



ISSN 2345 - 5012

Available online at: www.waterdevelop.com

Vol. (II)– No. (03)- S.N. (06)- Summer 2014
5th Article– P. 60-70

IBWRD

International Bulletin of
Water Resources & Development

An Evaluation of Artificial Neural and Neuro-Fuzzy Intelligent Models in Rainfall-Runoff Simulation: A Case Study of Balikhluhay Watershed, Ardabil Province, Iran

Rasool Imani¹, Hoda Qasemieh^{2*}, Abazar Esmali Ouri³

¹ M.Sc. in Watershed, Department of Range and Watershed, Faculty of Natural Resources and Geoscience, University of Kashan, Kashan, Iran
(rasool.imani@yahoo.com)

² Assistant professor, Department of Range and Watershed, Faculty of Natural Resources and Geoscience, University of Kashan, Kashan, Iran

³ Assistant professor, Department of Range and Watershed, Faculty of Agriculture and Natural Resources, Mohaghegh Ardabili University, Ardabil, Iran (esmailiouri@uma.ac.ir)

* Corresponding Author (h.ghasemieh@kashanu.ac.ir)

Article History
Revised: 14 April 2014

Received: 24 February 2014
Accepted: 29 April 2014

Reviewed: 27 March 2014
Published: 16 September 2014

Abstract

Due to different reasons like non-normative usage and sequential droughts, water scarcity has highlighted the necessity of water resources management. Studying the processes affecting water resources is necessary for a normative management with sustainable development. The most important hydrologic process is the rainfall-runoff process that influences both ground and surface water resources. The study of this process is closely related to water resources management. In the past two decades, the intelligent models have found more importance because of their high ability in simulation of nonlinear and complex processes like rainfall-runoff process. In this study, the efficiency of common intelligent models in hydrology including Multi-Layer Perceptron artificial neural network (MLP), Radial Basis Function artificial neural network (RBF) and Co-Active Neural Fuzzy Inference System (CANFIS) in rainfall-runoff simulation and estimation of monthly discharge in Balikhluhay watershed was investigated. According to the coefficients of MSE, NMSE, MAE and RMSE (0.0145, 0.276, 0.103 and 0.120 respectively), the MLP artificial neural network which has three hidden layers, three neurons in each layer, a momentum algorithm and hyperbolic tangent transfer which would stimulate the monthly discharge for a 24 month test period with high accuracy was chosen as the most accurate network

Keywords: Simulation, Rainfall-Runoff, Artificial Neural Network, Neuro-Fuzzy Network, Balikhluhay Watershed

ارزیابی مدل‌های هوشمند عصبی مصنوعی و عصبی-فازی در شبیه‌سازی فرآیند بارش- رواناب،

مطالعه موردی: حوضه آبخیز بالخلوچای، استان اردبیل

رسول ایمانی^۱، هدی قاسمیه^۲، ابازر اسمعیلی عوری^۳

^۱ دانشجوی کارشناسی ارشد آبخیزداری، گروه علوم مهندسی مرتع و آبخیزداری، دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان، کاشان (rasool.imani@yahoo.com)

^۲ استادیار، گروه علوم مهندسی مرتع و آبخیزداری، دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان، کاشان، نگارنده رابط (h.ghasemieh@kashanu.ac.ir)

^۳ استادیار، گروه مرتع و آبخیزداری، دانشکده فناوری کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل (esmailiouri@uma.ac.ir)

تاریخ داوری: ۱۳۹۳/۰۱/۰۷

تاریخ دریافت: ۱۳۹۲/۱۲/۰۵

تاریخچه انتشار مقاله

تاریخ انتشار: ۱۳۹۳/۰۶/۲۵

تاریخ پذیرش: ۱۳۹۳/۰۲/۰۹

تاریخ اصلاح: ۱۳۹۳/۰۱/۲۵

چکیده

محدودیت آب به دلایل مختلفی مانند مصارف غیراصولی و خشکسالی‌های متعدد، مدیریت منابع آب را بیش‌تر برجسته ساخته است. لازمه مدیریت اصولی و در راستای توسعه پایدار، شناخت و مطالعه فرآیندهای مؤثر بر منابع آب است و فرآیند هیدرولوژیکی بارش- رواناب، مهم‌ترین فرآیند هیدرولوژیکی می‌باشد که منابع آب سطحی و زیرزمینی را تحت تأثیر قرار می‌دهد. مطالعه این فرآیند ارتباط تنگاتنگی با مدیریت منابع آب دارد. مدل‌های هوشمند به دلیل توانایی بالا در شبیه‌سازی فرآیندهای پیچیده و غیرخطی مانند بارش- رواناب، در دو دهه اخیر نزد هیدرولوژیست‌ها جایگاه ویژه‌ای یافته است. در این پژوهش کارایی مدل‌های هوشمند پرکاربرد در زمینه آب‌شناختی، شامل شبکه‌های عصبی مصنوعی پرسپترون چندلایه، عصبی مصنوعی شعاعی و عصبی- فازی در شبیه‌سازی فرآیند بارش- رواناب و تخمین دبی ماهانه حوضه آبخیز بالخلوچای مورد ارزیابی قرار گرفت. با توجه به ضرایب MAE، NMSE، MSE و RMSE (به ترتیب ۰/۱۴۵، ۰/۲۷۶، ۰/۱۰۳ و ۰/۱۲۰) شبکه عصبی مصنوعی پرسپترون چندلایه با ۳ لایه مخفی و ۳ نرون در هر لایه، الگوریتم مونتیم و تابع محرک تانزانت هاپربولیک که توانست دبی ماهانه مربوط به دوره ۲۴ ماهه تست را با دقت بالایی شبیه‌سازی کند، به عنوان دقیق‌ترین مدل و ساختار انتخاب شد.

واژه‌های کلیدی: شبیه‌سازی، بارش- رواناب، شبکه عصبی مصنوعی، شبکه عصبی- فازی، حوضه آبخیز بالخلوچای

۱. مقدمه

توانایی مدل‌سازی سیستم‌های پیچیده و با الگوی غیرخطی را دارند (Ahmad and Simonovic, 2005؛ Jahangir et al., 2005؛ اسکندری نیا و همکاران، ۱۳۹۰، صف‌شکن و همکاران، ۱۳۹۰). از جمله این مدل‌ها می‌توان به شبکه عصبی پرسپترون چندلایه^۱ (MLP)، شبکه عصبی شعاعی^۲ (RBF) و شبکه ترکیبی عصبی-فازی^۳ (CANFIS) اشاره کرد که کاربرد عمده‌ای در مطالعات مرتبط با آب دارند (زارع‌ایبانه و بیات‌ورکشی، ۱۳۹۰؛ دستورانی و همکاران، ۱۳۹۰؛ Mason et al., 1996؛ Fernando and Jayawardena, 1998). از جمله این مطالعات می‌توان به موارد زیر اشاره کرد:

