



Runoff Prediction Using Black and Gray Box Models

M. Bagherpour^{1*}, S.M. Seyedian², A. Fatabadi²
and A. Mohammadi²

Abstract

In the past decade, machine learning is considered to be a promising approach for empirical rainfall-runoff modeling as a useful complement to hydrologic models, particularly in basins where data to support process-based models are limited. In this paper, we used black-box models (i.e. neuro-fuzzy and support vector machine) and gray-box models (i.e. TOPMODEL and HBV) for simulating the transformation of daily rainfall-runoff process in the Nodeh Khormaloo watershed located in Gorganrood River Basin and compare their performance in terms of predictive accuracy. For the black-box models, the three input vectors including discharge, temperature and rainfall were selected in nine different scenarios based on the sequential time series data. Our result showed that the neuro-fuzzy model which consisted of three antecedent values of flow and one antecedent values of temperature outperformed other models when the root mean square error and coefficient of determination were used as quality indicators. In general, the black-box models outperformed the HBV and TOPMODEL simulations for the calibration and validation data sets. A detailed comparison of the overall performance indicated that the neuro-fuzzy and SVM models predicted runoff in warm months were consistently lower than that in the cold months.

Keywords: Artificial Intelligence, Conceptual Model, Rainfall, Runoff.

Received: January 30, 2018

Accepted: July 27, 2018

پیش‌بینی رواناب با استفاده از مدل‌های جعبه سیاه و خاکستری

مهسا باقرپور^۱، سیدمرتضی سیدیان^{۲*}، ابوالحسن فتح‌آبادی^۲
و امین محمدی^۲

چکیده

در دهه گذشته، یادگیری ماشین یک روش مناسب برای مدل‌سازی تجربی بارش-رواناب به عنوان یک مکمل مفید برای مدل‌های هیدرولوژیکی مطرح شده است، به ویژه در حوضه‌هایی که داده‌ها برای اجرای مدل‌های هیدرولوژیکی محدود می‌باشند. در این تحقیق از مدل‌های جعبه سیاه (نروفازی و ماشین بردار پشتیبان) و مدل‌های جعبه خاکستری (TOPMODEL و HBV) برای شبیه‌سازی فرآیند بارش-رواناب روزانه در حوضه نوده خاندوز که در رودخانه گرگانرود قرار دارد، استفاده شد و عملکرد آن‌ها با توجه به دقت پیش‌بینی رواناب مقایسه گردید. برای مدل‌های جعبه سیاه، سه سری ورودی شامل دبی، دما و بارندگی در ۹ سناریوی متفاوت بر اساس داده‌های سری زمانی انتخاب گردید. مقایسه مقادیر میانگین مربعات خطا و ضریب تعیین نشان می‌دهد مدل نروفازی با دبی تا سه گام زمانی قبل و دمای گام زمانی قبل عملکرد بهتری نسبت به سایر سناریوها دارد. به طور کلی مدل‌های جعبه سیاه رواناب را در مرحله واسنجی و صحت‌سنجی با دقت بیشتری نسبت به HBV و TOPMODEL شبیه‌سازی کرده‌اند. مقایسه دقیق عملکرد کل مدل‌ها نشان داد که مدل‌های نروفازی و ماشین بردار پشتیبان رواناب را در فصل‌های گرم با دقت کمتری نسبت به فصل‌های سرد پیش‌بینی کرده‌اند.

کلمات کلیدی: بارش، رواناب، هوش مصنوعی، مدل مفهومی.

تاریخ دریافت مقاله: ۹۶/۱۱/۱۰

تاریخ پذیرش مقاله: ۹۷/۵/۵

1- Graduate Student in Watershed Management, Ghonbad Kavous University, Ghonbad Kavous, Iran.

2- Assistant Professor, Department of Agriculture, University, Ghonbad Kavous, Iran. Email: s.m.sevedian@gmail.com

*- Corresponding Author

۱- دانش‌آموخته کارشناسی ارشد آب‌خیزداری، دانشگاه گنبد کاووس-گنبد کاووس.

۲- استادیار دانشکده کشاورزی، دانشگاه گنبد کاووس-گنبد کاووس.

*- نویسنده مسئول

بحث و مناظره (Discussion) در مورد این مقاله تا پایان بهار ۱۳۹۸ امکانپذیر است.

همچنین، فرایند واسنجی تأثیر زیادی بر نتایج دارد و ممکن است باعث ایجاد خطا در شبیه‌سازی شود (Jakeman et al., 2006). معمولاً بعد از کالیبراسیون نیز بین داده‌های واقعی و مشاهداتی اختلاف وجود دارد که دلیل اصلی این ناسازگاری منابع متفاوت عدم قطعیت شامل داده‌های ورودی، پارامترهای مدل و ساختار مدل در مدل‌های بارش-رواناب می‌باشد (Kuczera and Parent, 1998; Vrugt et al., 2003). همچنین، معمولاً به دلیل کمبود داده و یا عدم آگاهی از فرآیند هیدرولوژیکی بارش-رواناب استفاده از مدل‌های فیزیکی برای مهندسان با چالش همراه است (Tingsanchal and Gautam, 2000). مدل‌هایی مانند TOPMODEL، HBV و HEC-HMS در گروه مدل‌های مفهومی جای دارند. از مزایای این نوع مدل‌ها قدرت استفاده از پارامترهای فیزیکی کمتر نسبت به سایر مدل‌ها برای برآورد پاسخ مناسب حوضه آبریز در مقابل بارش است.

در تحقیقات زیادی به منظور شبیه‌سازی بارش-رواناب از TOPMODEL (Nourani et al., 2011b; Bastola, 2008) و HBV (Azizian and Shokuhi, 2014; AI-Safi and Sarukkalige, 2017; Etter et al., 2017) استفاده شده است. (Yaghoubi and Massah Bavani, 2014) برای پیش‌بینی رواناب در منطقه نیمه‌خشک از مدل HBV استفاده کرد. (Bouffard, 2014) و (Seibert, 2009) رواناب شبیه‌سازی شده توسط TOPMODEL و HBV را با یکدیگر مقایسه کرد. مدل‌های مفهومی شامل چندین جزء می‌باشند که هر جزء بخشی از فرآیند بارش-رواناب را مدل می‌کند (Euser et al., 2013). در مدل‌های مفهومی نیاز است تا در هر حوضه مدل مناسب با توجه به فرآیندهای غالب حوضه انتخاب شود. با توجه به تفاوت‌های بین حوضه‌های مختلف مدل‌های متفاوتی برای حوضه‌های مختلف مناسب هستند (McMillan et al., 2011).

با توجه به مشکلات استفاده از مدل‌های فیزیکی و مفهومی، برخی از هیدرولوژیست‌ها مدل‌های جعبه سیاه را معرفی کردند که اغلب مشکلات ذکر شده را ندارد (Kashani et al., 2016). تعدادی از مدل‌های هوش مصنوعی در گروه جعبه سیاه قرار گرفته و اخیراً به طور گسترده در مباحث هیدرولوژیکی استفاده شده و نتایج موفقیت‌آمیزی داشته‌اند (Dorum et al., 2010; Talei et al., 2017; Ahani and Shourian, 2010a). در مدل‌های جعبه سیاه روابط بین ورودی و خروجی ارتباط فیزیکی قابل توجهی ندارند (Minns and Hall, 1996). (Montaseri and Ghavidel, 2014) از دو مدل نروفازی^۱ و برنامه‌ریزی ژنتیک و (Ayashm, 2015)

مدل‌سازی جریان رودخانه، شاخصی مناسب برای پیش‌بینی شرایط آینده و مدیریت منابع آب یک منطقه است. پاسخ حوضه به بارندگی و رواناب ایجاد شده در مقابل نفوذ و تبخیر مهمترین عامل برای تعیین مقدار منابع آب و برنامه‌ریزی و مدیریت آب موجود در حوضه آبریز می‌باشد (Uhlenbrook et al., 2004). در کشورهای خشک که مشکلات زیست‌محیطی و کمبود آب در حال افزایش است، آگاهی از منابع آب به منظور بررسی ارتباط بین تولید غذا، فعالیت‌های اقتصادی و اکوسیستم ضروری است (Falkenmark et al., 2007). همچنین مطالعات زیادی در زمینه تأثیر رواناب بر کیفیت آب مخازن و رودخانه‌ها و مشکلات حاصل از آن انجام شده است (Zhou and Liu et al., 2014). (et al., 2015) پیش‌بینی سیل بدون آگاهی از فرایند بارش-رواناب و شبیه‌سازی آن ممکن نمی‌باشد. به طور تقریبی ۴۰٪ از مخاطرات طبیعی مربوط به سیل می‌باشد و هر ساله ۲۰ تا ۳۰۰ میلیون نفر تحت تأثیر مشکلات ناشی از سیلاب قرار می‌گیرند (Dewan, 2013). در صورتی که در دنیا اقدامات مؤثری جهت کاهش خطرات سیل انجام نشود پیش‌بینی می‌شود تا سال ۲۰۵۰ سیل سالانه هزار میلیارد دلار خسارت وارد نماید (Hallegatte et al., 2013). سیل سال ۲۰۱۰ در پاکستان باعث مرگ افراد زیادی شد و میلیون‌ها دلار خسارت به محصولات و زیرساخت‌ها وارد کرد (Ghumman et al., 2011).

پیش‌بینی رواناب حاصل از بارندگی به مقدار قابل توجهی باعث کاهش خسارات ناشی از سیل و مدیریت بهتر منابع آب می‌شود. ماهیت پیچیده فرایندهایی مانند بارش-رواناب، پیش‌بینی دقیق این پدیده را با مشکل مواجه کرده است. در طول سال‌های اخیر مدل‌های بارش-رواناب مختلفی توسعه یافته و تغییرات قابل توجهی در آن‌ها ایجاد شده است. استفاده از مدل‌های بارش-رواناب به اواخر قرن ۱۹ بر می‌گردد و در حال حاضر مدل‌های هیدرولوژیکی متعددی جهت شبیه‌سازی فرایند بارش-رواناب وجود دارد (Wu and Chau, 2011). مدل‌های بارش-رواناب شامل مدل‌های فیزیکی، مفهومی، تجربی و هوش مصنوعی می‌باشد (Jothiprakash and Magar, 2009). مدل‌های مفهومی یا جعبه خاکستری (Gray box) بر مبنای قوانین فیزیکی استوارند و می‌توانند رفتارهای هیدرولوژیکی را با بیان تجربی شرح دهند. مدل‌های جعبه خاکستری در مقایسه با مدل‌های فیزیکی به داده‌های کمتری نیاز دارند و همچنین با توجه به ابعاد مسأله فرآیند واسنجی این مدل‌ها به حجم محاسبات و زمان کمتری نیاز دارند.

