

تأثیر پیش پردازش متغیرهای ورودی به شبکه عصبی برای پیش بینی جریان ماهانه با آنالیز مؤلفه‌های اصلی و موجک

حسین ریاحی مدوار^۴

سعید مرید^۳

اشکان فرخ‌نیا^۲

روح اله نوری^۱

(دریافت ۸۶۷/۱۲ پذیرش ۸۷/۷/۲۶)

چکیده

برآورد جریان حوضه آبریز با توجه به کاربرد گسترده آن در علوم مرتبط با صنعت آب، از دیرباز مورد توجه پژوهشگران بوده است. ارائه الگوهای نو و به کارگیری تکنیک‌های پیشرفته می‌تواند موجب ایجاد تحول در برآورد این سیستم دینامیک و غیرخطی شود. در این تحقیق برای پیش‌بینی جریان ماهانه، از شبکه عصبی پیشخور استفاده گردیده است. به علت تعداد زیاد متغیرهای مورد استفاده در این تحقیق برای پیش‌بینی جریان، شناخت متغیرهای مؤثر بر شبکه می‌تواند باعث بهبود نتایج گردد. به این منظور، با استفاده از تکنیک آماری آنالیز مؤلفه‌های اصلی، که باعث کاهش تعداد متغیرها و ورود متغیرهای مؤثر به شبکه می‌شود، اقدام به مدل‌سازی جریان شد (PCA-ANN). در ابتدا از PCA برای کاهش متغیرهای ورودی استفاده شد و پس از تبدیل ۱۸ متغیر به ۱۸ مؤلفه جدید، از ۸ مؤلفه اول در بهترین مدل به عنوان ورودی به شبکه استفاده گردید. همچنین با استفاده از موجک، پیش‌پردازش روی متغیرهای اصلی صورت گرفت و مدلی نیز برای پیش‌بینی جریان با این روش ارائه شد (WNN). در نهایت، نتایج به دست آمده از این سه مدل، حاکی از نقش مؤثر پیش‌پردازش روی متغیرها توسط PCA و موجک بود. همچنین در مقایسه با مدل‌های ANN و WNN در مدل PCA-ANN، ساختار ساده‌تر، سرعت آموزش شبکه بیشتر و نتایج رضایت‌بخش‌تر بود.

واژه‌های کلیدی: شبکه عصبی مصنوعی، پیش‌بینی جریان ماهانه، آنالیز مؤلفه اصلی، تبدیل موجک، رودخانه صوفی‌چای.

Effect of Input Variables Preprocessing in Artificial Neural Network on Monthly Flow Prediction by PCA and Wavelet Transformation

Roohollah Noori¹

Ashkan Farokhnia²

Saied Morid³

Hossein Riahi Madvar⁴

(Received Oct. 3, 2007 Accepted Oct. 17, 2008)

Abstract

River flow forecast has of long been the focus of attention due to its wide applications in water-related sciences. Development of new models and advanced techniques will bring about drastic changes in the estimation of this dynamic and nonlinear system. In this research, feed-forward Artificial Neural Network (ANN) was used to predict monthly flow. Given the numerous flow forecast variables used in the present study, identification of variables effective in the network was necessary to help obtain improved results. For this purpose, we modeled the flow using the Principal Component Analysis (PCA) technique that reduces the number of input variables to include only the ones effective in ANN (PCA-ANN). PCA was first employed to reduce the number of input variables whereby 18 original variables were changed to 18 new components and the first 8 in the best model were then selected as network inputs. In addition, wavelet transformation was used for preprocessing input variables in the network to develop a model for flow forecasting (WNN). Comparison of the results obtained from the three models (ANN, PCA-ANN, and WNN) indicated the positive effect of preprocessing by wavelet

1. Ph.D student of Environmental Engineering, University of Tehran (Corresponding Author), (+98) 9179331208, roohollahnoori@gmail.com

2. MSc. Student of Water Resources, Faculty of Agriculture, Tarbiat Moddaress University

3. Associate Prof. of Water Resources, Faculty of Agriculture, Tarbiat Moddaress University

4. PhD student of Hydraulic Structures, Faculty of Agriculture, Tarbiat Moddaress University

۱- دانشجوی دکتری مهندسی محیط زیست، دانشگاه تهران، (نویسنده مسئول) roohollahnoori@gmail.com ۰۹۱۷۹۳۳۱۲۰۸

۲- دانشجوی کارشناسی ارشد مهندسی منابع آب، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران

۳- دانشیار گروه مهندسی منابع آب، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران

۴- دانشجوی دکتری سازه‌های آبی، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران

and PCA on input variables. Another finding of the study was that the proposed model (PCA-ANN) had a simpler network architecture, faster training speed, and more satisfactory predicting performance in comparison with ANN and WNN models.

Keywords: Artificial Neural Network, Predication of Monthly Flow, Principal Component Analysis, Wavelet Transformation, Sofichay River.

۱- مقدمه

پیش‌بینی جریان رودخانه‌ها یکی از عوامل مهم و مؤثر در مدیریت بهینه منابع آب است. در این خصوص استفاده از مدل‌های شبکه عصبی مصنوعی^۱ به‌طور گسترده‌ای طی سالهای اخیر مورد توجه واقع شده است [۱، ۲ و ۳]. مدل‌های ANNs در مورد فرایندهایی که تعریف دقیق و کاملی از فیزیک آنها وجود ندارد، بسیار مؤثر عمل می‌کنند. خصوصیت دیگر این مدل‌ها که آنها را نسبت به سایر روشها و الگوریتم‌ها متمایز می‌سازد، حساسیت کمتر آنها نسبت به وجود خطا در ورودی‌ها می‌باشد که علت این امر، پردازش توزیعی اطلاعات^۲ است [۴ و ۵]. این دو ویژگی سبب افزایش رویکرد به این مدل‌ها در فرایندهای هیدرولوژیکی از قبیل پیش‌بینی جریان رودخانه شده است [۶، ۷ و ۸].

یکی از مشکلات در طراحی شبکه‌های عصبی مواجه شدن با ساختارهای پیچیده است که منجر به شبکه‌ای با معماری سنگین می‌شود. در این رابطه کولیبالی^۳ و همکاران روش الگوریتم توقف آموزش^۴ را برای حل این مشکل ارائه دادند [۷]. در این روش اطلاعات مسئله به سه دسته آموزش، صحت‌یابی و تست تقسیم می‌شوند که از اطلاعات تخصیص داده شده به منظور صحت‌یابی، برای جلوگیری از مشکل فوق‌برازشی^۵ شبکه استفاده می‌شود. مرحله مهم دیگر در طراحی ANNs، تعیین ورودی‌ها به شبکه است [۹، ۱۰ و ۱۱]. بسته به نوع فرایند، ممکن است عوامل مؤثر متعددی را بتوان یافت که این امر نیز می‌تواند سبب ایجاد شبکه‌هایی با ورودی زیاد و معماری پیچیده گردد.

