

برآورد رواناب با استفاده از استنتاج عصبی فازی و رگرسیون در حوضه آبریز دز

غزاله احمدیان احمدآباد^۱، محمود ذاکری نیری^{۲*} و صابر معظمی گودرزی^۳

۱- دانش آموخته کارشناسی ارشد گروه مهندسی عمران، واحد اسلامشهر، دانشگاه آزاد اسلامی، اسلامشهر، ایران

۲- گروه مهندسی عمران، واحد اسلامشهر، دانشگاه آزاد اسلامی، اسلامشهر، ایران Zakeriaiu@gmail.com

۳- گروه مهندسی عمران، واحد اسلامشهر، دانشگاه آزاد اسلامی، اسلامشهر، ایران

تاریخ پذیرش: ۹۸/۳/۳۱

تاریخ دریافت: ۹۸/۲/۲۶

چکیده

تخمین دبی جریان در حوضه آبریز، به دلیل تاثیر آن در مدیریت منابع آب، می تواند نقش اقتصادی مهمی داشته باشد. در این تحقیق، از مدل های (ANN)، (SVR) و (ANFIS) جهت پیش بینی رواناب حوضه آبریز دز استفاده شده است. همبستگی بین ایستگاه ها بررسی و ایستگاههای کمندان، زورآباد و دره تخت به دلیل همبستگی اندک با ایستگاههای اطراف، حذف شدند سپس به دلیل عدم بررسی دخالت انسانی، با استفاده از نرم افزار xistat روند ایستگاهها بررسی و ایستگاههای فاقد روند انتخاب شدند. جهت ارزیابی عملکرد مدل ها از ضریب همبستگی (R)، ضریب نش-ساتکلیف (NSE) و ریشه ی میانگین مربعات خطا (RMSE) استفاده شده است. نتایج این تحقیق حاکی از برتری ANFIS با رویکرد کلاسترینگ نسبت به رویکرد شبکه بندی است. مدل های (ANN)، (ANFIS) و (SVR) توانایی خوبی در شبیه سازی جریان حوضه آبریز دز داشته اند.

واژگان کلیدی: حوضه دز، شبکه عصبی مصنوعی، ماشین بردار پشتیبان، شبیه سازی، مدل بهینه.

مقدمه

ماهانه وساعتی نموده اند. هدف از این مطالعه، مقایسه ی عملکرد مدل های شبکه عصبی، سیستم های استنتاج عصبی فازی تطبیقی و رگرسیون بردار پشتیبان با یکدیگر می باشد.

مواد و روش ها

معرفی منطقه مورد مطالعه: رودخانه دز که سومین رودخانه بزرگ ایران است، یکی از منابع آب سطحی

پیش بینی رواناب ماهانه براساس سری های زمانی، از ابزارهای مدیریت سیلاب می باشد. لذا پیرامون شبیه سازی و بهینه سازی سیستم های مدیریت منابع آب، در (جدول ۱) جمع بندی کلی از این مطالعات ارائه شده است. بررسی سوابق مطالعاتی انجام شده نشان می دهد مطالعات فوق اقدام به پیش بینی به صورت

(chuan wang, 2009) نوع تابع فعال سازی برای لایه پنهان و خروجی را به ترتیب: تانژانت معکوس (tansig)، تابع خطی (purelin) و الگوریتم یادگیری لونیگ-مارکواردت (LM (Levenberg-Marquardt جهت آموزش شبکه، انتخاب شده است.

سیستم های استنتاج عصبی فازی تطبیقی

سیستم های استنتاج فازی که به سیستم های قاعده بنیاد فازی معروف می باشد، از عبارت های زبانی برای ارتباط بین ورودی ها و خروجی های مشاهده ای یک سیستم استفاده می نمایند (Ross, 1995) در این مطالعه تابع عضویت bell-shaped به تبعیت از تحقیق (Honey Badrzadeh, 2015) استفاده شده است و از دورویکرد شبکه بندی و کلاسترینگ جهت ایجاد FIS یه استفاده شده است.

