

پیش‌بینی جریان روزانه رودخانه نوران چای با استفاده از مدل ترکیبی شبکه‌های عصبی مصنوعی - تجزیه مؤلفه‌های اصلی

یوسف حسن‌زاده*، امین عبدی کردانی^۱، مریم شفیعی نجد^۲، سعید خوش طینت^۳

تاریخ دریافت: ۹۲/۱۱/۰۲ تاریخ پذیرش: ۹۳/۰۶/۲۹

- ۱- استاد، گروه مهندسی عمران آب، دانشکده مهندسی عمران، دانشگاه تبریز
 - ۲- دانشجوی دکتری، گروه مهندسی عمران آب، دانشکده مهندسی عمران، دانشگاه تبریز
 - ۳- دانشجوی کارشناسی ارشد، گروه مهندسی عمران آب، دانشکده مهندسی عمران، دانشگاه تبریز
 - ۴- کارشناس ارشد، دانشکده عمران، دانشگاه آزاد اسلامی واحد مهاباد
- * مسئول مکاتبات، پست الکترونیکی: yhassanzadeh@tabrizu.ac.ir

چکیده

پیش‌بینی دقیق جریان روزانه، نقش به‌سزایی در مدیریت کارآمد منابع آب ایفا می‌کند. به این منظور در این تحقیق سعی شده است که جهت مدل‌سازی هرچه دقیق‌تر فرآیند پیش‌بینی جریان روزانه رودخانه نوران چای واقع در حوضه آتشفشان، از شبکه‌های عصبی مصنوعی (ANN) استفاده گردد. همچنین به‌منظور افزایش کارایی ANN از تجزیه مؤلفه‌های اصلی (PCA) جهت پیش‌پردازش داده‌های ورودی استفاده گردیده و در نهایت داده‌های خروجی حاصل، با نتایج مدل رگرسیون خطی چند متغیره (MLR) مقایسه شده است. نتایج نشان داد که مدل ترکیبی ANN-PCA در قیاس با مدل ANN منفرد و MLR از دقت بسیار بالایی برخوردار است. به‌طوری‌که نتایج معیارهای ارزیابی شامل ضریب همبستگی (CC)، ضریب راندمان (EC) و جذر میانگین مربعات خطاها (RMSE) برای مدل ترکیبی ANN-PCA (در مرحله صحت‌سنجی) برابر $CC=0/9959$ ، $EC=0/9905$ و $RMSE=0/0071$ ، مدل ANN منفرد (در مرحله صحت‌سنجی) برابر $CC=0/9093$ ، $EC=0/8269$ و $RMSE=0/0405$ و مدل MLR برابر $CC=0/8866$ ، $EC=0/7810$ و $RMSE=0/0926$ به‌دست آمدند. همچنین استفاده از PCA به‌عنوان یک روش مؤثر جهت پیش‌پردازش داده‌ها، با ایجاد مؤلفه‌های مستقل از هم موجب از بین رفتن هم‌خطی چندگانه می‌شود. بنابراین PCA موجب افزایش کارایی مدل ANN می‌گردد.

واژه‌های کلیدی: پیش‌بینی جریان روزانه، تجزیه به مؤلفه‌های اصلی، حوضه آتشفشان، رگرسیون خطی چند متغیره، شبکه‌های عصبی مصنوعی

Daily Streamflow Forecasting of Nooranchay River Using the Hybrid Model of Artificial Neural Networks- Principal Component Analysis

Y Hassanzadeh^{1*}, A Abdi Kordani², M Shafiei Najd³, S Khoshtinat⁴

Received: 22 January 2014 Accepted: 20 September 2014

¹-Prof., Water Engin. Dept., Faculty of Civil. Engin., Univ. of Tabriz, Iran

²-Ph.D. Candidate, Water Engin. Dept., Faculty of Civil. Engin., Univ. of Tabriz, Iran

³-M.Sc. Student, Water Engin. Dept., Faculty of Civil. Engin., Univ. of Tabriz, Iran

⁴ M.Sc., Faculty of Civil. Engin., Islamic Azad University, Mahabad Branch, Iran

* Corresponding Author, Email: yhassanzadeh@tabrizu.ac.ir

Abstract

Accurate forecasting of the daily discharge plays a significant role in the efficient management of water resources. For this purpose in order to model more accurately the process of forecasting the daily discharge of Nooranchay river in Atashgah basin, the artificial neural networks model (ANN) was used. In addition, in order to increase the accuracy of ANN, the principal component analysis (PCA) was used for preprocessing of input data. Finally, the results of multivariate linear regression (MLR) model were compared with the obtained results in the mentioned hydrological simulation. The results indicated that the hybrid model of ANN-PCA in comparison with ANN and MLR, had the highest precision. So that the results of goodness-of-fit tests criteria, such as the correlation coefficient (CC), the efficiency coefficient (EC) and the root mean square error (RMSE) for the hybrid model of ANN-PCA (at the verification stage) were CC=0.9959, EC=0.9905 and RMSE=0.0071, and for the ANN (at the verification stage) were CC=0.9093, EC=0.8269 and RMSE=0.0405 and the results for the MLR were obtained as CC=0.8866, EC=0.7860 and RMSE=0.0926. Also the use of PCA as an effective method for pre-processing of data, created independent components which eliminated the multicollinearity. Therefore, the PCA increased the efficiency of the ANN.

