

تخمین تغییرات زمانی و مکانی سطح آب زیرزمینی با تلفیق مدل‌های هوشمند و روش‌های زمین آماری (دشت سمنان)

مبینا ربیعی^۱، حجت کرمی^{۲*}

تاریخ ارسال: ۱۳۹۸/۰۶/۰۷

تاریخ پذیرش: ۱۳۹۸/۱۱/۲۹

مقاله پژوهشی برگرفته از پایان‌نامه کارشناسی ارشد

چکیده

به دلیل پیچیدگی‌های موجود در طبیعت سیستم‌های آب زیرزمینی و همچنین محدودیت‌های موجود در حفر گمانه‌ها، مدل‌سازی زمانی و مکانی تراز آب زیرزمینی به آسانی میسر نمی‌باشد. به منظور یافتن راهکارهایی مفید برای پیش‌بینی زمانی-مکانی سطح آب زیرزمینی، از روش‌های هوش مصنوعی مانند RBF, ANN, SVR, ANFIS و مدل‌سازی ARIMA و ترکیب آن‌ها با روش‌های زمین آماری استفاده شده است. مطالعه موردی این تحقیق دشت سمنان می‌باشد. مرحله اول، مدل‌سازی زمانی سطح آب زیرزمینی با استفاده از روش‌های مختلف انجام گرفته است. نتایج نشان داد که مدل ANFIS نسبت به روش‌های دیگر پیش‌بینی ماهانه تراز آب زیرزمینی را در مرحله آزمایش با دقت بالاتری ارائه می‌دهد ($R^2 = 0.994$ و $RMSE = 0.041$). مرحله بعد، از داده‌های خروجی ANFIS، به عنوان داده‌های ورودی مدل زمین‌آمار استفاده شده است و مدل کریجینگ خطی به عنوان بهترین مدل برای توسعه مکانی تراز آب زیرزمینی انتخاب گردیده است ($R^2 = 0.8889$ و $RMSE = 2.376$). نتایج این پژوهش نشان داد که تلفیق مدل ANFIS و مدل کریجینگ خطی، یک روش مناسب برای پیش‌بینی زمانی و مکانی تراز آب زیرزمینی می‌باشد.

واژه‌های کلیدی: پیش‌بینی زمانی، پیش‌بینی مکانی، تراز آب زیرزمینی، زمین‌آمار، ANFIS.

^۱ دانشجوی کارشناسی ارشد مهندسی و مدیریت منابع آب، دانشکده مهندسی عمران، دانشگاه سمنان. mobina.rabee@semnan.ac.ir

^۲ دانشیار دانشکده مهندسی عمران، دانشگاه سمنان، سمنان، ایران، ۰۹۱۲۴۸۰۳۳۵۰. hkarami@semnan.ac.ir * (نویسنده مسئول)

مقدمه

در راستای سیر صعودی جمعیت، نیاز آبی افزایش یافته است. بگونه‌ای که با کاهش آب‌های سطحی، بشر مجبور به استفاده از آب‌های زیرزمینی بخصوص در مناطق خشک و نیمه خشک شده است. استفاده بیش از حد از این منابع با مشکلاتی از قبیل خشک شدن چاه‌های آب، افزایش هزینه پمپاژ و نشست زمین روبرو شده است. باتوجه به محدودیت زمانی و میزان کم ریزش‌های جوی باید کلیه برنامه‌ریزی‌های کوتاه‌مدت و بلندمدت تأمین آب در این مناطق بر مبنای حجم آب زیرزمینی در دسترس باشد. به دلیل اهمیت بالای منابع آب زیرزمینی در این مناطق و همچنین به منظور جلوگیری از مشکلات نامبرده بایستی پیش‌بینی دقیقی از حجم این منابع صورت گیرد (حبیبی و همکاران، ۱۳۹۴). در دهه اخیر محاسبات انجام شده در بازه‌های زمانی مکرر، نیازمند استفاده از حجم انبوهی از داده‌ها، صرف هزینه و زمان بیشتر بوده است (کماسی و همکاران، ۱۳۹۶). استفاده از مدل‌های هوشمند نظیر منطق فازی، شبکه‌های عصبی مصنوعی، الگوریتم ژنتیک، سیستم‌های عصبی-فازی، برنامه‌ریزی فازی-ژنتیک، به دلیل سرعت پردازش بالا، دقت زیاد و صرف هزینه و زمان کمتر نسبت به روش‌های دیگر در علوم مختلف بالاخص آب‌های زیرزمینی مورد استفاده قرار گرفته‌اند. به دلیل وجود پارامترهای مختلف نظیر هیدرولوژیکی و هیدروژئولوژیکی ارزیابی تغییرات و پیش‌بینی آب زیرزمینی مسأله‌ای پیچیده می‌باشد. بدین منظور، استفاده از مدل‌های زمین‌آمار در پیش-بینی مکانی تراز آب‌های زیرزمینی کاربرد وسیعی دارند. (Yoon et al., 2011) به منظور پیش‌بینی سطح آب زیرزمینی یک آبخوان ساحلی، شبکه عصبی مصنوعی و ماشین‌بردار پشتیبان را مقایسه کرده است. از میان متغیرهای احتمالی، سطح آب زیرزمینی پیشین، بارش و سطح جذر و مد به عنوان ساختار ورودی برگزیده شده است، سطح آب زیرزمینی پیشین به‌عنوان مؤثرترین متغیر ورودی انتخاب شده است. با وجود اینکه عملکرد مدل SVM شبیه و حتی در مواردی بهتر از ANN

