

## کاربرد مدل‌های تلفیق داده در شبیه‌سازی جریان رودخانه با استفاده از سیگنال‌های بزرگ مقیاس اقلیمی، مطالعه موردی: حوزه آبخیز سد جیرفت

نسرین میرزایی<sup>۱</sup> و امیریویا صراف<sup>۲\*</sup>

<sup>۱</sup> دانشجوی کارشناسی‌ارشد مهندسی و مدیریت منابع آب، گروه مهندسی عمران، واحد رودهن، دانشگاه آزاد اسلامی، رودهن، ایران و  
<sup>۲</sup> استادیار گروه مهندسی عمران، واحد رودهن، دانشگاه آزاد اسلامی، رودهن، ایران

تاریخ پذیرش: ۱۳۹۹/۰۷/۲۷

تاریخ دریافت: ۱۳۹۹/۰۴/۱۴

### چکیده

پیش‌بینی آبدهی رودخانه در حوزه‌های آبخیز از جایگاه ویژه‌ای در مدیریت و برنامه‌ریزی منابع آب به‌منظور طراحی تأسیسات آبی، آبخیز از رودخانه‌ها، مدیریت مصرف و مواردی از این قبیل برخوردار است. در پژوهش حاضر، عملکرد برخی از مدل‌های تلفیق داده شامل میانگین‌گیری ساده، میانگین‌گیری وزن‌دار و مدل شبکه عصبی مصنوعی تلفیقی در مدل‌سازی آبدهی ماهانه مورد ارزیابی و مقایسه قرار گرفته است. به همین منظور، ابتدا با استفاده از مدل‌های شبکه عصبی مصنوعی (ANN)، سامانه استنتاج عصبی-فازی تطبیقی (ANFIS)، مدل آریمای (ARIMA) و مدل رگرسیون بردار پشتیبان (SVR) به‌عنوان مدل‌های منفرد، پیش‌بینی آبدهی ماهانه در حوزه آبخیز بالادست سد جیرفت مورد بررسی قرار گرفت. سپس، مدل‌های منفرد با استفاده از متغیرهای پیش‌بینی کننده منتخب، آموزش و صحت‌سنجی شده، نتایج آن‌ها برای استفاده در فرایند تلفیق انتخاب شد. همچنین، از سیگنال‌های بزرگ مقیاس اقلیمی شامل ENSO، PDO و NAO در پیش‌بینی‌های هیدرولوژیک جریان رودخانه استفاده شده، عملکرد مدل‌های منفرد و تلفیقی در دو حالت با در نظر گرفتن این سیگنال‌ها و بدون در نظر گرفتن آن‌ها، بر اساس ارزیابی سه معیاره نش-ساتکلیف (NSE)، ضریب تبیین ( $R^2$ ) و میانگین مربعات خطا (MSE) مورد مقایسه قرار گرفته است. نتایج حاصل از این پژوهش حاکی از آن بود که رویکرد تلفیق داده دقت پیش‌بینی‌ها را تا حد قابل ملاحظه‌ای افزایش می‌دهد. علاوه بر این، مشخص شد که سیگنال‌های بزرگ مقیاس اقلیمی منجر به بهبود نتایج خصوصاً در دوره تست شده است. به‌عنوان مثال، نتایج حاصل از مدل تلفیقی ANN به همراه سیگنال‌های بزرگ مقیاس اقلیمی نشان می‌دهد که این مدل بهترین عملکرد را در میان مدل‌های تلفیق داده دارا می‌باشد. همچنین، معیار NSE نسبت به مدل تلفیقی ANN بدون سیگنال‌های بزرگ مقیاس در دوره آموزش ۰/۰۴ بهبود یافته، خطای MSE به میزان ۰/۰۱ کاهش پیدا کرده است.

**واژه‌های کلیدی:** مدل شبکه عصبی مصنوعی (ANN)، مدل شبکه عصبی-فازی تطبیقی (ANFIS)، مدل رگرسیون بردار پشتیبان (SVR)، مدل سری زمانی ARIMA، ENSO، PDO، NAO

### مقدمه

باعث تشدید بحران آب در بسیاری از کشورهای در حال توسعه شده است. در این میان، کشوری مانند ایران که سرزمین خشکی است و نزولات جوی آن از

امروزه مسائلی همچون افزایش مصرف، آلودگی آب‌ها و عدم برنامه‌ریزی و مدیریت صحیح منابع آب،

\* مسئول مکاتبات: sarraf@riau.ac.ir

دو مدل ماشین یادگیری پیشینه (ELM) و شبکه عصبی مصنوعی (ANN) و همچنین، تلفیق آن دو مدل با الگوریتم تبدیل موجک W-ELM و W-ANN در آبخوان دشت ارومیه و در نهایت، برای بالابردن قدرت پیش‌بینی و بهینه کردن اوزان ورودی مدل‌ها، از الگوریتم بهینه‌ساز ازدحام ذرات کوانتومی (QPSO) پرداختند و نتایج حاکی از آن بود که مدل هیبرید تبدیل موجک ماشین یادگیری پیشینه-بهینه‌ساز ازدحام ذرات کوانتومی W-ELM-QPSO عملکرد مناسب‌تری از نظر سرعت آموزش، آزمون و دقت نسبت به سایر مدل‌های منفرد به کار گرفته شده در پیش‌بینی تراز آبخوان دشت ارومیه داشته‌اند.

از آنجا که معمولاً مدل‌های پیش‌بینی هیدرولوژیکی مختلف، هر یک در جنبه‌ای نسبت به دیگر مدل‌ها برتری دارند، با تلفیق نتایج آن‌ها و تدوین یک مدل تلفیقی می‌توان پیش‌بینی بهتری داشت (Azmi و همکاران، ۲۰۱۰).

تا کنون، روابط و الگوهای گوناگون و پیچیده‌ای برای پیش‌بینی میزان آبدهی رودخانه‌ها، مانند انواع الگوهای مفهومی بارش-رواناب، الگوهای سری زمانی و الگوهای هیبریدی و روش‌های مختلف نظیر شبکه عصبی مصنوعی، منطق فازی، برنامه‌ریزی ژنتیک و غیره ارائه شده است (Shamseldin و O'Connor، ۲۰۰۷). تحقیقات اخیر نشان داده است که استفاده از رویکرد تلفیق داده نتایج بهتری در پیش‌بینی هیدرولوژیکی، نسبت به مدل‌های منفرد پیش‌بینی ارائه می‌کند. یکی از روش‌های پیش‌بینی متغیرهای هیدرولوژیکی استفاده از سیگنال‌های بزرگ‌مقیاس اقلیمی است. سیگنال به پدیده‌های بزرگ‌مقیاسی گفته می‌شود که تغییرات اقلیمی جهان و چرخه جو را تحت تاثیر قرار می‌دهند. پدیده‌هایی نظیر ENSO، NAO، AMO، PDO، SLP و SST از سیگنال‌های بزرگ‌مقیاس شناخته شده هستند. این سیگنال‌ها نمی‌توانند به تنهایی به‌عنوان پیش‌بینی کننده استفاده شوند و به همین دلیل، روش‌هایی نظیر تلفیق داده برای کار با آن‌ها ضروری است (Barlow و Cullen، ۲۰۰۲). در ادامه، به معرفی برخی از پژوهش‌های گذشته در زمینه پیش‌بینی جریان با استفاده از روش‌های تلفیق داده و بهره‌گیری از سیگنال‌های

یک سوم متوسط نزولات جهان کمتر است، در تنش آبی به سر می‌برد و هر ساله بر شدت آن افزوده می‌شود. در برنامه‌ریزی و مدیریت منابع آب، تعیین میزان تقاضای آب به راحتی قابل محاسبه می‌باشد، اما آنچه که محاسبه آن دشوار بوده، دارای عدم قطعیت بالاست، میزان جریان پیش‌بینی شده یک رودخانه در حوزه‌های آبخیز در دوره‌های آینده است. به عبارت بهتر، پیش‌بینی دقیق جریان و تغییرات آن در طول رودخانه در یک بازه زمانی در آینده، از ارکان اساسی برنامه‌ریزی و مدیریت منابع آب‌های سطحی به‌شمار رفته و نقش مهمی در ارتقای مدل‌های بهره‌برداری از مخازن و کنترل سیلاب به‌همراه دارد (Shahbazi و همکاران، ۲۰۱۴)، چرا که با استفاده از آن می‌توان خسارت ناشی از خشکسالی و سیل‌ها را تا حد قابل توجهی کاهش داد. بنابراین، پیش‌بینی هرچه دقیق‌تر مقدار آورد یک رودخانه به دلیل اهمیت در برنامه‌ریزی و مدیریت منابع آب، لزوم استفاده از ابزارها و روش‌های نوین در مدل‌سازی‌ها را ضروری می‌نماید (Shafaei و همکاران، ۲۰۱۴). روش‌های مختلفی برای پیش‌بینی جریان رودخانه ابداع شده است که به‌طور کلی می‌توان آن‌ها را به دو دسته مدل‌های مفهومی و مدل‌های مبتنی بر داده‌های آماری طبقه‌بندی کرد. در استفاده از این مدل‌ها انتخاب ورودی‌ها بسیار حائز اهمیت است. علاوه بر این، در دهه‌های اخیر، استفاده از سیگنال‌های بزرگ‌مقیاس اقلیمی به‌عنوان پیش‌بینی کننده‌ها، تحول عظیمی را در پیش‌بینی آورد جریان به‌وجود آورده است (Abrishamchi و همکاران، ۲۰۱۳). اگرچه کاربردهای زیادی از این مدل‌ها در مهندسی هیدرولوژی وجود دارد، اما به‌کارگیری مستقیم آن‌ها به‌عنوان مدل‌های پیش‌بینی بلندمدت به‌ندرت مورد بررسی قرار گرفته است. از سال ۱۹۹۰، استفاده از مفاهیم تلفیق داده، افق جدیدی را پیش روی محققان هیدرولوژی گشوده است. تلفیق داده، فرایند ترکیب کردن اطلاعاتی است که از طرق مختلف به‌دست می‌آیند، به‌گونه‌ای که از این عمل، جواب‌هایی دقیق‌تر و قابل اعتمادتر از حالتی که اطلاعات از یک منبع به‌دست می‌آیند، حاصل شوند. Afkhamifar و همکاران (۲۰۲۰) در حوزه علوم پیش‌بینی در مطالعات منابع آبی، به ارزیابی عملکرد

روش‌های تلفیق داده و سیگنال‌های بزرگ‌مقیاس اقلیمی به‌منظور پیش‌بینی جریان استفاده شده است. همچنین، در بحث مدل‌سازی از تلفیق مدل‌های سری زمانی (آریما) و مدل‌های جعبه سیاه (شبکه عصبی، انفیس و رگرسیون بردار پشتیبان، مدل موجک-شبکه عصبی) استفاده شده است و همین موضوع نوآوری مقاله حاضر را نشان می‌دهد.

