هایی که در این تحقیق استفاده می‌شود، گسسته می‌باشند. انترپی شانون برای متغیر تصادفی  $X$  به طول  $N$  با مقادیر  $(x_1, x_2, \dots, x_n)$  و احتمالات متناظر  $(p_1, p_2, \dots, p_n)$  از رابطه ۱ محاسبه می‌شود

$$H(X) = -\sum_{i=1}^N P(X_i) \log[P(X_i)] \quad (1)$$

شود [۲۸]:

MI بین دو متغیر تصادفی  $X$  و  $Y$  به‌صورت رابطه ۲ تعریف می‌شود

$$MI(X, Y) = H(X) + H(Y) - H(X, Y) \quad (2)$$

شود [۲۹]:

که  $H(X)$  و  $H(Y)$  به ترتیب انترپی  $X$  و  $Y$  می‌باشد و  $H(X, Y)$  انترپی مشترک  $X$  و  $Y$  می‌باشد که با رابطه ۳ محاسبه می‌گردد

$$H(X, Y) = -\sum_{i=1}^N \sum_{j=1}^N P(X_i, Y_j) \log[P(X_i, Y_j)] \quad (3)$$

[۳۰]:

در این مطالعه برای تعیین میزان ارتباط غیر خطی بین پارامترهای پیش‌بینی‌کننده (پارامترهای مدل GCM) و پارامتر پیش‌بینی شونده (بارش تبریز) و تعیین مؤثرترین پیش‌بینی‌کننده از روش MI استفاده شد.

#### ۲-۴- درخت تصمیم

درخت تصمیم یکی از ابزارهای قدرتمند و متداول برای

و RMSE استفاده شده است (به ترتیب روابط ۵ و ۶) [۳۹]. مقدار DC بین صفر تا  $\infty$  متغیر است، که هر چه مقدار آن به یک نزدیک باشد عملکرد مدل خوب ارزیابی می گردد. مقدار RMSE بین ۰ تا  $\infty$  متغیر است و چنانچه مقدار RMSE به صفر میل کند عملکرد مدل،

$$DC = 1 - \frac{\sum_{i=1}^n (O_i - Y_i)^2}{\sum_{i=1}^n (O_i - \bar{O}_i)^2} \quad (5)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - Y_i)^2}{N}} \quad (6)$$

خوب ارزیابی می گردد [۴۰].

$O_i$ ، و  $Y_i$  به ترتیب داده های بارش مشاهداتی، میانگین بارش مشاهداتی و بارش شبیه‌سازی شده می باشند و N تعداد کل پارامتر ورودی می باشد.

### ۳- بحث و نتایج

در این مطالعه برای پیش بینی بارش شهر تبریز در دوره آتی (۲۰۶۰-۲۰۲۰) از ریزمقیاس نمایی آماری داده های GCM استفاده شده است. برای این منظور از ترکیب مدل های هوش مصنوعی (ANN و ANFIS) با انتخاب بهینه پیش بینی کننده ها با روش های استخراج مشخصه درخت تصمیم و MI استفاده شده است. با توجه به اینکه روش تحقیق در سه گام ارایه شده است، در ادامه نتایج و بحث نیز در سه گام ارایه می گردد.

#### ۳-۱- نتایج گام اول (تعیین موثرترین مدل GCM و موثرترین پیش‌بینی کننده ها):

انتخاب مناسب ترین مدل GCM برای منطقه مورد مطالعه بر اساس محاسبه مقدار MI بین بارش ماهانه مشاهداتی شهر تبریز و بارش ماهانه چندین مدل در نظر گرفته شده (جدول ۱) در دوره ۲۰۰۵-۱۹۵۱ صورت گرفته است. از میان ۸ مدل GCM در نظر گرفته شده در این مطالعه، دو مدل BNU-ESM و Can-ESM۲ با دارا بودن بیشترین رابطه غیرخطی بر اساس MI به عنوان بهترین مدل انتخاب شده است (جدول ۲). لازم به ذکر است که در ۸ مدل

میان متغیرهای ورودی و خروجی است، نتیجه رضایت بخشی در پیش‌بینی و شبیه‌سازی های متغیر های منابع آب داشته است [۳۴]. مفاهیم ریاضی که بیانگر چگونگی عملکرد شبکه برای تولید مقدار خروجی است در [۳۵] بیان می گردد.

#### ۲-۶- سیستم استنتاج تطبیقی عصبی فازی (ANFIS)

در سال ۱۹۹۳، جانگ برای نخستین بار با کنار هم قرار دادن قابلیت‌های تئوری فازی و شبکه عصبی، مدل سیستم استنتاج تطبیقی عص فازی را ارائه داد [۳۶]. ساختار انفیس شامل توانایی‌های استنتاج سیستم فازی و انطباق‌پذیری شبکه عصبی است. انفیس روشی برای بهبود بخشیدن به قوانین سیستم فازی با کمک الگوریتم های آموزشی در شبکه‌های عصبی مصنوعی است. ساختار انفیس از یک شبکه عصبی پنج لایه تشکیل شده است که لایه اول شامل ورودی‌ها، لایه دوم شامل ترم‌های کلامی ورودی‌ها یا به عبارتی توابع عضویت، لایه سوم نشانگر بخش مقدم قوانین فازی، لایه چهارم شامل بخش تالی قوانین فازی و لایه پنجم نشان‌دهنده مرحله فازی زدایی است [۳۷]. برای جزئیات بیشتر به مرجع [۳۷] مراجعه شود.

#### ۲-۷- ترکیب مدل

ترکیب مدل به‌عنوان روشی پس پردازش برای کاهش عدم قطعیت مدل‌ها و کاهش نرخ خطا می باشد. فرض مبنایی این روش آن است که در حالت دسته جمعی احتمال اشتباه در تشخیص دسته یا جایگاه یک نمونه جدید خیلی کمتر از حالت پیش‌بینی با تنها یک مدل می باشد [۳۶ و ۳۸].