رگرسیون بردار پشتیبان

مدل رگرسیون بردار پشتیبان (SVR) به عنوان یک مدل داده محور جدید است که در سال ۱۹۹۵ توسط vapanik & cortes معرفی شده است. شبکه های عصبی SVR برخلاف سایر شبکه های عصبی، ریسک عدم طبقه بندی صحیح را بعنوان تابع هدف در نظر می گیرد و مقدار بهینه ی آن را حساب میکند. تابع کرنل مورد استفاده در این تحقیق به تبعیت از تحقیق (zaher Mundheryaseen, 2016) RBF، می باشد.

توسعه ی مدل

داده های مورد استفاده، داده های دبی ماهانه حوضه آبریز دز می باشد. ابتدا همبستگی بین ایستگاهها بررسی و سپس ایستگاههای دارای بیشترین همبستگی انتخاب که شامل ۳۴ ایستگاه می باشد سپس سه

مهم در بخش شمالی استان خوزستان است. حوضه ۳۲ درجه ۳۶ دقیقه ۳۳ ثانیه عرض شمالی واقع شده است. مساحت کل حوضه بالغ بر ۲۱۷۲۰ کیلومتر مربع و متوسط ارتفاع حوضه حدود ۱۶۰۰ متر می باشد. محدوده مورد مطالعه در این تحقیق، حوضه آبریز دز در بالادست سد دز است که مساحت آن حدود ۱۷۳۶۵ کیلومتر مربع می باشد. در این تحقیق، به منظور پیش بینی دبی ماهانه و به دلیل عدم بررسی دخالت انسانی، داده های دبی ماهانه ی ۱۱۳ ایستگاه فاقد روند مورد بررسی قرار گرفته شده است. ایستگاههای فاقد روند شامل: دز فول، تله زنگ، تنگ پنج (بختاری)، کشور، گوکان، چرخ و فلک، کاکلستان، کمال صالح، حسن آباد، ونایی (سرآب سفید)، سازمان آب، تپه چغاومروئ کمی باشد.

روش تحقیق

اهمیت پیش بینی جریان در تصمیماتی است که مبنای این پیش بینی، به منظور مدیریت بهینه منابع آب صورت می گیرد. این تحقیق، پیش بینی در افق ماهانه می باشد. با توجه به اهمیت پیش بینی در مدیریت سیلاب، در این تحقیق ضمن اشاره اجمالی به منابع مختلف و سوابق مطالعاتی انجام شده، از چندین تکنیک هوش محاسباتی از قبیل: (ANN)، (SVR) و (ANFIS) جهت پیش بینی رواناب ماهانه حوضه آبریز دز و مقایسه ی دقت تکنیک های ذکر شده با هم می باشد.

شبکه های عصبی مصنوعی

شبکه های عصبی مصنوعی، تاریخ ۵۰ سال دارند. شبکه عصبی مصنوعی مورد استفاده، شبکه عصبی MLP بایک لایه نهان می باشد. به تبعیت از تحقیق (wen

را با استفاده از آزمون من کندال روند ایستگاهها بررسی و ایستگاههای فاقد روند انتخاب شدند که شامل ۱۱۳ ایستگاه می باشد. از کل داده ها بصورت انتخاب شد. در شکل ۳ نمودار پراکنندگی دبی شبیه سازی شده و مشاهداتی در دوره های آموزش و آزمون، رسم شده است. نتایج نشان می دهد الگوی برتر، ورودی با دو ماه تاخیر با توجه به مقدار R و NSE در مرحله ی تست می باشد. در شکل ۴ مقادیر جریان اندازه گیری شده و شبیه سازی شده نشان داده شده است.

نتایج سیستم های استنتاج عصبی فازی تطبیقی با رویکرد شبکه بندی

جدول ۴ نتایج حاصل از شبیه سازی می باشد. در شکل ۵ نمودار پراکنندگی دبی شبیه سازی شده و مشاهداتی در دوره های آموزش و آزمون، رسم شده است. در شکل ۶ مقادیر جریان اندازه گیری و شبیه سازی شده با مدل مذکور می باشد. نتایج نشان می دهد الگوی برتر، ورودی با سه ماه تاخیر با توجه به اولویت قرار دادن مقدار R و NSE در مرحله ی تست، انتخاب شد.