مدل‌های توزیعی بارش-رواناب به اطلاعات قابل توجه هیدرولوژی، هواشناسی و مشخصات حوضه نیاز دارند که ممکن است موجود نباشد.

۲- مواد و روش‌ها

۲-۱- مدل HBV

مدل HBV یک مدل بارش-رواناب یکپارچه مفهومی جهت شبیه‌سازی فرآیندهای هیدرولوژی حوضه آبخیز است که توسط مؤسسه مطالعات هیدرولوژی و هواشناسی سوئد^{۲۱} برای پیش‌بینی مقدار رواناب سیستم‌های تولید انرژی در سال ۱۹۷۰ ارائه شده است. مدل HBV مورد استفاده شده در این تحقیق نسخه یکپارچه آن که قابلیت مدل‌سازی ذوب برف را نیز دارد، استفاده گردید. در این مدل چهار زیر مدل شامل ۱- تجمع و ذوب برف، ۲- رطوبت خاک و بارش مؤثر، ۳- تبخیر و تعرق، ۴- پاسخ رواناب حوضه، که کنترل‌کننده فرآیندهای مؤثر در مدل‌سازی بارش رواناب است، وجود دارد. ورودی‌های این مدل شامل بارش روزانه، دمای حداقل و حداکثر و تبخیر و تعرق روزانه است. مدل مقادیر بارش را با توجه به دما چه به صورت باران و چه به صورت برف دریافت می‌کند. آب باران و ذوب برف وارد بخش رطوبت خاک که مقدار بارش مؤثر را که در رواناب خروجی حوضه مؤثر است شبیه‌سازی می‌کند. باقیمانده بارش به ذخیره خاک افزوده شده که در صورت کافی بودن ذخیره خاک ممکن است این ذخیره تبخیر گردد. در بخش رواناب، خروجی اصلی مدل یعنی جریان خروجی حوضه که خود شامل سه بخش جریان سطحی، زیر سطحی و جریان پایه است، محاسبه می‌شود. در این قسمت برای تعیین دبی خروجی از دو مخزن استفاده می‌شود. اولین مخزن نزدیک سطح خاک بوده و برای محاسبه رواناب سطحی و زیر قشری استفاده می‌شود و دومین مخزن در عمق بیشتر قرار گرفته و برای شبیه‌سازی جریان پایه استفاده می‌شود. آن قسمت از آب باران و ذوب برف که بیشتر از ظرفیت نگهداری آب خاک است وارد مخزن اول می‌شود. هر دو مخزن در ارتباط با هم بوده و با توجه به ذخیره آب هر مخزن، آستانه ارتفاع در مخزن و ضرایب خشکیدگی بخش مختلف رواناب محاسبه می‌شود (AghaKouchak and Habib, 2010). در این مدل ۱۳ پارامتر وجود دارد که مقادیر حداکثر و حداقل هر یک از پارامترها در جدول ۱ آورده شده است و مقادیر آن‌ها با استفاده از داده‌های آموزش و روش SCE_MA بهینه‌سازی شده‌اند.

۲-۲- مدل TOPMODL

مدل هیدرولوژیکی TOPMODL به دلیل سادگی و استفاده از مفاهیم فیزیکی فرآیندهای روندیابی، در طی دهه‌های گذشته به طور گسترده جهت مدل‌سازی بارش رواناب به کار برده شده است (Beven, 1997). مدل TOPMODL یک مدل نیمه توزیعی است که در آن از مفهوم واحد پاسخ هیدرولوژیکی مبتنی بر شاخص رطوبت توپوگرافیکی برای

Behmanesh از دو مدل نروفازی و شبکه عصبی^۲ برای شبیه‌سازی بارش-رواناب استفاده کردند. (Veintimilla-Reyes et al. (2016) از دو نوع متفاوت شبکه عصبی و Anusree and Varghese (2016) از سه روش شبکه عصبی، نروفازی برای پیش‌بینی رواناب استفاده کردند. (Nourani (2016) نوع جدیدی از شبکه عصبی و Humphrey et al. (2016) با ترکیب مدل مفهومی و شبکه عصبی رواناب را پیش‌بینی کردند. (Ghorbani et al. (2015) با ترکیب موجک و مدل‌های هوش مصنوعی نشان داد موجک می‌تواند باعث افزایش دقت پیش‌بینی رواناب شود. در اغلب این تحقیقات مدل‌های جعبه سیاه رواناب را با دقت قابل قبولی پیش‌بینی کرده‌اند. تحقیقات (Javan et al. (2015) و Rezaeianzadeh et al. (2013) نشان داد مدل جعبه سیاه فرآیند بارش رواناب را با دقت بیشتری نسبت به مدل‌های مفهومی شبیه‌سازی می‌کند. تحقیقات زیادی در مورد پیش‌بینی رواناب با استفاده از ماشین بردار پشتیبان انجام شده است (Misra et al., 2009; Wang et al., 2009; Noori et al., 2011; Okkan and Serbes, 2012; Seyedian et al., 2014; He et al., 2014; Ahmadi et al., 2014; اما در تحقیقات کمی مدل‌های جعبه سیاه و مفهومی با یکدیگر مقایسه شده‌اند. (Pourreza Bilondi et al. (2014) رواناب روزانه رودخانه لیف آمریکا را شبیه‌سازی کردند و نشان دادند روش ماشین بردار پشتیبان رواناب را با دقت بیشتری نسبت به مدل مفهومی Hymod پیش‌بینی می‌کند. نتایج مطالعه (Kakaei Lefdani et al. (2013) نشان داد دقت مدل‌ها پیش‌بینی رواناب به ترتیب عبارتند از: ماشین بردار پشتیبان، نروفازی و مدل‌های مفهومی هیدرولوژیکی.

مرور منابع نشان می‌دهد در اغلب تحقیقات فقط یک مدل مفهومی با یک مدل هوش مصنوعی مقایسه شده است این در حالی است که با توجه به شرایط حوضه ممکن است مدل یکپارچه دیگری وجود داشته باشد که با توجه به ساختار خود و الگوریتم بهینه‌سازی، فرآیند بارش رواناب را با دقت بیشتری مدل‌سازی نماید. همچنین با توجه به آنکه در اکثر تحقیقات فقط دو مدل منفرد با هم مقایسه می‌شوند نمی‌توان عملکرد دو گروه مدل‌ها (مفهومی و جعبه سیاه) را با دقت زیادی تحلیل کرد. ممکن است در یک حوضه یک مدل مفهومی نسبت به یک مدل هوش مصنوعی دقت بیشتری داشته باشد اما دقت آن نسبت به مدل هوش مصنوعی دیگر کمتر باشد. بنابراین در این تحقیق فرآیند بارش-رواناب در رودخانه نوده‌خرمالو به صورت روزانه توسط دو مدل جعبه سیاه نروفازی و ماشین بردار پشتیبان و مدل‌های جعبه خاکستری TOPMODEL و HBV شبیه‌سازی می‌گردد.

Table 1- HBV model parameters range for Khormaloo basin
جدول ۱- محدوده پارامترهای مدل HBV برای حوضه آبخیز نوده خرمالو

No.	Symbol	Parameter definition	Under limit	Upper Limit
1	TS	Threshold Temperature (c)	3	-3
2	CFMAX	Degree day factor (mm/C)	20	0
3	CFR	Refreezing factor	1	0
4	CWH	Water holding capacity of snow	0.8	0
5	BETA	Exponential parameter in soil routine	7	0
6	LP	Limit for potential evapotranspiration	1	0.3
7	FC	Maximum soil moisture content(mm)	2000	1
8	PERC	Maximum flux from Upper to Lower Zone (mm/Dt)	100	0
9	K1	Recession coefficient for upper tank (1/Dt)	1	0.01
10	K2	Recession coefficient for lower tank (1/Dt)	0.10	0.05
11	K0	Near surface flow coefficient (1/Dt)	2	0.05
12	UZL	Near surface flow threshold (mm)	100	0
13	MAXBAS	Transfer function parameter	6	1

۲-۳- ماشین بردار پشتیبان رگرسیون (SVM)

اگر داده‌ها به صورت مجزا از هم باشند، SVM به ماشین‌های خطی برای تولید یک سطح بهینه که داده‌ها را بدون خطا و با حداکثر فاصله میان صفحه و نزدیکترین نقاط آموزشی (بردارهای پشتیبان) تفکیک می‌نمایند، آموزش می‌دهد. اگر نقاط آموزشی را به صورت $[x_i, y_i]$ و بردار ورودی $x_i \in R^n$ و ارزش طبقه $y_i \in \{-1, 1\}, i = 1, \dots, l$ تعریف کنیم، آنگاه در حالتی که داده‌ها به صورت خطی قابل تفکیک هستند، قواعد تصمیم‌گیری بر اساس رابطه ۱ به گونه‌ای تعریف می‌شوند که طبقات تصمیم‌گیری باینری را توسط یک صفحه بهینه تفکیک کنند:

همگن‌بندی حوضه استفاده می‌شود. در این مدل فرض می‌شود هدایت هیدرولیکی ناحیه اشباع با استفاده از شیب توپوگرافی سطح زمین قابل برآورد است. همچنین رابطه قابلیت انتقال خاک با عمق یک تابع توانی متناسب با کمبود اشباع است (Singh, 1995). در جدول ۲ پارامترهای مدل و حد بالا و پایین آن‌ها ارائه شده است. در این مدل ورودی‌های شامل بارش، تبخیر و تعرق پتانسیل، ارتفاع رواناب حوضه، تابع تأخیر حوضه و شاخص رطوبت توپوگرافیکی می‌باشد. به منظور بهینه‌سازی پارامترهای مدل از روش پرش تصادفی استفاده گردید.

