

کارایی شبکه‌های عصبی مصنوعی و سیستم استنتاج عصبی - فازی تطبیقی در مدل‌سازی بارش - رواناب در حوضه آبخیز سد زاینده‌رود

محمد تقی دستورانی^۱ حامد شریفی دارانی^۲ علی طالبی^۳ علیرضا مقدم‌نیا^۴

(دریافت ۸۸/۱۲/۱۶ پذیرش ۹۰/۲/۱۹)

چکیده

در دهه‌های اخیر به دلیل اهمیت یافتن مسئله آب و همین‌طور افزایش تمایل به محاسبه مقدار رواناب حاصل از بارش، توسعه و اجرای روش‌های مناسب برای پیش‌بینی رواناب از روی داده‌های بارش به مسئله‌ای ضروری تبدیل شده است. یکی از این روش‌ها که در بسیاری از رشته‌ها از جمله هیدرولوژی توسعه یافته است، استفاده از روش‌های محاسبات نرم نظیر منطق فازی و شبکه‌های عصبی مصنوعی است. در این تحقیق سعی گردید کارایی شبکه عصبی مصنوعی و سیستم استنتاج عصبی - فازی تطبیقی به منظور برآورد بارش - رواناب در حوضه سد زاینده‌رود، مورد ارزیابی قرار گیرد. به این منظور ابتدا با بهره‌گیری از نرم‌افزار Wingamma داده‌ها و پارامترهای موجود مورد بررسی و تجزیه و تحلیل قرار گرفت و پارامترهای ورودی مناسب به علاوه تعداد مناسب داده برای آموزش شبکه، تعیین گردید. سپس با استفاده از آمار روزانه بارش - رواناب، کارایی شبکه عصبی مصنوعی و سیستم عصبی - فازی در تخمین رواناب حاصل از بارش مورد بررسی قرار گرفت. در ادامه میزان دقت و صحت این دو روش با بهره‌گیری از روش‌های آماری، مقایسه شد. نتایج حاصل از این مطالعه نشان داد که شبکه عصبی مصنوعی و سیستم فازی - عصبی در شرایط مختلف و با ترکیب‌های مختلف پارامترهای ورودی، نتایج متفاوتی از خود نشان می‌دهند ولی در کل این دو روش به میزان قابل قبولی قادر به تخمین رواناب حاصل از بارش با به کارگیری پارامترهای ورودی مناسب و استفاده از ساختارهای مناسب شبکه عصبی مصنوعی و شبکه عصبی - فازی، هستند.

واژه‌های کلیدی: شبکه عصبی مصنوعی، سیستم استنتاج عصبی - فازی تطبیقی، بارش - رواناب، حوضه آبخیز سد زاینده‌رود، الگوریتم ژنتیک، آزمون گاما

Evaluation of the Application of Artificial Neural Networks and Adaptive Neuro-Fuzzy Inference Systems for Rainfall-Runoff Modelling in Zayandeh_road Dam Basin

Mohammad Taghi Dastorani¹ Hamed Sharifi Darani² Ali Talebi³ Alireza Moghadam Nia⁴

(Received Mar. 6, 2009 Accepted May. 9, 2011)

Abstract

During recent few decades, due to the importance of the availability of water, and therefore the necessity of predicting run off resulted from rain fall there has been an increase in developing and implementation of new suitable method for prediction of run off using precipitation data. One of these approaches that have been developed in several areas of sciences including water related fields, is soft computing techniques such as artificial neural networks and fuzzy logic systems. This research was designed to evaluate the applicability of artificial neural network and adaptive neuro -fuzzy inference system to model rainfall-runoff process in Zayandeh_road dam basin. It must be mentioned that, data have been analysed using Wingamma software, to select appropriate type and number of training input data before they can be used in the models. Then, it has been tried to evaluated applicability of artificial neural networks and neuro-fuzzy techniques to predict runoff

1. Assoc. Prof., Dept. of Natural Resources and Desert Studies, Yazd University, Yazd (Corresponding Author) (+98 351) 8210312 mdastorani@yazduni.ac.ir

2. Former Grad. Student of Watershed Management, Dept. of Natural Resources and Desert Studies, Yazd University, Yazd

3. Assist. Prof. of Watershed Management, Dept. of Natural Resources and Desert Studies, Yazd University, Yazd

4. Assist. Prof., Dept. of Natural Resources, Zabol University, Zabol

۱- دانشیار، دانشکده منابع طبیعی و کویر شناسی، دانشگاه یزد (نویسنده مسئول) ۸۲۱۰۳۱۲ (+۹۸ ۳۵۱) ۸۲۱۰۳۱۲ mdastorani@yazduni.ac.ir

۲- دانش آموزانه کارشناسی ارشد آبخیزداری، دانشکده منابع طبیعی و کویر شناسی، دانشگاه یزد

۳- استادیار، دانشکده منابع طبیعی و کویر شناسی، دانشگاه یزد

۴- استادیار، دانشکده منابع طبیعی، دانشگاه زابل

generated from daily rainfall. Finally, the accuracy of the results produced by these methods has been compared using statistical criterion. Results taken from this research show that artificial neural networks and neuro-fuzzy technique presented different outputs in different conditions in terms of type and number of inputs variables, but both method have been able to produce acceptable results when suitable input variables and network structures are used.

Keywords: Artificial Neural Network, Adaptive Neuro – Fuzzy Inference System, Rainfall-Runoff, Zayandeh_ rood Dam Catchment, Genetic Algorithm, Gamma Test.

۱- مقدمه

عمده ترین منبع تولید رواناب در اکثر حوضه های جهان بارندگی است که بسته به ویژگی های مختلف فیزیوگرافی و اقلیمی حوضه های آبخیز به مقدار مشخصی رواناب تبدیل می شود. پارامترهای متعدد دخیل در تبدیل بارش به رواناب، به همراه وجود پیچیدگی های زیاد و روابط غیرخطی بین این پارامترها با یکدیگر و همچنین با ورودی ها و خروجی های سیستم آبخیز، باعث شده پیش بینی دقیق مقدار رواناب حاصل از هر بارندگی بسیار مشکل باشد. در دهه های گذشته به دلیل وجود چنین مشکلاتی هیدرولوژیست ها و محققان سعی کرده اند مدل های ساده شده و تجربی را برای پیش بینی و محاسبه خصوصیات مختلف و مهم رواناب مانند دبی اوج سیلاب، زمان وقوع دبی اوج و غیره به کار گیرند. استفاده از این روشها علی رغم سادگی، دارای خطای زیادی در برآورد است و در بسیاری از مناطق نمی توان بر نتایج حاصل از آنها تکیه و استناد کرد. به همین علت، در دهه های اخیر سعی شده روشهایی مورد استفاده قرار گیرند که بتوانند شرایط طبیعی را تا حدودی درک کنند و نتایج حاصل از آنها از دقت و صحت مناسبی برخوردار باشند. یکی از روشهایی که در بسیاری از علوم از جمله هیدرولوژی توسعه یافته است، استفاده از روشهای محاسبات نرم نظیر منطق فازی، شبکه های عصبی مصنوعی و یا ترکیبی از این دو روش است.

اکبرپور و همکاران در سال ۱۳۸۲ در تحقیقی پس از بررسی های به عمل آمده اعلام کردند که نتایج حاصل از شبکه عصبی مصنوعی در مقایسه با مدل HEC-HMS از دقت بالاتری برخوردار است [۱]. دستورانی در سال ۱۳۸۶ به بررسی توانایی ها و ضعفهای شبکه عصبی مصنوعی در مدل سازی جریان های رودخانه ای پرداخت. نتایج نشان داد که شبکه های دینامیک در بحث پیش بینی بهنگام، کارایی بهتری دارند در حالی که شبکه های پرسپترون چندلایه در ترکیب با نرم افزارهای دیگر نسبت به کاربرد تنهای آنها به مراتب بهتر عمل می کنند [۲]. نورانی و همکاران در سال ۱۳۸۷ به مقایسه تکنیک های جدید مدل سازی هیدرولوژیکی پرداختند. نتایج حاصل از این تحقیق بیانگر آن است که روش استنتاج فازی دارای خطای کمتری نسبت به روش شبکه عصبی مصنوعی است. به علاوه در این تحقیق بیان شده است که مدل

فازی - عصبی نتایج بهتری از دو روش دیگر ارائه می دهد. به طوری که ضریب کارایی سیستم عصبی - فازی، استنتاج فازی و شبکه عصبی مصنوعی به ترتیب ۰/۹۷، ۰/۹۲ و ۰/۸۷ بوده است [۳]. گالی و همکاران^۱ در سال ۲۰۰۱ برای پیش بینی کوتاه مدت رواناب از شبکه عصبی مصنوعی در ترکیب با منطق فازی بهره گرفتند که نتایج به دست آمده را دارای صحت و ارزش بیشتری نسبت به نتایج حاصل از شبکه عصبی مصنوعی گزارش کردند [۴]. چانگ و همکاران^۲ در سال ۲۰۰۱ از شبکه های عصبی پس انتشار برای پیش بینی جریان های سیلابی استفاده نمودند. آنها نتیجه گرفتند که دقت و صحت نتایج حاصل از این مدل مناسب می باشد [۵].