ایستگاه کمندان، زورآباد و دره تخت به دلیل همبستگی اندک با ایستگاههای اطراف حذف و به دلیل عدم بررسی دخالت انسانی، ۳۴ ایستگاه موجود تصادفی، ۷۰ درصد جهت کالیبراسیون و ۳۰ درصد باقی مانده جهت تست انتخاب شده اند. در این تحقیق، ترکیبات ورودی طبق جدول ۲ جهت پیش بینی رواناب ماه شهریور انتخاب شده است.

معیارهای ارزیابی عملکرد مدل

پس از ساخت مدل های پیش بینی رواناب و اجرای آن ها، نتایج با سه معیار ریشه میانگین مجذور خطا RMSE، ضریب نشت سائکلیف NSE و ضریب همبستگی R مورد سنجش و ارزیابی قرار گرفت.

بحث و نتایج

نتایج شبکه عصبی

جدول ۳ نتایج حاصل از شبیه سازی می باشد با توجه به مقادیر جدول ۳ ورودی دو ماه تاخیر، با ۲ نرون در ورودی، ۳ نرون در لایه پنهان (تابع $tansig$) و ۱ نرون در لایه خروجی، (تابع $Purelin$)، به عنوان الگوی برتر با توجه به در اولویت قرار دادن مقدار ضریب همبستگی و ضریب نش در مرحله ی تست

جدول ۱- برخی مطالعات مربوط به کاربرد مدل های داده مینا در پیش بینی رواناب رودخانه

Data-Driven Modeling Technique	Studies
-Badrzadeh.H(2015)	ANN-ANFIS
Wang,w.c.chau,kw,cheng,C.T and Qiu(2009)	ANN-ANFIS-GP-SVM-ARMA
-Nourani.v(2017)	EANN
-Talei(2012)	SWMM-KWA-ANN-ANFIS
-Yaseen Z.M(2016)	ELM-SVR-GRNN

جدول ۲- الگوهای ورودی اعمال شده به مدل ها

میزان تاخیر	الگوهای ورودی
یک ماه	$Q(t)=f[Q(t-1)]$
دو ماه	$Q(t)=f[Q(t-1),Q(t-2)]$
سه ماه	$Q(t)=f[Q(t-1),Q(t-2),Q(t-3)]$


$Q(t)$: خروجی یا مقادیر پیش بینی جریان ماه شهریور ،

$Q(t-1)$: اولین ورودی با یک ماه تاخیر ،


f : نشان دهنده ی نوع مدل

جدول ۳- خلاصه نتایج آماری شبیه سازی با شبکه عصبی

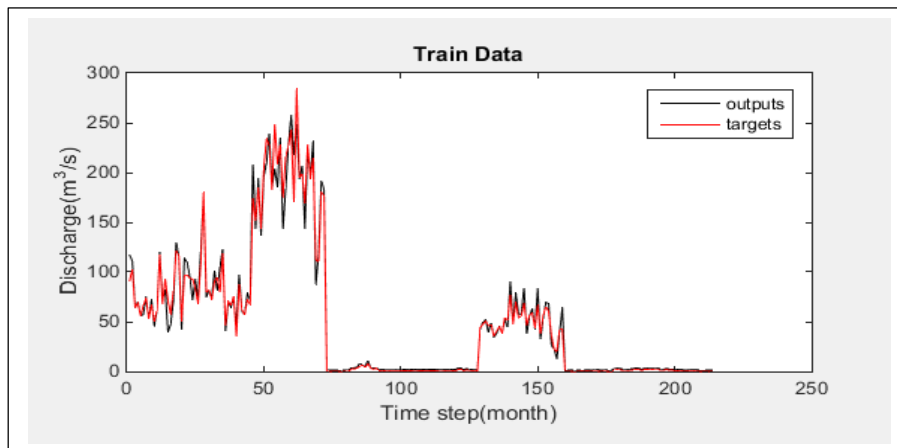
شبکه عصبی مصنوعی						
کالیبراسیون			تست			
میزان تاخیر	NSE	RMSE	R	NSE	RMSE	R
یک ماه	۰,۹۵	۱۴,۸۶	۰,۹۷	۰,۹۵	۱۴,۰۱	۰,۹۷
دو ماه	۰,۹۷	۹,۴۵	۰,۹۸	۰,۹۷	۱۱,۰۸	۰,۹۸
سه ماه	۰,۹۸	۸,۲۸	۰,۹۹	۰,۹۶	۱۳,۳۴	۰,۹۸