Table 2- TOPMODEL model range of parameters for Khormaloo basin
جدول ۲- محدوده پارامترهای مدل TOPMODEL برای حوضه آبخیز نوده خرمالو

No.	Symbol	Parameter definition	Under limit	Upper limit
1	Qs0	Initial subsurface flow per unit area (m)	0.0004	0
2	LnTe	Log of the areal average of transmissivity 0 (m ² /h)	3	-5
3	M	Model parameter controlling the rate of decline of transmissivity in the soil profile	0.1	0.03
4	Sro	Initial root zone storage deficit (m)	0.3	0
5	Srmax	Maximum root zone storage deficit (m)	0.5	0.01
6	Td	Unsaturated zone time delay per unit storage deficit (h/m)	1000	0
7	Vr	Channel flow inside catchment (m/h)	2500	100
8	K0	Surface hydraulic conductivity (m/h)	3	0
9	CD	Capillary drive	5	0

۲-۵- اجرای مدل‌های جعبه سیاه

برای شبیه‌سازی بارش-رواناب روزانه رودخانه نوده‌خرمالو از داده‌های مربوط به میانگین رواناب، بارندگی و دما در گام‌های زمانی مختلف با ترکیب متفاوت (جدول ۳) به‌عنوان ورودی برای مدل‌های ماشین بردار پشتیبان و نروفازی استفاده گردید. در مدل نروفازی هر ۹ ترکیب ورودی مختلف (تمامی سناریوها) با ۸ تابع عضویت مثلثی^{۱۱}، دوزنقه‌ای^{۱۲}، زنگوله‌ای^{۱۳}، گوسی^{۱۴}، گوسی^{۱۵}، پی^{۱۶}، دسیگموئید^{۱۷} و پسیگموئید^{۱۸} با خروجی ثابت و قوانین متغیر (بسته به تعداد ورودی هر سناریو) اجرا گردید. برای تعیین بهترین توابع عضویت و همچنین بهترین قوانین از فرایند آزمون و خطا استفاده شد. در هر تابع عضویت، در صورتی که یک قانون حذف می‌گردید و مقدار خطا کاهش می‌یافت قانون بعدی حذف می‌شد و در صورتی که خطا افزایش نشان می‌داد قانون مجدد به مجموعه قوانین اضافه می‌شد. در مدل ماشین بردار پشتیبان مقادیر C، ε و لا با روش آزمون و خطا به نحوی تعیین می‌شود که مقادیر خطای داده‌های آموزش^{۱۹} و آزمون^{۲۰} دارای کمترین مقدار و مشابه یکدیگر باشد. مشابه بودن مقادیر خطای آموزش و آزمون نشان می‌دهد مدل به خوبی آموزش دیده و می‌تواند با دقت بالایی رواناب را پیش‌بینی نماید.

۲-۶- ترکیب ورودی‌های مدل‌های جعبه سیاه

اطلاعات مورد استفاده شامل داده‌های روزانه رواناب، بارندگی و دما در طی ۴ سال دوره آماری است. ورودی‌های مدل‌های جعبه سیاه بر اساس مرور منابع تعیین شد. سپس با توجه به نتایج هر سناریو، ورودی‌هایی که خطا را افزایش می‌دادند و یا تأثیری بر کاهش خطا نداشتند حذف و ورودی‌های دیگر اضافه می‌شدند. برای شبیه‌سازی بارش-رواناب روزانه از سه متغیر با روش تأخیر زمانی استفاده شد. جدول ۳ ترکیب داده‌های ورودی را نشان می‌دهد. اندیس‌های t-1، t-2، ... نشان‌دهنده ورودی یک روز قبل، دو روز قبل و غیره است. به عنوان مثال مدل شماره ۹ با پنج ورودی Q_{t-1}، Q_{t-2}، Q_{t-3}، R_{t-1} و T_{t-1} به ترتیب دبی روز قبل، دبی دو روز قبل، دبی سه روز قبل، بارندگی روز قبل و دمای روز قبل را نشان می‌دهد.

از کل داده‌ها ۸۰٪ داده‌ها برای آموزش و ۲۰٪ باقی‌مانده برای آزمون استفاده شد.

۲-۷- منطقه مورد مطالعه

منطقه مورد مطالعه در این تحقیق حوضه گرگان‌رود است که از شریان‌های اصلی شمال کشور و استان گلستان می‌باشد.

$$y = \text{sign}(\sum_{i=1}^N y_i a_i (X, X) + b) \quad (1)$$

که در آن Y خروجی معادله، y_i ارزش طبقه نمونه آموزشی X_i و نشان‌دهنده ضرب داخلی است. بردار $x = (x_1, x_2, \dots, x_n)$ بردارهای i = 1, ..., N, X_i بردارهای پشتیبان هستند. در معادله ۱، پارامترهای a_i, b تعیین‌کننده ابر صفحه هستند. اگر داده‌ها به صورت خطی قابل تفکیک نباشند، معادله ۱ به صورت رابطه ۲ تغییر می‌یابد:

$$Y = \text{sign}(\sum_{i=1}^N y_i a_i K(X, X_i)) + b \quad (2)$$

تابع K(X, X_i) تابع کرنلی است که برای ایجاد ماشین‌هایی با انواع مختلفی از سطوح تصمیم‌گیری غیرخطی در فضای داده‌ها، ضرب‌های داخلی تولید می‌کند.

۲-۴- نروفازی (ANFIS)

چنانچه خروجی هر لایه شبکه نروفازی را به صورت Q_{i,j} نشان داده شود که خروجی i امین گروه در ۱ امین لایه است، آنگاه می‌توان عملکرد لایه‌های مختلف را به صورت زیر بیان کرد.

لایه ۱: هرگره در این لایه معادل یک مجموعه فازی می‌باشد (رابطه ۳):

$$Q_i^1 = \mu_{A_i}(x) \quad (3)$$

لایه ۲: هرگره این لایه \prod نشان داده شده است که در این گرعه سیگنال‌های ورودی در یکدیگر ضرب شده و تولید خروجی می‌کند (رابطه ۴):

$$w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), \quad i = 1, 2 \quad (4)$$

لایه ۳: هرگره در این لایه با N نشان داده شده که نسبت درجه فعالیت آمین قانون را به جمع درجه‌های فعالیت کلیه قوانین محاسبه می‌کند (رابطه ۵):

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (5)$$

لایه ۴: خروجی هرگره در این لایه به صورت رابطه ۶ است:

$$Q_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (6)$$

که در آن \bar{w}_i خروجی لایه سوم و {p_i, q_i, r_i} مجموعه پارامترهای تطبیقی این لایه می‌باشند. این پارامترها به نام پارامترهای نتیجه^{۱۰} خوانده می‌شوند.

لایه ۵: هرگره در این لایه که به صورت \sum نشان داده شده است مقدار خروجی نهایی را به صورت رابطه ۷ محاسبه می‌کند،

$$Q_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (7)$$

بارندگی و دمای ایستگاه نوده‌خاندوز در رودخانه نوده خرمالو است. ایستگاه نوده‌خاندوز در طول جغرافیایی ۳۴۶۶۱۷ متر، عرض جغرافیایی ۴۱۰۲۹۵۳ متر و ارتفاع از سطح دریا ۲۸۰ متر واقع شده است (Golestan regional water authority, 2004). در جدول ۴ برخی از خصوصیات آماری داده‌های مورد استفاده از ایستگاه مطالعاتی آورده شده است (Golestan regional water authority, 2004).

۸-۲- معیارهای ارزیابی

از پارامترهای آماری ضریب تعیین^{۲۲}، ریشه میانگین مربعات خطا^{۲۳}، میانگین خطای اریب^{۲۴} و قدر مطلق خطا به منظور بررسی مدل‌ها استفاده گردید. برای محاسبه ضریب تعیین، ریشه میانگین مربعات خطا، میانگین خطای اریب و قدر مطلق خطا به ترتیب از روابط ۸-۱۱ استفاده شد:

$$R^2 = 1 - \frac{\sum(Q_e - Q_o)^2}{\sum(Q_o - \bar{Q}_o)^2} \quad (8)$$

$$RMSE = \sqrt{\frac{\sum(Q_e - Q_o)^2}{N}} \quad (9)$$

$$MBE = \frac{\sum_{i=1}^N (Q_e - Q_o)}{N} \quad (10)$$

$$MEF = \frac{1}{N} \sum_{i=1}^n \left(\frac{|Q_e - Q_o|}{\max(Q_e) - \min(Q_e)} \right) \times 100 \quad (11)$$

که در آن N: تعداد داده‌ها، Q_e: دبی شبیه‌سازی شده، Q_o: دبی مشاهداتی، می‌باشند.

Table 3- Combination of inputs
جدول ۳- ترکیب ورودی‌های مختلف

Scenario No.	Output	Model Input				
1	Q _t	Q _{t-1}				
2	Q _t	Q _{t-1}	Q _{t-2}			
3	Q _t	Q _{t-1}	Q _{t-2}	Q _{t-3}		
4	Q _t	Q _{t-1}	Q _{t-2}	Q _{t-3}	Q _{t-4}	
5	Q _t	Q _{t-1}	Q _{t-2}	Q _{t-3}	R _{t-1}	
6	Q _t	Q _{t-1}	Q _{t-2}	Q _{t-3}	T _{t-1}	
7	Q _t	Q _{t-1}	Q _{t-2}	Q _{t-3}	R _{t-1}	R _{t-2}
8	Q _t	Q _{t-1}	Q _{t-2}	Q _{t-3}	T _{t-1}	T _{t-2}
9	Q _t	Q _{t-1}	Q _{t-2}	Q _{t-3}	R _{t-1}	T _{t-1}

در شرق از کوه‌های واقع در استان خراسان شمالی سرچشمه گرفته و پس از طی مسافت در حدود ۲۵۰ کیلومتر در استان گلستان در نهایت در غرب استان به دریای خزر می‌ریزد. این رودخانه از طول جغرافیایی ۵۴ درجه تا ۵۶ درجه و ۲۹ دقیقه شرقی و از عرض جغرافیایی ۳۶ درجه و ۳۶ دقیقه تا ۳۷ درجه و ۴۷ دقیقه شمالی امتداد دارد. مساحت حوضه آبریز گرگان‌رود حدود ۱۱۳۰۰ کیلومتر مربع است. حوضه آبریز گرگان‌رود با متوسط بارندگی ۶۰۰ میلی‌متر در سال دارای اقلیم معتدل خرسی است. داده‌های مورد استفاده در این تحقیق میانگین روزانه دبی،

Table 4- Statistical characteristics of runoff, rainfall and temperature of the Khormaloo River in period of 2000-2004

*جدول ۴- خصوصیات آماری رواناب، بارندگی و دما رودخانه نوده خرمالو در سال‌های ۸۳-۱۳۷۹

	Q _{mean} (m ³ s ⁻¹)	R _{min} (mm)	R _{mean} (mm)	R _{max} (mm)	T _{min} (C)	T _{mean} (C)	T _{max} (C)
October	1.57	0.00	2.02	35.00	7.50	14.96	23.50
November	1.35	0.00	2.47	49.00	0.00	9.62	18.00
December	1.34	0.00	2.63	52.50	-3.50	3.36	11.00
January	1.55	0.00	1.95	47.00	-5.00	2.47	11.50
February	2.14	0.00	3.18	63.00	-7.00	1.39	13.00
March	3.79	0.00	3.48	42.00	-6.50	5.58	19.00
April	3.04	0.00	4.71	48.50	-4.00	9.21	23.00
May	2.60	0.00	2.39	31.50	0.00	13.07	22.00
Jun	1.29	0.00	1.96	47.50	9.00	16.40	25.50
July	0.66	0.00	1.87	40.00	10.60	18.82	26.50
August	0.86	0.00	1.79	56.00	12.00	20.12	26.50
September	1.04	0.00	2.07	58.00	10.00	18.25	25.00

* (T) دما، (R) بارندگی و (Q) دبی

۳- نتایج و بحث

۳-۱- مدل‌های جعبه سیاه

نروفازی (سناریو ۷) باعث بهبود نتایج می‌شود اما تأثیر آن از دمای روز قبل کمتر است. همچنین با اضافه کردن دمای دو روز قبل (سناریو ۸) دقت شبیه‌سازی کاهش می‌یابد. با اضافه شدن بارندگی دو روز قبل به سناریو ۵، سناریو ۷ ایجاد می‌شود که اندکی باعث کاهش دقت ماشین بردار پشتیبان و افزایش دقت نروفازی می‌شود. در تحقیق Wu and Chau (2011) با اضافه کردن بارندگی دو روز قبل دقت برآورد رواناب کاهش پیدا کرد که مشابه نتایج ماشین بردار پشتیبان است اما در این تحقیق بارندگی دو روز قبل باعث کاهش خطای نروفازی نشده است.

