



سیدمهدی ثاقبیان^۱

بررسی مقایسه‌ای پارامترهای تأثیرگذار بر جریان ورودی ماهانه به یک سد مخزنی با بکارگیری روش- های فرا مدل

تاریخ دریافت: ۱۳۹۹/۰۴/۱۵ تاریخ پذیرش: ۱۴۰۲/۰۷/۲۳

چکیده

مدلسازی جریان ورودی به مخزن سد از مهمترین گام‌ها در مدیریت آبخیزداری حوزه‌ها، بهره‌برداری از مخازن سدها، سیستم‌های هشدار سیل، اولویت بندی حوزه‌ها از نظر میزان فرسایش و رسوبگذاری می‌باشند. مدیریت بهره‌برداری بهینه از سامانه‌های منابع آب نظیر مخازن سدها، مستلزم ارتقاء دقت پیش‌بینی جریان ورودی به آن‌ها است. به همین دلیل ضروری است که مقدار این پارامتر به طور دقیق تخمین زده شود. به منظور پیش‌بینی جریان ورودی به مخزن سد، روش‌های متعددی توسعه یافته‌اند. در تحقیق حاضر از روش‌های هوشمند ماشین بردار پشتیبان (SVM) و سیستم استنتاج تطبیقی عصبی-فازی (ANFIS) جهت تخمین میزان جریان ورودی به مخزن سد ستارخان استفاده شده است و نرخ تأثیر پارامترهای ورودی مختلف از قبیل بارش، دبی و دمای ماهیانه در دقت مدل‌ها مورد تحلیل قرار گرفته است. نتایج حاصله کارایی بالایی روش‌های فرامدل را در تخمین جریان ماهیانه ورودی به مخزن سد ستارخان نشان داد. بهترین نتایج برای داده‌های آزمون، در حالت مدلسازی بر اساس دبی و بارش ماهیانه مقادیر $R=0.878$ ، $DC=0.782$ ، $RMSE=0.063$ و در حالت مدلسازی بر اساس دما، بارش و دبی ماهیانه مقادیر $R=0.805$ ، $DC=0.708$ و $RMSE=0.108$ به دست آمدند. مطابق با نتایج مشاهده گردید که مدل با پارامترهای ورودی دبی و بارش ماهیانه منجر به جواب‌های دقیق‌تری می‌گردد.

واژه‌های کلیدی: بارش، دبی ورودی، دما، روش‌های فرامدل

مقدمه

تخمین مقدار جریان ورودی به سدهای ذخیره‌ای اولین و مهمترین قدم در برنامه ریزی و تخصیص بهینه آب به منابع مصرف و همچنین تولید انرژی برق - آبی به شمار می‌آید. برآورد هرچه دقیق‌تر مقدار جریان ورودی به مخازن، به دلیل نقشی که در مدیریت و بهره‌برداری از مخازن و تولید انرژی برقایی دارد، از موضوعات با اهمیت در مهندسی منابع آب محسوب می‌شود. (Amini et al., 2007) تخمین جریان ورودی به مخزن سد به دلیل تأثیر پارامترهای مختلف، یکی از پدیده‌های پیچیده در زمینه مهندسی آب بشمار می‌آید. این فرآیند دارای تغییرات

زمانی بوده و لذا مدل‌سازی آن بدلیل سرشت غیرخطی آن با مشکلاتی همراه می‌باشد. اگرچه تحقیقات تفصیلی از این فرآیند ممکن است بیشتر جنبه داشته باشد تا جنبه کاربردی، با این حال بسیاری از فعالیت‌ها و طراحی‌های مهندسی نیازمند تخمینی مناسب از کمیت و کیفیت جریان ورودی ناشی از یک بارش معین می‌باشند. جهت مدیریت و بهره‌برداری بهینه از مخازن سدها، مقدار جریان ورودی به آن‌ها باید به صورت دقیق پیش‌بینی گردد. اهمیت این موضوع در حوضه‌های بزرگ بدلیل آبیاری اراضی وسیع کشاورزی و تولید انرژی برقآبی بارزتر می‌باشد (Khatai and Mirzaei, 2013) از جمله مهمترین اهداف پیش‌بینی جریان ورودی به مخازن سدها، مقابله مناسب و به موقع با خطر سیلاب و سرریز شدن سدها و حداقل نمودن خسارت آن است. همچنین یکی از پیش‌نیازهای مهم در بهره‌برداری بهینه از سامانه‌های منابع آب چند منظوره‌ای که یکی از اهداف آن تولید برق باشد، اطلاع از میزان جریان ورودی به مخازن سدها در ماه‌های آینده می‌باشد. در منابع و مقالات، روش‌های ریاضی متعددی یافت می‌شود تا با شناسایی کمیت و کیفیت بارندگی برای یک ناحیه فرضی تخمین دقیقی از دبی ایجاد شود (Changchit and Terrell (1989). یک مدل ریاضی را که سه مشخصه مهم چند منظوره بودن، ورودی‌های تصادفی به مخزن و طبیعت سیستم‌های مخازن با مقیاس بزرگتر را منعکس می‌کند، گسترش دادند (Amini et al. 2007) در مقاله‌ای با عنوان بهینه‌سازی بهره‌برداری از مخازن سدها با در نظر گرفتن افق دید برنامه‌ریزی یک ساله و بازه‌های زمانی ماهیانه از روش بهینه‌سازی برای سد جیرفت استفاده کرده و نشان دادند که در بدترین شرایط خشکسالی نیز با مدیریت صحیح (استفاده از برنامه بهینه‌سازی) سد جیرفت نیاز پائین دست را برآورده می‌کند (Bani Habib and Valipour (2008). در سال ۱۳۸۷ ارزیابی مقایسه‌ای مدل‌های آرما، آرما و شبکه عصبی مصنوعی را در پیش‌بینی جریان ماهیانه ورودی به مخزن سد دز انجام دادند. نتایج به دست آمده نشان داد که در حالت کلی، با در نظر گرفتن ضریب همبستگی و معیار میانگین مربعات خطاها، مدل شبکه عصبی مصنوعی عملکرد بهتری نسبت به مدل رگرسیون خطی دارد. همچنین نتایج نشان داد که بهترین موقع برای پیش‌بینی یک روز جلوتر با استفاده از داده‌های نزدیکترین ایستگاه بالادست سد (تنگینج) و سه روز جلوتر با استفاده از داده‌های ایستگاه‌های ونایی (سراب سفید)، درودتیره، کمنداب و دره‌تخت انجام می‌شود (Khatai and Mirzaei (2013). به مقایسه کارایی پیش‌بینی دبی ماهیانه با استفاده از روش‌های هوش مصنوعی و سری‌های زمانی پرداختند. آنها نشان دادند در بین مدل‌های مختلف باکس-جنکینز بهترین پیش‌بینی دبی را مدل آرما نوع چهار ارائه کرده است. (Towfik (92003) تقابل پیش‌بینی خطی و غیرخطی را در جریان ماهیانه رودخانه نیل مورد بررسی قرار داد. نتایج نشان داد که غیرخطی بودن مدل‌های شبکه عصبی مصنوعی در بعضی موارد منجر به بهبود دقت پیش‌بینی آینده‌ی شده است (Noori et al. (2010). با استفاده از شبکه عصبی و رگرسیون میزان جریان رودخانه‌ی صوفی‌چای تبریز را بررسی نمودند و شبکه عصبی را به عنوان مدل با دقت بیشتر انتخاب کردند. با این وجود مدل‌سازی جریان ورودی به مخزن سد یک مسئله چالش‌برانگیز است. برای غلبه بر مشکلات موجود در این زمینه می‌توان از روش‌های محاسبات نرم، برای پیش‌بینی مقدار دبی متوسط ماهیانه ورودی به سدها استفاده نمود. با وجود اینکه مدل‌های