مندز^۴ و همکاران (۲۰۰۴) جریان روزانه رودخانه زالاس در شمال غرب کشور اسپانیا را با استفاده از مدل شبکه عصبی، شبیه‌سازی کردند و به این نتیجه رسیدند که با ترکیب یک مدل خطی ساده با مدل شبکه عصبی و تقسیم حوزه‌های آبخیز بزرگ به زیر حوضه‌های کوچک‌تر، شبکه عصبی، قابلیت بالایی در شبیه‌سازی فرآیند پیچیده بارش- رواناب خواهد داشت. احمد و سیمونویچ (۲۰۰۵) به شبیه‌سازی رواناب و پیش‌بینی دبی اوج، زمان و شکل هیدروگراف در رودخانه رد در استان مانیتوبا از کشور کانادا و با استفاده از مدل شبکه عصبی پرداختند و بر اساس ضریب همبستگی بین مقادیر پیش‌بینی و اندازه‌گیری شده، به این نتیجه رسیدند که این مدل‌ها دقت بالایی دارند. نیلسون^۵ و همکاران (۲۰۰۶) با استفاده از مدل‌های مفهومی و مدل‌های شبکه عصبی، به

نیاز رو به رشد به آب و محدودیت‌های کمی و کیفی موجود در منابع آب، بحث مدیریت منابع آب را بیش‌از پیش برجسته ساخته است. این در حالی است که مطالعه و شناسایی عوامل و فرآیندهای تأثیرگذار بر منابع آب، شرط اولیه و لازمه یک مدیریت جامع، صحیح و در راستای توسعه پایدار می‌باشد. مهم‌ترین فرآیند تأثیرگذار بر منابع آب، فرآیند هیدرولوژیکی بارش- رواناب بوده و بارندگی و تبخیر از جمله مؤثرترین عوامل بر این فرآیند و تعیین‌کننده بیلان آبی هستند (مهدوی، ۱۳۹۰، ۱۲۲). طی دهه‌های اخیر روابط و مدل‌های ساده و پیچیده متعددی در راستای بررسی روابط بین عوامل مؤثر بر فرآیند بارش- رواناب ارائه شده است که در این میان فنون جدید هوش محاسباتی^۱ (CI)، حدود دو دهه است که به دلیل توانایی بالا در محاسبات سیستم‌های پیچیده و غیرخطی مانند فرآیند بارش- رواناب و نیاز به پارامترهای کم‌تر و قابل اندازه‌گیری، نسبت به سایر مدل‌های مفهومی و تجربی، کاربرد گسترده‌ای در علوم مختلف به ویژه علم هیدرولوژی و مدیریت منابع آب پیدا کرده است (صف‌شکن و همکاران، ۱۳۹۰؛ Ghumman et al., 2011).

از جمله روش‌های هوش محاسباتی، مدل‌های شبکه عصبی است که جزو مدل‌های جعبه سیاه و یکپارچه می‌باشد و با الگوبرداری از شبکه عصبی مغز انسان،

۴. Co-active Neuron Fuzzy Inference System

۵. Mendez

6. Nilsson

1. Computational Intelligence

2. Multi-Layer Perceptron

3. Radial Basis Function

آموزش دلتا، شبکه عصبی پرسپترون چندلایه با تعداد ۲۹ نرون در لایه پنهان، دقت بالایی در شبیه‌سازی بارش-رواناب نسبت به مدل HEC-HMS دارد. برهانی‌داریان و فاتحی‌مرج (۱۳۸۷) طی پژوهشی با استفاده از شبکه عصبی مصنوعی و بر اساس شاخص‌های اقلیمی، به شبیه‌سازی بارش-رواناب و پیش‌بینی جریان رودخانه‌ای در حوزه آبخیز نازلوچای در استان آذربایجان غربی پرداختند و به این نتیجه رسیدند که پیش‌بینی درازمدت (یک سال قبل) جریان رودخانه با استفاده از پدیده‌های اقلیمی انسو (الینو و جریانات جنوبی (ENSO)) و نائو (نوسانات اطلس شمالی (NAO)) با دقت بالا و با استفاده از شبکه عصبی مصنوعی امکان‌پذیر است. نصری و همکاران (۱۳۸۸) رواناب روزانه حوزه آبخیز پلاسجان از زیرحوضه‌های زاینده‌رود در استان اصفهان را با استفاده از داده اقلیمی بارندگی و کاربرد مدل‌های هوشمند عصبی برآورد کردند و به این نتیجه رسیدند که شبکه عصبی پرسپترون چندلایه با چهار لایه مخفی، در شبیه‌سازی رواناب روزانه مبتنی بر آزمون‌های آماری دقت بالایی دارد. زارع‌ایبانه و بیات‌ورکشی (۱۳۹۰) طی پژوهشی به ارزیابی مدل‌های هوشمند عصبی و روش‌های تجربی در تخمین رواناب سالانه رودخانه زاینده‌رود در استان اصفهان پرداختند و به این نتیجه رسیدند که به دلیل محدودیت اطلاعات مورد نیاز روش‌های تجربی و دقت بالای مدل‌های هوشمند عصبی، کاربرد مدل عصبی قابل توصیه است. گیوه‌چی و باقرنژاد (۱۳۹۱) طی پژوهشی به مقایسه روش‌های تجربی و هوشمند عصبی در برآورد رواناب سالانه حوزه آبخیز کشف‌رود در استان خراسان رضوی پرداختند و بر اساس معیارهای مختلف سنجش خطا و کارایی مدل به این نتیجه رسیدند که شبکه عصبی با یک ورودی و ۳۶ نرون در لایه میانی بهترین عملکرد و دقت قابل قبول را در مقایسه با روش‌های تجربی دارد.

با توجه به کارایی مدل‌های هوشمند در شبیه‌سازی متغیرهای هیدرولوژیکی، هدف از انجام این پژوهش بررسی کارایی هر کدام از مدل‌های MLP، RBF و CANFIS و انتخاب سازگارترین مدل برای شبیه‌سازی فرآیند بارش-رواناب و