دما و بارندگی روز قبل (سناریوهای ۵ و ۶) تأثیر مشابهی بر شبیه‌سازی رواناب در ماشین بردار پشتیبان دارند اما در مدل نروفازی تأثیر دمای روز قبل بر بهبود نتایج شبیه‌سازی رواناب بیشتر از بارندگی روز قبل می‌باشد. استفاده از پارامتر دما به ویژه در حوضه‌های برف‌گیر مانند حوضه مطالعاتی این تحقیق نقش زیادی در افزایش دقت مدل‌ها دارد. Aalami and Hosseinzadeh (2010) نیز در تحقیقات خود به این موضوع اشاره کرده‌اند. Nabizadeh et al. (2011) بیان کردند استفاده از پارامتر دما فقط در ماه آذر در پیش‌بینی مؤثر بوده است که نشان می‌دهد تأثیر دما بر رواناب در تمام حوضه‌ها یکسان نیست. مقایسه سناریوهای ۶ و ۸ نشان می‌دهد با اضافه شدن دمای دو روز قبل به دمای روز قبل دقت پیش‌بینی رواناب در نروفازی به مقدار قابل توجهی کاهش و در ماشین بردار پشتیبان اندکی افزایش می‌یابد.

سناریو ۶ نروفازی و سناریو ۵ و ۶ ماشین بردار پشتیبان به‌عنوان سناریوهای قابل قبول انتخاب گردیدند. (Dastorani et al. (2011) و Talei et al. (2010b) نیز نشان دادند تأثیر ورودی‌های یکسان بر نتایج مدل‌های مختلف، متفاوت می‌باشد. سناریو ۶ در مدل نروفازی با ریشه میانگین مربعات خطای ۱/۲۳، ضریب تعیین ۰/۷۷، قدر مطلق خطا ۲/۴۲ و میانگین خطای اریب ۰/۰۶- در مرحله آزمون بهترین نتیجه را ارائه می‌دهد. خطای ریشه میانگین مربعات بهترین سناریو ماشین بردار پشتیبان نسبت به نروفازی حدود ۱۵ درصد بیشتر است و نروفازی توانسته با دقت بیشتری رواناب را شبیه‌سازی نماید.

شکل ۱ مقادیر مشاهداتی و شبیه‌سازی جریان رودخانه نوده‌خرمالو مربوط به سناریوهای ۳، ۵ و ۶ را در مقیاس روزانه در مرحله آزمون نشان می‌دهد. با توجه به این شکل مشاهده می‌شود با پارامترهای ورودی سناریو ۳ دقت هر دو مدل تقریباً یکسان است. در سناریو ۵ خط برازش مدل نروفازی و ماشین بردار پشتیبان در مقدار دبی‌های کم تفاوت چندانی با هم نداشته و در شبیه‌سازی دبی‌های کم عملکرد یکسانی داشته‌اند ولی خط برازش مدل نروفازی برای دبی‌های بالاتر از ۱۰ متر مکعب بر ثانیه به خط ۱:۱ نزدیک‌تر می‌باشد.

نتایج مربوط به اجرای نروفازی و ماشین بردار پشتیبان با سناریوهای مختلف در جدول ۵ آورده شده است. جدول ۵ نشان می‌دهد ورودی دبی یک روز قبل نمی‌تواند رواناب را به خوبی پیش‌بینی کند که مشابه نتایج Nourani et al. (2011a) می‌باشد. با اضافه شدن دبی دو روز قبل مقدار خطای نروفازی اندکی افزایش و ماشین بردار پشتیبان کاهش نشان می‌دهد. در سناریو ۳ با اضافه شدن دبی در سه گام زمانی قبل به سناریو ۲، مقدار خطای مدل نروفازی در مراحل آموزش و آزمون کاهش می‌یابد و ماشین بردار پشتیبان تقریباً تغییر نمی‌کند. با اضافه شدن دبی ۴ روز قبل (سناریو ۴) مشاهده می‌شود مقدار خطا و ضریب تعیین مدل نروفازی در مرحله آزمون مشابه سناریو ۳ است. همچنین، مقدار خطای سناریو ۴ ماشین بردار پشتیبان نسبت به سناریو ۳ اندکی کاهش یافته است. با افزایش تعداد ورودی، سرعت اجرای مدل‌ها کاهش می‌یابد، بنابراین با توجه به نتایج سناریوهای ۳ و ۴ هر دو مدل، بارندگی روز قبل به سناریو ۳ اضافه شد و سناریو ۵ اجرا گردید. مقایسه میزان خطای سناریو ۵ با سناریو ۳ در مرحله آزمون نشان می‌دهد مدل نروفازی و ماشین بردار پشتیبان به ترتیب مقدار خطا را ۹/۴ و ۸/۵ درصد کاهش داده‌اند. در تحقیق Talei et al. (2010b) و Wu and Chau (2011) ترکیب بارندگی و دبی تأثیر قابل توجهی بر دقت برآورد رواناب داشته است که مشابه نتایج هر دو مدل این تحقیق است. (Mutlu et al. (2008) و Goswami and O'Connor (2007) نیز نشان دادند ترکیب بارندگی و دبی در روزهای قبل، رواناب را با دقت قابل قبولی شبیه‌سازی می‌کند که مشابه نتایج نروفازی و ماشین بردار پشتیبان است.

سناریو ۶ با ترکیب ورودی دبی تا سه گام زمانی قبل و دمای روز قبل اجرا گردید. نتایج نشان می‌دهد مدل نروفازی در مرحله آزمون رواناب را با کمترین مقدار خطا و بیشترین ضریب تعیین شبیه‌سازی کرده است؛ اما دقت شبیه‌سازی ماشین بردار پشتیبان با سناریو ۶ تفاوت چندانی با سناریو ۵ ندارد و اضافه شدن دمای روز قبل مشابه بارندگی روز قبل در شبیه‌سازی تأثیرگذار بوده است. سناریو ۷، ۸ و ۹ با پنج پارامتر ورودی قادر به ارائه نتایج مطلوب‌تر نبوده و در برخی موارد نتایج مشابه یا ضعیف‌تر از سناریوهای ۵ و ۶ با تعداد پارامتر ورودی کمتر ارائه کرده‌اند. Nourani et al. (2011a) نیز نشان دادند هرچه ورودی‌ها بیشتر شود و بارندگی و دبی در روزهای قبل به ورودی‌ها اضافه شود، پیچیدگی مدل افزایش می‌یابد و ممکن است باعث افزایش خطای شبیه‌سازی گردد که مشابه نتایج به دست آمده توسط سناریوهای ۷، ۸ و ۹ می‌باشد. اضافه کردن بارندگی دو روز قبل به

Table 5- Results of statistical criteria for ANFIS and SVM with different input combination
جدول ۵- نتایج معیارهای آماری مربوط به مدل ANFIS و SVM با ترکیبات ورودی مختلف

Scenario	Membership function SVM parameters	Train				Test			
		RMSE	R ²	MBE	MEF	RMSE	R ²	MBE	MEF
ANFIS	1 Trimf	1.28	0.52	0.00	2.50	1.60	0.61	-0.12	2.58
	2 Gbellmf	1.26	0.53	0.00	2.49	1.63	0.60	-0.15	2.48
	3 Trimf	1.23	0.56	0.00	2.38	1.51	0.66	-0.12	2.40
	4 Gbellmf	1.10	0.64	0.00	2.45	1.50	0.68	0.00	2.50
	5 Trimf	1.08	0.65	0.00	2.40	1.38	0.71	-0.09	2.52
	6 Psigmf	1.17	0.60	0.00	2.35	1.23	0.77	-0.06	2.42
	7 Pimf	1.02	0.69	0.00	2.35	1.34	0.72	-0.04	2.42
	8 Trimf	1.10	0.65	0.00	2.56	1.41	0.70	-0.02	2.62
	9 Trimf	1.10	0.65	0.00	2.40	1.65	0.65	-0.04	2.52
SVM	1 C=1500, ε=0.005, γ=0.35	1.32	0.50	-0.12	2.30	1.57	0.63	-0.23	2.38
	2 C=2300, ε=0.03, γ=0.54	1.29	0.53	-0.15	2.20	1.52	0.67	-0.28	2.26
	3 C=900, ε=0.09, γ=0.43	1.27	0.54	-0.10	2.25	1.52	0.64	-0.18	2.30
	4 C=4100, ε=0.1, γ=0.91	1.23	0.57	-0.14	2.27	1.48	0.66	-0.18	2.32
	5 C=500, ε=0.003, γ=0.76	1.15	0.63	-0.01	2.30	1.41	0.72	-0.13	2.39
	6 C=6100, ε=0.07, γ=0.21	1.20	0.60	-0.15	2.30	1.42	0.70	-0.06	2.39
	7 C=17500, ε=0.01, γ=0.66	1.01	0.71	-0.01	2.31	1.44	0.70	-0.14	2.38
	8 C=120, ε=0.009, γ=0.03	1.17	0.62	-0.10	2.26	1.41	0.70	-0.11	2.31
	9 C=1150, ε=0.06, γ=0.042	1.24	0.56	-0.10	1.26	1.46	0.68	-0.12	1.26

در شکل ۲ مقادیر مشاهده‌ای و پیش‌بینی شده توسط سناریو ۶ هر دو مدل در دو دوره آموزش و آزمون آورده شده است. همان‌طور که ملاحظه می‌شود دقت مدل نروفازی و ماشین بردار پشتیبان در شبیه‌سازی دبی‌های کم در بیشتر نقاط یکسان بوده ولی مدل نروفازی دبی‌های بیشتر از ۱۰ متر مکعب بر ثانیه را با دقت بالاتری در دوره آموزش و آزمون شبیه‌سازی کرده است. (Behzad et al. (2009) و Kakaei Lefdani et al. (2013) نشان دادند که نروفازی و ماشین بردار پشتیبان در تمام بازه مورد بررسی نتایج یکسان ارائه می‌دهند که مشابه نتایج نروفازی این تحقیق می‌باشد و با نتایج ماشین بردار پشتیبان همخوانی ندارد.