با توجه به مطالب مذکور، می‌توان گفت که هدف از انجام پژوهش حاضر، ارزیابی کارایی برخی از مهمترین رویکردهای تلفیق داده در بهبود نتایج مدل‌های شبیه‌سازی به‌منظور پیش‌بینی متغیرهای هیدرولوژیکی مانند جریان بلندمدت آورد است. برای این منظور، با استفاده از مدل‌های داده‌محور، اقدام به پیش‌بینی جریان با استفاده از مدل‌های منفرد و تلفیقی شده است. لازم به ذکر است که منظور از مدل منفرد، یکی از مدل‌های سری زمانی یا داده‌محور است که به‌صورت انفرادی واسنجی و اجرا می‌شود. همچنین، منظور از مدل تلفیقی، تلفیق نتایج مدل‌های منفرد به روش‌های ریاضی و یا استفاده از یک مدل منفرد دیگر است. علاوه بر این، در مقاله حاضر تلاش شده است تا اثر استفاده از سیگنال‌های بزرگ‌مقیاس اقلیمی و ترکیب آن با مدل‌های منفرد و تلفیقی در پیش‌بینی بلندمدت جریان مورد بررسی قرار بگیرد.

### مواد و روش‌ها

حوزه آبخیز سد جیرفت در جنوب شرقی استان کرمان با موقعیت جغرافیایی  $21^{\circ} 43'$  تا  $13^{\circ} 43'$  طول شرقی و  $23^{\circ} 24'$  تا  $42^{\circ} 11'$  عرض شمالی با مساحت ۱۳۱۸۱۸ کیلومتر مربع واقع شده است. در این حوضه، رودخانه هلیل‌رود حوزه آبخیز جازموریان جریان دارد. این رودخانه از دامنه‌های جنوبی کوه‌های الله‌زار و بیدخان سرچشمه می‌گیرد و پس از عبور از چند شهر و روستا وارد چاله جازموریان می‌شود. رودخانه هلیل‌رود با طول ۳۹۰ کیلومتر تنها رودخانه دائمی استان کرمان است. مساحت حوزه آبخیز این رودخانه ۸۴۵۰ کیلومتر مربع و دبی متوسط آن ۱۳/۵ متر مکعب در ثانیه است. بر روی رود هلیل در سال ۱۳۷۰ سد جیرفت به‌منظور ذخیره آب کشاورزی، تأمین آب و جلوگیری از خسارت طغیان‌های شدید

بزرگ‌مقیاس پرداخته شده است. Wang و همکاران (۲۰۰۵) از چهار روش تلفیقی شامل میانگین‌گیری ساده، میانگین وزن‌دار با وزن‌های به‌روز شونده<sup>۱</sup> و میانگین وزن‌دار با وزن‌های نیمه ثابت<sup>۲</sup> به‌منظور تلفیق نتایج مدل‌های آرما و شبکه عصبی بهره بردند. Fenicia و همکاران (۲۰۰۷) رویکرد وزن‌دهی فازی را برای تلفیق نتایج دو مدل مفهومی به‌منظور شبیه‌سازی دبی رودخانه آلتزه<sup>۳</sup> در لوگزامبورگ ارائه کردند. Araghinejad و همکاران (۲۰۱۱) یک روش احتمالاتی بر اساس نزدیک‌ترین همسایگی را به‌منظور تلفیق شبکه‌های عصبی ارائه کردند. Najafi و همکاران (۲۰۱۵) مجموعه جامعی از روش‌های میانگین‌گیری تلفیق داده با شرایط و پیچیدگی‌های متفاوت را در چهار حوزه آبخیز در غرب ایالات متحده مورد ارزیابی قرار دادند. تا کنون، مطالعات مختلفی در ارتباط با همبستگی مقادیر سیگنال‌ها با بارندگی صورت گرفته که در ادامه به بررسی برخی از این مطالعات پرداخته شده است. Sveinsson و همکاران (۲۰۰۸) عملکرد سیگنال‌های بزرگ‌مقیاس در مدل‌های مختلف پیش‌بینی آورد را مورد ارزیابی قرار داده و به این نتیجه رسیدند که به‌کارگیری این سیگنال‌ها دقت پیش‌بینی را افزایش می‌دهد. Abrishamchi و همکاران (۲۰۱۳) با استفاده از سیگنال‌های NAO، PDO و SOI آورد سد دز را پیش‌بینی کردند. با توجه به مطالعات فوق، می‌توان دریافت استفاده از مفاهیم تلفیق داده، نتایج بهتری نسبت به مدل‌های منفرد به‌همراه داشته است. اگرچه تا کنون، مدل‌های بسیاری مانند ANN و ANFIS برای پیش‌بینی جریان رودخانه‌ها استفاده شده‌اند، اما در کمتر پژوهشی، از روش‌های تلفیق داده برای این منظور بهره گرفته شده است. در ایران نیز مانند سایر نقاط جهان، مطالعات بسیاری درخصوص این سیگنال‌ها انجام شده است، اما در هیچ‌یک از مقالات، اثر همزمان این سیگنال‌ها در نظر گرفته نشده است. از همین رو، در این پژوهش، به‌صورت همزمان از

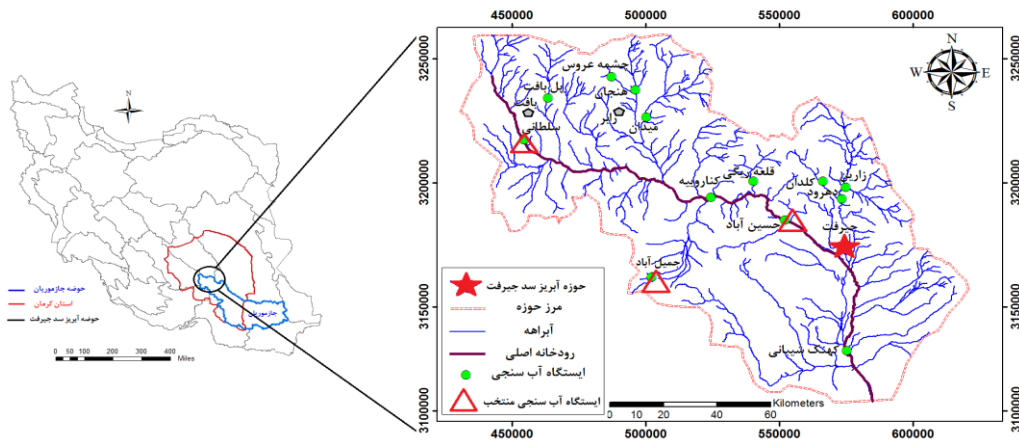
<sup>1</sup> Rollingly updated weighted average

<sup>2</sup> Semi-fixed weighted average

<sup>3</sup> Alzette

مورد بررسی در این پژوهش را نشان می‌دهد.

رود و همچنین، برای تولید انرژی برق آبی احداث شد. شکل ۱، موقعیت جغرافیایی حوضه و ایستگاه‌های



شکل ۱- موقعیت جغرافیایی حوزه آبخیز سد جیرفت و ایستگاه‌های هیدرومتری مورد مطالعه در آن

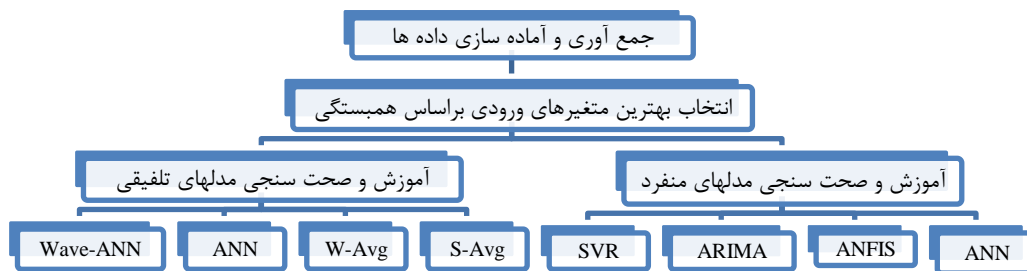
آن بهترین متغیرهای پیش‌بینی کننده و اطلاعات مورد نیاز برای پیش‌بینی جریان، با توجه به اطلاعات در دسترس از ایستگاه‌های سلطانی، حسین‌آباد و جمیل‌آباد در حوزه مطالعاتی اخذ شد. لازم به ذکر است که برای این منظور از داده‌های سال ۴۷-۱۳۴۶ تا سال ۹۴-۱۳۹۵ بهره گرفته شد.

آماده‌سازی داده‌ها: در تجزیه و تحلیل داده‌های هیدرولوژیکی ابتدا داده‌های پرت (Outlier) را حذف کرده، سپس، با استفاده از رابطه (۱) اقدام به نرمال‌سازی سری‌های زمانی می‌شود.

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

که در آن،  $x$  مقادیر واقعی سری زمانی،  $x_{max}$  بیشینه مقدار متغیر،  $x_{min}$  کمینه مقدار متغیر و  $z_i$  مقادیر نرمالیزه شده متغیر نام بین صفر و ۱ است.