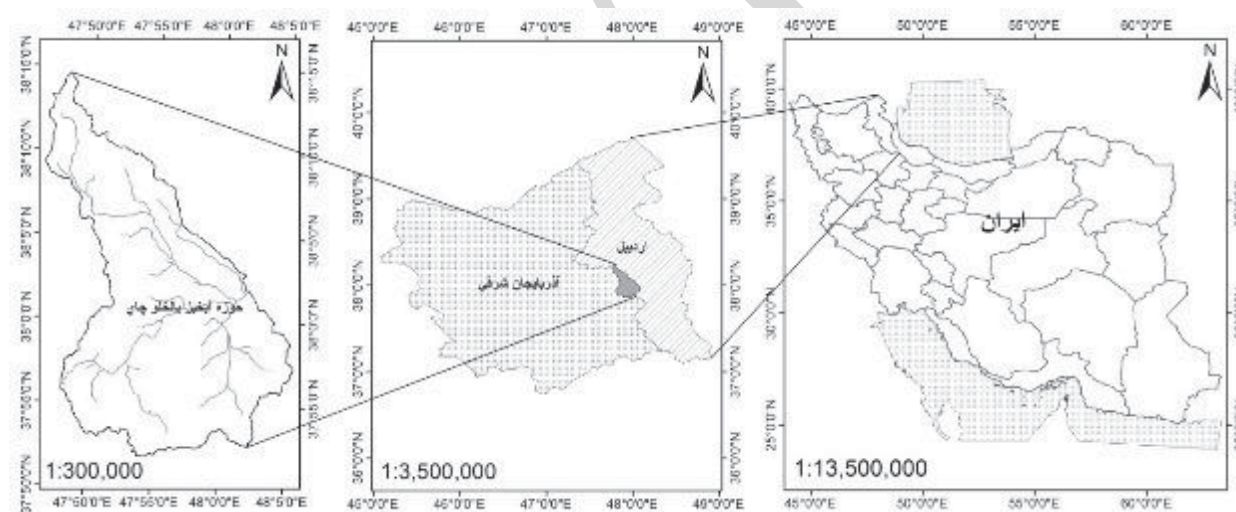
مقایسه رواناب ماهانه شبیه‌سازی شده در دو حوزه آبخیز بالکن و اسکارسواتن در کشور نروژ پرداختند و با مقایسه نتایج حاصل از دو مدل با مقادیر اندازه‌گیری شده در هر دو منطقه به این نتیجه رسیدند که مدل‌های شبکه عصبی در مقایسه با مدل‌های مفهومی، دارای دقت بیش‌تری هستند. عقیل^۱ و همکاران (۲۰۰۷) طی پژوهشی با استفاده از مدل‌های شبکه عصبی و سیستم عصبی-فازی، به شبیه‌سازی رواناب روزانه و ساعتی در حوزه آبخیز رودخانه چیلالوی از شاخه‌های رودخانه چیتاروم در کشور اندونزی پرداختند. آن‌ها سه شبکه عصبی پیش‌خور لونبرگ-مارکوات، تنظیم‌بازین و عصبی-فازی را با هم مقایسه کردند و به این نتیجه رسیدند که مدل عصبی-فازی نسبت به دو مدل دیگر دقت بالایی در شبیه‌سازی رواناب دارد. جو^۲ و همکاران (۲۰۰۹) در پژوهشی با استفاده از مدل‌های شبکه عصبی پس‌انتشار، به شبیه‌سازی بارش-رواناب و جریان روزانه رودخانه‌ای در حوزه آبخیز بالادست سد نانگاو روی رودخانه لوو در کشور چین پرداختند. آن‌ها برای بهبود شبیه‌سازی جریان روزانه، داده‌ها را به دو گروه داده‌های سیلابی و داده‌های بدون سیل تقسیم کردند و با مقایسه نتایج داده‌های تقسیم شده و تقسیم نشده به این نتیجه رسیدند که روش شبکه عصبی مصنوعی پس‌انتشار با داده‌های تقسیم‌بندی شده، اگرچه مقادیر دبی اوج را بیش‌تر تخمین زده، ولی دقت شبیه‌سازی جریان روزانه را در داده‌های بدون سیل به طور قابل ملاحظه‌ای افزایش داده است. گومان و همکاران (۲۰۱۱) طی پژوهشی به شبیه‌سازی رواناب و پیش‌بینی دبی در حوزه آبخیز رودخانه هاب در کشور پاکستان و با استفاده از مدل‌های شبکه عصبی پرداختند و با مقایسه مقادیر شبیه‌سازی و اندازه‌گیری شده به این نتیجه رسیدند که این مدل‌ها، دقت قابل قبولی در شبیه‌سازی رواناب دارند. جهانگیر و همکاران (۱۳۸۵) با استفاده از داده‌های باران‌نمود ۳۰ پیشامد بارندگی و آب‌نمود متناظر آن، به مقایسه شبکه عصبی مصنوعی و مدل HEC-HMS در شبیه‌سازی فرآیند بارش-رواناب در حوزه آبخیز معرف‌کارده در شمال شرقی استان خراسان پرداختند و به این نتیجه رسیدند که بر پایه قانون

بزقوش و سبلان جای گرفته است. شکل (۱) موقعیت کشوری و استانی حوضه آبخیز بالخلوچای را نشان می‌دهد. مساحت حوضه آبخیز بالخلوچای ۵۶۲۷۰/۷۹ هکتار است که ۷۱/۵۱ درصد (۴۰۲۳۹/۳۷ هکتار) از آن در استان اردبیل و ۲۸/۴۹ درصد (۱۶۰۳۱/۴۲ هکتار) از آن نیز در استان آذربایجان شرقی قرار گرفته است. بارش متوسط سالانه آن ۳۰۳ میلی‌متر و حداکثر ارتفاع آن در نزدیکی قله سبلان و حداقل ارتفاع آن در خروجی حوضه در محل ایستگاه هیدرومتری به ترتیب ۴۳۸۰ و ۱۵۶۰ متر از سطح دریا می‌باشد. آب این حوضه پس از عبور از ایستگاه هیدرومتری یامچی وارد مخزن سد یامچی در شهرستان اردبیل می‌شود. حوضه آبخیز بالخلوچای جزو زیرحوضه‌های حوزه آبخیز قره‌سواست که آب آن به رودخانه ارس وارد می‌شود و در نهایت به دریای خزر تخلیه می‌گردد (صفاری و همکاران، ۱۳۹۲، سایت سازمان آب منطقه‌ای اردبیل).

تخمین پارامتر دبی ماهانه بر اساس حداقل پارامترهای اقلیمی موجود در حوضه آبخیز بالخلوچای است. نتایج این تحقیق می‌تواند در زمینه‌های مختلف مدیریت منابع آب از جمله پیش‌بینی دبی‌های آینده و کنترل سیل، مدیریت مخزن سد و برنامه‌ریزی برای بهره‌برداری و در نهایت مطالعه و مدیریت حوضه‌های مجاور و مشابه اقلیمی و ادافیکی فاقد آمار و ایستگاه هیدرومتری، مورد استفاده قرار گیرد.

۲. منطقه مورد مطالعه

حوضه آبخیز بالخلوچای در محل ایستگاه درجه یک هیدرومتری یامچی، بخش بالایی رودخانه دائمی بالخلوچای در استان اردبیل و محدوده مورد مطالعه در این تحقیق را تشکیل می‌دهد. این حوضه آبخیز از نظر موقعیت جغرافیایی بین $37^{\circ} 51' 53''$ تا $47^{\circ} 46' 26''$ طول شرقی و $38^{\circ} 14' 33''$ عرض شمالی و در حدفاصل دو رشته کوه



شکل ۱. موقعیت کشوری و استانی حوضه آبخیز بالخلوچای.