۳-۲- مدل‌های مفهومی

نتایج معیارهای ارزیابی دو مدل HBV و TOPMODEL در جدول ۶ آورده شده است. همانند مدل‌های جعبه سیاه از یک دوره سه ساله برای آموزش و یک دوره یک ساله برای آزمون استفاده شد. مقادیر خطای هر دو مدل در مرحله آزمون نسبت به آموزش بیشتر است که نشان می‌دهد مدل‌ها نتوانسته‌اند به خوبی آموزش ببینند و نمی‌توانند رواناب را با دقت مرحله آموزش شبیه‌سازی نمایند. مقادیر خطای هر دو مدل HBV و TOPMODEL در مرحله آزمون تفاوت زیادی با یکدیگر ندارند و هر دو مدل، رواناب را با دقت کمی پیش‌بینی می‌کنند.

این موضوع به دلیل پیش‌بینی بهتر دبی‌های زیاد توسط مدل نروفازی است. به طور کلی هر دو مدل رواناب را کمتر از مقدار واقعی پیش‌بینی می‌کنند که مقدار منفی خطای MBE نیز این موضوع را تأیید می‌کند اما کم‌برآوردی در ماشین بردار پشتیبان بیشتر از نروفازی است.

در سناریو ۶ مانند سناریو ۵ هر دو مدل به طور کلی رواناب را کمتر از مقدار واقعی پیش‌بینی کرده‌اند اما دبی‌های بیشتر از ۱۰ متر مکعب بر ثانیه توسط نروفازی بهتر از ماشین بردار پشتیبان برآورد شده است. (Ghafari and Vafakhah (2013) نشان دادند نروفازی مقادیر زیاد رواناب را با دقت بیشتری نسبت به شبکه عصبی پیش‌بینی می‌کند. همچنین، (Goswami and O'Connor (2007) نیز نشان دادند مقادیر زیاد رواناب کمتر از مقدار واقعی پیش‌بینی می‌شود. به طور کلی بیشتر داده‌ها مربوط به دبی‌های کمتر از ۵ متر مکعب بر ثانیه و دبی‌های کم بوده و در نتیجه تعداد داده‌ها در این دامنه بیشتر است. در نتیجه هر دو مدل دبی‌های کم را با دقت بیشتری برآورد کرده‌اند. (Dastorani et al. (2011) نشان دادند شبکه عصبی و نروفازی داده‌های حد بالا را با دقت کمی پیش‌بینی می‌کنند که به دلیل تعداد کم این داده‌ها در مرحله آموزش است.

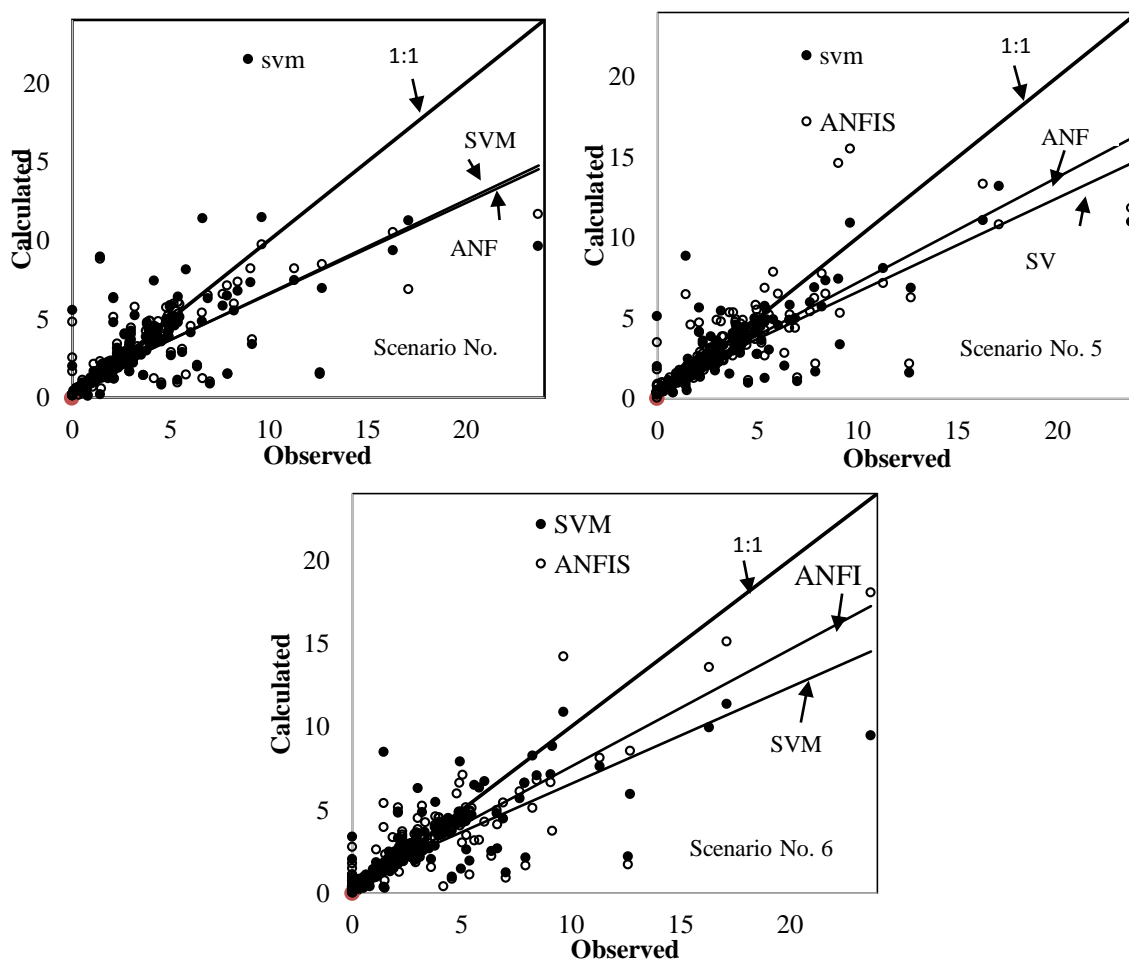


Fig. 1- Observational and computational fit line at test stage in scenarios 3, 5 and 6
 شکل ۱- برازش دبی‌های مشاهده‌ای و محاسباتی مرحله آزمون در سناریوهای ۳، ۵ و ۶

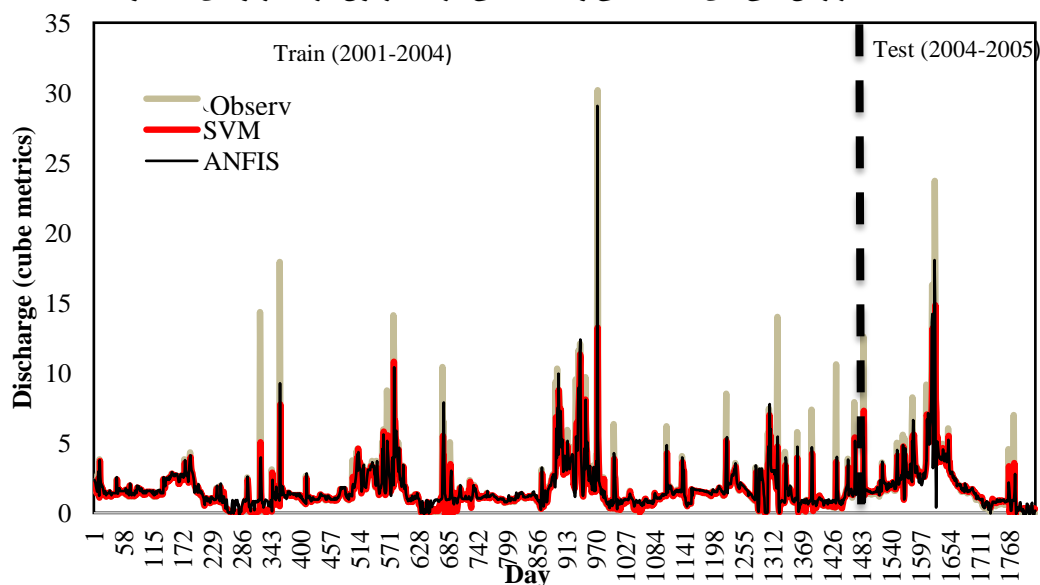


Fig. 2- Comparison of observed discharge and the results of Neuro-Fuzzy and Support Vector Machines Models in Scenario 6

شکل ۲- مقایسه مقادیر مشاهده‌ای و سناریو ۶ مدل‌های نروفازی و ماشین بردار پشتیبان

تحقیقات منابع آب ایران، سال چهاردهم، شماره ۵، زمستان ۱۳۹۷
 Volume 14, No. 5, Winter 2019 (IR-WRR)

رودخانه جریان داشته، دبی را چندین برابر مقدار واقعی برآورد کرده است.

مدل HBV در فصل بهار و تابستان رواناب را بسیار بهتر از TOPMODEL برآورد کرده است. (Kuo et al. (2010) نیز مشاهده کردند رواناب برآورد شده توسط HBV در ماه‌های گرم سال دارای دقت قابل قبولی است که مشابه این تحقیق می‌باشد.

شکل ۴ عملکرد چهار مدل مطالعاتی را در شبیه‌سازی فرایند بارش- رواناب نشان می‌دهد. مقادیر خطای شبیه‌سازی رواناب در هر دو مدل مفهومی بیشتر از مدل‌های هوشمند و مقادیر ضریب تعیین آن‌ها نیز بسیار کمتر از مدل‌های هوشمند است. شکل ۴ نشان می‌دهد نروفازی و ماشین بردار پشتیبان با دقت بیشتری توانسته‌اند رواناب را برآورد کنند. نروفازی و ماشین بردار پشتیبان با یک ورودی شامل دبی روز قبل (جدول ۵) توانستند رواناب را با دقت بسیار بیشتری نسبت به HBV و TOPMODEL برآورد کنند که بیانگر قدرت هوش مصنوعی در تحلیل پدیده بارش- رواناب و شبیه‌سازی دقیق‌تر می‌باشد.