Keywords: Artificial neural networks, Atashgah basin, Daily discharge forecasting, Multivariate linear regression, Principal component analysis

مقدمه

گذاری‌های کلان در هر کشوری را شامل می‌شود که سرمایه‌گذاری هنگفتی را هر ساله به‌خود اختصاص می‌دهد. شناخت هر چه بیشتر پدیده‌ها و پارامترهای مؤثر در مطالعات فرآیند بارش- رواناب و پیشرفت‌های

مهار آب‌های سطحی به‌منظور استحصال و کنترل اثرات مخرب سیلاب‌ها انجام می‌پذیرد و اهمیت آن به‌نحوی است که یکی از مهم‌ترین اهداف و سیاست-

نرون‌های لایه ورودی استفاده نمودند. علاوه بر این، بر مبنای همین مجموعه از داده‌ها، یک رگرسیون خطی ترتیب داده و به این نتیجه رسیدند که شبکه‌های عصبی در تمام موارد عملکرد بهتری نسبت به مدل رگرسیون خطی دارد. رهنما و نوری (۲۰۰۸) با استفاده از شبکه عصبی مصنوعی و تبدیلات موجک^۲، به پیش‌بینی رودخانه‌ای به‌کمک داده‌های بارش- رواناب حوضه هلیل رود در استان کرمان پرداختند. نتایج آن‌ها نشان داد که این مدل، توانایی‌های مدل شبکه عصبی را به مقدار قابل‌توجهی افزایش می‌دهد و سبب دقت بیشتر پیش‌بینی‌ها می‌شود. بر این اساس آن‌ها چنین فرض نمودند که قابلیت مدل ترکیبی در تخمین جریان بیشینه رودخانه‌ای، جهت طراحی سازه‌های هیدرولیکی در سدسازی بسیار مفید و مؤثر خواهد بود. ماچادو و همکاران (۲۰۱۱) برای مدل‌سازی بارش- رواناب ماهانه حوضه آبریزی در برزیل، از شبکه‌های عصبی مصنوعی استفاده نمودند. نتایج نشان داد که شبکه‌های عصبی مصنوعی در قیاس با مدل مفهومی IPHMEN، ضریب همبستگی و ناش-ساتکیف بالاتری داشت.

از جمله کارهایی که در زمینه مدل‌سازی با استفاده از ترکیب شبکه‌های عصبی مصنوعی و تجزیه به مؤلفه‌های اصلی انجام شده است می‌توان به موارد زیر اشاره نمود. چوی و پارک (۲۰۰۱) در تحقیقی با استفاده از ترکیب شبکه‌های عصبی مصنوعی و تجزیه به مؤلفه‌های اصلی، غلظت نیتروژن ورودی به یک تصفیه‌خانه فاضلاب در کشور کره جنوبی را پیش‌بینی نمودند. به این منظور مدل‌سازی با استفاده از دوازده متغیر کیفی آب و مدل‌های متفاوتی از شبکه‌های عصبی مصنوعی به دو صورت انجام گرفت. یکی بر اساس ورودی‌های اصلی و دیگری بر اساس ورودی‌های پیش‌پردازش شده (مؤلفه‌های اصلی). نتایج به‌دست آمده حاکی از برتری مدل ترکیبی فوق بود. هو و همکاران (۲۰۰۷) از تجزیه به مؤلفه‌های اصلی به‌عنوان ابزاری

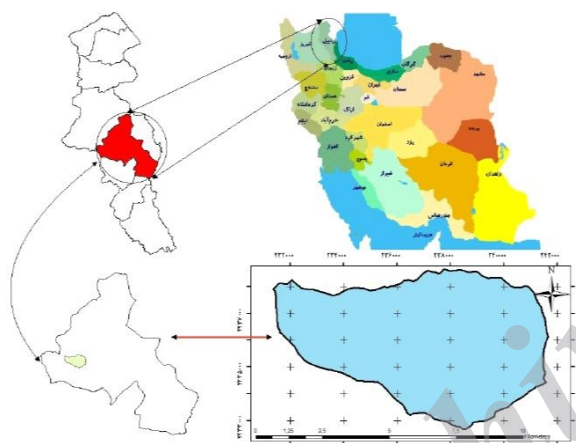
روزافزون در زمینه‌های محاسباتی منجر به تهیه مدل‌ها و نرم‌افزارهای متنوعی در این زمینه شده است. انجام تحلیل‌های مدل‌سازی به‌صورت دستی یکی از کارهای بسیار مشکل، وقت‌گیر و طاقت‌فرسا محسوب می‌گردد که اغلب به‌دلیل محدودیت زمانی، خطای انسانی و کمبود اطلاعات موردنیاز، نتایج قابل قبولی در بر ندارد. تاکنون مدل‌های بارش- رواناب فراوانی با قابلیت‌ها و پیچیدگی‌های متفاوت جهت پیش‌بینی سیلاب توسعه داده شده‌اند. گسترش استفاده از شیوه‌های نوین تخمین بارش- رواناب مانند شبکه‌های عصبی مصنوعی^۱، به‌عنوان یک روش قدرتمند و قابل‌اعتماد، می‌تواند برای برنامه‌ریزی و استفاده بهینه از منابع آبی کشور مورد استفاده مهندسان امور آب کشور قرار گیرد. علت استقبال از مدل‌های شبکه عصبی را می‌توان قدرت شبیه‌سازی مدل در فرآیندهایی که تعریف دقیق و درک خاصی از آن‌ها وجود ندارد و حساسیت کمتر آن نسبت به وجود خطا در ورودی‌ها دانست که این ویژگی باعث شد در مباحث پیش‌بینی به‌طور گسترده‌ای مورد توجه قرار گیرد.