باقرنژاد، ۱۳۹۱). توانایی شبکه عصبی در شبیه‌سازی فرآیندهای پیچیده و غیرخطی و نیاز به آمار کم‌تر، آن را به یکی از گزینه‌های مدنظر در شبیه‌سازی جریان تبدیل کرده است (دهقانی و همکاران، ۱۳۸۹). بررسی منابع و پژوهش‌های مختلف نشان داده است که ۹۰ درصد از شبکه‌های عصبی که در زمینه آب‌شناسی مورد استفاده قرار می‌گیرند، از نوع

۳. مواد و روش‌ها

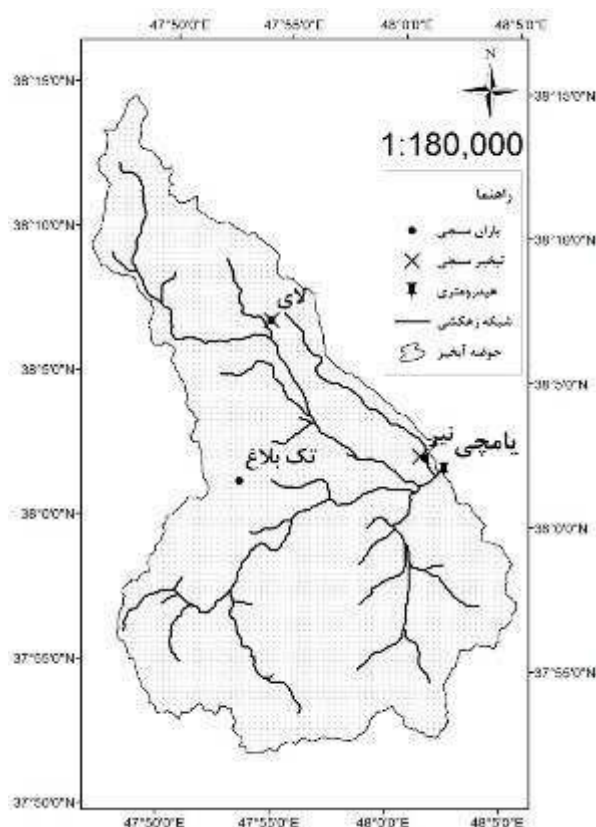
۳.۱. شبکه عصبی

شبکه عصبی الگویی برای پردازش اطلاعات و داده‌ها و ساختاری متشکل از گره‌های متراکم به نام نرون می‌باشد که هر نرون با نرون‌های قبلی و بعدی خود در ارتباط است و با تقلید از شبکه سلولی مغزی انسان، عملیات محاسباتی پیچیده را انجام می‌دهد (دهقانی و همکاران، ۱۳۸۹؛ گیوه‌چی و

ماهانه ایستگاه‌های تبخیرسنجی لای و نیر و همچنین داده‌های آب‌سنجی ماهانه ایستگاه هیدرومتری یامچی از طریق اداره آب منطقه‌ای استان اردبیل تهیه گردید. بدین ترتیب داده‌های هم‌بازه ۱۲ ساله از سال ۱۳۷۹ تا ۱۳۹۰ مشخص شدند و داده‌های پرت موجود در آن‌ها با استفاده از نرم‌افزار SPSS شناسایی و اصلاح گردیدند و در نهایت داده‌ها با استفاده از رابطه (۱) بین اعداد ۰/۱ و ۰/۹ نرمال شدند.

$$X_{norm} = 0.8 * \left(\frac{X_i - X_{min}}{X_{max} - X_{min}} \right) + 0.1 \quad (1)$$

در این معادله، X_{norm} داده نرمال شده، X_i داده غیر نرمال، X_{max} مقدار حداکثر داده‌های غیر نرمال و X_{min} مقدار حداقل داده‌های غیر نرمال است (Rajurkar et al., 2004). در این مرحله، داده‌ها آماده شدند و به عنوان پارامترهای ورودی و خروجی می‌توانند وارد شبکه گردند.



شکل ۲. حوضه آبخیز بالخلوچای، شبکه زهکشی و ایستگاه‌های هواشناسی و هیدرومتری.

شبکه‌های پیش‌خور با ناظر^۱ (FFN) هستند که با الگوریتم انتشار به عقب^۲ (BP) آموزش داده می‌شوند (Sajikumar and Thandaveswara, 1999; Coulibaly et al., 2000). این جهت در تحقیق حاضر، سه مدل مختلف از این شبکه‌ها شامل پرسپترون چندلایه (MLP)، شعاعی (RBF) و عصبی-فازی (CANFIS) که کاربرد گسترده‌ای در زمینه هیدرولوژی دارند، برای شبیه‌سازی جریان ماهانه انتخاب شده‌اند. مدل‌های مختلف شبکه عصبی مذکور در نرم‌افزار NeuroSolutions و تحت ویندوز طراحی و اجرا شدند. برای رسیدن به یک مدل شبکه عصبی، انجام مراحل مختلفی شامل انتخاب داده‌ها، پیش‌پردازش داده‌ها، معماری شبکه، آموزش و در نهایت آزمون مدل لازم است (رضایی و همکاران، ۱۳۸۶؛ زارع‌ایبانه و بیات‌ورکشی، ۱۳۹۰). هر کدام از مراحل یاد شده در ادامه به اختصار شرح داده شده است.


۲.۳. انتخاب و پیش‌پردازش داده‌ها

انتخاب داده یا به عبارت دیگر، انتخاب پارامترهای ورودی و خروجی شبکه، اولین گام در ایجاد شبکه است (نصری و همکاران، ۱۳۸۸). بررسی منابع مختلف نشان داد که پارامترهای اقلیمی بارندگی، دما و رطوبت به طور عمده در شبیه‌سازی بارش-رواناب مورد استفاده قرار گرفته است. در این تحقیق ترکیب دیگری از عناصر اقلیمی شامل بارندگی و تبخیر که به عنوان مهم‌ترین عوامل اقلیمی تعیین‌کننده بیلان آبی مطرح هستند، به عنوان پارامترهای ورودی و داده‌های آب‌سنجی ایستگاه هیدرومتری به عنوان پارامتر خروجی شبکه انتخاب شدند. نقشه‌های توپوگرافی ۱:۵۰۰۰۰ منطقه از طریق اداره کل منابع طبیعی استان اردبیل تهیه و رقومی شد. سپس به منظور تعیین ایستگاه‌های هواشناسی، از الحاقیه Arc Hydro در نرم‌افزار Arc-GIS 10.1، استفاده و محدوده حوضه آبخیز بالخلوچای در محل ایستگاه هیدرومتری یامچی - مطابق شکل (۲) - بسته شد. علاوه بر این، داده‌های بارندگی ماهانه ایستگاه‌های باران‌سنجی لای، نیر و تک‌بلاغ، داده‌های تبخیر

۳.۳. معماری شبکه عصبی

ساختار شبکه عصبی یا به عبارت دیگر معماری شبکه عصبی به طور معمول شامل سه لایه با وظایف مشخص می‌باشد که عبارتند از: لایه ورودی، لایه پنهان (لایه میانی) و لایه خروجی. لایه ورودی نقش دریافت متغیرهای ورودی و توزیع داده‌ها را در شبکه عصبی بر عهده دارد. در این تحقیق، داده‌های مستقل بارندگی سه ایستگاه باران‌سنجی و تبخیر دو ایستگاه تبخیرسنجی، لایه ورودی شبکه‌های عصبی را تشکیل می‌دهند و در عمل شامل ۵ گره در لایه ورودی می‌باشند. لایه خروجی شامل متغیری است که شبکه آن را شبیه‌سازی و نتایج را به

ازای ورودی‌های مشخص استخراج می‌کند. داده‌های وابسته ایستگاه هیدرومتری و مقادیر دبی شبیه‌سازی شده نیز لایه خروجی شبکه‌های عصبی این تحقیق را تشکیل می‌دهند. لایه پنهان نیز عمل پردازش داده‌ها را بر عهده دارد (اسکندری‌نیا و همکاران، ۱۳۹۰؛ فتاحی و همکاران، ۱۳۹۱). ساختار لایه‌های پنهان در شبکه عصبی مصنوعی (MLP و RBF) تا حدودی متفاوت با شبکه عصبی-فازی (CANFIS) است. شکل (۳) نمایش ساده‌ای از معماری شبکه عصبی مصنوعی و شبکه عصبی-فازی را نشان می‌دهد (زارع‌ایبانه و بیات‌ورکشی، ۱۳۹۰).