همچنین کسکین و همکاران^۳ در سال ۲۰۰۳ از منطق فازی برای پیش بینی مقدار رواناب با استفاده از داده های بارش در رودخانه دیم^۴ در منطقه مدیترانه میانی^۵ استفاده کردند. نتایج به دست آمده حاکی از آن بوده که پیش بینی های انجام شده توسط منطق فازی با داده های تاریخی همبستگی خوبی داشته و به طور کلی، نتایج مناسب و رضایت بخش بوده است [۶].

ماترئا^۶ در سال ۲۰۰۴ با استفاده از ترکیب شبکه های عصبی مصنوعی و منطق فازی موفق به ساخت مدلی گردید که می توانست با در اختیار داشتن آمار بارندگی و برخی از خصوصیات فیزیکی حوضه، رواناب را در یک زمان مناسب پیش بینی کند و به منظور ایجاد سیستم های هشدار سیل مورد استفاده قرار گیرد. وی صحت داده های پیش بینی شده را خوب برآورد کرد [۷]. ناواک و همکاران^۷ در سال ۲۰۰۴ به بررسی مهارت ها و توانایی های محاسبات فازی در پیش بینی به موقع جریان ها و تداوم آنها در حوضه آبخیز نارد^۸ در هند پرداختند. آنها به این منظور از مدل های بارش - رواناب بر اساس منطق فازی استفاده کردند که در نهایت نتیجه این مدل سازی را خیلی خوب دانستند. آنها در این تحقیق اعلام کردند که منطق فازی توانایی بالایی برای یافتن ارتباطات پنهان بین رخدادهای هیدرولوژیکی مثل بارش و رواناب دارد [۸].

¹ Goali et al.

² Chang et al.

³ Keskin et al.

⁴ Dim

⁵ Middle Mediterranean

⁶ Matreata

⁷ Navak et al.

⁸ Narmad

عقیل و همکاران^۱ در سال ۲۰۰۷ به بررسی مقایسه‌ای شبکه عصبی مصنوعی و سیستم عصبی- فازی در مدل‌سازی پیوسته رفتار روزانه و ساعتی رواناب پرداختند. نتایج حاصل از این مطالعه کارایی بهتر سیستم عصبی- فازی را نشان می‌دهد [۹].

در این مطالعه توانایی شبکه عصبی مصنوعی و سیستم عصبی- فازی در پیش‌بینی رواناب حاصل از بارش مورد مقایسه قرار گرفت. به عبارت دیگر فرضیات مورد نظر یا سؤالات پژوهشی در این تحقیق به این شرح بوده است که: اولاً آیا تکنیک‌های جدید مبتنی بر هوش مصنوعی از جمله شبکه عصبی مصنوعی و سیستم استنتاج عصبی- فازی تطبیقی اساساً قادر به مدل‌سازی فرایند بارش- رواناب هستند؟ و ثانیاً کدام یک از دو تکنیک ذکر شده در مدل‌سازی بارش رواناب توانایی بیشتر دارد؟ به این منظور ابتدا با استفاده از نرم‌افزار Wingamma بهترین ترکیب ورودی از بین پارامترهای ورودی موجود و همچنین بهترین اندازه تعداد داده‌های مربوط به مجموعه آموزش شبکه‌ها تعیین و سپس با استفاده از شبکه عصبی مصنوعی و سیستم عصبی- فازی، فرایند بارش- رواناب مدل‌سازی گردید. در تحقیقات گذشته اغلب یک روش هوش مصنوعی با یک یا چند روش سنتی مقایسه می‌گردید ولی در این تحقیق اولاً دو روش هوش مصنوعی با هم مقایسه شد و ثانیاً تعداد و ترکیب ورودی‌ها برای آموزش و آزمایش نیز با نرم‌افزارهای هوش مصنوعی تعیین گردید.

شاهرخ و اسکندری که دارای طول دوره آماری ۲۹ سال شامل داده‌های بارش و رواناب روزانه هستند.

در بین ایستگاههای کلیماتولوژی نیز تنها آمار ایستگاه قلعه شاهرخ دارای داده‌های مناسب و با طول دوره آماری کافی بوده و در بقیه ایستگاهها علاوه بر وجود نواقص زیاد آماری، دوره برداشت آمار نیز بسیار کوتاه بود. طول دوره آماری مناسب در ایستگاههای قلعه شاهرخ و اسکندری و همچنین موقعیت مناسب آنها در حوضه آبخیز مورد مطالعه، باعث شد که برای مدل‌سازی از آمار این دو ایستگاه استفاده گردد. در این دو ایستگاه آمار بارش روزانه، رواناب روزانه، دمای حداقل، دمای حداکثر و دمای متوسط ماهانه در طول دوره آماری ۲۹ ساله یعنی از سال ۱۳۵۵ تا ۱۳۸۴ وجود دارد. ولی آمار مربوط به رطوبت نسبی متوسط ماهیانه در ساعات ۶:۳۰، ۱۲:۳۰ و ۱۸:۳۰ تنها مربوط به سالهای ۱۳۷۵ تا ۱۳۸۴ معادل ۹ سال وجود دارد. بنابراین برای استفاده از داده‌های رطوبت نسبی به عنوان ورودی باید دوره آماری سایر پارامترها مانند دبی و رواناب بر اساس دوره آماری رطوبت نسبی تنظیم شود. با این توضیح، تعداد داده‌ها اگر از آمار رطوبت نسبی استفاده نشود برابر با ۱۰۹۸۰ و در حالی که از آن استفاده شود برابر با ۳۲۹۴ عدد است. نمای کلی حوضه مورد مطالعه در شکل ۱ آورده شده است.

۲- مواد و روشها

این مطالعه در حوضه آبخیز سد زاینده‌رود صورت گرفت که در واقع زیرحوضه‌ای از حوضه کاملاً بسته رودخانه زاینده‌رود واقع در جنوب غربی استان اصفهان است. مساحت این حوضه ۴۴/۴۲۶۵ کیلومتر مربع است که بین عرضهای جغرافیایی ۱۸°، ۳۲° تا ۱۰°، ۳۳° شمالی و در محدوده طولهای جغرافیایی ۰۳°، ۵۰° تا ۴۰°، ۵۰° شرقی قرار دارد. طول عمومی این حوضه در راستای شمالی- جنوبی و عرض آن در راستای غربی- شرقی است. در این مطالعه حوضه آبخیز سد زاینده‌رود به سه زیرحوضه اسکندری، قلعه شاهرخ و مرکزی تقسیم شد که از این میان، زیرحوضه مرکزی به دلیل نبود ایستگاه مناسب و رودخانه بزرگ و دائمی در آن و همچنین قرار گرفتن دریاچه سد در این زیرحوضه، مورد بررسی قرار نگرفت. در حوضه آبخیز سد زاینده‌رود ایستگاههای مختلف هیدرومتری و کلیماتولوژی وجود دارند که تقریباً در سرتاسر حوضه پراکنده هستند. اکثر این ایستگاهها دارای طول دوره آماربرداری کوتاه مدت (حداکثر ۸ سال) هستند، به جز ایستگاههای هیدرومتری قلعه



شکل ۱- نمای کلی حوضه آبخیز سد زاینده‌رود

¹ Agil et al.

در این مطالعه پس از برطرف کردن نواقص احتمالی، داده‌ها با استفاده از رابطه ۱ بین مقادیر صفر و یک نرمال شده و برای ورود به مدل‌ها آماده گردیدند

$$x_i = (x_i - x_{\min}) / (x_{\max} - x_{\min}) \quad (1)$$

که در این رابطه

x_{\min} و x_{\max} به ترتیب مقادیر حداکثر و حداقل سری آماری و x_i مقدار هر کدام از داده‌های موجود در سری آماری است.