بوده است، اما خطای مدل ANN کمتر از مدل SVM در مراحل آموزش و آزمون بوده است. همچنین ANN عدم قطعیت بالاتری را به همراه داشته است. (Porte et al., 2018) پیش‌بینی سطح آب زیرزمینی با استفاده از ANN را در نظر گرفته‌اند. که داده‌های بارندگی بیست سال، از سال ۱۹۹۶ تا ۲۰۱۵ به عنوان ورودی شبکه عصبی برای پیش‌بینی تراز آب زیرزمینی استفاده شد. نتایج حاصل نمایانگر پیش‌بینی خوب و قابل اطمینان این الگوریتم بوده است. (Das et al., 2019) مدل‌سازی عمق تراز آب را با استفاده از ANFIS انجام داده‌اند. همچنین با مقایسه بین روش‌های ANN و ANFIS به پیش‌بینی عمق تراز آب پرداختند. به منظور دستیابی به داده‌های ورودی مناسب از روش رگرسیون خطی چندگانه استفاده کردند. نتیجه حاصل نشان داد که مدل فازی عملکرد بهتری از مدل شبکه عصبی داشته است که این امر با کاهش توابع عضویت در مدل فازی همراه بوده است. (Mirarabi., 2019) مدل‌های داده محور را برای پیش‌بینی سطح آب زیرزمینی در سیستم‌های محصور و غیر محصور مورد ارزیابی قرار دادند. در این بین از SVR و ANN در زمان‌های ۱، ۲ و ۳ ماه پیش‌رو استفاده کردند. برای انتخاب ورودی‌های بهینه مدل، از ترکیب آزمون گاما و الگوریتم ژنتیک استفاده شد. از سوی دیگر، با افزایش ماه‌های پیش رو از دقت مدل‌ها کاسته شده است. نتیجتاً مشخص شد که مدل SVR نسبت به ANN هم در آبخوان محصور و هم نامحصور می‌تواند پیش‌بینی آب زیرزمینی را به صورت ماهانه انجام دهد.

از سوی دیگر، (دهقانی و همکاران، ۱۳۸۸) مقایسه سه روش ANN، ANFIS و زمین‌آمار در میان‌یابی سطح آب زیرزمینی را انجام داده‌اند. مختصات هندسی چاه‌های مشاهده‌ای به‌عنوان ورودی و مقادیر تراز سطح آب زیرزمینی به‌عنوان خروجی استفاده شده است. که شبکه عصبی مصنوعی از نوع پرسپترون چند لایه MLP و شبکه‌های تابع پایه شعاعی RBF به همراه دو روش دیگر به منظور یافتن بهترین روش میان‌یابی مورد



خروجی آن‌ها پیش‌بینی تراز آب در زمان $(t+1)$ بود. همچنین به منظور پیش‌بینی مکانی خروجی مدل‌سازی زمانی، به عنوان ورودی مدل زمین آمار قرار گرفت. پهنه‌بندی مکانی داده‌ها با روش کریجینگ در نرم‌افزار ArcGIS صورت گرفته است. نتایج نشان می‌دهد هرچه در انتخاب مدل‌ها و برازش آن‌ها دقت بیشتری شود، پیش‌بینی‌ها دقیق‌تر خواهند بود. و در مورد پیش‌بینی زمانی هرچه فاصله زمانی از آخرین مشاهده زمانی دورتر باشد. دقت پیش‌بینی کمتر خواهد شد. (رمضانی چرمهینه و ذونعمت کرمانی، ۱۳۹۶) کارایی روش‌های SVR، شبکه عصبی پرسپترون چندلایه و رگرسیون خطی چندمتغیره را به منظور پیش‌بینی تراز سطح آب زیرزمینی، مورد بررسی قرار دادند. که از اطلاعات ماهانه ۱۸ چاه مشاهده‌ای طی سال‌های ۱۳۷۹ تا ۱۳۸۹ به منظور شبیه‌سازی و پیش‌بینی سطح آب زیرزمینی با مدل‌های رگرسیون خطی چندمتغیره، شبکه عصبی پرسپترون چند لایه و دو مدل رگرسیونی ماشین بردار پشتیبان با توابع کرنل پایه شعاعی و خطی استفاده کردند. با توجه به معیارهای خطا، مدل‌های پرسپترون چند لایه و ماشین بردار پشتیبان به همراه توابع کرنل پایه شعاعی و خطی نتایج بهتری را در برداشتند.