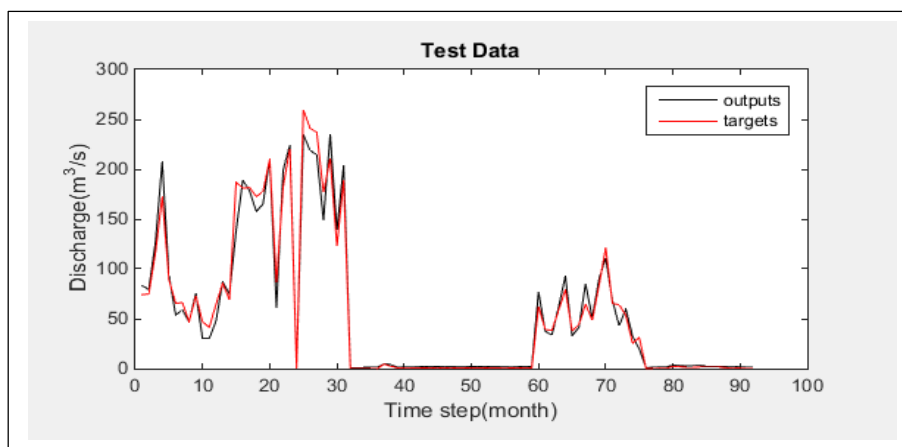
شکل ۱- نمودار پراکندگی دبی مشاهداتی و شبیه سازی شده با شبکه عصبی در دوره ی آموزش



شکل ۲- نمودار پراکندگی دبی مشاهداتی و شبیه سازی شده با شبکه عصبی در دوره ی آزمون




شکل ۳- مقادیر جریان اندازه گیری و شبیه سازی شده با شبکه عصبی در دوره ی آموزش




شکل ۴- مقادیر جریان اندازه گیری و شبیه سازی شده با شبکه عصبی در دوره ی آزمون

جدول ۴- خلاصه نتایج آماری شبیه سازی با سیستم های استنتاج عصبی فازی تطبیقی با رویکرد شبکه بندی


سیستم های استنتاج عصبی فازی تطبیقی با رویکرد شبکه بندی							
کالیبراسیون				تست			
میزان تاخیر	NSE	RMSE	R	NSE	RMSE	R	تعداد توابع عضویت
یک ماه	۰,۹۵	۱۴,۱۶	۰,۹۵	۰,۹۴	۱۶,۱۳	۰,۹۱	۲
دو ماه	۰,۹۷	۱۰,۳۸	۰,۹۷	۰,۹۷	۱۲,۰۶	۰,۸۹	۲
سه ماه	۰,۹۹	۵,۱۰	۰,۹۹	۰,۹۶	۱۳,۰۹	۰,۹۷	۲




شکل ۵- نمودار پراکنندگی دبی مشاهداتی و شبیه سازی شده با سیستم های استنتاج فازی در دوره ی آموزش



شکل ۶- نمودار پراکندگی دبی مشاهداتی و شبیه سازی شده با سیستم های استنتاج فازی در دوره ی آزمون



