

Investigating the Uncertainty of Data-Based Models in Forecasting Monthly Flow of the Hablehroud River

JABER SALEHPOOR LAGHANI¹, AFSHIN ASHRAFZADEH^{1*}, SEYED ALI MOUSSAVI¹

1. Department of Water Engineering, Faculty of Agricultural Sciences, University of Guilan, Rasht, Iran.

(Received: Aug. 10, 2019- Revised: Feb. 7, 2020- Accepted: Feb. 19, 2020)

ABSTRACT

Accurate and reliable forecasts of river flow are required for proper management of watershed systems. In recent years, data-driven models and especially artificial intelligent based models have been successfully used in various areas related to water resources. However, uncertainty analysis of these models has been less appreciated in prior studies. In the present study, the output uncertainty of five data-driven models including modular, PCA (Principle Component Analysis), TLRN (Time-Lagged Recurrent Network), ANFIS (Adaptive-Network-based Fuzzy Inference System) and SVM (Support Vector Machine) type models in forecasting river flow has been investigated using 95PPU, p-factor and d-factor quantities. Using the observed meteorological and flow data during 1998-2012 in Hablehroud Basin, different structures of the proposed models were trained and tested. The final values of p-factor and d-factor for each model type were obtained. The results showed that SVM with a p-factor of 82% produces the most reliable forecasts in the present study.

Keywords: Uncertainty, Monthly Streamflow, Stochastic Calibration, Neuro-Fuzzy Model, Gamma Test.

بررسی عدم قطعیت مدل‌های داده‌مبنا در پیش‌بینی دبی ماهانه حبله‌رود

جابر صالح پور لاقانی^۱، افشین اشرف‌زاده^{۱*}، سیدعلی موسوی^۱

۱. گروه مهندسی آب، دانشکده علوم کشاورزی، دانشگاه گیلان، رشت، ایران.

(تاریخ دریافت: ۱۳۹۸/۵/۱۹ - تاریخ بازنگری: ۱۳۹۸/۱۱/۱۸ - تاریخ تصویب: ۱۳۹۸/۱۱/۳۰)

چکیده

مدیریت مناسب حوضه‌های آبریز نیازمند در اختیار داشتن پیش‌بینی‌های دقیق و قابل اطمینان از دبی رودخانه‌هاست. در سالیان اخیر، مدل‌های داده‌مبنا و به‌ویژه مدل‌های مبتنی بر هوش مصنوعی، در زمینه‌های مختلف مرتبط با منابع آب با موفقیت مورد استفاده قرار گرفته‌اند. با این وجود، تحلیل عدم قطعیت این مدل‌ها کمتر مورد توجه قرار گرفته است. در مطالعه حاضر، عدم قطعیت خروجی پنج مدل مبتنی بر هوش مصنوعی شامل مدل‌هایی از نوع ماژولار، PCA، TLRN، ANFIS و SVM در پیش‌بینی دبی ماهانه حبله‌رود، با استفاده از کمیت‌های 95PPU، p-factor و d-factor مورد بررسی قرار گرفته است. با استفاده از داده‌های ثبت‌شده از متغیرهای هواشناسی و دبی طی سال‌های ۲۰۱۲-۱۹۹۸ در حوضه آبریز حبله‌رود در شرق استان تهران، ساختارهای متفاوتی از مدل‌ها مورد آموزش و آزمون قرار گرفتند. مقادیر نهایی p-factor و d-factor برای هر کدام از پنج مدل مورد بررسی محاسبه شد. نتایج نشان داد SVM با p-factor نهایی معادل با ۸۲ درصد در مرحله آزمون، قابل‌اعتمادترین مدل برای پیش‌بینی دبی ماهانه در حوضه مورد بررسی است.

واژه‌های کلیدی: عدم قطعیت، جریان ماهانه، واسنجی تصادفی، مدل عصبی-فازی، آزمون گاما.

مقدمه

مطالعات متعددی در زمینه کاربرد مدل‌های داده‌مبنا (data based) برای پیش‌بینی متغیرهای هیدرولوژیک انجام شده است. این مدل‌ها که دامنه وسیعی از مدل‌های رگرسیونی و سری زمانی تا مدل‌های مبتنی بر هوش مصنوعی را شامل می‌شوند قوانین فیزیکی حاکم بر فرآیندهای پیچیده هیدرولوژیک را نادیده گرفته و صرفاً با استفاده از مقادیر مشاهده‌شده از متغیرها در گذشته، مدل‌سازی را انجام می‌دهند. ساده‌سازی روابط و سهولت استفاده و همچنین نتایج نسبتاً قابل قبول به دست آمده از این مدل‌ها، باعث محبوبیت و کاربرد فراوان آن‌ها شده است. (Wu *et al.* (2014), Nourani *et al.* (2014), Yaseen *et al.* (2015) و Afan *et al.* (2016) عمده مطالعات انجام‌شده در زمینه کاربرد این مدل‌ها در هیدرولوژی و منابع آب را بررسی و جمع‌بندی کرده‌اند. بررسی مطالعات گذشته نشان می‌دهد آنچه در کاربرد مدل‌های داده‌مبنا کمتر مورد توجه قرار گرفته است موضوع عدم قطعیت موجود در خروجی این مدل‌هاست.

تحلیل عدم قطعیت تلاش می‌کند یک ساختار اصولی برای شناسایی عدم قطعیت مربوط به خروجی مدل فراهم کند. خطاهای تقریب‌های به کار رفته در اندازه‌گیری داده‌های ورودی، مقادیر پارامترها، ساختار مدل و الگوریتم روابط مابین پارامترها و متغیرها در مدل، همگی منابع عدم قطعیت هستند (Liu and

Gupta, 2007). با وجود راه‌های بسیار زیاد به منظور کمی کردن و کاهش این خطاها در تقریب مقادیر غیرقطعی موجود در هر سامانه منابع آب، حذف عدم قطعیت‌ها غیرممکن است و تصمیمات مدیریتی سامانه همچنان باید برای شرایط غیرقطعی آینده به‌روز شوند. برای یک مدل هیدرولوژیک می‌توان هفت بخش شامل مرز سیستم، ورودی‌ها، شرایط اولیه، پارامترها، حالت سیستم (شرایط مدل در گذر زمان)، خروجی و ساختار در نظر گرفت (Liu and Gupta, 2007). از میان هفت بخش یادشده، پنج مورد از آن‌ها شامل مرز سیستم، ورودی‌ها، شرایط اولیه، پارامترها و ساختار مدل بایستی قبل از اجرای مدل، مشخص شده و تخمین زده شده و یا تعریف شوند. هر کدام از این پنج بخش، به نوعی دارای عدم قطعیت هستند که این عدم قطعیت‌ها، به حالت سیستم و خروجی مدل تعمیم می‌یابند. در مطالعات مرتبط با پیش‌بینی متغیرهای هیدرولوژیک، عدم قطعیت حاصل از نوع مدل مورد استفاده کمتر مورد توجه قرار گرفته است (Georgakakos *et al.*, 2004; Dams *et al.*, 2015). با این وجود زمانی که از مدل‌های هیدرولوژیک برای پیش‌بینی یک متغیر تصادفی استفاده می‌شود، به نظر می‌رسد که نوع مدل می‌تواند از عوامل اصلی عدم قطعیت باشد و به کار بردن مجموعه‌ای شامل چندین مدل متفاوت هیدرولوژیک می‌تواند راهکاری برای ارزیابی این عدم قطعیت باشد (Butts *et al.*, 2004).

(Georgakakos *et al.* (2004) در مطالعه خود بر روی شش

ساختار مدل عصبی-فازی شامل تغییر در وزن‌های اولیه، تغییر در تعداد لایه‌ها و تعداد عناصر پردازشگر در هر لایه، تغییر در الگوریتم آموزش و تغییر در داده‌هایی که برای آموزش مورد استفاده قرار می‌گیرند، دامنه‌ای از پیش‌بینی‌ها به دست می‌آید که با تعیین درصدی از داده‌های مشاهده‌شده که در این دامنه واقع می‌شوند می‌توان عدم قطعیت مدل را به صورت کمی ارزیابی کرد. در حوضه مورد مطالعه، درصدی از داده‌های مشاهده‌شده که در دامنه پیش‌بینی قرار می‌گرفتند برابر با $97/2$ درصد و میانگین عرض دامنه برابر با $26/5$ مترمکعب در ثانیه به دست آمد. همچنین درصد خطا برای دبی‌های کمینه بین $3/85$ تا $6/13$ درصد و برای دبی‌های پیک بین $8/01$ تا $8/46$ درصد به دست آمد که نشان از عدم قطعیت بیشتر در پیش‌بینی دبی‌های کمینه بود. (Velázquez et al. (2013 با هدف کمی‌سازی اثر نوع مدل هیدرولوژیک بر عدم قطعیت پیش‌بینی دبی ماهانه، چهار مدل بارش-رواناب با ساختارهای متفاوت (یکپارچه، نیمه‌توزیعی و کاملاً توزیعی) را در دو حوضه در کانادا و آلمان واسنجی کردند و عنوان کردند هر چند ساختار مدل بر پیش‌بینی دبی بیشینه تأثیر قابل توجهی ندارد، اما عدم قطعیت در پیش‌بینی دبی میانگین، زیاد بوده و نمی‌توان تنها به نتایج حاصل از یک مدل اکتفا کرد. (Dams et al., (2015 نیز اثر سناریوی انتخاب‌شده برای تغییر اقلیم، ساختار مدل بارش-رواناب و تابع هدف مورد استفاده در واسنجی پارامترهای مدل را بر عدم قطعیت دبی‌های ماهانه پیش‌بینی‌شده در حوضه‌ای در شمال بلژیک بررسی کردند. نتایج نشان داد نوع مدل بارش-رواناب سهم نسبتاً قابل توجهی از عدم قطعیت پیش‌بینی دبی میانگین و بیشینه را به خود اختصاص می‌دهد و این عدم قطعیت، قابل مقایسه با عدم قطعیت حاصل از تغییر اقلیم است. (Lee & Kang (2016 از شبکه عصبی مصنوعی برای پیش‌بینی دبی روزان خروجی از حوضه‌ای در کره جنوبی استفاده کردند و با استفاده از روش دامنه پیش‌بینی، عدم قطعیت خروجی مدل را با تغییر دادن وزن‌های اولیه و تعداد عناصر پردازشگر در لایه میانی و همچنین تغییر دادن داده‌های مورد استفاده در آموزش برآورد کردند. در این تحقیق از چهار نوع تابع تبدیل برای مدل شبکه عصبی مصنوعی استفاده شد و نتایج نشان داد مدلی که از تابع تبدیل logistic استفاده می‌کند دارای کمترین عدم قطعیت است. در این مدل، درصدی از داده‌های مشاهده‌شده که در دامنه پیش‌بینی قرار داشتند برابر با 99 درصد و میانگین عرض دامنه برابر با $1/14$ مترمکعب در ثانیه به دست آمد.

Isazadeh et al. (2017) عدم قطعیت دو مدل شبکه عصبی مصنوعی و ماشین بردار پشتیبان را در برآورد پارامترهای کیفی آبخوان دشت گیلان بررسی کردند. در این تحقیق، با تغییر در

حوضه در جنوب ایالات متحده، عدم قطعیت برآورد دبی ساعتی خروجی از حوضه را با در نظر گرفتن دوازده مدل متفاوت برای برآورد این متغیر (از مدل‌های فرآیندی و توزیعی تا مدل‌هایی مفهومی و یکپارچه) محاسبه کردند. نتایج این تحقیق نشان داد استفاده از مجموعه‌ای از مدل‌ها برای برآورد دبی، کارآمدتر از انتخاب بهترین مدل بر مبنای ریشه میانگین مربعات خطاست چرا که با استفاده از مجموعه‌ای از مدل‌ها، می‌توان یک توزیع احتمالاتی شرطی به دست آورد که مشخص می‌کند با تحقق شرط قرار گرفتن دبی مشاهده‌شده در محدوده دبی‌های برآوردشده، احتمال برآورد درست فراوانی دبی مشاهده‌شده چه مقدار است.