مطالعات پژوهشگران حاکی از دقت مطلوب روش زمین آمار، به ویژه کریجینگ خطی است. همچنین به منظور پیش‌بینی زمانی تراز آب زیرزمینی از الگوریتم‌های ANFIS، SVR، ANN، RBF استفاده شده است. از سوی دیگر تلفیق روش‌های زمین آمار و روش‌های هوشمند به منظور بسط دادن نتایج شبیه‌سازی در کل منطقه مطالعاتی فاقد پیرومتر استفاده می‌شود.

در پژوهش حاضر، سعی شده است با تکیه بر توانایی مدل‌های هوشمند (SVR، ANN، ANFIS)، روش‌های سری زمانی ARIMA و روش زمین آمار (کریجینگ)، به ترتیب پیش‌بینی زمانی و مکانی تراز آب زیرزمینی

دقت مناسب مدل زمانی در کنار تحلیل مکانی می‌تواند ابزاری راهبردی در بحث مدیریت منابع آب باشد.

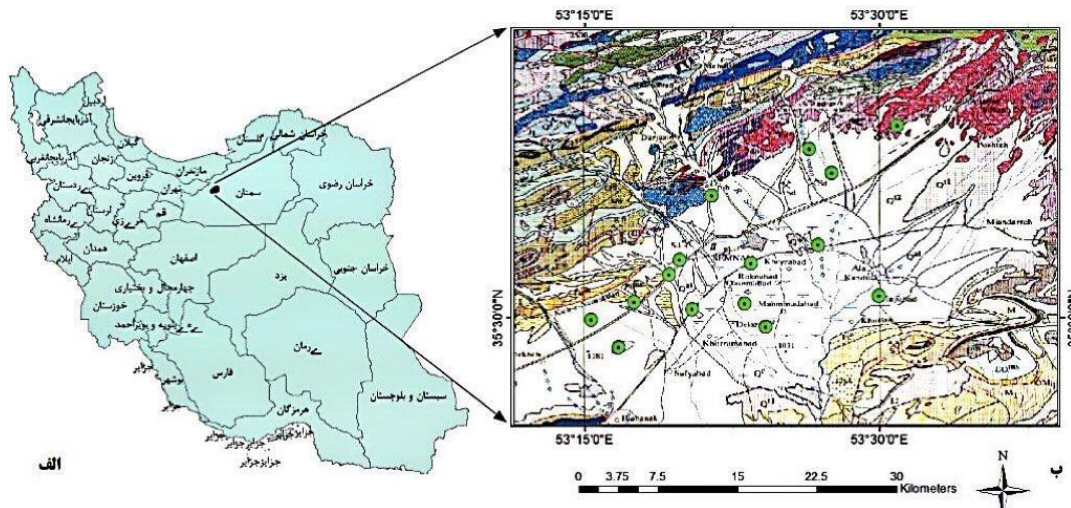
ارزیابی قرار گرفته اند. نتایج حاصل نشان می‌دهد که ANFIS با ضریب همبستگی ۹۸ درصد و میانگین مربعات خطای کمتر، از دقت بالاتری نسبت به دو روش دیگر برخوردار است. پس از آن روش زمین‌آمار و در آخر روش ANN نتایج مربوط را ارائه نموده است. (حبیبی و همکاران، ۱۳۹۴) به منظور پیش‌بینی زمانی و مکانی سطح آب زیرزمینی به ارائه مدل ترکیبی ژنتیک-کریجینگ پرداخته‌اند. از روش‌های هوش مصنوعی، نو فازی و برنامه‌ریزی ژنتیک استفاده شده است. و داده‌های ورودی مدل‌ها شامل بارش، تبخیر و سطح آب زیرزمینی بوده است. با انجام مدل‌سازی مشخص شد که دقت مدل برنامه‌ریزی ژنتیک از نو فازی بیشتر بوده و برای ترکیب با مدل زمین آمار در پیرومتر منتخب انتخاب شده است. در انتها نتایج ترکیب ژنتیک-کریجینگ نشان می‌دهد که برای پیش‌بینی مکانی و زمانی کل دشت و مناطق فاقد اندازه‌گیری سطح آب زیرزمینی استفاده خواهند شد. (دهقانی و نورعلی، ۱۳۹۵) در تخمین سطح آب زیرزمینی، روش‌های زمین آمار را با شبکه عصبی مصنوعی مقایسه کردند. به منظور درون‌یابی سطح آب زیرزمینی از شبکه عصبی مصنوعی پرسپترون چند لایه با الگوریتم آموزش لونیبرگ-مارکوارت استفاده شد. به منظور پیش‌بینی مکانی، روش زمین آمار استفاده گردید. که مشخص شد روش کریجینگ ساده با مدل دایره‌ای از میان دیگر روش‌ها نتیجه بهتری داشته است. در مجموع روش کوکریجینگ توانایی بالای درون‌یابی و تخمین سطح آب زیرزمینی نسبت به ANN داشته است. (کماسی و همکاران، ۱۳۹۶) نوسانات مکانی-زمانی سطح ایستایی آب‌های زیرزمینی را به روش ماشین بردار پشتیبان و کریجینگ مورد بررسی قرار دادند. در ابتدای امر داده‌های ۱۱ چاه پیرومتری، به دو صورت نرمال و غیر نرمال با روش SVM مدل‌سازی زمانی شد. در هر مرحله داده‌های یک چاه به عنوان ورودی مدل انتخاب شد و دشت سمنان انجام شود. از میان ۲۰ چاه پیرومتری موجود در دشت، از داده‌های تراز آب زیرزمینی چاه منتخب (مرحمت آباد) در این راستا استفاده شده است.