در زمینه مدل‌سازی بارش- رواناب با استفاده از شبکه‌های عصبی مصنوعی، مطالعات مختلفی از سال ۱۹۹۵ تاکنون صورت گرفته است که به چند مورد از آن‌ها اشاره می‌شود. وو و همکاران (۲۰۰۵) برای پیش- بینی رواناب یک حوضه کوچک در آمریکا، از شبکه‌های عصبی مصنوعی استفاده نمودند. این مدل در پیش‌بینی چندساعته رواناب با بازه‌های زمانی ۱۵ دقیقه‌ای نتایج قابل قبولی ارائه داد. در نهایت نتایج تحقیق نشان داد که می‌توان از شبکه‌های عصبی مصنوعی برای هشدار سیل در حوضه‌های شهری به‌صورت مفید و مؤثر استفاده نمود. راگیووانشی و همکاران (۲۰۰۶) از شبکه عصبی مصنوعی برای پیش‌بینی دبی جریان و نیز دبی رسوب در مقیاس‌های زمانی روزانه و هفتگی استفاده کردند. آن‌ها از اطلاعات بارش و دمای هوا به‌عنوان

² Wavelet transform¹ Artificial neural networks

۴۰/۸ کیلومتر مربع و متوسط ارتفاع آن از سطح دریا ۲۴۲۹ متر است که بیشینه ارتفاع آن ۳۶۸۰ متر و کمینه ارتفاع ۱۷۶۰ متر در خروجی حوضه هست. در شکل ۱ موقعیت جغرافیایی حوضه آبریز آتشگاه نشان داده شده است (رئوف و میرزایی ۱۳۹۱).

در این تحقیق، از داده‌های روزانه هواشناسی (بارش، ساعات آفتابی، دمای بیشینه و دمای کمینه) و رواناب ثبت شده در بازه زمانی ۷۷/۰۷/۰۱ الی ۸۹/۰۶/۳۱ (در مجموع ۴۳۸۳ داده) برای مدل‌سازی استفاده شده است.



شکل ۱- موقعیت حوضه آبریز آتشگاه.

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی روشی بر پایه پردازش اطلاعات و داده‌ها است که بر اساس سیستم مغز و اعصاب انسان و عملکرد آن‌ها شبیه‌سازی شده است. در این مدل، اجزای کوچکی به نام نرون وظیفه پردازش اطلاعات را به عهده دارند. این نرون‌ها به یکدیگر متصل شده و بسته به چگونگی این اتصالات، شبکه‌ها و مدل‌های مختلفی به وجود می‌آیند.

مدل ریاضی مورد استفاده برای بیان مقدار خروجی از شبکه عصبی، به صورت رابطه زیر ارائه شده است (کیم و والدس ۲۰۰۳):

جهت پیش‌پردازش داده‌های ورودی به شبکه‌های عصبی مصنوعی، برای مدل‌سازی بارش- رواناب یک‌ساعته حوضه رودخانه دارونگ واقع در ایالت گوانگشی چین بهره بردند و در نهایت نتیجه گرفتند که به‌طور کلی استفاده از تجزیه به مؤلفه‌های اصلی، رابطه بین بارش و رواناب را بهتر بیان می‌کند. نوری و همکاران (۱۳۸۸) جهت پیش‌بینی جریان ماهانه رودخانه صوفی چای از سه مدل شبکه عصبی مصنوعی تنها، مدل شبکه عصبی- موجک و مدل شبکه عصبی- تجزیه به مؤلفه‌های اصلی استفاده نمودند. نتایج نشان داد که در حالت کلی پیش‌پردازش متغیرهای ورودی توسط تبدیل موجک و یا تجزیه به مؤلفه‌های اصلی، اثر مثبتی در عملکرد شبکه‌های عصبی مصنوعی داشته است. همچنین هرچند نتایج دو روش مورد استفاده در پیش‌پردازش داده‌ها به هم نزدیک بود، ولی با توجه به ساختار شبکه حاصل برای آن‌ها، تجزیه به مؤلفه‌های اصلی ساختار ساده‌تری دارد که در نهایت سبب افزایش سرعت محاسبات می‌گردد.

در این تحقیق، به منظور پیش‌بینی جریان روزانه رودخانه نوران‌چای واقع در حوضه آبریز آتشگاه، از شبکه‌های عصبی مصنوعی به صورت تنها و همچنین تلفیق با تجزیه به مؤلفه‌های اصلی استفاده شده است. در نهایت نتایج حاصل از دو روش با روش رگرسیون خطی چند متغیره مورد مقایسه و ارزیابی قرار گرفته است.

مواد و روش‌ها

منطقه مطالعاتی

رودخانه نوران‌چای واقع در حوضه آبریز آتشگاه، یکی از سرشاخه‌های رودخانه قره‌سو در جنوب غربی شهرستان اردبیل و یکی از زیر حوضه‌های حوضه آبخیز سبلان هست. این حوضه دارای مشخصات با طول جغرافیایی ۴۸ درجه و ۳ دقیقه و عرض جغرافیایی ۳۸ درجه و ۱۳ دقیقه و به مساحت

۱۰۹۶ داده) برای صحت‌سنجی مدل استفاده شد. بر این اساس ابتدا داده‌ها مطابق فرمول زیر استاندارد شده و سپس در شبکه‌های عصبی مورد استفاده قرار گرفته‌اند (ضرغامی و همکاران ۲۰۱۱).

$$Y_i = \frac{X_{oi}}{X_{omax}}, \quad i=1,2,3,\dots,n \quad [۲]$$

در رابطه فوق Y_i مقادیر استاندارد شده، X_{oi} مقادیر مشاهداتی و X_{omax} بیشینه مقدار مشاهداتی هست. در اینجا جهت پیش‌بینی رواناب، از مدل‌های مختلف در شبکه‌های عصبی مصنوعی استفاده گردیده که بهترین آن‌ها در معادله زیر ارائه شده است.

$$R_{t+1} = f(R_t, P_t, S_t, Tmax_t, Tmin_t) \quad [۳]$$

در معادله فوق R_{t+1} مقدار رواناب در زمان $t+1$ ، R_t مقدار رواناب در زمان t ، P_t مقدار بارش در زمان t ، S_t مقدار ساعات آفتابی در زمان t ، $Tmax_t$ مقدار دمای بیشینه در زمان t و $Tmin_t$ مقدار دمای کمینه در زمان t می‌باشند.

