

شبیه‌سازی نوسانات سطح آب زیرزمینی با استفاده از مدل‌های ماشین بردار پشتیبان و سیستم استنتاج فازی-عصبی تطبیقی (مطالعه موردی: دشت مراغه)

محمد مهدی جعفری^۱، حسن اوجاقلو^{۲*}، محمد زارع^۳

تاریخ دریافت: ۱۳۹۸/۱۰/۲۵ تاریخ پذیرش: ۱۳۹۹/۲/۱۰

چکیده

به منظور مدیریت بهینه منابع آب زیرزمینی، ضروری است برآورد دقیقی از نوسانات سطح آب زیرزمینی انجام پذیرد که در سال‌های اخیر استفاده از روش‌های هوش مصنوعی بر پایه تئوری داده کاوی برای این منظور مورد توجه محققین قرار گرفته است. هدف از پژوهش حاضر، مقایسه عملکرد سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) و روش ماشین بردار پشتیبان (SVM) در شبیه‌سازی نوسانات سطح آب زیرزمینی می‌باشد. داده‌های بارش و سطح ایستابی ماهانه مربوط به تعداد ۲۵ چاهک مشاهده‌ای در بخشی از محدوده دشت مراغه واقع در استان آذربایجان شرقی مربوط به بازه زمانی ۲۲ ساله (۹۷-۱۳۷۵) به عنوان داده‌های ورودی مورد نیاز مدل‌ها استفاده شد. میانگین تراز سطح ایستابی در محدوده مورد مطالعه ۱۳۲۱ متر و میانگین بارش و دمای سالانه به ترتیب ۲۹۴ میلی‌متر و ۱۴ درجه سانتی‌گراد می‌باشد. مقادیر میانگین شاخص‌های آماری ضریب همبستگی و ریشه میانگین مربعات خطا برای مدل ANFIS به ترتیب برابر ۰/۹۱ و ۰/۳۸ متر و برای مدل SVM به ترتیب برابر ۰/۹۲ و ۰/۴۰ متر محاسبه شد. نتایج نشان داد، اضافه شدن پارامتر بارش ماهانه به داده‌های ورودی، اثر قابل توجهی بر دقت مدل ANFIS نداشته است ولی در مدل SVM منجر به افزایش دقت مدل به میزان ۱۴ درصد شد. به طور کلی می‌توان بیان داشت، دقت شبیه‌سازی هر دو مدل رضایت بخش بوده با این وجود مدل ANFIS از برتری جزئی نسبت به مدل SVM برخوردار می‌باشد.

واژه‌های کلیدی: تراز آب زیرزمینی، شبیه‌سازی، مدل‌های هوشمند

مقدمه

پارامترهای هیدرولوژیکی به دلیل ارزان و در دسترس بودن توسعه پیدا کرده است. در بین روش‌های غیرمستقیم، مدل‌های هوشمند عملکرد قابل قبولی را از خود نشان داده‌اند به طوری که در سال‌های اخیر مطالعات مختلفی در زمینه کاربرد این روش‌ها در شبیه‌سازی تراز آب زیرزمینی انجام گرفته است. یکی از روش‌های مورد توجه محققین، سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) بوده که در ادامه به برخی از مهم‌ترین مطالعات انجام گرفته در این زمینه اشاره شده است. در تحقیقی سطح آب‌های زیرزمینی دشت شیراز با استفاده از سری‌های زمانی و سیستم استنباط فازی-عصبی تطبیقی مدل‌سازی شد. مقایسه عملکرد مدل‌ها، حاکی از کارایی بسیار مناسب مدل خطی ARIMA نسبت به مدل ANFIS بود (چوبین و همکاران، ۱۳۹۳). اسکندری و همکاران (۱۳۹۷) ترکیب سیستم فازی-عصبی با تبدیل موجک برای مدل‌سازی و پیش‌بینی سطح آب زیرزمینی حوضه دالکی را ارزیابی نمودند. نتایج بیانگر این بود که

در بیشتر مناطق ایران منابع آب سطحی محدود بوده و اصلی‌ترین منبع تامین آب، آب‌های زیرزمینی می‌باشد. خشکسالی‌های اخیر همراه با برداشت بیش از حد آب‌های سطحی و زیرزمینی از طریق چاه‌های عمیق و نیمه‌عمیق منجر به افت شدید تراز آب‌های زیرزمینی شده است (اکبرزاده و همکاران، ۱۳۹۵). مهم‌ترین راهکار مقابله با بحران افت آب زیرزمینی، مدیریت صحیح این منابع ارزشمند از طریق پایش‌های مداوم و مستمر می‌باشد که بدین منظور نیاز به انجام اندازه‌گیری‌های میدانی پرهزینه و زمان‌بر است. در سال‌های اخیر استفاده از روش‌های غیرمستقیم به منظور تحلیل روند تغییرات

۱- دانشجوی کارشناسی ارشد آبیاری و زهکشی، دانشگاه زنجان

۲- استادیار گروه علوم و مهندسی آب، دانشگاه زنجان

۳- پژوهشگر موسسه تحقیقاتی مهندسی کشاورزی و زیست فناوری لابنیز

(ATB)، پتسدام، آلمان

(*- نویسنده مسئول)

(Email: ojaghrou@znu.ac.ir)

مدل ترکیبی دارای عملکرد بهتری از مدل فازی - عصبی بوده است. گویلی و همکاران (۱۳۹۷) به منظور پیش‌بینی نوسانات سطح آب دریاچه زریوار با در نظرگیری تراز آب زیرزمینی، از مدل‌های موجک - شبکه عصبی مصنوعی، برنامه‌ریزی بیان ژن، شبکه عصبی مصنوعی و مدل استنتاج عصبی - فازی تطبیقی استفاده نمودند. نتایج این تحقیق نشان داد که از چهار مدل مذکور، مدل موجک - شبکه عصبی مصنوعی بیشترین دقت را داشته است. در مطالعه‌ای دیگر عملکرد روش‌های سیستم استنتاج فازی - عصبی تطبیقی، روش وزن‌دهی معکوس فاصله و زمین آمار در تخمین سطح ایستابی دشت دهگلان استان کردستان مورد مقایسه قرار گرفت. بر اساس نتایج به‌دست آمده، روش ANFIS با مقدار RMSE برابر با ۰/۰۷ نسبت به سایر روش‌ها عملکرد بهتری داشت (کرد و همکاران، ۱۳۹۸). در پژوهشی روش برنامه‌ریزی بیان ژن و سیستم استنتاج فازی - عصبی به منظور پیش‌بینی نوسانات عمق آب زیرزمینی در کوتاه مدت مورد مقایسه قرار گرفتند. نتایج نشان داد، مدل برنامه‌ریزی بیان ژن عملکرد بهتری نسبت به مدل فازی - عصبی داشته است (Shiri and Kisi., 2011). موسوی و همکاران مدل ترکیبی Wavelet-ANFIS را به منظور پیش‌بینی سطح آب زیرزمینی برای دوره‌های زمانی مختلف در دشت مشهد به کار بردند. نتایج ایشان نشان داد، مدل ترکیبی Wavelet-ANFIS در مقایسه با مدل‌های ANFIS، ANN^۱ و Wavelet-ANN می‌تواند دقت پیش‌بینی سطح آب زیرزمینی را بهبود بخشد (Moosavi et al., 2013). نتایج مقایسه‌ای موسوی و همکاران (۱۳۹۷) در مقایسه روش‌های ANFIS و ANN به ترتیب برابر ۰/۰۲ و ۱/۰۶ به‌دست آمد که نشانگر عملکرد بهتر مدل ANFIS می‌باشد (Emamgholizadeh et al., 2014). ژورویچ و همکاران به منظور پیش‌بینی سطح آب زیرزمینی در ساحل چپ رودخانه دانوب در شمال صربستان از دو مدل شبکه عصبی مصنوعی و سیستم استنتاج فازی - عصبی استفاده نمودند. نتایج نشان داد، از هر دو مدل می‌توان به عنوان ابزاری مفید برای مدل‌سازی سطح آب زیرزمینی با دقت بالا استفاده نمود (Djurovic et al., 2015). در تحقیقی عملکرد مدل‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان و سیستم استنتاج فازی - عصبی تطبیقی در پیش‌بینی سطح آب زیرزمینی در نزدیکی دریاچه اوکیوبی فلوریدا مقایسه شد. نتایج نشان داد، دقت مدل‌های ANFIS و SVM نسبت به مدل ANN بیشتر می‌باشد (Gong et al., 2015). زارع و کخ با استفاده از مدل‌های هوشمند ANN و ANFIS، تغییرات تراز آب زیرزمینی در دشت میاندربند ایران را شبیه‌سازی و بیان داشتند مدل ANFIS عملکرد بهتری نسبت به

شبکه عصبی دارد (Zare and Koch., 2016). نورانی و موسوی مدل‌های شبکه عصبی مصنوعی و سیستم استنتاج فازی - عصبی را برای مدل‌سازی سطح آب زیرزمینی دشت میاندوآب واقع در شمال غربی ایران مورد استفاده قرار دادند. بعد از کالیبراسیون مدل‌ها، نتایج نشان داد که مدل استنتاج فازی - عصبی عملکرد بهتری از مدل شبکه عصبی مصنوعی داشته است (Nourani and Mousavi., 2016). نوسانات سطح آب زیرزمینی دشت میاندربند با استفاده از مدل‌های ANFIS، مدل خوشه‌بندی فازی و مدل ترکیبی Wavelet-ANFIS پیش‌بینی شد. در این تحقیق، عملکرد مطلوب‌تر مدل ترکیبی Wavelet-ANFIS با موجک مادری Symlet نسبت به مدل‌های دیگر گزارش شد به طوری که مقادیر RMSE و R² در مرحله آزمون به ترتیب ۰/۱۷، ۰/۹۸۴ برآورد گردید (Zare and Koch., 2018). در زمینه کاربرد مدل ماشین بردار پشتیبان (SVM^۲) در منابع آب و به خصوص آب زیرزمینی پژوهش‌های مختلفی انجام گرفته است که در ادامه به مهم‌ترین موارد اشاره شده است. رضایی و همکاران (۱۳۹۳) طراحی شبکه پیش‌بینی سطح آب زیرزمینی را با استفاده از روش حداقل مربعات ماشین بردار پشتیبان (LS-SVM) انجام دادند. ترکیب‌های مختلف پارامترهای اثرگذار بر تراز سطح آب زیرزمینی با استفاده از این مدل ارزیابی شد. مقادیر شاخص‌های میانگین خطای مطلق و ضریب همبستگی برای ترکیب داده ورودی برتر به ترتیب برابر با ۰/۳۴ و ۰/۹۹ گزارش شد. آخونی - پورحسینی و اسدی (۱۳۹۶) به ارزیابی عملکرد آزمون گاما برای پردازش و انتخاب ورودی‌های مناسب و کارایی روش‌های حداقل مربعات ماشین بردار پشتیبان و شبکه بیزین در پیش‌بینی سطح تراز ایستابی دشت اردبیل پرداختند. از میان دو مدل با ساختار ورودی یکسان، روش حداقل مربعات ماشین بردار پشتیبان عملکرد بهتری داشته است. عیسی‌زاده و همکاران (۱۳۹۷) به منظور تخمین پارامترهای کیفی آبخوان دشت گیلان از آزمون گاما و مدل‌های ماشین بردار پشتیبان و شبکه عصبی مصنوعی استفاده نمودند. نتایج نشان داد، عملکرد مدل SVM نسبت به مدل ANN، به ازای تعداد ورودی کمتر بهتر است و در تعداد ورودی بیشتر برعکس می‌باشد. اسکندری و همکاران (۱۳۹۷ الف) نوسانات سطح آب زیرزمینی دشت برازجان را با استفاده از ترکیب ماشین بردار پشتیبان و تبدیل موجک پیش‌بینی نمودند. نتایج نشان داد مدل ترکیبی دارای عملکرد بهتری نسبت به مدل ماشین بردار پشتیبان می‌باشد. یو و همکاران با استفاده از مدل ماشین بردار پشتیبان به پیش‌بینی تراز آب در رودخانه لانیانگ در تایوان پرداختند. نتایج نشان داد، این روش به خوبی سطح آب رودخانه را برای ۱ تا ۶ ساعت بعد پیش‌بینی می‌کند (Yu et al., 2006). در تحقیقی دیگر روش حداقل مربعات ماشین بردار پشتیبان