پس از بررسی‌های اولیه، پارامترهای موجود در هشت بردار ورودی (بارش، دمای حداقل، دمای حداکثر، دمای متوسط و رطوبت نسبی در ساعات ۶:۳۰، ۱۲:۳۰ و ۱۸:۳۰ و دبی پیشین) و یک بردار خروجی (دبی) مرتب شدند. برای تعیین ترکیب پارامترهای ورودی به مدل، از نرم‌افزار WinGamma استفاده شد. نرم‌افزار WinGamma در اصل تمام ترکیب‌های ورودی محتمل را مورد بررسی قرار می‌دهد و میزان صحت و دقت مدل‌سازی را در ترکیب‌های مختلف تعیین می‌کند. پارامتر اصلی مورد مقایسه در این نرم‌افزار مقدار گاما است که برای اطمینان بیشتر در این مطالعه از خطای استاندارد نیز استفاده شد. بنابراین ابتدا با استفاده از آزمون گاما، بردارهای ورودی که دارای اثر مثبت و یا منفی بر روی مدل‌سازی بودند تعیین گردید و سپس با استفاده از الگوریتم ژنتیک ترکیب‌های مختلف بردارهای ورودی در مدل‌سازی مورد آزمون قرار گرفت. در ادامه با مقایسه نتایج به‌دست آمده، بهترین ترکیب ورودی برای مدل‌سازی انتخاب شد. البته در این تحقیق برای اطمینان از نتایج حاصله از نرم‌افزار، از روش آزمون و خطا نیز استفاده شد. قابلیت دیگر WinGamma تعیین بهترین اندازه مجموعه آموزش شبکه با استفاده از گزینه M-test است. نرم‌افزار در این مورد نیز اندازه‌های مختلف برای مجموعه آموزش شبکه را مورد بررسی قرار می‌دهد که کاربر با در نظر گرفتن مقدار گاما و خطای استاندارد می‌تواند بهترین اندازه را تشخیص دهد.

به‌منظور مدل‌سازی از شبکه عصبی مصنوعی پیشرو با دو لایه مخفی استفاده شد که کدنویسی آن در محیط MATLAB صورت گرفت. با استفاده از آزمون و خطا، تابع انتقال لایه اول tansig و تابع انتقال لایه دوم purelin در نظر گرفته شد. برای آموزش شبکه آزمون و خطا نشان داد که trainlm جواب بهتر و سریع‌تری را ارائه می‌دهد.

نتایج حاصل از شبکه پیشرو با نتایج حاصل از رگرسیون خطی - محلی، رگرسیون خطی - محلی دینامیک، شبکه عصبی BFGS^۱ و شبکه دولایه پس انتشار مقایسه شد.

^۱ Broyden-Fletcher-Goldfarb- Shanno (BFGS)

در این تحقیق، علاوه بر شبکه عصبی مصنوعی از سیستم عصبی - فازی نیز استفاده گردید. کد مربوط به این سیستم همانند کد شبکه عصبی مصنوعی در محیط MATLAB نوشته و اجرا شد. تابع عضویت به‌کار رفته شده در این مطالعه از نوع زنگوله‌ای انتخاب گردید و نتایج با سایر توابع عضویت مورد مقایسه قرار گرفت.

برای برآورد مقدار رواناب ابتدا از بردار بارش به‌تنهایی به‌عنوان ورودی استفاده و سپس بردارهای ورودی مختلف به آن اضافه شد. ولی به‌دلیل عدم توانایی شبکه در مدل‌سازی، پارامترهای دبی پیشین در فاصله زمانی یک، دو و سه روز پیش به‌عنوان بردارهای ورودی جدید به شبکه عصبی مصنوعی و شبکه عصبی - فازی معرفی گردیدند.

برای مقایسه نتایج حاصل از مدل‌ها از سه معیار ضریب همبستگی (R^2)، ضریب کارایی (r^2) و جذر میانگین مربعات خطا (RMSE) استفاده شد (روابط ۲، ۳ و ۴).

$$R^2 = \frac{\sum (o_i - \bar{o})(p_i - \bar{p})}{\sqrt{\sum (o_i - \bar{o})^2 \sum (p_i - \bar{p})^2}} \quad (2)$$

$$RMSE = \left(\frac{\sum_{i=1}^n (p_i - o_i)^2}{n} \right)^{1/2} \quad (3)$$

$$r^2 = 1 - \left(\frac{\sum_{i=1}^n (o_i - p_i)^2}{\sum_{i=1}^n (o_i - \bar{o})^2} \right) \quad (4)$$

که در این روابط

\bar{o} و \bar{p} به ترتیب مقادیر مشاهده شده و شبیه‌سازی شده، \bar{o} و \bar{p} میانگین مقادیر مشاهده شده و شبیه‌سازی شده و n تعداد نمونه‌ها است.

۳- نتایج و بحث

در این مطالعه ابتدا داده‌ها مورد بررسی قرار گرفت و نواقص آماری تکمیل گردید. مشخصات آماری داده‌های مورد استفاده در جدول ۱ آورده شده است.

سپس با استفاده از نرم‌افزار WinGamma و با در نظر گرفتن دو پارامتر گاما و خطای استاندارد (SE) و همچنین از دو روش ژنتیک و آزمون گاما اقدام به تعیین بهترین ترکیب ورودی از بین ترکیب‌های ورودی مختلف و همچنین بهترین تعداد داده‌های آموزش

جدول ۱- مشخصات آماری داده‌های ایستگاه قلعه شاهرخ و اسکندری

ایستگاه	پارامتر آماری	بارش	دبی	حداقل		متوسط		رطوبت	
				دمای روزانه (C)	حداکثر دمای روزانه (C)	دمای روزانه (C)	متوسط دمای روزانه (C)	نسبی در ساعت	رطوبت نسبی در ساعت
قلعه شاهرخ	میانگین	۱/۰۷	۴۲/۲۱	-۷/۳۱	۲۳/۱۴	۹/۸۳	۳۶/۵۸	۳۶/۷۹	۶۶
	انحراف معیار	۴/۶۹	۴۱/۲۶	۱۳/۱۵	۱۰/۰۸	۸/۷	۲۳/۸۸	۲۳/۲	۱۱/۸۸
	حداکثر	۸۰	۶۴۶	۱۰	۳۸	۲۶/۵	۸۹	۸۸	۸۷
	حداقل	۰	۰/۴	-۴۸	-۱۴	-۱۲/۴	۰	۱۰	۲۱
اسکندری	میانگین	۱/۱۴	۴/۲۱	-۷/۳۱	۲۳/۱۴	۹/۸۳	۳۶/۵۸	۳۶/۷۹	۶۶
	انحراف معیار	۹/۹۳	۶/۰۲	۱۳/۱۵	۱۰/۰۸	۸/۷	۲۳/۸۸	۲۳/۲	۱۱/۸۸
	حداکثر	۹۲/۵	۱۰۵/۱۵	۱۰	۳۸	۲۶/۵	۸۹	۸۸	۸۷
	حداقل	۰	۰	-۴۸	-۱۴	-۱۲/۴	۰	۱۰	۲۱

جدول ۲- نتایج حاصل از الگوریتم ژنتیک، آزمون گاما و M-test

ایستگاه	ترکیب ورودی	الگوریتم ژنتیک		آزمون گاما		اندازه مجموعه آموزش (% از کل داده‌ها)
		SE	Gamma	SE	Gamma	
اسکندری	P, T(mean), T(max) P, RH(۶:۳۰),	۱۱۰/۷×۱۰ ^{-۵}	۱۱۰/۷×۱۰ ^{-۵}	۲۶۵/۸×۱۰ ^{-۶}	۱۱۰/۷×۱۰ ^{-۵}	۶۲
	RH(۱۲:۳۰), Rh(۱۸:۳۰), T(min)	۵۸۶/۳×۱۰ ^{-۶}	۵۸۶/۳×۱۰ ^{-۶}	۲۵۳/۶×۱۰ ^{-۶}	۵۸۶/۳×۱۰ ^{-۶}	۷۵
قلعه شاهرخ	P, T(min), T(max) P, RH(۶:۳۰),	۲۴۵/۵×۱۰ ^{-۵}	۲۴۵/۵×۱۰ ^{-۵}	۱۵۳/۸×۱۰ ^{-۶}	۲۴۵/۵×۱۰ ^{-۵}	۶۰
	RH(۱۲:۳۰), Rh(۱۸:۳۰), T(mean)	۱۰/۱۰×۱۰ ^{-۴}	۱۰/۱۰×۱۰ ^{-۴}	۵۴۴/۴×۱۰ ^{-۶}	۱۰/۱۰×۱۰ ^{-۴}	۷۴

