

EXTENDED ABSTRACT

Use of analytical data and intelligent models in runoff precipitation simulation (Case study: Bazoft basin)

B. Zaki¹, A.M. Akhoond-Ali^{2*}, M. Fathi-Moghadam³ and M.A. Maddah⁴

1- Graduated with a PhD, Department of Hydrology and Water Resources, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran.

2* - Corresponding Author, Professor, Department of Hydrology and Water Resources, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran. (aliakh@scu.ac.ir).

3- Professor, Department of Hydrology and Water Resources, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran.

4- Assistance Professor, Department of Hydrology and Water Resources, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran.

ARTICLE INFO

Article history:

Received: 5 January 2021

Revised: 1 February 2021

Accepted: 14 February 2021

Keywords:

Artificial Neural Network, ERA-Interim, Morghak station, precipitation time-series, wavelet transform.

TO CITE THIS ARTICLE:

Zaki, B., Akhoond-Ali, A. M., Fathi-Moghadam, M., Maddah, M. A. (2024). 'Use of analytical data and intelligent models in runoff precipitation simulation (Case study: Bazoft basin)', *Irrigation Sciences and Engineering*, 47(2), pp. 17-30. doi: 10.22055/jise.2021.36292.1947.

Abstract

Today, the use of intelligent models in simulating runoff has been widely used in water resources management. In this study, in order to predict the daily flow time series of the Morghak hydrometric station in Karun basin, an intelligent model of artificial neural network combined with wavelet analysis has been used. For this purpose, the ERA-INTRIM observational and analytical precipitation time series for 16 years (1378-1382) was decomposed by wavelet transform into frequency subsets, then each subset separately as input data to the artificial neural network model was introduced. The results showed that the analytical data have a high ability to simulate runoff precipitation models and can be a good alternative to observation data of rainfall stations. Also, according to the results of the wavelet transform technique, it can be effective in improving the performance of the simple ANN model for the Bazoft basin by 38% on a daily scale and 72% on a monthly scale.

Introduction

Estimation and forecasting of precipitation and its runoff have played effective and critical role in the watershed management and proper utilization of watershed, dams, and reservoirs and finally minimizing the damage caused by floods and drought. Therefore, this subject is the hydrologist's interest. Predicting any event forms the basis of crisis management, and when this goal can be achieved, the predicting model could be accessed. Several methods are used for predicting hydrological events such as precipitation. Using each of these methods is always with some error in results. Accurate prediction of hydrological signals such as precipitation can provide useful information to predict amount of precipitation for water resources and soil management in a basin. In addition, correct prediction of hydrological signals plays an important role in reducing the effects of drought on water resources systems. Hydrological systems are affected by many factors such as climate, land cover, soil infiltration rates, evapotranspiration which is dependent on stochastic components, multitemporal scales, and above-

mentioned nonlinear characteristics. Despite nonlinear relationships, uncertainty, and high lack of precision and variables temporal and spatial characteristics in water circulation system, none of the statistical and conceptual models which are proposed for accurate precipitation and runoff modeling were able to become a superior and capable model. Today, nonlinear networks are widely used as one intelligent system in predicting such a complex phenomenon. One of the methods that have been considered in recent years in the field of hydrology is the application of wavelet transform as new and effective method in signals and time series analysis. Monthly modeling and predicting of river flow D4 structure was used with application of wavelet neural network method and monthly flow data from two stations (Gerdelli Station on Canakdere River and Isakoy Station on Goksudere River) in the Eastern Black Sea, Turkey.

The neuro-wavelet model improved by two methods: combining discrete wavelet transform and multilayer perceptron (MLP) to predict monthly flow, compared with multilayer perceptron models of multilinear regression (MLR) and auto-correlated model (AR). Improvement in the performance of artificial neural networks (ANN) to predict seasonal time series was reviewed. So several structures of proposed artificial neural network are presented to predict seasonal time series. The model for four full time series was tested. The results of proposed neural network had been compared with the results of current statistical models and other structures of neural network. This comparison showed that the proposed model of neural network has less prediction error than other methods (Nourani et al., 2011). Approach improvement based on the precipitation-runoff modeling using a combination of artificial neural network-wavelet is performed, which shows the model that precipitation and discharge data entered as an input outperformed than the model just precipitation was entered as an input. Precipitation-runoff model using a combination of wavelet-neural network model is presented. According to the fitted coefficients (R^2), Root Mean Square Error (RMSE) concluded that the hybrid model of wavelet neural network is more efficient than the neural network and regression (Nourani and Komasi, 2013).

Materials and Methods

Bazoft basin is one of the sub-basins of big Karun with an area of 2973 square kilometers, which is located in the central part of the basin. This basin is completely mountainous and high, so that 2924 square kilometers are highlands. The minimum height in the basin is 861 meters and the maximum is 4091 meters above sea level in the northern parts. The average altitude in this area is 2115 meters above sea level. The Bazoft River is one of the most important tributaries of the Karun River, which originates from the foothills of the high Turks and Minar Mountains, 80 km southwest of Frieden. The length of this river is 160 km and its catchment area is located in high, snowy and mountainous areas and has a constant flow of water. The long-term average flow of this river at Marghk station is about 69.1 cubic meters per second. Figure (1) shows the location of the Bazoft basin. In this research, the Morghak station has been used to calibrate and validate the prediction models.