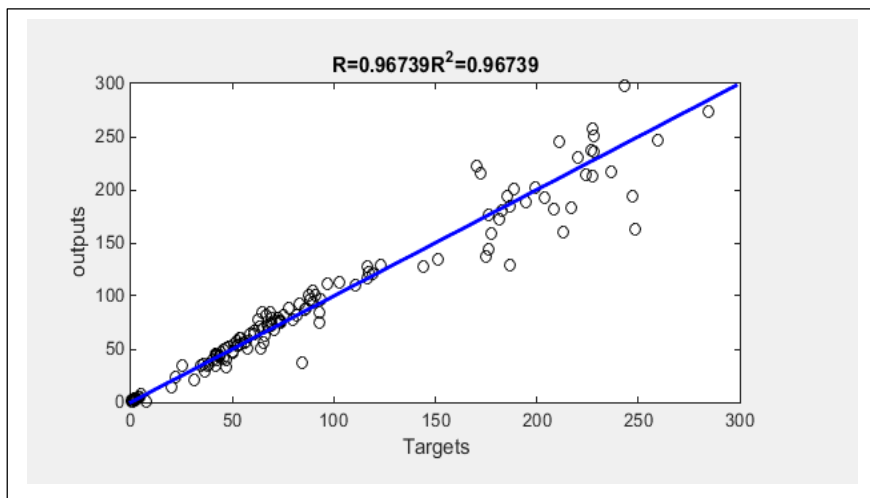
شکل ۷- مقادیر جریان اندازه گیری و شبیه سازی شده با سیستم های استنتاج فازی با رویکرد شبکه بندی در دوره ی آموزش




شکل ۸- مقادیر جریان اندازه گیری و شبیه سازی شده با سیستم های استنتاج فازی در رویکرد شبکه بندی در دوره ی آزمون

جدول ۵- خلاصه نتایج آماری سیستم های استنتاج عصبی فازی تطبیقی با رویکرد کلاسترینگ

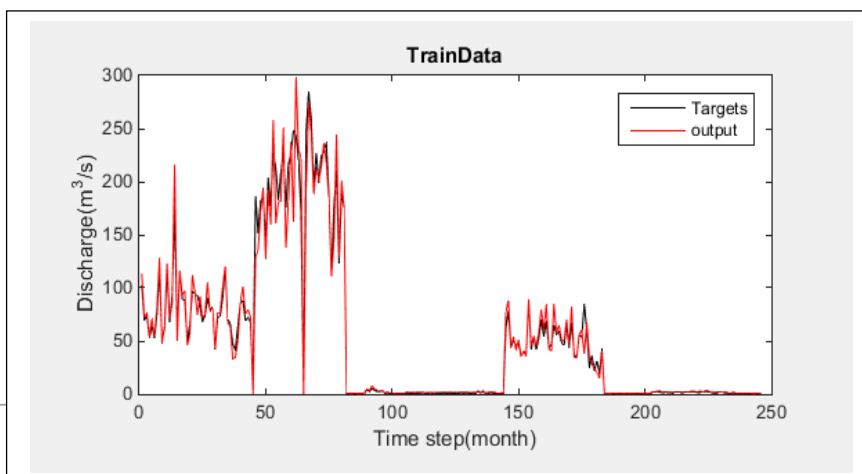
سیستم های استنتاج عصبی فازی تطبیقی با رویکرد کلاسترینگ							
کالیبراسیون				تست			
میزان تاخیر	NSE	RMSE	R	NSE	RMSE	R	تعداد کلاستر
یک ماه	۰,۹۴	۱۶,۰۶	۰,۹۴	۰,۹۳	۱۶,۲۴	۰,۹۳	۳
دو ماه	۰,۹۶	۱۲,۷۹	۰,۹۶	۰,۹۷	۱۰,۶۶	۰,۹۷	۴
سه ماه	۰,۹۷	۱۰,۹۲	۰,۹۷	۰,۹۶	۱۳,۶۲	۰,۹۰	۳




شکل ۹- نمودار پراکندگی دبی مشاهداتی و شبیه سازی شده با رویکرد کلاسترینگ در دوره ی آموزش



شکل ۱۰- نمودار پراکندگی دبی مشاهداتی و شبیه سازی شده با رویکرد کلاسترینگ در دوره ی آزمون