مواد و روش‌ها

منطقه مورد مطالعه

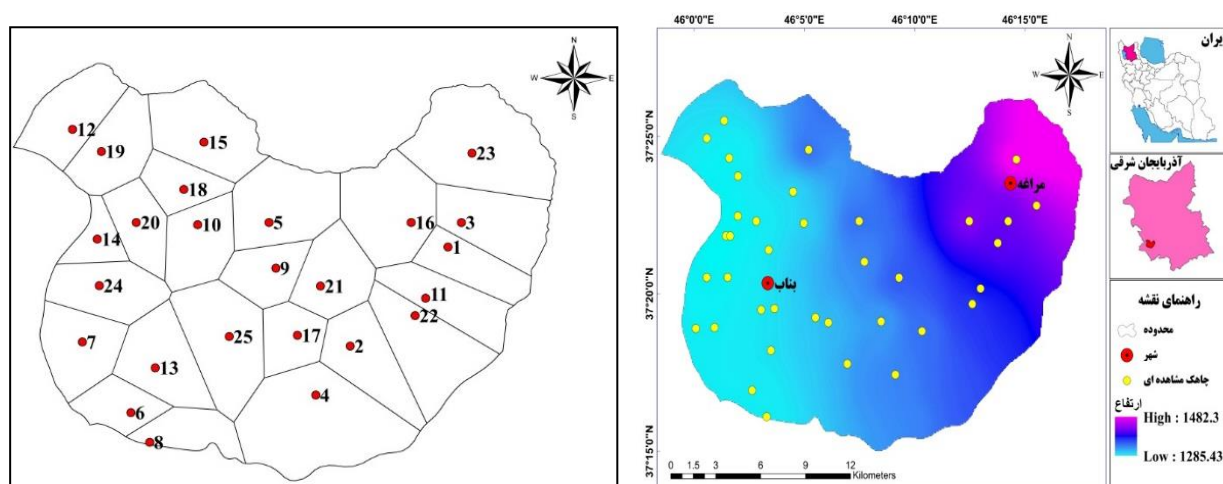
منطقه مورد مطالعه در این پژوهش بخشی از محدوده دشت مراغه واقع در شمال غربی ایران (استان آذربایجان شرقی) و دامنه‌های جنوبی کوه‌های سهند و جنوب شرقی دریاچه ارومیه و در فاصله ۱۲۰ کیلومتری جنوب غربی شهر تبریز می‌باشد. این دشت با ارتفاع متوسط حدود ۱۳۰۰ متر از سطح آب‌های آزاد، در موقعیت جغرافیایی ۴۶ درجه تا ۴۶ درجه و ۱۱ دقیقه طول شرقی و ۳۷ درجه و ۱۱ دقیقه تا ۳۷ درجه و ۲۸ دقیقه عرض شمالی واقع گردیده است. بر اساس آمار هواشناسی بلند مدت ایستگاه سینوپتیک مراغه، میانگین بارندگی و دمای سالانه در محدوده مورد مطالعه بر اساس داده‌های هواشناسی ۳۲ ساله (۱۳۹۷-۱۳۶۵) به ترتیب ۲۹۴ میلی‌متر و ۱۴ درجه سانتی-گراد می‌باشد. اقلیم منطقه نیز براساس سیستم طبقه‌بندی آمبرژه سرد و خشک تعیین شد. در شکل (۱) موقعیت جغرافیایی بخشی از محدوده دشت مراغه به همراه شبکه تیسرن بندی شده چاهک‌های مشاهده‌ای نشان داده شده است.

داده‌های استفاده شده

به منظور انجام پژوهش، ابتدا داده‌های هواشناسی ایستگاه سینوپتیک مراغه از سازمان هواشناسی و داده‌های تراز آب زیرزمینی دشت مراغه ثبت شده در بیش از ۴۰ چاهک مشاهده‌ای با دوره‌های آماری متفاوت (حداقل ۱۳ و حداکثر ۴۰ سال به صورت ماهانه) از شرکت آب منطقه‌ای استان آذربایجان شرقی اخذ شد. از تعداد ۴۰ چاهک مشاهده‌ای، ۱۳ چاهک دارای دوره آماری کمتر از ۲۰ سال بود و در ۲ چاهک نیز تعداد داده‌های گم شده متوالی زیاد بود لذا با در نظر گرفتن دوره آماری مشترک ۲۲ ساله (۱۳۹۷-۱۳۷۵) تعداد ۲۵ چاهک انتخاب و در شبیه‌سازی‌ها مورد استفاده قرار گرفت (جدول ۱). تکمیل نواقص آماری داده‌ها با استفاده از روش‌های رگرسیونی و درون‌یابی در محیط GIS انجام گرفت.

با توجه به طول دوره آماری مناسب داده‌های تراز آب زیرزمینی و همچنین بارش، ۷۰ درصد داده‌ها به منظور آموزش و ۳۰ درصد به منظور آزمون مورد استفاده قرار گرفت. برای این منظور داده‌های سطح ایستابی و بارش ماهانه از سال آبی ۷۶-۷۵ تا ۹۱-۹۰ به عنوان داده‌های مرحله آموزش و از سال آبی ۹۱-۹۰ تا ۹۸-۹۷ به عنوان داده‌های مرحله آزمون در نظر گرفته شد.

در پیش‌بینی رواناب میان مدت و بلندمدت به کار گرفته شد. مقایسه نتایج به دست آمده از این روش با شبکه عصبی مصنوعی نشان داد، روش ماشین بردار پشتیبان عملکرد بهتری از خود نشان داده است (Lijun and Shuquan., 2007). بهزاد و همکاران به مقایسه مدل-های ماشین بردار پشتیبان و شبکه عصبی در شبیه‌سازی سطح آبخوان Towaco در آمریکا در دوره‌های روزانه، هفتگی، دوهفته‌ها، ماهانه و دوماهه پرداختند. روش ماشین بردار پشتیبان عملکرد قابل قبول تری نسبت به شبکه عصبی مصنوعی به خصوص در دوره‌های زمانی طولانی‌تر از خود نشان داد (Behzad et al., 2010). یون و همکاران به مقایسه عملکرد روش‌های ماشین بردار پشتیبان و شبکه عصبی مصنوعی در پیش‌بینی تراز آب زیرزمینی آبخوان ساحلی در کره جنوبی پرداختند. نتایج به دست آمده از هر دو روش قابل قبول گزارش شد، با این وجود ضریب راندمان بیشتر در ماشین بردار پشتیبان موجب عملکرد بهتر آن شده بود (Yoon et al., 2011). مدل ماشین بردار پشتیبان در مطالعات هیدرولوژیکی مورد توجه محققانی نظیر یداو و الایزا به منظور پیش‌بینی نوسانات سطح آب دریاچه Loktak و نورانی و همکاران در مدل‌سازی رواناب-رسوب حوضه می‌سی‌سی‌پی، قرار گرفته است (Nourani et al., 2009; Yadav and Eliza., 2017). دمیرچی و همکاران به مدل‌سازی سطح آب زیرزمینی منطقه ریحانلی در ترکیه، با استفاده از تکنیک-های هوش مصنوعی پرداختند. در این مدل‌سازی از تکنیک‌های رگرسیون خطی چندمتغیره، سیستم استنتاج فازی-عصبی، مدل ترکیبی ماشین بردار پشتیبان با توابع پایه شعاعی و مدل ترکیبی ماشین‌های بردار پشتیبان با هسته‌های پلی استفاده شد و مقایسه‌ها نشان داد، روش‌های ماشین بردار با توابع پایه شعاعی و هسته‌های پلی بیشترین دقت را در تخمین سطح آب زیرزمینی دارند (Demirci et al., 2019). مدل‌های هوشمند با توجه به اینکه نیاز به داده‌های ورودی پیچیده و هزینه‌بر ندارند مورد استقبال محققین در علوم مختلف قرار گرفته است. نتایج مطالعات پیشین نشان می‌دهد استفاده از این روش‌ها در مطالعات آب زیرزمینی قابل قبول بوده و لذا ضروری است مدل‌های هوشمند مختلف در هر منطقه مورد ارزیابی قرار گیرند. با توجه به اینکه کاربرد همزمان سیستم استنتاج فازی و مدل ماشین بردار پشتیبان در شبیه‌سازی تراز آب زیرزمینی به ندرت مورد توجه محققین قرار گرفته است و از سوی دیگر در منطقه مورد مطالعه نیز تا کنون چنین تحقیقی انجام نگرفته است، لذا در این پژوهش، عملکرد دو روش هوشمند سیستم استنتاج فازی-عصبی تطبیقی و ماشین بردار پشتیبان به منظور شبیه‌سازی تراز آب زیرزمینی دشت مراغه در بازه زمانی داده‌برداری‌ها مورد ارزیابی و مقایسه قرار گرفته است.