در این مرحله، نتایج مدل‌های منفرد بار دیگر توسط مدل ANN با یکدیگر ترکیب شده‌اند. به عبارت دیگر ورودی لایه اول مدلی ترکیبی، خروجی‌های به‌دست آمده از دو مدل منفرد می باشد.

#### ۲-۸- معیار ارزیابی مدل

به‌علت کفایت معیاره های ضریب تبیین (DC) و جذر میانگین مربعات خطا<sup>۲</sup> (RMSE) در مدل سازی پارامترهای هیدروکلیماتولوژیکی در این مطالعه به‌منظور ارزیابی عملکرد مدل ریزمقیاس نمایی در فرآیند آموزش و صحت سنجی از دو معیاره DC

- 1 Determination coefficient
- 2 Root Mean Square Error

جدول ۲. نتایج مدل های GCM  
Table 2. Results of GCM models

مدل	MI
GISS--E2-R-CC	۰/۴۱
FIO-ESM	۰/۳۲
ACCESS1.0	۰/۵۱
BNU-ESM	۰/۷۹
CSIRO-MK3.6.0	۰/۴۸
Can-ESM2	۰/۸۶
IPSL-CM5B-LR	۰/۲۴
HadGEM2-AO	۰/۴۳

GCM، از میان چهار گره در نظر گرفته شده در این مطالعه نتایج گره هایی که بالاترین ارتباط غیرخطی را با پیش بینی شونده داشتند در جدول ۲ ارائه شده است.

پس از انتخاب مناسب ترین مدل GCM برای منطقه مورد مطالعه، موثرترین پیش کننده های مدل های داده محور (مدل های ریزمقیاس نمایی) بایستی تعیین گردد [۴۱]. بنابراین در این مطالعه از روش های استخراج مشخصه درخت تصمیم و MI برای انتخاب موثرترین پیش بینی کننده های مدل های GCM انتخاب شده (Can-ESM2 و BNU-ESM) استفاده شده است. نتایج موثرترین پیش بینی کننده ها در جدول ۳ ارائه شده است. بر این اساس، پیش بینی کننده هایی با بیشترین مقدار MI در هر گره انتخاب شده است. هم چنین براساس الگوریتم M5 روش درخت تصمیم پیش بینی کننده هایی که در گره های بالا درخت قرار گرفته اند و بیشترین امتیاز را دارا می باشند انتخاب شده است.

نتایج جدول ۳ نشان می دهد که موثرترین پیش بینی کننده

های بارش شهر تبریز بر اساس روش استخراج مشخصه MI، بادهای منطقه ای (Ua) و متغیرهای از نوع دما (ts، ta، tas) می باشند. این امر حاکی از وجود ارتباط غیرخطی بین بارش مشاهداتی و متغیرهای پیش بینی کننده دما و باد منطقه ای می باشد.

موثرترین پیش بینی کننده ها بر اساس روش استخراج مشخصه درخت تصمیم، متغیرهای از نوع دما (ts، ta، tas) و رطوبت (hus pr،) می باشند. ارزیابی موثرترین پیش بینی کننده های تعیین شده با روش درخت تصمیم نشان می دهد که روش درخت تصمیم به علت ماهیت چن خطی علاوه بر شناسایی موثرترین پیش بینی کننده هایی با ماهیت غیرخطی (متغیرهای دما)، توانایی شناسایی موثرترین پیش بینی کننده ها با ماهیت خطی (متغیرهای از نوع رطوبت) [۱۸] را نیز دارا می باشد. بنابراین بهتر است از روش استخراج مشخصه درخت تصمیم به جای روش های استخراج مشخصه غیرخطی (MI) و خطی (روش ضریب همبستگی) استفاده شود.

پیش بینی کننده های انتخاب شده در هر گره نشان دهنده تاثیر مرفولوژیکی آن منطقه در متغیرهای اقلیمی می باشد که در نتیجه بارش شهر تبریز را تحت تاثیر قرار می دهند. به نظر می رسد که علت مهم بودن گره های ۱، ۲ و ۳ نزدیکی به منابع رطوبتی از جمله دریاچه ارومیه، دریاچه sevan و دریاچه ی خزر می باشد. چرا که دما و باد از پارامترهای اصلی در شکل گیری رطوبت در مناطق دریایی می باشند.

با توجه به اینکه هیچ کدام از موثرترین پیش بینی کننده ها از نزدیک ترین گره شبکه GCM به ایستگاه تبریز (گره ۴) انتخاب نشده اند، می توان گفت بارندگی منطقه لزوماً ارتباطی با پیش بینی کننده ها (پارامترهای اقلیمی) نزدیک ترین منطقه ندارد. بنابراین انتخاب پیش بینی کننده ها از نزدیک ترین گره ممکن است معیار مناسبی در

جدول ۳. موثرترین پیش بینی کننده های GCM بر اساس روش MI و درخت تصمیم برای پیش بینی بارش  
Table 3. Dominant predictors based on MI and decision tree

مدل	روش استخراج مشخصه	ا <sup>a</sup> (موثرترین پیش بینی کننده ها)
BNU-ESM	MI	ua(850) <sup>(2)</sup> , ta(850) <sup>(1)</sup> , ua(200) <sup>(1)</sup> , ta(850) <sup>(3)</sup>
Can-ESM2		ta(500) <sup>(3)</sup> , ta(500) <sup>(1)</sup> , tas <sup>(3)</sup> , ua(200) <sup>(3)</sup>
BNU-ESM	درخت تصمیم	ta(200) <sup>(3)</sup> , ts <sup>(3)</sup> , ta(1000) <sup>(2)</sup> , pr <sup>(1)</sup>
Can-ESM2		Prc <sup>(3)</sup> , hus(850) <sup>(3)</sup> , tas <sup>(2)</sup> , ta(500) <sup>(2)</sup>

(<sup>a</sup>) شماره گریدها مطابق با شکل ۱ (a=1, 2, 3, 4)

(ANN) در نظر گرفته می شود.