و مساحت آن ۹۷۴۹۱ کیلومترمربع است. از شمال به کوه‌های پیغمبران و چغندرون از شرق به کوه‌های سه برادران از غرب به سیاه‌تپه و دشت سرخه و لاسجرد و از جنوب به ارتفاعات حاجی‌آباد خوریان و دشت بیابانک منتهی می‌شود و شهر سمنان تقریباً در مرکز دشت واقع است. شکل (۱) نمایانگر این منطقه است.

مواد و روش‌ها

معرفی منطقه مورد مطالعه

دشت سمنان در مختصات ۳۴ درجه و ۱۳ دقیقه تا ۳۷ درجه و ۲۰ دقیقه عرض شمالی و از ۵۱ درجه و ۵۱ دقیقه تا ۵۷ درجه و ۳ دقیقه طول شرقی قرار دارد



شکل (۱): منطقه مورد مطالعه الف - موقعیت جغرافیایی دشت سمنان واقع در استان سمنان؛ ب - نقشه زمین‌شناسی از منطقه با پراکنش برخی از چاه‌های پیزومتری (حداد و خراسانی، ۱۳۹۸)، نقاط سبز رنگ جانمایی چاه‌های مشاهده‌ای را نمایش می‌دهد.

هیدرولوژی و هیدروژئولوژی منطقه

زمان‌های مربوط به ماه حاضر و ماه‌های قبل $[t_0, t_0-1, t_0-2, t_0-3]$ و خروجی کلیه شبکه‌ها نیز، تراز آب زیرزمینی در ماه بعد $[t_0+1]$ می‌باشد. برای انجام مدل‌سازی داده‌های مربوط به آموزش ۸۰٪ داده‌ها، از ۱۳۷۵ تا ۱۳۹۲ و داده‌های مربوط به آزمایش ۲۰٪ داده‌ها از ۱۳۹۲ تا ۱۳۹۵ استفاده گردیده است. لازم به ذکر است که آمار و اطلاعات مورد نیاز از شرکت آب منطقه‌ای سمنان تهیه شده است (آب منطقه‌ای سمنان).

شبکه عصبی مصنوعی (ANNs)

شبکه عصبی مصنوعی از روش‌های قدرتمند مدل‌سازی غیر خطی محسوب می‌شود. این مدل‌های محاسباتی که با تقلید از مغز انسان کار می‌کنند، به

عوامل مختلفی از قبیل: دمای هوا، رطوبت هوا، میزان بارش، میزان تبخیر و تعرق، ظرفیت ذخیره آبخوان، میزان برداشت از چاه‌ها، تغذیه سفره‌های آب زیرزمینی بر سطح تراز آب زیرزمینی تأثیرگذار است. با توجه به این موضوع که اطلاعات مربوط به همه عوامل نامبرده در دشت سمنان در دسترس نبود، در این مطالعه پارامترهای: دما، بارش و رطوبت نسبی به عنوان عوامل تأثیرگذار بر سطح تراز آب زیرزمینی دشت سمنان در نظر گرفته شده‌اند. داده‌های ورودی شامل: میانگین حداقل حرارت (دما) ماهانه (T)، میانگین حداقل رطوبت نسبی ماهانه (R)، میزان بارش ماهانه (P)، سطح تراز آب زیرزمینی (Wt) در هر ماه مربوط به ۲۰ چاه مشاهده‌ای برای یک دوره ۲۰ ساله (۱۳۹۵-۱۳۷۵) در نظر گرفته شده است. داده‌های ورودی

چنین شبکه‌ای معمولاً به دو صورت بدون پایش و همراه پایش انجام می‌گیرد. آموزش همراه پایش، کاربرد روند نزولی شیب و رگرسیون خطی با وزن‌های بین لایه هدف و لایه میانی معین می‌شود. خروجی لایه میانه تابعی است از فاصله میان بردارهای مرکز شعاعی W_j و ورودی X که عمدتاً با تابع انتقال گوسین محاسبه می‌شود. روابط (۲)، (۳) و (۴) به ترتیب مربوط به خروجی لایه میانه، تابع گوسین و خروجی لایه هدف است.

$$\delta = \sqrt{\sum_{i=1}^n (x_i - w_{ij})} \quad (2)$$

$$f(\delta_j) = \text{Exp}(-\lambda \cdot \delta^2) \quad (3)$$

$$Z_k = \sum_{j=1}^j b_{jk} y_j \quad (4)$$

که در آن:

y_j : خروجی ژامین نرون لایه میانه

b_{jk} : ضریب وزن بین ژامین نرون لایه میانه و k امین

نرون لایه خروجی، λ ضریب ثابت (Mason et al., 1996)؛ (دهقانی و همکاران، ۱۳۸۸).