جمع‌آوری داده‌ها: در این پژوهش، ابتدا داده‌های هیدرولوژیکی مربوط به حوزه آبخیز جمع‌آوری و آماده‌سازی شده و سپس، از میان متغیرهای موجود، از مقادیر ضریب همبستگی متقابل بهره گرفته شده است. پس از تعیین متغیرهای پیش‌بینی‌کننده، مدل‌های منفرد پیش‌بینی آورد رودخانه اجرا شده است. سپس، در مدل تلفیق داده، اقدام به ترکیب نتایج مدل‌های منفرد شده است. در این مرحله، از سیگنال‌های بزرگ‌مقیاس اقلیمی نیز به‌منظور بهبود نتایج استفاده شد. شکل ۲، نمودار کلی متدولوژی جمع‌آوری داده‌ها، مشخص شد که سری‌های زمانی حاصل از داده‌های هیدرولوژیکی در ایستگاه مورد مطالعه با نقص آماری در برخی سال‌ها مواجه است. از این‌رو، به‌منظور ترمیم آمار داده‌های ایستگاه مورد مطالعه از ایستگاه‌های اطراف آن استفاده شد، پس از



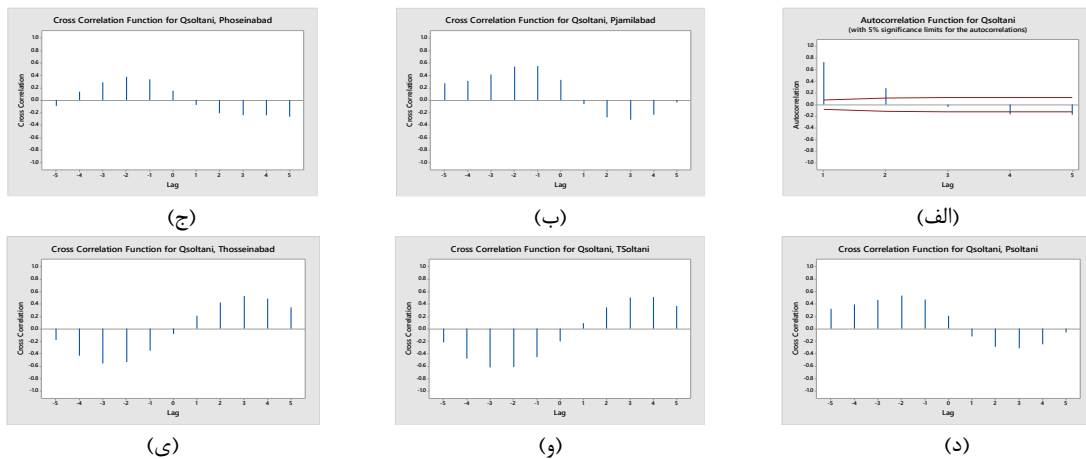
شکل ۲- نمودار کلی متدولوژی پژوهش

مطابق جدول ۲ شد. ورودی‌های کاندید شامل میانگین دما، بارش و جریان دوره‌های قبل در نظر گرفته شده است. شکل ۳، همبستگی ورودی‌های کاندید را با جریان ایستگاه سلطانی نشان می‌دهد.

**انتخاب ورودی‌های مدل:** در پژوهش حاضر، با انجام آزمون و خطا، اقدام به انتخاب ورودی‌ها شد. ابتدا، مطابق جدول ۱، همبستگی بین جریان و کاندیدهای ورودی تعیین شده و سپس، اقدام به ساخت مدل

جدول ۱- مقادیر همبستگی متقابل متغیرهای حوزه آبخیز کرمان

تاخیر ماهانه	ورودی	بارش P		دما T	
	ایستگاه سلطانی	ایستگاه سلطانی	ایستگاه حسین‌آباد	ایستگاه سلطانی	ایستگاه حسین‌آباد
t	۱/۰۰۰	۰/۳۲۳	۰/۱۵۶	-۰/۱۹۹	-۰/۱۷۹
t-۱	۰/۷۳۸	۰/۵۵۳	۰/۳۳۸	-۰/۴۵۳	-۰/۳۵۵
t-۲	۰/۲۸۵	۰/۵۴۹	۰/۳۷۶	-۰/۶۱۱	-۰/۵۳۲
t-۳	۰/۱۰۷	۰/۴۱۲	۰/۲۸۶	-۰/۶۱۷	-۰/۵۶۰
t-۴	-۰/۱۵۸	۰/۳۰۸	۰/۱۴۰	-۰/۴۸۲	-۰/۴۳۴



شکل ۳- همبستگی جریان سلطانی با جریان‌های (الف) سلطانی، (ب) بارش جمیل‌آباد، (ج) بارش حسین‌آباد، (د) بارش سلطانی، (و) دمای سلطانی و (و) دمای حسین‌آباد

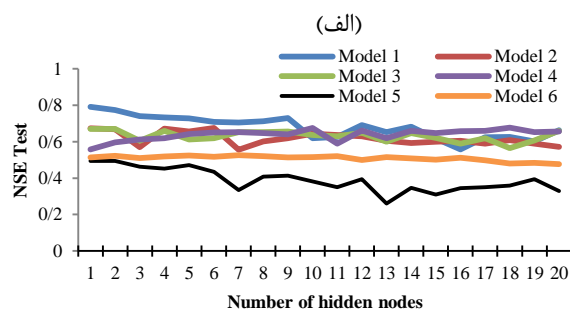

جدول ۲- ترکیب‌های مختلف برای انتخاب بهترین ترکیب ورودی‌ها

مدل	ساختارهای ورودی-خروجی
۱	$\hat{Q}_t = ((Pj)_{t-2}, (Psl)_{t-2}, (Phs)_{t-2}, (Tsl)_{t-2}, (Tsl)_{t-3}, (Ths)_{t-2}, (Ths)_{t-3})(Q_{t-1})$
۲	$\hat{Q}_t = ((Pj)_{t-2}, (Psl)_{t-2}, (Phs)_{t-2}, (Tsl)_{t-3}, (Ths)_{t-3})(Q_{t-1})$
۳	$\hat{Q}_t = ((Tsl)_{t-3}, (Ths)_{t-3})(Q_{t-1})$
۴	$\hat{Q}_t = ((Pj)_{t-2}, (Psl)_{t-2}, (Phs)_{t-2}, (Q_{t-1}))$
۵	$\hat{Q}_t = f((Q_{t-1}))$

به‌دست آمده از مدل،  $Q_t^f$  جریان مشاهداتی و  $\bar{Q}_0$  و  $\bar{Q}_p$  نیز میانگین جریان مشاهداتی و پیش‌بینی شده هستند. مقدار شاخص NSE بین مقدار  $-\infty$  تا یک متغیر است.  $NSE=1$  نشان‌دهنده دقت کامل و برابر بودن مقادیر مشاهداتی و محاسباتی است. در حالت  $0 < NSE < 1$  می‌توان به‌جای مقادیر پیش‌بینی شده از

**معیارهای ارزیابی نتایج:** در این مطالعه، برای تعیین دقت مدل‌ها در پیش‌بینی جریان، از سه معیار ارزیابی نش-سانکلیف (NSE) و میانگین مربعات خطا (MSE) و ضریب همبستگی یا تبیین ( $R^2$ ) به‌ترتیب طبق روابط (۲)، (۳) و (۴) استفاده شده است (Donyaii و همکاران، ۲۰۲۰ a, b). در روابط فوق،  $Q_p^f$  جریان

همکاران، ۲۰۱۱). تنظیم وزن‌ها و بایاس‌ها از طریق الگوریتم پس انتشار خطا<sup>۱</sup> (BP) انجام می‌شود. عملیات آموزش تا جایی ادامه پیدا می‌کند که شبکه، برای هر ورودی خاص، خروجی مطلوب را به دست آورد. رفتار و پیش‌بینی‌های شبکه عصبی به عواملی چون نوع تابع انتقال، تعداد نرون‌های لایه پنهان، وزن‌ها و بایاس‌ها بستگی دارد. در مدل ANN تابع انتقال لایه پنهان و لایه آخر به ترتیب لگاریتم سیگموئید و خطی هستند. شکل ۴، معیار NSE مدل‌های ANN با میانگین ۲۰ اجرای مختلف را نشان می‌دهد. بر اساس میانگین‌نش، دوره آموزش و آزمون مدل ۱ با بیشینه مقدار NSE انتخاب شده است. همچنین، تعداد بهینه نرون‌های لایه پنهان بر اساس بیشینه معیار NSE دوره تست در این مدل برابر نه به-دست آمده است.



شکل ۴- میانگین معیار NSE برای ANN‌های مختلف با نرون-های لایه پنهان، الف) دوره آموزش و ب) دوره تست

#### سامانه استنتاج عصبی تطبیقی فازی (ANFIS):

سامانه ANFIS از ترکیب دو ساختار شبکه‌های عصبی و سامانه‌های فازی تشکیل شده و از مزایای هر دو ساختار برخوردار است. Jang و همکاران در سال

میانگین داده‌ها استفاده کرد و مقادیر منفی NSE نیز نشانگر کم بودن دقت نتایج می‌باشد. از سوی دیگر، در معیار MSE هرچه مقدار آن کمتر باشد، مطلوبیت داده‌ها بیشتر است. معیار  $R^2$  میزان اطمینان به پیش‌بینی یک مدل را نشان می‌دهد. به نحوی که هرچه مقدار  $R^2$  به یک نزدیک‌تر باشد، مطلوبیت نتایج بیشتر است. از آنجایی که بالا و پایین بودن MSE لزوماً نشان‌دهنده مناسب بودن صحت یک مدل نیست و بایستی علاوه بر  $R^2$ ، نرمال بودن داده‌ها یا باقی‌مانده‌ها، ثابت بودن واریانس در سطوح مختلف، استقلال داده‌ها نسبت به زمان و اریب نبودن مشاهدات برای صحت مدل برازش شده مورد ارزیابی قرار بگیرد، لذا، در این پژوهش از معیار NSE نیز استفاده شده است.