(Butts et al. (2004 در مطالعه‌ای بر روی دبی‌های ساعتی خروجی از حوضه‌ای در ایالت اوکلاهما، تفاوت موجود میان نتایج حاصل از مدل‌های متفاوت را به‌عنوان عدم قطعیت برآورد یک مقدار مشاهده‌شده از دبی خروجی تعریف کردند و این عدم قطعیت را با بررسی 10 مدل متفاوت به کمیت درآوردند. نتایج این تحقیق حاکی از تفاوت بسیار زیاد در عملکرد مدل‌هایی با ساختارهای متفاوت بود و نشان داد در مدل‌سازی دبی خروجی از یک حوضه، عدم قطعیت حاصل از ساختار مدل نیز بایستی در کنار سایر عدم قطعیت‌ها مورد توجه قرار گیرد. (Bastola et al. (2011 در مطالعه‌ای بر روی چندین حوضه در ایرلند به این نتیجه رسیدند که مدل‌های مختلف بارش-رواناب یکی از عوامل مهم در عدم قطعیت پیش‌بینی دبی ماهانه خروجی از حوضه‌ها در سناریوهای مختلف تغییر اقلیم هستند. این محققین، عدم قطعیت حاصل از پارامترهای مدل‌های مورد استفاده را نزدیک به 50 درصد دبی مشاهده‌شده برآورد کردند بدین معنی که با تغییر پارامترهای یک مدل، خروجی تولیدشده توسط مدل می‌تواند 25 درصد بیشتر یا 25 درصد کمتر از دبی مشاهده‌شده باشد. با در نظر گرفتن ساختار مدل، این عدم قطعیت می‌تواند تا 70 درصد افزایش یابد. (Najafi et al. (2011 نیز در تحقیق خود برای تحلیل اثر تغییر اقلیم بر دبی خروجی از حوضه‌ای در ایالت اورگان به این نتیجه رسیدند که عدم قطعیت حاصل از نوع مدل بارش-رواناب در مقطعی از دوره آماری که حوضه با خشک‌سالی هیدرولوژیک مواجه است، مهم‌تر از عدم قطعیت حاصل از نوع مدل گردش عمومی جو مورد استفاده است. در دوره‌های خشک‌سالی، تغییر در نوع مدل بارش-رواناب می‌تواند دبی خروجی پیش‌بینی‌شده را 10 تا 30 درصد تغییر دهد.

(Kasiviswanathan et al. (2013 با استفاده از روش دامنه پیش‌بینی (prediction interval)، عدم قطعیت یک مدل عصبی-فازی را در پیش‌بینی هیدروگراف سیل حاصل از یک واقعه بارش در حوضه‌ای در غرب هند برآورد کردند. در این روش، با تغییر

است. بدین صورت که با انتخاب چند مدل متفاوت و ساختارهای متفاوت برای هر مدل، دامنه‌ای از مقادیر پیش‌بینی شده توسط مدل‌ها به دست آمده و عدم قطعیت خروجی هر مدل بررسی شده است. هدف نهایی، ارائه مجموعه‌ای از مدل‌هاست که قادر باشند دامنه‌ای از پیش‌بینی‌ها را ارائه کنند و تنها به یک مقدار قطعی پیش‌بینی شده اکتفا نشود.

مواد و روش‌ها

منطقه مورد مطالعه

در مطالعه حاضر، دبی خروجی از حوضه آبریز حبله‌رود که در شرق استان تهران واقع شده با استفاده از مدل‌های داده‌مبنا مدل‌سازی شده است. این حوضه آبریز در محدوده جغرافیایی ۵۲ درجه و ۲۰ دقیقه تا ۵۳ درجه و ۱۰ دقیقه طول شرقی و ۳۵ درجه و ۱۷ دقیقه تا ۳۵ درجه و ۵۹ دقیقه عرض شمالی واقع شده است. حبله‌رود که رودخانه اصلی این حوضه به شمار می‌رود در جهت عمومی شمال شرق به جنوب غرب، از فیروزکوه در شمال تا گرمسار در جنوب جریان دارد. موقعیت مکانی حوضه آبریز حبله‌رود در ایران و استان تهران در شکل (۱) نمایش داده شده است.

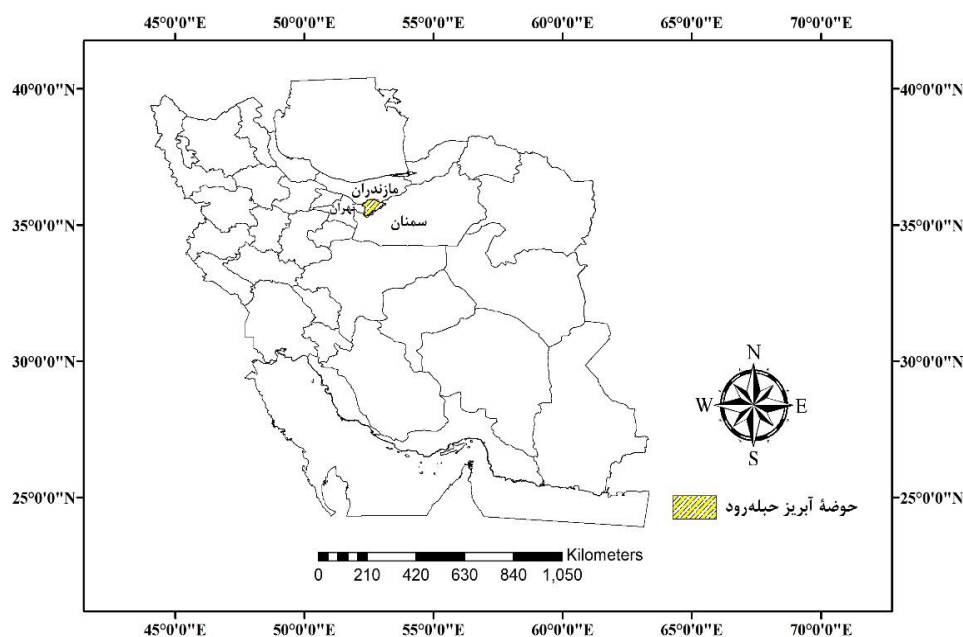
متغیرهای بارش، دما، رطوبت نسبی و تبخیر از تشت به‌عنوان بخشی از بردار ورودی به مدل‌ها مورد استفاده قرار گرفتند. داده‌های ماهانه مربوط به این متغیرها در سه ایستگاه سینوپتیک (متعلق به سازمان هواشناسی)، نه ایستگاه باران‌سنجی و دو ایستگاه تبخیرسنجی (هر ۱۱ ایستگاه متعلق به وزارت نیرو) از سازمان هواشناسی کشور و شرکت مدیریت منابع آب ایران دریافت شد. علاوه بر متغیرهای هواشناسی، دبی ماهانه با تأخیرهای متفاوت نیز به عنوان ورودی در نظر گرفته شد. آمار ماهانه دبی در ایستگاه هیدرومتری بنکوه واقع در خروجی حوضه از شرکت مدیریت منابع آب ایران دریافت شد. موقعیت ایستگاه‌های مورد استفاده در شکل (۲) نمایش داده شده است. در جدول (۱) نیز مشخصات آماری دبی ماهانه خروجی از حوضه ارائه شده است.

پارامترهای دو مدل یادشده، به ازای هر مقدار مشاهده‌شده از پارامترهای کیفی آبخوان، دامنه‌ای از برآوردها به دست آمد و عدم قطعیت هر مدل با محاسبه معیارهای p-factor (درصدی از داده‌های مشاهده‌شده که در دامنه برآوردها قرار می‌گیرند) و d-factor (میانگین عرض باند برآوردها) ارزیابی شد. نتایج نشان از کم‌تر بودن عدم قطعیت ماشین بردار پشتیبان نسبت به شبکه عصبی مصنوعی بود چراکه در p-factor یکسان (۹۹ درصد)، ماشین‌بردار پشتیبان دارای d-factor کمتری بود (۰/۱۱ نسبت به ۰/۲۵).

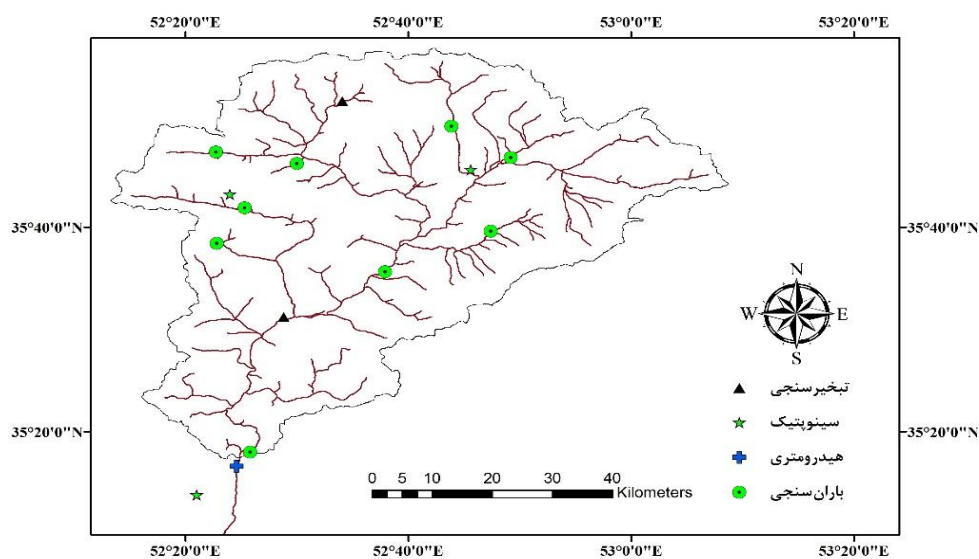
در مقاله حاضر سعی بر این است تا با کاربرد مفهوم باند عدم قطعیت خروجی مدل (95PPU) و معیارهای p-factor و d-factor، اثر عدم قطعیت ساختار چند مدل مبتنی بر هوش مصنوعی بر جریان ماهانه پیش‌بینی‌شده در حوضه آبریز حبله‌رود بررسی شود. 95PPU و دو فاکتور یادشده، توسط Abbaspour *et al.* (2004 & 2007) و Yang *et al.* (2008) به‌منظور کمی کردن عدم قطعیت مدل هیدرولوژیک SWAT (Soil and Water Assessment Tool) تعریف شده‌اند. این محققین عنوان می‌کنند که در برآورد یا پیش‌بینی دبی خروجی از حوضه، متناظر با یک مقدار مشاهده‌شده، نه یک مقدار قطعی بلکه در عمل مجموعه‌ای از مقادیر شبیه‌سازی‌شده را بایستی در اختیار داشت. در صورتی که مقدار مشاهده‌شده به نحوی قابل قبول در محدوده مقادیر شبیه‌سازی‌شده توسط مدل قرار گیرد، می‌توان مدل را واسنجی‌شده در نظر گرفت. در این نوع واسنجی که واسنجی تصادفی نام دارد، دامنه‌ای از مقادیر ممکن برای پارامترهای مدل در نظر گرفته می‌شود و در فرآیند واسنجی سعی می‌شود تا این دامنه‌ها به کمینه اندازه ممکن برسند اما این دامنه‌ها هیچ‌گاه به یک مقدار منحصر به فرد تقلیل نمی‌یابند. مدلی که بدین صورت واسنجی شده باشد، متناظر با هر مقدار مشاهده‌شده، دامنه‌ای از مقادیر شبیه‌سازی‌شده را ارائه می‌کند و بدین ترتیب عدم قطعیت مدل با تحلیل این دامنه و محاسبه 95PPU، p-factor و d-factor به‌صورت کمی بیان می‌شود. در این مقاله، از ایده روش واسنجی تصادفی که عدم قطعیت حاصل از پارامترهای مدل SWAT را بر خروجی مدل تحلیل می‌کند، به‌منظور کمی‌سازی عدم قطعیت حاصل از نوع و ساختار مدل‌های هوش مصنوعی استفاده شده