مرحله بعد مدل‌سازی با استفاده از سیستم عصبی-فازی بود. در مورد سیستم عصبی-فازی نتایج آزمون و خطا در مورد نوع ترکیب ورودی، هنگامی که بردارهای رطوبت نسبی نیز در ترکیب ورودی قرار می‌گیرند، با نتایج حاصل از نرم‌افزار هماهنگی ندارند. به این معنی که آزمون و خطا نشان می‌دهد، هنگامی که از ترکیب ورودی معرفی شده در جدول ۲ برای مدل‌سازی با سیستم عصبی-فازی استفاده شود، نتایج دارای صحت کمتری از ترکیب‌های دیگر است. البته همانطور که گفته شد این برای حالتی است که از بردارهای رطوبت نسبی نیز در ترکیب ورودی استفاده شود. جدول ۳ نتایج حاصل از مدل‌سازی با استفاده از شبکه عصبی مصنوعی و سیستم عصبی-فازی، در بهترین حالت‌های به دست آمده با استفاده از بردارهای ورودی بارش و دما را نشان می‌دهد.

همانطور که در جدول ۳ مشاهده می‌شود، نتایج شبکه عصبی مصنوعی و سیستم عصبی-فازی بسیار به هم نزدیک است. ولی با این وجود، سیستم عصبی-فازی با کارایی بهتر از شبکه عصبی

با استفاده از روش M-test گردید. در جدول ۲ نتایج مربوط به بهترین ترکیب و اندازه مجموعه آموزش به دست آمده از روش‌های بیان شده، برای دو ایستگاه قلعه شاهرخ و اسکندری و همچنین در دو حالت وجود بردارهای رطوبت نسبی در ترکیب ورودی و بدون بردارهای رطوبت نسبی در ترکیب ورودی، ارائه شده است. این نتایج از بین تعداد زیادی داده که توسط نرم‌افزار به دست آمده بود، حاصل شد و تنها در این گزارش به معرفی بهترین نتایج حاصله اکتفا شد.

ترکیبها و اندازه‌های مجموعه آموزش در هر مورد با استفاده از آزمون و خطا نیز مورد بررسی قرار گرفتند که در مورد شبکه عصبی مصنوعی نتایج با نتایج به دست آمده از نرم‌افزار WinGamma مطابقت داشت ولی در سیستم عصبی-فازی، در برخی موارد نتایج آزمون و خطا با نتایج نرم‌افزار متفاوت بود. در ادامه با استفاده از شبکه عصبی مصنوعی اقدام به مدل‌سازی فرایند بارش-رواناب شد.

مصنوعی موفق به پیش‌بینی مقدار رواناب با استفاده از داده‌های بارندگی می‌شود.

جدول ۴ نیز نتایج حاصل از مدل‌سازی با استفاده از شبکه عصبی مصنوعی و سیستم عصبی-فازی در بهترین حالت‌های به‌دست آمده با استفاده از بردارهای ورودی بارش، دما و رطوبت نسبی را نشان می‌دهد.

نکته‌ای که در جدول ۴ ملاحظه می‌شود، این است که در حالتی که ترکیب ورودی‌های مدل از دو بردار تشکیل شده باشد، سیستم عصبی-فازی نتایج بهتری را نسبت به شبکه عصبی مصنوعی از خود ارائه می‌دهد. ولی هنگامی که ترکیب ورودی از بیشتر از سه بردار تشکیل شده باشد، نتایج سیستم عصبی-فازی نسبت به شبکه عصبی مصنوعی از دقت و صحت کمتری برخوردار است.

نتایج ارائه شده در جدول‌های ۳ و ۴ با مقادیر قابل قبول و مورد انتظار از این دو مدل بسیار تفاوت دارند و در حقیقت نتایج نشان دهنده عدم توانایی این دو مدل در برآورد رواناب با استفاده از پارامترهای معرفی شده، هستند. نمودارهای به‌دست آمده نشان

می‌دهد که این عدم توانایی هر چند مربوط به تمامی مقادیر دبی است، ولی در مورد دبی‌های حد بالا با شدت بیشتری خود را نشان می‌دهد. به همین دلیل به‌منظور کاهش اثر دبی‌های حد بالا، از میانگین‌های متحرک ۳، ۵ و ۷ روزه استفاده شد. بهترین نتایج به‌دست آمده از میانگین‌های متحرک مختلف در جدول ۵ آورده شده است.

اگر جدول ۵ با جدول‌های ۳ و ۴ مقایسه شود، مشخص است که استفاده از میانگین متحرک باعث بهبود نتایج شده است. ولی میزان خطای موجود در نتایج حاصل از هر دو مدل، در این مرحله نیز بسیار زیاد است و قابل قبول نیست. بنابراین در مرحله بعد داده‌های دبی یک، دو و سه روز قبل به‌عنوان پارامترهای ورودی جدید به هر دو مدل معرفی شدند.

در این مرحله نیز طبق روال این مطالعه ابتدا با استفاده از نرم‌افزار WinGamma اقدام به تعیین بهترین ترکیب ورودی و اندازه مجموعه آموزش گردید. ولی WinGamma نتوانست برای تعیین بهترین اندازه مجموعه آموزش کمک کند و در بیشتر موارد

جدول ۳- نتایج شبکه عصبی مصنوعی و سیستم عصبی-فازی در ترکیب ورودی بارش و دما

ایستگاه	پارامترهای ورودی	شبکه عصبی مصنوعی			عصبی-فازی		
		r^2	RMSE	%R ²	r^2	RMSE	%R ²
قلعه شاهرخ	P,T(min)	۹/۵	۴۰/۶۹	۴/۹۷	۴۰/۰۷	۹/۵۹	-۶/۳۰
	P,T(mean)	۷/۶	۴۱/۳۲	-۶/۰۵	۳۹/۷۹	۱۰/۹۲	-۶/۱۰
	P,T(max)	۱۲/۸۸	۳۹/۸۳	-۴/۵۱	۳۹/۲۸	۱۳/۱	-۵/۵۴
	P,T(min),T(max)	۱۵/۰۳	۳۹/۷۱	۰/۱۳۹۷	۳۸/۴۹	۱۶/۴۸	-۳/۳۷
	P,T(min)	۸/۹	۵/۴۷	-۱/۷	۵/۷۳	۸/۹	-۱/۵
اسکندری	P,T(mean)	۱۰/۳۴	۵/۲۶	-۱/۹	۵/۳	۱۴/۱۹	-۱/۰۷
	P,T(max)	۱۴/۹۲	۵/۰۳	-۱/۹	۵/۳۴	۱۵/۳۵	-۱/۰۴
	P,T(mean),T(max)	۱۷/۰۷	۵/۳۲	۰/۰۹۴۵	۵/۳۱	۱۹/۷۱	-۰/۵۶

جدول ۴- نتایج شبکه عصبی مصنوعی و سیستم عصبی-فازی در ترکیب ورودی بارش، دما و رطوبت نسبی

ایستگاه	پارامترهای ورودی	شبکه عصبی مصنوعی			عصبی-فازی		
		r^2	RMSE	%R ²	r^2	RMSE	%R ²
قلعه شاهرخ	P,RH(۱۸:۳۰)	۷/۵	۴۵/۵۳	-۳/۲۹	۴۲/۹۷	۱۴/۲۱	-۴/۵۵
	P,RH(۶:۳۰)	۵/۶	۴۸/۱۲	-۲/۹۳	۴۷/۷۸	۱۱/۷۱	-۱/۷
	P,RH(۱۲:۳۰)	۹/۳	۴۴/۵۹	-۳/۷۳	۴۴/۷۱	۹/۱۴	-۳/۶۶
	P,T(mean) , RH(۱۲:۳۰) , RH(۶:۳۰),RH(۱۸:۳۰)	۲۹/۱۸	۴۵/۷	-۱/۱۸	۱۹۲/۸۴	۲	-۰/۱۷۳۳
	P,RH(۱۸:۳۰)	۲/۱۵	۱۱/۲۲	-۴/۷	۹/۲۹	۳/۴۹	-۵/۶۷
اسکندری	P,RH(۶:۳۰)	۲۰/۳۹	۱۰/۷۸	-۴/۳۲	۸/۹۷	۲۴/۴۸	-۵/۲۲
	P,RH(۱۲:۳۰)	۹/۴۱	۱۴/۱۶	-۴/۱۳	۱۰/۶۸	۱۶/۶۲	-۶/۰۵
	P,T(min) , RH(12:30) , RH(6:30),RH(18:30)	۳۵/۱۵	۷/۶۱	-۴/۵۵	۲۶/۵۷	۲۶/۷۷	-۰/۵۴۹۹