بر اساس مدل مورد استفاده در شبکه‌های عصبی مصنوعی، از شبکه پیشرو- انتشار برگشتی^۴ که توسط الگوریتم لونیگ- مارکوورت^۵ (LM) آموزش‌دیده شده است، جهت تخمین جریان مورد استفاده قرار می‌گیرد. تابع محرک از نوع تانژانت سیگموئید^۶ (tansig) بوده و مدل از سه لایه ورودی، میانی و خروجی تشکیل یافته است (یونابا و همکاران ۲۰۱۰). جهت انجام مدل‌سازی با استفاده از شبکه عصبی از جعبه‌ابزار تعبیه‌شده در نرم‌افزار MATLAB استفاده شد.

تجزیه به مؤلفه‌های اصلی

تجزیه به مؤلفه‌های اصلی از روش‌های آماری چند متغیره است. در مواردی که با حجم زیادی از

[۱]

$$\hat{y}_k = f_o \left[\sum_{j=1}^m w_{kj} \cdot f_h \left(\sum_{i=1}^n w_{ji} X_i + w_{jo} \right) + w_{ko} \right]$$

که در آن n تعداد کل نرون‌های لایه ورودی، m تعداد کل نرون‌های لایه میانی، k تعداد کل نرون‌های لایه خروجی، f_o تابع محرک^۱ مورد استفاده در لایه خروجی، f_h تابع محرک مورد استفاده در لایه میانی، w_{jo} مقدار وزن اریب نرون W_{ko} لایه میانی، مقدار وزن اریب نرون k ام لایه خروجی، w_{ji} مقدار وزنی است که به نرون k ام لایه ورودی اختصاص داده می‌شود تا بر اساس آن نرون W_{kj} لایه میانی مقدار وزنی است که به نرون k ام لایه خروجی (\hat{y}_k) به دست آید.

برای اینکه شبکه عصبی بتواند خروجی را تا حد امکان به هدف نزدیک کند، به فرآیند آموزش نیاز دارد. آموزش عبارت است از پیدا کردن مناسب‌ترین بردار وزن و بردار اریب و کمینه کردن تابع خطا بین داده‌های محاسباتی (خروجی) و داده‌های مشاهداتی (هدف) که معمولاً از رابطه میانگین مربع خطاها^۲ استفاده می‌شود. یکی از الگوریتم‌های آموزشی، روش انتشار برگشتی^۳ هست که با به دست آوردن مقدار وزن‌های اصلاح‌شده در هر مرحله، سبب بهبود نتایج می‌شود. در نهایت بعد از اینکه آموزش پایان یافت، شبکه قادر به ارائه جواب‌های منطقی به داده‌های ورودی جدید خواهد بود (حسن‌زاده و همکاران ۱۳۹۱ الف).

در این تحقیق، از میان داده‌های هواشناسی و رواناب ثبت‌شده در طی دوره آماری ثبت‌شده، ۷۵ درصد داده‌ها (داده‌های ۷۷/۰۷/۰۱ الی ۸۶/۰۶/۳۱ یعنی در مجموع ۳۲۸۷ داده) جهت واسنجی مدل و ۲۵ درصد بقیه (داده‌های ۸۶/۰۷/۰۱ الی ۸۹/۰۶/۳۱ یعنی در مجموع

⁴ Feedforward- backpropagation network

⁵ Levenberg- Marquardt (LM)

⁶ Tangent sigmoid

¹ Active function

² Mean square error (MSE)

³ Back propagation

استفاده از رگرسیون و مدل‌های مبتنی بر آن از قدمت زیادی در حل و مدل‌سازی مسائل هیدرولوژیکی برخوردار است. اگر اطلاعات دقیق هیدرولوژیکی موردنیاز نباشد و روش‌های پیچیده مدل‌سازی به‌اندازه کافی دقیق نباشند، مدل‌های رگرسیونی به‌عنوان یکی از بهترین انتخاب مطرح می‌باشند (کارآموز و عراقی نژاد ۱۳۸۴).

رگرسیون خطی روشی آماری است که در آن با ایجاد یک رابطه خطی بین دو یا چند متغیر مستقل^۱ به‌منظور پیش‌بینی متغیر وابسته^۲ استفاده می‌شود. فرم عمومی معادله رگرسیون خطی چند متغیره به‌صورت زیر بیان می‌شود:

$$Y_i = a_0 + \sum_{j=1}^n a_j X_{ij} \quad [۶]$$

که در آن a پارامترهای رگرسیون، X متغیرهای مستقل، a_0 خروج از مرکز و n تعداد متغیرهای مستقل هست.

معیار نیکویی برازش

جهت بررسی صحت نتایج خروجی، که در واقع بیان‌کننده اختلاف بین داده‌های مشاهداتی و محاسباتی هست، از معیارهای متفاوتی استفاده می‌گردد. معیارهای نیکویی برازش به دو صورت گرافیکی^۳ و آماری^۴ می‌باشند که هرکدام از آن‌ها ویژگی‌های منحصر به‌خود را داشته و به‌منظور خاصی بکار می‌روند. از آنجاکه روش گرافیکی روش دقیقی نیست و بسته به نظر اشخاص نتایج متفاوتی به‌دست می‌آید، بنابراین از معیارهای آماری استفاده می‌شود (حسن‌زاده و همکاران ۱۳۹۱ ب). معیارهای آماری با استفاده از روابط آماری جهت تعیین خطای بین داده‌های مشاهداتی و محاسباتی انجام می‌گیرد، که از

اطلاعات روبرو هستیم از این روش می‌توان به‌منظور کاهش پیچیدگی تحلیل متغیرها و همچنین تفسیر بهتر اطلاعات استفاده نمود (کامدویرن و همکاران ۲۰۰۵). 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 ایجادشده ترکیبی خطی از متغیرهای اولیه هستند. با استفاده از این تکنیک، ترکیباتی از P متغیر اولیه X_1, X_2, \dots, X_p و برای ایجاد P مؤلفه مستقل (معادل با تعداد متغیرهای اولیه مورد استفاده) یعنی Z_1, Z_2, \dots, Z_p ایجاد می‌شود. عدم همبستگی بین این مؤلفه‌ها جنبه‌های متفاوتی از متغیرهای اولیه را نمایان می‌سازند (منلی ۲۰۰۴).