$$NSE = 1 - \frac{\sum_{t=1}^T (Q_o^t - Q_p^t)^2}{\sum_{t=1}^T (Q_o^t - \bar{Q}_o)^2} \quad (2)$$

$$MSE = \sum_{t=1}^T (Q_o^t - Q_p^t)^2 \quad (3)$$

$$R^2 = \frac{l \sum_{t=1}^T (Q_o^t - \bar{Q}_o)(Q_p^t - \bar{Q}_p)}{\sum_{t=1}^T (Q_o^t - \bar{Q}_o)^2 (Q_p^t - \bar{Q}_p)^2} \quad (4)$$

#### مدل‌های منفرد

مدل شبکه عصبی مصنوعی (ANN): شبکه‌های عصبی ابزارهای محاسباتی شبیه‌سازی شده از مغز انسان هستند. این شبکه‌ها از واحدهای پردازنده به نام نرون تشکیل می‌شوند. یک نرون مصنوعی ورودی‌های خام را دریافت و با اعمال عملگرهای ریاضی بر روی آن‌ها، خروجی‌های سامانه را تولید می‌کند. نوع این شبکه‌ها که در پیش‌بینی‌ها و حل مسائل غیرخطی هیدرولوژی کاربرد دارند، شبکه‌های موسوم به پرسپترون چندلایه هستند. در لایه پنهان هر نرون از ترکیب وزن‌دار ورودی‌ها به دست آمده و از یک تابع انتقال (مانند تابع سیگموئید) عبور کرده و وارد لایه خروجی می‌شود. در لایه خروجی نیز مانند لایه پنهان از یک تابع انتقال استفاده می‌شود که معمولاً تابع انتقال نرون‌های این لایه خطی است (Yoon و


<sup>1</sup> Back Propagation of error

شامل آورد با یک گام زمانی تأخیر، دمای متوسط و بارش متوسط دو مجموعه فازی در نظر گرفته شده، در نهایت، ساختار مدل به صورت شکل ۵ است. با توجه به بالا رفتن حجم محاسبات در توابع با درجه توان بالاتر از تابع انتقال trapmf و برای آموزش شبکه از روش هیبرید استفاده شد که در آن در لایه اول از روش پس‌انتشار خطا و در لایه چهارم از روش تخمین کمترین مربعات خطا استفاده می‌شود.

۱۹۹۷، مدل ANFIS را که قابلیت ترکیب دو روش یاد شده را دارد، ارائه کردند. یکی از مهمترین عوامل در ساختار ANFIS، نوع توابع عضویت است. ساختار ANFIS از پنج لایه با تعدادی متغیر ورودی تشکیل شده که هر ورودی دو یا چند تابع عضویت دارد. در مدل ANFIS، به منظور بالا بردن دقت نتایج و کاهش حجم محاسبات از میانگین ایستگاه‌های مختلف استفاده شده است. برای متغیرهای پیش‌بینی‌کننده

جدول ۳- نتایج تغییر تابع عضویت براساس معیار MSE

MF	کرمان		MF	کرمان	
	آموزش	آزمون		آموزش	آزمون
trimf	۰/۰۲۷۷	۰/۰۲۱۹	pimf	۰/۰۲۴۹	۰/۰۲۳۳
trapmf	۰/۰۲۷۷	۰/۰۲۲۰	dsigmf	۰/۰۲۷۴	۰/۰۲۶۶
gbellmf	۰/۰۲۸۲	۰/۰۲۴۴	psigmf	۰/۰۲۸۸	۰/۰۲۷۹
gaussmf	۰/۰۲۷۳	۰/۰۲۵۵	zmf	۰/۰۲۹۷	۰/۰۲۶۹
gauss2mf	۰/۰۲۳۹	۰/۰۲۴۴			



شکل ۵- ساختار مدل ANFIS در پیش‌بینی جریان

زمانی دارای میانگین ثابت (ایستا) نباشد، ولی تفاضل آن ایستا باشد، می‌توان با استفاده از عملگر تفاضل آن سری زمانی را ایستا کرد. این تفاضل‌گیری تا مرحله dam می‌تواند ادامه یابد و مدل‌سازی آن با مدل آرما منجر به پیدایش مدل آرما<sup>۴</sup> غیر فصلی ARIMA (p,d,q) می‌شود که در آن p مرتبه اتورگرسیو، d مرتبه تفاضل‌گیری و q مرتبه میانگین متحرک مدل هستند. در صورتی‌که از عملگر تفاضل فصلی با تأخیر  $\omega$  استفاده شود، مدل فصلی ARIMA(P,D,Q) $\omega$  به وجود می‌آید. ترکیب این مدل‌ها، مدل‌های آرما مکرر<sup>۵</sup> ARIMA (p,d,q)(P,D,Q) $\omega$  را به وجود می‌آورند.

مدل آرما (ARIMA): از اوایل دهه ۶۰ میلادی به بعد، مدل‌های خودهمبسته<sup>۱</sup> (AR) استفاده گسترده‌ای در مهندسی هیدرولوژی و منابع آب پیدا کرده‌اند. اساس این مدل‌ها زنجیره مارکوف است و یکی از فرضیات اصلی در این مدل‌ها نرمال بودن سری زمانی است. یکی از مشکلات در مدل‌سازی سری‌های زمانی هیدرولوژیک، تغییرات سری زمانی در شرایط خاص است. به منظور رفع این مشکل بخش میانگین متحرک<sup>۲</sup> (MA) به مدل اتورگرسیو اضافه شده و مدل متحرک<sup>۳</sup> (ARMA) ارائه شده است. اگر یک سری

<sup>۴</sup> Auto Regressive Integrated Moving Average

<sup>۵</sup> Multiplicative ARIMA

<sup>۱</sup> Auto Regressive

<sup>۲</sup> Moving Average

<sup>۳</sup> Auto Regressive Moving Average

همچنین، اگر سری تفاضل‌گیری شده حاصل از سری زمانی  $x_t$  را با  $u_t$  نشان داده شود، در این حالت مدل ARIMA به صورت رابطه (۵) خواهد بود (همکاران، ۲۰۰۸).

همچنین، اگر سری تفاضل‌گیری شده حاصل از سری زمانی  $x_t$  را با  $u_t$  نشان داده شود، در این حالت مدل ARIMA به صورت رابطه (۵) خواهد بود (همکاران، ۲۰۰۸).

$$u_t = \sum_{i=1}^p \phi_i u_{t-i} + \varepsilon_t - \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (5)$$

که در آن،  $u$  سری حاصل از تفاضل  $d$ ام سری اصلی،  $\varepsilon_t$  متغیر تصادفی،  $\theta$  پارامتر مدل میانگین متحرک و  $\phi$  پارامتر مدل اتورگرسیون می‌باشد. در حالت کلی، مدل‌های غیرفصلی ARIMA(p,d,q) را می‌توان به صورت رابطه (۶) نیز نشان داد.

$$\phi(B)(1-B)^d Z_t = \theta(B)\varepsilon_t \quad (6)$$


برای مدل‌سازی سری‌های زمانی فصلی در کنار سری‌های زمانی غیرفصلی مدل آریما مکرر

رابطه (۷) تعریف می‌شود.


$$(1 - \Phi_1 B^\omega - \Phi_2 B^{2\omega} - \dots - \Phi_p B^{p\omega}) (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) (1 - B)^\omega \quad (7)$$

$$(1 - B)^D z_t = (1 - \Theta_1 B^\omega - \Theta_2 B^{2\omega} - \dots - \Theta_q B^{q\omega}) (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \varepsilon_t$$


که در آن،  $p$  مرتبه مدل خودهمبسته غیرفصلی،  $q$  مرتبه مدل میانگین متحرک غیرفصلی،  $P$  مرتبه مدل خودهمبسته فصلی،  $Q$  مرتبه مدل میانگین متحرک فصلی،  $\phi$  پارامتر مدل خودهمبسته غیرفصلی،  $\theta$  پارامتر مدل میانگین متحرک غیرفصلی،  $\Phi$  پارامتر مدل میانگین متحرک فصلی،  $\Theta$  پارامتر مدل میانگین متحرک فصلی و  $B$  عملگر تفاضل به صورت  $B(z_t) = z_t - 1$  است.




(ب)



(الف)



(د)



(ج)

شکل ۶- مدل ARIMA در پیش‌بینی ماهانه آورد، الف) سری زمانی آورد، ب) نمودار خودهمبستگی جزئی، ج) نمودار خودهمبستگی تفاضل‌گیری شده و د) نمودار خودهمبستگی باقی‌مانده‌ها

بر اساس نمودارها ترم دوره‌ای در سری زمانی دیده می‌شود و نیاز به تفاضل‌گیری و برازش مدل آریما فصلی وجود دارد، چرا که نمودار تابع خودهمبستگی شکل سینوسی دارد. با تفاضل‌گیری فصلی، نمودار تابع خودهمبستگی به صورت شکل ۶-ج تغییر می‌یابد. با توجه به این نمودار می‌توان حدس زد، مرتبه اتورگرسیون فصلی، یک بوده، مرتبه اتورگرسیون غیرفصلی می‌تواند یک یا دو باشد. با سعی و خطا مدل

به‌عنوان مدل مناسب برگزیده شد. در جدول ۴، مقادیر پارامترهای به‌دست آمده برای ضرایب مدل ARIMA ارائه شده است. بعد از تأیید مدل، از آن برای پیش‌بینی‌های یک گامه جریان استفاده شده است. بدین‌منظور، از ۸۰ درصد داده‌ها برای محاسبه ضرایب مدل و از ۲۰ درصد داده‌ها برای دوره پیش‌بینی استفاده شد.