خطای ریشه میانگین مربعات HBV حدود ۷ درصد بیشتر از TOPMODEL است. بیشترین تفاوت مربوط به خطای MBE می‌باشد که نشان می‌دهد در مجموع، TOPMODEL رواناب را بسیار بیشتر از مقدار واقعی برآورد کرده است.

شکل ۳ نتایج شبیه‌سازی دو مدل مفهومی را در دوره آزمون نشان می‌دهد. به طور کلی هر دو مدل رواناب را در نیمه اول هیدروگراف که مربوط به فصول پاییز و زمستان می‌شود کمتر از مقدار واقعی و در فصل تابستان، هر دو مدل دبی‌های پیک را بسیار بیشتر از مقدار واقعی برآورد کرده‌اند. در نیمه دوم سال آبی (بهار و تابستان) TOPMODEL در بیشتر طول دوره، تغییرات رواناب را به صورت یکنواخت و با روند ثابتی شبیه‌سازی کرده و رواناب را بسیار بیشتر از مقدار واقعی برآورد کرده است. (Holko and Lepisto (1997) مشاهده کردند با گرم شدن هوا در فصل بهار TOPMODEL رواناب را بیشتر از مقدار واقعی برآورد می‌کند اما در تحقیق آن‌ها در فصل تابستان رواناب با دقت قابل قبولی برآورد شده بود. در این تحقیق TOPMODEL نه تنها رواناب را در فصل بهار بیش‌برآورد داشته است بلکه در فصل تابستان نیز که بارندگی بسیار کم بوده و در اغلب زمان‌ها دبی پایه در

Table 6- Results of evaluation criteria for HBV and TOPMODEL models
جدول ۶- نتایج معیارهای ارزیابی مدل‌های HBV و TOPMODEL

	RMSE		R ²		MBE		MEF	
	TOPMODE	HBV	TOPMODEL	HBV	TOPMODEL	HBV	TOPMODEL	HBV
L								
Train	1.70	1.59	0.16	0.32	-0.001	-0.16	3.30	3.28
Test	2.31	2.48	0.17	0.19	0.13	-0.65	6.31	5.45




Fig. 3- Observed discharge and discharge simulated with HBV and TOPMODEL in test phase
شکل ۳- دبی مشاهداتی و شبیه‌سازی شده با HBV و TOPMODEL در مرحله آزمون

فرآیند واسنجی و کالیبره کردن پارامترها تأثیر زیادی بر عملکرد آن دارد به طوری که در این حالت حتی نوع تابع هدف که در بهینه‌سازی مورد استفاده قرار می‌گیرد بر عملکرد مدل مؤثر است (Westerberg et al., 2011). با توجه نتایج این تحقیق مشاهده می‌شود دو مدل مفهومی با توجه به ساختار خود نتوانسته‌اند فرآیندهای غالب حوضه را شبیه‌سازی کنند. در مدل‌های هوش مصنوعی با توجه به داده‌های موجود، ساختار (شامل نوع ورودی‌ها و نوع توابع عضویت، تعداد قوانین و غیره) مناسب انتخاب می‌شود. به طور کلی انعطاف‌پذیری این مدل‌ها بیشتر است. یکی از دلایل عملکرد مناسب این مدل‌ها را می‌توان ورودی‌های آن‌ها دانست که مقادیر دبی در گام زمانی قبل است که تأثیر زیادی بر دقت شبیه‌سازی رواناب دارد. با توجه به آن که در مدل‌های جعبه سیاه فقط داده‌های ورودی و خروجی مورد بررسی قرار می‌گیرند وجود داده‌های نویزدار در عملکرد مدل تأثیر زیادی می‌گذارند.

برای بررسی تأثیر بارندگی و دما در ماه‌های مختلف بر دقت شبیه‌سازی بارش-رواناب از سناریو ۵ (دبی تا سه گام زمانی قبل و بارندگی روز قبل) و ۶ (دبی تا سه گام زمانی قبل و دمای روز قبل) در دو مدل نروفازی و ماشین بردار پشتیبان که دارای بیشترین دقت بودند استفاده شد. در شکل ۵ معیارهای ارزیابی سناریوهای ۵ و ۶ در ماه‌های مختلف برای دو مدل آورده شده است. بیشترین مقدار ضریب همبستگی مدل نروفازی و ماشین بردار پشتیبان با سناریو ۶ به ترتیب برای ماه‌های اسفند و خرداد می‌باشد که تقریباً مشابه یکدیگر است (شکل ۵-A). کمترین ضریب تعیین نیز مربوط به ماه‌های مرداد و شهریور است و نتایج هر دو مدل تقریباً مشابه می‌باشد.

دقت هر دو روش نروفازی و ماشین بردار پشتیبان قابل قبول است؛ اما میانگین مربعات خطای نروفازی از ماشین بردار پشتیبان اندکی کمتر است. (Dorum et al. (2010 و Behzad et al. (2009 به ترتیب نشان دادند نروفازی و ماشین بردار پشتیبان یک روش مطمئن برای شبیه‌سازی فرایند بارش-رواناب می‌باشند.

مقایسه مدل‌های جعبه خاکستری و سیاه نشان می‌دهد نروفازی و ماشین بردار پشتیبان با استفاده از هوش مصنوعی می‌توانند رواناب را دقیق‌تر برآورد کنند. (Khan and Coulibaly (2006 نشان دادند هوش مصنوعی می‌تواند رواناب را بهتر از مدل HBV برآورد کند. (Nayak et al. (2013 مشاهده کردند مدل مبتنی بر هوش مصنوعی، رواناب را با دقت بیشتری نسبت به مدل مفهومی برآورد می‌کند که در راستای نتایج این تحقیق است. (Ghumman et al. (2011 با استفاده از بارندگی و دبی تا دو گام زمانی قبل، رواناب را با استفاده از شبکه عصبی و مدل‌های مفهومی برآورد کردند و نشان دادند دقت هر دو روش یکسان است که با نتایج این تحقیق همخوانی ندارد. همچنین، آن‌ها اشاره کردند که مدل‌های جعبه سیاه به اطلاعات هیدرولوژیکی و ویژگی‌های فیزیکی حوضه نیاز ندارند و با سرعت بیشتری اجرا می‌شوند. سرعت اجرای مدل‌های هوش مصنوعی متفاوت می‌باشد. در این تحقیق اجرای نروفازی برای هر سناریو به ویژه سناریوهایی با بیش از ۳ پارامتر ورودی چندین روز به طول می‌انجامد اما ماشین بردار پشتیبان با سرعت بسیار بیشتری نسبت به نروفازی اجرا می‌شود. در مدل‌های مفهومی بارش رواناب با توجه به ساختار مدل، برخی از فرآیندهای مؤثر در تبدیل بارش به رواناب مورد بررسی قرار می‌گیرد. در این حالت با توجه به فرآیندهای غالب حوضه ممکن است مدل در حوضه مورد نظر پاسخ مناسبی ارائه ندهد. از سوی دیگر در این مدل‌ها

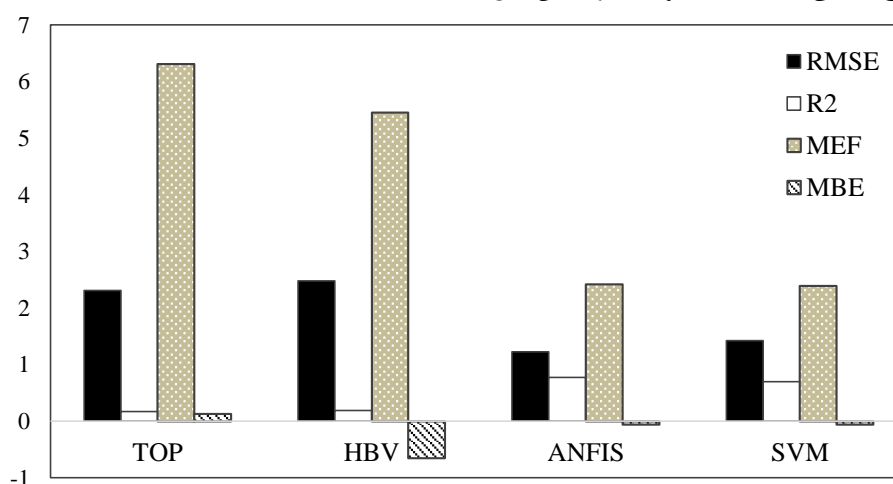


Fig. 4- Comparison of four models statistical criteria at test phase

شکل ۴- مقایسه معیارهای آماری چهار مدل مطالعاتی در مرحله آزمون

تقریباً یکسان است. در ماه خرداد سناریو ۶ هر دو مدل اندکی بهتر از سناریو ۵ می‌باشد. در ماه‌های گرم سال (تیر، مرداد و شهریور) تفاوت زیادی بین مدل‌ها و سناریوها وجود ندارد و تقریباً میانگین مربعات خطای آن‌ها یکسان است. به طور کلی از دی تا اسفند که هوا سرد می‌شود پارامتر دما باعث افزایش دقت پیش‌بینی می‌گردد و در بهار و تابستان به جز خرداد ماه تفاوتی بین سناریو ۵ و ۶ مشاهده نمی‌گردد.

شکل ۵-C نشان می‌دهد مدل‌ها در اسفند ماه رواناب را بسیار کمتر از مقدار واقعی پیش‌بینی کرده‌اند. از خرداد تا شهریور ماه که دمای هوا به شدت در حال افزایش بوده و میزان بارندگی‌ها کم و میانگین دبی رودخانه در حال کاهش می‌باشد مقادیر خطای MEF توسط هر دو مدل و هر دو سناریو زیاد می‌باشد که بیانگر بیش‌برآوردی هر دو مدل است. شکل ۵-D نشان می‌دهد به طور کلی دقت پیش‌بینی رواناب در فصول گرم کمتر از فصول سرد است.