جدول ۵- نتایج حاصل از شبکه عصبی-فازی و شبکه عصبی مصنوعی در ترکیبهای مختلف ورودی با میانگین متحرکهای مختلف

مدل	ایستگاه	پارامترهای ورودی	میانگین متحرک		شبکه عصبی مصنوعی	
			روزه X	%R ²	RMSE	r ²
شبکه عصبی مصنوعی	قلعه شاهرخ	P,T(min),T(max) P,T(mean), RH(۱۲:۳۰), RH(۶:۳۰), RH(۱۸:۳۰)	۵	۱۵/۲۹	۳۶/۵۲	۰/۱۴۶۲
			۷	۲۰/۳۲	۴/۲۷	۰/۱۱۲۵
			۵	۲۳/۰۷	۸/۷۵	-۲/۷۵
سیستم عصبی-فازی	قلعه شاهرخ	P,T(min),T(max) P, RH(۱۸:۳۰)	۷	۲۵/۲۸	۳۳/۷۱	-۲/۸۴
			۷	۱۸/۶۵	۳۹/۴۲	-۰/۹۴۰۳
			۷	۲۴/۵۱	۴/۷۶	-۰/۳۶۰۲
	اسکندری	P, T(mean), T(max) P, T(min), RH(۱۲:۳۰), RH(۶:۳۰), RH(۱۸:۳۰)	۷	۳۹	۷/۱۳	-۲/۰۸

جدول ۶- نتایج حاصل از الگوریتم ژنتیک و آزمون گاما، با وجود داده‌های دبی پیشین

اندازه مجموعه	آزمون گاما		الگوریتم ژنتیک		ترکیب ورودی ×	ایستگاه
	SE	Gamma	SE	Gamma		
آموزش (% از کل داده‌ها)						
۸۰	۱/۶×۱۰ ^{-۵}	۱۳۵/۳×۱۰ ^{-۶}	۱/۶×۱۰ ^{-۵}	۱۳۵/۳×۱۰ ^{-۶}	P,Q(t-1),Q(t-2), Q(t-3), T(mean), T(min)	اسکندری
۶۰	۹/۵×۱۰ ^{-۵}	۵/۷×۱۰ ^{-۵}	۹/۵×۱۰ ^{-۵}	۵/۷×۱۰ ^{-۵}	P,Q(t-1), Q(t-2), Q(t-3), RH(۶:۳۰), Rh(۱۸:۳۰),	
۸۰	۲/۴×۱۰ ^{-۵}	۳۰/۸×۱۰ ^{-۵}	۲/۴×۱۰ ^{-۵}	۳۰/۸×۱۰ ^{-۵}	P,Q(t-1), Q(t-2), Q(t-3), T(min)	قلعه شاهرخ
۸۰	۵/۴×۱۰ ^{-۵}	۳۳/۹×۱۰ ^{-۵}	۵/۴×۱۰ ^{-۵}	۳۳/۹×۱۰ ^{-۵}	P,Q(t-1), Q(t-3), RH(۶:۳۰), Rh(۱۸:۳۰), T(min)	

ارتباط با مقادیر اندازه‌گیری شده، هستند. اولین نکته‌ای که در جدول ۷ مشخص است، این است که بردارهای دبی پیشین کمک زیادی به هر دو تکنیک در مدل‌سازی کرده‌اند و نتایج به مقدار زیادی بهبود یافته است. ولی همانطور که مشخص است، ترکیبهای ورودی بهینه‌ای که از نرم‌افزار winGamma حاصل شدند، در سیستم عصبی- فازی نتوانسته‌اند بهترین جواب را ارائه بدهند و استفاده از بارش به همراه دبی یک روز قبل به عنوان ورودی، نتایج بهتری را ارائه داده است، در صورتی که در شبکه عصبی مصنوعی اینگونه نیست.


از آنجا که در مراحل قبلی این مطالعه استفاده از میانگین‌های متحرک ۵ و ۷ روزه توانست نتایج را به میزان مناسبی بهبود ببخشد، برای ادامه کار از میانگین متحرک برای بهترین ترکیب‌هایی که از جدول ۷ نتیجه شدند، استفاده گردید. نتایج در جدول ۸ ارائه شده است.

قادر به ارائه نتیجه نبود؛ بنابراین به این منظور تنها از آزمون و خطا استفاده شد. لازم به ذکر است که بهترین ترکیب ورودی برای دو حالت در نظر گرفتن متغیر رطوبت نسبی در ترکیب ورودی و عدم در نظر گرفتن آن در ترکیب، تعیین گردید. نتایج در جدول ۶ آورده شده است. در این جدول ملاحظه می‌شود که مقادیر گاما و خطای استاندارد نسبت به آنچه که در جدول ۲ آورده شده است، بسیار کمتر است که این نشان دهنده تأثیر مثبت داده‌های دبی پیشین است. بنابراین انتظار می‌رود اضافه شدن این بردارها به جمع بردارهای ورودی، کمک زیادی به شبکه عصبی مصنوعی و سیستم عصبی- فازی در مدل‌سازی نماید.


بعد از تعیین بهترین ترکیب ورودی اقدام به مدل‌سازی با استفاده از شبکه عصبی مصنوعی و سیستم عصبی- فازی گردید. نتایج در جدول ۷ آورده شده است. شکل‌های ۲، ۳، ۴ و ۵ نیز نشان‌دهنده بهترین مقادیر برآورد شده توسط شبکه عصبی مصنوعی و سیستم عصبی- فازی در ایستگاههای قلعه شاهرخ و اسکندری در

جدول ۷- نتایج شبکه عصبی مصنوعی و سیستم عصبی- فازی در ترکیب ورودی بارش، دما، رطوبت نسبی و دبی پیشین


عصبی- فازی			شبکه عصبی مصنوعی			پارامترهای ورودی	ایستگاه
r^2	RMSE	$R^2/\%$	r^2	RMSE	$R^2/\%$		
۰/۵۳۶۷	۴۵/۹۴	۵۵/۱۲	۰/۸۳۱۹	۱۷/۷۸	۸۷/۳۷	P,Q(t-1), Q(t-2), Q(t-3), T(min)	قلعه شاهرخ
۰/۱۹۲۷	۸۸/۳۱	۲۰/۶۸	۰/۷۵۷۹	۲۳/۴۴	۸۱/۴۲	P, Q(t-1), Q(t-3), T(min), RH(۶:۳۰), RH(۱۸:۳۰)	
۰/۸۷۶۰	۱۴/۳۷	۸۸/۴۴	۰/۸۲۷۲	۱۶/۷۳	۸۷/۲۹	P, Q(t-1)	
۰/۷۱۱۹	۲۰/۴۵	۷۶/۵۱	۰/۶۷۹۰	۲۲/۳۲	۷۷/۴۴	P, Q(t-2)	
۰/۶۳۶۵	۲۳/۱۵	۷۰/۳	۰/۶۰۵۱	۲۴/۳۳	۷۲/۶۸	P, Q(t-3)	
۰/۴۶۹۲	۵/۷۴	۴۷	۰/۹۳۲۹	۱/۷۳	۹۳/۳	P,Q(t-1), Q(t-2), Q(t-3), T(min), T(mean)	اسکندری
-۰/۵۵۳۳	۱۰/۲۲	۱۷/۵۲	۰/۸۰۷۸	۳/۵۴	۸۱/۱	P, Q(t-1), Q(t-2), Q(t-3), RH(۶:۳۰), RH(۱۸:۳۰)	
۰/۹۴۴۵	۱/۵۵	۹۴/۴۸	۰/۸۱۱۶	۱/۹۰۳	۸۸/۷۷	P, Q(t-1)	
۰/۸۳۳۸	۲/۲۲	۸۸/۷۱	۰/۷۳۲۸	۲/۲۲	۸۳/۸۵	P, Q(t-2)	
۰/۸۴۵۲	۲/۵۳	۸۵/۲۶	۰/۶۶۱۰	۲/۵	۷۸/۴۴	P, Q(t-3)	




شکل ۳- نتایج شبکه عصبی- فازی در ترکیب ورودی بارش و دبی پیشین در ایستگاه قلعه شاهرخ