شکل ۱۱- مقادیر جریان اندازه گیری و شبیه سازی شده با رویکرد **subtractive clustering** در دوره ی آموزش




شکل ۱۱- مقادیر جریان اندازه گیری و شبیه سازی شده با رویکرد **subtractive clustering** در دوره ی آزمون

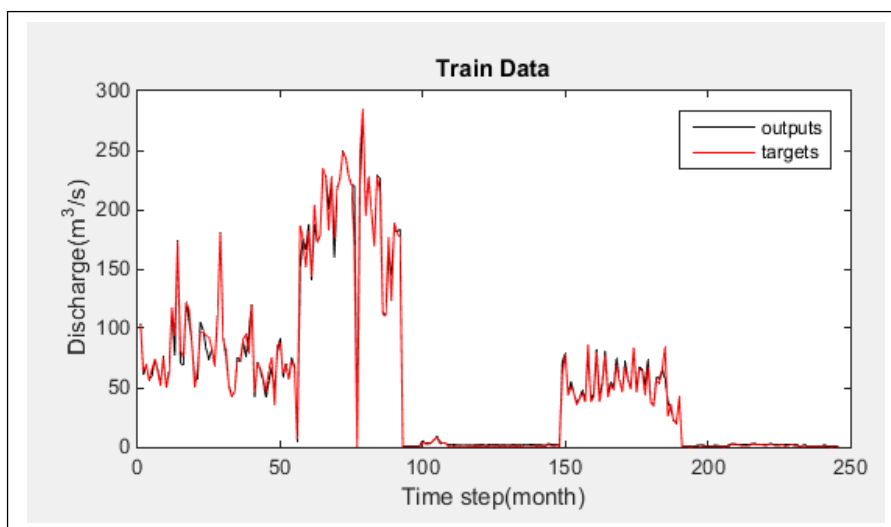
جدول ۶- خلاصه نتایج رگرسیون بردار پشتیبان

رگرسیون بردار پشتیبان							
کالیبراسیون				تست			
میزان تاخیر	NSE	RMSE	R	NSE	RMSE	R	متغیرهای مدل
یک ماه	۰,۹۵	۱۵,۲۰	۰,۹۷	۰,۹۵	۱۲,۱۶	۰,۹۸	C=6000 Epsilon=40 Sigma=50
دو ماه	۰,۹۹	۶,۴۶	۰,۹۹	۰,۹۶	۱۲,۷۰	۰,۹۸	C=6000 Epsilon=40 Sigma=50
سه ماه	۰,۹۹	۳,۰۱	۰,۹۹	۰,۹۱	۲۰,۹۸	۰,۹۵	C=6000 Epsilon=40 Sigma=50

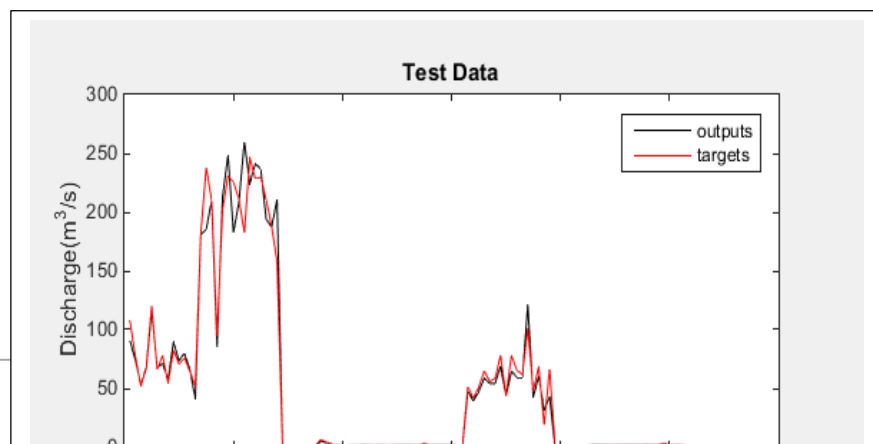




شکل ۱۳- نمودار پراکنندگی دبی مشاهداتی و شبیه سازی شده با رگرسیون بردار پشتیبان در دوره ی آزمون



شکل ۱۴- مقادیر جریان اندازه گیری و شبیه سازی شده با رگرسیون بردار پشتیبان در دوره ی آموزش



-Wang, W.C., Chau, K.W., Cheng, C.T. and Qiu, L., (2009). "A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series". Journal of hydrology, 374(3-4), pp.294-306.