Fig. 1- Location of meteorological and hydrometric station of Morghak in the Bazoft basin

Table 1- Results of ANN model in daily and monthly time scales

Precipitation data	Network structure	Input variables	(R^2)	
			Training	Validation
ERA-Intrim	(2,9,1)	P(t), E(t)	0.782	0.762
Observations	(2,6,1)		0.780	0.784
ERA-Intrim	(4,9,1)		0.776	0.679
Observations	(4,6,1)	P(t), P(t-1), E(t), E(t-1)	0.795	0.789
ERA-Intrim	(6,11,1)		0.785	0.779
Observations	(6,11,1)	P(t), P(t-1), P(t-2), E(t), E(t-1), E(t-2)	0.803	0.793
ERA-Intrim	(8,14,1)	P(t), P(t-1), P(t-2), P(t-3), E(t), E(t-1), E(t-2), E(t-3)	0.794	0.779
Observations	(8,14,1)		0.786	0.790
ERA-Intrim	(10,14,1)	P(t), P(t-1), P(t-2), P(t-3), P(t-4), E(t), E(t-1), E(t-2), E(t-3), E(t-4)	0.789	0.780
Observations	(10,9,1)		0.794	0.788

Results and Discussion

In order to model the rainfall-runoff process of the basin, the Multi-Layer Perceptron (MLP) model with feed-in network structure was used. This type of neural network model with error propagation algorithm is widely used in modeling hydrological parameters (ASCE, 2000). In this study, five input models were used for the neural network model, the results of which are presented in Table (1). Each MLP model was trained with 3-20 hidden neurons in the hidden layer and the Lorentz-Marquadt training algorithm. It has been shown that when the number of hidden layer neurons exceeds the threshold, it does not have a significant effect on model performance (Abraham and see, 2000). In this modeling based on evaluation criteria, the model did not show good results on a daily time scale, which may be due to the presence of unstable signals in the data. Increasing the time steps to enter the ANN model did not significantly improve the performance of the model, but in general, due to the ease of access to ERA-Intrim data and good performance as well as observational data, its neural network structures were selected as the appropriate model. Also, three time steps were selected as the appropriate input for using the model. In the next step, by combining wavelet analysis and ANN model, the effect of mother wavelet type and analysis level on the performance of WANN model was investigated. In this study, the time series of data were analyzed with Haar mother wavelets (simple mother wavelet) and db-4 (complex mother wavelet) at different levels. Then, the obtained subsets at different levels were considered as the input of ANN model. According to the results, the db-4 mother wavelet performs better than the Haar mother wavelet. It should be noted that the level of decomposition of rainfall and runoff time series was considered the same. The scatter plot and time series of the observational data and the selected model are given in Figures (2) and (3). As shown in the simulated flow dispersion diagram using the hybrid model, this model had an estimated minimum of 18% in the simulated flow rate estimation at discharges above 400 cubic meters per second.




Fig. 2- Selected time series of neural wavelet model for Morghak hydrometric station

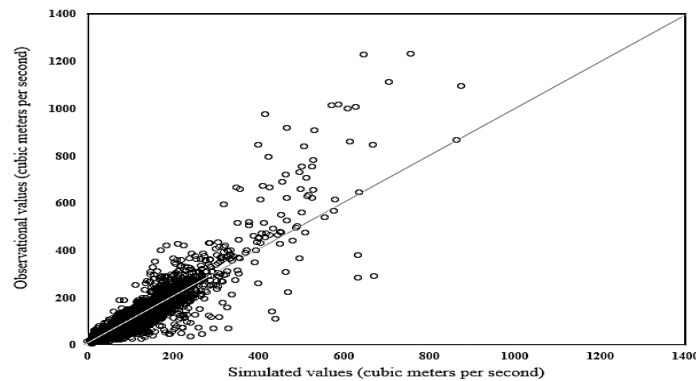


Fig. 3- Dispersion diagram of selected wavelet-neural model for Morghak hydrometric station

Acknowledge

This work was supported by the Research Council of the Shahid Chamran University of Ahvaz (Grant number: SCU.WH99.457). The authors also thank the Khuzestan Water and Power Authority (KWPA) for providing the data, used in this paper.

References

- 1- Abrahart, R.J. and See, L., 2000. Comparing neural network and autoregressive moving average techniques for the provision of continuous river flow forecasts in two contrasting catchments. *Hydrological processes*, 14(11-12), pp.2157-2172. DOI:10.1002/1099-1085(20000815/30)14:11/12<2157::AID-HYP57>3.0.CO;2-S
- 2- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000. Artificial neural networks in hydrology. II: Hydrologic applications. *Journal of Hydrologic Engineering*, 5(2), pp.124-137.
- 3- Nourani, V., Kisi, Ö. and Komasi, M., 2011. Two hybrid artificial intelligence approaches for modeling rainfall-runoff process. *Journal of Hydrology*, 402(1-2), pp.41-59. DOI: 10.1016/j.jhydrol.2011.03.002.
- 4- Nourani V., and Komasi M. 2013. A geomorphology-based ANFIS model for multi-station modeling of rainfall-runoff process. *Journal of Hydrology*, 490, pp. 41-55. DOI: 10.1016/j.jhydrol.2013.03.024.





استفاده از داده‌های باز تحلیلی و مدل‌های هوشمند در شبیه‌سازی رابطه بارش رواناب (مطالعه موردی: حوضه آبریز بازفت)

بهزاد زکی^۱، علی محمد آخوندعلی^{۲*}، منوچهر فتحی مقدم^۳ و محمدامین مداح^۴

- ۱- دانش آموخته دکتری، گروه هیدرولوژی و منابع آب، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران.
 ۲- استاد گروه هیدرولوژی و منابع آب، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران. aliakh@scu.ac.ir
 ۳- استاد گروه سازه‌های آبی، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران.
 ۴- استادیار گروه هیدرولوژی و منابع آب، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران.

پذیرش: ۱۳۹۹/۱۱/۲۶

بازنگری: ۱۳۹۹/۱۱/۲۳

دریافت: ۱۳۹۹/۱۰/۱۶

چکیده

امروزه استفاده از مدل‌های هوشمند در شبیه‌سازی فرایند بارش رواناب کاربرد زیادی به‌ویژه در مدیریت منابع آب پیدا کرده است. در این مطالعه به‌منظور پیش‌بینی سری زمانی جریان روزانه در ایستگاه هیدرومتری مرغک، واقع در حوضه کارون، از مدل هوشمند شبکه عصبی مصنوعی تلفیق شده با آنالیز موجک استفاده شده است. برای این منظور، سری زمانی بارش مشاهده‌ای و باز تحلیلی ERA-INTRIM به مدت ۱۶ سال (۱۳۸۲-۱۳۹۷) به‌وسیله‌ی تبدیل موجک به زیر سری‌های فرکانسی تجزیه شد، سپس این زیر سری‌ها هر کدام به‌طور جداگانه به‌عنوان داده‌های ورودی به مدل شبکه عصبی مصنوعی وارد گردید. نتایج به‌دست آمده حاکی از آن بود که داده‌های باز تحلیلی توانایی بالایی در شبیه‌سازی مدل‌های بارش رواناب دارند و می‌توانند جایگزین خوبی برای داده‌های مشاهده‌ای ایستگاه‌های بارش باشند. همچنین مطابق نتایج روش تبدیل موجک می‌تواند بر بهبود عملکرد مدل ANN ساده برای حوضه بازفت در مقیاس روزانه برابر ۳۸ درصد و در مقیاس ماهانه برابر ۷۲ درصد مؤثر باشد.