ازدیاد تعداد متغیرهای ورودی می‌تواند سبب پیچیدگی ساختار شبکه و ناپایداری آن گردد که یکی از دلایل آن افزایش تعداد وزن‌ها نسبت به تعداد ورودی‌هاست [۱۲]. از طرفی در مواردی متغیرها از همبستگی بالایی برخوردار هستند که استفاده از همگی آنها نوعی ورود اطلاعات تکراری را به‌همراه دارد [۱۳]. این موارد می‌تواند از یافتن مدل‌های بهینه جلوگیری کند [۱۴]. لذا توصیه می‌گردد که تا حد امکان تعداد ورودی‌ها کمتر باشد، حتی اگر باعث از دست رفتن پاره‌ای از اطلاعات موجود شود [۱۲]. روشهای

متفاوتی برای رفع مشکل ذکر شده پیشنهاد شده‌اند، مثلاً الگوریتم ژنتیک و دیگر روشهای بهینه‌سازی [۱۱ و ۱۵]. ولی در این روشها نیز برخی متغیرها به‌طور مستقیم حذف می‌گردد و اثر آنها در نظر گرفته نمی‌شود. روش تحلیل مؤلفه‌های اصلی^۶ نیز برای رفع مشکلات مذکور، پیشنهاد شده و در کنار ANN در مطالعاتی مورد استفاده قرار گرفته است [۱۳ و ۱۶]. هر چند که این روش در مطالعات منابع آب کمتر مورد توجه بوده است ولی در موضوعات مختلف زیست‌محیطی به‌طور گسترده‌ای مورد استفاده واقع شده است. مثلاً چوی^۷ و پارک^۸ در تحقیقی با استفاده از ترکیب شبکه عصبی و آنالیز مؤلفه اصلی، (PCA-ANNs)، اقدام به پیش‌بینی غلظت نیتروژن کلدال کل^۹ ورودی به تصفیه‌خانه فاضلاب کردند [۱۷]. به این منظور محاسبات با استفاده از دوازده متغیر کیفی آب و مدل‌های متفاوتی از همبستگی و ANNs انجام گرفت. طی محاسبات، ورودی‌ها هم مستقیم و هم به شکل مؤلفه‌های اصلی^{۱۰} مورد بررسی واقع گردید. نتایج به‌دست آمده حاکی از برتری مدل PCA-ANNs بود. همچنین در این مطالعه نقش مؤثر PCA در کم کردن معماری شبکه به اثبات رسید. از کارهای دیگر انجام گرفته می‌توان به تحقیق لو^{۱۱} و همکاران اشاره کرد [۱۸]. آنها با استفاده از ANNs از نوع توابع پایه شعاعی^{۱۲} و روش PCA به پیش‌بینی سه نوع آلاینده هوا در هنگ کنگ اقدام نمودند. برای پیش‌بینی غلظت این آلاینده‌ها، از شش متغیر آلاینده هوا و پنج متغیر هواشناسی به‌عنوان ورودی استفاده شد و پس از انجام PCA، شش مؤلفه اول که بیش از ۸۵ درصد مجموع اطلاعات متغیرهای اولیه را دربر داشتند، انتخاب و به‌عنوان ورودی به شبکه معرفی شدند. نتایج به‌دست آمده از این تحقیق مشخص کرد که استفاده از PCA-ANNs اگرچه نتایج ضعیف‌تری نسبت به استفاده از ANN داشت، ولی معماری ساده‌تر و سرعت آموزش سریع‌تر از مزایای آن بوده است.

از دیگر پیش‌پردازش‌هایی که در سری‌های زمانی فصلی مورد استفاده قرار گرفته است، می‌توان به تبدیل موجک^{۱۳} اشاره کرد.

⁶ Principal Component Analysis (PCA)

⁷ Choi

⁸ Park

⁹ Total Kjeldahl Nitrogen

¹⁰ Principal Componenets (PCs)

¹¹ Lu

¹² Radial Base Functons (RBF)

¹³ Wavelet Transform

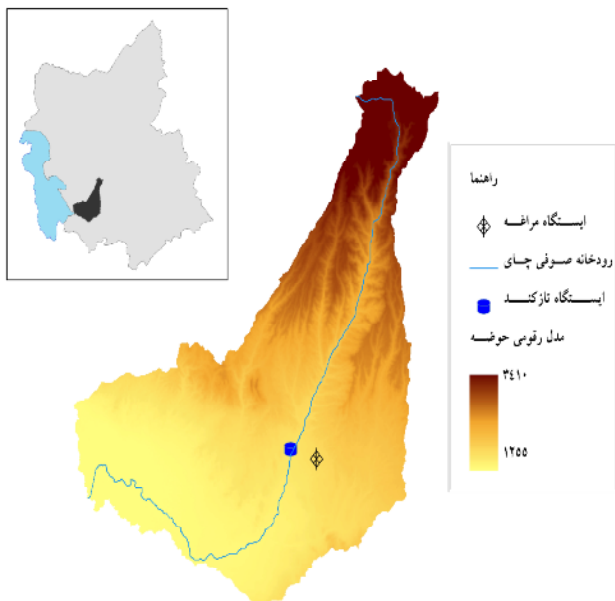
¹ Artificial Neural Networks (ANNs)

² Distributed Processing

³ Coulibaly

⁴ Stop Training Algorithm (STA)

⁵ Overfitting



شکل ۱- موقعیت منطقه مورد مطالعه و ایستگاههای مورد استفاده در این تحقیق

آن می توان اشاره کرد. ساختار ANNs که به آن، معماری اطلاق می گردد، به شکلی است که نرون ها در دسته هایی که لایه نام دارند، مرتب می شوند. معماری معمول ANNs متشکل از سه لایه است: لایه ورودی که داده ها را در شبکه توزیع می کند، لایه پنهان که داده ها را پردازش می کند و لایه خروجی که نتایج را به ازای ورودی های مشخص، استخراج می کند. یک شبکه می تواند چندین لایه پنهان داشته باشد. ولی تحقیقات تثبیت انجام گرفته در این زمینه نشان داده اند که یک لایه پنهان برای این گونه مدل ها می تواند هر تابع پیچیده و غیر خطی را تقریب زند [۲۲، ۲۳، ۲۴]. همچنین نتایج تجربی و عملی نیز این موضوع را تأیید می کنند [۲۴، ۲۵ و ۲۶]. بنابراین در این تحقیق از شبکه عصبی پرسپترون^۴ چند لایه با یک لایه پنهان برای پیش بینی جریان ماهانه استفاده گردید.

۲-۳- تبدیل موجک

طبق تعریف، موجک یک "موج کوچک" می باشد که انرژی آن در ناحیه کوچکی متمرکز شده و ابزار مناسبی برای بررسی پدیده های گذرا^۵ است. موجک نوسان حدقلی دارد که به سمت صفر نزول می کند و این نزول باید در جهات مثبت و منفی واقع در دامنه اش محدود شود. این مشخصه باعث می شود که موجک انعطاف پذیر بوده و مانند یک تابع رفتار کند. لذا با توجه به رفتارهای موجی نامنظم پدیده های هیدرولوژیک، قابلیت مدل سازی این پدیده ها

استفاده از تبدیل موجک برای تحلیل و پیش بینی سری های زمانی با استفاده از شبکه های عصبی مصنوعی و فازی-عصبی در حال گسترش است [۱۹]. از موارد استفاده تبدیل موجک به همراه شبکه عصبی مصنوعی می توان به تحقیقات انجام گرفته توسط لابات^۱ و همکاران برای مدل سازی بارش-رواناب در چشمه های کارستیک در فرانسه و مطالعات وانگ^۲ و دینگ^۳ برای مدل سازی سطح آب زیرزمینی اشاره کرد [۲۰ و ۲۱].