حائز اهمیت‌ترین گام در آموزش در شبکه عصبی نحوه ارائه داده‌ها در یک محدوده است. بدین منظور از نرمال‌سازی متغیرهای ورودی استفاده می‌شود (Mason et al., 1996).

$$X_{normal} = \frac{(X - X_{min})}{(X_{max} - X_{min})} \quad (5)$$

که در آن:

X_{min} و X_{max} به ترتیب کمترین و بیشترین مقدار، X_{normal} مقدار واقعی و مقدار نرمال شده داده‌ها می‌باشد.

سیستم استنتاج فازی - عصبی تطبیقی (ANFIS)

ساختار شبکه عصبی - فازی از الگوریتم‌های شبکه عصبی و منطق فازی به منظور ایجاد ارتباط بین فضای ورودی و خروجی استفاده کرده است. بدین معنی که

منظور پردازش اطلاعات فعالیت می‌کنند (Mokhtarzad et al., 2017)؛ (محمدی و همکاران، ۱۳۹۶). ساختار شبکه عصبی مصنوعی از یک لایه ورودی، یک لایه خروجی و حداقل یک لایه پنهان تشکیل شده است (Anderson, 1995). اساس کار ANN یافتن ارتباط غیر خطی بین داده‌ها و تعمیم نتایج برای داده‌های دیگر می‌باشد (کیا، ۱۳۹۰). شبکه عصبی پرسپترون چند لایه (MLP) و شبکه تابع پایه شعاعی (RBF) از موارد کاربردی شبکه عصبی مصنوعی محسوب می‌شوند.

شبکه عصبی (MLP)

آموزش شبکه عصبی MLP، با الگوریتم پس انتشار خطا (BP) صورت می‌گیرد. عملکرد این الگوریتم بر اساس یادگیری سعی و خطا می‌باشد. خروجی هر لایه به عنوان ورودی لایه بعد در نظر گرفته می‌شود. که بردار ورودی $X(x_1, x_2, \dots, x_n)$ با وارد شدن هر یک از بردارها به شبکه، توسط یک وزن به گره مربوطه متصل می‌شوند. با اتصال پیوسته وزن‌ها، بردار وزن $W(w_1, w_2, \dots, w_n)$ به گره مد نظر ارتباط می‌یابد. خروجی گره که در معادله (۱) نوشته شده با Y نمایش داده می‌شود (دهقانی و همکاران، ۱۳۸۸):

$$Y = f(WX + b) \quad (1)$$

که در آن:

b : بایاس بوده که مانند بردار وزن‌ها قابل تغییر است.

f : تابع انتقال، که به صورت خطی یا غیر خطی می‌باشد (منهاج، ۱۳۸۱؛ کیا، ۱۳۹۰).

شبکه RBF

نخستین بار بروم هد و لاو در سال ۱۹۸۸ شبکه‌های تابع شعاع مبنا را همراه با یک لایه میانه معرفی کردند. شبکه‌ای از نوع شبکه‌های پیشرو (FF) که لایه خروجی آن تابعی خطی و لایه میانه اغلب تابع گوسین می‌باشد (Dibik et al., 1999; Mason et al., 1996). آموزش

روش رگرسیون بردار پشتیبان SVR اشاره کرد. هدف این الگوریتم یافتن تابعی با بیشترین انحراف از بردار هدف واقعی برای داده‌های یادگیری می-باشد (Smola, 1996; 1998). تابع SVR به صورت زیر بیان می‌شود:

$$f(x) = w\varphi(x) + b \quad (6)$$

φ : تابع انتقال است. به منظور دستیابی به عملکرد مناسب SVR، می‌توان تابع را به طریق زیر بهینه کرد:

$$\text{minimize: } \frac{1}{2} \|w\|^2 + c \left(\sum_{i=1}^N (\xi_i + \xi_i^*) \right) \quad (7)$$

Subject

$$\begin{cases} y_i - W^T \varphi(X_i) - b \leq \varepsilon + \xi_i \\ W^T \varphi(X_i) + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0, i = 1, 2, \dots, N \end{cases} \quad (8)$$

که در آن:

ξ_i و ξ_i^* : خطای محاسبه جریمه متغیرها.

C: ضریب مثبت مبادله‌ای به منظور درجه خطای آزمایش به همین ترتیب برای حل مشکل بهینه‌سازی، باید الگوریتم موجود را پیوسته به حداقل رساند (Platt, 1999). اگر رابطه (8) با ضرب‌کننده-های لاگرانژی (α_i, α_i^*) بازنویسی شوند، معادلات زیر حاصل می‌شوند:

$$\max_{\alpha, \alpha^*} \begin{cases} -\frac{1}{2} \sum_{l=1}^N (\alpha_l - \alpha_l^*) (\alpha_l - \alpha_l^*) K(X_l, X_l) \\ -\varepsilon \sum_{l=1}^N (\alpha_l + \alpha_l^*) + \sum_{l=1}^N (\alpha_l - \alpha_l^*) \end{cases}$$


$$\text{Subject to } \begin{cases} \sum_{i=1}^N (\alpha_i - \alpha_i^*) = 0 \\ 0 \leq \alpha_i, \alpha_i^* \leq C \end{cases} \quad (9)$$

$$\text{to obtain } \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(X_i, X_i) + b$$