شکل ۱- موقعیت محدوده مطالعاتی، چاهک‌های مشاهده‌ای و شبکه تیسین بندی

جدول ۱- مشخصات چاهک‌های مورد مطالعه

شماره چاهک	نام چاهک	مساحت (هکتار)	ارتفاع (متر)	شماره چاهک	نام چاهک	مساحت (هکتار)	ارتفاع (متر)
۱	سراجو (خشکبارچی)	۱۱۹۴	۱۳۹۷/۲	۱۴	آخوند قشلاق	۶۵۰	۱۲۸۰/۵۸
۲	سزاوار موسوی	۱۶۵۹	۱۳۳۱	۱۵	آلقو	۲۰۹۹	۱۳۳۶/۳۱
۳	ورجوی	۱۸۰۱	۱۴۰۴/۸	۱۶	پهرآباد	۲۲۴۳	۱۴۱۳/۴۱
۴	ینگى کند خوشه مهر	۳۶۹۴	۱۳۲۷/۹۲	۱۷	خوشه مهر قبرستان	۱۰۰۷	۱۳۱۴/۲۵
۵	روشت بزرگ ایستگاه راه آهن	۲۰۹۶	۱۳۳۷/۸۹	۱۸	روشت کوچک	۹۲۱	۱۲۹۶/۲۶
۶	خانه برق قدیم	۹۳۱	۱۲۸۷/۰۱	۱۹	بناب انرژی اتمی	۱۵۲۷	۱۲۸۰/۲۵
۷	قره چقق بهداشت	۱۵۵۳	۱۲۸۵/۰۹	۲۰	بناب منطقه آبیاری	۱۰۸۹	۱۲۸۲/۱۴
۸	خلیلوند روبروی آجرپزی	۹۹۸	۱۲۸۶/۸۲	۲۱	جاده سرچ بغل کانال	۱۴۵۴	۱۳۴۵/۷۱
۹	مراغه فرودگاه	۱۰۹۴	۱۳۲۵/۲۳	۲۲	خانقاه قبرستان	۲۱۲۶	۱۳۵۹/۱۷
۱۰	زاوشت قبرستان	۱۴۱۶	۱۲۹۷/۹	۲۳	مراغه خواجه نصیرشمالی	۳۲۵۱	۱۴۷۴/۲۴
۱۱	ورجوی ملکی	۱۴۶۵	۱۳۷۱/۹۹	۲۴	بناب اول راه دریا	۱۵۲۹	۱۲۸۴/۲۵
۱۲	خضولو شورگل	۱۶۴۵	۱۲۸۴/۴	۲۵	چلغای محوطه مسجد	۲۲۸۵	۱۳۰۵/۲۲
۱۳	زوارق بیمارستان	۱۷۰۶	۱۳۹۲/۳۶				

استنتاج فازی- عصبی تطبیقی شامل پنج لایه می‌باشد که در شکل (۲) نمونه طراحی شده از یک سیستم استنتاج فازی- عصبی نشان داده شده است. لایه اول: گره‌های ورودی، هر گره از این لایه مقادیر عضویتی که به هر یک از مجموعه‌های فازی مناسب تعلق دارند، با استفاده از تابع عضویت تولید می‌کند (Jang., 1993):

$$O_{i,i} = \mu_{A_i}(x) \quad \text{for } i=1,2 \quad (1)$$

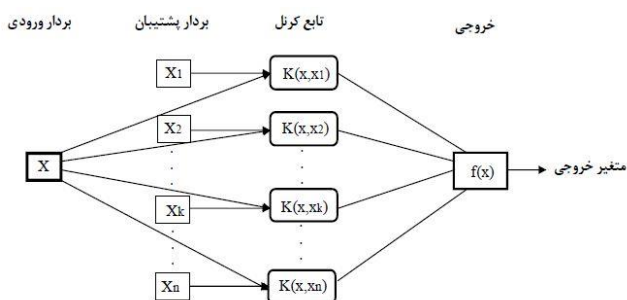
$$O_{i,i} = \mu_{B_{i-2}}(y) \quad \text{for } i=3,4 \quad (2)$$

سیستم استنتاج فازی- عصبی تطبیقی (ANFIS)

این مدل برای اولین بار توسط جانگ توسعه پیدا نمود به طوری که ضمن داشتن قابلیت یادگیری شبکه‌های عصبی و قدرت استنتاج سامانه‌های فازی، قابلیت یافتن هر نوع شبیه یا نگاشت غیرخطی را دارد و می‌تواند به طور دقیق، ورودی‌ها (مقادیر اولیه) را با خروجی (مقادیر پیش‌بینی شده) مرتبط سازد (Jang., 1993). روش استنتاج فازی شامل سه نوع سیستم پرکاربرد ممدانی، سوگنو و سوکاموتو می‌باشد. سیستم سوگنو دارای خروجی قطعی بوده و در تحقیق حاضر نیز از این سیستم استفاده شده است. ساختار سیستم سوگنو در روش

سیگنال‌های ورودی است (Jang., 1993):

$$O_{2,i} = w_i = \mu_{A_i}(x) \times \mu_{B_{i-2}}(y) \quad i=1,2 \quad (3)$$



شکل ۳- ساختار ماشین بردار پشتیبان (Yoon et al., 2011)

معرفی شد (Cortes and Vapnik., 1995). اولین کاربرد این روش در مسائل آب توسط دیبیک و همکاران با شبیه‌سازی بارش - رواناب ارائه شد (Dibike et al., 2001). ماشین بردار پشتیبان یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که از اصل استقرای کمینه‌سازی خطای ساختاری استفاده کرده و منجر به یک جواب بهینه کلی می‌گردد. شکل (۳) ساختار ماشین بردار پشتیبان را نشان می‌دهد. در مدل رگرسیون بردار پشتیبان تابعی مرتبط با متغیر وابسته y که خود تابعی از چند متغیر مستقل x است، برآورد می‌شود. رابطه میان متغیرهای مستقل و وابسته با تابع جبری مانند $f(x)$ به علاوه مقداری اغتشاش (خطای مجاز ε) مشخص می‌شود.

$$f(x) = W^T \cdot \phi(x) + b \quad (7)$$

$$y = f(x) + noise \quad (8)$$

چنانچه بردار ضرایب، b ثابت مشخصه‌های تابع رگرسیونی و $\phi(x)$ نیز تابع کرنل باشد، آنگاه هدف پیدا کردن فرم تابعی برای $f(x)$ است. این مهم با واسنجی مدل ماشین بردار پشتیبان توسط مجموعه‌ای از نمونه‌ها (مجموعه واسنجی) محقق می‌شود. برای محاسبه W^T و b لازم است تابع خطا (معادله ۹) در مدل ماشین بردار پشتیبان رگرسیونی، با در نظر گرفتن شرایط مندرج (قیود) در معادله (۱۰) بهینه شود.

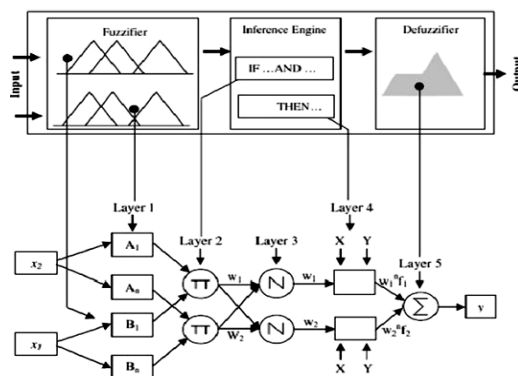
$$W^T \cdot \phi(x_i) + b - y_i \leq \varepsilon + \varepsilon_i^* \quad (9)$$

$$\frac{1}{2} W^T \cdot W + C \sum_{i=1}^N \varepsilon_i + C \sum_{i=1}^N \varepsilon_i^* y_i \quad (10)$$

$$-W^T \cdot \phi(x_i) - b \leq \varepsilon + \varepsilon_i^*$$

$$\varepsilon_i, \varepsilon_i^* \geq 0 \quad i=1,2, \dots, N$$

در روابط بالا، x یا y ورودی‌های غیرفازی به گره i و A_i و B_i برچسب‌های زبانی هستند که به ترتیب با توابع عضویت μ_{B_i} و μ_{A_i} مشخص می‌شوند. لایه دوم: گره‌های قاعده می‌باشد و هر گره در این لایه در سیگنال ورودی ضرب می‌شود و خروجی، نتیجه‌ای از تمامی



شکل ۲- ساختار مدل استنتاجی فازی - عصبی (Zare and Koch., 2018)

لایه سوم: گره‌های متوسط می‌باشد به طوری که در این لایه، i امین گره نسبت درجه فعالیت قانون i ام را به مجموع درجه فعالیت کلیه قوانین به صورت رابطه (۴) نرمال سازی می‌کند (Jang., 1993):

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i=1,2 \quad (4)$$

لایه چهارم: گره‌های نتیجه، گره i در این لایه مشارکت قانون i ام را به سمت خروجی مدل با استفاده از تابع زیر محاسبه می‌کند (Jang., 1993):

$$O_{4,i} = \bar{w}_i f = \bar{w}_i (p_i + q_i + r_i) \quad i=1,2 \quad (5)$$

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

لایه پنجم: گره‌های خروجی، تنها گره این لایه، خروجی کلی ANFIS به عنوان جمع‌بندی از تمام ورودی‌های مدل که غیرفازی شده است را مطابق زیر محاسبه می‌کند (Jang., 1993):

$$O_{5,i} = \sum_{i=1}^4 \bar{w}_i f = \frac{\sum_{i=1}^4 w_i f}{\sum_{i=1}^4 w_i} \quad (6)$$

در این تحقیق، به منظور مدل‌سازی با سیستم استنتاج فازی-عصبی تطبیقی، کدهای مورد نیاز در نرم افزار متلب تهیه شد. در کد تهیه شده، توابع عضویت مختلف تعریف شد و خروجی بهینه مدل بر اساس کمترین اختلاف با داده‌های مشاهداتی تعیین شد.

ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان یا به اختصار SVM توسط کرتز و واپنیک

$$k(x, x_i) = \frac{\exp(-\|x - x_i\|^2)}{\sigma^2} \quad (12)$$

داده‌های ورودی مدل

از جنبه‌های اولیه و مهم در استفاده از مدل ANFIS و SVM شناخت کامل و صحیح از ساختار آن است. بررسی مطالعات پیشین نشان می‌دهد، داده‌های تراز آب زیرزمینی و بارش با تاخیرهای زمانی مختلف بیشترین همبستگی را با تراز آب زیرزمینی در زمان هدف (خروجی مدل) دارند (Nayak et al., 2006; Zare and Koch., 2018). در این تحقیق نیز داده‌های مذکور با ترکیب‌های مختلف به عنوان اطلاعات ورودی مدل‌ها تعریف شد (جدول ۲). پارامترهای P_t و GWL_t به ترتیب تراز آب زیرزمینی و بارش در دوره زمانی ماهانه و P_{t-1} , P_{t-2} , GWL_{t-1} , GWL_{t-2} به ترتیب تراز آب زیرزمینی در دوره‌های زمانی گذشته و GWL_{t+1} تراز آب زیرزمینی در دوره آینده می‌باشد.