با توجه به مطالب ذکر شده، در این مقاله تلاش گردید تا نقش پیش پردازش داده های ورودی مدل شبکه عصبی با تکنیک PCA و موجک برای پیش بینی جریان یک ماهه آینده مورد ارزیابی قرار گیرد که در این خصوص جریان رودخانه صوفی چای به عنوان منطقه مطالعاتی در نظر گرفته شد.

۲- مواد و روشها

۲-۱- منطقه مطالعاتی

رودخانه صوفی چای از رودخانه های بزرگ حوضه آبریز دریایچه ارومیه می باشد که ورودی اصلی به سد علویان را تشکیل می دهد و متوسط آرد سالانه آن ۴/۶ متر مکعب در ثانیه است. این رودخانه از دامنه های جنوبی کوه های سهند سرچشمه گرفته و پس از عبور از قسمت غربی شهر مراغه و جنوب شهر بناب به دریایچه ارومیه می ریزد. اطلاعات بارندگی، تابش خورشیدی و دمای هوا به صورت مقادیر حداقل، حداکثر و میانگین در مقیاس ماهانه، به مدت ۱۸ سال یعنی از اواسط سال ۱۳۶۲ تا اواخر ۱۳۸۳ از ایستگاه سینوپتیک مراغه و متوسط ماهانه دبی رودخانه صوفی چای نیز در محل ایستگاه هیدرومتری تازکند در بالادست سد علویان تهیه گردید. با توجه به برف گیر بودن حوضه این رودخانه، استفاده از کلیه اطلاعات موجود مورد توجه قرار گرفت. لذا در این مطالعه، ۶ متغیر هر کدام با سه تأخیر زمانی که مجموعاً ۱۸ متغیر را تشکیل می دهند، به عنوان ورودی مدل ها مدنظر قرار گرفتند. شکل ۱ موقعیت این حوضه آبریز و ایستگاههای مربوطه را در استان آذربایجان شرقی نشان می دهد.

۲-۲- شبکه های عصبی مصنوعی

ANNs از انواع مدل های محاسباتی هستند که قادرند رابطه میان ورودی ها و خروجی های یک سیستم فیزیکی (هر چند پیچیده و غیر خطی) را توسط شبکه ای از گره ها که همگی به هم متصل هستند، تعیین نمایند. از مهم ترین عوامل تعریف ANNs به نحوه معماری


⁴ Perceptron

⁵ Non-Stationary

¹ Labat

² Wang

³ Ding



شکل ۲- تجزیه موج اولیه به امواج ثانویه تقریب و جزئیات

۲-۴- آنالیز مؤلفه‌های اصلی

PCA از روشهای آماری چندمتغیره است. در مواردی که با حجم زیادی از اطلاعات روبرو هستیم از این روش می‌توان به منظور کاهش پیچیدگی تحلیل متغیرها و همچنین تفسیر بهتر اطلاعات استفاده نمود [۲۹]. با اعمال این روش، متغیرهای اولیه به مؤلفه‌های جدید و مستقل از یکدیگر (با ضریب همبستگی صفر برای هر دو مؤلفه) تبدیل می‌شوند. مؤلفه‌های جدید ایجاد شده ترکیبی خطی از متغیرهای اولیه هستند [۱۸]. با استفاده از این تکنیک، ترکیباتی از P متغیر اولیه، $X_1, \dots, X_2, \dots, X_p$ ، برای ایجاد P مؤلفه مستقل (معادل با تعداد متغیرهای اولیه مورد استفاده)، $Z_1, \dots, Z_2, \dots, Z_p$ ، ایجاد می‌شود. عدم همبستگی بین این مؤلفه‌ها یک ویژگی مفید است زیرا عدم همبستگی به این معنی است که مؤلفه‌ها جنبه‌های متفاوتی از متغیرهای اولیه را نمایان می‌سازند [۳۰]. در این روش، متغیرهای اولیه به طور مستقیم مورد استفاده قرار نمی‌گیرند بلکه ابتدا به مؤلفه‌هایی تبدیل می‌شوند، سپس این مؤلفه‌ها به جای متغیرهای اولیه استفاده می‌شوند. همچنین چون در تشکیل مؤلفه‌ها از تمام متغیرها استفاده می‌گردد، در نتیجه اطلاعات متغیرهای اولیه

توسط امواج نامنظم (موجکها) نسبت به امواج منظم (امواج سینوسی و ...) بیشتر است. تبدیل موجک در دو شکل پیوسته و گسسته به کار می‌رود که در این تحقیق از روش تبدیل گسسته موجکی^۱ استفاده شد.

۲-۳-۱- تبدیل گسسته موجکی

مشکل بزرگ تبدیل پیوسته موجکی، زمان‌بر بودن آن و همچنین تولید مقادیر زیاد اطلاعات است، زیرا در این نوع تبدیل ضرایب موجکی در هر مقیاس ممکن محاسبه می‌گردند. برای حل این مشکل تبدیل موجک فقط برای زیر مجموعه‌ای از "مقیاسها و موقعیتها"^۲ انجام می‌شود. چنانچه مقیاس و موقعیت بر پایه توان دو انتخاب شوند (مقیاس و موقعیت دوگانه)، تحلیل سیگنال بسیار سریع‌تر و با دقت کافی انجام می‌شود. با اعمال تبدیل مذکور، داده‌های اولیه موجکی شده و به دو دسته تقسیم می‌شوند. دسته اول که تقریب^۳ نامیده می‌شود، دارای فرکانس کم بوده و نشان دهنده روند کلی داده‌های موجود است. این دسته در محاسبات نقش بسیار مهمی ایفا می‌کند.

دسته دوم جزئیات^۴ نام دارد که دارای فرکانس بالا و پریود کم است و بیانگر تغییرات محدود در داده‌ها می‌باشد. در شکل ۲ تجزیه داده‌ها به دسته‌های ذکر شده نشان داده شده است.

در اکثر مطالعات انجام شده در مورد منابع آب از موجکهای هار^۵، دایچی^۶ و سیملت^۷ استفاده گردیده است [۲۷ و ۲۸] که توابع آنها به ترتیب در شکل‌های ۳، ۴ و ۵ نشان داده شده است.

¹ Discrete Wavelet Transform (DWT)

² Scales and Positions


³ Approximations

⁴ Details


⁵ Haar

⁶ Daubechies


⁷ Symlet



شکل ۵- تابع سیملت



شکل ۴- تابع دایچی



شکل ۳- تابع هار

با کمترین تلفات توسط مؤلفه‌های حاصل ارائه می‌شود [۳۱]. هر مؤلفه اصلی می‌تواند با یک دنباله به صورت رابطه ۱ مشخص شود

$$Z_i = a_{i1}X_1 + a_{i2}X_2 + \dots + a_{ip}X_p \quad (1)$$

که در آن

Z_i مؤلفه مورد نظر، a_{ij} ضرایب مربوط به متغیرهای اولیه و X_i نیز متغیرهای اولیه است.