جدول ۱- مشخصات آماری دبی ماهانه در ایستگاه هیدرومتری بنکوه

پارامتر	\bar{x}	\bar{y}	\bar{z}	\bar{v}	\bar{w}	\bar{u}	\bar{t}	\bar{s}	\bar{r}	\bar{q}	\bar{p}	\bar{o}
میانگین (مترمکعب در ثانیه)	۶/۰۲	۷/۹۱	۷/۸۶	۷/۲۴	۶/۹۰	۸/۷۷	۱۲/۴۷	۱۳/۰۶	۸/۲۴	۵/۵۶	۴/۵۰	۴/۲۶
انحراف معیار (مترمکعب در ثانیه)	۲/۸۵	۲/۷۰	۲/۱۳	۱/۷۰	۱/۶۵	۲/۶۹	۴/۳۸	۸/۳۴	۶/۰۲	۳/۷۸	۲/۷۸	۲/۶۱
بیشینه (مترمکعب در ثانیه)	۱۲/۶۷	۱۳/۴۷	۱۱/۶۶	۱۱/۰۳	۹/۲۰	۱۶/۵۵	۲۲/۳۸	۳۱/۰۲	۲۴/۴۱	۱۶/۴۷	۱۲/۴۲	۱۲/۸۱
کمینه (مترمکعب در ثانیه)	۱/۹۹	۲/۸۱	۳/۷۴	۴/۱۷	۳/۰۲	۴/۰۹	۳/۲۲	۰/۵۹	۰/۵۸	۰/۱۱	۰/۴۰	۰/۳۴
ضریب چولگی	۰/۷۱	۰/۲۸	-۰/۰۶	-۰/۱۱	-۰/۵۱	۰/۸۸	-۰/۱۴	۰/۶۵	۱/۰۹	۱/۰۸	۰/۸۹	۱/۰۷
ضریب تغییرات	۰/۴۷	۰/۳۴	۰/۲۷	۰/۲۴	۰/۳۱	۰/۳۵	۰/۶۴	۰/۷۳	۰/۶۸	۰/۶۲	۰/۶۱	۰/۶۱



شکل ۱- موقعیت مکانی حوضه آبریز حبله‌رود



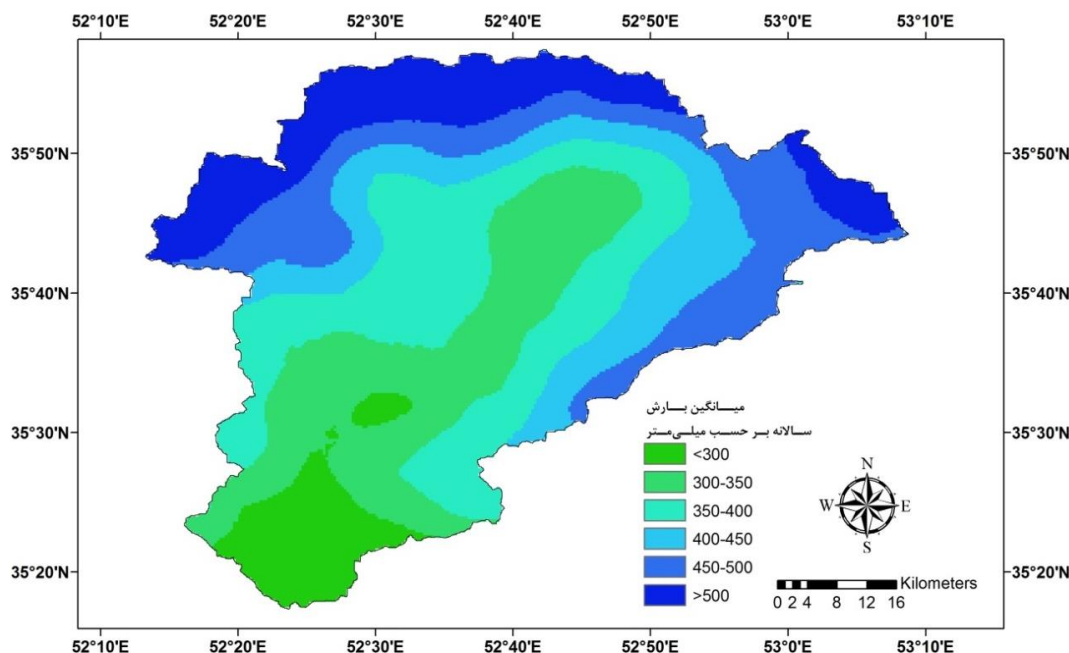
شکل ۲- موقعیت مکانی ایستگاه‌های تبخیرسنجی، سینوپتیک، هیدرومتری و باران‌سنجی مورد استفاده در حوضه حبله‌رود

در مورد متغیرهای دما و رطوبت نسبی، حوضه به سه بخش ابتدایی، میانی و انتهایی تقسیم‌بندی شد و میانگین معمولی برای هر متغیر در هر بخش محاسبه شد. مجموع تبخیر از تشت در هر کدام از سه بخش حوضه نیز به‌عنوان ورودی در نظر گرفته شد. با توجه به تعداد زیاد متغیرهای ورودی، قبل از اقدام به مدل سازی، مؤثرترین متغیرهای ورودی با استفاده از آزمون گاما سازی (Stefánsson *et al.*, 1997) تعیین شدند. در این آزمون، ابتدا آمار آزمون (γ) با در نظر گرفتن تمامی متغیرها برآورد می‌شود. این مقدار γ_{all} نامیده می‌شود. سپس با حذف یک متغیر، آمار آزمون

پس از انجام پردازش‌های مقدماتی شامل انجام آزمون همگنی و روند، حذف داده‌های پرت و بازسازی آمار ناقص بر روی کلیه داده‌های موجود، آمار تمامی ایستگاه‌های مورد استفاده، برای سال‌های ۱۹۹۸ تا ۲۰۱۲ میلادی هم‌پایه شد و مورد استفاده قرار گرفت. میانگین وزنی بارش با استفاده از روش Thiessen در نرم‌افزار ArcGIS در سطح حوضه برآورد شد و به‌عنوان ورودی مدل‌ها برای پیش‌بینی دبی در خروجی مورد استفاده قرار گرفت. میانگین درازمدت ارتفاع بارش سالانه در سطح حوضه در شکل (۳) نمایش داده شده است.

ندارد و می‌توان این متغیر را از فرآیند مدل‌سازی حذف کرد. بر مبنای نتایج حاصل از آزمون گاما، متغیرهای نهایی مورد استفاده در مدل‌سازی تعیین شدند.

مجدداً برآورد شده و با γ_{all} مقایسه می‌شود. در صورتی که مقدار برآورد شده با حذف یک متغیر، از γ_{all} کوچک‌تر باشد می‌توان نتیجه گرفت که متغیر وابسته، به متغیر حذف‌شده حساسیت



شکل ۳- تغییرات مکانی بارش درازمدت سالانه در حوضه حبله‌رود

پردازش اطلاعات و لایه خروجی محل تولید داده‌های خروجی شبکه عصبی مصنوعی است. هر کدام از لایه‌های ورودی، میانی و خروجی به نوبه خود، از اجزایی به نام عنصر پردازشگر (processing element) یا نورون (neuron) تشکیل شده‌اند. نورون‌ها در واقع، واحدهای محاسباتی ساده‌ای هستند که از کنار هم قرار دادن آن‌ها، شبکه ساخته می‌شود. در ساختار شبکه، نورون‌ها توسط اتصالاتی به یکدیگر مرتبط می‌شوند. به هر اتصال، عددی تحت عنوان وزن اتصال نسبت داده می‌شود. هر نورون از طریق اتصال‌های ورودی خود، ورودی‌هایی را از نورون‌های دیگر دریافت می‌کند و در فرآیندی که شامل دو بخش است، خروجی خود را تولید می‌کند. در بخش اول، مجموع وزنی مقادیر ورودی به نورون، با در نظر گرفتن یک ورودی تحت عنوان بایاس، محاسبه می‌شود. در بخش دوم، نورون مقدار محاسبه‌شده در بخش اول را در یک تابع ریاضی که تابع انتقال نام دارد قرار داده و خروجی خود را محاسبه می‌کند. این خروجی به سایر نورون‌های شبکه انتقال داده می‌شود و در نهایت، خروجی شبکه در آخرین لایه تولید می‌شود. شبکه‌های عصبی مصنوعی توانایی خود برای پردازش درست اطلاعات را از طریق فرآیندی تحت عنوان آموزش به دست می‌آورند. در این فرآیند، وزن‌های اختصاص داده‌شده به اتصال‌های میان نورون‌های لایه‌های مختلف شبکه، به منظور به

مدل‌های مورد استفاده

در سال‌های اخیر مدل‌های مختلفی در زمینه پیش‌بینی جریان رودخانه، بر پای روش‌های مدل‌سازی داده‌مبنا توسعه داده شده‌اند. عملکرد این مدل‌ها مبتنی بر یافتن رابطه‌ای بین داده‌های ورودی و خروجی یک سیستم، بدون درک صریحی از فرآیندهای فیزیکی بر روی داده‌ها در آن سیستم است. البته دانش فرد متخصص در مورد فرآیندهای فیزیکی مرتبط با سیستم می‌تواند به بهبود انتخاب متغیرها و نتایج حاصل از به‌کارگیری مدل منتهی شود (Ahani & Shourian, 2017). بنابراین با توجه به ضرورت بررسی اثر نوع مدل داده‌مبنا بر عدم قطعیت خروجی مدل، در مطالعه حاضر عدم قطعیت پنج مدل مختلف شامل شبکه‌های عصبی مصنوعی از نوع ماژولار، PCA و TLRN، سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) و ماشین بردار پشتیبان (SVM) مورد ارزیابی قرار گرفت.

شبکه‌های عصبی مصنوعی ماژولار (MNN-Modular Neural Networks)

شبکه‌های عصبی مصنوعی از ترکیب لایه‌هایی تحت عناوین لایه ورودی، لایه‌های میانی یا پنهان و لایه خروجی تشکیل می‌شوند. لایه ورودی محل دریافت اطلاعات، لایه یا لایه‌های میانی محل

همین ترتیب پیش می‌رود تا مؤلفه‌ای که کوچکترین مقدار واریانس را شامل می‌شود ایجاد شود. هنگامی که تجزیه کامل شد، مؤلفه‌های حاصل، درجه متفاوتی از همبستگی با متغیرهای مشاهده‌ای را نشان خواهند داد ولی به طور کامل غیرمرتبط با یکدیگر هستند. با در نظر گرفتن یک کمینه درصد واریانس معین، می‌توان مؤلفه‌های اصلی که سهم کمتری از این مقدار را نسبت به واریانس کل در مجموعه داده‌ها دارند حذف کرد (Samani *et al.*, 2007) و بدین ترتیب ابعاد مجموعه داده‌ها، بدون اینکه هیچ اطلاعاتی از دست برود کاهش داده می‌شود (Azari and Samani, 2015).