جدول ۲- ترکیب‌های مختلف داده ورودی مدل‌های هوشمند

مدل SVM			مدل ANFIS		
خروجی	ورودی	ترکیب	خروجی	ورودی	ترکیب
GWL_{t+1}	$GWL_t, GWL_{t-1}, GWL_{t-2}$	۱	GWL_{t+1}	$GWL_t, GWL_{t-1}, GWL_{t-2}$	۱
GWL_{t+1}	$GWL_t, GWL_{t-1}, GWL_{t-2}, P_t, P_{t-1}, P_{t-2}$	۲	GWL_{t+1}	$GWL_t, GWL_{t-1}, GWL_{t-2}, P_t, P_{t-1}, P_{t-2}$	۲

پارامترهای GWL و P به ترتیب تراز آب زیرزمینی و بارش ماهانه و اندیس‌های t نشان دهنده شماره ماه داده‌ها می‌باشند.

هر کدام از چاهک‌های مشاهده‌ای تهیه شد (شکل ۴). مطابق شکل ملاحظه می‌گردد، روند تغییرات تراز آب زیرزمینی به صورت نزولی بوده و سطح آب زیرزمینی در بازه زمانی ۲۲ ساله (۹۷-۱۳۷۵) حدود ۲/۵۳ متر افت داشته است. به طور کلی روند تغییرات تراز آب زیرزمینی متناسب با تغییرات بارندگی می‌باشد. کاهش بارش‌ها در سال‌های اخیر همزمان با افزایش برداشت‌ها از منابع آب زیرزمینی، اثر قابل توجهی بر کاهش تراز آب زیرزمینی داشته است. در مقابل و در بازه زمانی سال ۸۱ تا ۸۷ افزایش بارش‌ها منجر به بالا آمدن تراز آب زیرزمینی در محدوده مورد مطالعه شده است.

نتایج مدل ANFIS

مدل‌سازی‌ها با استفاده از روش ANFIS انجام و خروجی مدل‌ها با داده‌های مشاهداتی مورد مقایسه قرار گرفت. در این بخش نتایج مربوط به بهترین ساختار سیستم استنتاج فازی ارائه شده است. در جدول (۳) مقادیر مربوط به شاخص‌های آماری محاسبه شده برای ترکیب داده ورودی اول و دوم آورده شده است.

در معادلات بالا C عددی صحیح و مثبت است که عامل تعیین جرمه در هنگام رخ دادن خطای واسنجی مدل است، تابع کرنل، N تعداد نمونه‌ها و دو مشخصه \mathcal{E}_i^* و \mathcal{E}_i متغیرهای کمبود هستند (Isazadeh et al., 2017). در نهایت، تابع رگرسیون بردار پشتیبان را می‌توان به فرم زیر بازنویسی کرد:

$$f(x) = \sum_{i=1}^N \overline{\alpha}_i \cdot \phi(x_i)^T \cdot \phi(x) + b \quad (11)$$

در معادله (۱۱)، $\overline{\alpha}_i$ میانگین ضرایب لاگرانژ است. محاسبه $\phi(x)$ در فضای مشخصه آن ممکن است بسیار پیچیده باشد. برای حل این مشکل روند معمول در مدل رگرسیون بردار پشتیبان انتخاب یک تابع کرنل است. با توجه به اینکه در ماشین بردار پشتیبان معمولاً از توابع کرنل پایه شعاعی استفاده می‌گردد، در این تحقیق نیز از این تابع استفاده گردیده است. فرمول کرنل پایه شعاعی در معادله (۱۲) آورده شده است که در آن، $k(x, x_i)$ تابع کرنل نامیده می‌شود.

معیارهای آماری برای مقایسه مدل‌ها

به منظور مقایسه و ارزیابی عملکرد مدل‌های هوشمند در تخمین تراز آب زیرزمینی، از شاخص‌های آماری ضریب همبستگی پیرسون (R)، جذر میانگین مربعات خطا ($RMSE$) و میانگین قدر مطلق خطا (MAE) به شرح روابط زیر استفاده شد.

$$R = \frac{\sum_{i=1}^n (x_i - x_{mean})(y_i - y_{mean})}{\sqrt{\sum_{i=1}^n (x_i - x_{mean})^2 \sum_{i=1}^n (y_i - y_{mean})^2}} \quad (13)$$


$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2} \quad (14)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - x_i| \quad (15)$$

در روابط بالا، x_i : داده‌های اندازه‌گیری شده، y_i : داده‌های شبیه‌سازی شده، x_{mean} و y_{mean} به ترتیب میانگین داده‌های اندازه‌گیری شده، شبیه‌سازی شده و n : تعداد داده‌های مشاهداتی می‌باشند.

نتایج و بحث

پس از بازسازی و تکمیل داده‌ها، میانگین وزنی تراز آب زیرزمینی در محدوده مورد مطالعه با استفاده از شبکه پلیگون‌بندی و داده‌های



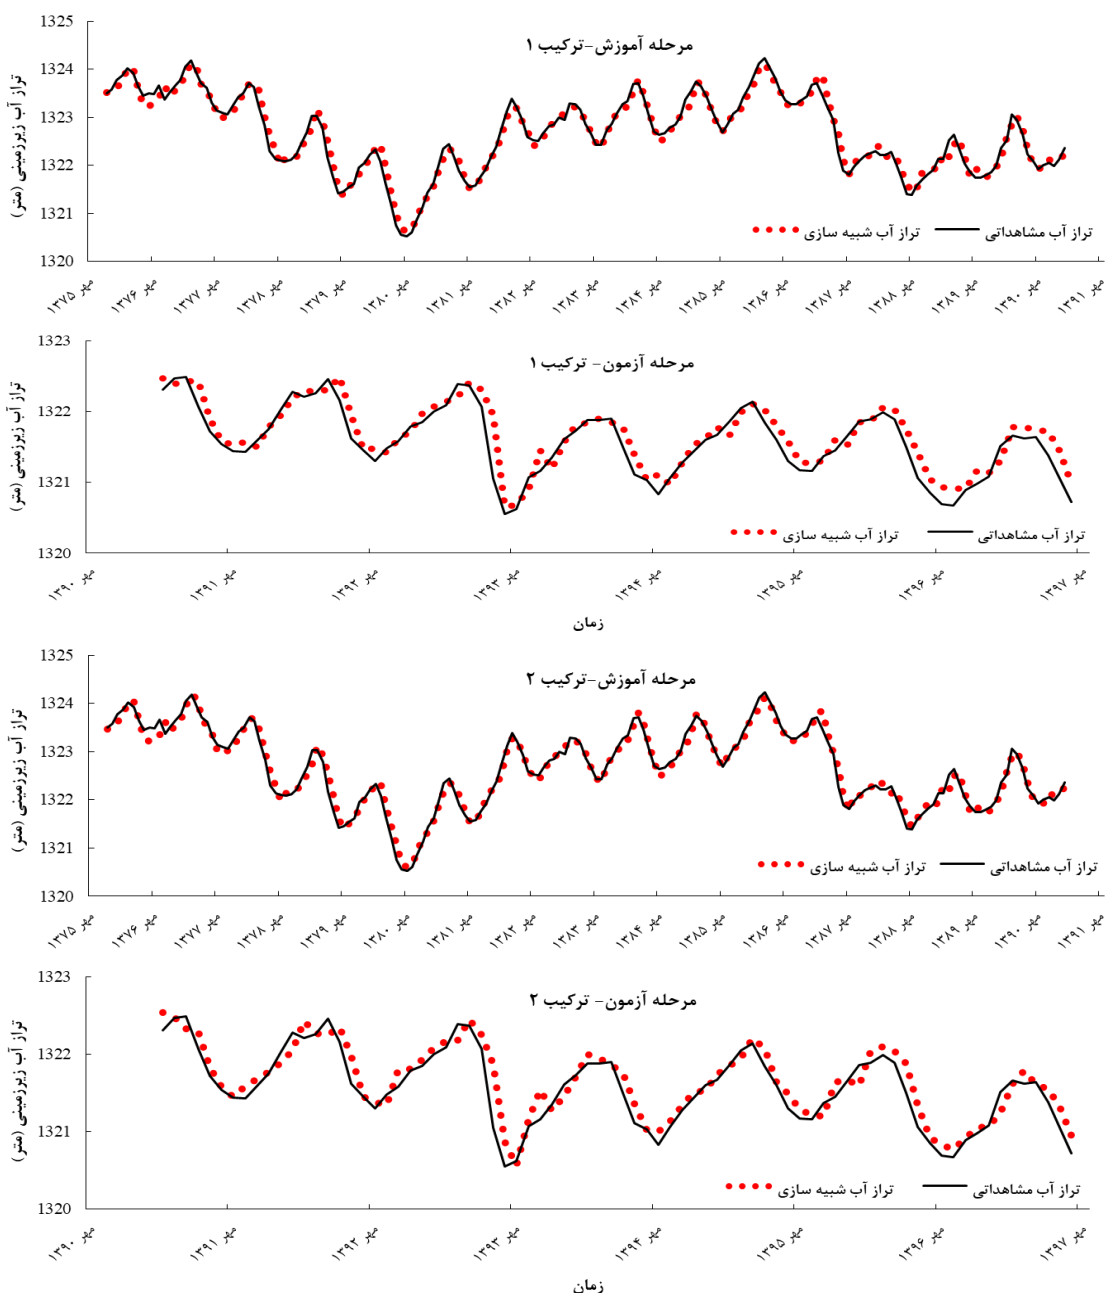
شکل ۴- میانگین تغییرات ماهانه و سالانه تراز آب زیرزمینی در محدوده مورد مطالعه (۹۷-۱۳۷۵)