شکل ۳. (الف) نمونه معماری شبکه عصبی-فازی و (ب) شبکه عصبی مصنوعی.

محرك نیز به صورت الگوریتم‌های لونیبرگ-مارکوات^۱ و مومنتم^۲ و توابع محرك تانژانت هایپربولیک^۳ و سیگموئید^۴ انتخاب شدند. تعداد تکرار^۵ نیز برای تمامی شبکه‌های طراحی شده، ۱۰۰۰ در نظر گرفته شد. جدول (۱) معماری شبکه‌های عصبی مصنوعی استفاده شده را نشان می‌دهد. در معماری شبکه عصبی-فازی نیز نوع تابع عضویت، تعداد تابع عضویت، الگوریتم و تابع محرك در نظر گرفته می‌شود. توابع عضویت گوسن^۶ و زنگوله‌ای^۷، الگوریتم‌های مومنتم و لونیبرگ-

معماری لایه پنهان در شبکه عصبی مصنوعی شامل تعیین تعداد لایه‌های پنهان، تعداد نرون (گره)‌های هر لایه، تعیین الگوریتم و تابع محرك می‌باشد. طراحی شبکه‌های عصبی مورد استفاده در این تحقیق بر اساس منابع متعدد مرتبط بررسی شده انجام گرفت. تعداد لایه‌های پنهان و نرون‌های هر لایه با روش آزمون و خطا، قضاوت مهندسی و بهترین برازش بین مقادیر مشاهده‌ای و شبیه‌سازی شده انتخاب شدند. الگوریتم‌ها و توابع

5. Epochs
6. Gaussian
7. Bell

1. Levenberg Marquat
2. Momentum
3. Tanh Axon
4. Sigmoid Axon

مارکوات، توابع محرک تانزانت هایپربولیک و سیگموئید و تعداد تابع عضویت نیز به روش آزمون و خطا در معماری شبکه‌های عصبی-فازی انتخاب شدند. جدول (۲) معماری شبکه‌های عصبی-فازی استفاده شده را نشان می‌دهد.

جدول ۱. معماری شبکه‌های عصبی مصنوعی.

| مدل | الگوریتم | تابع محرک | تعداد لایه مخفی | تعداد نرون |
|-----|-------------------|--------------|-----------------|-------------|
| MLP | Momentum | Tanh Axon | آزمون و خطا | آزمون و خطا |
| | | Sigmoid Axon | آزمون و خطا | آزمون و خطا |
| | Levenberg-Marquat | Tanh Axon | آزمون و خطا | آزمون و خطا |
| | | Sigmoid Axon | آزمون و خطا | آزمون و خطا |
| RBF | Momentum | Tanh Axon | آزمون و خطا | آزمون و خطا |
| | | Sigmoid Axon | آزمون و خطا | آزمون و خطا |
| | Levenberg-Marquat | Tanh Axon | آزمون و خطا | آزمون و خطا |
| | | Sigmoid Axon | آزمون و خطا | آزمون و خطا |

جدول ۲. معماری شبکه‌های عصبی-فازی.

| مدل | تابع عضویت | الگوریتم | تابع محرک | تعداد تابع عضویت |
|--------|------------|-------------------|--------------|------------------|
| CANFIS | Bell | Momentum | Tanh Axon | آزمون و خطا |
| | | | Sigmoid Axon | آزمون و خطا |
| | | Levenberg-Marquat | Tanh Axon | آزمون و خطا |
| | | | Sigmoid Axon | آزمون و خطا |
| | Guassian | Momentum | Tanh Axon | آزمون و خطا |
| | | | Sigmoid Axon | آزمون و خطا |
| | | Levenberg-Marquat | Tanh Axon | آزمون و خطا |
| | | | Sigmoid Axon | آزمون و خطا |

۴.۳. آموزش و آزمون شبکه

به منظور آموزش شبکه عصبی و ارزیابی نتایج آن، داده‌ها به سه بخش تقسیم شدند. بخش اول داده‌ها از سال ۱۳۷۹ تا ۱۳۸۷ (حدود ۸۰ درصد داده‌ها) برای آموزش شبکه^۱، بخش دوم، داده‌های سال ۱۳۸۸ (حدود ۵ درصد داده‌ها) برای اعتبارسنجی^۲ و بخش سوم داده‌های سال ۱۳۸۹ تا ۱۳۹۰ (حدود ۱۵ درصد داده‌ها) برای آزمون شبکه^۳ انتخاب شدند.

۵.۳. ارزیابی و انتخاب بهترین شبکه

طبق جدول‌های (۱) و (۲)، تعداد ۱۶ مدل شبکه عصبی مختلف از نظر نوع شبکه، الگوریتم، تابع محرک و تابع عضویت

ساخته شد و تعداد لایه‌های مخفی و نرون‌ها در مدل‌های شبکه عصبی مصنوعی (MLP و RBF) و تعداد تابع عضویت در مدل‌های عصبی-فازی (CANFIS) با روش آزمون و خطا و اختصاص اعداد مختلف برای هر کدام از ۱۶ شبکه تعریف شد و در نهایت یک معماری برای هر شبکه که بهترین برازش را بین مقادیر شبیه‌سازی و مشاهده شده داشت، انتخاب گردید. معیار گزینش این شبکه‌ها، ضریب همبستگی^۴ بین داده‌های مشاهده‌ای و شبیه‌سازی شده در مرحله تست شبکه (داده سال ۸۹ و ۹۰) است. ضریب همبستگی (R) طبق رابطه (۲) محاسبه می‌شود و میزان همبستگی و درجه نزدیکی دو متغیر را نسبت

3. Testing
4. Correlation

1. Training
2. Cross Validation

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_{obsi} - Y_{simi}| \quad (5)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_{obsi} - Y_{simi})^2} \quad (6)$$

که در آن‌ها Y_{obsi} و Y_{simi} به ترتیب مقدار مشاهده‌ای و شبیه‌سازی شده \bar{Y}_{obs} و \bar{Y}_{sim} به ترتیب میانگین مقادیر مشاهده‌ای و شبیه‌سازی شده، V_{simi} واریانس داده‌های شبیه‌سازی شده و n تعداد داده‌ها است.

۴. یافته‌ها و بحث

نتایج مربوط به معماری شبکه‌های عصبی مصنوعی و شبکه‌های عصبی-فازی انتخاب شده بر اساس آماره ارزیابی ضریب همبستگی (R)، برای هر کدام از ۱۶ مدل طرح شده به ترتیب در جدول (۳) و (۴) آورده شده است.