شبکه عصبی مصنوعی برگشتی با تأخیر زمانی (TLRN-Time Lag Recurrent Network)

شبکه عصبی مصنوعی برگشتی با تأخیر زمانی (TLRN)، یک شبکه عصبی مصنوعی توسعه‌یافته با ساختار حافظه کوتاه‌مدت زمانی است. بیشتر داده‌ها در دنیای واقعی تابعی از متغیر زمان می‌باشند و این شبکه برای مدل‌سازی این سری‌های زمانی غیرخطی استفاده می‌شود. فعالیت‌های تحقیقاتی اخیر در مورد شبکه TLRN نشان داده است که این روش توانایی بسیار بالایی در حل مسائل پیچیده در کلیه رشته‌های مهندسی دارد. ساختار شبکه TLRN همانند شبکه‌های عصبی مصنوعی، به وسیله ارتباط بین عناصر پردازشگر، تعیین وزن‌های ارتباطی و تابع فعالیت معرفی می‌شود و معمولاً از لایه ورودی، لایه‌های میانی (پنهان) و لایه خروجی تشکیل شده است (Wieland *et al.*, 2010).

سیستم استنتاج عصبی-فازی تطبیقی (ANFIS-Adaptive Neuro-Fuzzy Inference System)

سیستم‌های استنتاج عصبی-فازی ترکیبی از سیستم‌های استنتاج فازی و شبکه‌های عصبی مصنوعی‌اند که هدف آن‌ها، یافتن پارامترهای یک سیستم استنتاج فازی به کمک الگوریتم‌های آموزش شبکه‌های عصبی مصنوعی است. سیستم‌های استنتاج عصبی-فازی بر اساس نوع رابطه بین سیستم فازی و شبکه عصبی مصنوعی، به دو گروه عمده شامل سیستم‌های استنتاج عصبی-فازی تعاونی (cooperative) و سیستم‌های استنتاج عصبی-فازی هیبرید (hybrid) تقسیم می‌شوند. در سیستم‌های استنتاج عصبی-فازی تعاونی، شبکه عصبی مصنوعی و سیستم استنتاج فازی به‌طور مستقل از یکدیگر عمل می‌کنند در حالی که در سیستم‌های استنتاج عصبی-فازی هیبرید، هر دو سیستم در قالب یک معماری واحد بیان می‌شوند. سیستم استنتاج عصبی-فازی تطبیقی یا ANFIS گونه‌ای

کمینه رساندن اختلاف میان خروجی‌های تولیدشده توسط شبکه و خروجی‌های واقعی یا مشاهده‌شده، تنظیم می‌شوند. با توجه به قابلیت تنظیم وزن‌ها در یک شبکه عصبی مصنوعی، این شبکه‌ها را شبکه‌های تطبیقی نیز می‌نامند. الگوریتم‌های مختلفی برای آموزش شبکه‌های عصبی مصنوعی ارائه شده است که به عنوان نمونه می‌توان به الگوریتم‌های پس‌انتشار خطا و کمینه میانگین مربعات اشاره کرد. در هر کدام از این الگوریتم‌ها، از مجموعه معادلاتی تحت عنوان قانون یادگیری برای تنظیم وزن‌ها استفاده می‌شود.

پرسپترون چندلایه (MLP-Multilayer Perceptron) متداول‌ترین نوع از شبکه‌های عصبی مصنوعی است که از یک لایه ورودی، یک یا دو لایه میانی و یک لایه خروجی تشکیل شده است. هر کدام از این لایه‌ها نیز از تعدادی عنصر پردازشگر تشکیل شده‌اند که وظیفه تولید خروجی مدل را بر عهده دارند. بر حسب چگونگی اتصال نورون‌ها به یکدیگر و ساختار شبکه، نوع آموزش شبکه و همچنین کاربرد آن، شبکه‌های عصبی مصنوعی به انواع مختلفی تقسیم‌بندی می‌شوند که به عنوان نمونه می‌توان به شبکه‌های پیش‌خور (feedforward)، تابع پای شعاعی (radial basis function، برگشتی (recurrent)، خودسازمان‌دهنده (self-organizing) و ماژولار (modular) اشاره کرد. شبکه‌های عصبی مصنوعی ماژولار از چندین شبکه پرسپترون چندلایه موازی تشکیل شده‌اند. تعداد وزن‌های بین لایه‌های این شبکه‌ها در مقایسه با پرسپترون چندلایه کمتر است که منجر به افزایش سرعت پردازش در شبکه می‌شود. در این مطالعه از شبکه‌های ماژولار با یک یا دو لایه میانی و توابع تبدیل از نوع سیگموئید با ضابطه $1/(1 + e^{-x})$ و همچنین تابع پای شعاعی استفاده شده است. آموزش شبکه‌ها نیز با استفاده از الگوریتم‌های پس‌انتشار خطا و کمینه میانگین مربعات انجام شده است.

آنالیز مؤلفه‌های اصلی (PCA-Principal Component Analysis) روش PCA که در سال ۱۹۰۱ توسط کارل پیرسون پیشنهاد شده است ابزاری برای شناسایی همبستگی موجود میان شمار زیادی از متغیرها، از راه کاهش ابعاد مجموعه داده‌های حجیم است (Ding & He, 2004). PCA از دید ریاضی به عنوان یک تبدیل خطی متعامد (orthogonal linear transformation) تعریف می‌شود که داده‌ها را به سامانه‌ای با مختصات جدید تبدیل می‌کند به گونه‌ای که بیشترین واریانس داده‌ها را به مختصات اول نسبت می‌دهد و مؤلفه اصلی اول (first PCA) را ایجاد می‌کند. همچنین بیشترین واریانس دوم به مختصات دوم اختصاص داده شده و مؤلفه اصلی دوم (second PCA) ساخته می‌شود. این روند با

پارامترهای سیستم فازی Sugeno درجه یک است (در صورتی که f مقداری ثابت در نظر گرفته شود سیستم فازی Sugeno سیستمی از درجه صفر است).

۵- گره خروجی (لایه پنجم): در این لایه که شامل یک گره می‌باشد، خروجی ANFIS با تجمیع تمامی سیگنال‌های ورودی محاسبه می‌شود. در این لایه، طی یک فرآیند ساده غیرفازی‌سازی، نتایج قوانین فازی به یک خروجی قطعی تبدیل می‌شود:

$$OP_i^5 = \sum_{i=1}^2 \bar{w}_i f_i = \frac{\sum_{i=1}^2 w_i f_i}{w_1 + w_2} \quad (\text{رابطه ۵})$$

سیستم ANFIS می‌تواند از یک شبکه عصبی مصنوعی پیش‌خور و تلفیقی از الگوریتم‌های آموزش پس‌انتشار خطا و کمینه میانگین مربعات برای یافتن مقادیر بهینه مجموعه پارامترهای سیستم استنتاج فازی $\{p_i, q_i, r_i\}$ استفاده کند. نوع عمومی‌تری از ANFIS که از یک شبکه عصبی مصنوعی ماژولار بهره می‌گیرد از الگوریتم‌های یادگیری شبکه عصبی و منطق فازی به منظور طراحی نگاشت غیرخطی بین فضای ورودی و خروجی استفاده می‌کند. این سیستم با توجه به توانایی در ترکیب قدرت زبانی یک سیستم فازی با قدرت عددی یک شبکه عصبی، موفقیت‌های بسیاری را در مدل‌سازی و کنترل سیستم‌های پیچیده داشته است (Karimi et al., 2013). برای تولید مجموعه‌های فازی در سیستم عصبی-فازی ANFIS از روشی موسوم به افزایش‌بندی (partitioning) داده‌ها استفاده می‌شود. روش‌های متداول برای افزایش‌بندی شامل سه روش شبکه‌بندی (grid partitioning)، درختی (tree partitioning) و خوشه‌بندی فازی تفریقی (subtractive clustering) است که در این مقاله از روش‌های شبکه‌بندی و تفریقی استفاده شده است.

ماشین بردار پشتیبان (SVM-Support Vector Machine) ماشین بردار پشتیبان یکی از روش‌های یادگیری تحت نظارت (supervised learning) است که هم برای دسته‌بندی و هم رگرسیون قابل استفاده است. این روش توسط Vapnik (1998) بر پای تئوری یادگیری آماری بنا نهاده شده است. ماشین بردار پشتیبان که روشی مناسب برای مسائل پیش‌بینی نیز به‌شمار می‌رود (Pai & Hong, 2007) در اصل یک دسته‌بندی-کننده دو کلاسی است که کلاس‌ها را توسط یک مرز خطی از هم جدا می‌کند. در این روش نزدیک‌ترین نمونه‌ها به مرز تصمیم‌گیری را بردارهای پشتیبان می‌نامند. این بردارها معادله مرز تصمیم‌گیری را مشخص می‌کنند. مرز تصمیم‌گیری

از سیستم‌های استنتاج عصبی-فازی هیبرید است که بر اساس نوع سیستم فازی مورد استفاده در سه نوع مختلف ارائه شده است. سیستم استنتاج عصبی-فازی تطبیقی نوع سه، از سیستم

استنتاج فازی Sugeno استفاده می‌کند. این سیستم نروفازی را می‌توان برای دو متغیر ورودی، یک متغیر خروجی، دو قانون اگر-آنگاه و دو مجموعه فازی برای هر ورودی، در پنج لایه که شرح هر کدام در ادامه آورده شده است به صورت زیر خلاصه کرد (Chang & Chang, 2006):

۱- گره‌های ورودی (لایه اول): در این لایه با فرض تقسیم‌بندی هر کدام از ورودی‌های به دو مجموعه فازی، درجه عضویت ورودی‌ها با استفاده از روابط زیر محاسبه می‌شود:

$$\begin{cases} OP_i^1 = U_{A_i}(x_1); & i=1,2 \\ OP_i^1 = U_{B_{i-2}}(x_2); & i=3,4 \end{cases} \quad (\text{رابطه ۱})$$

که در آن؛ OP_i^1 خروجی لایه اول، x_1 و x_2 ورودی‌ها، i شماره هر کدام از گره‌های لایه و U_{A_i} و U_{B_i} توابع عضویت می‌باشند. توابع عضویت متفاوتی را می‌توان به منظور تعیین درجه‌های عضویت به کار برد که به عنوان نمونه می‌توان به توابع عضویت مثلثی، دوزنقه‌ای، گاوسی و زنگوله‌ای تعمیم‌یافته اشاره کرد.