که در آن:

توانایی قدرت زبانی استنتاج سیستم‌های فازی بعلاوه خصوصیت آموزش‌پذیری شبکه‌های عصبی را دارا می-باشد. این سیستم اولین بار توسط جانگ در سال ۱۹۹۳ معرفی شد. به همین ترتیب توانسته هر عملکرد مداوم واقعی با هر درجه‌ای را در سطح جهانی تقریب دهد (Jang et al., 1997). ANFIS این امکان را ایجاد می‌کند که قوانین داده‌های فازی را از داده‌های عددی بیرون آورده و مبتنی بر قانون-بنیاد، به صورت انطباقی انجام شود.

ساختار ANFIS با ۵ لایه پیکربندی شده است. این لایه‌ها به صورت گره‌های ورودی (میزان تعلق به بازه فازی)، گره‌های وزن قوانین (ضرب مقادیر ورودی به هر گره در همدیگر)، گره‌های میانگین (محاسبه نسبی قوانین)، گره‌های متعاقب (عملیات در سیگنال‌های ورودی) و گره‌های خروجی نامگذاری شده است (Chen et al., 2006). ورودی‌ها دارای دو یا چند تابع عضویت می‌باشند. این سیستم بر اساس آموزش با نظارت، پیش می‌رود، که هدف یادگیری شبکه‌های انطباقی است (Chang and Chang, 2005). در شکل ۲ نمای شماتیک از این سیستم با ۵ لایه آورده شده است.



شکل (۲): ساختار سیستم استنتاج عصبی- فازی

تطبیقی (Moghaddamnia et al., 2009)

رگرسیون بردار پشتیبان (SVR)

ماشین بردار پشتیبان SVM رویکرد یادگیری ماشین نسبتاً جدید در زمینه تحقیقات داده محور است. که شناسایی الگو و اصل کاهش خطر ساختاری را انجام می‌دهد (Vapnik, 1998). از انواع SVM می‌توان به

روش کریجینگ

روش کریجینگ بر منطق میانگین متحرک وزن دار استوار بوده و می توان آن را از برترین تخریب گرهای خطی نارایب دانست. از سوی دیگر یک برآوردکننده درون یابی دقیق می باشد. با توجه به اینکه روش کریجینگ اغلب بطور نامنظم نمونه گیری می شود. داده های مجهول و خطای مربوطه را تخمین می زند. در روش کریجینگ ساده به منظور درون یابی متغیرها در نقطه مورد نظر از معادله زیر استفاده می شود:

$$Z(X_0) = m + \sum_{i=1}^N \lambda_i [Z(x_i) - m] \quad (11)$$

که در آن:

λ_i : وزن های مربوط به کریجینگ ساده

$Z(X_0)$: مقدار معیار تخمین زده

$Z(x_i)$: مقدار معیار محاسباتی در موقعیت i ام

m میانگین معیار کانسار می باشد (حسینی، ۱۳۷۷).

به همین ترتیب میزان واریانس به صورت زیر می باشد:

$$\sigma^2 sk = m + \sum_{i=1}^N \lambda_i \gamma_{i0} - \gamma_{00} \quad (12)$$

اندازه گیری واریوگرام به منظور بررسی همبستگی میان محاسبات مربوط به متغیر در مجاورت یک نقطه و تعیین تغییرات مکانی می باشد. شرح این کار با عملکردی به نام شبه واریوگرام صورت میگیرد. که به صورت زیر انجام میگیرد:

$$\gamma(h) = \frac{1}{2n} \sum_{i=1}^N [Z(x_i) - Z(x_i + h)]^2 \quad (13)$$

که در آن:

$Z(x_i + h)$: مقادیر اندازه گیری شده در مکان

$(x_i + h)$ ، $\gamma(h)$ مقدار شبه واریوگرام در فاصله مکانی

n و h تعداد نقاط مورد نظر در کریجینگ می باشد. در

این پژوهش سعی شده از شبه واریوگرام خطی و گوسین

N و k : تعداد بردارهای پشتیبان و تابع کرنل هستند. به منظور ایجاد تابع کرنل پایه شعاعی می توان از فاکتور σ استفاده کرد. و برای به حداقل رسانی این الگوریتم باید ضرایب c ، ϵ و σ را تغییر داد (Shiri et al., 2018; Woo, 2020).

$$K(X_i, X_j) = \exp\left(-\frac{\|X_i - X_j\|^2}{2\sigma^2}\right) \quad (10)$$

میانگین متحرک خود همبستگی (ARIMA)

مدل سازی سری های زمانی در چهار مرحله انجام می گیرد. مرحله اول، با ایجاد تمایز و تغییر سری ها، ایستایی و نرمال بودن، بررسی می گردد. در این بخش عملکرد با همبستگی (ACF) و همبستگی جزئی (PACF) دیده می شود. در محله دوم، به منظور انتخاب مدل و محاسبه پارامترها (p,q,d) با عملکرد احتمال از شباهت میان ACF و PACF استفاده می گردد (چاهکوتاهی و خاشعی، ۱۳۹۸). که در پارامترهای مذکور p درجه خود رگرسیون، d درجه تفاضل گیری و q درجه میانگین متحرک است. در این راستا برای توجیه مرحله شناسایی و انتخاب دامنه اولیه مدل، مقادیر پارامترهای مدل محاسبه می شوند. در مرحله سوم، مدل مناسبی به جهت ارضای خطاهای مفروض انتخاب می شود. در مرحله پایانی، اگر مدل مناسب نباشد، مدل دیگری جایگزین می شود این مراحل تا جایی ادامه می یابد که خطا به حداقل برسد. پس از آن مدل انتخابی برای برازش و پیش بینی استفاده می شود (Box and Jenkins, 1970).