جدول ۳- مقادیر شاخص‌های آماری محاسبه شده برای مدل ANFIS

شماره چاهک	ترکیب داده ورودی اول						ترکیب داده ورودی دوم					
	ضریب همبستگی		خطا میانگین مربعات		میانگین خطای مطلق (متر)		ضریب همبستگی		خطا میانگین مربعات		میانگین خطای مطلق (متر)	
	آموزش	آزمون	آموزش	آزمون	آموزش	آزمون	آموزش	آزمون	آموزش	آزمون	آموزش	آزمون
۱	۰/۹۰	۰/۹۰	۰/۶۶	۰/۷۷	۰/۵۲	۰/۶۲	۰/۹۰	۰/۸۸	۰/۶۶	۰/۸۴	۰/۵۳	۰/۶۵
۲	۰/۹۵	۰/۹۶	۰/۲۹	۰/۳۱	۰/۱۹	۰/۲۳	۰/۹۶	۰/۹۶	۰/۲۷	۰/۲۹	۰/۱۹	۰/۲۲
۳	۰/۸۶	۰/۷۲	۰/۴۴	۰/۵۳	۰/۳۲	۰/۴۲	۰/۷۲	۰/۸۷	۰/۴۳	۰/۵۰	۰/۳۱	۰/۴۱
۴	۰/۹۷	۰/۹۵	۰/۵۰	۰/۲۳	۰/۳۲	۰/۱۵	۰/۹۵	۰/۹۷	۰/۴۸	۰/۲۶	۰/۳۰	۰/۲۰
۵	۰/۹۰	۰/۷۲	۰/۴۴	۰/۹۴	۰/۲۱	۰/۶۶	۰/۷۲	۰/۹۰	۰/۴۵	۰/۷۲	۰/۲۸	۰/۵۰
۶	۰/۹۸	۰/۹۵	۰/۶۰	۰/۵۰	۰/۴۴	۰/۳۵	۰/۹۵	۰/۹۸	۰/۵۴	۰/۳۹	۰/۴۰	۰/۳۱
۷	۰/۹۴	۰/۹۴	۰/۶۲	۰/۴۸	۰/۴۴	۰/۳۷	۰/۹۴	۰/۹۶	۰/۵۵	۰/۵۵	۰/۴۱	۰/۴۴
۸	۰/۹۸	۰/۹۱	۰/۵۴	۰/۵۰	۰/۳۷	۰/۳۷	۰/۹۸	۰/۹۸	۰/۵۰	۰/۵۵	۰/۳۵	۰/۴۵
۹	۰/۸۵	۰/۸۸	۰/۲۶	۰/۱۷	۰/۱۵	۰/۱۳	۰/۸۵	۰/۸۶	۰/۲۱	۰/۱۸	۰/۱۴	۰/۱۳
۱۰	۰/۹۹	۰/۹۷	۰/۴۰	۰/۲۸	۰/۲۷	۰/۲۳	۰/۹۹	۰/۹۹	۰/۳۸	۰/۲۷	۰/۲۵	۰/۲۱
۱۱	۰/۹۰	۰/۹۲	۰/۵۵	۰/۵۶	۰/۴۱	۰/۴۴	۰/۹۰	۰/۹۱	۰/۵۱	۰/۶۱	۰/۴۰	۰/۴۸
۱۲	۰/۹۶	۰/۹۳	۰/۲۵	۰/۱۳	۰/۱۸	۰/۱۰	۰/۹۶	۰/۹۷	۰/۲۴	۰/۱۳	۰/۱۶	۰/۱۱
۱۳	۰/۹۸	۰/۹۷	۰/۵۲	۰/۵۷	۰/۳۷	۰/۴۸	۰/۹۸	۰/۹۸	۰/۴۵	۰/۴۵	۰/۳۳	۰/۳۶
۱۴	۰/۹۷	۰/۹۸	۰/۱۹	۰/۱۶	۰/۱۴	۰/۱۳	۰/۹۷	۰/۹۷	۰/۱۸	۰/۱۷	۰/۱۲	۰/۱۳
۱۵	۰/۹۶	۰/۹۶	۰/۴۲	۰/۳۲	۰/۲۸	۰/۲۵	۰/۹۶	۰/۹۷	۰/۴۰	۰/۳۷	۰/۲۷	۰/۲۶
۱۶	۰/۸۱	۰/۷۶	۰/۵۹	۰/۲۹	۰/۳۵	۰/۲۲	۰/۸۱	۰/۸۰	۰/۶۱	۰/۲۸	۰/۳۶	۰/۲۳
۱۷	۰/۸۹	۰/۹۳	۰/۳۱	۰/۴۹	۰/۲۳	۰/۳۴	۰/۸۹	۰/۹۰	۰/۲۹	۰/۴۷	۰/۲۲	۰/۳۳
۱۸	۰/۹۸	۰/۹۹	۰/۳۳	۰/۱۹	۰/۲۱	۰/۱۷	۰/۹۸	۰/۹۷	۰/۳۸	۰/۲۲	۰/۲۴	۰/۱۷
۱۹	۰/۹۷	۰/۹۳	۰/۲۷	۰/۱۸	۰/۱۸	۰/۱۴	۰/۹۷	۰/۹۸	۰/۲۳	۰/۱۸	۰/۱۵	۰/۱۴
۲۰	۰/۹۶	۰/۹۷	۰/۴۷	۰/۵۷	۰/۳۴	۰/۴۶	۰/۹۶	۰/۹۶	۰/۴۷	۰/۵۱	۰/۳۴	۰/۳۸
۲۱	۰/۹۳	۰/۹۵	۰/۲۳	۰/۲۱	۰/۱۵	۰/۱۸	۰/۹۳	۰/۹۴	۰/۲۱	۰/۱۹	۰/۱۴	۰/۱۵
۲۲	۰/۸۸	۰/۸۷	۰/۲۷	۰/۳۴	۰/۲۲	۰/۲۵	۰/۸۸	۰/۸۹	۰/۲۶	۰/۳۲	۰/۲۱	۰/۲۶
۲۳	۰/۸۹	۰/۸۸	۰/۱۶	۰/۰۶	۰/۱۲	۰/۰۵	۰/۸۹	۰/۸۷	۰/۱۷	۰/۱۰	۰/۱۳	۰/۰۹
۲۴	۰/۹۵	۰/۹۱	۰/۴۷	۰/۵۶	۰/۳۳	۰/۴۳	۰/۹۵	۰/۹۷	۰/۳۹	۰/۵۴	۰/۲۸	۰/۴۳
۲۵	۰/۹۵	۰/۹۵	۰/۳۱	۰/۲۹	۰/۲۲	۰/۲۲	۰/۹۵	۰/۹۶	۰/۲۹	۰/۲۹	۰/۲۲	۰/۲۲

آموزش در محدوده ۰/۸۰ تا ۰/۹۹ و به طور میانگین ۰/۹۴ و در مرحله آزمون در محدوده ۰/۷۴ تا ۰/۹۸ و به طور میانگین ۰/۹۱- دست آمد. مقدار ریشه میانگین مربعات خطا نیز برای مرحله آموزش در محدوده ۰/۱۷ تا ۰/۶۶ متر و به طور میانگین ۰/۳۸ متر و برای مرحله آزمون در محدوده ۰/۱۰ تا ۰/۸۴ متر و به طور میانگین ۰/۳۷ متر برآورد شد. اضافه شدن پارامتر بارش در ترکیب داده ورودی دوم منجر به کاهش خطا در ۱۴ چاهک شده است. از سوی دیگر در ۱۱ چاهک نیز مقدار RMSE افزایش یافته است.

مطابق جدول (۳) ملاحظه می‌گردد در ترکیب داده ورودی اول، مقدار ضریب همبستگی مرحله آموزش بین داده‌های مشاهداتی و شبیه‌سازی شده با روش ANFIS در محدوده ۰/۸۱ تا ۰/۹۹ و به طور میانگین ۰/۹۳ محاسبه گردید. برای مرحله آزمون نیز مقدار ضریب همبستگی در محدوده ۰/۷۲ تا ۰/۹۹ و به طور میانگین ۰/۹۱ به دست آمد. مقدار شاخص ریشه میانگین مربعات خطا برای آموزش در محدوده ۰/۱۶ تا ۰/۶۶ متر و به طور میانگین ۰/۴۰ متر و برای مرحله آزمون نیز در محدوده ۰/۰۶ تا ۰/۹۴ متر و به طور میانگین ۰/۳۹ متر تعیین شد. در ترکیب داده ورودی دوم، مقدار ضریب همبستگی مرحله

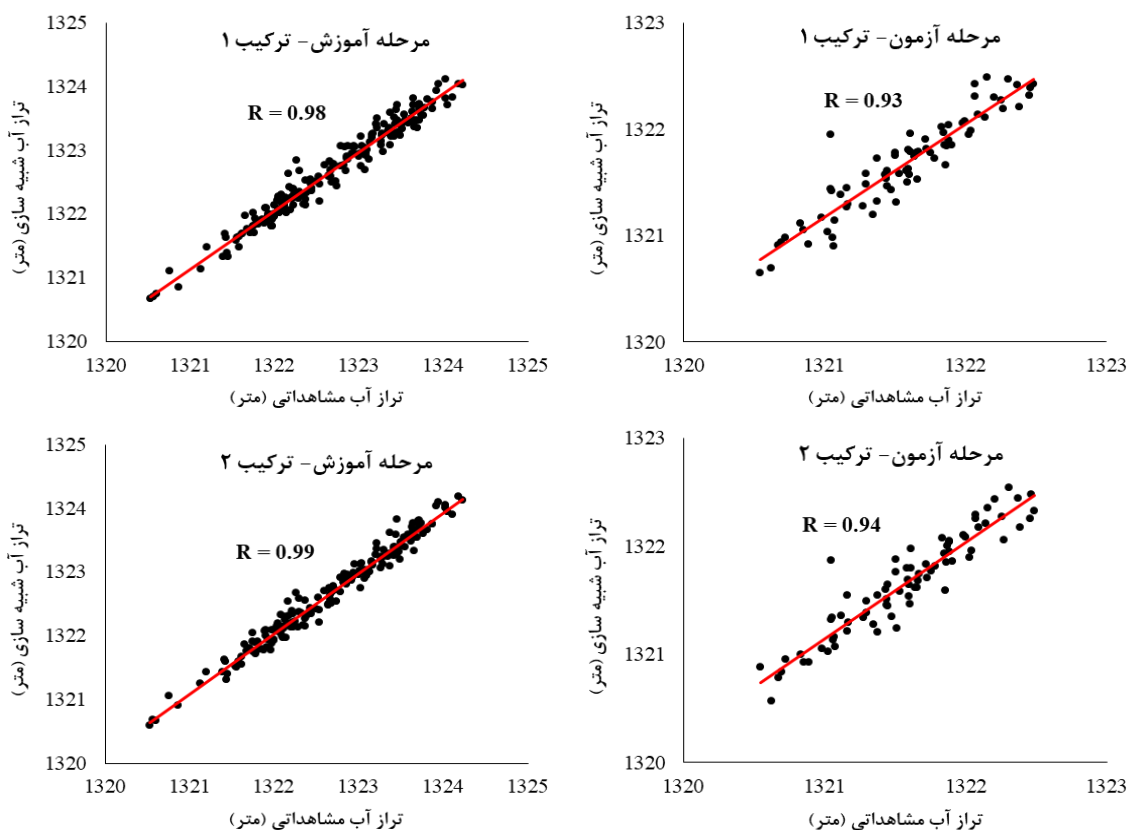


شکل ۵- میانگین تراز آب زیرزمینی مشاهده‌ای و شبیه‌سازی شده با استفاده از مدل ANFIS

تغییرات تراز آب زیرزمینی ملایم بوده است مدل ANFIS عملکرد بالایی از خود نشان داده و در برخی ماهها مثل خرداد ماه سالهای ۹۶ و ۹۷ که شیب تغییرات شدید بوده است اختلاف بین نتایج مدل و مشاهدهها بیشتر شده است. به طور کلی نتایج به دست آمده نشان دهنده عملکرد قابل قبول مدل ANFIS می باشد و می توان آن ها را با نتایج مطالعات پیشین مورد ارزیابی و مقایسه قرار داد. زارع و کخ مقادیر R^2 و RMSE محاسبه شده در مرحله صحت سنجی را با استفاده از مدل ANFIS به ترتیب ۰/۹۶ و ۰/۵۲ متر گزارش نمودند (Zare and Koch., 2016). نتایج مطالعه نورانی و موسوی نشان داد که مدل ANFIS نسبت به مدل ANN با توجه به ضریب همبستگی ۰/۹۷ و جذر میانگین مربعات خطای ۰/۰۴ عملکرد بهتری داشته است (Nourani and Mousavi., 2016).