همانند مدل ریزمقیاس نمایی ANN، در مدل ترکیبی از مدل ANN با ساختار سه لایه و الگوریتم انتشار برگشتی برای ریزمقیاس کردن بارش استفاده شده است. پارامترهای ورودی به مدل ترکیبی بارش به دست آمده از مدل های ریزمقیاس نمایی منفرد ANN و ANFIS می باشد. لایه دوم داده های بارش مشاهداتی به عنوان داده هدف می باشد و لایه آخر بارش محاسباتی می باشد که خروجی مدل ترکیبی نامیده می شود. بهترین ساختار شبکه (تعداد بهینه نرون های لایه پنهان و تعداد گام های تکرار) با سعی خطا تعیین شده است. در این مطالعه تعداد بهینه نرون های لایه پنهان و گام های تکرار به ترتیب ۶ و ۸۰۰ می باشد.

جدول ۴ نتایج مدل های ریزمقیاس نمایی را نشان می دهد. نتایج ریزمقیاس نمایی بارش بر اساس معیارهای ارزیابی نشان می دهد که روش استخراج مشخصه درخت تصمیم به علت ماهیت چند خطی ۳۹٪-۱۰٪ عملکرد بهتری نسبت به روش MI در مرحله صحت سنجی دارد. دلیل این عملکرد را می توان چنین عنوان کرد که روش درخت تصمیم از مزایای روش های استخراج مشخصه خطی و غیرخطی برخوردار می باشد و می تواند پارامترهایی را که دارای ارتباط خطی و غیرخطی با بارش منطقه می باشند، شناسایی کند. این در حالی است که روش MI فقط قادر به شناسایی پارامترهایی است که دارای ارتباط غیرخطی با بارش منطقه می باشند و پارامترهایی که ارتباط خطی با بارش منطقه داشته باشند را نمی تواند شناسایی کند. در حالی که پارامترهایی که دارای ارتباط خطی با بارش منطقه می باشند نیز مهم هستند.

همچنین نتایج جدول ۴ حاکی از این می باشد که مدل ترکیبی عملکرد بهتری نسبت به مدل های ریزمقیاس نمایی منفرد در ریزمقیاس کردن بارش تبریز دارد. به طوریکه مدل ترکیبی مبتنی بر هوش مصنوعی ۶۵٪-۱۰٪ عملکرد بهتری نسبت به مدل های منفرد ریزمقیاس نمایی، در مرحله صحت سنجی نشان داده است. عملکرد مناسب مدل ترکیبی نسبت به مدل های ریزمقیاس نمایی منفرد حاکی از این می باشد که مدل ترکیبی در ریزمقیاس کردن، عدم قطعیت های موجود در هر مدل را پوشش می دهد و امکان بهره مندی از مزایای هر دو مدل را ممکن می سازد.

سری زمانی بارش ماهانه مشاهداتی و ریزمقیاس شده برای ایستگاه

انتخاب موثرترین پیش بینی کننده نباشد. از این رو انتخاب پیش بینی کننده ها از گره های مختلف در اطراف منطقه مورد مطالعه می تواند تاثیر مناسبی در دقت پیش بینی داشته باشد.

## ۲-۳- نتایج گام دوم (ریزمقیاس نمایی)

در گام دوم، برای ریزمقیاس کردن موثرترین پیش بینی کننده های تعیین شده با روش های درخت تصمیم و MI، از دو مدل مبتنی بر هوش مصنوعی ANN و ANFIS که از رایج ترین مدل ها در مدل سازی پارامترهای هیدروکلیماتولوژیکی می باشد استفاده شده است. قبل از ریزمقیاس نمودن، موثرترین پیش بینی کننده ها در دوره ۲۰۰۵-۱۹۵۱ استاندارد می شوند. برای آموزش و صحت سنجی مدل ها ۷۵٪ از داده های ورودی برای آموزش و ۲۵٪ برای آزمایش در نظر گرفته شده است.

مدل ANN با ساختار سه لایه و الگوریتم انتشار برگشتی برای ریزمقیاس کردن بارش ایستگاه سینوپتیک تبریز استفاده شده است. برای جلوگیری از بیش برآزش مدل ANN، از روش آزمون و خطا برای تعیین تعداد بهینه نرون های لایه پنهان و گام های تکرار در فرآیند آموزش شبکه استفاده شده است. در این مطالعه محدوده گام های تکرار و تعداد نرون های لایه پنهان به ترتیب ۱۰۰-۱۰ و ۱-۱۰ در نظر گرفته شده است.

هم چنین مدل ANFIS با تابع عضویت پی شکل برای نگاشت رابطه غیرخطی بین متغیرهای پیش بینی کننده و پیش بینی شونده استفاده شده است. در مدل ANFIS نیز برای تعیین نوع و تعداد توابع عضویت بهینه از روش آزمون و خطا استفاده شده است.

نتایج ریزمقیاس نمایی بارش با مدل های ANN و ANFIS بر اساس معیارهای ارزیابی DC و RMSE در جدول ۴ ارائه شده است. نتایج جدول ۴ نشان می دهد که در هر دو مدل GCM (Can-ESM2 و BNU-ESM) مدل ANN در مقایسه با مدل ANFIS عملکرد نسبتاً مناسبی در ریزمقیاس نمایی بارش ایستگاه تبریز دارد. برای افزایش کارایی مدل ریزمقیاس نمایی آماری از مدل ترکیبی مبتنی بر هوش مصنوعی (ترکیب مدل ANN با مدل ANFIS) استفاده شده است. برای این منظور نتایج بارش مدل سازی شده در دوره ۲۰۰۵-۱۹۵۱ با هر کدام از مدل های ANN و ANFIS مجدداً به عنوان ورودی به مدل ANN (به علت عملکرد نسبتاً مناسب مدل

جدول ۴. نتایج ریزمقیاس نمایی بارش ایستگاه تبریز  
Table 4. Downscaling results of precipitation