در این روش، متغیرهای اولیه به‌طور مستقیم مورد استفاده قرار نمی‌گیرند، بلکه به مؤلفه‌هایی تبدیل می‌شوند، سپس این مؤلفه‌ها به‌جای متغیرهای اولیه استفاده می‌شوند. همچنین چون در تشکیل مؤلفه‌ها از تمام متغیرها استفاده می‌گردد، در نتیجه اطلاعات متغیرهای اولیه با کمترین تلفات توسط مؤلفه‌های حاصل ارائه می‌شود (جانسون و ویچرن ۲۰۰۷). هر مؤلفه اصلی می‌تواند با یک دنباله به‌صورت رابطه زیر مشخص شود:

$$Z_i = a_{i1} X_1 + a_{i2} X_2 + \dots + a_{ip} X_p \quad [۷]$$

که در آن Z_i نامین مؤلفه اصلی، a_{ij} ضرایب مربوط به متغیرهای اولیه، P تعداد متغیرهای اولیه و X_i نیز متغیرهای اولیه است. ضرایب مربوط به متغیرهای اولیه از حل رابطه زیر به‌دست می‌آید:

$$R - \lambda I = 0 \quad [۸]$$

که در آن I ماتریس واحد، R ماتریس همبستگی بین متغیرهای اولیه و λ نیز مقادیر ویژه هست. بر اساس این مقادیر ویژه، بردارهای ویژه به‌دست می‌آیند (نوری و همکاران ۱۳۸۸).

رگرسیون خطی چند متغیره

^۱ Independent variable(s)

^۲ Dependent variable

^۳ Graphical test

^۴ Statistical test

RMSE ۰/۰۳۵۱ ۰/۰۴۰۵

نتایج حاصل از مدل ترکیبی شبکه‌های عصبی

مصنوعی- تجزیه به مؤلفه‌های اصلی

در این بخش جهت پیش‌بینی رواناب از مدل ترکیبی شبکه‌های عصبی مصنوعی و تجزیه به مؤلفه‌های اصلی استفاده می‌شود. بدین ترتیب ابتدا مؤلفه‌های اصلی داده‌های بارش، رواناب، ساعات آفتابی، دمای بیشینه و دمای کمینه روز گذشته، توسط تجزیه به مؤلفه‌های اصلی انتخاب و سپس با ورود داده‌های مؤلفه‌های اصلی در شبکه‌های عصبی مصنوعی، مقدار رواناب پیش‌بینی می‌شود.

در این شیوه ابتدا باید تعداد مؤلفه‌های اصلی انتخاب گردند. بنابراین توسط نرم‌افزار Minitab ماتریس بردار ویژه (ماتریس λ) و ماتریس درصد بردار ویژه (ماتریس $\lambda\%$) محاسبه شدند که نتایج آن به صورت زیر

هست:

$$\lambda = \begin{bmatrix} 2.339 & 0 & 0 & 0 & 0 \\ 0 & 1.160 & 0 & 0 & 0 \\ 0 & 0 & 0.844 & 0 & 0 \\ 0 & 0 & 0 & 0.551 & 0 \\ 0 & 0 & 0 & 0 & 0.106 \end{bmatrix} \quad [۷۰]$$

$$\lambda\% = \begin{bmatrix} 46.8 & 0 & 0 & 0 & 0 \\ 0 & 23.2 & 0 & 0 & 0 \\ 0 & 0 & 16.9 & 0 & 0 \\ 0 & 0 & 0 & 11.0 & 0 \\ 0 & 0 & 0 & 0 & 2.1 \end{bmatrix} \quad [۷۱]$$

پرکاربردترین آن‌ها ضریب همبستگی^۱ (CC)، ضریب راندمان^۲ (EC) و جذر میانگین مربعات خطاها^۳ (RMSE) هست (حسن‌زاده و همکاران ۲۰۱۱).

$$CC = \frac{\sum_{i=1}^n [(X_{oi} - \bar{X}_o)(X_{ci} - \bar{X}_c)]}{\left[\sum_{i=1}^n (X_{oi} - \bar{X}_o)^2 \sum_{i=1}^n (X_{ci} - \bar{X}_c)^2 \right]^{1/2}} \quad [۷]$$

$$EC = 1 - \frac{\sum_{i=1}^n (X_{oi} - X_{ci})^2}{\sum_{i=1}^n (X_{oi} - \bar{X}_o)^2} \quad [۸]$$

$$RMSE = \left[\frac{1}{n} \sum_{i=1}^n (X_{oi} - X_{ci})^2 \right]^{1/2} \quad [۹]$$

در رابطه فوق n تعداد کل داده‌ها، X_{oi} آمین داده مشاهداتی، X_{ci} آمین داده محاسباتی، \bar{X}_o میانگین داده‌های مشاهداتی و \bar{X}_c میانگین داده‌های محاسباتی هست.

نتایج و بحث

نتایج حاصل از شبکه‌های عصبی مصنوعی

نمودارهای دو مرحله واسنجی و صحت‌سنجی برای مدل مورد استفاده در شبکه‌های عصبی مصنوعی، در شکل های ۲ و ۳ ارائه شده است.

نتایج مدل‌سازی با استفاده از شبکه‌های عصبی مصنوعی در دو مرحله واسنجی و صحت‌سنجی، در جدول ۱ ارائه گردیده است.

جدول ۱- نتایج نیکویی برآزش مدل‌سازی رواناب بر

اساس شبکه‌های عصبی مصنوعی.