۲- گره‌های قوانین (لایه دوم): در این لایه برای هر کدام از قوانین اگر-آنگاه، مقداری تحت عنوان نیروی انگیزش (firing strength) استخراج می‌شود. خروجی‌های این لایه (OP_i^2) از ضرب درجه‌های عضویت محاسبه‌شده در لایه اول به دست می‌آیند:

$$OP_i^2 = w_i = U_{A_i}(x_1)U_{B_i}(x_2); \quad i=1,2 \quad (\text{رابطه ۲})$$

۳- گره‌های میانگین (لایه سوم): هدف اصلی از ایجاد این لایه، تعیین نسبت نیروی انگیزش هر قانون فازی به مجموع نیروهای انگیزش تمامی قوانین است. خروجی این لایه (OP_i^3) به صورت زیر محاسبه می‌شود:

$$OP_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}; \quad i=1,2 \quad (\text{رابطه ۳})$$

۴- گره‌های تالی (consequence) (لایه چهارم): در این لایه، سیستم استنتاج فازی Sugeno به کار گرفته‌شده و میزان مشارکت هر قانون فازی در خروجی کل محاسبه می‌شود:

$$OP_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i); \quad i=1,2 \quad (\text{رابطه ۴})$$

که در آن؛ \bar{w}_i خروجی لایه سوم و $\{p_i, q_i, r_i\}$ مجموعه

ابعاد کوچک‌تر مورد استفاده قرار می‌گیرد. چند نمونه از توابع هسته‌ای مهم عبارت‌اند از چند جمله‌ای، پایه شعاعی، گوسی پایه شعاعی و تانژانت هیپربولیک که به ترتیب به صورت زیر نوشته می‌شوند:

$$K(x, x_i) = ((x \cdot x_i) + 1)^d \quad \text{(رابطه ۸)}$$

$$K(x, x_i) = \exp(-\gamma |x - x_i|^2) \quad \text{(رابطه ۹)}$$

$$K(x, x_i) = \exp(-|x - x_i|^2 / 2\sigma^2) \quad \text{(رابطه ۱۰)}$$

$$K(x, x_i) = \tanh(b(x \cdot x_i) - c) \quad \text{(رابطه ۱۱)}$$

که در آن؛ K تابع هسته‌ای و d درجه چندجمله‌ای است و پارامترهای σ , γ , b و c نیز توسط کاربر تعریف می‌شوند. انتخاب تابع هسته‌ای برای SVM به حجم داده‌های آموزشی و ابعاد بردار ورودی بستگی دارد. در این مطالعه از توابع هسته‌ای یادشده به منظور ساخت مدل ماشین بردار پشتیبان استفاده شده است.

ایجاد مدل‌هایی با ساختار متفاوت

برای ایجاد هر کدام از مدل‌های مورد استفاده در این تحقیق، انتخاب‌های متعددی در اختیار کاربر قرار دارد که در این مقاله اثر نوع مدل و ساختار انتخاب‌شده برای آن، بر عدم قطعیت خروجی‌ها بررسی شده است. این انتخاب‌ها شامل وزن‌های تصادفی اولیه، تعداد لایه‌های میانی (یک یا دو)، تعداد عناصر پردازشگر در لایه یا لایه‌های میانی، نوع تابع تبدیل و الگوریتم مورد استفاده در آموزش هستند. تعداد مؤلفه‌های اصلی در شبکه عصبی مصنوعی PCA و ابعاد و نوع ساختار حافظه در شبکه عصبی مصنوعی TLRN نیز بخشی از انتخاب‌ها برای این دو مدل است. در مورد ANFIS، نوع سیستم فازی مورد استفاده (سوگنوی درجه صفر یا درجه یک)، روش مورد استفاده در افزایش ورودی‌ها (روش شبکه‌بندی و روش خوشه‌بندی فازی تفریقی) و نوع تابع عضویت (مثلی، ذوزنقه‌ای، گوسی و یا زنگوله‌ای) نیز بخشی از انتخاب‌ها برای این مدل را تشکیل می‌دهند. در مورد SVM نیز نوع تابع هسته‌ای مورد استفاده و پارامترهای آن، از انتخاب‌های کاربر به شمار می‌روند. بر اساس انتخاب‌های ممکن، بیش از ۵۰ ساختار برای هر کدام از پنج نوع مدل در نظر گرفته شد و هر کدام از این ساختارها مورد آموزش و آزمون قرار گرفتند. آموزش با ۸۰ درصد از داده‌ها و آزمون با ۲۰ درصد از داده‌ها که به صورت تصادفی انتخاب شده بودند انجام شد. عملکرد هر مدل در هر ساختار، در مراحل واسنجی (آموزش) و اعتبارسنجی (آزمون) با استفاده از ریشه میانگین مربعات خطا (RMSE-Root Mean Square Error) و ضریب نش-ساتکلیف (Nash-Sutcliffe)

ابرسطحی (hyperplane) است که قادر باشد با بیشینه فاصله ممکن، بردارهای ورودی متفاوت را از یکدیگر جدا کند. به این ابرسطح، ابرسطح با بیشینه مرز جداکننده گفته می‌شود. برای ساختن ابرسطح با بیشینه مرز جداکننده، در ابتدا دو ابرسطح موازی ساخته می‌شوند که قادر باشند داده‌های مربوط به دو دسته را از یکدیگر جدا کنند. معادله ابرسطح با بیشینه مرز جداکننده، با حل یک مسئله بهینه‌سازی چندجمله‌ای درجه دو با قیود خطی به دست می‌آید. در این مسئله بهینه‌سازی، فرض بر این است که هر قدر فاصله ابرسطح با بیشینه مرز جداکننده از هر دو ابرسطح موازی بیشتر باشد، خطای دسته‌بندی هم کمتر خواهد بود. به زبان ریاضی، این مسئله بهینه‌سازی به صورت زیر نوشته می‌شود: (رابطه ۶)

$$\text{Minimize } \Phi(\mathbf{w}, \xi^*, \xi) = \frac{1}{2} \|\mathbf{w}\|^2 + C(\sum \xi_i^* + \sum \xi_i)$$

$$\text{Subject to: } \begin{cases} y_i - ((\mathbf{w} \cdot \mathbf{x}_i + b)) \leq \varepsilon + \xi_i \\ ((\mathbf{w} \cdot \mathbf{x}_i + b)) - y_i \leq \varepsilon + \xi_i^* \\ \xi_i^*, \xi_i \geq 0 \quad i = 1, \dots, n \end{cases}$$

که در آن: $\mathbf{w} = (w_0, \dots, w_n)$ بردار وزن‌ها و ξ_i^* و ξ_i متغیرهای کمکی می‌باشند. پارامتر C به عنوان یک پارامتر تنظیم‌کننده شناخته شود که مقدار آن از طریق سعی و خطا تعیین می‌شود. اگر به C مقدار بزرگی اختصاص داده شود، خطای آموزش کم می‌شود اما در عوض، قابلیت تعمیم کاهش می‌یابد. اگر به C مقدار کوچکی اختصاص یابد، قابلیت تعمیم افزایش می‌یابد. اگر C بی‌نهایت بزرگ باشد، ماشین اجازه وقوع هیچ خطایی را در داده‌های آموزش ندارد و حاصل، یک مدل پیچیده خواهد بود. از سوی دیگر، وقتی C به سمت صفر میل می‌کند می‌تواند خطای زیادی را در زمان آموزش تحمل کند و در نتیجه، پیچیدگی مدل کمتر خواهد بود. مقدار پارامتر ε نیز در وضعیت بردارهای پشتیبان مؤثر است. با انتخاب مقادیر خیلی بزرگ برای این پارامتر، بردارهای پشتیبان کاهش داده می‌شوند. مقادیر خیلی کوچک از این پارامتر نیز موجب می‌شوند تا بردارهای پشتیبان زیاد شده و احتمال خطای بیشتر، افزایش یابد. روش ماشین بردار پشتیبان را می‌توان در تقریب توابع نیز به کار برد. در تقریب توابع، روش ماشین بردار پشتیبان از رابطه زیر استفاده می‌کند:

$$y(\mathbf{x}) = \sum_{i=1}^n w_i K(\mathbf{x}, \mathbf{x}_i) + w_0 \quad \text{(رابطه ۷)}$$

که در آن؛ n تعداد نقاط مشاهده‌شده از تابع مورد تقریب، $y(\mathbf{x})$ تقریب تابع به ازای بردار ورودی $\mathbf{x} = (w_0, \dots, w_n)$ وزن‌ها و K تابعی تحت عنوان تابع هسته‌ای (kernel) است. تابع هسته‌ای به منظور نگاشت فضای ورودی به یک فضای ورودی با

متفاوت برای هر مقدار مشاهده شده) تعریف می‌شود. بدیهی است هر مقدار مشاهده شده، یا در این محدوده واقع می‌شود و یا خارج از این محدوده قرار خواهد گرفت. معیار p-factor نشان می‌دهد چند درصد از داده‌هایی که برای آموزش یا آزمون در نظر گرفته شده‌اند در باند 95PPU قرار می‌گیرند. این معیار با شمارش تعداد داده‌های مشاهده شده‌ای که در باند 95PPU هستند محاسبه می‌شود و بدیهی است مقدار مطلوب آن ۱۰۰ درصد است. لازم به ذکر است هر مقدار مشاهده شده، 95PPU مربوط به خود را داراست و به عبارت دیگر عرض این باند در مقادیر مشاهده شده متفاوت، تغییر می‌کند. بر این اساس، معیار دوم یا d-factor به صورت نسبت میانگین عرض باند عدم قطعیت به انحراف معیار مقادیر مشاهده شده تعریف می‌شود و مقدار ایده‌آل آن برابر با صفر است:

$$d\text{-factor} = \frac{\frac{1}{n} \sum_{i=1}^n (Q_{U,i} - Q_{L,i})}{S_m} \quad (\text{رابطه ۱۷})$$

در این معادله، $Q_{U,i}$ و $Q_{L,i}$ به ترتیب صدک ۲/۵ و صدک ۹۷/۵ خروجی‌های حاصل از ساختارهای متفاوت به ازای مقدار مشاهده شده \bar{m} و S_m انحراف معیار مقادیر مشاهده شده است. در عمل، نزدیک بودن d-factor به صفر به معنای کم بودن عدم قطعیت خروجی مدل است. البته با کوچک شدن d-factor، p-factor نیز کاهش می‌یابد و از مقدار مطلوب خود (۱۰۰ درصد) فاصله می‌گیرد. بنابراین بایستی بین این دو فاکتور، تعادلی مناسب برقرار کرد و به مقادیری بهینه دست یافت. در عمل برای دستیابی به مقادیر بهینه این دو فاکتور از روش سعی و خطا استفاده می‌شود. در پیش‌بینی دبی، p-factor، بیشتر از ۷۰ درصد و d-factor کمتر از ۱/۵ مقادیری قابل قبول هستند و سعی می‌شود در مدل نهایی، مقادیری از این دو فاکتور که همزمان در محدوده قابل قبول باشند به دست آید (Abbaspour et al., 2015).