شکل ۲- نتایج شبکه عصبی مصنوعی در ترکیب ورودی بارش، دما و دبی پیشین در ایستگاه قلعه شاهرخ



شکل ۵- نتایج شبکه عصبی- فازی در ترکیب ورودی بارش و دبی پیشین در ایستگاه اسکندری



شکل ۴- نتایج شبکه عصبی مصنوعی در ترکیب ورودی بارش، دمای حداقل و دبی پیشین در ایستگاه اسکندری

جدول ۸- نتایج حاصل از شبکه عصبی- فازی و شبکه عصبی مصنوعی در ترکیبهای مختلف با میانگین متحرکهای مختلف

r^2	RMSE	$R^2/\%$	میانگین متحرک X روز	پارامترهای ورودی	ایستگاه	مدل
۰/۹۷۱۸	۶/۴۹	۹۷/۷	۵	P&Q(t-1) & Q(t-2) & Q(t-3) & T(min)	قلعه شاهرخ	شبکه عصبی مصنوعی
۰/۹۹۵۳	۰/۴۰۹	۹۹/۵	۷	P&Q(t-1) & Q(t-2) & Q(t-3) & T(min) & T(mean)	اسکندری	
۰/۹۶۷۵	۶/۹۴	۹۶/۹۲	۵	P, T(min), T(max)	قلعه شاهرخ	سیستم عصبی- فازی
۰/۹۹۴۲	۰/۴۴۹۸	۹۹/۴۲	۷	P, RH(۶:۳۰)	اسکندری	

نتایج ارائه گردیده در جدول ۸ نشان می‌دهند که میانگین متحرک در این مورد نیز باعث بهبود نتایج به‌میزان زیادی شده است و نتایج حاصل از هر دو مدل به مقادیر اندازه‌گیری شده بسیار نزدیک شده‌اند و تفاوت جزئی نیز بیشتر مربوط به داده‌های حد بالای دبی می‌باشد. به این معنی که مدل‌ها در برآورد داده‌های حد پایین و متوسط دبی بسیار موفق‌تر از برآورد داده‌های حد بالا عمل کرده‌اند.

در این بخش به منظور مقایسه، از شبکه عصبی BFGS، شبکه دو لایه پس انتشار، رگرسیون خطی محلی و رگرسیون خطی محلی دینامیک، برای بررسی ترکیبی که در هر ایستگاه بدون استفاده از میانگین متحرک، بهترین جواب را ارائه داده است، استفاده گردیده و نتایج در جدول ۹ ارائه شده است.

با وجود اینکه نتایج برخی از مدل‌ها مثل شبکه دو لایه پس انتشار در ایستگاه قلعه شاهرخ، خیلی به نتایج حاصل از شبکه پیشرو نزدیک بود، ولی با این وجود بهترین نتیجه را در هر دو ایستگاه، شبکه پیشرو ارائه نموده است. از آنجا که در سیستم عصبی - فازی

می‌توان از توابع عضویت مختلف استفاده کرد که ممکن است در نتیجه نهایی تأثیر گذار باشند، در این مرحله ترکیب ورودی که بدون در نظر گرفتن میانگین متحرک، بهترین نتایج را ارائه داده، برای هر ایستگاه در نظر گرفته شد و با تابع عضویت‌های مختلف مورد بررسی قرار داده شد. نتایج در جدول ۱۰ ارائه شده است. همانطوری که در جدول ۱۰ ملاحظه می‌شود، با تغییر تابع عضویت، نتایج تفاوت چندانی پیدا نمی‌کنند. ولی در بین آنها تابع عضویت گوسی زنگوله‌ای نتایج بهتری را از خود نشان داده است.

در ادامه برای روشن شدن علت عدم توانایی شبکه در تعیین داده‌های حد بالا، اقدام به تعیین درصد آماری داده‌ها در دهکهای آماری گردید. به این ترتیب که فاصله بین حداقل و حداکثر در هر دسته داده، به ده قسمت مساوی ارزشی تقسیم شده و نشان داده شد که در هر دهک چند درصد از کل داده‌ها وجود دارند (جدول ۱۱). نتایج حاصل از جدول ۱۱ نشان می‌دهد که تعداد داده‌های حد بالا نسبت به کل داده‌ها بسیار کم است که این امر می‌تواند مهم‌ترین عامل عدم توانایی شبکه برای شبیه‌سازی مناسب داده‌های حد بالا

جدول ۹- نتایج حاصل از مدل‌های متفاوت در ایستگاه قلعه شاهرخ و اسکندری

ایستگاه	پارامترهای ورودی	مدل	R ² /%	RMSE	r ²
اسکندری	P&Q(t-1) & Q(t-2) & Q(t-3) & T(min) & T(mean)	FF ¹	۹۳/۳	۱/۷۳	۰/۹۳۲۹
		BFGS	۵۶/۵۷	۷/۸۸	۰/۵۱۵۱
		TLBP ²	۷۹/۴۶	۸/۵۴	۰/۵۹۸۴
		LLR ³	۳۰/۶۳	۲۷/۵۱	۰/۱۸۷۲
		DLLR ⁴	۳۰/۶۳	۲۷/۵۱	۰/۱۸۷۲
قلعه شاهرخ	P&Q(t-1) & Q(t-2) & Q(t-3) & T(min)	FF	۸۷/۳۷	۱۷/۷۸	۰/۸۳۱۹
		BFGS	۸۷/۳۵	۱۷/۹	۰/۸۲۶۸
		TLBP	۸۷/۲۴	۱۷/۲۱	۰/۸۱۵۲
		LLR	۶۷/۶۰	۲۸/۳۳	۰/۶۴۳۶
		DLLR	۶۷/۶۰	۲۸/۳۳	۰/۶۴۳۶

جدول ۱۰- نتایج حاصل از شبکه عصبی - فازی در ترکیب‌های مختلف با میانگین متحرک‌های مختلف

ایستگاه	پارامترهای ورودی	تابع عضویت	R ² /%	RMSE	r ²
اسکندری	P& Q(t-1)	گوسی	۹۲/۰۴	۱/۹۳	۰/۹۱۹۸
		گوسی ترکیبی	۹۳/۲۴	۱/۸۰	۰/۹۳۰۸
		گوسی زنگوله‌ای	۹۴/۴۸	۱/۵۵	۰/۹۴۴۵
		سیگموئیدی	۹۳/۲۵	۱/۷۴	۰/۹۳۲۲
		گوسی	۸۷/۷۳	۱۴/۷۶	۰/۸۶۷۰
قلعه شاهرخ	P& Q(t-1)	گوسی ترکیبی	۸۸/۳۵	۱۴/۳۸	۰/۸۷۴۲
		گوسی زنگوله‌ای	۸۸/۴۴	۱۴/۳۷	۰/۸۷۶۰
		سیگموئیدی	۸۷/۹۲	۱۴/۶۹	۰/۸۷۰۸

¹ Feed-Forward Network (FF)

² Two Layer Back Propagation (TLBP)

³ Local Linear Regression (LLR)

⁴ Dynamic Local Linear Regression (DLLR)

جدول ۱۱- تعیین فراوانی آماری داده‌ها در دهک‌های ارزشی برای دو ایستگاه مورد نظر

قلعه شاهرخ			اسکندری		
تعداد داده‌ها	درصد داده‌ها	محدوده دهک	تعداد داده‌ها	درصد داده‌ها	محدوده دهک
۸۶۳۳	۷۸/۶۳۷	۰-۶۴/۵۶	۱۰۰۹۰	۹۱/۸۸۹	۰-۱۰/۵۱
۱۹۲۴	۱۷/۵۱۳	۶۴/۵۶-۱۲۹/۱۲	۶۴۱	۵/۸۳۵	۱۰/۵۱-۲۱/۰۲
۳۲۷	۲/۹۷۷	۱۲۹/۱۲-۱۹۳/۶۸	۱۶۹	۱/۵۴۸	۲۱/۰۲-۳۱/۵۳
۷۰	۰/۶۳۷	۱۹۳/۶۸-۲۵۸/۲۴	۴۳	۰/۳۹۱	۳۱/۵۳-۴۲/۰۴
۱۲	۰/۱۰۹	۲۵۸/۲۴-۳۲۲/۸	۱۶	۰/۱۴۶	۴۲/۰۴-۵۲/۵۵
۶	۰/۰۵۵	۳۲۲/۸-۳۸۷/۳۶	۱۴	۰/۱۲۷	۵۲/۵۵-۶۳/۰۶
۴	۰/۰۳۶	۳۸۷/۳۶-۴۵۱/۹۲	۴	۰/۰۳۶	۶۳/۰۶-۷۳/۵۷
۱	۰/۰۰۹	۴۵۱/۹۲-۵۱۶/۴۸	۰	۰	۷۳/۵۷-۸۴/۰۸
۲	۰/۰۱۸	۵۱۶/۴۸-۵۸۱/۰۴	۲	۰/۰۱۸	۸۴/۰۸-۹۴/۵۹
۱	۰/۰۰۹	۵۸۱/۰۴-۶۴۶	۱	۰/۰۰۹	۹۴/۵۹-۱۰۶

ورودی‌های متفاوت وجود دارد، پس نمی‌تواند ناشی از ساختار شبکه باشد و باید به دنبال دلیل دیگری برای آن بود. بررسی‌ها نشان دهنده آن است که این مسئله به احتمال زیاد ناشی از تعداد کم داده‌های حد بالا در آموزش مدل است.