صحت سنجی		آموزش		مدل ریزمقیاس نمایی	موثرترین پارامتر ورودی	روش استخراج مشخصه	مدل GCM
N <sup>1</sup> -RMSE	DC	N <sup>1</sup> -RMSE	DC				
۰/۱۰	۰/۶۱	۰/۱۱	۰/۶۵	ANN			
۰/۱۲	۰/۴۶	۰/۱۳	۱۵۰	ANFIS	ua(850) <sup>(2)</sup> , ta(850) <sup>(1)</sup> , ua(200) <sup>(1)</sup> , ta(850) <sup>(3)</sup>	MI	
۰/۰۸	۰/۷۶	۰/۰۹	۱۷۹	مدل ترکیبی ANN و ANFIS			BNU-ESM
۰/۰۸	۱۷۷	۰/۰۹	۱۷۹	ANN			
۰/۱۰	۰/۶۴	۰/۱۱	۰/۶۶	ANFIS	ta(200) <sup>(3)</sup> , ts <sup>(3)</sup> , ta(1000) <sup>(2)</sup> , pr <sup>(1)</sup>	درخت تصمیم	
۰/۰۷	۱۸۴	۰/۰۶	۱۸۸	مدل ترکیبی ANN و ANFIS			
۰/۰۹	۰/۶۷	۰/۱۱	۰/۶۹	ANN			
۰/۱۱	۱۵۱	۰/۱۳	۱۵۴	ANFIS	ta(500) <sup>(3)</sup> , ta(500) <sup>(1)</sup> , tas <sup>(3)</sup> , ua(200) <sup>(3)</sup>	MI	
۰/۰۷	۱۸۳	۰/۰۷	۱۸۵	مدل ترکیبی ANN و ANFIS			
۰/۰۷	۱۸۳	۰/۰۷	۱۸۷	ANN			Can-ESM2
۰/۱۰	۰/۶۶	۰/۱۰	۱۷۲	ANFIS	Prc <sup>(3)</sup> , hus(850) <sup>(3)</sup> , tas <sup>(2)</sup> , ta(500) <sup>(2)</sup>	درخت تصمیم	
۰/۰۵	۱۹۱	۰/۰۵	۱۹۴	مدل ترکیبی ANN و ANFIS			

N<sup>1</sup>-RMSE نشان دهنده مقادیر RMSE نرمال شده


بر جو تاثیرگذار است برای دوره های آتی مشکل است، محققان به بررسی شرایط مختلف با استفاده از فرضیه های مختلف در مورد شرایط اقتصادی، اجتماعی، تکنولوژیکی و محیطی آینده، تحت عنوان سناریوهای پیش بینی پرداخته اند. سناریوهای RCP، شرایط اقلیمی دوره آتی را در چهار حالت اقلیمی مختلف توصیف می کند. از میان چهار سناریوی (RCP2.6, RCP4.5, RCP6, RCP8.5) دو سناریوی RCP4.5 و RCP8.5 در این مطالعه استفاده شده است.

پیش بینی بارش ایستگاه تبریز در دوره آتی (۲۰۲۰-۲۰۶۰) تحت سناریوهای RCP4.5 و RCP8.5 با استفاده از مدل ترکیبی

تبریز در دوره ۲۰۰۵-۱۹۵۱ نشان می دهد که مدل ترکیبی ریزمقیاس نمایی در مقایسه با مدل های منفرد ANN و ANFIS می تواند روند مناسب تری از داده های مشاهداتی را نشان دهد (شکل ۴ و ۵). دلیل چنین بهبودی این است که مدل ترکیبی، نقاط قوت هر مدل را شناسایی می کند و نقاط ضعف مدل های منفرد (ANN و ANFIS) را با تعیین وزن مناسب از طریق مرحله آموزش، کاهش می دهد.

### ۳-۳- نتایج گام سوم (پیش بینی بارش در دوره آتی)

از آن جایی که پیش بینی آلودگی ها و سایر عوامل انسانی که



شکل ۴. متوسط بارش ماهانه مشاهداتی و ریزمقیاس شده با مدل های ANN، ANFIS و مدل ترکیبی ANN با ANFIS، و موثرترین پیش‌بینی کننده ها بر اساس روش استخراج مشخصه (a) مدل BNU-ESM، (b) مدل Can-ESM2