در شکل (۶) پراکندگی مقادیر مربوط به میانگین تراز آب زیرزمینی مشاهدهای و شبیه سازی شده با استفاده از مدل ANFIS در محدوده مطالعاتی نشان داده شده است. همبستگی بالایی بین داده های مشاهداتی و شبیه سازی شده در مرحله آزمون وجود دارد و می توان بیان داشت مدل به خوبی روند تغییرات تراز آب زیرزمینی را شبیه سازی نموده است.

حداقل و حداکثر اختلاف بین شاخص RMSE ترکیب اول و دوم به ترتیب صفر و ۲۳ درصد و به طور میانگین ۹ درصد محاسبه شد. با این وجود می توان بیان داشت، اثر بارش بر عملکرد مدل ANFIS قابل توجه نمی باشد. نتایج مطالعات پیشین از جمله اسکندری و همکاران (۱۳۹۷) و زارع و کخ (Zare and Koch., 2018) نیز تایید کننده نتیجه به دست آمده می باشد، به طوری که شاخص تراز آب زیرزمینی با تاخیرهای چند ماهه به عنوان موثرترین عامل بر دقت پیش بینی ها با استفاده از مدل های هوشمند گزارش شده است. شکل (۵) نیز تراز آب زیرزمینی مشاهدهای و شبیه سازی شده با مدل ANFIS را برای ترکیب داده ورودی اول و دوم نشان می دهد. در نمودارهای ارائه شده، از میانگین وزنی تراز آب مشاهدهای و شبیه سازی شده مربوط به ۲۵ چاهک مورد مطالعه استفاده شده است. شکل های ارائه شده برای مرحله آزمون، قابلیت بالای مدل ANFIS را در شبیه سازی تراز آب زیرزمینی در محدوده مورد مطالعه نشان می دهد. در ترکیب داده ورودی اول و در برخی نقاط اوج نمودار تراز سطح ایستابی، اختلاف بین مقادیر مشاهدهای و شبیه سازی شده مشهود می باشد که در ترکیب داده ورودی دوم از این اختلاف کاسته شده است. در واقع می توان بیان داشت در ماههایی از سال که شیب



شکل ۶- همبستگی بین تراز آب زیرزمینی مشاهدهای و شبیه سازی شده با استفاده از مدل ANFIS

نتایج مدل SVM

خطا برای آموزش در محدوده ۰/۰۷ تا ۰/۶۵ متر و به طور میانگین ۰/۲۹ متر و برای مرحله آزمون نیز در محدوده ۰/۰۵ تا ۰/۷۸ متر و به طور میانگین ۰/۴۰ متر به دست آمد. مقادیر شاخص‌های آماری مذکور برای ترکیب داده ورودی دوم نیز محاسبه شد به طوری که مقدار ضریب همبستگی مرحله آموزش در محدوده ۰/۸۶ تا ۰/۹۹ و به طور میانگین ۰/۹۵ و در مرحله آزمون در محدوده ۰/۸۰ تا ۰/۹۷ و به طور میانگین ۰/۹۲ می‌باشد. مقدار ریشه میانگین مربعات خطا برای مرحله آموزش در محدوده ۰/۱۷ تا ۰/۶۶ متر و به طور میانگین ۰/۳۵ متر و برای مرحله آزمون در محدوده ۰/۰۸ تا ۰/۷۷ متر و به طور میانگین ۰/۳۹ متر تعیین شد. در این مدل نیز اضافه شدن پارامتر بارش در ترکیب داده ورودی دوم منجر به کاهش خطا در ۹ چاهک شده است.

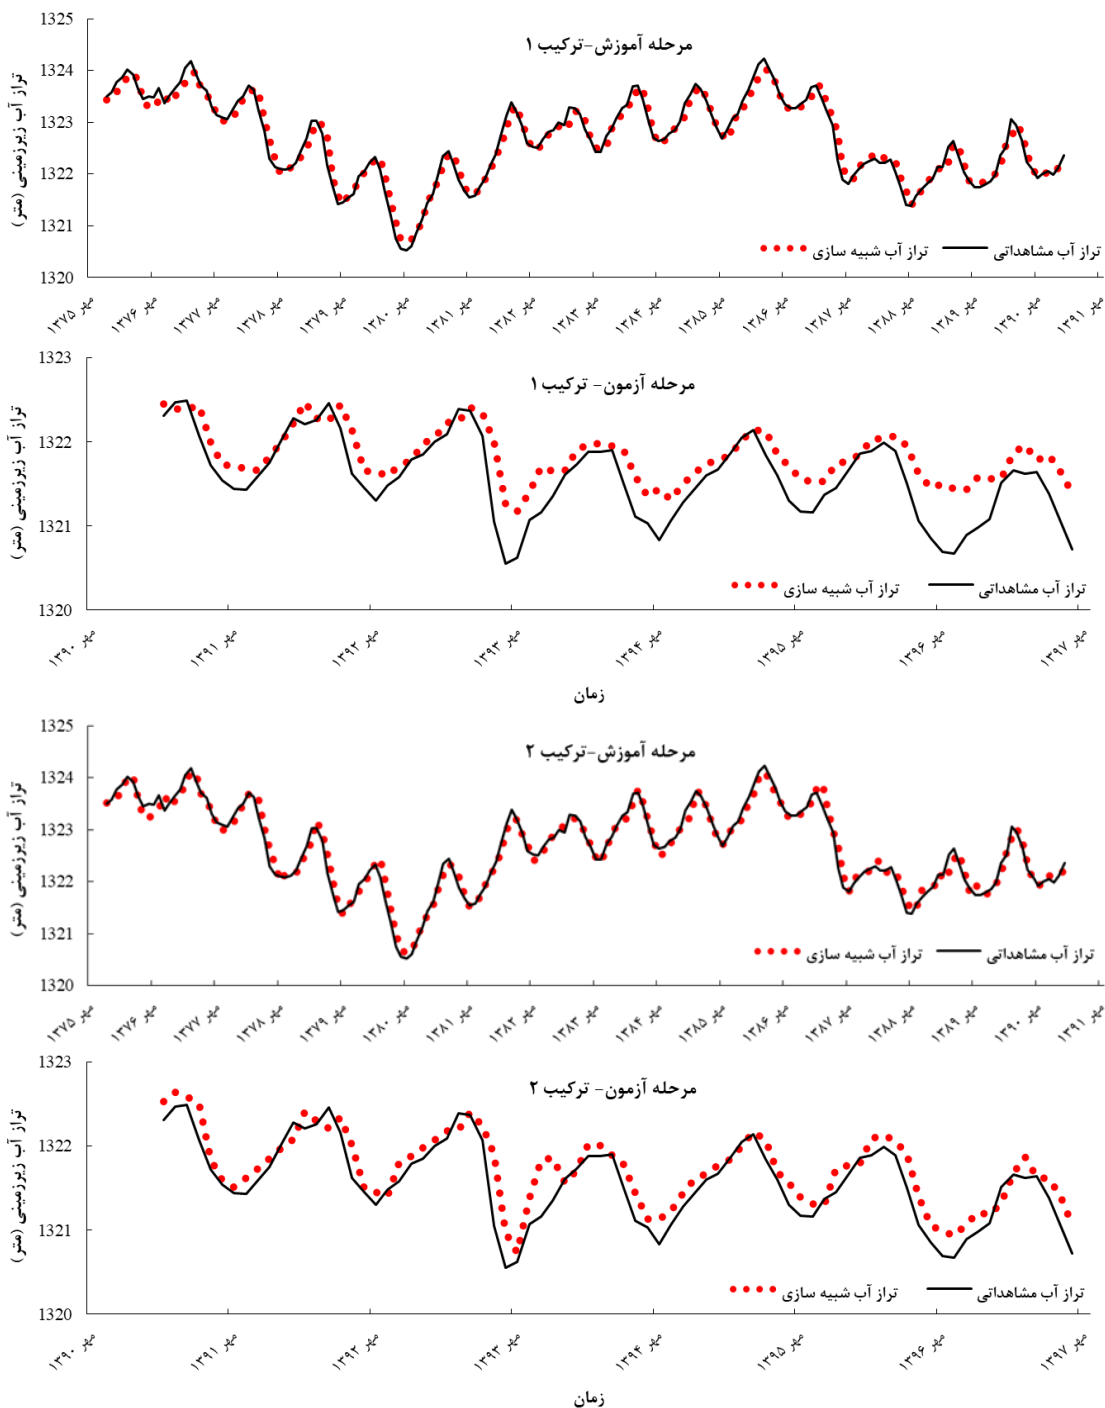
مدل‌سازی‌ها با استفاده از روش ماشین بردار پشتیبان انجام و خروجی مدل‌ها با داده‌های مشاهداتی مورد مقایسه قرار گرفت. در مدل SVM بهترین عملکرد مربوط به تابع کرنل پایه شعاعی بود و لذا تمامی نتایج ارائه شده نیز به همین تابع مرتبط می‌باشد. در جدول (۴) مقادیر مربوط به شاخص‌های آماری محاسبه شده ارائه گردیده است. در ترکیب داده ورودی اول، مقدار ضریب همبستگی مرحله آموزش بین داده‌های مشاهداتی و شبیه‌سازی شده با روش SVM در محدوده ۰/۸۷ تا ۰/۹۹ و به طور میانگین ۰/۹۴ محاسبه گردید. برای مرحله آزمون نیز مقدار ضریب فوق در محدوده ۰/۷۴ تا ۰/۹۸ و به طور میانگین ۰/۹۱ به دست آمد. مقدار شاخص ریشه میانگین مربعات