میانگین مربعات خطا (شکل ۵-B) نشان می‌دهد در ماه مهر تفاوت قابل توجهی بین سناریوها و مدل‌های هوش مصنوعی وجود ندارد و تقریباً خطای پیش‌بینی رواناب در آن‌ها یکسان است. در ماه آبان سناریو ۶ در هر دو مدل دبی را با مقدار خطای کمتری شبیه‌سازی می‌کند. در آذر ماه سناریو ۵ نروفازی و ۶ ماشین بردار پشتیبان نتایج یکسانی ارائه می‌دهند. در دی ماه سناریو ۶ هر دو مدل و در بهمن و اسفند سناریو ۶ ماشین بردار پشتیبان دارای میانگین مربعات خطای کمتری است. همچنین، در بهمن ماه نتایج سناریوهای ۵ و ۶ نروفازی مشابه سناریو ۵ ماشین بردار پشتیبان است که خطای آن‌ها از سناریو ۶ ماشین بردار پشتیبان بیشتر است. با توجه به این‌که در ماه‌های زمستانی و سرد سال بیشتر بارش‌ها به صورت برف می‌باشد پارامتر دما باعث کاهش میزان خطای مدل شده است. ماه‌های فروردین و اردیبهشت که دمای هوا در حال افزایش بوده و بیشتر بارش‌ها بصورت بارندگی می‌باشد تفاوتی بین سناریوها و مدل‌ها وجود ندارد و نتایج

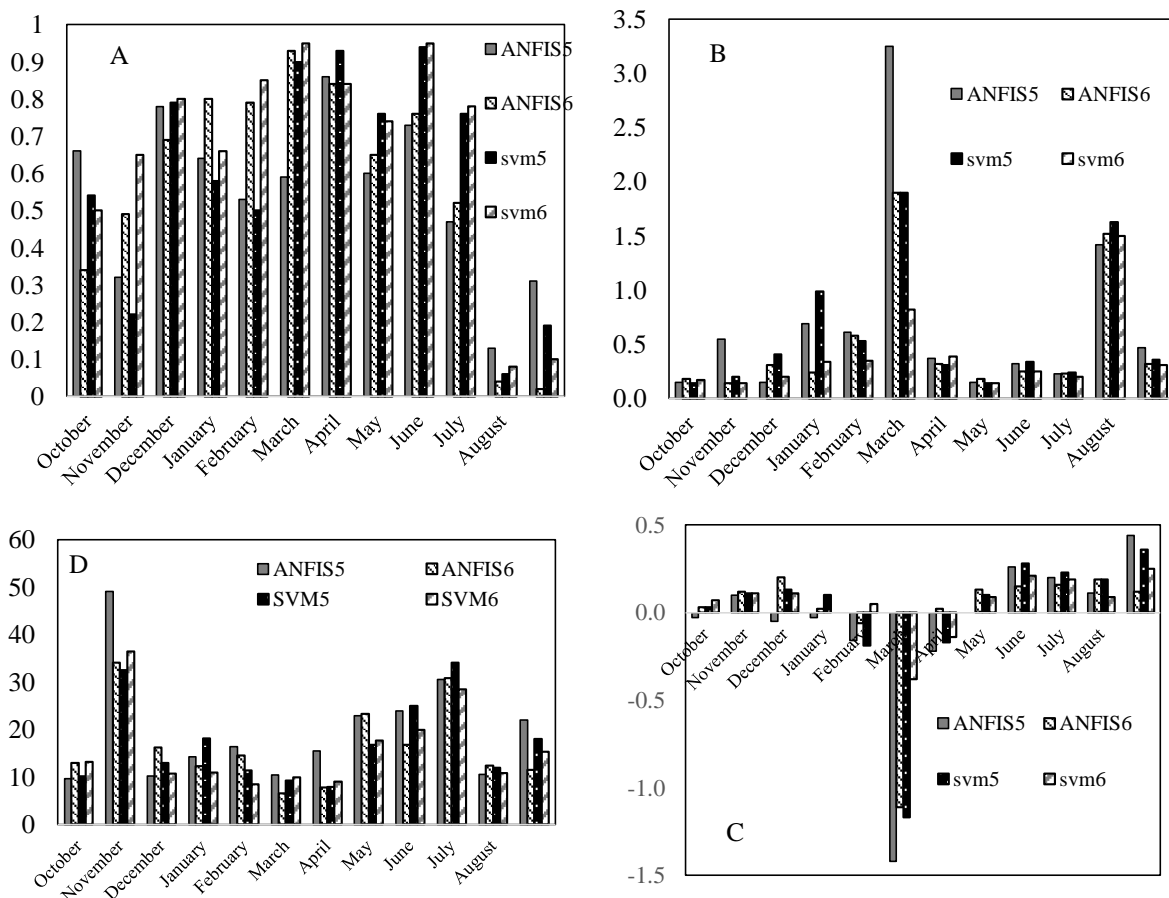


Fig. 5- Comparing the monthly discharge from neuro-fuzzy and support vector machines in scenarios 5 and 6: A) Coefficient determination, B) RMSE, C) MBE, D) MEF

شکل ۵- مقایسه ماهانه مدل‌های نروفازی و ماشین بردار پشتیبان در سناریوهای ۵ و ۶: (A) ضریب همبستگی، (B) خطای RMSE، (C) خطای MBE و (D) خطای MEF

- 3- Support Vector Machine
- 4- Structural Risk Minimization
- 5- Genetic Programming
- 6- Multiple Regressive Pattern Recognition Technique
- 7- Conceptual Hydrological Model
- 8- Tahtali&Gordes
- 9- Least Squares Support Vector Machines
- 10- Consequent Parameters
- 11- Trimf
- 12- Trapmf
- 13- Gbellmf
- 14- Gaussmf
- 15- Gauss2mf
- 16- Pimf
- 17- Dsigmf
- 18- Psigmf
- 19- Train
- 20- Test
- 21- Swedish Meteorological and Hydrological Institute
- 22- Coefficient Of Correlation
- 23- Error Root Mean Square
- 24- Mean Bias Error

۵- مراجع

- Aalami M, Hosseinzadeh H (2010) Modeling rainfall-runoff process in Lighvan Chai basin using conditional threshold temperature neuron. *Journal of Water and Soil Sciences* 20.1(2):97-110 (In Persian)
- Aghakouchak A, Habib E (2010) Application of a conceptual hydrologic model in teaching hydrologic processes. *International Journal of Engineering Education* 26(4):963-973
- Ahani A, Shourian M (2017) Prediction of Monthly Streamflow Using Data-driven Models. *Iran-Water Resources Research* 13(2):207-214 (In Persian)
- Ahmadi F, Radmanesh F, Mirabbasi Najaf Abadi R (2014) Comparison between genetic programming and support vector machine methods for daily river flow forecasting (Case Study: Barandoozchay River). *Journal of Water and Soil* 28(6):1162-1171 (In Persian)
- Al-safi H, Sarukkalige P (2017) Assessment of future climate change impacts on hydrological behavior of Richmond river catchment. *Water Science and Engineering* 10(3):197-208
- Anusree K, Varghese KO (2016) Streamflow prediction of karuvannur river basin using ANFIS, ANN and MNLN Models. *Procedia Technology* 24:101-108
- Azizian A, Shokoohi A (2014) An investigation on the effects of DEM creation methods on performance of the TOPMODEL. *Iran-Water Resources Research* 10(1):111-116 (In Persian)

۴- نتیجه گیری

در این مطالعه از مدل‌های هیدرولوژیکی HBV و TOPMODEL و مدل‌های هوش مصنوعی نروفازی و ماشین بردار پشتیبان برای شبیه‌سازی بارش-رواناب ایستگاه نوده‌خاندوز طی یک دوره آماری ۴ ساله استفاده شد. ترکیبی از داده‌های رواناب، بارندگی و دما در مقیاس روزانه در گام‌های زمانی قبل به‌عنوان پارامترهای ورودی انتخاب شد و ۹ سناریو طراحی گردید. استفاده از ورودی‌های بارندگی و دمای روز قبل به همراه دبی در سه گام زمانی قبل خطای پیش‌بینی هر دو مدل را کاهش داد. در این تحقیق با بررسی بیشتر عوامل بارندگی و دما و دقت این عوامل در بهبود شبیه‌سازی‌ها مشخص شد عامل دما به عنوان پارامتری مؤثر در ماه‌های سرد، مقدار خطای پیش‌بینی را کاهش می‌دهد و دقت هر دو روش در شبیه‌سازی ماه‌های گرم سال کم بوده و با تغییر سناریو دقت پیش‌بینی رواناب بهبود پیدا نکرده است.

مقایسه معیارهای ارزیابی نشان می‌دهد مدل‌های جعبه سیاه به عنوان ابزاری قدرتمندتر در پیش‌بینی‌ها عمل کرده و استفاده از مدل‌های مفهومی با توجه به اینکه چندان وقت‌گیر نمی‌باشد به عنوان ابزاری مناسب برای تخمین اولیه یک حوضه قابل قبول می‌باشد. به طور کلی هر دو مدل جعبه سیاه توانایی بالایی در شبیه‌سازی بارش-رواناب روزانه دارند. اگرچه دقت مدل ماشین بردار پشتیبان نسبت به مدل نروفازی اندکی کمتر بود اما مدل ماشین بردار پشتیبان به مراتب ساده‌تر از مدل نروفازی می‌باشد و می‌تواند به عنوان یک روش کاربردی و قابل رقابت با سایر روش‌ها در شبیه‌سازی بارش-رواناب بکار گرفته شود.

به هر حال، همواره باید توجه کرد که هرچند مدل‌های جعبه سیاه، نیازی به معادلات با پایه فیزیکی (که بیشتر به صورت غیرخطی و پیچیده‌اند) ندارند، ولی درک فرآیندها و تأثیر عوامل مورد نظر در داده‌های ورودی بر روی خروجی مدل‌ها بسیار مهم است و در صورت عدم درک، نمی‌توان انتظار نتایج مطلوبی را داشت. در صورتی که مدل‌های جعبه سیاه برای محدوده‌ای که آموزش ندیده‌اند اجرا شود معمولاً از برون‌یابی استفاده می‌کنند و نتایج آن‌ها قابل اعتماد نیست. همچنین، برخی از مدل‌های جعبه سیاه مانند نروفازی به زمان زیادی برای اجرا نیاز دارند که باعث می‌شود کار با این مدل‌ها پیچیده و زمان‌بر باشد.