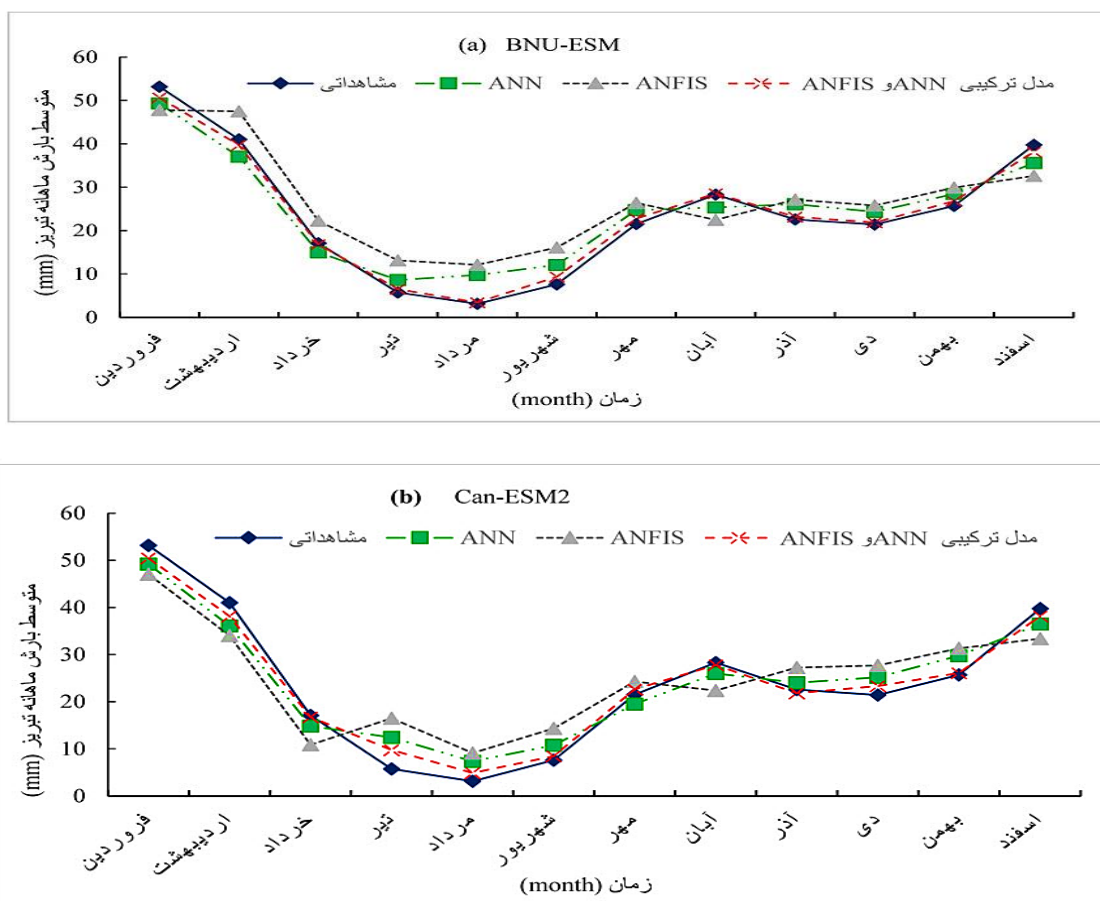
Fig. 4. Mean monthly observation and downscaled precipitation using ANN, ANFIS and ensemble model of ANN and ANFIS, and the most effective predictors based on MI feature extraction method a) BNU-ESM model, b) Can-ESM2 model

نتیجه این امر نیز مانع از تشکیل قطرات باران می گردد. اما با توجه به جهت وزش باد در تبریز که غالباً از شمال شرق می باشد [۴۳]، وزش باد شدید در فصل بهار باعث پراکنده شدن ذرات آلاینده می گردد. بنابراین این امر امکان تشکیل قطرات باران را فراهم می سازد. برای بررسی تغییرات بارش سالانه تبریز در دوره آتی، توزیع بارش دوره آتی (۲۰۲۰-۲۰۶۰) و بارش در دوره پایه (۱۹۵۱-۲۰۰۵) به صورت نمودار جعبه‌ای<sup>۱</sup> ترسیم گردیده و اختلاف آن محاسبه شده است. شکل ۷ توزیع بارش منطقه را بر اساس کمینه، چارک اول، میانگین، چارک سوم و بیشینه تغییرات برای بارش مشاهداتی و مدل سازی شده با مدل ترکیبی ANN و ANFIS بر اساس موثرترین پیش‌بینی کننده های تعیین شده با روش تصمیم در دوره پایه (۱۹۵۱-۲۰۰۵) و بارش پیش‌بینی شده در دوره آتی تحت دو سناریو (۲۰۲۰-۲۰۶۰) نشان می دهد. براساس شکل ۷ در هر دو مدل

کالیبره شده با موثرترین پیش‌بینی کننده های تعیین شده با روش درخت تصمیم (به علت نتایج مناسب) در گام دوم صورت گرفته است. برای ارزیابی نتایج پیش‌بینی، نتایج بارش پیش‌بینی شده برای دوره ۲۰۲۰-۲۰۶۰ تحت سناریوهای RCP4.5 و RCP8.5 در مقابل نتایج بارش مشاهداتی (۱۹۵۱-۲۰۰۵) در شکل ۶ نشان داده شده است. همان طوری که در شکل ۶ مشاهده می شود منطقه مورد مطالعه در دوره آتی (۲۰۲۰-۲۰۶۰) در برخی ماه ها شاهد افزایش بارندگی و در برخی دیگر شاهد کاهش بارندگی خواهد بود. در هر دو مدل GCM (Can-ESM2، BNU-ESM) و تحت هر دو سناریو (RCP4.5 و RCP8.5) بارش در فصل بهار افزایش خواهد یافت اما در فصل های پاییز و زمستان کاهش بارندگی مشاهده می شود. در فصل تابستان تغییرات بارش اندک و تقریباً ثابت خواهد بود. به نظر می رسد کاهش بارندگی در فصول سرد سال به علت افزایش آلودگی می باشد [۴۲]. انتشار ذرات آلاینده مانع از شکل گیری ذرات ریز بخار می شود در

1 Boxplot






شکل ۵. متوسط بارش ماهانه مشاهداتی و ریزمقیاس شده با مدل های ANN، ANFIS و مدل ترکیبی ANN با ANFIS، و موثرترین پیش بینی کننده ها بر اساس روش استخراج مشخصه درخت تصمیم به (a) مدل BNU-ESM، (b) مدل Can-ESM2

Fig. 5. Mean monthly observation and downscaled precipitation using ANN, ANFIS and ensemble model of ANN and ANFIS, and the most effective predictors based on decision tree feature extraction method a) BNU-ESM model, b) Can-ESM2 model