کلید واژه‌ها: تبدیل موجک، سری زمانی بارش، شبکه عصبی مصنوعی، ایستگاه مرغک، ERA-Intrim.

مقدمه

محدودیت پوشش مکانی است. امروزه، با ظهور فناوری‌های پیشرفته در فرآیند دریافت اطلاعات هواشناسی ماهواره‌ای، روش‌های متعددی در زمینه پردازش داده‌ها و برآورد مقادیر بارندگی مطرح شده است. استفاده از داده‌های باز تحلیلی شده به‌عنوان یک ابزار مؤثر، شکاف‌های اندازه‌گیری زمینی را کاهش داده و مشکلات موجود را تا حدودی برطرف می‌نماید. مزیت بررسی بارندگی با استفاده از داده‌های باز تحلیلی، شناخت بهتر پدیده بارش و پارامترهای مؤثر آن در یک گستره مکانی وسیع است، به‌همین دلیل طی دهه‌های اخیر محققان زیادی به تلاش و تحقیق در زمینه‌ی تخمین بارندگی با داده‌های باز تحلیلی پرداخته‌اند.

اولین داده‌های باز تحلیلی شده در سال ۱۹۷۹ تولید شد و در اختیار پژوهشگران این زمینه قرار گرفت. در ادامه با توجه به عملکرد این مدل، ایرادهای آن برطرف شد و خروجی‌های مدل پیوسته بهبود یافت. گرچه اصلاح پیوسته مدل‌ها باعث کاهش خطای داده‌های پیش‌بینی و خطای باز تحلیلی شده اما از طرفی باعث می‌شد که سری‌های زمانی داده‌های باز تحلیلی شده همگنی لازم را در طی زمان از دست بدهند و کارایی لازم برای بررسی تغییرات اقلیمی در سطح کره زمین را نداشته باشند (Raziei et al., 2011). Bengtsson و Shukla (1988) و Trenberth و Olson (1988) برای حل این موضوع پیشنهاد استفاده از یک

امروزه برآورد رواناب در حوضه‌ها به‌عنوان یک مسأله مهم در مدیریت منابع آب مطرح است و بخش جدا نشدنی مطالعه‌های طرح‌های آبی به‌شمار می‌آید (Nourani and Komasi, 2013). مدل‌های متعددی به‌منظور شبیه‌سازی این فرآیند پیچیده هیدرولوژیک توسعه پیدا کرده است. مدل‌های هوشمند هم‌چون شبکه عصبی مصنوعی Artificial Neural Network (ANN) توانایی نسبتاً خوبی در مدل‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیک غیر خطی نشان داده‌اند (Nourani et al., 2009). به‌عنوان مثال، Pourhaghi et al (2018) نشان دادند که شبکه‌های عصبی مصنوعی به خوبی می‌توانند رابطه بین بارندگی و رواناب را مدل‌سازی کنند. در مدل‌های هوش مصنوعی، مهمترین داده ورودی مدل‌های شبیه‌ساز بارش-رواناب، پارامتر بارش است. روش‌های سنتی مورد استفاده برای این پارامتر دارای مشکلاتی از جمله پرهزینه بودن، عدم استقرار ایستگاه اندازه‌گیری در مناطق صعب العبور، پراکنش نامناسب ایستگاه‌های هواشناسی است. رادارهای بارندگی برخی از این مسائل را تا حدودی برطرف می‌نماید اما آن‌ها هم دارای مشکلاتی از جمله پرهزینه بودن، داشتن خطاهای معنی‌دار، ناهمگنی جمع‌آوری داده به خاطر پراکندگی مکانی و خطای تبدیل بازتاب‌پذیری به نرخ بارندگی و

هم متصل شده اند. شبکه عصبی با استفاده از آمار گذشته و شبکه‌ای از گره‌ها یا نرون‌های ساده که به یکدیگر متصل بوده و هر یک عملیات ریاضی ساده‌ای انجام می‌دهند، می‌تواند سیستم‌های پیچیده را شبیه‌سازی کند. تبدیل‌های موجک برای تجزیه و جدا کردن روند از جزئیات داده‌ها به‌کار می‌روند. به‌وسیله این تبدیل‌ها سری‌های زمانی به موجک‌هایی تقسیم می‌شوند که هر یک نسخه‌های جابه‌جا شده و مقیاس شده از موجک مادر هستند. تبدیل موجک به دو صورت گسسته و پیوسته انجام می‌شود. تبدیل موجک پیوسته در تمام مقیاس‌ها می‌تواند عمل کند ولی در عین حال به مقدار زیادی داده و زمان محاسباتی نیاز دارد؛ بنابراین در بیشتر پژوهش‌ها از تبدیل موجک گسسته به دلیل سادگی و سرعت زیاد محاسبات (با توجه به دقت مورد نیاز) استفاده شده است.

در مدل ترکیبی شبکه عصبی-موجک (WANN) زیرسری‌هایی که توسط تبدیل‌های موجک تولید شده‌اند، به عنوان ورودی شبکه عصبی استفاده می‌شوند؛ به این صورت که هر زیرسری به طور جداگانه به همراه بارندگی به شبکه عصبی اعمال شده و شبکه آموزش داده شده و تست می‌شود. در نهایت خروجی شبکه یا همان هیدروگراف آینده در زمان $t+1$ ، با جمع جبری مقادیر متناظر پیش‌بینی شده تمام زیرسری‌ها به‌دست می‌آید. برای این منظور برنامه ای با نرم‌افزار R2019 MATLAB نوشته شد. شکل (۱) به‌صورت شماتیک این مدل را نشان می‌دهد.