جدول ۴- ضرایب محاسبه شده در مدل ARIMA در پیش‌بینی ماهانه آورد

تخمین نهایی پارامترها در مدل ARIMA					
نوع	ضریب	SE ضریب	نوع	ضریب	SE ضریب
AR ۱	۰/۷۶۸۹	۰/۲۰۳۴	MA ۱	-۰/۰۳۸۴	۰/۲۰۶۵
AR ۲	-۰/۱۷۸۵	۰/۱۴۰۳	SMA ۱۲	۰/۸۱۸۹	۰/۰۵۱۹
SAR ۱۲	۰/۱۳۶۳	۰/۰۷۰۲	ثابت	۰/۰۰۰۳	۰/۰۰۰۷
SAR ۲۴	۰/۱۳۸۰	۰/۰۵۸۵			

استفاده از کرنل چند جمله‌ای اجرا شد. نوع تابع کرنل و پارامترهای آن با استفاده از سعی و خطا مطابق جدول ۵ تعیین شد.

جدول ۵- مقادیر پارامترهای مدل رگرسیون بردار پشتیبان

پارامترهای مدل SVR			
پارامتر	پارامتر کرنل ( $\gamma$ )	ضریب ثابت (C)	خطای مجاز ( $\epsilon$ )
مقدار	۰/۵۱	۳۵۰	۰/۰۰۱

#### مدل‌های تلفیقی:

**میانگین‌گیری ساده:** این روش، روشی ساده است ولی برابر در نظر گرفتن وزن‌های مدل‌های منفرد از مشکلات این روش است. خروجی این مدل با میانگین‌گیری از خروجی مدل‌های منفرد مطابق رابطه (۱۳) به دست می‌آید.

$$\hat{y}_l = \frac{1}{m} \left( \sum_{j=1}^m \hat{y}_{lj} \right) \quad i=1, \dots, n \quad (13)$$

که در آن،  $m$  تعداد مدل‌های منفرد و  $n$  تعداد مشاهدات است.

**میانگین‌گیری وزن‌دار:** در این روش به هر مدل منفرد یک وزن اختصاص داده می‌شود و خروجی آن مطابق روابط (۱۴) و (۱۵) تعیین می‌شود که در آن  $C_j$  وزن هر مدل منفرد است.

$$\hat{y}_l = \frac{1}{m} \left( \sum_{j=1}^m C_{ij} \hat{y}_{lj} \right) \quad i=1, \dots, n \quad (14)$$

$$\hat{y}_l = \sum_{j=1}^n \left( \hat{y}_{lj} - \sum_{j=1}^m C_{ij} \hat{y}_{lj} \right)^2 \quad (15)$$

**مدل تلفیقی شبکه عصبی مصنوعی:** ورودی مدل، نتایج به دست آمده از مدل‌های منفرد انتخابی برای عملیات تلفیق می‌باشد. در مدل تلفیقی شبکه عصبی نتایج مدل‌های منفرد به عنوان ورودی شبکه و ساختار

**مدل رگرسیون بردار پشتیبان (SVR):** رگرسیون بردار پشتیبان یک سامانه یادگیری کارآمد بر مبنای بهینه‌سازی مقید است که از کمینه‌سازی خطای ساختاری استفاده کرده، به یک جواب بهینه کلی می‌رسد. هدف مدل SVR پیدا کردن رابطه میان متغیرهای مستقل ( $x$ ) و وابسته ( $y$ ) با تابع جبری مانند  $f(x)$  مطابق رابطه (۸) است (Bilandi و همکاران، ۲۰۱۵).

$$f(x) = W^T \cdot \phi(x) + b \quad (8)$$

$$y = f(x) + noise$$

با توجه به پیچیده بودن محاسبه  $\phi(x)$  در فضای مشخصه آن، می‌توان از توابع کرنل قابل استفاده در مدل SVR بهره برد. توابع کرنل به چهار دسته چند جمله‌ای<sup>۱</sup> با سه مشخصه هدف (رابطه (۹))، کرنل تابع پایه شعاعی<sup>۲</sup> با یک مشخصه هدف (رابطه (۱۰))، کرنل سیگموئیدی<sup>۳</sup> با دو مشخصه هدف (رابطه (۱۱)) و کرنل خطی<sup>۴</sup> (رابطه (۱۲)) تقسیم می‌شوند (Ahmadi و همکاران، ۲۰۱۵).

$$K(x, x_i) = (\gamma \cdot x' \cdot x_i + c_0)^d \quad (9)$$

$$K(x, x_i) = \exp(-\gamma |x - x_i|^2) \quad (10)$$

$$K(x, x_i) = \tanh(\gamma \cdot x' \cdot x + c_0) \quad (11)$$

$$K(x, x_i) = x' \cdot x \quad (12)$$

که در آن‌ها،  $\gamma$  پارامتر کرنل،  $x$  بردار ورودی‌ها،  $x_i$  بردار پشتیبان،  $c_0$  ضریب ثابت و  $d$  درجه چند جمله‌ای هستند و مقادیر بهینه آن‌ها از طریق سعی و خطا محاسبه می‌شود. با توجه به ساختار مدل SVR، داده‌ها به صورت استاندارد شده وارد مدل شده، با

<sup>1</sup> Polynomial kernel

<sup>2</sup> Radial basis function kernel

<sup>3</sup> Sigmoid kernel

<sup>4</sup> Linear kernel


$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (16)$$

$$\psi_{(a,b)}(t) = \psi\left(\frac{t-b}{a}\right) \quad (17)$$

در ساخت مدل تلفیقی با استفاده از مدل موجک- شبکه عصبی ابتدا خروجی شبکه واسنجی شده با استفاده از موجک تجزیه شده، سپس، وارد شبکه عصبی می‌شود و طبق رابطه (۱۸) به دست می‌آید (Chan و Adamowski, ۲۰۱۱).


$$\theta(X) = g_{Wavelet-ANN} [D_j(f_{ANN}(X, W^b | T^b))] \quad (18)$$

در شکل ۷- الف، نمونه‌ای از تجزیه موجک Bior در هشت سطح نشان داده شده است. همان‌طور که مشاهده می‌شود، در سیگنال‌های جریان ماهانه در سطح هشت تقریباً هیچ بسامدی وجود ندارد، اما این سطح تجزیه باعث ازدیاد ورودی‌ها خواهد شد. بنابراین، با سعی و خطا سطوح مختلف تجزیه بررسی خواهند شد. در ادامه، نتایج انتخاب بهترین موجک و بهترین سطح در شکل ۷- ب، نشان داده شده است. بر اساس نتایج مشاهده می‌شود که موجک Sym و سطح تجزیه سه به‌عنوان بهترین نوع موجک و با بیشترین معیار NSE دوره تست تعیین شده است. همچنین، بهترین اجرای این مدل با معیار NSE ۰/۹۸ در دوره آموزش و ۰/۹۱ در دوره تست به‌منظور پیش-بینی جریان انتخاب شده است.



مدل با سعی و خطا حاوی چهار لایه و لایه‌های پنهان به‌ترتیب با هشت و پنج نرون در نظر گرفته شده است. برای آموزش شبکه از الگوریتم پس‌انتشار خطا و با انتخاب تانژانت سیگموئیدی به‌عنوان تابع انتقال لایه‌ها و همچنین، تعداد تکرارهای لازم در فرایند یادگیری شبکه ۱۰۰۰ در نظر گرفته شد و شبکه با معیار میانگین مربعات خطا مورد ارزیابی قرار گرفت.

**مدل تلفیقی موجک-شبکه عصبی مصنوعی:** موجک‌ها توابع ریاضی هستند که داده‌ها را به اجزاء فراوانی (فرکانس) تفکیک کرده، هر جز را با نمایش متناسب با مقیاس آن جزء مطالعه می‌کنند. یکی از مزایای تبدیل موجک نسبت به روش‌های فوریه سنتی، توان بالای تحلیل آن‌ها در شرایطی است که سیگنال‌ها با گسستگی و جهش‌های سریع همراه هستند (BabaAli و Dehghani, ۲۰۱۷). سه شرط لازم برای این که تابعی بتواند به‌عنوان تبدیل موجکی عمل کند شامل تعداد نوسان محدود، بازگشت سریع به صفر در هر دو جهت مثبت و منفی در دامنه خود و میانگین صفر است. تابع موجک  $\psi(t)$  که با رابطه (۱۶) تعریف می‌شود، موجک مادر نامیده می‌شود.  $\psi_{(a,b)}(t)$  (موجک دختر) نیز با استفاده از انتقال و تغییر مقیاس موجک مادر طبق رابطه (۱۷) حاصل می‌شود (Mallat, ۱۹۸۹).



شکل ۷- الف) نمونه‌ای از تجزیه موجک bior در هشت سطح و ب) میانگین نش دوره تست مدل هیبریدکننده موجک-شبکه عصبی در سطوح تجزیه مختلف

عظیمی را در پیش‌بینی‌ها به‌وجود آورده است. این سیگنال‌ها الگوهای جوی و یا اقیانوسی هستند و در مکان معینی تشکیل می‌شوند و نام آن مکان را با خود به همراه دارند. از جمله این سیگنال‌ها می‌توان به

سیگنال‌های بزرگ مقیاس اقلیمی در پیش‌بینی متغیرهای هیدرولوژیکی: در دهه‌های اخیر، شناسایی سیگنال‌های بزرگ مقیاس اقلیمی به‌عنوان پیش‌بینی‌کننده پدیده‌های هیدرولوژیکی، تحول

مثبت موجب ظهور زمستانی گرم و مرطوب در اروپا و شرایط سرد و خشک در شمال کانادا و گرینلند می‌شود. در فاز منفی هوای مرطوب به سوی مدیترانه و هوای سرد به سمت شمال اروپا منتقل می‌شود. نوسانات دهه‌ای اقیانوس آرام<sup>۴</sup> (PDO) نیز یک الگوی ENSO ۱۰ ساله با اثرات مکانی آب و هوایی مشابه با ENSO ولی با رفتار زمانی متفاوت می‌باشد. PDO به‌طور قابل توجهی بر روی منابع آب مانند پوشش برف و آب شرب مناطقی مانند شمال آمریکا و سواحل شمال کالیفرنیا تا خلیج آلاسکا تاثیر دارد (Mantua و Hare, ۲۰۰۲). سیگنال‌های بزرگ‌مقیاس نمی‌توانند به‌تنهایی به‌عنوان پیش‌بینی کننده در پیش‌بینی بارش، رواناب و یا سایر متغیرهای هیدرولوژیکی استفاده شوند. برای استفاده از سیگنال‌ها به‌عنوان ورودی مدل‌های پیش‌بینی ابتدا باید همبستگی سیگنال‌ها را با پیش‌بینی شونده‌ها محاسبه کرد. چنانچه همبستگی بالایی بین آن‌ها باشد، می‌توان از سیگنال‌ها در کنار سری زمانی داده‌ها به‌عنوان ورودی به انواع مدل‌ها در پیش‌بینی متغیرها و شاخص‌های مختلف هیدرولوژیکی مانند بارش، رواناب، شاخص‌های خشکسالی و غیره استفاده کرد.