معیار ارزیابی	مرحله واسنجی	مرحله صحت سنجی
CC	۰/۹۲۵۱	۰/۹۰۹۳
EC	۰/۸۵۹۷	۰/۸۲۶۹

¹ Correlation coefficient

² Efficiency coefficient

³ Root mean square errors

در معادله فوق $Z1_t$ مؤلفه اصلی اول، $Z2_t$ مؤلفه اصلی دوم و $Z3_t$ مؤلفه اصلی سوم می‌باشند. بر اساس مدل ترکیبی فوق، از شبکه پیشرو-انتشار برگشتی که توسط الگوریتم لونیبرگ-مارکوارت آموزش‌دیده شده است، جهت تخمین جریان شد. تابع محرک از نوع تانژانت سیگموئید بوده و مدل از سه لایه ورودی، میانی و خروجی تشکیل یافته است. بر این اساس نمودارهای دو مرحله واسنجی و صحت‌سنجی برای مدل ترکیبی شبکه‌های عصبی مصنوعی- تجزیه به مؤلفه‌های اصلی، در شکل های ۴ و ۵ ارائه شده است.


نتایج نیکویی برازش مدل ترکیبی شبکه‌های عصبی مصنوعی- تجزیه به مؤلفه‌های اصلی در دو مرحله واسنجی و صحت‌سنجی، در جدول ۲ ارائه گردیده است.

نتایج حاصل از رگرسیون خطی چند متغیره

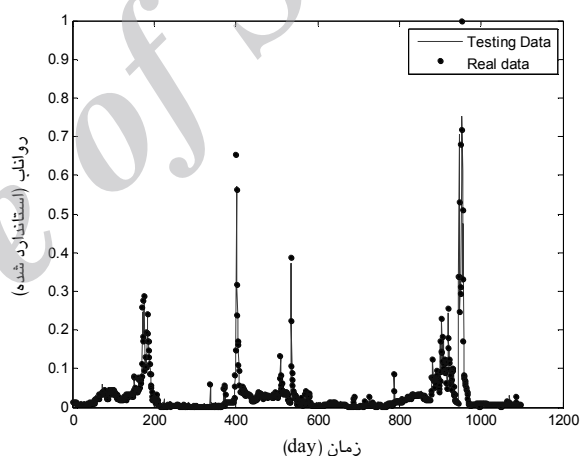
در روش رگرسیونی برای مدل‌سازی رواناب نیز می‌توان از همان تابع ارائه شده در شبکه‌های عصبی مصنوعی استفاده نمود. معادله رگرسیونی مورد استفاده، در زیر ارائه شده است.

$$R_{t+1} = a R_t + b P_t + c S_t + d T_{max_t} + e T_{min_t} + f \quad [13]$$

در معادله فوق R_{t+1} متغیر وابسته، R_t ، P_t ، S_t ، T_{max_t} و T_{min_t} متغیرهای مستقل می‌باشند. همچنین a ، b ، c ، d ، e و f ضرایب متغیرهای مستقل می‌باشند که برای به دست آوردن آن‌ها از نرم‌افزار MINTAB استفاده شده است. با استفاده از نرم‌افزار فوق، ضرایب به کار رفته در معادله رگرسیونی فوق به صورت $a=0/877$ ، $b=0/491$ ، $c=-0/194$ ، $d=0/189$ ، $e=-0/109$ و $f=0/016$ به دست آمدند.



شکل ۲- نمودار مرحله واسنجی با استفاده از شبکه‌های عصبی مصنوعی.




شکل ۳- نمودار مرحله صحت‌سنجی با استفاده از شبکه‌های عصبی مصنوعی.

با توجه به ماتریس درصد بردار ویژه، از میان پنج مؤلفه اصلی، سه مؤلفه اول (Z_1 ، Z_2 و Z_3) در حدود ۸۶/۹ درصد ($16/9+23/2+46/8$) کل پراکندگی و اطلاعات متغیرهای اصلی را بیان می‌کنند. بنابراین، سه مؤلفه اصلی انتخاب و به عنوان ورودی در شبکه‌های عصبی مصنوعی استفاده می‌شوند. مدل مورد استفاده در مدل ترکیبی شبکه‌های عصبی مصنوعی- تجزیه مؤلفه‌های اصلی در معادله زیر ارائه شده است:

$$R_{t+1} = f(Z1_t, Z2_t, Z3_t) \quad [12]$$

مستقل، مقداری بزرگتر دارد. به عبارت دیگر در روش رگرسیونی مقدار رواناب در زمان $t+1$ بیشتر به مقدار رواناب در زمان t بستگی دارد. اما با توجه به اینکه در مدل‌سازی رواناب یکی از فاکتورهای تعیین‌کننده بارش هست، بنابراین نمی‌توان از نقش این عامل چشم‌پوشی نمود. در شکل ۶ داده‌های مشاهداتی و محاسباتی رواناب با استفاده از رگرسیون خطی چند متغیره نشان داده شده است.



شکل ۶- نمودار داده‌های به دست آمده با استفاده از مدل رگرسیون خطی چند متغیره.


نتایج مدل‌سازی رواناب با استفاده از مدل رگرسیون خطی چند متغیره، در جدول ۳ ارائه گردیده است.

جدول ۳- نتایج نیکویی برازش مدل‌سازی رواناب بر اساس رگرسیون خطی چند متغیره.


نتایج	معیار ارزیابی
۰/۸۸۶۶	CC
۰/۷۸۶۰	EC
۰/۰۹۲۶	RMSE

مقایسه نتایج حاصل از روش‌های مختلف مدل‌سازی رواناب

از جدول‌های مربوط به نتایج مدل‌سازی با استفاده از شبکه‌های عصبی مصنوعی، مدل ترکیبی شبکه‌های عصبی مصنوعی- تجزیه به مؤلفه‌های اصلی



شکل ۴- نمودار مرحله واسنجی با استفاده از مدل ترکیبی شبکه‌های عصبی- تجزیه به مؤلفه‌های اصلی.



شکل ۵- نمودار مرحله صحت‌سنجی با استفاده از مدل ترکیبی شبکه‌های عصبی- تجزیه به مؤلفه‌های اصلی.


جدول ۲- نتایج نیکویی برازش مدل‌سازی رواناب بر اساس مدل ترکیبی شبکه‌های عصبی مصنوعی- تجزیه به مؤلفه‌های اصلی.