منطقه مورد مطالعه

حوضه آبریز بازفت یکی از زیرحوضه‌های کارون بزرگ با وسعت ۲۹۷۳ کیلومتر مربع می‌باشد که در قسمت مرکزی حوضه واقع شده است. این حوضه کاملاً کوهستانی و مرتفع بوده به‌طوری که ۲۹۲۴ کیلومتر مربع آن را ارتفاعات تشکیل می‌دهد. حداقل ارتفاع در حوضه ۸۶۱ متر و حداکثر آن ۴۰۹۱ متر از سطح دریا مربوط به قسمت‌های شمالی آن می‌باشد. متوسط رقم ارتفاعی در این محدوده معادل ۲۱۱۵ متر از سطح دریا است. آمار ایستگاه‌های هیدرومتری و هواشناسی موجود در این حوضه در جداول (۱) و (۲) ارائه شده است. رودخانه بازفت از شاخه‌های مهم رودخانه کارون بوده که از دامنه‌های کوه‌های بلند تورک و منار واقع در ۸۰ کیلومتری جنوب غربی فریدن سرچشمه می‌گیرد. طول این رودخانه ۱۶۰ کیلومتر بوده و حوضه آبریز آن در مناطق مرتفع، برف‌گیر و کوهستانی واقع شده و دارای جریان آب دائمی می‌باشد. دبی متوسط دراز مدت این رودخانه در ایستگاه مرغک حدود ۶۹/۱ متر مکعب در ثانیه می‌باشد. در شکل (۲) موقعیت حوضه آبریز بازفت نشان داده شده است. در این تحقیق از ایستگاه مرغک به‌منظور واسنجی و صحت‌سنجی مدل‌های پیش‌بینی استفاده شده است.

مدل معین (بدون تغییر در طی زمان) ولی با داده‌های روزآمد را برای تولید داده‌های بازتحلیل شده عرضه دادند. این پیشنهاد سازنده سبب شد تا مراکز تولید داده‌های بازتحلیل شده مانند European Centre for Medium-Range Weather Forecasts (ECMWF) مدل معینی را برای تولید داده‌های بازتحلیل شده مورد استفاده قرار دهد و داده‌های بازتحلیل شده ۱۵ روزه را عرضه کند که از ۱۹۷۹ تا ۱۵ سال بعد را پوشش می‌داد. مرکز ECMWF بعدها داده‌های ERA-40 را عرضه کرد که نسبت به ERA-15 دقت مکانی و ارتفاعی به مراتب بیشتری داشت. با توجه به بازخورد داده‌های ERA-15 و ERA-40 این مرکز توانست ERA-Intrim را عرضه کند که نسل پیشرفته‌تری از دو نسخه پیشین است (Dee et al., 2011). تحقیقات خوبی در زمینه استفاده از داده‌های ECMWF انجام شده است (Belo-Pereira et al., Rubel and Rudolf, 2001؛ Schiemann et al., 2008؛ Ma et al., 2009؛ 2011؛ Peña-Arancibia et al., 2013؛ Wang et al., 2012؛ Rhodes et al., 2015؛ De Leeuw et al., 2015).

در ایران نیز کم و بیش تحقیقات خوبی در زمینه استفاده از داده‌های پیش‌تحلیل شده انجام شده است (Azizian and Ramezani, 2019؛ Sharghi et al, 2018 Bahroloum et al., 2020). Raziei و Sotoudeh (2017)، به بررسی داده‌های بارش مرکز اروپایی پیش‌بینی‌های میان‌مدت جوی European Centre for Medium-Range Weather Forecasts (ECMWF) پرداختند. این کار برای مناطق گوناگون اقلیمی ایران انجام شد. نتیجه این بررسی نشان داد که Interim-ERA دقت خوبی در پیش‌بینی بارش بسیاری از نقاط کشور دارد و میزان خطای آن در بیش از ۷۰ درصد از ایستگاه‌های مورد بررسی اندک و قابل چشم‌پوشی است. با توجه به محدودیت اطلاعات مورد نیاز روابط تجربی و دقت بالای مدل‌های هوشمند کاربرد مدل‌های عصبی مصنوعی قابل توصیه است. در این مطالعه برای دستیابی به نتایج مطلوب، واسنجی مدل در طول دوره آموزش استفاده گردید تا از بروز مشکلات بیش‌برازش جلوگیری کرده و عملکرد مدل را بهبود بخشد. با این حال، هنوز محدودیت‌هایی مانند زمان بهینه‌سازی مورد نیاز برای شبیه‌سازی را می‌توان در نظر گرفت. هدف از این مطالعه، مدل‌سازی بارش رواناب با استفاده از مدل‌های هوش مصنوعی حوضه آبریز بازفت است. در این مطالعه از داده‌های پیش‌تحلیل به‌عنوان ورودی مدل استفاده شده است و نتایج آن با داده‌های مشاهده‌ای ایستگاه‌های باران‌سنجی مورد مقایسه قرار گرفت.

مواد و روش‌ها

شبکه‌های عصبی مصنوعی (ANN)، الهام گرفته شده از فرآیند یادگیری مغز انسان است. یک شبکه عصبی شامل تعداد زیادی نرون مصنوعی است که بر طبق معماری خاص شبکه به

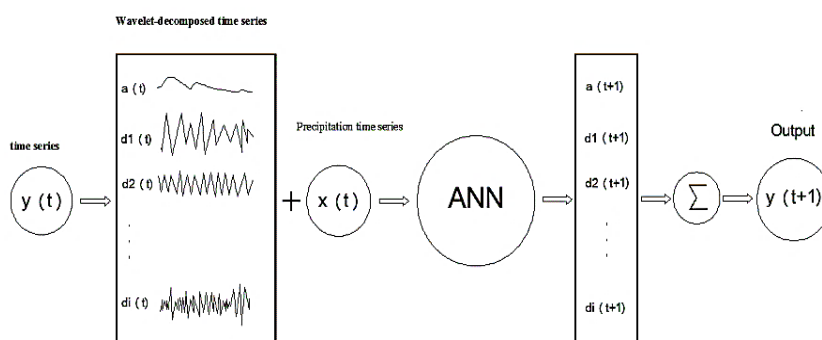


Fig. 1- Structure of proposed WANN model

شکل ۱- ساختار مدل پیشنهادی ترکیبی شبکه عصبی - موجک

جدول ۱- مشخصات ایستگاه‌های هواشناسی حوضه آبریز بازفت

Table 1- Details of meteorological stations of Bazoft catchment

Station	Type	Height (m)	Longitude (Degree)	Latitude (Degrees)	Latitude (Degrees)	Station Code
Goshehpol-Baran	Ordinary rain gauge	1712	49.94	32.36	1985	21435
Chaman Goli	Evaporation	1531	50.03	32.21	1996	21150
Chaman Goli	Ordinary rain gauge	1500	50.03	32.2	-	42140
Morghak	Evaporation	949	50.45	31.66	2000	21233