هیدرولوژیکی مختلفی جهت مدل‌سازی پارامترهای دبی پیشنهاد شده اند، اما با توجه به ماهیت غیرخطی و ویژگی‌های متغیر زمانی و مکانی در سیستم گردش آبی، هیچ یک از مدل‌های آماری و مفهومی پیشنهاد شده به منظور الگوسازی دقیق دبی جریان نتوانسته اند به عنوان یک مدل برتر و توانا شناخته شوند و عدم قطعیت در پیش‌بینی‌ها از اعتبار برآوردها از طریق مدل‌های مختلف می‌کاهد. در بین مدل‌ها، مدل‌های سری زمانی جهت پیش‌بینی به کار رفته اند. این مدل‌ها در حقیقت مدل‌های تصادفی هستند که در مورد سری زمانی که شامل N مشاهده از یک جامعه نامتناهی است، بوسیله یک فرایند تصادفی بوجود آمده است. انواع مدل‌های سری‌های زمانی عبارتند از مدل اتورگرسیون، مدل میانگین متحرک، مدل ترکیبی. با این حال، امروزه شبکه‌های غیرخطی به عنوان یکی از سیستم‌های هوشمند در پیش‌بینی پدیده‌های پیچیده بسیار مورد استفاده قرار می‌گیرند. این روش‌ها که اکثراً الهام گرفته از پدیده‌های موجود در طبیعت هستند و می‌توانند برای پیش‌بینی هرگونه متغیری که در آن رابطه بین متغیرهای مربوطه به خوبی درک نمی‌شود، پیدا کردن اندازه و شکل راه‌حل نهایی دشوار است، و روش‌های تحلیلی ریاضی رایج قادر به حل آن‌ها نبوده و یا بسیار زمان‌بر هستند، استفاده شوند، به‌عنوان ابزاری توانمند در حل مسائل پیچیده به شمار می‌آیند و معمولاً دارای جواب بهتری نسبت به روش‌های کلاسیک هستند. این مدل‌ها به طور معناداری، خطاهای کوچکتری را در پیش‌بینی نسبت به مدل‌های آماری نشان می‌دهند و دارای سرعت پیش‌بینی بالاتری هستند. (Govindaraju, 2000) از جمله این روش‌ها می‌توان به شبکه‌های عصبی مصنوعی (ANN)، برنامه‌ریزی ژنتیک (GP)، ماشین بردار پشتیبان (SVM) و مدل‌های فازی (NF) اشاره کرد. روش ماشین بردار پشتیبان (SVM) به‌عنوان یکی از روش‌های هوشمند، اغلب گزینه خوبی برای پیش‌بینی بر مبنای رگرسیون می‌باشد و همچنین سیستم استنتاج فازی-عصبی انطباقی (ANFIS) که ترکیب شبکه‌های عصبی و سیستم فازی بر مبنای ریاضیات فازی است، قابلیت خوبی در آموزش، ساخت و طبقه‌بندی دارد. تاکنون از این روش‌ها برای پیش‌بینی پارامترهای مختلفی استفاده گردیده است که از آن جمله می‌توان به تخمین بار رسوبی معلق (Kisi et al., 2006)، تخمین بار بستر در مقاطع دایره‌ای شکل (Roushangar and Ghasempour., 2017)، رابطه بین غلظت رسوب معلق و دبی جریان (Lohani et al., 2007)، پیش‌بینی جریان ورودی به رودخانه‌ها (Zahiri and Najafzadeh, 2018) (Sahoo and Ray, 2006)؛ تخمین سطح آب دریاچه (Khan and Coulibaly, 2006)، شبیه‌سازی جریان بر روی سرریزهای جانبی (Parsai et al., 2014) و تخمین دبی سیلاب (Bermudez et al., 2018) اشاره کرد. با توجه به اینکه در مدل‌سازی جریان ورودی به مخزن سد پارامترهای مختلفی تاثیرگذار بوده و مساله دارای عدم قطعیت می‌باشد لذا، در این تحقیق با استفاده از داده‌های مربوط به سد ستارخان قابلیت و کارایی روش‌های هوشمند SVM و ANFIS در تخمین جریان ورودی ماهانه به مخزن سد تحت سه سناریو مختلف مورد بررسی قرار گرفت. در این راستا مدل‌های مختلفی تحت سه سناریو و بر اساس تنها دبی ماهیانه ورودی به مخزن، بر اساس دبی و بارش ماهیانه و همچنین بر اساس دبی، بارش و دمای ماهیانه تعریف گردید و تاثیر مدل‌سازی متفاوت در تخمین این

پارامتر ارزیابی شد و برای هر حالت، مدل برتر تعیین گردید. همچنین، با استفاده از روش آنالیز حساسیت فاکتوریل پارامترهای تاثیرگذار و دارای همبستگی بیشتر با جریان ورودی به مخزن سد تعیین شد.

مواد و روش‌ها

موقعیت و مشخصات عمومی سد ستارخان

سد مخزنی ستارخان (شکل ۱) در ۱۹ کیلومتری غرب شهرستان اهر و در ۲ کیلومتری روستای گونجیک (نزدیکترین روستا به سد) ساخته شده است و از نوع خاکی با هسته رسی می باشد. رودخانه اهر چای در مسیر خود تعدادی رود کوچک را در بر می‌گیرد و بر اساس محاسبات هیدرولوژیکی به طور متوسط سالانه به میزان ۹۲ میلیون مترمکعب آب به دریاچه سد می‌رساند. مساحت حوزه آبریز رودخانه اهرچای از سرشاخه تا انتهای دشت‌های شهرستان اهر ۹۵۰ کیلومتر مربع بوده که از مجموع مساحت فوق ۸۵۵ کیلومتر مربع آن را آبریزهای کوهستانی و ۹۵ کیلومتر مربع باقیمانده را دشت‌های شهرستان اهر به خود اختصاص داده‌اند. نزولات جوی در قسمت اعظم حوزه به استثنای ارتفاعات حوزه که برفگیر هستند اکثرا به صورت باران است. این سد چند منظوره برای مقاصد کنترل طغیانهای رودخانه اهرچای، تامین آب کشاورزی، تامین آب شرب، تامین آب صنعت و تامین آب زیست محیط احداث گردیده است. ایستگاه‌های نزدیک به سد ستارخان، کاسین و اورنگ می باشند. حداکثر تراز سطح آب نسبت به سطح مبنا و دبی موجود در آمار ایستگاه کاسین به ترتیب ۷۰ سانتیمتر و ۶۶.۹ مترمکعب در ثانیه و حداکثر رسوب برداشت شده ۹۲.۳۴۹۴ تن در روز می باشد. با توجه به کم بودن طول شاخه رودخانه در محدوده این ایستگاه مشخص است که مقدار دبی و رسوب در این ایستگاه از ایستگاه‌های پایین‌دست کمتر خواهد بود. حداکثر تراز سطح آب نسبت به سطح مبنا و دبی اندازه گیری شده در ایستگاه اورنگ به ترتیب ۱۵۷ سانتیمتر و ۱۳.۱۷ مترمکعب در ثانیه و همچنین حداکثر رسوب برداشت شده ۴۷.۱۷۳۰۸ تن در روز است (گزارش آب منطقه‌ای، ۲۰۰۹).

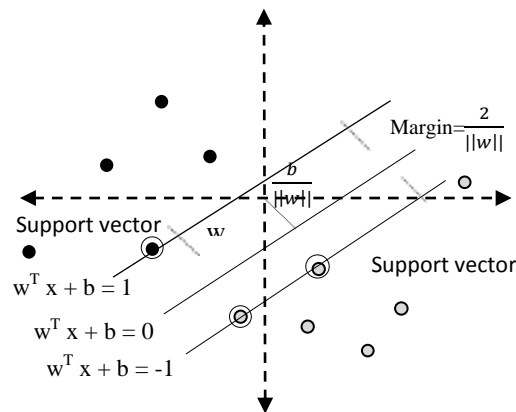


شکل ۱: موقعیت سد ستارخان اهر

Figure 1: Location of Ahar Sattarkhan dam

ماشین بردار پشتیبان SVM

الگوریتم SVM، جزء الگوریتم‌های تشخیص الگو دسته‌بندی می‌شود که برای اولین بار توسط وپنیک معرفی شد (Vapnik., 1995). مبنای کاری SVM دسته‌بندی خطی داده‌ها است و در تقسیم خطی داده‌ها سعی می‌شود خطی انتخاب شود که حاشیه اطمینان بیشتری داشته باشد (شکل ۲). در واقع هدف الگوریتم SVM این است که خطی را بیابد که از داده‌های موجود در دو کلاس دارای بیشترین فاصله باشد و یا به عبارت دیگر دارای کمترین ریسک عملیاتی باشد. در مرحله بعد دو صفحه مرزی موازی با صفحه تفکیک کننده رسم می‌شود و تا زمانی که به داده‌ها برخورد کنند از هم دور می‌شوند. صفحه تفکیک کننده‌ای که بیشترین فاصله را از صفحات دسته‌بندی داشته باشد بهترین صفحه تفکیک کننده است. نزدیک‌ترین داده‌های آموزشی به صفحات تفکیک کننده، بردار پشتیبان نامیده می‌شود. در مسائلی که داده‌ها به‌طور خطی تفکیک‌پذیر نباشند، می‌توان با نگاشت داده‌ها به یک فضای ویژگی، آن‌ها را بصورت خطی جداپذیر نمود. نگاشت داده‌ها به فضای ویژگی با استفاده از توابع کرنل انجام می‌گیرد. در مسائل SVM انتخاب تابع کرنل بسیار مهم می‌باشد و انتخاب آن به نوع و ماهیت مسئله بستگی دارد؛ بنابراین نمی‌توان تابعی را به‌طور قطعی به‌عنوان تابع مناسب برای SVM معرفی کرد و نسبت به شرایط این موضوع می‌تواند متغیر باشد. انواع مختلف تابع کرنل در جدول ۱ نمایش داده شده است.