### نتایج و بحث

**نتایج مدل‌های منفرد در پیش‌بینی آورد:** در تمامی مدل‌های منفرد به‌منظور پیش‌بینی آورد ایستگاه سلطانی در حوزه آبخیز کرمان، ۸۰ درصد داده‌ها به‌منظور آموزش و ۲۰ درصد داده‌ها به‌منظور تست مدل در نظر گرفته شده است. با توجه به آن‌که دوره صحت‌سنجی به‌منظور کنترل بیش‌برازش است، با توجه به نتایج مطلوب مدل در دوره آموزش و تست به نظر نمی‌رسد، بیش‌برازش اتفاق افتاده باشد، بنابراین، نیازی به وجود دوره صحت‌سنجی نیست. در جدول ۶، نتایج حاصل از ارزیابی مدل‌های منفرد بر اساس معیارهای NSE، MSE و R<sup>2</sup> ارائه شده است. همچنین، در شکل ۸، جریان ماهانه مشاهداتی و شبیه‌سازی شده به‌وسیله مدل‌های منفرد به‌صورت مقایسه‌ای نشان داده شده است.

ENSO، NAO، AMO، PDO، SST و SLP اشاره نمود. با توجه به آنکه در پژوهش حاضر، از سه سیگنال بزرگ‌مقیاس NAO، SOI و PDO برای شبیه‌سازی جریان آورد رودخانه استفاده شده، در ادامه به معرفی آن‌ها پرداخته شده است (Moazami و Goudarzi و همکاران، ۲۰۲۰).

<sup>۱</sup> ENSO از دو واژه النینو و نوسانات جنوبی گرفته شده است و یکی از شاخص‌ترین سیگنال‌هایی است که باعث ایجاد ناهنجاری‌های بزرگ آب و هوایی در نقاط مختلف جهان می‌شود. این پدیده در دو فاز سرد (لانینا) و گرم (النینو) تعریف می‌شود. گرم شدن بیش از معمول آب‌های شرقی و مرکزی اقیانوس آرام را النینو گویند. لانینا عکس وضعیت النینو است و به شرایطی گفته می‌شود که در آن دمای سطح آب در نواحی شرقی اقیانوس آرام خیلی کمتر از معمول و فشار هوا نیز به میزان زیادی بیشتر از میانگین درازمدت شود. یکی از شاخص‌های اندازه‌گیری شدت پدیده ENSO گرادیان فشار در امتداد شرقی غربی اقیانوس آرام می‌باشد که به‌وسیله شاخص SOI<sup>۲</sup> بیان می‌شود. این شاخص، بر اساس اختلاف فشار بارومتری هوای سطح دریا در داروین استرالیا و جزیره تاهیتی در منطقه جنوب شرقی آسیا به‌صورت رابطه (۱۹) محاسبه می‌شود.

$$SOI = 10 \frac{(P_{diff} - P_{diffav})}{SD(P_{diff})} \quad (19)$$

که در آن،  $P_{diff}$  اختلاف SLP ماهانه در دو شهر داروین و تاهیتی،  $P_{diffav}$  میانگین بلندمدت  $P_{diff}$  و  $SD(P_{diff})$  انحراف معیار  $P_{diff}$  می‌باشد. معمولاً SOI کمتر از ۰/۵- را شرایط النینو و بیشتر از ۰/۵+ را لانینا و SOI بین این دو مقدار را شرایط خنثی (نرمال) می‌نامند. پدیده نوسانات اطلس شمالی<sup>۳</sup> (NAO) بیانگر وضعیت تکرارپذیر در توده‌های اتمسفری میان مراکز پرفشار استوایی و کم‌فشار قطبی است. این پدیده بر اساس نوسانات فشار هوا در مقیاس نصف‌النهاری بین پرفشار Azore و کم‌فشار ایسلند می‌باشد که در دو فاز مثبت و منفی قرار می‌گیرد. فاز

<sup>۱</sup> El Nino South Oscillation


<sup>۲</sup> South Oscillation Index

<sup>۳</sup> North Atlantic Oscillation

<sup>۴</sup> Pacific Decadal Oscillation

جدول ۶- نتایج مدل‌های منفرد در پیش‌بینی جریان آورد ماهانه

مدل	دوره آموزش			دوره تست		
	NSE	R <sup>2</sup>	MSE	NSE	R <sup>2</sup>	MSE
ANN	۰/۰۰۶	۰/۸۳۸	۰/۸۳۴	۰/۰۰۷	۰/۸۰۹	۰/۷۱۰
ANFIS	۰/۰۰۱	۰/۹۷۳	۰/۹۷۲	۰/۰۰۸	۰/۶۸۸	۰/۶۸۷
ARIMA	۰/۰۰۶	۰/۸۳۳	۰/۸۳۴	۰/۰۰۷	۰/۶۵۳	۰/۵۱۰
SVR	۰/۰۰۵	۰/۷۶۵	۰/۷۶۷	۰/۰۰۸	۰/۶۴۳	۰/۶۲۵



شکل ۸- جریان ماهانه شبیه‌سازی شده به‌وسیله مدل‌های منفرد در دوره پیش‌بینی

نسبت به نقاط اوج مشاهداتی دارد. این مدل همچنین، در جریان‌های کم، مقادیر شبیه‌سازی شده منفی تولید کرده که باعث افزایش خطا شده است. در نهایت، مدل SVR نیز در جریان‌های اوج، عملکردی نسبتاً مشابه با سایر مدل‌های منفرد دارد؛ لیکن در جریان‌های کم این مدل قادر به شبیه‌سازی نوسانات جریان نیست.

**نتایج مدل‌های تلفیقی در پیش‌بینی آورد:** با توجه به نتایج مطلوب مدل‌های منفرد، از تمامی مدل‌ها در بخش تلفیق داده نیز بهره گرفته شده است، اما نسبت به مدل SVR با احتیاط بیشتری برخورد می‌شود؛ به همین دلیل، مدل‌های تلفیقی در حالت اول با وجود مدل SVR و در حالت دوم بدون این مدل اجرا شده، در ادامه نتایج چهار تکنیک مختلف شامل میانگین‌گیری ساده، میانگین‌گیری وزن‌دار، مدل تلفیقی شبکه عصبی و مدل تلفیقی موجک-شبکه عصبی به‌عنوان مدل‌های تلفیقی ارائه شده است. نتایج حاصل از این روش‌های مختلف تلفیقی، در هر دو حالت (با SVR و بدون آن)، در دوره‌های آموزش و تست در جدول ۷ ارائه شده است.

به‌عنوان یک جمع‌بندی کلی، از مقایسه نتایج مدل‌های منفرد و تلفیقی در پیش‌بینی ماهانه آورد

به‌عنوان یک جمع‌بندی کلی از مقایسه نتایج به‌دست آمده از مدل‌های منفرد در پیش‌بینی آورد ماهانه حوزه آبخیز جیرفت بر اساس معیارهای مختلف، می‌توان دریافت که مدل ANFIS در دوره آموزش بهترین عملکرد را دارد و لیکن این مدل در دوره تست نتوانسته عملکرد مطلوبی ارائه کند. از سوی دیگر، مدل ANN که دارای بالاترین معیار NSE در دوره تست است، در دوره آموزش عملکردی کاملاً یکسان با مدل ARIMA داشته است. با در نظر گرفتن ضریب تبیین به‌عنوان معیار اطمینان به یک مدل می‌توان نتیجه گرفت که اطمینان به پیش‌بینی مدل ANN با بالاترین R<sup>2</sup> در دوره تست بیش از سایر مدل‌های منفرد است. با توجه به این شکل، ملاحظه می‌شود که مدل ANN و SVR در مقادیر پیک عملکردی تقریباً مشابه داشته‌اند. لیکن، در مقادیر خشکسالی به مدل ANFIS بهترین عملکرد را دارد. در نقاط اوج، مدل ANN نزدیک‌ترین مقدار شبیه‌سازی را به مقادیر مشاهداتی دارد، لیکن، این مدل در نقطه اوج چهارم و پنجم، جریان را بیش از مقدار واقعی پیش‌بینی کرده است. همچنین، مدل ANFIS نسبت به سایر مدل‌های منفرد مقادیر شبیه‌سازی کمتری


موارد زیر بیان می‌شود:

- نتایج مدل موجک شبکه عصبی به ترتیب مناسب‌تر از نتایج مدل شبکه عصبی مصنوعی، مدل میانگین-گیری وزن‌دار و مدل میانگین‌گیری ساده است.
- مشکل بیش برآزش مدل ANFIS در مدل میانگین‌گیری ساده برطرف شده است.
- در تمامی مدل‌های تلفیقی، حذف مدل SVR از فرایند تلفیق داده منجر به افزایش خطا در دوره تست شده است.
- دو مدل تلفیقی شبکه عصبی و موجک-شبکه


عصبی تقریباً نتایج یکسانی دارند و استفاده از مدل موجک-شبکه عصبی باعث شده نتایج مدل‌سازی اندکی بهبود یابد. اما با توجه به حجم بالای محاسبات در تجزیه موجک به نظر می‌رسد، مدل تلفیقی شبکه عصبی عملکرد بهتری داشته، مدل موجک شبکه عصبی را از روند محاسبات خارج می‌نمائیم. نتایج مدل‌های منفرد و تلفیقی در دوره‌های آموزش و تست به صورت مقایسه‌ای در شکل ۹ و بر اساس معیارهای MSE و NSE نشان داده شده است.