معیار ارزیابی	مرحله واسنجی	مرحله صحت‌سنجی
CC	۰/۹۹۹۸	۰/۹۹۵۹
EC	۰/۹۹۹۵	۰/۹۹۰۵
RMSE	۰/۰۰۱۹	۰/۰۰۷۱

ضرایب به دست آمده در روش رگرسیون خطی چند متغیره نشان می‌دهد که ضریب R_1 (مقدار رواناب در زمان قبل) در قیاس با ضرایب سایر متغیرهای

پیش‌پردازش)، وجود هم خطی چندگانه، باعث پایین آمدن دقت پیش‌بینی در قیاس با مدل ترکیبی شبکه‌های عصبی مصنوعی- تجزیه مؤلفه‌های اصلی می‌گردد.

همچنین از شکل‌های مربوط به شبکه‌های عصبی مصنوعی تنها و ترکیبی (شکل‌های ۷ و ۸)، چنین استنباط می‌گردد که دو مدل فوق، داده‌های دبی کوچک‌تر را بهتر از داده‌های دبی بزرگ‌تر پیش‌بینی می‌کنند.



شکل ۷- نمودار پراکندگی داده‌های مشاهداتی و محاسباتی با استفاده از شبکه‌های عصبی مصنوعی.

نتیجه‌گیری کلی

با توجه به نتایج حاصل در این تحقیق، می‌توان جمع‌بندی‌های زیر را ارائه نمود:

- مدل ترکیبی شبکه‌های عصبی مصنوعی- تجزیه مؤلفه‌های اصلی در دو مرحله واسنجی و صحت-سنجی نسبت به شبکه‌های عصبی مصنوعی و سپس رگرسیون خطی چند متغیره نتایج بسیار بهتری را ارائه می‌دهد.
- مزیت تجزیه به مؤلفه‌های اصلی در این است که باوجود کاهش تعداد متغیرهای ورودی، هیچ تغییری در حذف متغیرها به‌طور مستقیم ایجاد نمی‌کند. بنابراین مدل ترکیبی شبکه‌های عصبی مصنوعی- تجزیه به مؤلفه‌های اصلی با تعداد ۳ ورودی، جواب‌های بهتری را نسبت به شبکه‌های

و رگرسیون خطی چند متغیره (جدول‌های ۱ الی ۳) که بر اساس سه مقدار ارائه‌شده جهت بررسی معیار نیکویی برازش به‌دست‌آمده‌اند، می‌توان چنین نتیجه گرفت که از میان روش‌های فوق، ابتدا مدل ترکیبی شبکه‌های عصبی مصنوعی- تجزیه به مؤلفه‌های اصلی، سپس شبکه‌های عصبی مصنوعی تنها و درنهایت رگرسیون خطی چند متغیره بهترین برازش را بر داده-های مشاهداتی دارند. بدین ترتیب که نتایج آزمون نیکویی برازش برای مدل ترکیبی شبکه‌های عصبی مصنوعی- تجزیه به مؤلفه‌های اصلی در مرحله صحت-سنجی برابر $CC=0/9959$ ، $EC=0/9905$ و $RMSE=0/0071$ ، شبکه‌های عصبی مصنوعی برابر $CC=0/9093$ ، $EC=0/8269$ و $RMSE=0/0405$ و رگرسیون خطی چند متغیره برابر $CC=0/8876$ ، $EC=0/7870$ و $RMSE=0/0926$ به‌دست آمدند. همچنین نمودار پراکندگی داده‌های مشاهداتی و محاسباتی به‌دست‌آمده از شبکه‌های عصبی مصنوعی (به‌صورت تنها و ترکیبی) در شکل‌های ۷ و ۸ ارائه گردیده است. مقایسه شکل‌های مذکور، کارآیی تجزیه به مؤلفه‌های اصلی، در پیش‌پردازش داده‌ها جهت ورود به شبکه‌های عصبی مصنوعی، در قیاس با داده‌های اصلی (بدون اعمال پیش‌پردازش) را نشان می‌دهد.

در شبکه‌های عصبی مصنوعی، با افزایش تعداد نرون لایه ورودی، ساختار شبکه پیچیده‌تر می‌گردد. در صورتی‌که با استفاده از تجزیه به مؤلفه‌های اصلی در پیش‌پردازش داده‌ها، این مشکل مرتفع می‌گردد و با کاهش داده‌های ورودی که در بردارنده خصوصیات و ویژگی‌های داده‌های اصلی می‌باشند، ساختار مدل ساده‌تر می‌گردد و مخصوصاً در مواردی که بین داده-های ورودی همبستگی نسبتاً قوی وجود داشته باشد، با ایجاد داده‌های مستقل موجب از بین رفتن هم‌خطی چندگانه^۱ و افزایش کارآیی مدل می‌گردد. به‌همین دلیل در شبکه‌های عصبی مصنوعی تنها (بدون

^۱ Multicollinearity

(۱۵)، مشخص شد که با تعداد ۵ نرون در لایه میانی، می‌توان به جواب مطلوب دست‌یافت و استفاده از تعداد زیاد نرون در لایه میانی، نه تنها تفاوتی در جواب حاصله ایجاد نمی‌کند، بلکه فقط زمان اجرای برنامه را طولانی‌تر می‌کند.

- در روش رگرسیون خطی چند متغیره، مقدار رواناب در زمان $t+1$ (یعنی R_{t+1})، بیشتر به مقدار رواناب در زمان t (یعنی R_t)، بستگی دارد. اما با توجه به اینکه در مدل‌سازی فرآیند بارش- رواناب یکی از فاکتورهای تعیین‌کننده بارش هست، بنابراین نمی‌توان از نقش این عامل و سایر عوامل چشم‌پوشی نمود.