به یکدیگر نشان می‌دهد. هرچه مقدار عددی این ضریب به ۱ نزدیک باشد، نشان‌دهنده کارایی بیش‌تر مدل است.

$$R = \frac{\sum_{i=1}^n (Y_{obsi} - \bar{Y}_{obs}) * (Y_{simi} - \bar{Y}_{sim})}{\sqrt{\sum_{i=1}^n (Y_{obsi} - \bar{Y}_{obs})^2 * \sum_{i=1}^n (Y_{simi} - \bar{Y}_{sim})^2}} \quad (2)$$

همچنین برای ارزیابی کارایی مدل‌های بهینه انتخاب شده از ضرایب میانگین مربعات خطا^۱ (MSE)، میانگین مربعات خطای نرمال شده^۲ ($NMSE$)، میانگین مطلق خطا^۳ (MAE) و ریشه میانگین مربعات خطا^۴ ($RMSE$) نیز استفاده شده است که به ترتیب از روابط (۳)، (۴)، (۵) و (۶) محاسبه می‌شوند.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_{obsi} - Y_{simi})^2 \quad (3)$$

$$NMSE = \frac{MSE}{V_{sim}} \quad (4)$$

جدول ۳. معماری شبکه‌های عصبی مصنوعی انتخاب شده و ضریب همبستگی در مرحله آموزش و تست.

| مدل | الگوریتم | تابع محرک | شماره مدل | تعداد لایه مخفی | تعداد نرون | (R) مرحله آموزش | (R) مرحله تست |
|-----|--------------------|--------------|-----------|-----------------|------------|-----------------|---------------|
| MLP | Momentum | Tanh Axon | ۱ | ۳ | ۳ | ۰/۸۶۶ | ۰/۹۲۳ |
| | | Sigmoid Axon | ۲ | ۲ | ۴ | ۰/۶۱۲ | ۰/۸۳۴ |
| | Levenberg- Marquat | Tanh Axon | ۳ | ۴ | ۴ | ۰/۹۷۶ | ۰/۹۲۲ |
| | | Sigmoid Axon | ۴ | ۲ | ۳ | ۰/۸۶۴ | ۰/۹۱۹ |
| RBF | Momentum | Tanh Axon | ۵ | ۵ | ۵ | ۰/۸۵۷ | ۰/۹۲۴ |
| | | Sigmoid Axon | ۶ | ۲ | ۱۰ | ۰/۷۷۲ | ۰/۸۵۹ |
| | Levenberg-Marquat | Tanh Axon | ۷ | ۲ | ۷ | ۰/۳۱۶ | ۰/۴۱۷ |
| | | Sigmoid Axon | ۸ | ۲ | ۶ | ۰/۶۴۱ | ۰/۷۳۸ |

جدول ۴. معماری شبکه‌های عصبی-فازی انتخاب شده و ضریب همبستگی در مرحله آموزش و تست.

| مدل | تابع عضویت | الگوریتم | تابع محرک | شماره مدل | تعداد تابع عضویت | (R) مرحله آموزش | (R) مرحله تست |
|--------|------------|-------------------|--------------|-----------|------------------|-----------------|---------------|
| CANFIS | Bell | Momentum | Tanh Axon | ۹ | ۲ | ۰/۸۰۸ | ۰/۸۸۹ |
| | | | Sigmoid Axon | ۱۰ | ۲ | ۰/۷۴۳ | ۰/۸۰۰ |
| | | Levenberg-Marquat | Tanh Axon | ۱۱ | ۲ | ۰/۸۶۴ | ۰/۸۹۰ |
| | | | Sigmoid Axon | ۱۲ | ۲ | ۰/۸۴۱ | ۰/۸۹۳ |
| | Gaussian | Momentum | Tanh Axon | ۱۳ | ۲ | ۰/۸۱۲ | ۰/۸۹۶ |
| | | | Sigmoid Axon | ۱۴ | ۲ | ۰/۷۴۸ | ۰/۸۱۹ |
| | | Levenberg-Marquat | Tanh Axon | ۱۵ | ۲ | ۰/۵۳۹ | ۰/۸۴۸ |
| | | | Sigmoid Axon | ۱۶ | ۲ | ۰/۸۱۳ | ۰/۸۹۸ |

تعداد لایه پنهان، تعداد نرون‌های لایه پنهان و تعداد نرون‌های لایه خروجی) از شبکه عصبی مصنوعی پرسپترون چند لایه،

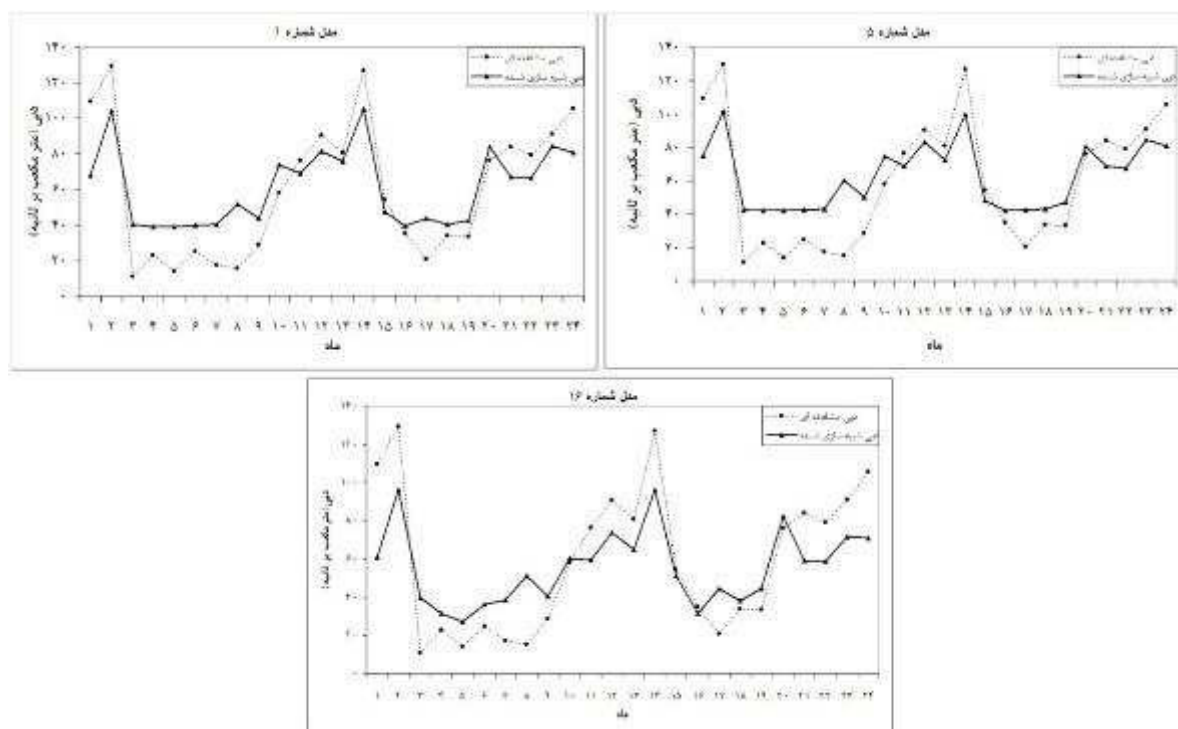
با توجه به جدول‌های (۳) و (۴)، مدل شماره (۱) با ساختار (۱-۳-۵) (از چپ به راست شامل تعداد نرون‌های لایه ورودی،

3. Mean Absolut Error
4. Root Mean Square Error

1. Mean Square Error
2. Normalized Mean Square Error

شبیه‌سازی شده و دبی مشاهده‌ای برای هر کدام از سه مدل بهینه انتخاب شده و برای داده‌های ۲۴ ماهه دوره تست شبکه (سال ۸۹ و ۹۰) در شکل (۴) آورده شده است. همچنین ضرایب نشان‌دهنده کارایی مدل‌های بهینه انتخاب شده در جدول (۵) آورده شده است.