جدول ۲- مشخصات ایستگاه‌های هیدرومتری حوضه آبریز بازفت

Table 2- Specifications of Bazoft catchment hydrometric stations

Station	Type	Height (m)	Longitude (Degree)	Latitude (Degrees)	Latitude (Degrees)	Station Code
Goshehpol-Baran	Grade 4 water meter	1716	49.94	32.36	Ab Torke	21435
Tashnavu	Grade 4 water meter	1722	49.90	32.38	Tashnavi	21996
Shahid Khedri Bridge	Grade 1 water meter	1665	49.85	32.39	Bazoft	21060
Mavarz	Grade 1 water meter	1476	50.07	32.17	Bazoft	21476
Booeeneh Shengi	Grade 4 water meter	1675	49.85	32.41	Shengi	21481
Morghak	Grade 1 water meter	913	50.45	31.66	Bazoft	21233




Fig. 2- Overview and location of meteorological and hydrometric stations of Bazoft catchment (Almasi et al, 2017)

شکل ۲- نمای کلی و موقعیت ایستگاه‌های هواشناسی و هیدرومتری حوضه آبریز بازفت (Almasi et al, 2017)

میانگین حوضه آبریز را نشان دهد. داده‌های باز تحلیل شده علاوه بر حل این مشکلات، به آسانی در دسترس همگان است و برای تمام حوضه‌های آبریز قابل تهیه است. امروزه پایگاه‌های اطلاعات هواشناسی متعددی برای تهیه این اطلاعات وجود دارد. هر یک از پایگاه‌ها از الگوریتم خاصی برای تهیه این آمار استفاده می‌کنند که اهمیت بررسی صحت و عدم قطعیت آنها الزامی است. ERA-Interim آخرین به روزرسانی جو زمین است که توسط مرکز اروپایی پیش‌بینی میان‌برد هوا (ECMWF) ارائه شده است. (Raziei and Sotoudeh, 2017) این داده‌ها پارامترهای زیادی از جمله دما، بارش، تبخیر و تعرق، فشار بخار آب و تابش کل خورشیدی را شامل می‌شود. در این تحقیق، از پایگاه داده ERA-Interim برای تهیه داده‌های بارش و تبخیر استفاده گردید که نمودار آن‌ها در شکل (۴) آورده شده است. خلاصه آمار به‌کار برده شده در جدول (۳) آمده است.

جمع‌آوری اطلاعات و ابزار مورد نیاز

اطلاعات آب‌سنجی

به‌منظور شبیه‌سازی حوضه آبریز بازفت از داده‌های آب‌سنجی ایستگاه مرغک استفاده شد. ایستگاه هیدرومتری مرغک در خروجی حوضه آبریز بازفت قرار داد. داده‌های این ایستگاه به صورت روزانه از سال ۱۳۴۵ تاکنون توسط سازمان آب و برق خوزستان ثبت گردیده و در دسترس می‌باشد. سری زمانی روزانه داده‌های آب‌سنجی ایستگاه مرغک در شکل (۳) آمده است.

اطلاعات هواشناسی ERA-Interim

شبیه‌سازی مدل بارش- رواناب حوضه آبریز بازفت نیازمند داده‌های بارندگی است. این اطلاعات می‌تواند از ایستگاه‌های هواشناسی و سینوپتیکی وزارت نیرو و سازمان هواشناسی تهیه گردد. ایراد این اطلاعات علاوه بر صرف وقت و هزینه زیاد این است که این آمار نماینده یک نقطه روی زمین است و نمی‌تواند

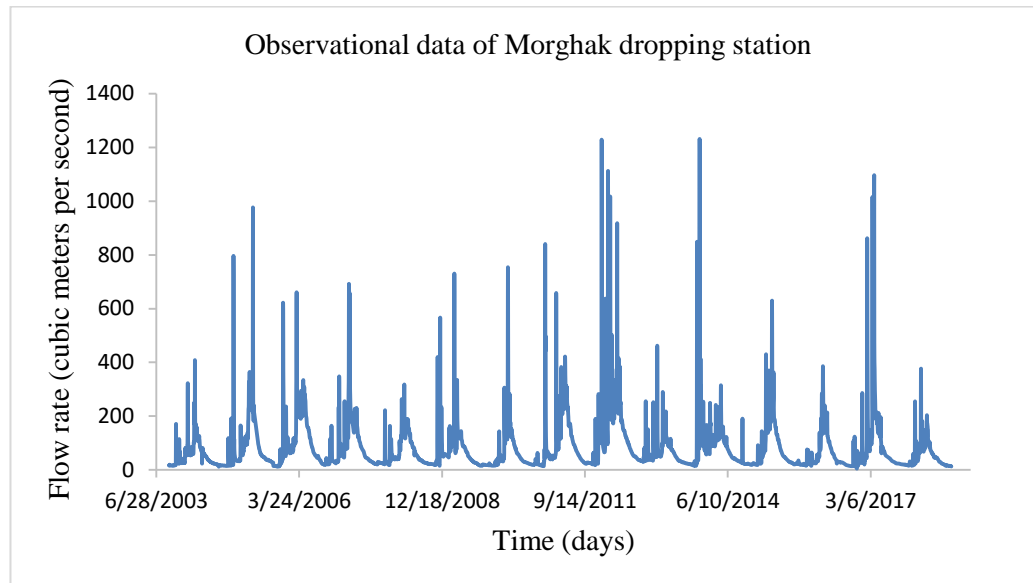


Fig. 3- Daily flow chart of Morghak hydrometric station

شکل ۳- نمودار آبدهی روزانه ایستگاه هیدرومتری مرغک




Fig. 4- Graph of average rainfall and daily evaporation of ERA-Intrim database for Bazoft catchment