روش های زمین آمار

زمین آمار شاخه ای از علم آمار است که به دو دسته، روش های زمین آماری و روش های کلاسیک تقسیم می شود. روش های کلاسیک شامل چند ضلعی، عکس فاصله، مجذور فاصله و روش های زمین آماری شامل انواع روش های کریجینگ و کوکریجینگ می باشند (حسینی، ۱۳۷۷).

$$MAE = \frac{1}{N} \sum_{i=1}^N |O_i - P_i| \quad (۱۷)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (O_i - \bar{O}_i)^2} \quad (۱۸)$$

در این روابط O_i و P_i به ترتیب شامل داده‌های مشاهداتی و پیش‌بینی شده می‌باشند. N تعداد داده‌ها و \bar{O}_i میانگین داده‌های مشاهداتی است.

مدلسازی و تحلیل نتایج

هدف از مطالعه حاضر، بررسی پنج روش ANN، ARIMA، SVR، ANFIS و زمین آمار در پیش‌بینی سطح آب زیرزمینی می‌باشد. از سوی دیگر، از داده‌های آماری مربوط به یک چاه مشاهده‌ای منتخب (پیرومترمرحمت‌آباد)، که اطلاعات مربوط به تراز آب زیرزمینی آن در دوره زمانی (۱۳۹۵-۱۳۷۵) کامل بوده، استفاده شده است. چنین فرآیندی به دلیل جلوگیری از تکرار مراحل آموزش در ۲۰ چاه مشاهده‌ای صورت گرفته است. در ابتدا با بررسی بیشترین همبستگی میان متغیرهای ورودی هواشناسی و تأثیر آن‌ها بر تراز آب زیرزمینی مشخص شد که متغیرهای دما، بارش و رطوبت نسبی با تراز آب زیرزمینی بیشترین وابستگی را دارند. داده‌های مورد نظر با سه دوره تأخیر به عنوان ورودی انتخاب شده‌اند که مجموعاً ۱۶ گره را در بر می‌گیرند و خروجی تمامی مدل‌سازی‌ها تراز آب زیرزمینی در زمان (t_{0+1}) می‌باشد.

برآورد تراز آب زیرزمینی با استفاده از ANN

در مدل‌سازی شبکه عصبی مصنوعی تعداد لایه‌های میانی، تعداد نرون‌های لایه میانی (مخفی)، نوع الگوریتم آموزش و همچنین نوع توابع محرک لایه مخفی در آموزش و میزان کارایی شبکه عصبی تأثیر بسزایی دارند. در مطالعه حاضر، برای تعیین لایه میانی یکی از پرکاربردترین توابع انتقال، تابع سیگموئید مورد استفاده قرار گرفته است. در این بین از توابع محرک tan sigmoid و log sigmoid و در لایه خروجی از تابع

در مدل‌سازی کریجینگ استفاده شود، که معادله خطی آن در زیر آمده است:

$$\gamma(h) = ah \quad (۱۴)$$

که در آن:

α و $\gamma(h)$ پارامترهای مدل‌سازی و میزان شبه واریوگرام در فاصله مکانی h می‌باشند (کارآموز و عراقی‌نژاد، ۱۳۸۹).

روش وزن‌دهی عکس فاصله (IDW)

یکی از روش‌های میان‌یابی کلاسیک محسوب می‌شود. که وابسته به فاصله میان موقعیت‌های مشاهده شده و موقعیتی که باید مقدار متغیر محاسبه شود، می‌باشد. وزن‌دهی آن در عکس فواصل از نقاط مجهول صورت می‌گیرد. بدین ترتیب که بر اساس نزدیکی به موقعیت وزن اختصاص می‌یابد. و نقاط معلوم با نقاط اطراف ورودی یک محدوده معین محاسبه می‌شوند. چنین برآوردی به صورت زیر بیان می‌گردد:

$$Z_j = \frac{\sum_{i=1}^N \left[\frac{Z_i}{(h_{ij}+s)^\beta} \right]}{\sum_{i=1}^N \left[\frac{1}{(h_{ij}+s)^\beta} \right]} \quad (۱۵)$$

که در آن:

Z_j : مقدار برآورد شده در نقطه مورد نظر j ،
 Z_i : مقدار مشاهده‌ای در نقطه‌ای به فاصله h از نقطه مورد نظر،
 h_{ij} : فاصله بین نقطه مشاهده‌ای تا نقطه مورد برآورد،
 s : فاکتور تعدیل کننده و β وزن نقطه مورد نظر می‌باشد. (Murphy et al, 2010).