جدول ۴- مقادیر شاخص‌های آماری محاسبه شده برای مدل SVM

شماره چاهک	ترکیب داده ورودی اول						ترکیب داده ورودی دوم					
	ضریب همبستگی		جذر میانگین مربعات خطا (متر)		میانگین خطای مطلق (متر)		ضریب همبستگی		جذر میانگین مربعات خطا (متر)		میانگین خطای مطلق (متر)	
	آموزش	آزمون	آموزش	آزمون	آموزش	آزمون	آموزش	آزمون	آموزش	آزمون	آموزش	آزمون
۱	۰/۹۰	۰/۹۰	۰/۶۵	۰/۷۸	۰/۵۳	۰/۶۳	۰/۹۱	۰/۹۱	۰/۶۶	۰/۷۷	۰/۵۴	۰/۶۲
۲	۰/۹۶	۰/۹۶	۰/۲۷	۰/۳۱	۰/۱۷	۰/۲۲	۰/۹۶	۰/۹۶	۰/۲۸	۰/۳۲	۰/۱۹	۰/۲۳
۳	۰/۹۰	۰/۸۱	۰/۱۵	۰/۳۷	۰/۲۹	۰/۳۰	۰/۸۹	۰/۸۲	۰/۴۰	۰/۴۲	۰/۳۰	۰/۳۷
۴	۰/۹۸	۰/۹۵	۰/۳۴	۰/۲۳	۰/۲۵	۰/۱۶	۰/۹۹	۰/۹۳	۰/۳۲	۰/۲۴	۰/۲۴	۰/۱۷
۵	۰/۸۹	۰/۸۰	۰/۲۲	۰/۶۶	۰/۲۳	۰/۴۵	۰/۹۱	۰/۸۵	۰/۴۵	۰/۵۶	۰/۲۳	۰/۴۰
۶	۰/۹۸	۰/۹۷	۰/۴۱	۰/۵۴	۰/۳۹	۰/۴۴	۰/۹۹	۰/۹۵	۰/۵۱	۰/۶۲	۰/۳۶	۰/۴۸
۷	۰/۹۴	۰/۹۵	۰/۴۰	۰/۳۹	۰/۴۲	۰/۳۱	۰/۹۶	۰/۹۳	۰/۵۴	۰/۵۲	۰/۳۸	۰/۴۰
۸	۰/۹۸	۰/۹۴	۰/۲۵	۰/۶۰	۰/۳۱	۰/۵۳	۰/۹۸	۰/۹۱	۰/۴۰	۰/۵۷	۰/۳۰	۰/۴۴
۹	۰/۹۲	۰/۹۰	۰/۱۷	۰/۱۶	۰/۱۳	۰/۱۳	۰/۹۱	۰/۹۱	۰/۱۷	۰/۱۵	۰/۱۳	۰/۱۲
۱۰	۰/۹۹	۰/۹۷	۰/۱۷	۰/۲۱	۰/۲۷	۰/۱۷	۰/۹۹	۰/۹۶	۰/۳۳	۰/۲۲	۰/۲۳	۰/۱۷
۱۱	۰/۹۱	۰/۹۵	۰/۵۲	۰/۵۰	۰/۳۹	۰/۴۲	۰/۹۱	۰/۹۳	۰/۴۹	۰/۵۴	۰/۳۸	۰/۴۴
۱۲	۰/۹۶	۰/۹۲	۰/۰۷	۰/۱۳	۰/۱۹	۰/۱۱	۰/۹۸	۰/۹۱	۰/۲۰	۰/۱۳	۰/۱۵	۰/۱۱
۱۳	۰/۹۸	۰/۹۴	۰/۲۲	۰/۶۰	۰/۳۳	۰/۴۸	۰/۹۸	۰/۹۶	۰/۴۶	۰/۵۶	۰/۳۳	۰/۴۶
۱۴	۰/۹۷	۰/۹۸	۰/۱۸	۰/۱۸	۰/۱۳	۰/۱۴	۰/۹۷	۰/۹۷	۰/۱۹	۰/۱۷	۰/۱۳	۰/۱۳
۱۵	۰/۹۸	۰/۹۶	۰/۳۲	۰/۳۲	۰/۲۴	۰/۲۴	۰/۹۸	۰/۹۶	۰/۳۳	۰/۳۴	۰/۲۳	۰/۲۵
۱۶	۰/۹۲	۰/۸۸	۰/۳۸	۰/۲۱	۰/۲۹	۰/۱۷	۰/۹۴	۰/۸۰	۰/۳۲	۰/۲۶	۰/۲۶	۰/۲۰
۱۷	۰/۹۰	۰/۹۱	۰/۳۰	۰/۴۷	۰/۲۳	۰/۳۴	۰/۹۱	۰/۹۲	۰/۳۰	۰/۶۰	۰/۲۳	۰/۴۳
۱۸	۰/۹۸	۰/۹۵	۰/۳۰	۰/۳۸	۰/۲۰	۰/۲۸	۰/۹۸	۰/۹۵	۰/۳۱	۰/۴۱	۰/۲۱	۰/۳۲
۱۹	۰/۹۸	۰/۹۳	۰/۱۹	۰/۱۷	۰/۱۴	۰/۱۳	۰/۹۸	۰/۹۴	۰/۲۳	۰/۱۷	۰/۱۶	۰/۱۳
۲۰	۰/۹۷	۰/۹۱	۰/۴۱	۰/۹۸	۰/۲۹	۰/۸۰	۰/۹۶	۰/۹۶	۰/۴۵	۰/۸۳	۰/۳۳	۰/۶۸
۲۱	۰/۹۴	۰/۹۴	۰/۲۲	۰/۲۱	۰/۱۴	۰/۱۷	۰/۹۴	۰/۹۵	۰/۲۲	۰/۲۲	۰/۱۵	۰/۱۷
۲۲	۰/۸۷	۰/۷۴	۰/۲۹	۰/۶۴	۰/۲۳	۰/۵۲	۰/۸۸	۰/۹۲	۰/۲۹	۰/۳۳	۰/۲۴	۰/۲۸
۲۳	۰/۸۸	۰/۸۹	۰/۱۷	۰/۰۵	۰/۱۳	۰/۰۴	۰/۸۶	۰/۸۵	۰/۱۹	۰/۰۸	۰/۱۴	۰/۰۷
۲۴	۰/۹۵	۰/۸۵	۰/۴۷	۰/۶۹	۰/۳۳	۰/۵۲	۰/۹۱	۰/۹۱	۰/۴۰	۰/۵۹	۰/۲۹	۰/۴۴
۲۵	۰/۹۸	۰/۹۳	۰/۲۲	۰/۳۳	۰/۱۶	۰/۲۵	۰/۹۷	۰/۹۷	۰/۲۷	۰/۲۵	۰/۲۰	۰/۲۱

ترکیب داده ورودی اول، اختلاف قابل توجهی بین نقاط اوج و فرود منحنی تراز آب زیرزمینی مشاهده‌ای و شبیه‌سازی شده وجود دارد. شکل (۷) تراز آب زیرزمینی مشاهده‌ای و شبیه‌سازی شده با مدل SVM را برای ترکیب داده ورودی اول و دوم نشان می‌دهد.

از سوی دیگر در ۱۶ چاهک، مقدار RMSE افزایش یافته است. حداقل و حداکثر اختلاف بین شاخص RMSE ترکیب اول و دوم به ترتیب صفر و ۳۳ درصد و به طور میانگین ۱۴ درصد محاسبه شد. در نتیجه، مدل SVM نیز مشابه ANFIS توانسته با دقت قابل قبولی تراز آب زیرزمینی را در محدوده مورد مطالعه شبیه‌سازی نماید. در







شکل ۷- میانگین تراز آب زیرزمینی مشاهده‌ای و شبیه‌سازی شده با استفاده از مدل SVM

مقادیر R و RMSE را برای دوره ماهانه با استفاده از مدل ماشین بردار پشتیبان به ترتیب برابر ۰/۹۶ و ۰/۱۳۴ محاسبه نمودند (Behzad et al., 2010). نتایج مطالعه آخونی‌پورحسینی و اسدی (۱۳۹۶) حاکی از برتری مدل ماشین بردار پشتیبان نسبت به شبکه بیزین باتوجه به ضریب همبستگی ۰/۹۹، میانگین خطای مطلق ۰/۲۰۴ و جذر میانگین مربعات خطا ۰/۳۰۷ می‌باشد. در این روش نیز همبستگی مناسبی بین داده‌های مشاهداتی و شبیه‌سازی شده در مرحله آزمون وجود دارد. همانطور که ملاحظه می‌گردد، مقدار همبستگی در ترکیب داده ورودی دوم نسبت به اول مقداری جزئی افزایش یافته است.

نتیجه‌گیری

پیش‌بینی صحیح و مطمئن تراز آب زیرزمینی یکی از مهم‌ترین مسائل مربوط به مدیریت منابع آب زیرزمینی می‌باشد. در این مطالعه، داده‌های ماهانه سطح ایستابی ۲۵ چاهک مشاهده‌ای در یک دوره زمانی ۲۲ ساله به منظور ارزیابی و مقایسه عملکرد مدل‌های ANFIS و SVM در شبیه‌سازی تراز آب زیرزمینی مورد استفاده قرار گرفت.

مطابق شکل (۷) ملاحظه می‌گردد، در هر سال آبی، تراز آب زیرزمینی در ماه‌های انتهایی فصل تابستان و اوایل فصل پاییز به کمترین مقدار خود رسیده است. بالا رفتن برداشت آب در فصل تابستان از طریق چاه‌های آب بخش کشاورزی مهمترین دلیل موضوع اشاره شده می‌باشد. بیشترین اختلاف بین نتایج مدل و مشاهده‌ای نیز مربوط به ماه‌های اشاره شده می‌باشد و به عبارتی خطای مدل‌های هوشمند در شبیه‌سازی تراز آب زیرزمینی در ماه‌های اوج برداشت آب نسبت به سایر ماه‌ها بیشتر می‌باشد. البته با اضافه شدن پارامتر بارش در ترکیب داده ورودی دوم از میزان این اختلاف به طور قابل توجهی کاسته شده است. پارامتر بارش اثر قابل توجهی بر افزایش دقت مدل SVM داشته است و استفاده از تاخیرهای زمانی این پارامتر در شبیه‌سازی‌ها، منجر به افزایش همبستگی بین داده‌ها به خصوص در نقاط کمینه و بیشینه تراز آب زیرزمینی شده است. در شکل (۸) پراکندگی مقادیر مربوط به میانگین تراز آب زیرزمینی مشاهده‌ای و شبیه‌سازی شده با استفاده از مدل SVM نشان داده شده است. مشابه مدل ANFIS، می‌توان بیان داشت دقت مدل SVM قابل قبول می‌باشد و مقادیر خطای مدل در تحقیق حاضر را می‌توان با نتایج مطالعات پیشین در این زمینه مورد ارزیابی و مقایسه قرار داد. بهزاد و همکاران



شکل ۸- همبستگی بین تراز آب زیرزمینی مشاهده‌ای و شبیه‌سازی شده با استفاده از مدل SVM

چوبین، ب.، ملکبان، آ.، ساجدی حسینی، ف. و رحمتی، ا. ۱۳۹۳. پیش‌بینی سطح ایستابی با استفاده از سری‌های زمانی و سیستم استنباط فازی - عصبی تطبیقی. تحقیقات آب و خاک ایران. ۴۵: ۱۹-۲۸.