لازم به ذکر است در مدل‌های بارش-رواناب مفهومی و فیزیکی (مانند مدل SWAT)، پارامترهای مورد استفاده در مدل مبنایی فیزیکی دارند و بنابراین می‌توان برای آن‌ها پیش از شروع واسنجی، دامنه‌ای از مقادیر ممکن در نظر گرفت. اما در مدل‌های مبتنی بر هوش مصنوعی، پارامترهای مدل (به عنوان مثال وزن اتصالاتی که در یک شبکه عصبی مصنوعی وجود دارند) فاقد مبنای فیزیکی هستند و بنابراین از ابتدا نمی‌توان برای آن‌ها همانند پارامترهای فیزیکی، دامنه‌ای از مقادیر فرض کرد بلکه مقادیر اولیه این پارامترها به صورت تصادفی انتخاب شده و سپس با استفاده از یک الگوریتم ریاضی، مقدار بهینه پارامترها محاسبه

coefficient) ارزیابی شد. این دو معیار به ترتیب به صورت زیر محاسبه می‌شوند:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q_{m,i} - Q_{s,i})^2}{n}} \quad (\text{رابطه ۱۲})$$

$$\frac{\sum_{i=1}^n (Q_m - Q_s)^2}{\sum_{i=1}^n (Q_{m,i} - \bar{Q}_m)^2} NS = 1 - \quad (\text{رابطه ۱۳})$$

در این روابط، Q نشان دهنده دبی ماهانه حوضه، زیرنویس m نشان دهنده مقدار اندازه‌گیری شده، زیرنویس s نشان دهنده خروجی مدل و n تعداد داده‌های مشاهده شده است. Moriasi et al. (2007)، مقادیر NS کمتر از ۰/۵، بین ۰/۵ تا ۰/۶۵، بین ۰/۶۵ تا ۰/۷۵ و بیشتر از ۰/۷۵ را به ترتیب به عنوان شبیه‌سازی نامناسب، رضایت‌بخش، خوب و بسیار خوب طبقه‌بندی می‌کنند. برای ارائه نتایج مربوط به آموزش و آزمون مدل‌ها از نمودار جعبه و خط (box and whisker plot) استفاده شده است. برای ترسیم این نمودار، ابتدا برای هر مدل و هر ساختار، مقادیر RMSE و NS در مراحل آموزش و آزمون محاسبه شدند. بدین ترتیب برای هر مدل، به تعداد ساختارهای در نظر گرفته شده، RMSE و NS در اختیار بوده است که کمینه، چارک اول (Q_1)، میانه یا چارک دوم (Q_2)، چارک سوم (Q_3) و بیشینه این مقادیر محاسبه شد. سپس میان چارکی دامنه (IQR-Inter Quartile Range)، خط بالا (upper whisker) و خط پایین (lower whisker) به صورت زیر محاسبه شدند:

$$IQR = Q_3 - Q_1 \quad (\text{رابطه ۱۴})$$

$$\text{upper whisker} = \min[\max - Q_3, 1.5 \times IQR] \quad (\text{رابطه ۱۵})$$

$$\text{lower whisker} = \min[Q_1 - \min, 1.5 \times IQR] \quad (\text{رابطه ۱۶})$$

مقادیری از RMSE و NS که بیشتر از $Q_3 + 1.5 \times IQR$ و یا کمتر از $Q_1 - 1.5 \times IQR$ بودند نیز به عنوان داده پرت در نظر گرفته شدند.

با توجه به آنچه گفته شد، در هر مدل و به ازای هر دبی ماهانه مشاهده شده، به تعداد ساختارهای در نظر گرفته شده برای مدل، دبی پیش‌بینی شده در اختیار بوده است. همان‌گونه که در بخش مقدمه ذکر شد، تفاوت موجود میان نتایج حاصل از یک مدل را می‌توان به عنوان عدم قطعیت مدل در پیش‌بینی یک مقدار مشاهده شده از دبی تعریف کرد (Butts et al., 2004; Kasiviswanathan et al., 2013). در این مطالعه، کمی‌سازی این عدم قطعیت با استفاده از مفهوم باند عدم قطعیت (95PPU) و معیارهای p-factor و d-factor انجام شده است. باند عدم قطعیت خروجی مدل (95PPU) به صورت فاصله میان صدک ۲/۵ تا صدک ۹۷/۵ خروجی مدل (خروجی‌های گرفته شده از ساختارهای

0.155	0.044	RH _{t-3}
0.171	0.051	Q _{t-1}
0.169	0.049	Q _{t-2}
0.161	0.048	Q _{t-3}

P: بارش ماهانه، T: میانگین ماهانه دما، E: تبخیر ماهانه از نشت، RH: میانگین ماهانه رطوبت نسبی، Q: دبی

اعتبارسنجی مدل‌ها و بررسی عدم قطعیت خروجی

شکل (۴) ریشه میانگین مربعات خطا (RMSE) و ضریب نش-ساتکلیف (NS) را برای هر مدل در مراحل آموزش و آزمون نمایش می‌دهد. به تعداد ساختارهای در نظر گرفته شده برای هر مدل، مقادیر محاسبه شده از RMSE و NS در اختیار بوده است. شکل (۴) دامنه نتایجی که با ایجاد تغییر در ساختار هر مدل حاصل می‌شود را نمایش می‌دهد. در این شکل دایره قرمز رنگ نشان‌دهنده مقدار کمینه از RMSE یا NS، دایره مشکی نشان‌دهنده مقدار بیشینه از RMSE یا NS، ضلع پایین مستطیل نشان‌دهنده چارک اول، خط وسط در مستطیل نشان‌دهنده میانه، ضلع بالای مستطیل نشان‌دهنده چارک سوم، خط عمودی بالای مستطیل نشان‌دهنده upper whisker و خط عمودی پایین مستطیل نشان‌دهنده lower whisker است و داده‌های پرت نیز با علامت × مشخص شده‌اند. طول مستطیل نیز نشان‌دهنده دامنه میان چارکی (IQR) است.

همان‌گونه که در شکل (۴) مشاهده می‌شود، بیشینه مقدار به‌دست‌آمده برای ضریب نش-ساتکلیف (NS) در مرحله آموزش، برابر با ۰/۸۷ و مربوط به مدل‌های ANFIS و SVM است. کمینه مقدار به‌دست‌آمده برای RMSE در مرحله آموزش نیز مربوط به مدل‌های SVM و Modular است (به ترتیب ۱/۴۰ و ۱/۴۱). میانه RMSE در مرحله آموزش برای سه مدل ANFIS، Modular و SVM تقریباً با یکدیگر برابر (به ترتیب ۱/۸۵، ۱/۸۶ و ۱/۸۶) و کمتر از دو مدل دیگر (۱/۹۶ برای PCA و ۱/۹۴ برای TLRN) است. میانه NS در مرحله آموزش برای این سه مدل نیز تقریباً برابر با یکدیگر (به ترتیب ۰/۵۲، ۰/۵۲ و ۰/۵۱) و بیشتر از دو مدل دیگر (۰/۴۷ برای PCA و ۰/۴۹ برای TLRN) است. با توجه به تقسیم‌بندی انجام‌شده برای NS که مقادیر بیشتر از ۰/۵ را شبیه‌سازی رضایت‌بخش توصیف می‌کند (Moriasi et al., 2007) می‌توان گفت عملکرد ۵۰ درصد از ساختارهای در نظر گرفته شده برای سه مدل ANFIS، Modular و SVM در مرحله آموزش رضایت‌بخش بوده است (با توجه به نمودار، ۵۰ درصد از مقادیر NS در این سه مدل، مقداری بیشتر از ۰/۵ یا میانه NS داشته‌اند). به عبارت دیگر احتمال اینکه با انتخاب یکی از این سه مدل، به ساختاری با عملکرد رضایت‌بخش دست یابیم بیشتر از زمانی است که یکی از دو مدل PCA و TLRN انتخاب شوند. علاوه بر این، دامنه میان چارکی (IQR)

می‌شود. بنابراین در این مطالعه، عدم قطعیتی که در نتایج خروجی مدل‌ها مشاهده می‌شود به سایر عوامل نسبت داده شده است چرا که در دو مدل که به عنوان مثال دارای لایه‌های میانی متفاوت هستند، مقدار بهینه و قطعی پارامترهای مدل با استفاده از الگوریتم مورد استفاده در آموزش محاسبه می‌شود و با فرض قرار نگرفتن در بهینه محلی، آموزش مجدد مدل تغییری عمده در نتایج ایجاد نخواهد کرد.

نتایج و بحث

تعیین مؤثرترین متغیرهای ورودی


نتایج حاصل از اجرای آزمون گاما در جدول (۲) ارائه شده است. در این جدول، مقدار γ_{all} که با در نظر گرفتن تمامی متغیرها محاسبه شده در اولین سطر نوشته شده است. با حذف هر کدام از متغیرهای ورودی، آماره آزمون محاسبه و در سطرها بعد ارائه شده است. در این جدول V-ratio شاخصی است که امکان مدل‌سازی متغیر وابسته را نمایش می‌دهد. در صورتی که مقدار این شاخص برابر با یک باشد، متغیر وابسته رفتاری کاملاً تصادفی داشته و امکان مدل‌سازی آن با متغیرهای ورودی در نظر گرفته شده نیست. هر چه این شاخص به صفر نزدیک‌تر باشد امکان مدل‌سازی متغیر وابسته با استفاده از متغیرهای ورودی بیشتر است. بر مبنای مقادیر ارائه شده در جدول (۱)، مؤثرترین متغیرهای ورودی به مدل‌ها انتخاب شدند. به عنوان مثال، همان‌گونه که در این جدول مشاهده می‌شود حذف متغیر رطوبت نسبی در دو ماه قبل (RH_{t-2})، باعث کاهش در مقدار γ_{all} از ۰/۴۸ به ۰/۴۵ می‌شود و بنابراین می‌توان این متغیر را از مجموعه متغیرهای ورودی حذف کرد. علاوه بر این، مقدار V-ratio نیز با حذف RH_{t-2} همچنان به صفر نزدیک است و امکان مدل‌سازی متغیر وابسته بدون این متغیر وجود دارد. مؤثرترین متغیرهای ورودی که برای مرحله بعد انتخاب شده‌اند در جدول (۲) با حروف ضخیم مشخص شده‌اند.

جدول ۲- نتایج حاصل از آزمون گاما برای انتخاب مؤثرترین متغیرهای ورودی

ورودی حذف شده	γ	V-ratio
---	0.048	0.165
P_{t-1}	0.051	0.168
P_{t-2}	0.049	0.166
P_{t-3}	0.048	0.165
T_{t-1}	0.049	0.169
T_{t-2}	0.048	0.167
T _{t-3}	0.047	0.154
E_{t-1}	0.049	0.167
E _{t-2}	0.047	0.161
E _{t-3}	0.046	0.157
RH_{t-1}	0.048	0.166
RH_{t-2}	0.045	0.157

دیگر بیشتر است. از این نظر، مدل Modular بهترین وضعیت را نسبت به چهار مدل دیگر در مرحله آموزش دارد.

در مدل PCA در مرحله آموزش برای هر دو معیار NS و RMSE بیشتر از چهار مدل دیگر است. این بدان معنی است که تفاوت یا نوسان عملکرد در ساختارهای انتخاب شده برای این مدل، از مدل های



شکل ۴- معیارهای ارزیابی مدل‌ها در پیش‌بینی دبی ماهانه (سمت چپ مرحله آموزش و سمت راست مرحله آزمون)

نشان می‌دهد. Behzad *et al.* (2009) به منظور پیش‌بینی دبی روزان رودخانه بختیاری در استان چهارمحال و بختیاری، از مدل‌های شبکه عصبی مصنوعی، تلفیق شبکه عصبی مصنوعی و الگوریتم ژنتیک (ANN-GA) و SVM استفاده کردند. نتایج این تحقیق نشان داد استفاده از مدل SVM باعث کاهش RMSE و همچنین افزایش ضریب همبستگی، نسبت به دو مدل شبکه عصبی مصنوعی و ANN-GA می‌شود (در مورد RMSE، ۲۰/۷ نسبت به ۲۸/۳ و ۲۶/۱ مترمکعب در ثانیه و در مورد ضریب همبستگی، ۰/۹۷ نسبت به ۰/۹۵ و ۰/۹۶). Tan *et al.* (2018) مطالعه‌ای بر روی حوضه رودخانه یانگ‌تسه در چین به منظور پیش‌بینی دبی ماهانه در سه ایستگاه هیدرومتری، از مدل‌های شبکه عصبی مصنوعی، ANFIS، SVM و SAR(1) (مدل سری زمانی فصلی خودهمبسته با تأخیر یک ماه) استفاده کرده و عملکرد مدل‌ها را بر مبنای NS، RMSE و قدر مطلق خطا مقایسه کردند.