شکل ۲: جداسازی داده‌ها در SVM و بردارهای پشتیبان

Figure 2: Data separation in SVM and support vectors

جدول ۱- انواع تابع کرنل در الگوریتم SVM

Table 1- Types of kernel function in SVM algorithm

| نوع کرنل | تابع کرنل | پارامتر کرنل |
|------------|--|--------------|
| Linear | $K(x_i, x_j) = (x_i, x_j)$ | - |
| Polynomial | $K(x_i, x_j) = ((x_i, x_j) + 1)^d$ | d |
| RBF | $K(x_i, x_j) = \exp(-\frac{\ x_i - x_j\ ^2}{2\sigma^2})$ | γ |
| Sigmoid | $K(x_i, x_j) = \tanh(-\alpha(x_i, x_j) + c)$ | α, c |

سیستم استنتاج عصبی - فازی انطباقی ANFIS

شبکه‌های عصبی - فازی با الگوبرداری از سیستم کارکرد مغز انسان، با پردازش داده‌ها تجربی و بدون توجه به فیزیک مسئله، قانون نهفته مابین داده‌ها را کشف می‌نمایند. نکته مهم منطق فازی امکان برقراری ارتباط بین فضای ورودی به فضای خروجی می‌باشد و مکانیسم اولیه برای انجام این کار لیستی از جملات است که قانون نامیده می‌شوند. در فرآیند If-Then آموزش، این قوانین به صورت موازی ارزیابی و تعیین می‌شوند. از طرف دیگر شبکه‌های عصبی دارای توانایی آموزش از محیط (جفت‌های ورودی - خروجی) می‌باشد. جانگ برای اولین بار با در نظر گرفتن توانایی‌های تئوری فازی و شبکه عصبی، مدل سیستم استنتاج عصبی - فازی انطباقی را ارائه داد (Jang, 1993). مدل سیستم استنتاج عصبی انطباقی شبکه‌ای چندلایه، متشکل از گره‌ها (ANFIS) فازی و کمانهای اتصال‌دهنده گره‌ها می‌باشد. سیستم فازی با مجموعه‌ای شامل N قاعده فازی بیان می‌گردد و شامل پنج لایه: گره‌های ورودی، گره‌های قاعده، گره‌های متوسط، گره‌های نتیجه و گره‌های خروجی است.

روش‌های آنالیز حساسیت

تحلیل حساسیت به بررسی چگونگی تغییرات در خروجی مدل نسبت به تغییرات در مؤلفه‌های ورودی می‌پردازد. سؤالاتی که با تحلیل حساسیت پاسخ داده می‌شود شامل این موارد است: چه مؤلفه‌های ورودی بیشترین تغییرات را در خروجی مدل ایجاد می‌کند؟ آیا مؤلفه‌هایی وجود دارد که تغییرات قابل اغماض بر روی خروجی بگذارد؟ آیا اندرکنشی بین مؤلفه‌ها وجود دارد که باعث افزایش یا تضعیف تغییرات ایجاد شده با یک متغیر خاص شود؟ روش‌های کلی تحلیل حساسیت با توجه به اینکه تغییرات خروجی به وسیله تغییرات مؤلفه‌های ورودی اطراف یک مقدار مرجع، یا در کل فضای ممکن به دست آید، به دو گروه محلی و جامع تقسیم می‌گردد. روش‌های تحلیل حساسیت محلی معمولاً پارامترهای مدل را به عنوان متغیر ورودی در نظر گرفته و هدف آن‌ها ارزیابی تأثیر عدم قطعیت پارامتر ورودی مدل بر عملکرد مدل است. روش‌های تحلیل حساسیت جامع، هم پارامترهای مدل و هم سایر عوامل ورودی مدل در یک فرآیند شبیه‌سازی را در نظر می‌گیرد. یکی از روش‌های آنالیز حساسیت روش حذف متغیر ورودی است که در آن تغییرات در خروجی مدل بررسی می‌شود درحالی‌که یکی از متغیرهای ورودی حذف شده و بقیه در مدل باقی مانده‌اند. روش دیگر آنالیز فاکتوریل است که جهت بررسی تأثیرات اصلی پارامترها از نظر کمی استفاده می‌شود. هر گاه در یک مدل تعداد نسبتاً زیادی متغیر وجود داشته باشد، یافتن رابطه‌ها و یا به عبارت دیگر همبستگی بین این متغیرها به روش‌های معمولی بسیار مشکل و گاه ناممکن است. روش آنالیز فاکتوریل برای رفع این مشکل در سال ۱۹۰۱ توسط پیرسون به وجود آمد و بر مبنای آن متغیرها به گونه‌ای دسته - بندی می‌شوند که در نهایت به دو یا چند عامل که همان مجموعه متغیرها هستند محدود می‌گردند، به عبارت دیگر، متغیرهای مورد استفاده در مدل بر اساس صفات مشترکشان به دو یا چند دسته محدود شده و این دسته‌ها را فاکتور می‌نامند. پس از آن روابط بین فاکتورها به دست آمده و در هر فاکتور نیز روابط بین متغیرهای آن محاسبه شده و در نهایت روابط بین متغیرها محاسبه می‌شود (Tezcan et al., 2015).

به‌طور کلی هدف از آنالیز فاکتوریل به شرح زیر خلاصه می‌شود:

الف) تفسیر وجود همبستگی درونی بین تعدادی صفت قابل مشاهده از طریق عواملی که قابل مشاهده نیستند و آنها را فاکتور گویند.

ب) ارائه روش ترکیب و خلاصه کردن تعداد زیادی از متغیرها در تعدادی گروه متمایز.

ج) از بین متغیرهای مختلف، تأثیرگذارترین آنها تعیین می‌شود و در پژوهش‌های بعدی به‌طور جزئی‌تر، متغیرهای تأثیرگذار را با تکرار بیشتری بررسی می‌کنند.

با توجه به موارد بالا، عمده‌ترین هدف استفاده از تحلیل فاکتوریل، کاهش حجم داده‌ها و تعیین مهم‌ترین متغیرهای مؤثر در شکل‌گیری پدیده‌هاست. از آنجا که در اکثر پدیده‌های هیدرولیکی عوامل مختلفی تأثیرگذار بود و در اغلب موارد با تعداد زیادی از متغیرها روبرو هستیم در نتیجه برای کاهش تعداد متغیرها و همچنین تعیین مؤثرترین پارامترها می‌توان از آنالیز فاکتوریل به‌عنوان یک روش مناسب استفاده کرد.

مدل‌های پیشنهادی و ارزیابی اعتبار مدل‌ها

پس از تهیه اطلاعات و داده‌های لازم از سد ستارخان و ایستگاه‌های نزدیک به آن (کاسین و اورنگ) از طریق شرکت آب منطقه‌ای استان، ساختار ورودی مدل‌ها بر اساس پارامترهای دبی، بارش و دمای ماهیانه تعریف گردید. مدل‌های پیشنهادی در جدول (۲) نشان داده شده است. همچنین به‌منظور ارزیابی کارایی روش‌های به‌کاررفته در این تحقیق از سه معیار ارزیابی مدل استفاده گردیده است که عبارت‌اند از: ضریب همبستگی شاخصی است که درجه همبستگی بین دو متغیر را به صورت عددی نشان می‌دهد و به این صورت تحلیل همبستگی به سهولت و روشنی بیشتری امکان پذیر می‌شود. (DC) ضریب تبیین، (RMSE) ریشه میانگین مربعات خطاها و (MBE) میانگین انحراف خطا. هر چه مقدار R و DC به یک نزدیک‌تر و مقدار RMSE و MBE برای یک مدل کوچک‌تر باشد به معنی مطلوب بودن آن مدل می‌باشد. روابط این پارامترهای آماری به صورت زیر می‌باشند:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (l_{mi} - l_{pi})^2}{N}} \quad \text{رابطه (۱)}$$

$$DC = 1 - \frac{\sum_{i=1}^N (l_{mi} - l_{pi})^2}{\sum_{i=1}^N (l_{mi} - \bar{l}_{mi})^2} \quad \text{رابطه (۲)}$$

$$R = \frac{\sum_{i=1}^N (l_{mi} - \bar{l}_{mi}) \times (l_{pi} - \bar{l}_{pi})}{\sqrt{\sum_{i=1}^N (l_{mi} - \bar{l}_{mi})^2 \times \sum_{i=1}^N (l_{pi} - \bar{l}_{pi})^2}} \quad \text{رابطه (۳)}$$

$$MBE = \frac{\sum_{i=1}^N (l_{pi} - l_{mi})}{n} \quad \text{رابطه (۴)}$$

l_{mi} : دبی ورودی اندازه‌گیری شده، $\overline{l_{mi}}$: متوسط دبی ورودی اندازه‌گیری شده، l_{pi} : دبی ورودی پیش‌بینی شده، $\overline{l_{pi}}$:

متوسط دبی ورودی پیش‌بینی شده، N : تعداد داده‌ها.