نتایج جدول ۱۱ نشان می‌دهد که بیش از ۹۰ درصد کل داده‌ها در همان دو دهک اول قرار دارند و در هر دو ایستگاه در ۴ دهک آخر (که باید اعداد حداکثر و دبی‌های حد بالا در آنها قرار بگیرند) کمتر از ۱ درصد از کل داده‌ها قرار گرفته‌اند. این رقم کمتر از ۹ عدد داده از بین ۱۰۹۸۰ عدد داده است. اگر تمامی این داده‌ها هم در قالب گروه آموزش، برای یادگیری در اختیار شبکه قرار بگیرند، با توجه به رابطه بسیار پیچیده بین پارامترهای ورودی و خروجی، نمی‌توان انتظار زیادی از شبکه عصبی مصنوعی و سیستم عصبی-فازی برای آموزش مناسب و ارائه جواب درست، داشت. بنابراین بسیار طبیعی است که داده‌های ارائه شده توسط هر دو مدل در مورد دبی‌های حد بالا با داده‌های مشاهده‌ای اختلاف داشته باشند.

در این مطالعه برای حل و یا کاهش این مشکل از میانگین متحرک استفاده شد که باعث کاهش اثر حداکثرها و حداقل‌ها در یک مجموعه از داده‌ها می‌گردد. نتایج نشان می‌دهد که در هر دو ایستگاه اسکندری و قلعه شاهرخ و همچنین در استفاده از هر دو مدل، میانگین متحرک باعث بهبود نتایج شده است و نمودارهای حاصل از آزمون‌های مختلف نشان می‌دهند که داده‌های حد بالا بهتر برآورد شده‌اند. البته باز هم اختلافاتی وجود دارد که این عادی و ناشی از خطای مدل است.

نکته دیگری که مناسب است در این بخش بدان توجه شود، کارایی نرم‌افزار WinGamma و میزان صحت نتایج حاصل از آن است. در این مطالعه از نرم‌افزار WinGamma برای تعیین بهترین ترکیب ورودی و نیز مناسب‌ترین اندازه مجموعه آموزش برای هر دو مدل، استفاده شد. در مورد شبکه عصبی مصنوعی، نتایج آزمون و

باشد. علاوه بر آن همان‌طور که از نتایج به‌خوبی مشخص است، شبکه عصبی مصنوعی و سیستم عصبی-فازی تا قبل از اینکه داده‌های دبی پیشین به جمع ورودی‌ها اضافه شوند، قادر به ارائه جواب‌های مناسبی در پیش‌بینی رواناب نیستند. با بررسی داده‌ها مشخص شد که رابطه بین بارش و رواناب در منطقه مورد مطالعه یک رابطه بسیار پیچیده است. به طوری که حتی با محاسبه تأخیر زمانی بین بارش و رواناب و اعمال آن در سری‌های آماری، داده‌ها رابطه‌ای مشخص را از خود نشان نمی‌دهند. در بسیاری از موارد میزان روانابی که از یک میزان ثابت بارش در دفعات متعدد ایجاد شده است، تناسبی با یکدیگر ندارند. به این معنی که گاهی مقدار مشخصی بارش باعث ایجاد حجم قابل توجهی رواناب شده است ولی در موارد دیگر همان مقدار بارش، حجم بسیار کمتری از رواناب ایجاد کرده و یا تغییر زیادی در دبی پایه رودخانه حاصل نکرده است. بنابراین مدل‌ها قادر به یادگیری و تشخیص این رابطه نیستند.

در نظر گرفتن دبی پیشین به عنوان متغیر ورودی جدید باعث بهبود قابل توجهی در مدل‌سازی در هر دو روش شد و نتایج را تا حد قابل قبولی به مقادیر مشاهده شده نزدیک کرد. این امر قابل پیش‌بینی بود، زیرا همان‌طور که از نتایج آزمون گاما نیز بر می‌آید، داده‌های دبی پیشین قوی‌ترین رابطه را با رواناب و در نتیجه بیشترین اثر مثبت در مدل‌سازی را دارند که این اثر حتی از اثر بارش نیز بیشتر است.

در نتایج به‌دست آمده مشاهده می‌شود که با اینکه استفاده از دبی پیشین باعث بهبود نتایج به مقدار زیادی شده است، ولی این بهبود نتایج بیشتر مربوط به دبی‌های حد پایین و متوسط است و مدل‌ها برای پیش‌بینی دبی‌های حد بالا از خود ضعف نشان می‌دهند. با توجه به اینکه این مشکل در شبکه عصبی مصنوعی و سیستم عصبی-فازی و در ساختارهای مختلف این دو و نیز ترکیب

خطاهای متعدد نشان داد که می‌توان به نتایج حاصل از WinGamma اعتماد کرد. ولی در مورد سیستم عصبی - فازی این موضوع عمومیت پیدا نمی‌کند. نتایج به دست آمده از این تحقیق نشان می‌دهند که هنگامی که تعداد پارامترهای ورودی کم است، نتایج حاصل از آزمون و خطا با نتایج WinGamma تطابق دارد. ولی وقتی تعداد پارامترهای ورودی زیاد می‌شود این‌طور نیست و نمی‌توان از نتایج WinGamma استفاده کرد.

در میان شبکه‌های عصبی استفاده شده در این مطالعه نتایج نشان می‌دهند که در هر دو ایستگاه، شبکه عصبی پیشرو با تنظیماتی که در بخش‌های قبلی ارائه شد، قابلیت بهتری در برآورد رواناب دارد. همچنین در سیستم عصبی - فازی، تابع عضویت گوسی زنگوله‌ای نتایج بهتری را از خود نشان داد.

یکی از اهداف اصلی این تحقیق مقایسه کارایی شبکه عصبی مصنوعی و الگوریتم عصبی - فازی در برآورد بارش - رواناب بود. ولی نتایج به دست آمده به گونه‌ای است که دقیقاً نمی‌توان گفت که شبکه عصبی کارایی بهتری دارد یا سیستم عصبی - فازی. در مواردی که تعداد بردارهای ورودی کمتر از ۴ عدد است، سیستم عصبی - فازی اکثرآ جواب بهتری داده است. اما در مواردی که تعداد پارامترهای ورودی زیاد می‌شود، از صحت نتایج حاصل از سیستم عصبی - فازی به مقدار زیادی کاسته شده و نتایج شبکه عصبی مصنوعی بهتر به نظر می‌رسند. این وضعیت حتی زمانی که داده‌های دبی پیشین به عنوان ورودی به سیستم معرفی می‌گردند نیز دیده می‌شود. این موضوع با آنچه که انتظار می‌رفت تفاوت دارد زیرا در مورد شبکه عصبی - فازی هنگامی که داده‌های دبی پیشین و بارش، تنها بردارهای ورودی باشند، نتایج بسیار خوب بوده و بهتر از نتایج شبکه عصبی مصنوعی است. ولی اگر از ترکیبهایی که علاوه بر موارد بالا، بردارهای ورودی دیگر مانند دما و رطوبت نسبی را نیز در بر می‌گیرند، استفاده شود، مشاهده می‌گردد که علی‌رغم اینکه سیستم عصبی - فازی در مرحله آموزش به خوبی آموزش می‌بیند، ولی در مرحله آزمون جواب خوبی را ارائه نمی‌دهد و به اصطلاح دچار یک سردرگمی و گیجی می‌شود.