رضایی، ا.، خاشعی سیوکی، ع. و شهیدی، ع. ۱۳۹۳. طراحی شبکه پایش سطح آب زیرزمینی با استفاده از مدل حداقل مربعات ماشین بردار پشتیبان (LS-SVM). تحقیقات آب و خاک ایران. ۴۵: ۴: ۳۸۹-۳۹۶.

عیسی‌زاده، م.، بی‌آزار، س. م.، اشرف‌زاده، ا. و خانجانی، ر. ۱۳۹۷. تخمین پارامترهای کیفی آبخوان دشت گیلان با استفاده از آزمون گاما و مدل‌های ماشین بردار پشتیبان و شبکه عصبی مصنوعی. علوم و تکنولوژی محیط زیست. ۲۰: ۶: ۵-۲۱.

کرد، م.، یوسفی، ن. و نوین‌پور، ا. ع. ۱۳۹۸. مقایسه روش‌های سیستم استنتاج فازی-عصبی تطبیقی (ANFIS)، وزن‌دهی معکوس فاصله و زمین آمار در تخمین سطح ایستابی (مطالعه موردی: دشت دهگلان، استان کردستان). اکو هیدرولوژی. ۶: ۱: ۶۴-۵۱.

گویلی، س.، جوادی، س.، بنی‌حیب، م. ا. و ثانی‌خانی، ه. ۱۳۹۷. مقایسه مدل‌های هوشمند در پیش‌بینی نوسانات تراز سطح آب دریاچه زریوار با در نظرگیری تراز آب زیرزمینی. تحقیقات منابع آب ایران. ۱۴: ۳: ۳۳۹-۳۴۴.

Behzad, M., Asghari, K. and Coppola, E.JR. 2010. Comparative study of SVMs and ANNs in aquifer water level prediction. Journal of Computing in Civil Engineering. 24: 408-413.

Cortes, C. and Vapnik, V. 1995. Support Vector Networks. Machine Learning. 20: 273-297.

Demirci, M., Unes, F. and Korlu, S. 2019. Modeling of groundwater level using artificial intelligence techniques: a case study of reyhanli region in turkey. Ecology and Environmental Research. 17. 2: 2651-2663.

Dibike, Y., Velickov, S., Solomatine, D. and Abbott, M. 2001. Model induction with of support vector machines: Introduction and applications. Journal of Computing in Civil Engineering. 15: 208-216.

Djurovic, N., Domazet, N., Stricevic, R., Pocuca, V., Spalevic, V., Pivic, R., Gregoric, E. and Domazet, U. 2015. Comparison of groundwater level models based on artificial neural networks and ANFIS. The Scientific World Journal. 2: 1-13.

Emamgholizadeh, S., Moslemi, K. and Karami, G. H. 2014. Prediction the groundwater level of Bastam Plain (Iran) by Artificial Neural Network (ANN) and

مقایسه نتایج به دست آمده از دو روش مورد مطالعه نشان داد، عملکرد هر دو روش قابل قبول بوده و اختلاف قابل توجهی بین روش ANFIS و SVM وجود ندارد. خطای برآورد شده برای روش ANFIS حدود ۵ درصد کمتر از روش SVM بود و لذا می‌توان بیان داشت روش ANFIS از برتری جزئی نسبت به روش SVM برخوردار بوده است. تحلیل حساسیت مدل ANFIS نشان داد که از بین پارامترهای استفاده شده در این تحقیق، پارامتر سطح آب زیرزمینی دارای بیشترین اهمیت می‌باشد. نتایج بدست آمده از ترکیب داده ورودی اول شامل سه تاخیر زمانی سطح ایستابی و ترکیب داده ورودی دوم شامل سه تاخیر زمانی سطح ایستابی و بارش نشان داد، اضافه شدن پارامتر بارش ماهانه به داده‌های ورودی، اثر قابل توجهی بر دقت این مدل نداشته است. با این وجود در مدل SVM منجر به کاهش اختلاف بین مقادیر مشاهداتی و شبیه‌سازی شده در نقاط بیشینه و کمینه تراز آب زیرزمینی شده است. با توجه به دقت قابل قبول مدل ANFIS در شبیه‌سازی نوسانات آب زیرزمینی، می‌توان از مدل مذکور به منظور پیش‌بینی‌های میان مدت تراز آب زیرزمینی در منطقه مورد مطالعه استفاده نمود. در واقع با استفاده از تاخیرهای زمانی تراز آب زیرزمینی به عنوان ورودی مدل، می‌توان تراز آب زیرزمینی را در ماه‌های آینده با درجه اعتمادپذیری بالا پیش‌بینی نمود.

منابع

آخونی‌پور حسینی، ف. و اسدی، ا. ۱۳۹۶. کاربرد شبکه بیزین و مدل ماشین بردار پشتیبان در پیش‌بینی تغییرات سطح تراز ایستابی (مطالعه موردی: دشت اردبیل). علوم و مهندسی آبخیزداری ایران. ۱۱: ۳۶-۴۲: ۳۳.

اسکندری، ع.، فرامرزیان یاسوج، ف.، سلگی، ا. و زارعی، ح. ۱۳۹۷. ارزیابی ترکیب ANFIS با تبدیل موجک برای مدل‌سازی و پیش‌بینی سطح آب زیرزمینی. پژوهشنامه مدیریت حوزه آبخیز. ۹: ۱۸: ۵۶-۶۹.

اسکندری، ع.، سلگی، ا. و زارعی، ح. ۱۳۹۷. شبیه‌سازی نوسانات سطح آب زیرزمینی با استفاده از ترکیب ماشین بردار پشتیبان و تبدیل موجک. علوم و مهندسی آبیاری دانشگاه شهید چمران اهواز. ۴۱: ۱: ۱۸۰-۱۶۵.

اکبرزاده، ف.، حسن‌پور، ح. و امامقلی‌زاده، ص. ۱۳۹۵. پیش‌بینی تراز آب زیرزمینی دشت شاهرود با استفاده از شبکه عصبی مصنوعی تابع پایه شعاعی. پژوهشنامه مدیریت حوزه آبخیز. ۷: ۱۳: ۱۱۸-۱۰۴.

- 536: 10 -25.
- Nourani, V., Alami, M.T. and Aminfar, M.H. 2009. Combined neural - wavelet model for prediction of Ligvanchayi watershed precipitation. *Engineering Applications of Artificial Intelligence*. 22: 466–472.
- Shiri, J. and Kisi, O. 2011. Comparison of genetic programming with neuro-fuzzy systems for predicting short-term water table depth fluctuations. *Computers and Geosciences*. 37: 1692–1701.
- Yadav, B. and Eliza, Kh. 2017. A hybrid Wavelet-Support Vector Machine model for prediction of lake water level fluctuations using Hydro-Meteorological data. *Measurement*. 10: 294-301.
- Yoon, H., Jun, S.C., Hyun, Y., Bae, G.O. and Lee, K.K. 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.
- Yu, P.S., Chen, S.T. and Chang, I.F. 2006. Support vector regression for real-time flood stage forecasting. *Journal of Hydrology*. 328: 704-716.
- Zare, M. and Koch, M. 2016. Using ANN and ANFIS Models for simulating and predicting groundwater level fluctuations in the Miandarband Plain, Iran. 4th IAHR Europe Congress, Liege, Belgium: 416-423.
- Zare, M. and Koch, M. 2018. Groundwater level fluctuations simulation and prediction by ANFIS-and hybrid Wavelet-ANFIS/Fuzzy C-Means (FCM) clustering models: Application to the Miandarband plain. *Journal of Hydro-Environment Research*. 18: 63-76.
- Adaptive Neuro-Fuzzy Inference System (ANFIS). *Water Resources Management*. 28: 5433–5446.
- Gong, Y., Zhang, Y., Lan, S. and Wang, H. 2015. A comparative study of Artificial Neural Networks, Support Vector Machines and Adaptive Neuro Fuzzy Inference System for forecasting groundwater levels near lake Okeechobee, Florida. *Water Resources Management*. 30: 375–391.
- 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: 610.
- Jang, J.S.R. 1993. ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man and Cybernetics*. 23.3: 665-685.
- Lijun, F. and Shuquan, L. 2007. Forecasting the runoff using least square support vector machine. *Tianjin Teaching Committee. TJGL06-099: 884-889.*
- Moosavi, V., Vafakhah, M., Shirmohammadi, B. and Behnia, N. 2013. A Wavelet–ANFIS Hybrid Model for groundwater level forecasting for different prediction periods. *Water Resources Management*. 27: 1301-1321.
- Nayak, P. C., Satyaji Rao, Y. R. and Sudheer, K. P. 2006. Groundwater level forecasting in a shallow aquifer using artificial neural network approach. *Water Resources Management*. 20: 77–90.
- Nourani, V. and Mousavi, SH. 2016. Spatiotemporal groundwater level modeling using hybrid artificial intelligence-meshless method. *Journal of Hydrology*.

Groundwater Level Fluctuation Simulation Using Support Vector Machines and Adaptive Neuro Fuzzy Inference System (Case Study: Maragheh Plain)

M.M. Jafari¹, H. Ojaghlou*², M. Zare³

Received: Feb.14, 2020

Accepted: Apr.29, 2020

Abstract

In order to optimal management of groundwater resources, accurate estimate of groundwater level fluctuations is required. In recent years, the use of artificial intelligence methods based on data mining theory has increasingly attracted researchers' attention. The purpose of the present study is to compare the performance of adaptive neuro-fuzzy inference system (ANFIS) and support vector machine (SVM) methods to simulate groundwater level fluctuations. A 22-year dataset (1996-2018) including hydrological parameters such as monthly precipitation (P) and groundwater level (GL) from 25 observation wells in some parts of Maragheh plain located in East Azarbaijan province were used as models input data. The average groundwater level in the study area is 1321 m and the annual precipitation and temperature was calculated 294 mm and 14 °C, respectively. Mean values of statistical indices of correlation coefficients and root mean square error were calculated 0.91 and 0.38 m for the ANFIS model and 0.92 and 0.40 m for the SVM model, respectively. Results showed that the addition of monthly precipitation parameter to the input data had no significant effect on the accuracy of the ANFIS model, however, the model prediction accuracy increased by 14% for the SVM model. In general, the simulation accuracy of both models was acceptable. However, it can be stated that the ANFIS model has a slight advantage over the SVM model.

Keywords: Groundwater level, Simulation, Intelligent models

1 - M.Sc Student of Irrigation and Drainage, Department of Water Science and Engineering, University of Zanjan

2 - Assistant Professor, Department of Water Science and Engineering, University of Zanjan

3 - Research Scientist, Leibniz Institute for Agricultural Engineering and Bioeconomy (ATB), Potsdam, Germany

(* - Corresponding Author Email: ojaghlou@znu.ac.ir)