پی‌نوشت‌ها

- 1- Adaptive Nero-Fazzy Inference System
- 2- Artificial Neural Network

- Hajjghoshan Watershed). *Journal of Watershed Management Research* 4(8):120-136 (In Persian)
- Ghorbani MA, Azani A, Mahmoudi Vanolya S (2015) Rainfall-runoff modeling using hybrid intelligent models. *Iran-Water Resources Research* 11(2):146-150 (In Persian)
- Ghumman AR, Ghazaw YM, Sohail AR, Watanabe K (2011) Runoff forecasting by artificial neural network and conventional model. *Alexandria Engineering Journal* 50(4):345-350
- Golestan regional water authority (2004) Annual report of the Nodeh Khandouz station. Golestan regional water authority Publishers, Iran
- Goswami M, O'Connor KM (2007) Real-time flow forecasting in the absence of quantitative precipitation forecasts: A multi-model approach. *Journal of Hydrology* 334(1-2):125-140
- Hallegatte S, Green C, Nicholls RJ, Corfee-Morlot J (2013) Future flood losses in major coastal cities. *Nature Climate Change* 3(9):802-806
- He Z, Wen X, Liu H, Du J (2014) A comparative study of artificial neural network adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region. *Journal of Hydrology* 509:379-386
- Holko L, Lepisto A (1997) Modelling the hydrological behavior of a mountain catchment using TOPMODEL. *Journal of Hydrology* 196:361-377
- Humphrey G, Gibbs M, Dandy G, Maier H (2016) A hybrid approach to monthly streamflow forecasting: integrating hydrological model outputs into a Bayesian artificial neural network. *Journal of Hydrology* 540:623-640
- Jakeman AJ, Letcher J, Norton JP (2006) Ten iterative steps in development and evaluation of environmental models. *Environmental Modeling Software* 21(5):602-614
- Javan K, Fallah Haghgoo Lialestani MR, Nejadhossein M (2015) A comparison of ANN and HSPF models for runoff simulation in Gharehsoo River watershed, Iran. *Modeling Earth Systems and Environment* 1(41):1-13
- Jothiprakash V, Magar R (2009) Soft computing tools in rainfall-runoff modeling. *ISH Journal of Hydraulic Engineering* 15(1):84-96
- Kakaei Lafdani E, Moghaddamnia A, Pahlavanravi A, Ahmadi A, Jajarmizadeh M (2013) Daily rainfall-runoff prediction and simulation using ANN, ANFIS and conceptual hydrological MIKE11/NAM models. *International Journal of Engineering and Technology Sciences* 1(1):32-50
- Bastola S, Ishidaira H, Takeuchi K (2008) Regionalisation of hydrological model parameters under parameter uncertainty: a case study involving TOPMODEL and basins across the globe. *Journal of Hydrology* 357:188-206
- Behmanesh J, Ayashm S (2015) Rainfall-runoff modeling in the turkey river using numerical and regression methods. *Journal of Fundamental Applied Sciences* 7(1):91-102
- Behzad M, Asghari K, Eazi M, Palhang M (2009) Generalization performance of support vector machines and neural networks in runoff modeling. *Expert Systems with Applications* 36(4):7624-7629
- Beven KJ (1997) TOPMODEL: a critique. *Hydrological Processes* 11(9):1069-1085
- Bouffard JS (2014) A comparison of conceptual rainfall-runoff modelling structures and approaches for hydrologic prediction in ungauged peatland basins of the James Bay lowlands. M.Sc. Thesis, School of Geography, University of Carleton
- Dastorani MT, Sharifi Darani H, Talebi A, Moghadam Nia A (2011) Evaluation of the application of artificial; neural network and adaptive neuro fuzzy interface system for rainfall runoff modeling in Zayande Rood river basin. *Journal of Water and Wastewater* 22(4):114-125 (In Persian)
- Dewan A (2013) Floods in a megacity: Geospatial techniques in assessing hazards, risk and vulnerability. Dordrecht, Springer, 199p
- Dorum A, Yazar A, Sevimli F, Onucyildiz M (2010) Modelling the rainfall-runoff data of susurluk basin. *Expert Systems with Applications* 37(9):6587-6593
- Etter S, Addor N, Huss M, David F (2017) Climate change impacts on future snow ice and rain runoff in a swiss mountain catchment using multi-dataset calibration. *Journal of Hydrology: Regional Studies* 13:222-239
- Euser T, Winsemius HC, Hrachowitz M, Fenicia F, Uhlenbrook S, Savenije H (2013) Framework to assess the realism of model structures using hydrological signatures. *Hydrology and Earth System Sciences* 17(5):1893-1912
- Falkenmark M, Finlayson CM, Gordon LJ (2007) Agriculture, water and ecosystems: avoiding the costs of going too far. In: *Water for Food, Water for Life: A Comprehensive Assessment of Water Management in Agriculture* (ed. by D. Molden), London: Earthscan and Colombo, Sri Lanka: International Water Management Institute, 10248p
- Ghafari GH, Vafakhah M (2013) Simulation of rainfall-runoff process using artificial neural network and adaptive neuro-fuzzy interface system (Case Study:

- Noori R, Khakpour A, Dehghani M, Farokhnia A (2011) Monthly stream flow prediction using support vector machine based on principal component analysis. *Journal of Water and Wastewater* 22(1):118-129 (In Persian)
- Nourani V (2016) An emotional ANN (EANN) approach to modeling rainfall-runoff process. *Journal of Hydrology* 544:267-277
- Nourani V, Kisi O, Komasi M (2011a) Two hybrid artificial intelligence approaches for modeling rainfall-runoff process. *Journal of Hydrology* 402(1-2):41-59
- Nourani V, Roughani A, Gebremichael M (2011b) TOPMODEL capability for rainfall-runoff modeling of the amnameh watershed at different time scales using different terrain algorithms. *Journal of Urban and Environmental Engineering* 5(1):1-14
- Okkan U, Serbes ZA (2012) Rainfall-runoff modeling using least squares support vector machines. *Environmetrics* 23(6):549-564
- Pourreza Bilondi M, Khashei Siuki A, Sadeghi Tabas S (2014) Daily rainfall-runoff modeling with Least Square Support Vector Machine (LS-SVM). *Journal of Water and Soil Conservation Research* 21(6):293-304 (In Persian)
- Rezaeianzadeh M, Stein A, Tabari H, Abghari H, Jalalkamali N, Hosseinipour EZ, Singh VP (2013) Assessment of a conceptual hydrological model and artificial neural networks for daily outflows forecasting. *International Journal of Environmental Sciences Technology* 10(2):1181-1192
- Seibert J (1999) Conceptual runoff models-fiction or representation of reality?. Ph.D. Thesis, Faculty of Science and Technology, Acta University
- Seyedian M, Soleimani M, Kashani M (2014) Flood flow forecasting using data mining and time series. *Journal of Ecohydrology* 1(3):167-179 (In Persian)
- Singh VP (1995) Computer models of watershed hydrology. Water Resources Publication, Fort Collins, Colorado, 1130p
- Talei A, Choy Chua L, Quek Ch (2010a) A novel application of a neuro-fuzzy computational technique in event-based rainfall-runoff modeling. *Expert Systems with Applications* 37(12):7456-7468
- Talei A, Choy Chua L, Wong T (2010b) Evaluation of rainfall and discharge inputs used by adaptive network-based fuzzy inference systems (ANFIS) in rainfall-runoff modeling. *Journal of Hydrology* 391(3-4):248-262
- Tingsanchali T, Gautam MR (2000) Application of tank, NAM, ARMA and neural network models to flood
- Kashani MH, Ghorbani MA, Dinpashoh Y, Shahmorad S (2016) Integration of Volterra model with artificial neural networks for rainfall-runoff simulation in forested catchment of Northern Iran. *Journal of Hydrology* 540:340-354
- Khan MS, Coulibaly P (2006) Bayesian neural network for rainfall-runoff modeling. *Water Resources Research* 42(7):1-18
- Kuczera G, Parent E (1998) Monte Carlo assessment of parameter uncertainty in conceptual catchment models: The Metropolis algorithm. *Journal of Hydrology* 211(1-4):69-85
- Kuo CH, Gan T, Yu P (2010) Seasonal streamflow prediction by a combined climate-hydrologic system for river basins of Taiwan. *Journal of Hydrology* 387:292-303
- Liu R, Wang J, Shi J, Chen Y, Sun C, Zhang P, Shen Z (2014) Runoff characteristics and nutrient loss mechanism from plain farmland under simulated rainfall conditions. *Science of the Total Environment* 468-469:1069-1077
- McMillan HK, Clark MP, Bowden WB, Duncan M, Woods RA (2011) Hydrological field data from a modeller's perspective: Part 1. Diagnostic tests for model structure. *Hydrological Processes* 25(4):511-522
- Minns AW, Hall MJ (1996) Artificial neural networks as rainfall-runoff models. *Hydrological Sciences Journal* 41(3):399-417
- Misra D, Oommen T, Agarwal A, Mishra S, Thompson A (2009) Application and analysis of support vector machine based simulation for runoff and sediment yield. *Biosystems Engineering* 103(4):527-535
- Montaseri M, Ghavidel S (2014) River flow forecasting by using soft computing. *Journal of Water and Soil* 28(2):394-405 (In Persian)
- Mutlu E, Chaubey I, Hexmoor H, Bajwa1 SG (2008) Comparison of artificial neural network models for hydrologic predictions at multiple gauging stations in an agricultural watershed. *Hydrological Processes* 22(26):5097-5106
- Nabizadeh M, Mosaedi A, Hesam M, Dehghani A, Zakerinia M, Meftah M (2011) River flow forecasting using fuzzy inference system (fis) and comparative fuzzy inference system (ANFIS). *Iran-Watershed Management Science & Engineering* 5(17):7-14 (In Persian)
- Nayak PC, Venkatesh B, Krishna B, Jain SK (2013) Rainfall-runoff modeling using conceptual, data driven, and wavelet based computing approach. *Journal of Hydrology* 493(17):57-67

- Westerberg IK, Guerrero JL, Younger PM, Beven KJ, Seibert J, Halldin S, Freer JE, Xu CY (2011) Calibration of hydrological models using flow-duration curves. *Hydrological Earth System Sciences* 15(7):2205-2227
- Wu CI, Chau KW (2011) Rainfall-runoff modeling using artificial neural network coupled with singular spectrum analysis. *Journal of Hydrology* 399(3-4):394-409
- Yaghoubi M, Massah Bavani A (2014) Sensitivity analysis and comparison of capability of three conceptual models HEC-HMS, HBV and IHACRES in simulating continuous rainfall-runoff in semi-arid basins. *Journal of Earth and Space Physics* 40(2):153-172 (In Persian)
- Zhou ZZ, Huang TL, Ma WX, Li Y, Zeng K (2015) Impacts of water quality variation and rainfall runoff on Jinpen Reservoir, in Northwest China. *Water Science and Engineering* 8(4):301-308
- forecasting. *Hydrological Processes* 14(14):2473-2487
- Uhlenbrook S, Roser S, Tilch N (2004) Hydrological process representation at the meso-scale: the potential of a distributed, conceptual catchment model. *Journal of Hydrology* 291(3-4):278-296
- Veintimilla-Reyes J, Cisneros F, Vanegas P (2016) Artificial neural networks applied to flow prediction: a use case for the Tomebamba River. *Procedia Engineering* 162:153-161
- Vrugt JA, Gupta HV, Bouten W, Sorooshian S (2003) A shuffled complex evolution metropolis algorithm for optimization and uncertainty assessment of hydrologic model parameters. *Water Resources Research* 39(8):1201-1219
- Wang W, Chau K, Cheng Ch, Qiu L (2009) A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *Journal of Hydrology* 374(3-4):294-306