جدول ۲- مدل‌های تعریف شده در تحقیق

Table 2- Models defined in the research

| نام مدل | پارامترهای ورودی |
|---------|-----------------------------|
| M1 | Q_{t-1} |
| M2 | Q_{t-2} |
| M3 | Q_{t-1}, Q_{t-2} |
| M4 | P_{t-1} |
| M5 | P_{t-1}, Q_{t-1} |
| M6 | P_{t-2}, Q_{t-2} |
| M7 | T_{t-1}, P_{t-1} |
| M8 | T_{t-1}, Q_{t-1} |
| M9 | $P_{t-1}, T_{t-1}, Q_{t-1}$ |

در جدول ۲، Q نشان دهنده جریان ورودی به مخزن سد می‌باشد. پارامترهای Q_{t-1} و Q_{t-2} نشانگر دبی در ماه گذشته و دو ماه گذشته می‌باشند. همچنین P نشان دهنده میزان بارش و T بیانگر دماست. لازم به توضیح است که آموزش نرم‌افزار در صورت اعمال یکسری پیش‌پردازش‌ها بر روی ورودی‌ها و هدف می‌تواند کارآیی بالاتری داشته باشد. اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود لذا نرمالیزه کردن داده‌ها خصوصاً زمانی که دامنه تغییرات ورودی‌ها زیاد باشد کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند. روش استفاده شده برای پیش‌پردازش داده‌ها در این تحقیق به شرح زیر است:

$$x_n = 0.1 + 0.9 \times \left(\frac{x - x_{\min}}{x_{\max} - x_{\min}} \right) \quad \text{رابطه ۶}$$

در این رابطه x_{\max} ، x_{\min} به ترتیب حداقل و حداکثر مقدار داده‌های مشاهده شده و x_n داده نرمال شده می‌باشد. برای رسیدن به نتایج بهتر و دقیق‌تر روند آموزش چند بار تکرار گردید و نهایتاً الگوی ۳۰٪ داده‌ها جهت تست و ۷۰٪ داده‌ها جهت آموزش به عنوان الگوی برتر انتخاب شد. با توجه به اینکه داده‌ها به صورت نرمالیزه شده به کار خواهند رفت، بنابراین معیارهای ارزیابی بی‌بعد بوده و دارای واحد نخواهند بود.

نتایج و بحث

در این تحقیق جریان ورودی ماهیانه به مخزن سد ستارخان تحت سه سناریو مختلف مورد بررسی قرار گرفت. در سناریو اول مدل‌های مختلفی بر اساس تنها دبی ماهیانه ورودی به مخزن تعریف گردید. سناریو دوم بر اساس تاثیر هم‌زمان دبی و بارش ماهیانه و سناریو سوم بر اساس تاثیر هم‌زمان دبی، بارش و دمای ماهیانه در تخمین جریان ورودی ماهیانه به مخزن سد تعریف گردید و تاثیر مدل‌سازی متفاوت مورد ارزیابی قرار گرفت. نتایج حاصله در ادامه آورده شده است.


سناریو اول: تعریف مدل‌ها تنها بر اساس دبی ماهیانه

جهت بررسی تاثیر دبی ماهیانه به عنوان تنها پارامتر ورودی در تخمین میزان جریان ورودی به مخزن سد چندین مدل تعریف گردید و مورد بررسی قرار گرفت. نتایج حاصل از تحلیل مدل‌های این حالت به صورت جدول ۳ آورده شده است. همانطور که از نتایج جدول مشاهده می‌گردد با در نظر گرفتن داده‌های ایستگاه اورنگ، مدل $Q=f(Q_{t-1}, Q_{t-2})$ با داشتن پارامترهای دبی ورودی یک ماه و دو ماه گذشته به عنوان پارامتر ورودی مدل منجر به جوابهای دقیق‌تری گردیده است. برای این مدل سری داده‌های تست یا استفاده از روش ANFIS با داشتن $R=0.726$ ، $DC=0.514$ ، $RMSE=0.115$ و $MBE=-0.023$ بهترین نتایج را از لحاظ معیارهای ارزیابی ارائه کرده‌اند. همچنین مشاهده می‌گردد که با استفاده از داده‌های ایستگاه کاسین نیز مدل $Q=f(Q_{t-1}, Q_{t-2})$ با داشتن بیشترین R و DC و کمترین میزان خطا ($RMSE$) بهترین مدل می‌باشد. برای این حالت مقادیر $R=0.826$ ، $DC=0.694$ ، $RMSE=0.094$ و $MBE=0.0044$ برای سری داده‌های آزمون بدست آمده است. ملاحظه می‌گردد که نتایج روش ANFIS تا حدودی دقیق‌تر از روش SVM می‌باشد. با توجه به نتایج حاصله مشاهده می‌گردد که در تخمین میزان جریان ورودی به مخزن سد، استفاده از پارامتر دبی ماه گذشته در مقایسه با تخمین جریان ورودی با استفاده از دبی دو ماه گذشته منجر به جوابهای دقیق‌تری می‌گردد. همچنین در بین ایستگاه‌ها مدل برتر ایستگاه کاسین بهترین نتایج را ارائه داده است. در شکل ۳ نمودار بهترین مدل برای سری داده‌های آموزش و تست برای مدل برتر ایستگاه کاسین نشان داده شده است.

جدول ۳- نتایج حاصل از تحلیل مدل‌ها در حالت مدلسازی بر اساس دبی ماهیانه

Table 3- The results of the analysis of the models in the modeling based on the monthly discharge

| مدل | روش | معیارهای ارزیابی | | | | | | | |
|-------------------------|-------|------------------|-------|-------|--------|----------|-------|-------|--------|
| | | آموزش | | | | صحت سنجی | | | |
| | | R | DC | RMSE | MBE | R | DC | RMSE | MBE |
| ایستگاه اورنگ | | | | | | | | | |
| $Q=f(Q_{t-1})$ | ANFIS | ۰/۶۷۳ | ۰/۴۸۵ | ۰/۱۰۱ | -۰/۰۳۳ | ۰/۶۱۳ | ۰/۳۶۷ | ۰/۱۲۱ | -۰/۰۴۱ |
| | SVM | ۰/۶۵۷ | ۰/۴۷۳ | ۰/۱۰۴ | -۰/۰۳۹ | ۰/۵۹۸ | ۰/۳۵۸ | ۰/۱۲۵ | -۰/۰۴۴ |
| $Q=f(Q_{t-2})$ | ANFIS | ۰/۶۲۲ | ۰/۳۴۶ | ۰/۱۳۲ | -۰/۰۵۲ | ۰/۴۴۹ | ۰/۲۹۸ | ۰/۱۳۶ | -۰/۰۶۱ |
| | SVM | ۰/۶۰۷ | ۰/۳۳۸ | ۰/۱۳۴ | -۰/۰۵۵ | ۰/۴۳۸ | ۰/۲۹۱ | ۰/۱۳۸ | -۰/۰۶۳ |
| $Q=f(Q_{t-1}, Q_{t-2})$ | ANFIS | ۰/۷۹۳ | ۰/۵۸۱ | ۰/۰۹۷ | -۰/۰۱۸ | ۰/۷۲۶ | ۰/۵۱۴ | ۰/۱۱۵ | -۰/۰۲۳ |
| | SVM | ۰/۷۷۴ | ۰/۵۶۷ | ۰/۰۹۹ | -۰/۰۱۹ | ۰/۷۰۸ | ۰/۵۰۱ | ۰/۱۱۷ | -۰/۰۲۸ |
| ایستگاه کاسین | | | | | | | | | |
| $Q=f(Q_{t-1})$ | ANFIS | ۰/۷۵۳ | ۰/۴۷۹ | ۰/۱۰۲ | -۰/۰۵۸ | ۰/۶۷۴ | ۰/۳۳۲ | ۰/۱۲۸ | -۰/۰۷۴ |
| | SVM | ۰/۷۳۵ | ۰/۴۶۷ | ۰/۱۰۶ | -۰/۰۶۲ | ۰/۶۵۸ | ۰/۳۲۴ | ۰/۱۳۲ | -۰/۰۷۸ |
| $Q=f(Q_{t-2})$ | ANFIS | ۰/۶۱۸ | ۰/۳۲۷ | ۰/۱۳۳ | -۰/۰۷۹ | ۰/۶۱۶ | ۰/۲۹۲ | ۰/۱۳۵ | -۰/۰۸۷ |
| | SVM | ۰/۶۰۲ | ۰/۳۱۹ | ۰/۱۳۴ | -۰/۰۸۱ | ۰/۶۰۱ | ۰/۲۸۵ | ۰/۱۳۷ | -۰/۰۸۹ |
| $Q=f(Q_{t-1}, Q_{t-2})$ | ANFIS | ۰/۸۴۲ | ۰/۷۰۴ | ۰/۰۸۲ | -۰/۰۳۹ | ۰/۸۲۶ | ۰/۶۹۴ | ۰/۰۹۴ | -۰/۰۴۴ |
| | SVM | ۰/۸۲۱ | ۰/۶۸۷ | ۰/۰۸۳ | -۰/۰۴۳ | ۰/۸۰۵ | ۰/۶۷۴ | ۰/۰۹۷ | -۰/۰۴۸ |