ضرایب مربوط به متغیرهای اولیه از حل رابطه ۲ به دست می‌آید [۳۲]

$$|R - \lambda I| = 0 \quad (2)$$

که در آن

I ماتریس واحد، R ماتریس همبستگی بین متغیرهای اولیه و λ نیز مقادیر ویژه می‌باشد.

از این مقادیر ویژه، بردارهای ویژه به دست می‌آیند. جزئیات بیشتر در مورد PCA در منابع دیگر ارائه شده است [۳۳-۳۶].

۲-۵- معیارهای ارزیابی

برای مقایسه نتایج خروجی، چهار معیار آماری متداول استفاده شد که عبارت‌اند از: ضریب تبیین (R^2)، میانگین خطای مطلق^۱، جذر میانگین مربعات خطا^۲ و میانگین قدرمطلق خطای نسبی^۳. بهترین عملکرد مدل بر اساس معیار R^2 ، مقدار یک و براساس سایر معیارها مقدار صفر را به همراه دارد. اما، این شاخصها مبین متوسطی از خطا در عملکرد مدل هستند و اطلاعاتی در مورد توزیع خطا در نتایج ارائه نمی‌کنند. به این منظور روش تحلیل آستانه خطا^۴ نیز مورد استفاده قرار گرفت [۲۵، ۲۶، ۳۷ و ۳۸]. شاخص TS_x برای مقدار x درصد از پیش‌بینی‌ها، نشان دهنده توزیع خطا در مقادیر پیش‌بینی شده برای هر مدل است. این شاخص که برحسب درصد تعریف می‌شود، برای مقادیر مختلف قدرمطلق خطای نسبی ارائه می‌شود. مقدار TS برای x درصد از پیش‌بینی‌ها طبق رابطه ۳ به دست می‌آید

$$TS_x = \frac{Y_x}{n} \cdot 100 \quad (3)$$

که در آن

n تعداد کل و Y_x تعداد دبی‌های پیش‌بینی شده (از کل تعداد n) برای هر مقدار مطلق خطای نسبی کمتر از x درصد است.

۳- نتایج و بحث

۳-۱- آنالیز مؤلفه‌های اصلی

مقدار KMO برابر $0/694$ (جهت اطلاعات بیشتر در مورد این آماره می‌توان به نوری و همکاران رجوع کرد [۳۶])، امکان اجرای PCA بر متغیرهای مورد استفاده را تأیید کرد. برای اجرای PCA پس از استاندارد کردن متغیرهای ورودی، ماتریس متقارن همبستگی R از مرتبه ۱۸ (معادل با تعداد متغیرهای ورودی) تشکیل شد. با حل رابطه ۲، ۱۸ مقدار ویژه و به ازای هر مقدار ویژه ۱۸ بردار ویژه حاصل شد که با استفاده از آنها، ۱۸ مؤلفه از متغیرهای اولیه، یعنی به تعداد متغیرهای ورودی، ایجاد گردید مشخصات این مؤلفه‌ها در جدول ۱ نشان داده است.

در جدول ۱ اطلاعات مربوط به ارزش هر مؤلفه و درصد پراکندگی از متغیرهای اولیه که توسط هر مؤلفه نشان داده می‌شود، ارائه شده است. همچنین در این جدول ملاحظه می‌گردد که ۸ مؤلفه اول نزدیک به ۹۹ درصد کل پراکندگی و اطلاعات متغیرهای اصلی را بیان می‌کنند. مقادیر بردارهای ویژه که ضرایب را به منظور تعیین مؤلفه‌ها تعیین می‌کنند، با استفاده از PCA در جدول ۲ نشان داده شده است. در این جدول مؤثرترین متغیرها در تشکیل هر مؤلفه به صورت برجسته آمده است. همان‌طور که مشاهده می‌گردد در تشکیل مؤلفه اول که به تنهایی بیش از ۵۸ درصد اطلاعات متغیرهای اولیه را شامل می‌شود، دماهای دو ماه قبل و تابش سه و دو ماه قبل بیشترین تأثیر را داشته‌اند، که این نتایج با توجه به برفگیر بودن حوضه مورد مطالعه قابل توجیه می‌باشد و تحلیل‌های PCA به خوبی آن را بیان کرده است.

جدول ۱- درصد اطلاعاتی از متغیرهای اولیه که توسط هر مؤلفه بیان می‌شود

مؤلفه	ارزش هر مؤلفه از ۱۸	درصد پراکندگی	درصد پراکندگی تجمعی
اول	۱۰/۴۶	۵۸/۱۳	۵۸/۱۳
دوم	۴/۰۵	۲۲/۵۰	۸۰/۶
سوم	۰/۹۶	۵/۳۳	۸۵/۹۷
چهارم	۰/۷۱	۳/۹۳	۸۹/۸۹
پنجم	۰/۵۷	۳/۱۴	۹۳/۰۳
ششم	۰/۴۶	۲/۵۸	۹۵/۶۲
هفتم	۰/۳۷	۲/۰۸	۹۷/۷۰
هشتم	۰/۱۵	۰/۸۲	۹۸/۵۱
نهم	۰/۱۰	۰/۵۶	۹۹/۰۸
دهم	۰/۰۶	۰/۳۶	۹۹/۴
یازدهم	۰/۰۳	۰/۱۹	۹۹/۶۳
دوازدهم	۰/۰۲	۰/۱۱	۹۹/۷۴
سیزدهم	۰/۰۱	۰/۰۸	۹۹/۸۲
چهاردهم	۰/۰۱	۰/۰۷	۹۹/۹۰
پانزدهم	۰/۰۱	۰/۰۶	۹۹/۹۶
شانزدهم	۰/۰۰۵	۰/۰۳	۹۹/۹۹
هفدهم	۰/۰۰۲	۰/۰۱	۹۹/۹۹۹
هجدهم	۰/۰۰۰۱	۰/۰۰۰۷	۱۰۰/۰۰۰

⁵ Kaiser-Meyer-Olkin

¹ Mean Absolute Error (MAE)

² Root Mean Square Error (RMSE)

³ Average Absolute Relative Error (AARE)

⁴ Threshold Statistics (TS)