نتایج این مطالعه حاکی از آن است که به طور کلی در ماه‌های خشک سال، مدل SAR(1) و در ماه‌های تر سال، مدل

با توجه به شکل (۴) و نمودارهای مربوط به مرحله آزمون می‌توان این‌گونه نتیجه‌گیری کرد که عملکرد ساختارهای در نظر گرفته شده برای مدل‌های SVM و ANFIS نسبت به سه مدل دیگر در مرحله آزمون بهتر بوده است. کمینه مقدار RMSE در مرحله آزمون برابر با ۱/۴۷ و مربوط به این دو مدل بوده است. همچنین بیشینه مقادیر NS در مرحله آزمون برابر با ۰/۶۹ و ۰/۶۸ و به ترتیب مربوط به SVM و ANFIS بوده است. چارک سوم در مرحله آزمون برای NS در این دو مدل به ترتیب برابر با ۰/۵۰ و ۰/۵۱ به دست آمده است. به عبارت دیگر، ۲۵ درصد از ساختارهای در نظر گرفته شده برای این دو مدل، در مرحله آزمون دارای عملکرد رضایت‌بخش بوده‌اند. مقایسه نتایج حاصل در دو مرحله آموزش و آزمون نیز مشخص می‌کند که دو مدل ANFIS و SVM بهتر توانسته‌اند دبی خروجی از حوضه را شبیه‌سازی کنند به این معنی که عملکرد آن‌ها در دو مرحله آموزش و آزمون مشابه است اما به عنوان مثال، مدل Modular که در مرحله آموزش عملکردی مشابه با ANFIS و SVM دارد، در مرحله آزمون عملکردی به مراتب ضعیف‌تر نسبت به این دو مدل از خود

شبکه عصبی مصنوعی دارای بهترین عملکرد است. همچنین در ماه‌های خشک سال و در یک ایستگاه هیدرومتری، بهترین عملکرد پس از مدل SAR(1) مربوط به مدل SVM و در دو ایستگاه هیدرومتری دیگر، بهترین عملکرد مربوط به مدل ANFIS بوده است. (Feng et al. (2020) در تحقیقی به منظور پیش‌بینی دبی ماهانه ورودی به دو مخزن بر روی رودخانه یانگ‌تسه در چین، عملکرد مدل‌های SVM و شبکه عصبی مصنوعی را مقایسه کردند. در این تحقیق، ابتدا سری زمانی مشاهده‌شده از دبی با استفاده از روش variational mode decomposition که الگوریتمی برای تبدیل یک سیگنال به اجزای تشکیل‌دهنده آن است به چند بخش تفکیک شده و سپس هر بخش با مدل‌های یادشده مورد مدل‌سازی قرار گرفته است. نتایج این تحقیق حاکی از برتری مدل SVM نسبت به مدل سری زمانی در هر دو ایستگاه مورد مطالعه بود.

همان‌گونه که ذکر شد، به منظور کمی‌سازی عدم قطعیت خروجی مدل‌ها از باند عدم قطعیت (95PPU) و معیارهای p-factor و d-factor استفاده شده است. برای خروجی‌های به دست آمده از تمامی ساختارهای یک مدل برای هر مقدار مشاهده‌شده، صدک ۲/۵ و صدک ۹۷/۵ محاسبه شد. فاصله میان این دو صدک در هر مقدار مشاهده‌شده، باند عدم قطعیت مدل در پیش‌بینی این مقدار مشاهده‌شده را نشان می‌دهد. با محاسبه درصدی از مقادیر مشاهده‌شده که در محدوده باند مربوط به خود قرار می‌گیرند و همچنین میانگین عرض باندهای عدم قطعیت، p-factor و d-factor برای هر مدل محاسبه شد. مقادیر اولیه برای این دو فاکتور که با در نظر گرفتن خروجی تمامی ساختارها محاسبه شده‌اند در سطرهای اول و دوم جدول (۳) ارائه شده است. همان‌گونه که مشاهده می‌شود، محاسبه این دو فاکتور با در نظر گرفتن تمامی

ساختارها برای هر مدل، منجر به مقادیری بزرگ برای هر دو فاکتور می‌شود (بیشتر از ۹۲ درصد برای p-factor و بیشتر از ۲/۳۴ برای d-factor). هر چند مقادیر به دست آمده برای p-factor در تمامی مدل‌ها به مقدار ایده‌آل آن (۱۰۰ درصد) نزدیک است اما باید توجه داشت که همزمان، d-factor نیز باید مقداری کمتر از ۱/۵ داشته باشد که این شرط در مورد هیچ کدام از مدل‌ها صدق نمی‌کند. کمینه مقدار d-factor اولیه برابر با ۲/۳۴ و مربوط به مدل SVM است که بیشتر از ۵۶ درصد با حد مطلوب (کمتر از ۱/۵) فاصله دارد. به منظور دستیابی به مقادیر بهینه برای p-factor و d-factor، بر اساس دو آمار NS و RMSE، ده درصد از بدترین ساختارهای هر مدل انتخاب شده و حذف شدند و این رویه تا رسیدن به مقدار مطلوب برای d-factor (کمتر از ۱/۵) ادامه پیدا کرد. مقادیر نهایی برای این دو معیار در سطرهای سوم و چهارم جدول (۳) ارائه شده است. همان‌گونه که مشاهده می‌شود، برای مدل‌های Modular، PCA، TLRN امکان برقراری هر دو شرط (p-factor بیشتر از ۷۰ درصد و d-factor کمتر از ۱/۵) محقق نشده و مقادیر ارائه‌شده در جدول، بهترین مقادیری است که امکان رسیدن به آن‌ها وجود داشته است. اما در دو مدل ANFIS و SVM، هر دو فاکتور در محدوده مناسب قرار دارند. با توجه به مقادیر نهایی دو فاکتور می‌توان گفت که مدل SVM نسبت به سایر مدل‌ها از عدم قطعیت کمتری برخوردار است؛ به این معنی که انتخاب ساختارهای متفاوت برای این مدل، منجر به مجموعه جواب‌هایی با باند عدم قطعیت کمتر نسبت به سایر مدل‌ها می‌شود اما همچنان درصدی از مقادیر مشاهده‌شده که در این باند قرار می‌گیرند در محدوده رضایت‌بخش (بیشتر از ۷۰ درصد) است.

جدول ۳- عدم قطعیت خروجی مدل‌ها

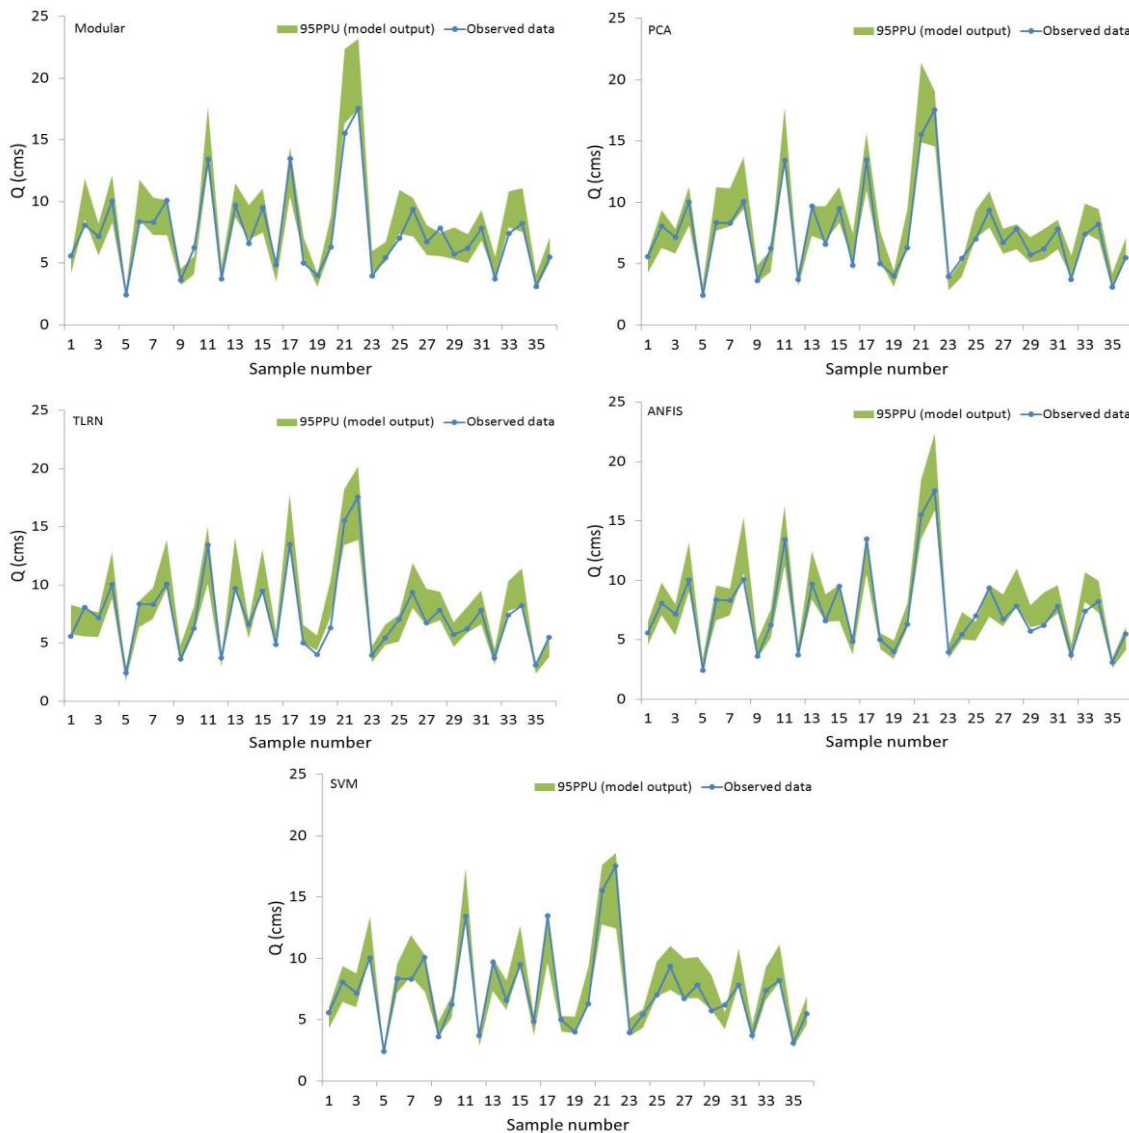
SVM	ANFIS	TLRN	PCA	Modular	پارامتر
۹۴	۹۶	۹۳	۹۵	۹۲	p-factor (%) اولیه
۲/۳۴	۲/۳۶	۲/۹۱	۳/۰۱	۲/۸۵	d-factor اولیه
۸۲	۷۸	۷۱	۷۰	۷۰	p-factor (%) نهایی
۱/۴۳	۱/۴۸	۱/۵۳	۱/۵۶	۱/۵۲	d-factor نهایی

در شکل (۵) مقادیر مشاهده‌شده به همراه باند 95PPU آن‌ها در مرحله آزمون نمایش داده شده است. 95PPU نشان‌دهنده خروجی نهایی هر کدام از مدل‌هاست و همان‌گونه که مشاهده می‌شود هر مدل، مجموعه‌ای از مقادیر پیش‌بینی شده را به ازای یک مقدار مشاهده‌شده ارائه می‌کند. مقدار (p-factor)-1

نشان‌دهنده خطای هر کدام از مدل‌هاست که بر این اساس، ساختارهای منتخب برای مدل SVM را می‌توان به عنوان بهترین ساختارها انتخاب کرد. P-factor نهایی برای مدل SVM برابر با ۸۲ درصد به دست آمده است. این بدان معنی است که با وجود انتخاب ساختارهای مختلف برای این مدل که منجر به دامنه‌ای

دبی‌های بیشینه، بیشتر از عرض این باند در کمینه دبی‌های مشاهده شده است و بنابراین می‌توان گفت عدم قطعیت در پیش‌بینی مقادیر کم، کمتر از عدم قطعیت در پیش‌بینی بیشینه دبی‌های مشاهده شده است. در صورتی که هدف از مدل‌سازی، پیش‌بینی دبی‌های بیشینه باشد می‌توان با تعریف یک حد آستانه، تحلیل عدم قطعیت و محاسبه p-factor و d-factor را به دبی‌های بیشتر از حد آستانه محدود کرد.