شکل ۳: نمودار بهترین مدل در حالت مدلسازی بر اساس دبی ماهیانه، ایستگاه کاسین

Figure 3: Diagram of the best model in modeling based on monthly discharge, Kasin station

سناریو دوم: تعریف مدل‌ها بر اساس دبی و بارش ماهیانه

در این حالت جهت بررسی تاثیر بارش و دبی ماهیانه در تخمین جریان ورودی به مخزن سد ستارخان از داده‌های ماهیانه بارش و دبی در سد ستارخان و ایستگاه‌های مربوطه استفاده شده است. نتایج حاصله به صورت جدول ۴ ارائه گردیده است. همانطور که از نتایج جدول ۴ مشاهده می‌گردد برای تمامی ایستگاه‌های در نظر گرفته شده مدل $Q=f(p_{t-1}, Q_{t-1})$ با داشتن پارامترهای بارش ماهیانه و دبی ورودی یک ماه گذشته به عنوان پارامترهای ورودی منجر به جوابهای دقیق‌تری گردیده است. همانطور که مشاهده می‌گردد ایستگاه کاسین بیشترین R و DC و کمترین RMSE و MBE را داراست. مطابق با نتایج بدست آمده استفاده از پارامترهای دبی یک ماه و دو ماه گذشته در کنار پارامتر بارش ماهیانه سبب افزایش دقت مدل در تخمین میزان جریان ورودی به مخزن سد گردیده است. همچنین برای تمامی مدل‌های تعریف‌شده، تخمین میزان جریان ورودی بر اساس دبی ماه گذشته در مقایسه با تخمین جریان ورودی به مخزن سد بر اساس دبی دو ماه گذشته منجر به جوابهای دقیق‌تری گردیده است. در بین ایستگاه‌ها مدل برتر در ایستگاه کاسین بهترین نتایج را ارائه داده است. در شکل ۴ نمودار بهترین مدل برای سری داده‌های تست برای مدل برتر ایستگاه کاسین نشان داده شده است.



جدول ۴- نتایج حاصل از تحلیل مدل‌ها در حالت مدلسازی بر اساس دبی و بارش ماهیانه

Table 4- The results of the analysis of the models in modeling based on monthly discharge and precipitation

| مدل | روش | معیارهای ارزیابی | | | | | | | |
|-------------------------|-------|------------------|-------|-------|---------|----------|-------|-------|---------|
| | | آموزش | | | | صحت سنجی | | | |
| | | R | DC | RMSE | MBE | R | DC | RMSE | MBE |
| ایستگاه اورنگ | | | | | | | | | |
| $Q=f(p_{t-1})$ | ANFIS | ۰/۵۹۹ | ۰/۳۵۵ | ۰/۱۲۵ | -۰/۰۰۸۶ | ۰/۴۶۶ | ۰/۲۸۸ | ۰/۱۴۰ | -۰/۰۰۹۳ |
| | SVM | ۰/۵۸۴ | ۰/۳۴۶ | ۰/۱۲۹ | -۰/۰۰۸۹ | ۰/۴۵۵ | ۰/۲۸۱ | ۰/۱۴۱ | -۰/۰۰۹۹ |
| $Q=f(p_{t-1}, Q_{t-1})$ | ANFIS | ۰/۸۵۳ | ۰/۸۰۷ | ۰/۰۷۱ | ۰/۰۰۳۳ | ۰/۸۳۸ | ۰/۷۵۲ | ۰/۰۷۴ | ۰/۰۰۴۶ |
| | SVM | ۰/۸۳۱ | ۰/۷۸۷ | ۰/۰۷۳ | ۰/۰۰۳۷ | ۰/۸۱۸ | ۰/۷۳۴ | ۰/۰۷۶ | ۰/۰۰۴۹ |
| $Q=f(p_{t-2}, Q_{t-2})$ | ANFIS | ۰/۶۲۷ | ۰/۳۹۱ | ۰/۱۲۵ | ۰/۰۰۶۸ | ۰/۴۴۶ | ۰/۲۹۵ | ۰/۱۳۵ | ۰/۰۰۷۹ |
| | SVM | ۰/۶۱۲ | ۰/۳۸۱ | ۰/۱۲۷ | ۰/۰۰۷۱ | ۰/۴۳۵ | ۰/۲۸۸ | ۰/۱۳۹ | ۰/۰۰۸۳ |

ادامه جدول ۴

| ایستگاه کاسین | | | | | | | | | |
|-------------------------|-------|-------|-------|-------|---------|-------|-------|--------|---------|
| $Q=f(p_{t-1})$ | ANFIS | ۰/۶۹۶ | ۰/۴۴۷ | ۰/۱۱۷ | -۰/۰۰۶۶ | ۰/۶۳۴ | ۰/۴۴۳ | ۰/۱۱۹ | -۰/۰۰۷۱ |
| | SVM | ۰/۵۷۹ | ۰/۴۰۱ | ۰/۱۳۸ | -۰/۰۰۷۳ | ۰/۵۱۱ | ۰/۳۳۲ | ۰/۱۳۱ | -۰/۰۰۷۷ |
| $Q=f(p_{t-1}, Q_{t-1})$ | ANFIS | ۰/۸۵۸ | ۰/۷۹۴ | ۰/۰۷۴ | ۰/۰۰۱۵ | ۰/۸۷۸ | ۰/۷۸۲ | ۰/۰۶۳ | ۰/۰۰۲۲ |
| | SVM | ۰/۸۴۴ | ۰/۷۹۱ | ۰/۰۶۹ | ۰/۰۰۱۸ | ۰/۸۰۵ | ۰/۷۷۸ | ۰/۰۷۲ | ۰/۰۰۲۸ |
| $Q=f(p_{t-2}, Q_{t-2})$ | ANFIS | ۰/۷۲۶ | ۰/۶۰۶ | ۰/۰۹۲ | ۰/۰۰۴۹ | ۰/۷۰۴ | ۰/۵۹۰ | ۰/۰۹۴ | ۰/۰۰۵۵ |
| | SVM | ۰/۷۰۱ | ۰/۵۹۸ | ۰/۰۹۱ | ۰/۰۰۵۲ | ۰/۶۹۳ | ۰/۵۸۶ | ۰/۰۹۳۴ | ۰/۰۰۵۹ |
| ایستگاه اورنگ و کاسین | | | | | | | | | |
| $Q=f(p_{t-1})$ | ANFIS | ۰/۶۶۸ | ۰/۴۵۱ | ۰/۱۱۴ | -۰/۰۰۶۶ | ۰/۵۶۲ | ۰/۳۴۳ | ۰/۱۲۰ | -۰/۰۰۷۳ |
| | SVM | ۰/۶۷۹ | ۰/۴۳۶ | ۰/۱۱۸ | -۰/۰۰۶۹ | ۰/۶۱۹ | ۰/۴۳۲ | ۰/۱۲۱ | -۰/۰۰۷۶ |
| $Q=f(p_{t-1}, Q_{t-1})$ | ANFIS | ۰/۸۵۲ | ۰/۸۰۹ | ۰/۰۷۲ | ۰/۰۰۳۹ | ۰/۸۰۳ | ۰/۶۲۳ | ۰/۰۸۸ | ۰/۰۰۵۵ |
| | SVM | ۰/۸۲۹ | ۰/۷۴۵ | ۰/۰۸۱ | ۰/۰۰۴۱ | ۰/۷۹۸ | ۰/۶۲۶ | ۰/۰۸۸ | ۰/۰۰۵۳ |
| $Q=f(p_{t-2}, Q_{t-2})$ | ANFIS | ۰/۷۷۸ | ۰/۶۲۹ | ۰/۰۹۰ | ۰/۰۰۴۸ | ۰/۷۵۳ | ۰/۵۳۳ | ۰/۰۹۶ | ۰/۰۰۶۶ |
| | SVM | ۰/۷۰۸ | ۰/۵۹۱ | ۰/۰۹۳ | ۰/۰۰۵۴ | ۰/۶۸۷ | ۰/۵۷۶ | ۰/۰۹۵ | ۰/۰۰۶۱ |