جدول ۲- مقادیر بردارهای ویژه (ضرایب به منظور تعیین مؤلفه‌ها) به دست آمده از PCA

متغیر	PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8	PC9	PC10	PC11	PC12	PC13	PC14	PC15	PC16	PC17	PC18
R _{t-2}	۰/۲۵	۰/۶۸	-۰/۲۰	۰/۲۶	۰/۵۲	۰/۳۱	-۰/۰۲	۰/۳۱	۰/۰۳	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰
R _{t-1}	۰/۵۲	۰/۴۸	۰/۴۰	۰/۲۷	-۰/۰۲	-۰/۴۴	-۰/۰۱	-۰/۰۱	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰
R	۰/۶۱	۰/۱۰	۰/۵۸	-۰/۰۵	-۰/۰۷	۰/۴۸	۰/۱۹	۰/۰۱	-۰/۰۲	۰/۰۱	۰/۰۱	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰
Q _{t-2}	۰/۵۳	۰/۵۲	-۰/۴۲	۰/۲۶	-۰/۲۰	۰/۳۵	-۰/۱۴	۰/۰۶	۰/۱۵	۰/۰۱	۰/۰۱	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰
Q _{t-1}	۰/۲۴	۰/۸۱	-۰/۰۷	۰/۳۷	-۰/۳۰	-۰/۰۶	-۰/۰۲	۰/۰۶	-۰/۰۱	-۰/۲۲	-۰/۰۱	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰
Q	۰/۱۱	۰/۷۸	۰/۳۹	۰/۰۸	-۰/۲۴	-۰/۳۲	۰/۱۵	۰/۰۵	۰/۱۷	۰/۰۱	۰/۰۱	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰
Rad _{t-2}	۰/۹۴	-۰/۱۸	۰/۱۰	۰/۱۱	-۰/۰۳	۰/۰۴	-۰/۰۱	۰/۰۴	-۰/۲۰	-۰/۰۱	۰/۰۵	-۰/۰۲	-۰/۰۹	-۰/۰۱	۰/۰۴	-۰/۰۱	-۰/۰۱	-۰/۰۱
Rad _{t-1}	۰/۹۳	۰/۲۹	۰/۰۷	-۰/۰۹	۰/۰۱	۰/۰۳	۰/۰۱	-۰/۱۷	۰/۰۱	۰/۰۳	۰/۰۱	-۰/۰۲	-۰/۰۱	-۰/۰۵	-۰/۰۴	-۰/۰۲	۰/۰۰	۰/۰۰
Rad _t	۰/۶۷	۰/۶۷	۰/۰۳	-۰/۲۶	۰/۰۴	-۰/۰۵	-۰/۱۲	-۰/۰۵	۰/۰۰	۰/۰۳	۰/۰۳	۰/۰۰	۰/۰۰	۰/۰۳	۰/۰۲	-۰/۰۱	۰/۰۱	۰/۰۰
Tmin _{t-2}	۰/۷۹	-۰/۵۳	۰/۱۰	۰/۲۴	-۰/۰۴	۰/۰۴	۰/۰۵	-۰/۰۱	۰/۱۰	-۰/۰۱	۰/۰۷	-۰/۰۴	-۰/۰۵	۰/۰۰	-۰/۰۲	-۰/۰۱	-۰/۰۲	۰/۰۰
Tmin _{t-1}	۰/۹۷	-۰/۱۰	۰/۰۹	۰/۰۳	-۰/۰۱	۰/۰۶	۰/۰۱	-۰/۰۱	۰/۱۴	۰/۰۱	-۰/۰۹	-۰/۰۳	-۰/۰۲	-۰/۰۲	۰/۰۰	۰/۰۰	۰/۰۰	-۰/۰۱
Tmin _t	۰/۹۰	۰/۳۶	۰/۰۲	-۰/۱۷	۰/۰۷	-۰/۰۳	۰/۱۵	-۰/۰۲	۰/۰۳	۰/۰۳	-۰/۰۳	-۰/۰۴	-۰/۰۳	-۰/۰۴	۰/۰۳	۰/۰۲	۰/۰۲	۰/۰۰
Tmax _{t-2}	۰/۸۲	-۰/۵۰	۰/۱۳	۰/۲۳	-۰/۰۱	۰/۰۱	-۰/۰۳	۰/۰۳	-۰/۰۱	۰/۰۱	۰/۰۵	-۰/۰۲	-۰/۰۱	۰/۰۳	۰/۰۳	۰/۰۱	۰/۰۳	۰/۰۰
Tmax _{t-1}	۰/۹۹	-۰/۰۷	۰/۱۰	۰/۰۴	۰/۰۱	۰/۰۲	۰/۰۱	۰/۰۲	۰/۰۱	۰/۰۱	۰/۰۲	۰/۰۱	۰/۰۰	-۰/۰۲	-۰/۰۵	۰/۰۴	۰/۰۰	۰/۰۰
Tmax _t	۰/۸۹	۰/۳۹	۰/۰۳	-۰/۲۰	۰/۰۶	-۰/۰۳	۰/۰۱	-۰/۰۳	۰/۰۴	۰/۰۶	-۰/۰۳	-۰/۰۳	-۰/۰۳	۰/۰۱	-۰/۰۱	-۰/۰۲	۰/۰۰	۰/۰۰
Tmean _{t-2}	۰/۸۱	-۰/۵۰	۰/۱۲	۰/۲۳	-۰/۰۱	۰/۰۳	-۰/۰۱	۰/۰۳	۰/۰۱	۰/۰۱	۰/۰۹	۰/۰۴	۰/۰۸	-۰/۰۲	-۰/۰۶	۰/۰۰	۰/۰۰	۰/۰۰
Tmean _{t-1}	۰/۹۸	-۰/۰۶	۰/۱۰	۰/۰۵	۰/۰۱	۰/۰۱	۰/۰۱	۰/۰۳	۰/۰۰	-۰/۱۴	۰/۰۰	۰/۰۳	۰/۰۷	۰/۰۳	۰/۰۴	۰/۰۴	۰/۰۰	۰/۰۰
Tmean _t	۰/۸۸	۰/۴۰	۰/۰۲	-۰/۱۹	۰/۰۷	-۰/۰۲	۰/۰۳	۰/۰۵	-۰/۰۳	۰/۰۵	۰/۰۸	۰/۰۸	-۰/۰۳	-۰/۰۵	۰/۰۵	۰/۰۳	۰/۰۰	۰/۰۰

جدول ۳- نتایج آموزش و تست برای سه مدل

شاخص	مدل ANN		مدل WNN		مدل 8PCs-ANN	
	آموزش	صحت سنجی	آموزش	صحت سنجی	آموزش	صحت سنجی
R ²	۰/۹۲	۰/۸۱	۰/۹۹	۰/۸۸	۰/۹۶	۰/۸۹
MAE	۰/۸۹	۱/۰۵	۰/۲۲	۰/۸۷	۰/۶۶	۰/۸۹
RMSE	۱/۳۶	۱/۶۹	۰/۲۸	۱/۴۳	۰/۹۲	۱/۳۳
AARE (%)	۴۸/۷	۵۲/۵	۲۱/۸۶	۵۰/۵۱	۳۱	۳۶

۲-۳- طراحی شبکه عصبی منتخب

لازم است ابتدا هر کدام از متغیرها و مؤلفه‌ها قبل از ورود به شبکه عصبی، استاندارد شوند که در این تحقیق از رابطه ۴ استفاده شد [۳۹].


$$N = 0.8 \times \frac{(X_i - \text{MIN}_{X_i})}{(\text{MAX}_{X_i} - \text{MIN}_{X_i})} + 0.1 \quad (4)$$

که در آن

X_i متغیر یا مؤلفه MIN_{X_i} حداقل مقدار متغیر یا مؤلفه، MAX_{X_i} حداکثر مقدار متغیر یا مؤلفه مورد نظر و N نیز مقادیر استاندارد شده است. با استفاده از این رابطه محدوده هر متغیر بین ۰/۱ تا ۰/۹ قرار می‌گیرد.