مدل شماره (۵) با ساختار (۱-۵-۵-۵) از شبکه عصبی مصنوعی شعاعی و مدل شماره (۱۶) با ساختار (۱-G-۲-۵) (از چپ به راست شامل تعداد نرون‌های لایه ورودی، تعداد تابع عضویت، نوع تابع عضویت (G=Guassian) و تعداد نرون لایه خروجی) از شبکه عصبی-فازی به عنوان مدل‌های بهینه در شبیه‌سازی رواناب ماهانه انتخاب شدند. نمودار دبی



شکل ۴. دبی ماهانه مشاهده و شبیه‌سازی شده مدل‌های بهینه انتخاب شده (۱، ۵ و ۱۶).

جدول ۵. ضرایب کارایی مدل‌های بهینه انتخاب شده.

| شماره مدل | R | MSE | NMSE | MAE | RMSE |
|-----------|-------|--------|-------|-------|-------|
| ۱ | ۰/۹۲۳ | ۰/۰۱۴۵ | ۰/۲۷۶ | ۰/۱۰۳ | ۰/۱۲۰ |
| ۵ | ۰/۹۲۴ | ۰/۰۱۶۹ | ۰/۳۲۲ | ۰/۱۱۳ | ۰/۱۳۰ |
| ۱۶ | ۰/۸۹۸ | ۰/۰۱۸۴ | ۰/۳۵۱ | ۰/۱۱۴ | ۰/۱۳۶ |

بالخروجی با استفاده از پارامترهای اقلیمی ذکر شده انتخاب می‌شود. همچنین نتایج، نشان دهنده برتری شبکه عصبی پرسپترون چندلایه (MLP) نسبت به شبکه عصبی مصنوعی شعاعی (RBF) و شبکه عصبی-فازی (CANFIS) است و ترکیب منطق فازی با شبکه عصبی نتوانست دقت مدل را در شبیه‌سازی بارش-رواناب افزایش دهد. همچنین نتایج جدول (۳) برتری الگوریتم مومنتوم و تابع محرک تانژانت

با توجه به نتایج جدول‌های (۳)، (۴) و (۵)، اگرچه مدل شماره (۵) از نظر ضریب همبستگی بهترین مدل می‌باشد؛ ولی مدل شماره (۱) با توجه به مقدار ضرایب تعیین کننده خطا (MSE)، NMSE، MAE و RMSE به ترتیب برابر با ۰/۰۱۴۵، ۰/۲۷۶، ۰/۱۰۳ و ۰/۱۲۰ و کم‌تر از ۲ مدل دیگر) و همچنین ساده‌تر بودن ساختار مدل (نصیری و یمانی، ۱۳۸۸) به عنوان بهترین مدل شبکه عصبی برای شبیه‌سازی دبی ماهانه حوضه آبخیز

منابع

اسکندری نیا، ع.، نظریور، ه.، ضیاء تبار احمدی، م.، خ.، تیموری، م. و ذاکرمشفق، م. (۱۳۹۰). بررسی تأثیر عامل بارش پیشین در برآورد جریان رودخانه توسط شبکه عصبی (مطالعه موردی: رودخانه بختیاری). *پژوهشنامه مدیریت حوزه آبخیز*، ۲(۳)، ۵۱-۶۲.

برهانی‌داریان، ع. و فاتحی‌مرج، ا. (۱۳۸۷). کاربرد شبکه عصبی مصنوعی در پیش‌بینی جریان رودخانه با استفاده از شاخص‌های اقلیمی (مطالعه موردی: حوزه آبخیز نازلوچای). *مجله دانشکده فنی دانشگاه تبریز*، ۳۵(۳)، ۵۱-۶۲.

بهروزی خزایی، ن.، امیری‌چایجان، ر.، توکلی‌هشتجین، ت. و خوش تقاضا، م. ه. (۱۳۸۶). بررسی شاخص‌های مهم خشک شدن انگور در روش خشک کردن با جریان هوای گرم به کمک شبکه‌های عصبی مصنوعی. *پژوهش کشاورزی*، ۷(۳)، ۱۵۴-۱۴۱.

جهانگیر، ع.، ا.، رائینی، م. و ضیاء احمدی، م. خ. (۱۳۸۵). شبیه‌سازی فرآیند بارش-رواناب با شبکه عصبی مصنوعی (ANN) و مقایسه با مدل HEC-HMS در حوضه معرف کارده. *مجله آب و خاک (علوم و صنایع کشاورزی)*، ۲۲(۲)، ۷۲-۸۴.

دستورانی، م. ت.، شریفی‌داریانی، ح. و طالبی، ع. (۱۳۹۰). کارایی شبکه‌های عصبی مصنوعی و سیستم استنتاج عصبی-فازی تطبیقی در مدل‌سازی بارش-رواناب در حوزه آبخیز سد زاینده‌رود. *آب و فاضلاب*، ۲۲(۴)، ۱۱۴-۱۲۵.

دهقانی، م.، مرید، س. و نوروزی، ع. ا. (۱۳۸۹). ارزیابی شبیه‌سازی رواناب حوضه‌های برفی با مدل شبیه‌سازی (SRM) و شبکه عصبی برای برآورد انرژی برقی در مواجهه با کمبود آمار. *تحقیقات منابع آب ایران*، ۶(۳)، ۱۲-۲۴.

رضایی، ع.، مهدوی، م.، لوکس، ک.، فیض‌نیا، س. و مهدیان، م. ح. (۱۳۸۶). مدل‌سازی منطقه‌ای دبی‌های اوج در زیر حوضه‌های آبخیز سد سفیدرود با استفاده از شبکه عصبی مصنوعی. *علوم و فنون کشاورزی و منابع طبیعی*، ۱۱(۱)، ۲۵-۳۹.

زارع‌ایبانه، ح. و بیات‌ورکشی، م. (۱۳۹۰). ارزیابی مدل‌های هوشمند عصبی و تجربی در تخمین رواناب سالانه. *نشریه آب و خاک (علوم و صنایع کشاورزی)*، ۲۵(۲)، ۳۶۵-۳۷۹.

صفاری، ا.، قنوتی، ع. ا.، بهشتی‌جاوید، ا. و حسینی، ه. (۱۳۹۲). برآورد و پهنه‌بندی رواناب ناشی از بارش‌های حداکثر ۲۴ ساعته با استفاده از روش

هایبولیک در شبکه عصبی مصنوعی و جدول (۴) نیز برتری دو تابع عضویت از نوع گوسن را در شبکه عصبی-فازی برای شبیه‌سازی رواناب ماهانه نشان می‌دهد و با نتایج مطالعات زارع‌ایبانه و ورکشی (۱۳۹۰)، بهروزی خزایی و همکاران (۱۳۸۶)، توران و یوردوسو^۱ (۲۰۰۹)، مقدم‌نیا و همکاران (۲۰۰۹) مطابقت دارد.