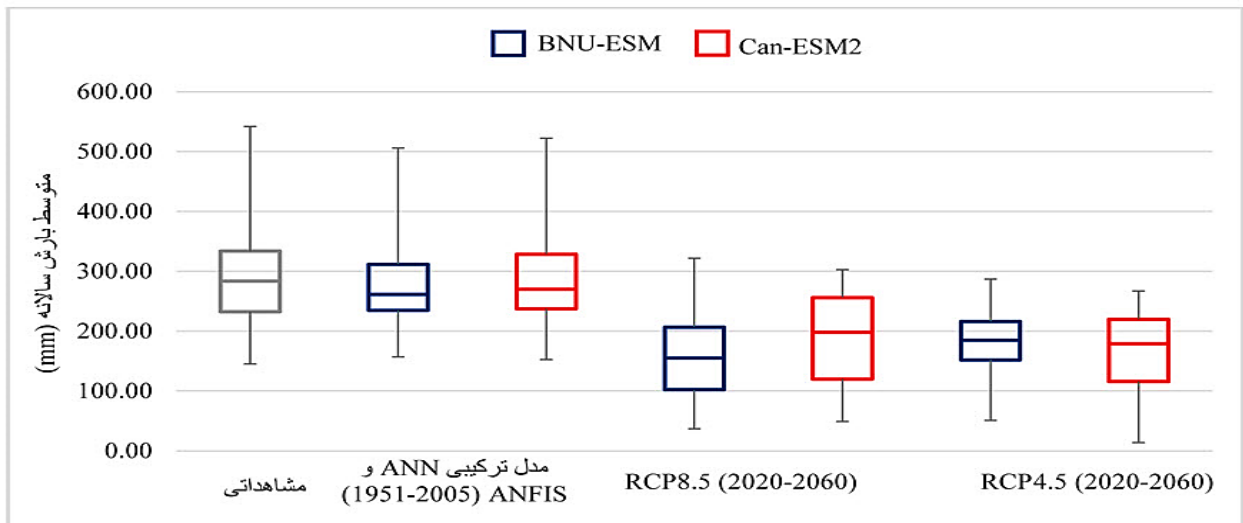
#### ۴- نتیجه گیری

با توجه به این که بارش از جمله متغیرهای کلیدی تاثیرگذار بر منابع آب می باشد، از این رو در این مطالعه برای بررسی تاثیر تغییر اقلیم بر بارش تبریز در دوره آتی (۲۰۲۰-۲۰۶۰) از مدل ترکیبی ANN و ANFIS برای ریزمقیاس نمایی داده های مدل های (GCM Can-ESM2 و BNU-ESM) استفاده شده است. برای دوره آتی داده های GCM تحت دو سناریو RCP4.5 و RCP8.5 مورد استفاده قرار گرفته است. به منظور افزایش دقت مدل ریزمقیاس نمایی، از روش های استخراج مشخصه درخت تصمیم و MI برای انتخاب موثرترین پیش بینی کننده استفاده شده است. از مزایای روش های استخراج مشخصه درخت تصمیم و MI، کاهش تعداد متغیرهای پیش بینی کننده و انتخاب موثرترین پیش بینی کننده بدون در نظر گرفتن موقعیت مکانی و صرفاً بر اساس رابطه چندخطی و غیرخطی بین پیش بینی کننده و

GCM متوسط بارش سالانه مدل سازی شده با مدل ترکیبی مبتنی بر روش استخراج مشخصه درخت تصمیم با متوسط بارش مشاهداتی تبریز مطابقت دارد. این امر حاکی از عملکرد مناسب مدل ترکیبی در ریزمقیاس نمایی بارش منطقه مورد مطالعه می باشد. مقایسه نتایج سناریوهای RCP4.5 و RCP8.5 نشان می دهد که هر دو سناریو عملکرد مشابهی در پیش بینی بارندگی منطقه در دوره آتی دارند. به طوریکه نتایج شبیه سازی نشان می دهد که بارش تبریز در دوره آتی و تحت سناریوهای RCP4.5 و RCP8.5 ۳۰٪-۴۰٪ کاهش می یابد. بر این اساس می توان گفت اگرچه بارش کاهش می یابد، اما احتمال وقوع وقایع حدی افزایش می یابد. این نتایج با گزارش های تهیه شده توسط IPCC در سال ۲۰۱۳ مطابقت دارد. بدین صورت که در بیشتر مناطق کاهش بارش احتمال وقوع وقایع حدی را افزایش می دهد.



شکل ۶. متوسط بارش ماهانه مشاهداتی و بارش پیش‌بینی‌شده برای دوره آتی (۲۰۲۰-۲۰۶۰) تحت سناریوهای RCP4.5 و RCP8.5  
 Fig. 6. Mean monthly observations and predicted precipitation for the future (2020-2060) under RCP4.5 and RCP8.5 scenarios



شکل ۷. نمودار جعبه ای متوسط بارش سالانه مشاهداتی، مدل‌سازی‌شده با مدل ترکیبی ANN و ANFIS و بارش سالانه پیش‌بینی‌شده تحت شکل ۷. نمودار جعبه ای متوسط بارش سالانه مشاهداتی، مدل‌سازی‌شده با مدل ترکیبی ANN و ANFIS و بارش سالانه پیش‌بینی‌شده تحت سناریوهای RCP8.5 و RCP4.5

Fig. 7. Box diagram of mean annual observation and modeled precipitation using ensemble model of ANN and ANFIS and predicted annual precipitation under RCP4.5 and RCP8.5 scenarios