با توجه به استفاده از روش STA، دوره آماری به سه بخش شامل سالهای ۱۳۶۲ تا ۱۳۶۵ برای صحت‌یابی، ۱۳۶۵ تا ۱۳۷۹ برای آموزش (در این مدت، طی چهار سال اندازه‌گیری‌ها انجام نشده که به دلیل مدت طولانی آن از بازسازی آماری پرهیز شده است) و ۱۳۸۰ تا ۱۳۸۳ برای تست مورد استفاده قرار گرفت.

بعد از استاندارد کردن ۱۸ متغیر اولیه و پس از تغییر معماری شبکه، مدل‌های متفاوتی از پیش‌بینی جریان ایجاد شد که نتایج آن در جدول ۳ و شکل‌های ۶ و ۷ آمده است. در این مرحله با توجه به معیارهای انتخاب مدل‌ها، معماری شامل ۱۰ نرون در لایه پنهان برگزیده شد.



شکل ۶- نتایج مرحله آموزش شبکه برای سه مدل ANN، WNN و 8PCs-ANN

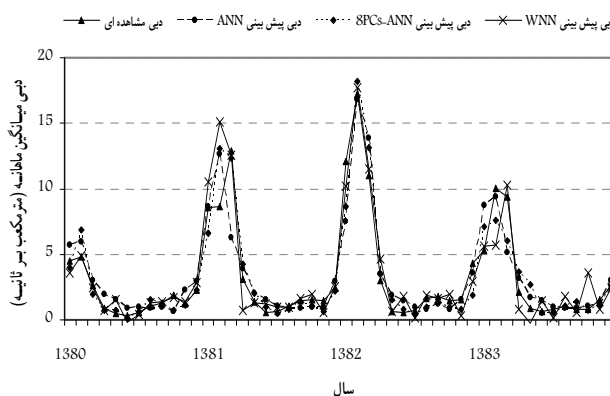
نهایتاً مدل ۳ و ۶ که به ترتیب شامل مولفه‌های ۱ تا ۵ (5PC-ANN) و ۱ تا ۸ (8PC-ANN) هستند، ضمن برخورداری از ساختار ساده، نتایج مطلوب‌تری را به همراه داشته‌اند. مانند مرحله قبل در این بخش نیز از روش STA استفاده گردید. شکل ۸ نیز مقایسه این دو مدل را نشان می‌دهد.

برای قضاوت بهتر و انتخاب یکی از این دو گزینه، هم‌چنین نمودار تحلیل آستانه خطا در مرحله تست محاسبه و در شکل ۹ ارائه شده است.

با توجه به شکل‌های ۸ و ۹ مشاهده می‌شود که مدل 8PCs-ANN، نتایج بهتری نسبت به مدل 5PCs-ANN داشته است. شکل ۸ گویای عملکرد بهتر مدل 8PCs-ANN به خصوص در دوره‌های پرآبی است، که معمولاً مشاهدات کمتری برای آن وجود دارد. هم‌چنین شکل ۹ قدرمطلق خطای نسبی برای مدل 8PCs-ANN را در بیشتر موارد کمتر از مدل 5PCs-ANN نشان می‌دهد.

۳-۵- ارزیابی مدل‌های ANN، WNN و 8PCs-ANN

به منظور ارزیابی سه ترکیب مدل فوق، نتایج مربوطه در جدول ۳ و شکل‌های ۶ و ۷ آمده است. همان‌طور که قابل مشاهده است، مدل‌های ANN و WNN، دارای نتایج بهتری نسبت به مدل 8PCs-ANN می‌باشند؛ به طوری که تمامی شاخصهای آماری مقادیر مطلوب‌تری را در این دو مدل دارا هستند. در بین این دو مدل نیز مدل 8PCs-ANN دارای شاخصهای R^2 ، RMSE و AARE بهتری نسبت به مدل WNN است، هر چند که شاخص MAE ضعیف‌تری از مدل WNN دارد. برای بررسی و مقایسه بهتر نتایج، نمودار توزیع خطای مدل‌ها با استفاده از روش تحلیل آستانه خطا



شکل ۷- نتایج مرحله تست شبکه برای سه مدل ANN، WNN و 8PCs-ANN

۳-۳- شبکه عصبی و موجک

برای این بخش مراحل کار به این شکل بود که ابتدا موجک مناسب^۱ انتخاب گردید. سپس با اعمال تبدیل روی داده‌ها، ضرایب تقریب و جزئیات آنها استخراج و داده‌ها موجکی شدند. در مرحله بعد مدل مناسب شبکه عصبی تعیین گردید و برای ارزیابی نهایی مجدداً داده‌ها غیرموجکی شدند. در این مرحله نیز با توجه به معیارهای ارزیابی، مدل با ۱۰ نرون در لایه پنهان به عنوان مدل بهینه پیش‌بینی جریان انتخاب شد. نتایج نهایی آموزش و تست WNN در جدول ۳ و شکل‌های ۶ و ۷ آمده است.

۳-۴- شبکه عصبی و آنالیز مؤلفه اصلی

برای این بخش نیز، بعد از استاندارد کردن مؤلفه‌ها (جدول ۲)، شبکه عصبی مناسب با تغییر تعداد مولفه‌های ورودی ارزیابی شد که نتایج در جدول ۴ بیان شده است. همان‌گونه که ملاحظه می‌گردد،

^۱ Symlet

جدول ۴- نتایج مرحله آموزش و تست شبکه عصبی برای تعداد مؤلفه‌های مختلف

مدل	تعداد نرون	تعداد مؤلفه	مرحله آموزش شبکه				مرحله صحت‌یابی شبکه			
			AARE(%)	RMSE	MAE	R^2	AARE(%)	RMSE	MAE	R^2
۱	۱۰	۳	۵۱/۷۸	۲/۱۳	۱/۳۵	۰/۸۱	۴۲/۰۸	۱/۷۴	۱/۰۵	۰/۸۲
۲	۹	۴	۴۹/۳	۱/۸۸	۱/۲۳	۰/۸۶	۴۶/۰۱	۱/۸۱	۱/۰۵	۰/۸۳
۳	۱۰	۵	۴۶/۳۴	۱/۷۱	۱/۱۱	۰/۸۹	۴۱/۸۵	۱/۴۸	۰/۹۴	۰/۹۱
۴	۸	۶	۴۴/۳۲	۱/۳۹	۰/۹۲	۰/۹۲	۳۶/۵	۱/۵۲	۰/۹۴	۰/۸۶
۵	۸	۷	۵۳/۳۳	۱/۶۱	۱/۱۴	۰/۸۹	۴۲/۳۹	۱/۴۶	۰/۹۳	۰/۸۷
۶	۷	۸	۴۲/۹۴	۰/۸۸	۰/۶۸	۰/۹۷	۴۴/۶۲	۱/۵	۰/۹۱	۰/۸۶
۷	۱۰	۱۰	۴۸/۴	۱/۵۱	۱/۰۶	۰/۹۱	۵۲/۴۷	۱/۵۱	۱/۰۷	۰/۸۶
۸	۱۲	۱۲	۵۲/۷۷	۱/۲۲	۰/۸۶	۰/۹۴	۵۳/۸۱	۱/۳۶	۰/۸۹	۰/۸۸
۹	۱۴	۱۴	۴۰/۲۷	۱/۲۶	۰/۸۵	۰/۹۳	۳۹/۴۴	۱/۶۴	۰/۹۱	۰/۸۳