جدول ۷- نتایج مدل‌های منفرد و تلفیقی در پیش‌بینی ماهانه آورد

دوره تست			دوره آموزش			مدل
NSE	R <sup>2</sup>	MSE	NSE	R <sup>2</sup>	MSE	
۰/۸۰۰	۰/۸۱۲	۰/۰۰۵	۰/۹۳۵	۰/۹۴۰	۰/۰۰۲	S-Avg
۰/۸۰۷	۰/۸۱۴	۰/۰۰۵	۰/۹۴۴	۰/۹۴۵	۰/۰۰۲	W-Avg
۰/۸۹۴	۰/۸۹۵	۰/۰۰۳	۰/۹۷۸	۰/۹۷۸	۰/۰۰۱	ANN
۰/۹۱۳	۰/۹۱۵	۰/۰۰۲	۰/۹۸۸	۰/۹۸۹	۰/۰۰۱	Wave-ANN
۰/۷۷۶	۰/۷۹۳	۰/۰۰۶	۰/۹۴۱	۰/۹۴۴	۰/۰۰۲	S-Avg
۰/۷۹۱	۰/۸۰۰	۰/۰۰۵	۰/۹۴۶	۰/۹۴۸	۰/۰۰۲	W-Avg
۰/۸۴۲	۰/۸۵۵	۰/۰۰۴	۰/۹۷۶	۰/۹۷۶	۰/۰۰۲	ANN
۰/۹۱۴	۰/۹۱۵	۰/۰۰۴	۰/۹۸۹	۰/۹۸۹	۰/۰۰۱	Wave-ANN



(ب)




(الف)

شکل ۹- مقایسه مدل‌های مختلف در پیش‌بینی آورد ماهانه بر اساس معیار، الف) MSE و ب) NSE

در نظر گرفتن این سیگنال‌ها به عنوان ورودی در مدل‌های شبیه‌سازی جریان منجر به کاهش خطای پیش‌بینی شود. در ادامه، نتایج سه مدل ANN، ANFIS و SVR با استفاده از سیگنال‌های بزرگ‌مقیاس ارائه شده است (Zamanirad و همکاران، ۲۰۱۹). از آنجایی که مدل ARIMA یک مدل خودهمبسته است و نمی‌توان متغیر دیگری به ورودی‌های آن اضافه کرد، در نتیجه، در این بخش از روند مدل‌سازی حذف می‌شود.

**نتایج مدل‌های منفرد به همراه سیگنال‌های بزرگ‌مقیاس:** در این بخش، از سه سیگنال بزرگ‌مقیاس NAO، SOI و PDO در پیش‌بینی جریان آورد ماهانه استفاده شده است. برای این منظور، ابتدا همبستگی سه متغیر مذکور با جریان ایستگاه سلطانی مطابق شکل ۱۰ محاسبه شده است. همان‌طور که در شکل مشخص است، همبستگی جریان با مقادیر سیگنال‌های بزرگ‌مقیاس بسیار کمتر از سایر متغیرهای هیدرولوژیکی است، لیکن انتظار می‌رود که



(ج)


(ب)

(الف)


شکل ۱۰- همبستگی جریان ایستگاه سلطانی با الف (NAO)، ب (SOI) و ج (PDO)

نتایج حاصل از عملکرد سیگنال‌های بزرگ‌مقیاس در تعیین معیارهای ارزیابی مختلف در دوره‌های آموزش و تست با مدل‌های منفرد مذکور در جدول ۸ ارائه شده است.

در شکل ۱۱، معیارهای ارزیابی مدل‌های منفرد در دو حالت بدون در نظر گرفتن سیگنال‌های بزرگ‌مقیاس و همراه با سیگنال‌ها نشان داده شده است.



(الف) بر اساس معیار MSE



(ب) بر اساس معیار NSE

شکل ۱۱- مقایسه مدل‌های منفرد در دو حالت بدون سیگنال‌های بزرگ‌مقیاس و همراه با سیگنال‌ها در پیش‌بینی آورد ماهانه در دوره‌های تست و آموزش بر اساس معیار، الف (MSE) و ب (NSE)

جدول ۸- نتایج حاصل از مدل‌های منفرد به همراه سیگنال‌های بزرگ‌مقیاس

دوره تست		دوره آموزش			مدل‌های منفرد با سیگنال‌های بزرگ مقیاس	
MSE	R <sup>2</sup>	NSE	MSE	R <sup>2</sup>		
۰/۰۰۴	۰/۸۱۰	۰/۸۰۷	۰/۰۰۴	۰/۸۹۹	۰/۸۸۱	ANN
۰/۰۰۵	۰/۸۰۸	۰/۸۰۴	۰/۰۰۲	۰/۹۶۰	۰/۹۶۰	ANFIS
۰/۰۱۰	۰/۷۹۳	۰/۷۲۷	۰/۰۰۷	۰/۸۲۱	۰/۸۲۰	SVR

به همراه سیگنال‌های بزرگ‌مقیاس در پیش‌بینی آورد ماهانه ارائه شده است. لازم به ذکر است که با توجه به نتایج قابل قبول مدل SVR در حالت بدون سیگنال،

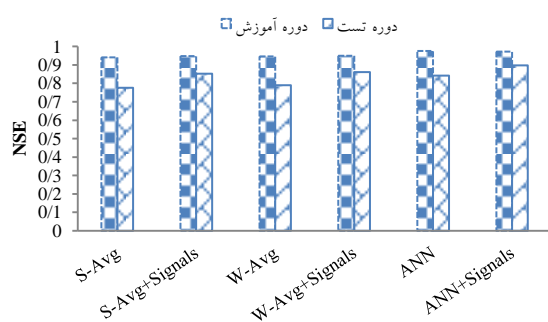
نتایج مدل‌های تلفیقی به همراه سیگنال‌های بزرگ‌مقیاس در پیش‌بینی آورد ماهانه: در جدول ۹، نتایج مدل‌های تلفیقی بر اساس معیارهای مختلف

در این قسمت، این مدل از روند تلفیق نتایج حذف نمی‌شود. همچنین، در شکل ۱۲ نتایج معیارهای ارزیابی مدل‌های منفرد در دو حالت بدون در نظر گرفتن سیگنال‌های بزرگ مقیاس و همراه با سیگنال‌ها نشان داده شده است.


در این قسمت، این مدل از روند تلفیق نتایج حذف نمی‌شود. همچنین، در شکل ۱۲ نتایج معیارهای ارزیابی مدل‌های منفرد در دو حالت بدون در نظر گرفتن سیگنال‌های بزرگ مقیاس و همراه با سیگنال‌ها نشان داده شده است.

جدول ۹- نتایج مدل‌های تلفیقی بر اساس معیارهای مختلف به همراه سیگنال‌های بزرگ مقیاس در پیش‌بینی آورد ماهانه

دوره تست			دوره آموزش			مدل‌های تلفیقی با سیگنال‌های بزرگ مقیاس
MSE	R <sup>2</sup>	NSE	MSE	R <sup>2</sup>	NSE	
۰/۰۰۴	۰/۸۶۰	۰/۸۵۳	۰/۰۰۲	۰/۹۵۰	۰/۹۴۸	Savg
۰/۰۰۳	۰/۸۶۱	۰/۸۶۲	۰/۰۰۲	۰/۹۶۲	۰/۹۵۰	Wavg
۰/۰۰۳	۰/۹۱۷	۰/۸۹۹	۰/۰۰۱	۰/۹۷۶	۰/۹۷۳	ANN




(ب)




(ف)


شکل ۱۲- مقایسه مدل‌های تلفیقی در دو حالت بدون سیگنال‌های بزرگ مقیاس و همراه با سیگنال‌ها بر اساس معیار، الف) MSE و ب) NSE



(ج)



(ب)




(الف)

شکل ۱۳- جریان ماهانه شبیه‌سازی شده به وسیله مدل‌های تلفیقی در دو حالت بدون سیگنال و همراه با سیگنال در دوره پیش‌بینی، الف) میانگین گیری ساده، ب) میانگین گیری وزن دار و ج) شبکه عصبی مصنوعی

در دوره‌های تست و آموزش و همچنین، در دو حالت بدون در نظر گرفتن سیگنال‌ها و با آن‌ها در شکل ۱۴ نشان داده شده است.

به‌عنوان جمع‌بندی از مقایسه مدل‌ها، مدل تلفیقی شبکه عصبی با بالاترین معیار NSE و R<sup>2</sup> و کمترین میزان خطای MSE، بهترین عملکرد را داراست. نتایج حاصل از معیار NSE برای مدل‌های منفرد و تلفیقی



شکل ۱۴- مقایسه معیار NSE در دوره‌های تست و آموزش، الف) مدل‌های منفرد و ب) مدل‌های تلفیقی