شکل ۴: نمودار بهترین مدل در حالت مدلسازی بر اساس دبی و بارش ماهیانه، ایستگاه کاسین

Figure 4: Diagram of the best model in modeling based on monthly discharge and precipitation, Kasin station

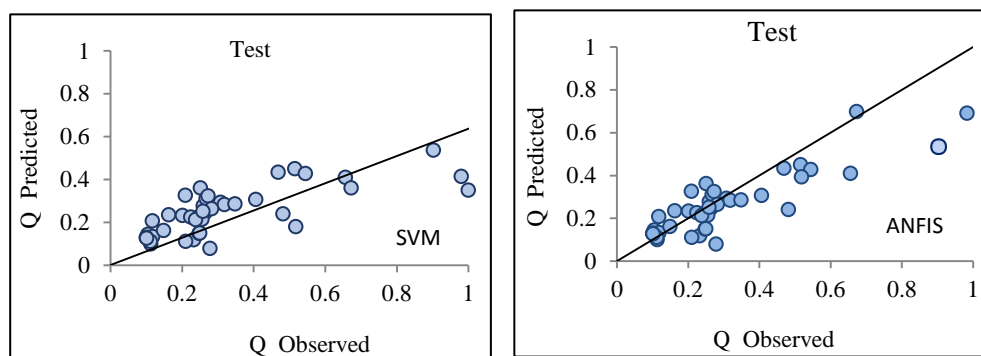
سناریو سوم: تعریف مدل‌ها بر اساس دبی، بارش و دمای ماهیانه

جهت بررسی اثر همزمان بارش، دما و دبی ماهیانه در تخمین میزان دبی ورودی به مخزن سد، مدل‌هایی با در نظر گرفتن داده‌های سد ستارخان تعریف گردید و مورد بررسی قرار گرفت. نتایج حاصله به صورت جدول ۵ و شکل ۵ ارائه گردیده است. نتایج بدست آمده از مدل‌های یک و دو بیان‌گر آن است که اثر دبی ماهیانه نسبت به بارش ماهیانه در افزایش دقت مدل‌ها بیشتر است. همچنین در بین تمامی مدل‌های تعریف شده، مدل با پارامترهای ورودی $Q=f(T_{t-1}, p_{t-1}, Q_{t-1})$ مدل برتر می‌باشد.

جدول ۵- نتایج حاصل از تحلیل مدل‌ها در حالت مدلسازی بر اساس دبی، بارش و دمای ماهیانه

Table 5- The results of the analysis of the models in modeling based on monthly discharge, precipitation and temperature

| مدل | روش | معیارهای ارزیابی | | | | | | | |
|----------------------------------|-------|------------------|-------|-------|--------|----------|-------|-------|--------|
| | | آموزش | | | | صحت سنجی | | | |
| | | R | DC | RMSE | MBE | R | DC | RMSE | MBE |
| سد ستارخان | | | | | | | | | |
| $Q=f(T_{t-1}, p_{t-1})$ | ANFIS | ۰/۵۷۵ | ۰/۴۱۱ | ۰/۱۲۱ | -۰/۰۴۵ | ۰/۵۰۱ | ۰/۳۳۰ | ۰/۱۳۱ | -۰/۱۱۵ |
| | SVM | ۰/۵۷۹ | ۰/۴۰۱ | ۰/۱۳۸ | -۰/۰۴۹ | ۰/۵۱۱ | ۰/۳۳۱ | ۰/۱۳۰ | -۰/۱۲۱ |
| $Q=f(T_{t-1}, Q_{t-1})$ | ANFIS | ۰/۸۲۱ | ۰/۵۹۵ | ۰/۰۹۴ | -۰/۰۲۵ | ۰/۷۰۱ | ۰/۵۸۱ | ۰/۱۱۱ | -۰/۰۳۱ |
| | SVM | ۰/۷۰۱ | ۰/۵۸۸ | ۰/۰۹۸ | -۰/۰۲۹ | ۰/۶۹۳ | ۰/۵۷۶ | ۰/۱۱۶ | -۰/۰۳۶ |
| $Q=f(T_{t-1}, p_{t-1}, Q_{t-1})$ | ANFIS | ۰/۸۴۸ | ۰/۷۵۴ | ۰/۰۸۷ | -۰/۰۱۶ | ۰/۸۵۳ | ۰/۷۱۰ | ۰/۱۰۵ | -۰/۰۷۵ |
| | SVM | ۰/۸۴۴ | ۰/۷۴۱ | ۰/۰۸۹ | -۰/۰۱۸ | ۰/۸۰۵ | ۰/۷۰۸ | ۰/۱۰۸ | -۰/۰۷۹ |



شکل ۵: نمودار بهترین مدل در حالت مدلسازی بر اساس دبی، بارش و دمای ماهیانه

Figure 5: Diagram of the best model in modeling based on monthly discharge, precipitation and temperature

تعیین پارامترهای موثر در مدلسازی دبی ورودی به مخزن سد

با استفاده از آنالیز حساسیت فاکتوریل میزان همبستگی هر کدام از پارامترها بر روی دبی و همچنین تاثیر این پارامترها بر روی هم تعیین شد. نتایج حاصل از تحلیل حساسیت در جدول ۶ آورده شده است. مشاهده می‌گردد که در بین پارامترهای به کار رفته $Q(t-1)$ همبستگی مطلوبی را با Q نشان می‌دهد و همبستگی آن با سایر پارامترها به جز دما به صورت مستقیم می‌باشد. با توجه به نتایج آنالیز حساسیت برای ایستگاه سد ستارخان ملاحظه می‌شود که همبستگی دبی رودی به مخزن سد با پارامتر دما به صورت معکوس است.

جدول ۶- ماتریس همبستگی حاصل از آنالیز فاکتوریل

Table 6- Correlation matrix obtained from factorial analysis

| اورنگ | Q | Q _{t-1} | Q _{t-2} | P _{t-1} |
|------------------|---|------------------|------------------|------------------|
| Q | ۱ | ۰.۶۱۱ | ۰.۴۹۸ | ۰.۳۲۳ |
| Q _{t-1} | | ۱ | ۰.۶۰۱ | ۰.۳۲۹ |
| Q _{t-2} | | | ۱ | -۰.۰۳۸ |
| P _{t-1} | | | | ۱ |

| کاسین | Q | Q _{t-1} | Q _{t-2} | P _{t-1} |
|------------------|---|------------------|------------------|------------------|
| Q | ۱ | ۰.۶۲۱ | ۰.۵۴۸ | ۰.۳۱۹ |
| Q _{t-1} | | ۱ | ۰.۶۱۵ | ۰.۳۷۱ |
| Q _{t-2} | | | ۱ | -۰.۰۲۳ |
| P _{t-1} | | | | ۱ |

| سد ستارخان | Q | Q _{t-1} | T _{t-1} | P _{t-1} |
|------------------|---|------------------|------------------|------------------|
| Q | ۱ | ۰.۵۲۷ | -۰.۳۳۱ | -۰.۲۳۴ |
| Q _{t-1} | | ۱ | -۰.۱۸۵ | ۰.۰۵۲ |
| T _{t-1} | | | ۱ | ۰.۰۱۷۵ |
| P _{t-1} | | | | ۱ |