۵۰ درصد از پیش‌بینی‌های مرحله آزمون در مدل ANN حدود ۲۸ درصد است، در حالی که این مقدار برای مدل WNN حدود ۳۳ درصد و در مدل 8PCs-ANN، ۲۵ درصد می‌باشد. به همین ترتیب برای ۹۰ درصد این مقادیر ۱۵۳ درصد، ۱۳۲ درصد و ۶۹ درصد است که تأثیر مثبت پیش‌پردازش را نشان می‌دهد. همچنین با توجه به شکل ۷ مشخص می‌شود که مدل‌های 8PCs-ANN و WNN نسبت به مدل ANN در ماه‌های پرآبی دارای عملکرد بهتری هستند. به عنوان مثال قدرمطلق خطای پیش‌بینی هر یک از سه مدل در سه پیک آبی مشاهده شده در شکل ۷ یعنی ماه سوم سال ۱۳۸۰ و ماه دوم سالهای ۱۳۸۲ و ۱۳۸۳ برای سه مدل WNN، ANN و 8PCs-ANN به ترتیب برابر با ۰/۴۷، ۵/۰۰ و ۳/۸۹ است که حاکی از بهبود عملکرد مدل‌ها با عمل پیش‌پردازش بر روی متغیرها، خصوصاً توسط PCA است. همان‌طور که قبلاً در مطالعات گذشته در زمینه پیش‌بینی جریان به اثبات رسیده است، نتایج به دست آمده از این تحقیق نیز تأییدی است بر نقش مثبت پیش‌پردازش متغیرهای ورودی به شبکه عصبی توسط تبدیل موجک در پیش‌بینی جریان [۱۹ و ۲۸]. همچنین اگرچه از روش ترکیبی PCA-ANN در مطالعات مربوط به پیش‌بینی جریان استفاده نشده است، ولی استفاده از این روش در دیگر زمینه‌های علوم همواره با بهبود عملکرد شبکه عصبی همراه بوده است [۱۶، ۱۷ و ۱۸].


۴- نتیجه‌گیری

در این تحقیق سه شکل استفاده از مدل شبکه عصبی مصنوعی برای پیش‌بینی جریان ماهانه رودخانه صوفی‌چای مورد بررسی قرار گرفت. در مرحله اول مدلی با استفاده از ANN با ۱۸ متغیر ورودی طراحی شد. در مرحله بعد پیش‌پردازش متغیرهای ورودی توسط موجک PCA انجام شد. نتایج زیر از این تحقیق قابل ارائه است:


- ۱- با بررسی این سه مدل مشخص گردید که در حالت کلی پیش‌پردازش متغیرهای ورودی اثر مثبتی در عملکرد شبکه عصبی داشته است.

۲- نتایج PCA نشان داد که ۸ مؤلفه اول جمعاً ۹۹ درصد اطلاعات ۱۸ متغیر اولیه را دارا هستند که توانست در کاستن تعداد ورودی‌ها نقش مؤثری را ایفا نماید.

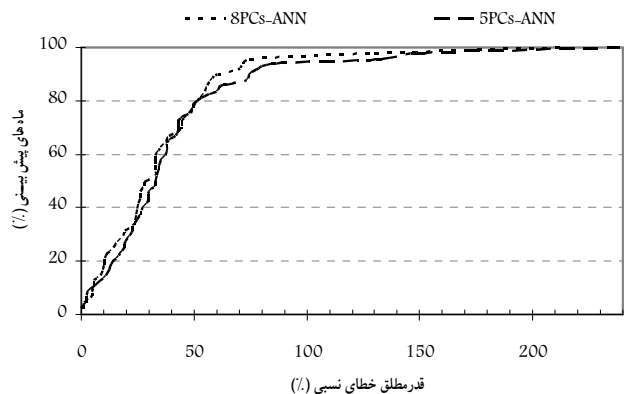
۳- استفاده از روش STA هر چند امکان بررسی ساختارهای بیشتری برای شبکه در مدت زمان کمتر را فراهم می‌کند، ولی در کاهش پیچیدگی ساختار شبکه تأثیری ندارد. ولی استفاده از PCA باعث کاهش پیچیدگی و ناپایداری مدل شبکه عصبی، و به تبع آن کمتر کردن مدت زمان آموزش شبکه گردیده است.



شکل ۸- سری زمانی داده‌های مشاهده‌ای و پیش‌بینی شده برای مدل‌های 8PCs-ANN و 5PCs-ANN در مرحله تست



شکل ۹- نمودار تحلیل آستانه خطا برای مدل‌های 8PCs-ANN و 5PCs-ANN در مرحله تست



شکل ۱۰- تحلیل آستانه قدرمطلق خطای نسبی برای سه مدل ANN، WNN و 8PCs-ANN

قدرمطلق خطای نسبی (ARE)^۱ نیز رسم شد (شکل ۱۰). با توجه به این نمودار ملاحظه می‌گردد که به عنوان مثال حداکثر ARE برای

^۱ Absolute Relative Error

می‌کاهد، ولی هیچ متغیری را به‌طور مستقیم حذف نمی‌کند، ضمن اینکه به‌دلیل کم شدن تعداد ورودی‌ها و ایجاد ساختار ساده‌تر سرعت محاسبات نیز بالا می‌رود.

۴- مقایسه PCA و موجک در پیش‌پردازش داده‌ها نشان داد که هرچند نتایج نزدیک هستند، ولی با توجه به ساختار شبکه حاصل برای آنها، PCA ساختار ساده‌تری را سبب شده است. مزیت این روش در این است که با وجود این که از تعداد متغیرهای ورودی