نکته قابل توجه اینکه، این موضوع در مورد داده‌های حد بالا و یا متوسط با شدت بسیار بیشتری خود را نشان می‌دهد. به این معنی که در شرایط توضیح داده شده، سیستم عصبی - فازی در مرحله آزمون، داده‌های حد پایین را خوب برآورد می‌کند. ولی هنگامی که به داده‌های حد بالا یا حتی متوسط می‌رسد، نتایج به شدت متغیر و نامنظم می‌شوند. مسئله دیگری که قابل توجه است این است که اگر در نتایج دقت شود، مشخص است هنگامی که در سیستم عصبی - فازی از داده‌های بارش، دبی پیشین و دما به عنوان ورودی استفاده گردد، نسبت به حالتی که به مجموعه مذکور داده‌های رطوبت نسبی

نیز اضافه شود، هر چند همان مشکل اختلال ناشی از تعداد بالای پارامترهای ورودی وجود دارد، ولی نتایج به مقدار قابل توجهی بهتر می‌شوند. اگر برای مقایسه، نتایج حاصل از همین ترکیبها در شبکه عصبی بررسی شود، مشخص می‌گردد که اولاً نتایج بهتر از حالتی است که از بردار بارش به همراه دبی پیشین به عنوان ورودی استفاده شده است و ثانیاً نتایج ترکیب ورودی بارش، دبی پیشین و دما و همچنین ترکیب ورودی بارش، دبی پیشین، دما و رطوبت نسبی، تفاوت بسیار کمتر از آن چیزی که در سیستم عصبی - فازی دارند را نشان می‌دهند. همان‌طور که در بخش‌های قبل بیان شد، تعداد داده‌ها هنگامی که از بردارهای رطوبت نسبی استفاده نشود برابر با ۱۰۹۸۰ و هنگامی که از بردارهای رطوبت نسبی استفاده گردد برابر با ۳۲۹۴ عدد است که این می‌تواند یکی از دلایل وجود مشکل بیان شده در بالا باشد. از آنجایی که اثر مثبت این دو گروه ترکیب ورودی در مدل‌سازی توسط شبکه عصبی مصنوعی ثابت شده است، برای جواب به این مسئله باید به دنبال پاسخی به جز اثر منفی پارامترها در مدل‌سازی بود. بنابراین می‌توان این‌گونه بیان کرد که وقتی تعداد بردارهای ورودی در سیستم عصبی - فازی بالا می‌رود، تعداد روابط فازی که توسط سیستم ایجاد می‌گردد بسیار زیاد می‌شود و سیستم بین این همه رابطه فازی گیج شده و نمی‌تواند رابطه درست را تشخیص داده و فرا بگیرد، بنابراین تا حد امکان تنها سعی در حفظ روابط موجود می‌کند.

به‌طور ساده‌تر می‌توان گفت سیستم به جای فرا گرفتن روابط موجود تلاش می‌کند روابط را از بر کند. این عمل همان کاری است که انسان در زمان حفظ کردن مطالب بدون فهمیدن و درک کردن آنها انجام می‌دهد. در نتیجه مشاهده می‌شود که سیستم در مرحله آموزش نتایج خوبی را ایجاد می‌کند ولی در مرحله ارزیابی که از داده‌های جدیدی استفاده می‌گردد، نمی‌تواند مقادیر مورد نظر را به خوبی برآورد کند. از طرفی به نظر می‌آید با وجود اینکه تعداد پارامتر ورودی زیاد باعث ایجاد اختلال در عملکرد سیستم می‌شود، ولی در همین تعداد بالای پارامتر ورودی نیز اگر تعداد داده‌های ورودی زیاد شود، سیستم قادر به پاسخگویی به تعداد بیشتری از روابط فازی ایجاد شده بر اساس بالا رفتن تعداد مثالهای ارائه شده می‌شود و در نهایت نتایج بهتری را در ارزیابی مدل از خود ارائه می‌دهد.

۴- نتیجه‌گیری

به‌طور کلی می‌توان سه نتیجه عمده از این تحقیق گرفت:

۱- شبکه عصبی مصنوعی و سیستم عصبی - فازی بدون معرفی دبی پیشین به عنوان ورودی به مدل، قادر به برآورد مناسبی از رواناب نیستند. دلیل این امر هم وجود روابط بسیار پیچیده بین بارش و

رواناب در حوضه مورد مطالعه است. به عبارت دیگر پیچیدگی بیش از حد موجود در روابط بین بارش و رواناب باعث شده شبکه عصبی مصنوعی و سیستم فازی-عصبی قادر به درک درست روابط نباشند و در نتیجه نتایج حاصل از آنها در مقایسه با داده‌های واقعی دارای خطای زیادی باشند.

۲- وارد کردن دبی پیشین می‌تواند نتایج را تا حدود زیادی بهبود ببخشد و کارایی هر دو مدل را افزایش دهد. زیرا همان‌طور که داده‌های حاصل از Wingamma نشان می‌دهند دبی پیشین قوی‌ترین رابطه را با رواناب به جریان در آمده در بستر رودخانه دارد. بنابراین طبیعی است که استفاده از این پارامتر بتواند کمک زیادی به مدل برای درک رابطه بین بارش و رواناب و فهم روند تغییرات دبی در منطقه بکند.

۳- هنگامی که تعداد پارامترهای ورودی کمتر از ۴ عدد است، نتایج حاصل از سیستم عصبی-فازی بهتر از نتایج شبکه عصبی مصنوعی

است و مواقعی که تعداد پارامترهای ورودی زیاد باشند، سیستم عصبی-فازی توانایی خود را تا حد زیادی از دست داده و نتایج حاصل از شبکه عصبی مصنوعی بهتر هستند. به نظر می‌رسد دلیل این مسئله عدم توانایی سیستم فازی-عصبی در پیدا کردن رابطه بین ورودی و خروجی در شرایطی که تعداد پارامترهای ورودی زیاد هستند، باشد.

چنانچه به فرضیات این تحقیق توجه شود، مشخص می‌گردد که جواب سوال پژوهشی اول به‌طور نسبی مثبت است یعنی نتایج تحقیق نشان دهنده آن است که این روشها با به‌کارگیری پارامترهای ورودی مناسب و استفاده از ساختارهای صحیح به‌میزان قابل قبولی قادر به تخمین رواناب حاصل از بارش هستند. در رابطه با فرض دوم نیز نتایج نشان دهنده آن است که برتری این روشها نسبت به هم به تعداد پارامترهای ورودی مورد استفاده بستگی دارد.

۶- مراجع

- 1- Akbarpour, M., Rahnama, M. B., and Barani, Gh. A. (2003). "Comparison of artificial neural network and HEC-HMS models on rainfall-runoff process." *4th Iranian Hydraulic Conf.*, Shiraz University, Shiraz, 1025-1032. (In Persian)
- 2- Dastorani, M. T. (2007). "Evaluation of the application of artificial intelligence models on simulation and real-time prediction of peak flow." *J. of Science and Tech. of Agriculture and Natural Resources (Water and Soil Science)*, 40, 27-36. (In Persian)
- 3- Noorani, V., and Salehi, K. (2008). "Rainfall-runoff modeling using ANFIS and comparing with ANN and fuzzy logic." *4th National Civil Eng. Conf.*, Tehran University, Tehran. (In Persian)
- 4- Goali, Q., Chen, S., and Wang, D. (2001). "An intelligent runoff forecasting method based on fuzzy sets, neural network and genetic algorithm." <www.sciencedirect.com.> (Oct. 5, 2009)
- 5- Chang, F., and Chen, Y.C. (2001). "A counter propagation fuzzy-neural network modeling approach to real time streamflow prediction." *J. Hydrology*, 245, 153-164.
- 6- Keskin, M.E., Taylan, E.D., and Yilmaz, A.G. (2003). "Flow prediction with fuzzy logic approaches: Dim stream." *International Congress on River Basin Management*, Antalya, Turkey.
- 7- Matreata, M. (2004). "Artificial neural network and fuzzy logic models in operational hydrological forecasting system." <www.sciencedirect.com.> (Sep. 17, 2009)
- 8- Navak, P. C., Sudheer, K. P., and Ramasastri, K. S. (2004). "Fuzzy computing based rainfall-runoff model for real time flood forecasting." *J. of Hydrological Proc.*, 19, 955-968.
- 9- Aqil, M., Kita, I., Yano, A., and Nishiyama, S. (2007). "A comparative study of artificial neural networks and neuro-fuzzy in continuous modeling of the daily and hourly behaviour of runoff." *J. Hydrology*, 337, 22-34.