-Nourani, V., (2017). An Emotional ANN (EANN) approach to modeling rainfall- runoff process. Journal of Hydrology, 544, pp.267-277.

-Talei, A. and Chua, L.H., (2012). "Influence of lag time on event-based rainfall-runoff modeling using the data driven approach". Journal of hydrology, 438, pp.223-233.

(2016)." Stream-flow forecasting using extreme learning machines: a case study in a semi-arid region in Iraq". Journal of Hydrology, 542, pp.603-614.

نتایج رگ سمن د دا، بشتسان

شکل ۱۵- مقادیر جریان اندازه گیری و شبیه سازی شد
نتایج نشان می دهد ورودی با دو ماه تاخیر بعنوان الگوی برتر، با توجه به در اولویت قرار دادن مقدار R و NSE انتخاب شده است. شکل ۹ نمودار پراکندگی دبی مشاهداتی و شبیه سازی شده می باشد. شکل ۱۰ مقادیر جریان اندازه گیری و شبیه سازی شده می باشد.

نتیجه گیری

هر سه مدل توانایی خوبی در شبیه سازی جریان داشته اند. نتایج تحقیق حاضر با تحقیقات انجام شده توسط ون جوان وانگ (۲۰۰۹) نیز مطابقت دارد.

منابع

-فاریابی، م.، چیت سازان، م.، (۱۳۹۵)، "بررسی بر همکش رودخانه و ایخوان با استفاده از پارامترهای فیزیکوشیمیایی، مطالعه موردی: بخش شمالی محدوده دز فول-اندیمشک"، فصلنامه علمی پژوهشی زمین شناسی محیط زیست، سال دهم، شماره ۳۴، ص ۱۰۱.

-پوستی زاده، ن.، (۱۳۹۰)، "مقایسه کاربرد شبکه عصبی مصنوعی با سیستم های استنتاج فازی در پیش بینی جریان رودخانه زاینده رود"، تحقیقات منابع آب ایران، سال هفتم، شماره ۲، ص ۹۳.

-Yaseen, Z.M., Jaafar, O., Deo, R.C., Kisi, O., Adamowski, J., Quilty, J. and El-Shafie, A.,

Assessment of Adaptive neural fuzzy inference systems and support vector regression in runoff estimation(A case study:Dez Basin)

Ghazaleh Ahmadian Ahmadabad¹, Mahmoud Zakeri Niri^{*2} & Saber Moazami Goudarzi³

1- M.s. Department of Civil Engineering, Islamshahr Branch, Islamic Azad University, Islamshahr, Iran
2-Department of Civil Engineering, Islamshahr Branch, Islamic Azad University, Islamshahr, Iran
3- Department of Civil Engineering, Islamshahr Branch, Islamic Azad University, Islamshahr, Iran

Abstract

Estimation of discharge flow in basin due to impact on water resource management can have an important economic role. In this research several computational intelligence techniques such as ANN, SVR and ANFIS have been used to predict the runoff of Dez basin. Correlation between stations was investigated and stations of Kamandan, Zoorabad and Daretakht were eliminated due to small correlation with around stations. Then due to lack of human intervention with using xlstat software were evaluated trend of stations and were selected stations without trend. In order to evaluate the performance of models were used correlation, RMSE and NSE. Results of this research showed that ANFIS with clustering approach gives better estimation than grid partitioning approach. ANN, ANFIS and SVR have a good ability to simulate the flow of Dez basin.

Keywords: Dez basin, Artificial Neural Network, Support Vector machine, simulation, optimal model.