از مقادیر پیش‌بینی شده برای هر مقدار مشاهده شده می‌شود، همچنان ۱۸ درصد از داده‌های مشاهده شده در محدوده ۹۵ درصد میانی دامنه عدم قطعیت خود قرار نمی‌گیرند. با این وجود، این درصد برای مدل‌های PCA، Modular، TLRN و ANFIS به ترتیب برابر با ۳۰، ۳۰، ۲۹ و ۲۲ است و مشاهده می‌شود که نسبت به SVM عملکرد ضعیف‌تری داشته‌اند. نمودارهای ارائه شده همچنین نشان می‌دهند عرض باند عدم قطعیت در



شکل ۵- مقایسه خروجی تولید شده توسط مدل‌های مختلف و مقادیر مشاهده شده در مرحله آزمون

می‌توان معادل با توزیع احتمالاتی متغیر تصادفی دبی در نظر گرفت که مشخص می‌کند این متغیر تصادفی، با چه احتمالی مقادیر متفاوت را اختیار خواهد کرد. در صورت انتخاب صدک‌های ۲/۵ و ۹۷/۵ برای تعیین عرض این دامنه، محدوده‌ای که به احتمال ۹۵ درصد مقدار واقعی در آن قرار خواهد گرفت، مشخص

نتیجه‌گیری

در نگرش تصادفی به موضوع پیش‌بینی جریان خروجی از حوضه‌های آبریز، دامنه‌ای از پیش‌بینی‌ها برای متغیر دبی خروجی ارائه می‌شود و به پیش‌بینی تنها یک مقدار قطعی با احتمال ۱۰۰ درصد اکتفا نمی‌شود. در این نگرش، دامنه پیش‌بینی شده را

نهایی تولیدشده توسط آن‌ها، با توجه به محدوده‌های قابل قبول برای معیارهای p-factor (بیشتر از ۷۰ درصد) و d-factor (بیشتر از ۱/۵) تعیین شدند. در حوضه مورد بررسی، بهترین نتیجه برای مدل‌های SVM و ANFIS حاصل شد که در عین حال که مقادیر p-factor آن‌ها بیشتر از ۷۰ درصد بود، d-factor آن‌ها نیز در محدوده قابل قبول کمتر از ۱/۵ به دست آمد. هرچند اجرای این روش نسبت به یافتن مدلی با بهترین ساختار زمان بیشتری می‌گیرد اما این روش می‌تواند تحلیل بهتری از رفتار تصادفی متغیر مورد شبیه‌سازی ارائه کند.

REFERENCES

- Abbaspour, K. C., Johnson C. A. and van Genuchten, M. Th. (2004). Estimating uncertain flow and transport parameters using a sequential uncertainty fitting procedure. *Vadose Zone Journal*, 3. 1340–1352.
- Abbaspour, K. C., Rouholahnejad, E., Vaghefi, S., Srinivasan, R., Yang, H. and Kløve, B. (2015). A continental-scale hydrology and water quality model for Europe: Calibration and uncertainty of a high-resolution large-scale SWAT model. *Journal of Hydrology*, 524. 733–752.
- Abbaspour, K. C., Yang, J., Maximov, I., Siber, R., Bogner, K., Mieleitner, J., Zobrist, J. and Srinivasan, R. (2007). Modelling hydrology and water quality in the pre-Alpine/Alpine Thur watershed using SWAT. *Journal of Hydrology*, 333. 413–430.
- Afan, H. A., El-shafie, A., Mohtar, W. H. M. W. and Yaseen, Z. M. (2016). Past, present and prospect of an Artificial Intelligence (AI) based model for sediment transport prediction. *Journal of Hydrology*, 541. 902–913.
- Ahani, A. and Shourian, M. (2017). Prediction of Monthly Streamflow Using Data-driven Models. *Iran Water Resources Research*, 13(2). 207–214. (In Farsi)
- Azari, T. and Samani, N. (2015). Two Multilayer Perceptron Networks for the Determination of Leaky Confined Aquifer Parameters. *Scientific Quarterly Journal, GEOSCIENCES*, 25(97). 375–386. (In Farsi)
- Bastola, S., Murphy, C. and Sweeney, J. (2011). The role of hydrological modelling uncertainties in climate change impact assessments of Irish river catchments. *Advances in Water Resources*, 34(5). 562–576.
- Behzad, M., Asghari, K., Eazi, M. and Palhang, M. (2009). Generalization performance of support vector machines and neural networks in runoff modeling. *Expert Systems with Applications*, 36(4). 7624–7629
- Butts, M. B., Payne, J. T., Kristensen, M. and Madsen, H. (2004). An evaluation of the impact of model structure on hydrological modelling uncertainty for streamflow simulation. *Journal of Hydrology*, 298(1–4). 242–266.
- Chang, F. and Chang, Y. (2006). Adaptive neuro-fuzzy inference system for Prediction of water Level in reservoir. *Advances in Water Resources*, 29. 1–10.
- Dams, J., Nossent, J., Senbeta, T. B., Willems, P. and Batelaan, O. (2015). Multi-model approach to assess the impact of climate change on runoff. *Journal of Hydrology*, 529. 1601–1616.
- Ding, C. and He, X. (2004). K-Means clustering via principal component analysis. In proceedings of the 21st International Conference on Machine Learning, Banff, Canada.
- Feng, Z-K., Niu, W-J., Tang, Z-Y., Jiang, Z-Q., Xu, Y., Liu, Y. and Zhang, H-R. (2020). Monthly runoff time series prediction by variational mode decomposition and support vector machine based on quantum-behaved particle swarm optimization. *Journal of Hydrology*, 583. 124627.
- Georgakakos, K. P., Seo, D. J., Gupta, H., Schaake, J. and Butts, M. B. (2004). Towards the characterization of streamflow simulation uncertainty through multimodel ensembles. *Journal of Hydrology*, 298(1–4). 222–241.
- Isazadeh, M., Biazar, S. M. and Ashrafzadeh, A. (2017). Support vector machines and feed-forward neural networks for spatial modeling of groundwater qualitative parameters. *Environmental Earth Sciences*, 76(17). 1–14.
- Karimi, S., Shiri, J. and Nazemi, A. (2013). Estimating Daily Reference Crop Evapotranspiration Using Artificial Intelligences-Based ANFIS and ANN Techniques and Empirical Models. *Water and Soil Science*, 23(2). 139–158. (In Farsi)
- Kasiviswanathan, K. S., Cibin, R., Sudheer, K. P. and Chaubey, I. (2013). Constructing prediction interval for artificial neural network rainfall runoff models based on ensemble simulations. *Journal of Hydrology*, 499. 275–288.
- Lee, D. H. and Kang, D. S. (2016). The application of the artificial neural network ensemble model for simulating streamflow. *Procedia Engineering*, 154. 1217–1224.
- Liu, Y. and Gupta, H. V. (2007). Uncertainty in hydrologic modeling: Toward an integrated data assimilation framework. *Water Resources Research*, 43. 1–18.
- Moriassi, D. N., Arnold, J. G., Van Liew, M. W.,

می‌شود و به همین ترتیب می‌توان عرض دامنه مربوط به احتمال‌های دیگر را نیز تعیین کرد. مدلی که قادر به تولید دامنه‌ای مناسب از پیش‌بینی‌ها باشد را می‌توان به عنوان بهترین مدل در نظر گرفت. در این مقاله روشی برای انتخاب مدلی که بهترین دامنه از پیش‌بینی‌ها را مشخص می‌کند، بر مبنای مفهوم 95PPU و معیارهای p-factor و d-factor ارائه شد. با در نظر گرفتن پنج مدل متفاوت و ساختارهای متفاوت برای هر مدل، مجموعه‌ای از مدل‌های واسنجی‌شده و دامنه‌ای از مقادیر خروجی برای هر مقدار مشاهده‌شده حاصل شد. مدل‌های نهایی و دامنه

- Bingner, R. L., Harmel, R. D. and Veith, T. L. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transaction of ASABE*, 50(3). 885–900.
- Najafi, M. R., Moradkhani, H. and Jung, I. W. (2011). Assessing the uncertainties of hydrologic model selection in climate change impact studies. *Hydrological Processes*, 25(18). 2814–2826.
- Nourani, V., Baghanam, H., Adamowski, J. and Kisi, O. (2014). Applications of hybrid wavelet–Artificial Intelligence models in hydrology: A review. *Journal of Hydrology*, 514. 358–377.
- Pai, P. F. and Hong, W. C. (2007). A recurrent support vector regression model in rainfall forecasting. *Hydrological Process*, 21. 819–827.
- Samani, N., Gohari-Moghadam, M. and Safavi, A. A. (2007). A simple neural network model for the determination of aquifer parameters. *Journal of Hydrology*, 340(1–2). 1–11.
- Stefánsson, A., Končar, N. and Jones, A. (1997). A note on the gamma test. *Neural Computing and Application*, 5(3). 767–780.
- Tan, Q-F., Lei, X-H., Wang, X., Wang, H., Wen, X., Ji, Y. and Kang, A-Q. (2018). An adaptive middle and long-term runoff forecast model using EEMD-ANN hybrid approach. *Journal of Hydrology*, 567. 1–11.
- Vapnik, V. N. (1998). *Statistical Learning Theory*. Wiley, New York.
- Velázquez, J. A., Schmid, J., Ricard, S., Muerth, M. J., Gauvin St-Denis, B., Minville, M., Chaumont, D., et al. (2013). An ensemble approach to assess hydrological models' contribution to uncertainties in the analysis of climate change impact on water resources. *Hydrology and Earth System Sciences*, 17(2), 565–578.
- Wieland, R., Mirschel, W., Zbell, B., Groth, K., Pechenick, A. and Fukuda, K. (2010). A new library to combine artificial neural networks and support vector machines with statistics and a database engine for application in environmental modeling. *Environmental Modelling & Software*, 25(4). 412–420.
- Wu, W., Dandy, G. C. and Maier, H. R. (2014). Protocol for developing ANN models and its application to the assessment of the quality of the ANN model development process in drinking water quality modelling. *Environmental Modelling & Software*, 54. 108–127.
- Yang, J., Reichert, P., Abbaspour, K. C., Xia, J. and Yang, H. (2008). Comparing uncertainty analysis techniques for a SWAT application to the Chaohe Basin in China. *Journal of Hydrology*, 358. 1–23.
- Yaseen, Z. M., El-shafie, A., Jaafar, O., Afan, H. A. and Sayl, K. N. (2015). Artificial intelligence based models for stream-flow forecasting: 2000–2015. *Journal of Hydrology*, 530. 829–844.