نتیجه گیری

استفاده مناسب از آب مخازن سدها به عنوان تأمین کننده اصلی آب بخش کشاورزی، شرب و صنعت در پرتو مدیریت و بهره برداری بهینه از این مخازن امکان پذیر است و این خود بدون اطلاع از میزان جریان ورودی به مخازن در دوره های زمانی آتی ممکن نمی باشد. در این تحقیق کارآیی روش های هوش مصنوعی جهت تخمین دبی ماهیانه ورودی به مخزن سد ستارخان تحت سه سناریو مختلف مورد ارزیابی قرار گرفت. در حالت کلی مطابق با نتایج حاصله از مطالعه سایر محققین مشاهده گردید که روش های فرامدل به کار رفته کارایی خوبی را در تخمین دبی ورودی به سد ستارخان دارا می باشند. نتایج کلی حاصل از پژوهش به صورت زیر می باشد:

- جهت بررسی تاثیر دبی ماهیانه (سناریو اول) به عنوان تنها پارامتر ورودی در تخمین میزان جریان ورودی به مخزن سد سه مدل تعریف گردید و مورد بررسی قرار گرفت. نتایج حاصل از تحلیل مدل های این حالت نشان داد مدل $Q=f(Q_{t-1}, Q_{t-2})$ با داشتن پارامترهای دبی ورودی یک ماه و دو ماه گذشته به عنوان پارامتر ورودی بیشترین R و DC و کمترین میزان خطا (MBE, RMSE) را داراست و بهترین مدل می باشد. بهترین نتایج برای داده های آزمون، در حالت مدلسازی بر اساس دبی ماهیانه یا استفاده از روش ANFIS به صورت مقادیر $R=0.826$ ، $DC=0.694$ ، $RMSE=0.094$ و $MBE=0.0044$ بدست آمد. برای تمامی مدل های تعریف شده، تخمین میزان جریان ورودی بر اساس دبی ماه گذشته در مقایسه با تخمین جریان ورودی به مخزن سد بر اساس دبی دو ماه گذشته منجر

به جواب‌های دقیق‌تری گردیده است.

- با بررسی تاثیر بارش و دبی ماهیانه (سناریو دوم) در تخمین جریان ورودی به مخزن سد ستارخان مشاهده گردید که برای تمامی ایستگاه‌های در نظر گرفته شده مدل $Q=f(p_{t-1}, Q_{t-1})$ با داشتن پارامترهای بارش و دبی ورودی یک ماه گذشته به عنوان پارامترهای ورودی منجر به جوابهای دقیق‌تری گردیده است. نتایج حاصله نشان داد که ایستگاه کاسین بیشترین R و DC و کمترین RMSE را داراست. در این حالت بهترین نتایج برای داده‌های آزمون به صورت $MBE=0.0022$ و $RMSE=0.063$ ، $DC=0.782$ ، $R=0.878$ به دست آمد.

همچنین مشاهده گردید که استفاده از پارامترهای دبی یک ماه و دو ماه گذشته در کنار پارامتر بارش ماهیانه سبب افزایش دقت مدل در تخمین میزان جریان ورودی به مخزن سد گردیده است.

- بررسی اثر همزمان بارش، دما و دبی ماهیانه (سناریو سوم) در تخمین میزان دبی ورودی به مخزن سد ستارخان نیز نشان داد که در بین مدل‌ها، مدل با پارامترهای ورودی $Q=f(T_{t-1}, p_{t-1}, Q_{t-1})$ مدل برتر بوده و بهترین نتایج برای داده‌های آزمون یا استفاده از روش ANFIS، به صورت $MBE=-0.079$ ، $DC=0.708$ ، $R=0.805$ و $RMSE=0.108$ می‌باشد. مطابق با نتایج حاصل از آنالیز حساسیت فاکتوریل مشخص گردید که اثر دبی ماهیانه نسبت به بارش و دمای ماهیانه در افزایش دقت مدل بیشتر می‌باشد.

References

- Amini, A., Ebrahimi, H. and Rahnama, M. (2017). "Optimizing the use of dam reservoirs using the genetic algorithm method (Jiroft Dam case study)". *The 6th Iran Hydraulic Conference*. [In Persian].
- Baareh, A.K.M., Sheta, A.F. and Al-khanifes, K. (2006). "Forecasting River Flow in the USA: A Comparison between Auto-Regression and Neural Network Non-Parametric Models". *Journal of Computer Science*, 2(10), 775-780.
- Bani Habib, M., Valipour, A. (2007). "Comparative evaluation of ARMA, ARIMA and self-correlated artificial neural network models in predicting the flow entering the Dez dam reservoir". *The first international conference on the water crisis*. Zabel University, 2p. [In Persian].
- Bermudez, M., Cea, L., Puertas, J., Sopolana, J. and Ruano, S. (2018). "Long-term flood hazard simulation in a coastal river reach based on least squares support vector machine regression". *In AGU Fall Meeting Abstracts*.
- Changchit, C., Terrell, M. P. (1989). "CCGP model for multiobjective reservoir systems." *Journal of Water Resources Planning and Management*, 115(5), 658-670.
- Govindaraju, R.S. (2000). "Artificial neural networks in hydrology. I: preliminary concepts". *Journal of Hydrologic Engineering*, 5(2), 115-123.
- Jang, J. R. (1993). "ANFIS: adaptive network-based fuzzy inference system". *IEEE Transactions on Systems, Man, and Cybernetics*, 23: 665-685.
- Khan, M. S., Coulibaly, P. (2006). "Application of support vector machine in lake water level Prediction". *Journal of Hydraulic Engineering*, 11(3), 199-205.
- Khatai, M. Mirzaei, M. R. (2013). "Comparison of the efficiency of forecasting monthly discharge using artificial neural network and time series methods". *Scientific Journal of Watershed Engineering and Management Research*, 5(2), 74-84. [In Persian].
- Kisi, O., Karahan, M. E., Sen, Z. (2006). "River suspended sediment modeling using fuzzy logic approach". *Hydrological Processes*, 20(20), 4351-4362.
- Lohani, A. K., Goel, N. K., Bhatia, K. S. (2007). "Deriving stage-discharge-sediment concentration relationships using fuzzy logic". *Hydrological Sciences Journal*, 52(4), 793-807.
- Noori, R., A. Khakpour, B. Omidvar and A. Farokhnia. (2010). "Comparison of ANN and principal component analysis-multivariate linear regression models for predicting the river flow based on developed discrepancy ratio statistic". *Expert Systems with Applications*, 37, 5856-5862.
- Parsai, A., Haqi Abi, A.H., Najafian, Sh. (2014). "Simultaneous development of numerical model and artificial intelligence to simulate flow on lateral overflows". *Journal of Water Sciences and Engineering*, 5(12), 7-20. [In Persian].
- Roushangar, K., Ghasempour, R. (2017). "Prediction of non-cohesive sediment transport in circular channels in deposition and limit of deposition states using SVM". *Water Science and Technology: Water Supply*, 17(2), 537-551.
- Sahoo, G. B. and Ray, C. (2006). "Flow forecasting for a Hawaii stream using rating curves and neural networks". *Journal of Hydrology*, 15, 63-80.
- Tawfik, M. (2003). "Linearity versus non-linearity in forecasting Nile River flows". *Advances in Engineering Software*, 34, 515-524.
- Tezcan, U.U., Ates, F., Erginel, N., Ozcan, O., Oduncu, E. (2015). "Adsorption of disperse orange 30 dye onto activated carbon derived from Holm Oak (*Quercus Ilex*) acorns: A 3k factorial design and analysis". *Journal of Environmental Management*, 155, 89-95.
- Vapnik, V. (1995). *The Nature of Statistical Learning Theory*. Data Mining and Knowledge Discovery, Springer Verlag, New York, 47p.
- Water Department of East Azarbaijan Province. (2009). *Technical technical report of the hydrographic and topography operation of the Sattar Khan Dam*. Darya Tarsim Consulting Company, 74p. [In Persian].

- Zahiri, A, Najafzadeh, M. (2018). "Optimized expressions to evaluate the flow discharge in main channels and floodplains using evolutionary computing and model classification". *International journal of river basin management*, 16(1), 123-132.