شکل ۴- نمودار میانگین بارش و تبخیر روزانه پایگاه اطلاعات داده ERA-Intrim برای حوضه آبریز بازفت

جدول ۳- خلاصه آمار داده‌های آب‌سنجی و هواشناسی مورد استفاده در مطالعه حاضر

Table 3 - Summary of hydrometric and meteorological data used in the present study

Station name	Station type	Average(cms)	Maximum(cms)	Minimum(cms)	Coefficient of Variation
Morghak	Hydrometry	33.41	680	1.97	41.42
ERA-Intrim	Rainfall	1.34	57.55	0	5.31
Observations	Rainfall	2.28	136.79	0	8.14

معیارهای ارزیابی مدل

در این پژوهش، برای ارزیابی مدل‌های مورد نظر از نمایه‌های ضریب همبستگی، جذر میانگین مربعات خطا (RMSE) و ضریب نش - ساتکلیف (NS) استفاده شده است. در روابط زیر، Q_i مقدار مشاهده شده در گام i ام، \hat{Q}_i مقدار محاسبه شده در همان زمان، n تعداد داده‌ها و \bar{Q} میانگین مقادیر مشاهداتی می‌باشد (روابط ۱ و ۲). هرچه مقدار ضریب همبستگی بالاتر و RMSE کمتر باشد، نتایج دقیق‌تر و قابل اعتمادتر هستند و ضریب NS رابطه (۳) بیانگر دقت قابل قبول مدل خواهد بود.

$$R = \left(1 - \frac{\sum_{i=1}^n (Q_i - \hat{Q}_i)^2}{\sum_{i=1}^n (Q_i - \bar{Q})^2}\right)^{0.5} \quad (1)$$

$$RMSE = \left(\frac{\sum_{i=1}^n (Q_i - \hat{Q}_i)^2}{n}\right)^{0.5} \quad (2)$$

$$NS = \left(1 - \frac{\sum_{i=1}^n (Q_i - \hat{Q}_i)^2}{\sum_{i=1}^n (Q_i - \bar{Q})^2}\right) \quad (3)$$

نتایج و بحث

نتایج حاصل از مدل ANN و WANN

به منظور مدل‌سازی فرآیند بارش - رواناب حوضه از مدل پرسپترون چندلایه Multi-Layer Perceptron (MLP) با ساختار شبکه پیش‌خور استفاده شد. این نوع مدل شبکه عصبی همراه با الگوریتم پس انتشار خطا در مدل‌سازی پارامترهای هیدرولوژیک کاربرد وسیعی دارد (ASCE, 2000). در این مطالعه، پنج الگوی ورودی جدول (۴) برای مدل شبکه عصبی استفاده شد که نتایج آن در جدول (۵) آورده شده است. هر مدل MLP با ۲۰-۳ نرون مخفی در لایه پنهان و الگوریتم آموزش لورنبرگ-مارکوات آموزش دیده شد. ثابت شده است وقتی تعداد نرون‌های لایه مخفی از حد آستانه‌ای بالاتر برود، تأثیر چشم‌گیری روی عملکرد مدل ندارد (Abrahart and See, 2000). در این مدل‌سازی براساس معیارهای ارزیابی، مدل در مقیاس زمانی روزانه نتایج چندان خوبی از خود نشان نداد که این امر ممکن است به دلیل وجود سیگنال‌های نا ایستا در داده‌ها باشد. افزایش

گام‌های زمانی برای ورود به مدل ANN، عملکرد مدل را بهبود چشم‌گیری نداده است اما در کل با توجه به سهولت دسترسی داده‌های ERA-Intrim و عملکرد مناسب هم‌چون داده‌های مشاهده‌ای، ساختارهای شبکه عصبی آن به‌عنوان مدل مناسب انتخاب گردید. هم‌چنین سه گام زمانی به‌عنوان ورودی مناسب برای استفاده از مدل انتخاب شد (جدول ۵).

در مرحله بعد با ترکیب آنالیز موجک و مدل ANN، تأثیر نوع موجک مادر و سطح تجزیه بر عملکرد مدل WANN مورد بررسی قرار گرفت. مطالعه‌ها نشان می‌دهد موجک‌های مادر Haar، db-4 در مدل‌سازی بارش - رواناب عملکرد بهتری از خود نشان می‌دهند (Nourani, 2011). بنابراین در این مطالعه سری زمانی داده‌ها با موجک‌های مادر Haar (موجک مادر ساده) و db-4 (موجک مادر پیچیده) در سطوح مختلف تجزیه شد. در ادامه، زیرسری‌های به‌دست آمده در سطوح مختلف به‌عنوان ورودی مدل ANN در نظر گرفته شد. در آخر مدل آموزش دیده شده صحت‌سنجی شد که نتایج آن در جدول (۶) آورده شده است. مطابق نتایج، موجک مادر db-4 عملکرد بهتری نسبت به موجک مادر Haar از خود نشان می‌دهد. لازم به ذکر است سطح تجزیه سری‌های زمانی بارش و رواناب یکسان در نظر گرفته شد. نمودار پراکندگی و سری زمانی داده‌های مشاهداتی و مدل منتخب در شکل‌های (۵) و (۶) آورده شده است. همان‌گونه که در نمودار پراکندگی دبی شبیه‌سازی شده با استفاده از مدل هیبریدی نشان داده شده این مدل در برآورد میزان دبی شبیه‌سازی شده کم تخمینی به مقدار متوسط ۱۸ درصد در دبی‌های بالاتر از ۴۰۰ متر مکعب بر ثانیه داشته است. میزان متوسط سطح تجزیه مناسب با توجه به طول سری داده‌ها از رابطه (۴) محاسبه می‌شود (Wang and Ding, 2003):

$$L = \text{int}[\log N] \quad (4)$$

که در آن N تعداد داده‌های سری زمانی است. این رابطه بدون در نظر گرفتن تناوب داده‌ها، تنها طول سری داده‌ها را تأثیر داده است که این خود ممکن است باعث ایجاد خطا در پیدا کردن سطح تجزیه بهینه شود. برای رفع این مشکل سطوح مختلف نزدیک به این مقدار در نظر گرفته شد.