۵- مراجع

- 1- Karunanithi, N., Grenney, W.J., Whitley, D., and Bovee, K. (1994). "Neural networks for river flow prediction." *J. of Computing in Civil Engineering*, 8 (2), 201-220.
- 2- Kisi, O. (2004). "River flow modeling using artificial neural networks." *J. of Hydrologic Engineering*, 9(1), 60-63.
- 3- Wang, W., Van Gelder, P. H., Vrijling, J. K., and Ma, J. (2006). "Forecasting daily streamflow using hybrid ANN models." *J. of Hydrology*, 324 (1-4), 383-399.
- 4- Dawson, C.W., and Wilby, R. (1998). "An artificial neural network approach to rainfall-runoff modeling." *J. of Hydrol. Sci.*, 43, 14-66.
- 5- Tokar, A.S., and Markus, M. (2000). "Precipitation runoff modeling using artificial neural network and conceptual models." *J. Hydrol. Eng, ASCE.*, 5, 156-161.
- 6- ASCE Task Committee. (2000). "Artificial neural network in hydrology." *J. of Hydrologic Engineering*, 5, 124-144.
- 7- Coulibaly, P., Ancti, F., and Bobee, B. (2000). "Daily reservoir inflow forecasting using artificial neural networks with stopped training approach." *J. of Hydrology*, 230 (3-4), 244-257.
- ۸- رستم افشار، ن.، فهمی، ه.، و پیره، ع. (۱۳۸۵). "شبیه‌سازی و پیش‌بینی جریان رودخانه‌ها با استفاده از شبکه عصبی و مدل فوریه." *م. علمی پژوهشی تحقیقات منابع آب ایران*، جلد دوم، ۳۶-۴۴.
- 9- Yapo, P., Gupta, V.K., and Sorooshian, S. (1996). "Sensitivity of conceptual rainfall-runoff algorithms to errors in input data-case of the GR2M model." *J. of Hydrology*, 181 (1-4), 23-48.
- 10- Zealand, C., Burn, D.H., and Simonovic, S.P. (1999). "Short term streamflow forecasting using artificial neural networks." *J. of Hydrology*, 214 (1-4), 32-48.
- 11- Bowden, G.J., Maier, H.R., and Dandy, G.C. (2005). "Input determination for neural network models in water resources applications. Part 2. Case study: forecasting salinity in a river." *J. of Hydrology*, 301 (1-4), 93-107.
- 12- Haykin, S., (1999). *Neural networks: a comprehensive foundation*, 2nd Ed., Prentice Hall., New Jersey, USA.
- 13- Zhang, Y.X. (2007). "Artificial neural networks based on principal component analysis input selection for clinical pattern recognition analysis." *Talanta*, 73 (1), 68-75.
- 14- Broadhurst, D., Goodacre, R., Jones, A., Rowland, J.J., and Kell, D.B. (1997). "Genetic algorithms as a method for variable selection in multiple linear regression and partial least squares regression, with applications to pyrolysis mass spectrometry." *Anal. Chim. Acta.*, 348 (1-3), 71-86.
- 15- Bowden, G.J., Dandy, G.C., and Maier, H.R., (2005). "Input determination for neural network models in water resources applications. Part1. background and methodology." *J. of Hydrology*, 301, 75-92.
- 16- Zhang, Y., Li, H., Hou, A., and Havel, J. (2006). "Artificial neural networks based on principal component analysis input selection for quantification in overlapped capillary electrophoresis peaks." *Chemometrics and Intelligent Laboratory Systems*, 82 (1-2), 165-175.
- 17- Choi, D.J., and Park, H. (2001). "A hybrid artificial neural network as a software sensor for optimal control of a wastewater treatment process." *Water Res.*, 35 (16), 3959-3967.
- 18- Lu, W.Z., Wang, W.J., Wang, X.K., Xu, Z.B., and Leung, A.Y.T. (2003). "Using improved neural network to analyze RSP, NO_x and NO₂ levels in urban air in Mong Kok, Hong Kong." *Environmental Monitoring and Assessment*, 87 (3), 235-254.
- ۱۹- نوری، م.، و رهنما، م. ب. (۱۳۸۵). "مدل بارندگی-رواناب با استفاده از تئوری موجک و شبکه‌های عصبی مصنوعی، مطالعه موردی: هلیل رود." *مفتمین کنفرانس بین‌المللی عمران، تهران، ایران*.

- 20- Labat, D., Ababou, R., and Mangin, A. (2000). "Rainfall-runoff relations for karstic springs. Part II: continuous wavelet and discrete orthogonal multiresolution analyses." *J. of Hydrology*, 238 (3-4), 149-178.
- 21- Wang, W., and Ding, J. (2003). "Wavelet network model and Its application to the prediction of hydrology." *Nature and Science*, 1 (1), 67-71.
- 22- Cybenko, G. (1989). "Approximation by superposition of a sigmoidal function." *Math. Control Signals Syst.*, 2, 303-314.
- 23- Hornik, K., Stinchcombe, M., and White, H. (1989). "Multilayer feedforward networks are universal approximators." *Neural Networks*, 2 (5), 359-366.
- 24- Zhang, G., Patuwo, B.E., and Hu, M.Y. (1998). "Forecasting with artificial neural networks: the state of the art." *Int. J. Forecasting*, 14 (1), 35-62.
- 25- Jalili-Ghazizade, M., and Noori, R. (2008). "Prediction of municipal solid waste generation by use of artificial neural network: a case study of Mashhad." *Int. J. Environ. Res*, 2 (1), 13-22.
- ۲۶- نوری، ر.، اشرفی، خ.، اژدرپور، ا. (۱۳۸۷). "مقایسه کاربرد روش‌های شبکه عصبی مصنوعی و رگرسیون خطی چندمتغیره بر اساس تحلیل مؤلفه‌های اصلی برای پیش‌بینی غلظت میانگین روزانه مونوکسید کربن: مطالعه موردی شهر تهران." *م. علمی-پژوهشی فیزیک زمین و فضا*, ۳۴، ۱۳۵-۱۵۲.
- 27- Milidui, R. L., Machado, R. J., and Renteria, R. P. (1999). "Time-series forecasting through wavelets transformation and a mixture of expert models." *Neurocomputing*, 28, 145-156.
- 28- Cannas, B., Fanni, A., See, L., and Sias, G. (2006). "Data preprocessing for river flow forecasting using neural networks: Wavelet transforms and data partitioning." *Physics and Chemistry of the Earth*, 31 (18), 1164-1171.
- 29- Camdevyren, H., Demyr, N., Kanik, A., and Keskin, S. (2005). "Use of principal component scores in multiple linear regression models for prediction of Chlorophyll-a in reservoirs." *Ecol Modell.*, 181 (4), 581-589.
- 30- Manly, B.F.J. (1986). *Multivariate statistical methods: A Primer*, 2nd Ed., Chapman and Hall, London, UK.
- 31- Johnson, R.A., Wichern, D.W. (1982). *Applied multivariate statistical analysis*, 3rd Ed., Prentice-Hall Inc., Englewood Cliffs, USA.
- 32- Legates, D.R., and McCabe, G.J. (1999). "Evaluating the use of "Goodness-of-fit" measures in hydrologic and hydroclimatic model validation." *Water Resour. Res.*, 35, 233-241.
- 33- Davis, J.C. (1986). *Statistical and data analysis in geology*, 2nd Ed., John Wiley and Sons, New York.
- 34- Wackernagel, H. (1995). *Multivariate geostatistics. an introduction with applications*, 2nd Ed., Springer, New York and London.
- 35- Tabachnick, B.G., Fidell, L.S. (2001). *Using multivariate statistics*, 3rd Ed., Allyn and Bacon, Boston, London.
- ۳۶- نوری، ر.، کراچیان، ر.، خدادادی، ا.، شکیبایی‌نیا، ا. (۱۳۸۶). "ارزیابی اهمیت ایستگاه‌های پایش کیفی رودخانه‌ها با استفاده از آنالیزهای مولفه و فاکتور اصلی، مطالعه موردی: رودخانه کارون." *م. علمی-پژوهشی آب و فاضلاب*, ۶۳ (۳)، ۶۰-۶۹.
- 37- Jain, A., and Indurthy, S.K.V.P. (2003). "Comparative analysis of event based rainfall-runoff modeling techniques-deterministic, statistical, and artificial neural networks." *J. of Hydrologic Engineering*, 8 (2), 93-98.
- 38- Jain, A., Ormsbee, L.E. (2004). "An evaluation of the available techniques for estimating missing fecal coliform data." *J. Am. Water Resour. Assoc.* 40 (6), 1617-1630.
- 39- Rajurkar, M.P., Kothyarib, U.C., Chaube, U.C. (2004). "Modeling of the daily rainfall-runoff relationship with artificial neural network." *J. of Hydrology*, 285 (1-4), 96-113.