- temperature parameters in two dry and superhero climates (Case study: Kerman and Bam). , Watershed Management Research, (2013) 117-131.
- [2] R. Le Roux, M. Katurji, P. Zawar-Reza, H. Quénol, A. Sturman, Comparison of statistical and dynamical downscaling results from the WRF model, *Environmental Modelling & Software*, 100 (2018) 67-73.
- [3] B. Timbal, Z. Li, E. Fernandez, The Bureau of meteorology statistical downscaling model graphical user interface: user manual and software documentation, Citeseer, 2008.
- [4] R.L. Wilby, C.W. Dawson, E.M. Barrow, SDSM—a decision support tool for the assessment of regional climate change impacts, *Environmental Modelling & Software*, 17(2) (2002) 145-157.
- [5] P. Almasi, S. Soltani, Assessment of the climate change impacts on flood frequency (case study: Bazoft Basin, Iran), *Stochastic Environmental Research and Risk Assessment*, 31(5) (2017) 1171-1182.
- [6] K. Goubanova, V. Echevin, B. Dewitte, F. Codron, K. Takahashi, P. Terray, M. Vrac, Statistical downscaling of sea-surface wind over the Peru–Chile upwelling region: diagnosing the impact of climate change from the IPSL-CM4 model, *Climate Dynamics*, 36(7-8) (2011) 1365-1378.
- [7] J. Liu, S. Chen, L. Li, J. Li, Statistical Downscaling and Projection of Future Air Temperature Changes in Yunnan Province, China, *Advances in Meteorology*, 2017 (2017).
- [8] A. Anandhi, V. Srinivas, D.N. Kumar, R.S. Nanjundiah, Role of predictors in downscaling surface temperature to river basin in India for IPCC SRES scenarios using support vector machine, *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 29(4) (2009) 583-603.
- [9] J.T. Schoof, S. Pryor, Downscaling temperature and precipitation: A comparison of regression-based methods and artificial neural networks, *International Journal of Climatology*, 21(7) (2001) 773-790.
- [10] M. Devak, C. Dhanya, A. Gosain, Dynamic coupling of support vector machine and K-nearest neighbour for downscaling daily rainfall, *Journal of Hydrology*, 525 (2015) 286-301.
- پیش بینی‌شونده می باشد. پس از انتخاب موثرترین پیش‌بینی‌کننده با روش درخت تصمیم و MI ریزمقیاس نمایی با مدل های هوش مصنوعی (مدل ANN، مدل ANFIS و مدل ترکیبی ANN با ANFIS) صورت گرفته‌است. نتایج ریزمقیاس نمایی نشان داد که بر اساس معیار DC (مرحله صحت‌سنجی) مدل ترکیبی مبتنی بر هوش مصنوعی ۶۵٪-۲۴٪ عملکرد بهتری نسبت به مدل های هوش مصنوعی منفرد در ریزمقیاس کردن بارش تبریز در دوره پایه (۲۰۰۵-۱۹۵۱) دارد. همچنین بررسی نتایج مدل‌سازی با مؤثرترین پارامترهای ورودی به‌دست آمده با دو روش استخراج مشخصه درخت تصمیم و MI نشان داد که روش درخت تصمیم در مقایسه با روش MI نتایج قابل‌مقایسه ای را ارائه می دهد. به‌خاطر دلایل ذکرشده یعنی مناسب بودن نتایج شبیه‌سازی بارش دوره پایه با مدل ترکیبی و مؤثرترین پارامتر ورودی تعیین‌شده با روش درخت تصمیم، پیش‌بینی بارش آینده تبریز تحت سناریوهای RCP4.5 و RCP8.5 برای هر دو مدل GCM فقط با مدل ترکیبی ANN و ANFIS و با ورودی های تعیین‌شده با روش مشخصه MI انجام گرفت. نتایج پیش‌بینی نشان داد که بارش تبریز در دوره آتی (۲۰۲۰-۲۰۶۰) تحت سناریوی RCP4.5 ۴۰٪-۳۰٪ و تحت سناریوی RCP8.5 ۳۹٪-۳۴٪ کاهش می یابد. نتایج این مطالعه با نتایج مطالعات [۴۴ و ۴۵] که اذعان نمودند بارش تبریز در دوره آتی کاهش می یابد مطابقت دارد.
- در نهایت این مطالعه نتایج مناسبی برای روش استخراج مشخصه برای انتخاب موثرترین ورودی، ریزمقیاس نمایی آماری و به‌طور خاص ترکیب روش های استخراج مشخصه با روش ریزمقیاس نمایی آماری مبتنی بر ترکیب مدل های هوش مصنوعی ارائه کرده‌است. روش ارائه‌شده می تواند در پیش‌بینی سایر پارامترهای اقلیمی (دما، میزان رطوبت و دیگر موارد) در مطالعات آتی مورد استفاده قرار گیرد. همچنین روش ریزمقیاس نمایی ارائه‌شده می تواند با روش های دیگر ریزمقیاس نمایی آماری و دینامیکی مورد مقایسه قرار گیرد. همچنین به‌علت توانایی های مختلف مدل های مبتنی بر هوش مصنوعی، پیشنهاد می گردد که از روش های مختلف هوش مصنوعی و ترکیب آن ها در ریزمقیاس نمایی استفاده گردد.

## مراجع

- [1] M. Rezaei, M. Nahtani, A. Abkar, M. Rezaei, M. Mirkazehi Rigi, The survey of the efficiency of SDSM for predicting