## نتیجه‌گیری

با توجه به اهمیت برنامه‌ریزی و مدیریت منابع، پیش‌بینی دقیق جریان رودخانه با استفاده از ابزارها و روش‌های نوین مدل‌سازی به ضرورتی اجتناب‌ناپذیر تبدیل شده است. تا کنون، روش‌های متعددی برای پیش‌بینی جریان آورد رودخانه توسعه یافته است. در این میان، مدل‌های هوشمند، همچون مدل‌های سری زمانی، شبکه‌های عصبی مصنوعی، منطق فازی با الهام‌گیری از طبیعت، از دقت قابل قبولی در تخمین پارامترهای مربوط به پدیده‌های طبیعی برخوردار بوده‌اند. علاوه بر این، استفاده از مفاهیم تلفیق داده، نتایج بهتری نسبت به مدل‌های منفرد به همراه داشته است. همچنین، مطالعات بیانگر بهتر شدن نتایج مدل‌های هوشمند در صورت استفاده از سیگنال‌های بزرگ‌مقیاس اقلیمی به‌عنوان پیش‌بینی کننده بوده است. در مقاله حاضر، تلاش شد تا بهره‌گیری از روش‌های تلفیق داده و سیگنال‌های بزرگ‌مقیاس اقلیمی به‌صورت هم‌زمان در پیش‌بینی جریان رودخانه مورد ارزیابی قرار بگیرد. به همین منظور، با انتخاب حوزه آبخیز سد جیرفت به عنوان مطالعه موردی، با استفاده از روش‌های منفرد (مدل‌های ANN، ANFIS، ARIMA و SVR) و تلفیقی (مدل‌های میانگین‌گیری ساده، میانگین‌گیری وزن‌دار و مدل تلفیقی شبکه عصبی و مدل تلفیقی موجک-شبکه عصبی) به پیش‌بینی جریان رودخانه در این منطقه پرداخته شد. در این مقاله، همچنین، از سیگنال‌های بزرگ‌مقیاس اقلیمی شامل ENSO، NAO و PDO در پیش‌بینی‌های هیدرولوژیک جریان رودخانه استفاده شد و عملکرد مدل‌های منفرد و تلفیقی در دو حالت با در نظر گرفتن این سیگنال‌ها و بدون در نظر گرفتن آن‌ها بر اساس ارزیابی با سه معیار  $R^2$ ، NSE و MSE

مورد مقایسه قرار گرفته است. نتایج حاصل از این پژوهش، نشان داد که رویکرد تلفیق داده دقت پیش‌بینی‌ها را تا حد قابل ملاحظه‌ای افزایش می‌دهد. علاوه بر این، مشخص شد که سیگنال‌های بزرگ‌مقیاس اقلیمی منجر به بهبود نتایج خصوصاً در دوره تست شده است. به‌عنوان مثال، نتایج حاصل از مدل تلفیقی شبکه عصبی به همراه سیگنال‌های بزرگ‌مقیاس اقلیمی نشان می‌دهد که این مدل بهترین عملکرد را در میان مدل‌های تلفیق داده دارد. معیار NSE نسبت به مدل تلفیقی شبکه عصبی بدون سیگنال‌های بزرگ‌مقیاس در دوره آموزش  $0.04$  بهبود یافته و خطای MSE به میزان  $0.001$  کاهش پیدا کرده است. همچنین، مقایسه نتایج مدل‌های منفرد و تلفیقی در دوره‌های آموزش و تست به‌صورت مقایسه‌ای نشان داد که عملکرد مدل تلفیقی در دوره تست از تمامی مدل‌های منفرد بهتر بوده و در دوره آموزش نیز بر اساس معیارهای ارزیابی مختلف، نتایج این مدل از مدل‌های منفرد به غیر از مدل ANFIS بهتر است.

همچنین، مشخص شد که حذف مدل SVR از فرایند تلفیق داده باعث کاهش دقت در این مدل، خصوصاً در دوره تست شده است. بر اساس نتایج، مشاهده شد که در میان مدل‌های منفرد، مدل ANFIS کمترین خطا و بالاترین معیار NSE را در دوره آموزش دارد که تقریباً مشابه با مدل تلفیقی شبکه عصبی مصنوعی در حالت اول است. لیکن، این مدل در دوره تست خطای نسبتاً بالایی دارد که از این نظر مشابه مدل SVR است. همچنین، در بین مدل‌های تلفیقی نیز مدل ANN در حالت اول در هر دو دوره آموزش و تست کمترین خطا و بالاترین معیار نش را دارد و از این نظر، بهترین مدل در پیش‌بینی



در نهایت، نتایج سری زمانی مشاهداتی و پیش‌بینی حاصل از مدل‌های تلفیقی مختلف به صورت مقایسه‌ای در دو حالت بدون سیگنال و همراه با سیگنال‌های بزرگ‌مقیاس نشان داد که مدل ANN در دو حالت در مقادیر اوج تقریباً عملکرد مشابهی دارند، لیکن در مقادیر کم جریان وجود سیگنال‌های بزرگ‌مقیاس منجر به بهبود نتایج شده است. همچنین، بر اساس نتایج مشخص شد که استفاده از دو مدل تلفیقی میانگین‌گیری وزن‌دار بدون سیگنال‌ها و همراه با سیگنال‌های بزرگ‌مقیاس، این مدل توانسته دو پیک اول را بهتر از میانگین‌گیری ساده شبیه‌سازی کند. همچنین، نتایج حاصل از مدل تلفیقی شبکه عصبی بدون سیگنال‌ها و همراه با سیگنال‌های بزرگ‌مقیاس حاکی از بهترین عملکرد به‌وسیله این مدل در مقایسه با سایر مدل‌ها بوده است.

آورد ماهانه انتخاب می‌شود. همچنین، این نتیجه حاصل شد که در دوره آموزش مدل‌های ANFIS و ARIMA بالاترین و مدل‌های SVR و مدل تلفیقی ANN کمترین MSE را دارند. لیکن با توجه به اختلاف بالای خطای مدل ANFIS و تلفیقی ANN در دوره‌های آموزش و تست، مدل تلفیقی ANN عملکرد بهتری دارد، چرا که در مدل ANFIS بیش‌برازش اتفاق افتاده است. در میان مدل‌های تلفیقی نیز مدل تلفیقی ANN کمترین خطای آموزش و تست را دارد که نزدیک به مدل تلفیقی موجک-شبکه عصبی است و با در نظر گرفتن حجم محاسبات در تجزیه سیگنال‌ها مدل تلفیقی شبکه عصبی مصنوعی در هر دو حالت به‌عنوان بهترین مدل با کمترین MSE و بالاترین معیار NSE در هر دو دوره آموزش و تست انتخاب می‌شود.

#### منابع مورد استفاده

1. Abrishamchi, A., H. Ashuri and H. Moradkhani. 2013. Long-term forecast of Zayandehrud River flow using collective flow forecasting technique (ESP) and large climatic scale signals. 8th International Congress of Civil Engineering, Shiraz, Shiraz University.
2. Adamowski, J. and F.H. Chan. 2011. A wavelet neural network conjunction model for groundwater level forecasting. *Journal of Hydrology*, 407(4): 28-40.
3. Afkhamifar, S. and A.P. Sarraf. 2020. Prediction of groundwater level in Urmia Plain aquifer using hybrid model of wavelet Transform-Extreme Learning Machine based on quantum particle swarm optimization. *Watershed Engineering and Management*, 12(2): 351-364 (in Persian).
4. Ahmadi, F., F. Radmanesh and R. Mir Abbasi. 2015. Comparison of genetic programming methods and support vector machine in predicting daily river flow, case study: Barandozchay River. *Journal of Water and Soil (Agricultural Sciences and Industries)*, 28(6): 1162-1171.
5. Azmi, M., S. Araghinejad and M. Kholghi. 2010. Multi model data fusion for hydrological forecasting using K-Nearest Neighbour Method. *Iranian Journal of Science and Technology*, 34(B1): 81-92.
6. BabaAli, H.R. and R. Dehghani. 2017. Comparison of wave and neural network models in groundwater level forecasting. *Hydrogeology*, 2(2): 96-108.
7. Bilandi, M., A. Khashiee Siuki and P. Sadeghi Tabas. 2015. Forecast of Ravanab daily with the model of minimum squares of support vector machine. *Journal of Water and Soil Protection Research*, 21(6): 293-304.
8. Box, G.E.P., G.M. Jenkins and G.C. Reinsel. 2008. *Time series analysis, forecasting and control*. 4th Edition, Englewood Cliffs, New Jersey, Prentice Hall.
9. Donyaii, A.R., A.P. Sarraf and H. Ahmadi. 2020a. Optimization of reservoir dam operation using gray wolf, crow search and whale algorithms based on the solution of the nonlinear programming model. *Journal of Water and Soil Science*, In Press (in Persian).
10. Donyaii, A.R., A.P. Sarraf and H. Ahmadi. 2020b. Multi-objective optimal utilization policy of boostan dam reservoir using whale and NSGA-II algorithms based on game theory and shannon entropy method. *Iranian Water Researches Journal*, In Press (in Persian).
11. Moazami Goudarzi, F., A.P. Sarraf and H. Ahmadi. 2020. Prediction of runoff within Maharlu Basin for future 60 years using RCP scenarios. *Arabian Journal of Geosciences*, 13(605): 1-17.
12. Shafaei, M., A. Fakheri Fard, S. Darbandi and M.A. Ghorbani. 2014. Predicting the daily flow of the river using the wavy hybrid model and neural network, case study of Veniar Hydrometric Station in Ajichchay catchment area. *Quarterly Journal of Irrigation and Water Engineering*, 4(14): 123-128.
13. Shahbazi, A., A. Akhund Ali and F. Radmanesh. 2014. River flow forecasting using group flow forecasting (ESP). *National Conference on Civil Engineering and Sustainable Development with a Focus on Reducing the Risk of Natural Disasters*, Mashhad, Khavaran Higher Education Institute.

14. Sveinsson, O.G.B., U. Lall, J. Gaudet, Y. Kushnir, S. Zebiak and V. Fortin. 2008. Analysis of climatic states and atmospheric circulation patterns that influence Québec spring streamflows. *Journal of Hydrologic Engineering*, 13(6): 1-14.
15. Toofani, P., A. Mosaedi and A. Fakhelifard. 2012. Precipitation forecast with direct use of wave theory. *Journal of Water and Soil*, 25(5): 1217-1226.
16. Wang, W., P. VanGleider and J.K. Vrijling. 2005. Improving daily streamflow forecasts by combining ARMA and ANN models. In *processings of the International Conference on Innovation Advances and Implementation of Flood Forecasting Technology*, Tromsø, Norway.
17. Yoon, H., S.C. Jun, Y. Hyun, G.O. Bae and K.K. Lee. 2011. A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. *Journal of Hydrology*, 396: 128-138.
18. Zamanirad, M., A.P. Sarraf, H. Sedghi, A. Saremi and P. Rezaee. 2019. Modeling the influence of groundwater exploitation on land subsidence susceptibility using machine learning algorithms. *Natural Resources Research Journal*, 29(2): 1127-1141.