جدول ۴- الگوهای ورودی مورد استفاده در مقیاس زمانی روزانه و ماهانه

Table 4- Input structures to model in daily and monthly time series

Template number	Model input pattern	Output
Input pattern 1	P(t), E(t)	Q(t+1)
Input pattern 2	P(t), P(t-1), E(t), E(t-1)	Q(t+1)
Input pattern 3	P(t), P(t-1), P(t-2), E(t), E(t-1), E(t-2)	Q(t+1)
Input pattern 4	P(t), P(t-1), P(t-2), P(t-3), E(t), E(t-1), E(t-2), E(t-3)	Q(t+1)

جدول ۵- نتایج حاصل از مدل ANN در مقیاس روزانه و ماهانه

Table 5- Results of ANN model in daily and monthly time scales

Precipitation data	Network structure	Input variables	(R^2)	
			Training	Validation
ERA-Intrim	(2,9,1)	P(t), E(t)	0.782	0.762
Observations	(2,6,1)		0.780	0.784
ERA-Intrim	(4,9,1)		0.776	0.679
Observations	(4,6,1)	P(t), P(t-1), E(t), E(t-1)	0.795	0.789
ERA-Intrim	(6,11,1)		0.785	0.779
Observations	(6,11,1)	P(t), P(t-1), P(t-2), E(t), E(t-1), E(t-2)	0.803	0.793
ERA-Intrim	(8,14,1)	P(t), P(t-1), P(t-2), P(t-3), E(t), E(t-1), E(t-2),	0.794	0.779
Observations	(8,14,1)	E(t-3)	0.786	0.790
ERA-Intrim	(10,14,1)	P(t), P(t-1), P(t-2), P(t-3), P(t-4), E(t), E(t-	0.789	0.780
Observations	(10,9,1)	1), E(t-2), E(t-3), E(t-4)	0.794	0.788

جدول ۶- نتایج حاصل از مدل WANN برای الگو ورودی بهینه

Table 6- Results of WANN model for optimal input pattern

Mother wavelet	Decomposition Level $i=j$	Evaluation criteria			
		RMSE	MAE	R^2	NS
Db-4	2	0.031	0.3189	0.80	0.73
Db-4	3	0.028	0.2901	0.81	0.75
<u>Db-4</u>	<u>4</u>	<u>0.025</u>	<u>0.2789</u>	<u>0.83</u>	<u>0.76</u>
Db-4	5	0.025	0.2781	0.83	0.75
Haar	2	0.038	0.3856	0.79	0.71
Haar	3	0.035	0.3528	0.82	0.74
Haar	4	0.032	0.3598	0.82	0.73
Haar	5	0.032	0.3412	0.83	0.73




Fig. 5- Selected time series of neural wavelet model for Morghak hydrometric station

شکل ۵- سری زمانی مدل منتخب موجک-عصبی برای ایستگاه هیدرومتری مرغک




Fig. 6- Dispersion diagram of selected wavelet-neural model for Morghak hydrometric station

شکل ۶- نمودار پراکندگی مدل منتخب موجک-عصبی برای ایستگاه هیدرومتری مرغک

بازفت در مقیاس روزانه برابر ۳۸ درصد و در مقیاس ماهانه برابر ۷۲ درصد بوده است. همچنین تأثیر تبدیل موجک بر بهبود عملکرد مدل Db-4 برای حوضه مذکور در مقیاس روزانه برابر ۸۲ درصد بوده است. به‌طور کلی می‌توان نتیجه گرفت که عملکرد مدل هیبریدی پیشنهادی مطلوب بوده و با کیفیت مدل هیبریدی WANN که به‌عنوان مدلی مطلوب شناخته شده است، برابری می‌نماید.

سپاسگزاری

بدینوسیله از حمایت مالی معاونت پژوهش و فناوری دانشگاه شهید چمران اهواز در قالب پژوهانه (SCU.WH99.457) در انجام این پژوهش تشکر و قدردانی می‌گردد. نویسندگان همچنین از سازمان آب و برق خوزستان برای حمایت و ارائه داده‌های مورد استفاده در این مقاله تشکر می‌کنند.

نتیجه‌گیری

استفاده از مدل‌های بارش-رواناب هم‌چون مدل‌های هوشمند به‌عنوان ابزاری کارآمد در مدیریت حوضه‌های آبریز همواره مورد توجه بوده است. از جمله پارامترهای ورودی این مدل، بارش است. استفاده از داده‌های زمینی بارش دارای مشکلاتی هم‌چون هزینه‌بر بودن، پراکنش نامناسب ایستگاه‌های هواشناسی، نبود ایستگاه در مناطق صعب‌العبور است. استفاده از داده‌های باز تحلیلی ERA-Intrim می‌تواند یک راه حل مناسب برای حل این مشکلات باشد. برای این منظور، برآورد و پیش‌بینی آبنمود ایستگاه آب‌سنجی مرغک با استفاده از داده‌های ERA-Intrim مورد تحلیل قرار گرفت. نتایج تحقیق نشان داد که داده‌های ERA می‌تواند نماینده خوبی برای بارش حوضه آبریز مورد مطالعه باشد و در مدل‌سازی‌ها جایگزین داده‌های مشاهداتی گردد. تبدیل موجک بر بهبود عملکرد مدل ساده ANN برای حوضه

References

- 1- Abrahart, R.J. and See, L., 2000. Comparing neural network and autoregressive moving average techniques for the provision of continuous river flow forecasts in two contrasting catchments. *Hydrological processes*, 14(11-12), pp.2157-2172. DOI: 10.1002/1099-1085(20000815/30)14:11/12<2157::AID-HYP57>3.0.CO;2-S
- 2- Almasi, P. Soltani, S. Goodarzi, M. Modarres, R., 2017. Assessment the Impacts of Climate Change on Surface Runoff in Bazoft Watershed. *JWSS*.; 20 (78) pp:39-52. DOI: 10.18869/acadpub.jstnar.20.78.39.
- 3- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000. Artificial neural networks in hydrology. II: Hydrologic applications. *Journal of Hydrologic Engineering*, 5(2), pp.124-137.