- مدل‌های شبکه‌های عصبی مصنوعی به دلیل در نظر گرفتن روابط غیرخطی موجود میان داده‌های ورودی و خروجی، و به دنبال آن افزایش دقت در مدل‌سازی می‌تواند جایگزین مناسبی برای مدل‌های مرسوم رگرسیون خطی باشد.

سیاس‌گذاری

این پروژه تحقیقاتی با حمایت مالی کمیته تحقیقات شرکت سهامی آب منطقه‌ای اردبیل تحت قرارداد شماره ۵۲۱۵۷/۹۰۰ مورخ ۹۰/۱۱/۱۱ با کد ۱۳۹۰/۲۶۲/م/ت/ن‌ی به انجام رسیده است. بدین‌وسیله از معاونت محترم پژوهش شرکت سهامی آب منطقه‌ای اردبیل و داوران محترم، تقدیر و تشکر به عمل می‌آید.

عصبی مصنوعی تنها با تعداد ۵ ورودی ارائه می‌دهد. ضمن اینکه به دلیل کم شدن تعداد ورودی‌ها و ایجاد ساختار ساده‌تر سرعت محاسبات نیز بالا می‌رود.

- استفاده از تجزیه به مؤلفه‌های اصلی به‌عنوان یک روش مؤثر جهت پیش‌پردازش داده‌ها، با ایجاد داده‌های مستقل موجب از بین رفتن هم‌خطی چندگانه و در نهایت افزایش کارایی مدل می‌گردد.



شکل ۸- نمودار پراکندگی داده‌های مشاهداتی و محاسباتی با استفاده از مدل ترکیبی شبکه‌های عصبی مصنوعی- تجزیه به مؤلفه‌های اصلی.

- تعداد نرون‌های مورد استفاده برای لایه میانی در شبکه‌های عصبی مصنوعی، از طریق سعی و خطا آزمایش شد و از میان تعداد نرون‌های مختلف (۲ تا

منابع مورد استفاده

حسن‌زاده ی، عبدی ا و فاخری‌فرد ا، ۱۳۹۱الف. پیش‌بینی خشک‌سالی با استفاده از الگوریتم ژنتیک و مدل ترکیبی شبکه عصبی- موجکی. آب و فاضلاب، دوره ۲۳، شماره ۸۳، صفحه‌های ۴۸ تا ۵۹.

حسن‌زاده ی، عبدی ا و فاخری‌فرد ا، ۱۳۹۱ب. کاربرد روش‌های فراکاوشی در پایش خشک‌سالی. دانش آب‌و خاک، جلد ۲۲، شماره ۳، صفحه‌های ۲۹ تا ۴۶.

رئوف م و میرزایی س، ۱۳۹۱. بررسی تأثیر احداث بندهای تأخیری بر روی زمان تمرکز حوزه (مطالعه موردی: حوزه آتشگاه اردبیل). کد مقاله ۵۴۷، اولین کنفرانس ملی راهکارهای دستیابی به توسعه پایدار در بخش‌های کشاورزی، منابع طبیعی و محیط‌زیست. ۲۱-۲۰ اسفندماه، اداره کل پدافند غیرعامل، تهران.

نوری ر، فرخ‌نیا ا، مرید س و ریاحی مدوار ح، ۱۳۸۸. تأثیر پیش‌پردازش متغیرهای ورودی به شبکه عصبی برای پیش-بینی جریان ماهانه با تجزیه مؤلفه‌های اصلی و موجک. آب و فاضلاب، دوره ۲۰، شماره ۶۹، صفحه‌های ۱۳ تا ۲۲. کارآموز م و عراقی نژاد ش، ۱۳۸۴. هیدرولوژی پیشرفته. چاپ اول. انتشارات دانشگاه امیرکبیر، تهران.

- 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. *Ecological Modelling* 181(4): 581-589.
- Choi DJ and Park H, 2001. A hybrid artificial neural network as a software sensor for optimal control of a wastewater treatment process. *Water Research* 3 (16): 3959-3967.
- Hassanzadeh Y, Abdi A, Talatahari S and Singh VP, 2011. Meta-heuristic algorithms for hydrologic frequency analysis. *Water Resources Management* 25: 1855-1879.
- Hu T, Wu F and Zhang X, 2007. Rainfall-runoff modeling using principal component analysis and neural network. *Nordic Hydrology* 38(3): 235-248.
- Johnson RA and Wichern DW, 2007. *Applied Multivariate Statistical Analysis*, 6th Edition. Prentice Hall, New Jersey.
- Kim TW and Valdes JB, 2003. Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks. *Journal of Hydrologic Engineering* 8(6): 319-328.
- Machado F, Mine M, Kaviski E and Fill H, 2011. Monthly rainfall-runoff modeling using artificial neural networks. *Hydrological Sciences Journal* 56(3): 349-361.
- Manly BFJ, 2004. *Multivariate Statistical Methods: A Primer*, 3rd Edition. Chapman and Hall/CRC, London.
- Raghuwanshi NS, Singh R and Reddy LS, 2006. Runoff and sediment yield modeling using artificial neural network: upper Siwane river, India. *Journal of Hydrologic Engineering* 11(1): 71-79.
- Rahnama MB and Nouri M, 2008. Developing of Halil river rainfall-runoff model, using conjunction of wavelet transform and artificial neural network. *Research Journal of Environmental Science* 2(5): 385-392.
- Wu S, Han JS, Annambhotla S and Bryant BS, 2005. Artificial neural networks for forecasting watershed runoff and stream flows. *Journal of Hydrologic Engineering* 10: 216-222.
- Yonaba H, Anctil F and Fortin V, 2010. Comparing sigmoid transfer functions for neural network multistep ahead streamflow forecasting. *Journal of Hydrologic Engineering* 15(4): 275-283.
- Zarghami M, Abdi A, Babaeian I, Hassanzadeh Y and Kanani R, 2011. Climate change impacts on runoffs in east Azerbaijan, Iran. *Global and Planetary Change* 78: 137-146.

Archived at SID