۵. نتیجه‌گیری

به دلیل ماهیت پیچیده و غیرخطی فرآیند بارش-رواناب و همچنین توانایی بالای روش نوین هوش محاسباتی در مدل‌سازی و حل سیستم‌های غیرخطی و پیچیده، در این پژوهش به ارزیابی کارایی و دقت مدل‌های هوشمند مختلف رایج در شبیه‌سازی بارش-رواناب پرداخته شد. به دلیل اهمیت بالای عوامل اقلیمی به ویژه بارندگی و تبخیر در تعیین بیلان آبی، عوامل مذکور در مقیاس ماهانه جهت شبیه‌سازی دبی ماهانه در حوضه آبخیز بالخلوچای، استفاده شد و کارایی مدل‌های شبکه عصبی مصنوعی (MLP و RBF) و شبکه عصبی-فازی (CANFIS) مورد بررسی قرار گرفت. در نهایت با توجه به ضرایب کارایی مدل، شبکه عصبی مصنوعی پرسپترون چندلایه با تعداد سه لایه مخفی و سه نرون در هر لایه مخفی به عنوان دقیق‌ترین مدل برای تخمین دبی ماهانه انتخاب شد. نتایج این پژوهش می‌تواند برای پیش‌بینی‌های آتی، مطالعه و مدیریت حوضه‌های آبخیز مشابه و مجاور و مدیریت مخزن سد یامچی که از آب این حوضه تغذیه شده و دارای کاربری کشاورزی و شرب می‌باشد، مورد استفاده قرار گیرد. همچنین پیشنهاد می‌شود جهت افزایش دقت مدل‌سازی و پیش‌بینی از داده‌های مختلف اقلیمی مؤثر بر رواناب در مقیاس روزانه استفاده شود.

سپاسگزاری

بدین وسیله از زحمات بخش مطالعات آب‌های سطحی شرکت آب منطقه‌ای استان اردبیل به دلیل ارائه آمار و داده‌های مورد نیاز این پژوهش کمال تشکر و قدردانی به عمل می‌آید.

۱. Turan and Yurdusev

- networks and xinanjiang model. *Neurocomputing*, 72(13-15), 2873-2883.
- Jahangir, A., Raeni, M., Ziatabar Ahmadi, M. & Akbarpoor, A. (2005) Simulating of rainfall-runoff process using the artificial neural network in Kardeh watershed. *5th Conference the Hydraulic of Iran*, Bahonar Shahid University of Engineering, Kerman, Iran.
- Mendez, M. C., Manteiga, W. G., Bande, M. F., Sanchez, J. M. P. & Calderon, R. L. (2004) Modeling of the monthly and daily behavior of the runoff of the xallas river using box-jenkins and neural networks methods. *Journal of Hydrology*, 296(1), 38-58.
- Moghaddamia, A., Ghafari Gousheh, M. & Piri, J. (2009) Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques. *Advances in Water Resources*, 32(1), 89-97.
- Mason, J. C., Price, R. K. & Temme, A. (1996) A neural network model of rainfall-runoff using radial basis functions. *Journal of Hydraulic Research*, 34(4), 537-548.
- Nilsson, P., Uvo, C. B. & Berndtsson, R. (2006) Monthly runoff simulation: comparing and combining conceptual and neural network models. *Journal of Hydrology*, 321(1-4), 344-363.
- Rajurkar, M. P., Kothiyari, U. C. & Chaube, C. C. (2004) Modeling of the daily rainfall runoff relationship with artificial neural network. *Journal of Hydrology*, 285(1-4), 96-113.
- Turan, M. E. & Yurdusev, M. A. (2009) River flow estimation from upstream flow records by artificial intelligence methods. *Journal of Hydrology*, 369(1), 71-77.
- Sajikumar, N. & Thandaveswara, B. S. (1999) A non-linear rainfall-runoff model using artificial neural networks. *Journal of Hydrology*, 216(1), 32-55.
- SCS-CN (حوضه سد یامچی). فصلنامه بین‌المللی انجمن جغرافیای ایران، ۱۱(۳۸)، ۲۰۱-۲۱۷.
- صف‌شکن، ف.، پیرمردیان، ن. و افشین شریفان، ر. (۱۳۹۰) شبیه‌سازی آبنمود بارش-رواناب با توجه به الگوی زمانی بارش و استفاده از شبکه عصبی مصنوعی در حوزه آبخیز معرف کسلیان. *مجله علمی-پژوهشی علوم و مهندسی آبخیزداری ایران*، ۵(۱۵)، ۱-۱۰.
- فتاحی، ا.، دلاور، م. و نوحی، ک. (۱۳۹۱) پیش‌بینی جریان رودخانه‌های کارون شمالی با استفاده از شبکه عصبی مصنوعی. *فصلنامه تحقیقات جغرافیایی*، ۲۷(۱)، ۵۱-۷۷.
- گیوه‌چی، م. و باقرنژاد، ح. (۱۳۹۱) مقایسه و برآورد رواناب سالانه با استفاده از روش‌های تجربی و شبکه عصبی. *نهمین کنگره بین‌المللی مهندسی عمران*، دانشگاه صنعتی اصفهان.
- مهدوی، م. (۱۳۹۰) *مدیریت کاربردی*، جلد دوم، چاپ چهارم، تهران، دانشگاه تهران.
- نصری، م.، مدرس، ر. و دستورانی، م. ت. (۱۳۸۸) کاربرد مدل شبکه عصبی در برآورد رواناب (مطالعه موردی: حوزه آبخیز پلاسجان-حوزه آبخیز زاینده‌رود). *آمایش محیط*، ۲(۵)، ۲۳-۳۷.
- نصیری، ع. و یمانی، م. (۱۳۸۸) تجزیه و تحلیل شبکه‌های عصبی مصنوعی ژئومورفولوژیکی در برآورد رواناب مستقیم (حوضه جاجرود، زیرحوضه امامه). *پژوهش‌های جغرافیای طبیعی*، ۴۱(۶۸)، ۳۳-۴۴.
- سایت اداره کل آب منطقه‌ای استان اردبیل (www.arrw.ir).
- Ahmad, S. & Simonovic, S. P. (2005) An artificial neural network model for generating hydrograph from hydro-meteorological parameters. *Journal of Hydrology*, 315(1-4), 236-251.
- Aqil, M., Kita, I., Yano, A. & Nishiyama, S. (2007) A comparative study of artificial neural networks and neuro-fuzzy in continuous modeling of the daily and hourly behaviour of runoff. *Journal of Hydrology*, 337(1-2), 22-34.
- Coulibaly, P., Anctil, F. & Bobee, B. (2000) Multivariate reservoir inflow forecasting using temporal neural networks. *Journal of Hydrologic Engineering*, 5(2), 115-123.
- Fernando, D. A. & Jayawardena, A. W. (1998) Runoff forecasting using RBF networks with OLS algorithm. *Journal of Hydrologic Engineering*, 3(3), 203-209.
- Ghumman, A. R., Ghazaw, Y. M., Sohail, A. R. & Watanabe, K. (2011) Runoff forecasting by artificial neural network and conventional model. *Alexandria Engineering Journal*, 50(4), 345-350.
- Ju, Q., Yu, Z., Hao, Z., Ou, G., Zhao, J. & Liu, D. (2009) Division-based rainfall-runoff simulations with bp neural