- 4- Azizian, A., Ramezani, H., 2019. Assessing the Accuracy of European Center for Medium Range Weather Forecasts (ECMWF) Reanalysis Datasets for Estimation of Daily and Monthly Precipitation. *Iranian Journal of Soil and Water Research* 50 (4), 777-791. DOI: 10.22059/IJSWR.2018.261613.667962.
- 5- Bahroloum, R., Ramezani, H., Azizian, A. and Ababaei, B., 2020. Use of Gridded Weather Datasets in Simulation of Wheat Yield and Water Requirement (Case Study: Iran's Qazvin Plain). *Iranian journal of Ecohydrology* 7 (3), 691-706. DOI: 10.22059/IJE.2020.303567.1339.
- 6- Belo-Pereira, M., Dutra, E. and Viterbo, P., 2011. Evaluation of global precipitation data sets over the Iberian Peninsula. *Journal of Geophysical Research: Atmospheres*, 116(D20). DOI: 10.1029/2010JD015481.
- 7- Bengtsson, L. and Shukla, J., 1988. Integration of space and in situ observations to study global climate change. *Bulletin of the American Meteorological Society*, 69(10), pp.1130-1143. DOI: 10.1175/1520-0477(1988)069<1130:IOSAIS>2.0.CO;2.
- 8- Dee, D.P., Uppala, S.M., Simmons, A.J., Berrisford, P., Poli, P., Kobayashi, S., Andrae, U., Balmaseda, M.A., Balsamo, G., Bauer, D.P. and Bechtold, P., 2011. The ERA-Interim reanalysis: Configuration and performance of the data assimilation system. *Quarterly Journal of the royal meteorological society*, 137(656), pp.553-597. DOI: 10.1002/qj.828.
- 9- De Leeuw, J., Methven, J. and Blackburn, M., 2015. Evaluation of ERA-Interim reanalysis precipitation products using England and Wales observations. *Quarterly Journal of the Royal Meteorological Society*, 141(688), pp.798-806. DOI: 10.1002/qj.2395.
- 10- Ma, L., Zhang, T., Frauenfeld, O.W., Ye, B., Yang, D. and Qin, D., 2009. Evaluation of precipitation from the ERA-40, NCEP-1, and NCEP-2 Reanalyses and CMAP-1, CMAP-2, and GPCP-2 with ground-based measurements in China. *Journal of Geophysical Research: Atmospheres*, 114(D9). DOI: 10.1029/2008JD011178.
- 11- Nourani, V., Alami, M.T. and Aminfar, M.H., 2009. A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation. *Engineering Applications of Artificial Intelligence*, 22(3), pp.466-472. DOI: 10.1016/j.engappai.2008.09.003.
- 12- Nourani, V., Kisi, Ö. and Komasi, M., 2011. Two hybrid artificial intelligence approaches for modeling rainfall-runoff process. *Journal of Hydrology*, 402(1-2), pp.41-59. DOI: 10.1016/j.jhydrol.2011.03.002.
- 13- Nourani V., and Komasi M. 2013. A geomorphology-based ANFIS model for multi-station modeling of rainfall-runoff process. *Journal of Hydrology*, 490, pp. 41-55. DOI: 10.1016/j.jhydrol.2013.03.024.
- 14- Peña-Arancibia, J.L., van Dijk, A.I., Renzullo, L.J. and Mulligan, M., 2013. Evaluation of precipitation estimation accuracy in reanalyses, satellite products, and an ensemble method for regions in Australia and South and East Asia. *Journal of Hydrometeorology*, 14(4), pp.1323-1333. DOI: 10.1175/JHM-D-12-0132.1.
- 15- Pourhaghi, A., Solgi, A., Radmanesh, F., Shehni darabi, M. (2018). 'Hybrid Usage of The Wavelet transform and Intelligent to Simulation River Flow (Case Study: KaKa Reza and Sarab seyed Ali rivers)', *Irrigation and Water Engineering*, 8(4), pp. 1-17. (in Persian).
- 16- Raziei, T., Bordi, I. and Pereira, L.S., 2011. An application of GPCP and NCEP/NCAR datasets for drought variability analysis in Iran. *Water resources management*, 25(4), pp.1075-1086.
- 17- Raziei, T. and Sotoudeh, F., 2017. Investigation of the accuracy of the European Center for Medium Range Weather Forecast (ECMWF) in forecasting observed precipitation in different climates of Iran. *Journal of the earth and space physics*, 43(1), pp.133-147. (in Persian).

- 18-Rhodes, R.I., Shaffrey, L.C. and Gray, S.L., 2015. Can reanalyses represent extreme precipitation over England and Wales?. *Quarterly Journal of the Royal Meteorological Society*, 141(689), pp.1114-1120. DOI: 10.1002/qj.2418.
- 19-Rubel, F. and Rudolf, B., 2001. Global daily precipitation estimates proved over the European Alps. *Meteorologische Zeitschrift*, 10(5), pp.407-418.
- 20-Schiemann, R., Lüthi, D., Vidale, P.L. and Schär, C., 2008. The precipitation climate of Central Asia—intercomparison of observational and numerical data sources in a remote semiarid region. *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 28(3), pp.295-314. DOI: 10.1002/joc.1532
- 21-Sharghi E, Nourani V, Najafi H, Molajou A, 2018. Emotional ANN (EANN) and Wavelet-ANN (WANN) approaches for markovian and seasonal based modeling of rainfall-runoff process. *Water Resources Management* 32(10):3441-3456
- 22-Trenberth, E. and Olson, G., 1988. Evaluation of NMC global analyses: 1979-1987.
- 23-Wang W., and Ding S. 2003. Wavelet network model and its application to the predication of hydrology. *Nat. Sci*, 1(1):67–71.
- 24-Wang, A. and Zeng, X., 2012. Evaluation of multireanalysis products with in situ observations over the Tibetan Plateau. *Journal of geophysical research: atmospheres*, 117(D5) DOI: 10.1029/2011JD016553.