Comparative Study of Effective Parameters on Monthly Inflow of a Reservoir Dam via Meta Model Approaches

Introduction

Estimating the amount of incoming flow to storage dams is the first and most important step in planning and optimal allocation of water to consumption sources and also hydro-electric energy production (Amini et al., 2007). In order to manage and optimally exploit dam reservoirs, the amount of inflow to them must be accurately predicted. The importance of this issue is more obvious in large basins due to the irrigation of vast agricultural lands and the production of electric energy (Khatai and Mirzaei, 2013). One of the most important goals of predicting the inflow to the reservoirs of dams is to properly and timely deal with the risk of flooding and overflowing of dams and minimizing its damage. Also, one of the important prerequisites in the optimal use of multi-purpose water resource systems, one of the goals of which is to produce electricity, is to know the amount of inflow to the reservoirs of the dams in the coming months. Modeling the flow entering the dam reservoir is a challenging issue. To overcome the existing problems in this field, soft methods can be used to predict the average monthly flow rate entering the dams. Although different hydrological models have been proposed to model runoff parameters, but due to the nonlinear nature and temporal and spatial variable characteristics in the water circulation system, none of the advanced statistical and conceptual models has not been recognized as a superior and capable model, and the uncertainty in the predictions reduces the validity of the estimates made by different models. Among the models, time series models have been used for prediction aims. Also, nowadays nonlinear networks are widely used as one of the intelligent systems in predicting complex phenomena. These methods can be used to predict any variable in which: the relationship between the relevant variables is not well understood, it is difficult to find the size and shape of the final solution, and mathematical analytical methods unable to solve them or they are very time-consuming. These models significantly show smaller errors in prediction than statistical models and have a higher prediction speed (Govindaraju, 2000). Among these methods, artificial neural networks (ANN), genetic programming (GP), support vector machine (SVM) and fuzzy models (NF) can be mentioned.

In this research, using the data related to Sattarkhan dam, the ability and efficiency of SVM and ANFIS methods in estimating the monthly inflow to the dam reservoir under three different scenarios

were investigated. In this regard, different models were defined under three scenarios: based on only the monthly flow rate entering the reservoir, based on monthly flow rate and precipitation, and also based on monthly flow rate, precipitation, and temperature. The effect of different modeling on the estimation of this parameter was evaluated and for each case, the superior model was determined. Also, by using the factorial sensitivity analysis method, the most effective parameters in the modeling process were determined.

Methodology

Intelligence models

Among data driven methods, kernel-based approaches are relatively innovative and important techniques in terms of different kernel functions and the statistical learning theory. Support Vector Machin (SVM) is an important kernel-based method that can adapt itself to estimate any parameter of interest by sufficient inputs. There are different kernel functions that can be used for this aim. The SVM method is found to be the best performing when there are a large number of features and discriminative information is spread across them. The most important parameter used in these models includes the kernel function. The proper selection of the kernel type is often achieved based on trial and error. The RBF kernel leads to better forecasting results compared to the other kernel types in the evaluation of hydrological problems. Also, Adaptive Network-based Fuzzy Inference System (ANFIS) is a powerful tool that can help improve the accuracy of predictions made by AI models. Additionally, ANFIS can help reduce the amount of time needed to train AI models. ANFIS is also effective at handling non-linear data, which is often encountered in real-world applications.

Proposed models and validity evaluation of models

After obtaining the necessary information and data from the SattarKhan dam and the stations close to it (Kasin and Orang) through the regional water company of the province, the input structure of the models was defined based on the parameters of discharge, precipitation and monthly temperature. The proposed models are shown in Table 1. Also, in order to evaluate the effectiveness of the methods used in this research, three evaluation criteria of the model have been used, which are: (R) correlation coefficient, (DC) determination coefficient, (RMSE) root mean square error, and (MBE) mean error deviation.

Table 1- Models defined in the research

| Model | Inputs |
|-------|--------------------|
| M1 | Q_{t-1} |
| M2 | Q_{t-2} |
| M3 | Q_{t-1}, Q_{t-2} |
| M4 | P_{t-1} |
| M5 | P_{t-1}, Q_{t-1} |
| M6 | P_{t-2}, Q_{t-2} |
| M7 | T_{t-1}, p_{t-1} |

| | |
|----|-----------------------------|
| M8 | T_{t-1}, Q_{t-1} |
| M9 | $P_{t-1}, T_{t-1}, Q_{t-1}$ |

Results and discussion

In this research, the monthly inflow to the Sattarkhan dam reservoir was investigated under three different scenarios. In the first scenario, different models were defined based on only the monthly flow rate entering the reservoir. The second scenario was defined based on the simultaneous effect of discharge and monthly precipitation, and the third scenario was defined based on the simultaneous effect of discharge, precipitation, and monthly temperature in estimating the monthly inflow to the dam reservoir, and the effect of different modeling was evaluated. The results obtained from models one and two indicate that the effect of monthly discharge is greater than monthly precipitation in increasing the accuracy of the models. Also, among all defined models, the model with input parameters $Q=f(T_{t-1}, p_{t-1}, Q_{t-1})$ is the best model. Figure 1 shows the best model in modeling based on monthly discharge, precipitation and temperature.

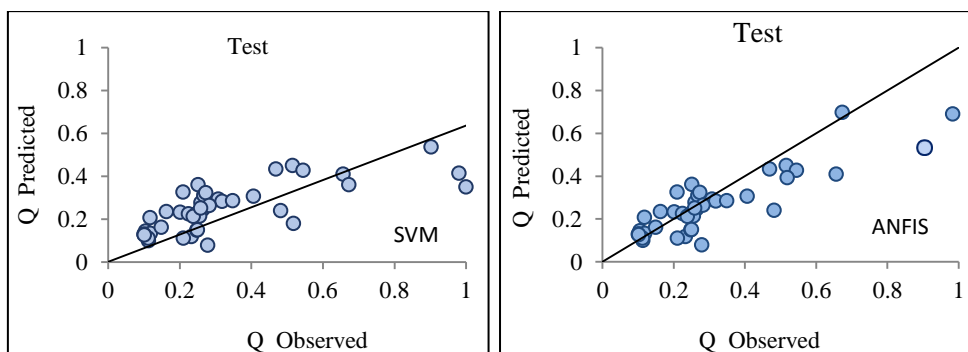


Figure 1- Diagram of the best model in modeling based on monthly discharge, precipitation and temperature

Using factorial sensitivity analysis, the correlation of each of the parameters on the flow rate and the effect of these parameters on each other were determined. The results of the sensitivity analysis are given in Table 2. It can be seen that among the used parameters, $Q(t-1)$ shows a favorable correlation with Q and its correlation with other parameters except temperature is direct. According to the results of the sensitivity analysis for the Sattarkhan dam station, it can be seen that the correlation between the river flow to the dam reservoir and the temperature parameter is inverse.

Table 2- Correlation matrix obtained from factorial analysis

| Orang | Q | Q_{t-1} | Q_{t-2} | P_{t-1} |
|-------|---|-----------|-----------|-----------|
| Q | 1 | 0.611 | 0.498 | 0.323 |

| | | | | |
|------------|---|-----------|-----------|-----------|
| Q_{t-1} | | 1 | 0.601 | 0.329 |
| Q_{t-2} | | | 1 | -0.038 |
| p_{t-1} | | | | 1 |
| Kasin | Q | Q_{t-1} | Q_{t-2} | p_{t-1} |
| Q | 1 | 0.621 | 0.548 | 0.319 |
| Q_{t-1} | | 1 | 0.615 | 0.371 |
| Q_{t-2} | | | 1 | -0.023 |
| p_{t-1} | | | | 1 |
| Sattarkhan | Q | Q_{t-1} | T_{t-1} | p_{t-1} |
| Q | 1 | 0.527 | -0.331 | -0.234 |
| Q_{t-1} | | 1 | -0.185 | 0.052 |
| T_{t-1} | | | 1 | 0.0175 |
| p_{t-1} | | | | 1 |

Conclusion

The results showed the desired efficiency of the Meta model approaches in estimating the monthly inflow into the Sattarkhan dam reservoir. The best results for the test data, in the state of modeling based on monthly discharge and precipitation was obtained the values of $R= 0.878$ $DC= 0.782$, $RMSE= 0.063$ and in the state of modeling based on monthly temperature, precipitation and discharge was obtained the values of $R= 0.805$, $DC= 0.708$ and $RMSE= 0.108$ were obtained. According to the results, the model with the parameters of the monthly discharge and precipitation leads to more accurate results.

References

- Amini, A., Ebrahimi, H. and Rahnama, M. (2017). "Optimizing the use of dam reservoirs using the genetic algorithm method (Jiroft Dam case study)". *The 6th Iran Hydraulic Conference*. [In Persian].
- Khatai, M. Mirzaei, M. R. (2013). "Comparison of the efficiency of forecasting monthly discharge using artificial neural network and time series methods". *Scientific Journal of Watershed Engineering and Management Research*, 5(2), 74-84. [In Persian].
- Govindaraju, R.S. (2000). "Artificial neural networks in hydrology. I: preliminary concepts". *Journal of Hydrologic Engineering*, 5(2), 115-123.