- under the climate change conditions based on automated statistical downscaling, *Stochastic Environmental Research and Risk Assessment*, 26(2) (2012) 157-176.
- [23] S. Beecham, M. Rashid, R.K. Chowdhury, Statistical downscaling of multi-site daily rainfall in a South Australian catchment using a Generalized Linear Model, *International journal of climatology*, 34(14) (2014) 3654-3670.
- [24] P.R. Tiwari, S. Kar, U. Mohanty, S. Kumari, P. Sinha, A. Nair, S. Dey, Skill of precipitation prediction with GCMs over north India during winter season, *International Journal of Climatology*, 34(12) (2014) 3440-3455.
- [25] R.L. Wilby, S. Charles, E. Zorita, B. Timbal, P. Whetton, L. Mearns, Guidelines for use of climate scenarios developed from statistical downscaling methods, Supporting material of the Intergovernmental Panel on Climate Change, available from the DDC of IPCC TGCIA, 27 (2004) -.
- [26] S.-T. Chen, P.-S. Yu, Y.-H. Tang, Statistical downscaling of daily precipitation using support vector machines and multivariate analysis, *Journal of hydrology*, 385(1-4) (2010) 13-22.
- [27] C.E. Shannon, A mathematical theory of communications I and II. , *Bell LABs Technical Journal*, 27 (1948) 379-423.
- [28] V.P. Singh, Hydrologic synthesis using entropy theory, *Journal of Hydrologic Engineering*, 16(5) (2011) 421-433.
- [29] H.H. Yang, S. Van Vuuren, S. Sharma, H. Hermansky, Relevance of time-frequency features for phonetic and speaker-channel classification, *Speech communication*, 31(1) (2000) 35-50.
- [30] Z. Gao, B. Gu, J. Lin, Monomodal image registration using mutual information based methods, *Image and Vision Computing*, 26(2) (2008) 164-173.
- [31] E. Frank, Y. Wang, S. Inglis, G. Holmes, I.H. Witten, Using model trees for classification, *Machine learning*, 32(1) (1998) 63-76.
- [32] J.R. Quinlan, Learning with continuous classes, in: 5th Australian joint conference on artificial intelligence, World Scientific, 1992, pp. 343-348.
- [33] M. Pal, S. Deswal, M5 model tree based modelling of reference evapotranspiration, *Hydrological Processes: An*
- [11] R. Chadwick, E. Coppola, F. Giorgi, An artificial neural network technique for downscaling GCM outputs to RCM spatial scale, *Nonlinear Processes in Geophysics*, 18(6) (2011).
- [12] H. Mahsifar, R. MAKNOUN, B. Saghafian, The impact of climate change on Urmia Lake water level, *Iran-Water Resources Research*, 7 (2011) 47-58.
- [13] G.P. Zhang, Time series forecasting using a hybrid ARIMA and neural network model, *Neurocomputing*, 50 (2003) 159-175.
- [14] A. Mishra, V. Desai, V. Singh, Drought forecasting using a hybrid stochastic and neural network model, *Journal of Hydrologic Engineering*, 12(6) (2007) 626-638.
- [15] V. Nourani, Ö. Kisi, M. Komasi, Two hybrid artificial intelligence approaches for modeling rainfall-runoff process, *Journal of Hydrology*, 402(1-2) (2011) 41-59.
- [16] M.R. Najafi, H. Moradkhani, S.A. Wherry, Statistical downscaling of precipitation using machine learning with optimal predictor selection, *Journal of Hydrologic Engineering*, 16(8) (2010) 650-664.
- [17] R. Haji Hosseini, J. Yazdi, S. Golian, Downscaling GCMs by Artificial Neural Network (ANN). , in: Iran's second national irrigation and drainage congress., 2016.
- [18] Z. Razzaghzadeh, V. Nourani, ANN based statistical downscaling of GCM model for prediction of hydroclimatic parameters (Case study: Tabriz City). , in: 16th Iranian Hydraulic Conference, 2017.
- [19] V. Nourani, A.H. Baghanam, J. Adamowski, O. Kisi, Applications of hybrid wavelet-Artificial Intelligence models in hydrology: A review, *Journal of Hydrology*, 514 (2014) 358-377.
- [20] V. Nourani, M.T. Sattari, A. Molajou, Threshold-based hybrid data mining method for long-term maximum precipitation forecasting, *Water Resources Management*, 31(9) (2017) 2645-2658.
- [21] Z. Alihosseini, nvestigation and Analysis of Wind Effects on Wind Climate Features Case Study: East Azarbaijan Province, M.Se thesis, Tabriz university, 2010.
- [22] J. Guo, H. Chen, C.-Y. Xu, S. Guo, J. Guo, Prediction of variability of precipitation in the Yangtze River Basin

- resources management, 23(14) (2009) 2877.
- [41] O. Kisi, Evapotranspiration modelling from climatic data using a neural computing technique, *Hydrological Processes: An International Journal*, 21(14) (2007) 1925-1934.
- [42] Z. Levin, W.R. Cotton, *Aerosol pollution impact on precipitation: a scientific review*, Springer Science & Business Media, 2008.
- [43] A. Gholampour, R. Nabizadeh, S. Naseri, M. Yunesian, H. Taghipour, N. Rastkari, S. Nazmara, S. Faridi, A.H. Mahvi, Exposure and health impacts of outdoor particulate matter in two urban and industrialized area of Tabriz, Iran, *Journal of Environmental Health Science and Engineering*, 12(1) (2014) 27.
- [44] H. Sanikhani, Y. Dinpajoh, S. Pour Yusef, S.Z. Ghavidel, B. Solati, The Impacts of Climate Change on Runoff in Watersheds (Case Study: Ajichay Watershed in East Azerbaijan Province, Iran), *Journal of Water and Soil*, 27(6) (2014) 1225-1234.
- [45] N. Toorini, M.R. Hesami kermani, Climate Change Prediction Using Nero Fuzzy (Case Study:Tehran and Tabriz Stations), *Sharif Journal of Civil Engineering*, 30(1) (2014) 139-147.
- International Journal, 23(10) (2009) 1437-1443.
- [34] H.R. Maier, G.C. Dandy, Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications, *Environmental modelling & software*, 15(1) (2000) 101-124.
- [35] S. Haykin, *Neural networks (Computer science)*, MacMillan College Publishing Co, New York, 1994.
- [36] J.-S. Jang, ANFIS: adaptive-network-based fuzzy inference system, *IEEE transactions on systems, man, and cybernetics*, 23(3) (1993) 665-685.
- [37] J.-S.R. Jang, C.-T. Sun, E. Mizutani, *Neuro-fuzzy and soft computing; a computational approach to learning and machine intelligence*, Prentice Hall, 1997.
- [38] E. Sharghi, V. Nourani, N. Behfar, Earthfill dam seepage analysis using ensemble artificial intelligence based modeling, *Journal of Hydroinformatics*, 20(5) (2018) 1071-1084.
- [39] D.R. Legates, G.J. McCabe Jr, Evaluating the use of “goodness of fit” measures in hydrologic and hydroclimatic model validation, *Water resources research*, 35(1) (1999) 233-241.
- [40] V. Nourani, M. Komasi, A. Mano, A multivariate ANN-wavelet approach for rainfall–runoff modeling, *Water*

چگونه به این مقاله ارجاع دهیم

Z. Razzaghzadeh, V. Nourani, N. Behfar, *The conjunction of the feature extraction method with AI-based ensemble statistical downscaling models*, *Amirkabir J. Civil Eng.*, 52(4) (2020) 841-858.

DOI: [10.22060/ceej.2018.14986.5806](https://doi.org/10.22060/ceej.2018.14986.5806)