معیار ارزیابی

به منظور ارزیابی عملکرد و مقایسه روش‌های هوشمند و زمین آمار، از معیارهای مجذور میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE) و ضریب همبستگی (R^2)، طبق روابط (۱۶)، (۱۷) و (۱۸) استفاده شده است:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (O_i - P_i)^2}{N}} \quad (۱۶)$$



روش سعی و خطا بدست آورده که مشاهده می‌شود با افزایش تعداد نرون‌های این لایه میزان همبستگی کاهش و مقدار خطاها افزایش می‌یابد. و همچنین از دو نوع الگوریتم یادگیری در آموزش شبکه عصبی استفاده شده، الگوریتم شبکه عصبی پس انتشار و لونیبرگ-مارکوآرت (LM)، که نتایج مربوط به (LM) با ۴ نرون در یک لایه پنهان با تابع محرک tansig بهترین نتیجه را در بر داشته است. در جدول (۱) نتایج مربوط به ANN آورده شده است (جهانشاهی و مقدم-نیا، ۱۳۹۱): (Daliakopoulos et al., 2008):

انتقال خطی purelin استفاده گردیده. که تابع محرک سیگموئید تانژانت هیپربولیک نسب به توابع لگاریتم هیپربولیک نتایج بهتری را در بر داشته. لازم به ذکر است، به عنوان مقدار ابتدایی تعداد نرون لایه میانی، ۴ به همراه یک لایه مخفی در نظر گرفته شده است. برای بررسی تعداد لایه مخفی از ۱، ۲ و ۳ لایه میانی استفاده شده که نتایج مشخص می‌کند با افزایش تعداد لایه‌ها از میزان قدرت شبکه عصبی کاسته شده، بنابراین به منظور بهره‌برداری بهتر از نتایج از یک لایه مخفی استفاده شده است. در ادامه تعداد نرون لایه مخفی را با

جدول (۱): نتایج مدل‌سازی ANN با تعداد مختلف لایه پنهان، انواع مختلف تابع محرک لایه میانی و تعداد متفاوت نرون لایه

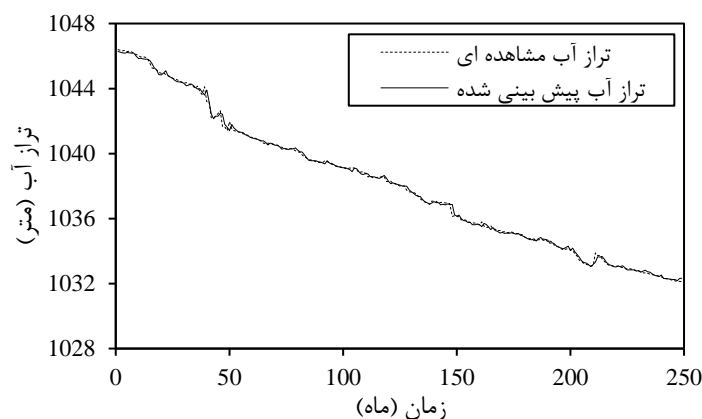
میانی

| مرحله آزمایش (تست) | | | مرحله آموزش | | | مشخصات مربوط به ساختار الگوریتم |
|--------------------|--------|----------------|-------------|--------|----------------|---------------------------------|
| RMSE | MAE | R ² | RMSE | MAE | R ² | |
| ۰/۱۱۶۸ | ۰/۰۷۸۶ | ۰/۹۵۳۴ | ۰/۱۳۴۷ | ۰/۰۹۱۹ | ۰/۹۹۸۴ | ۱ |
| ۰/۱۴۹۰ | ۰/۰۹۶۴ | ۰/۹۳۱۵ | ۰/۱۵۷۱ | ۰/۰۹۶۳ | ۰/۹۹۸۱ | ۲ |
| ۰/۱۴۱۹ | ۰/۰۷۴۸ | ۰/۹۲۷۹ | ۰/۱۳۱۲ | ۰/۰۹۴۸ | ۰/۹۹۸۶ | ۳ |
| ۰/۱۴۲۹ | ۰/۰۷۳۸ | ۰/۹۲۸۶ | ۰/۱۵۵۶ | ۰/۰۹۸۸ | ۰/۹۹۸۱ | log-sigmoid |
| ۰/۱۱۶۸ | ۰/۰۷۸۶ | ۰/۹۵۳۴ | ۰/۱۴۳۷ | ۰/۰۹۱۹ | ۰/۹۹۸۴ | tan-sigmoid |
| ۰/۱۱۶۸ | ۰/۰۷۸۶ | ۰/۹۵۳۴ | ۰/۱۴۳۷ | ۰/۰۹۱۹ | ۰/۹۹۸۴ | ۴ |
| ۰/۲۰۹۶ | ۰/۱۷۱۳ | ۰/۹۱۳۶ | ۰/۱۶۸۴ | ۰/۱۲۱۴ | ۰/۹۹۸۳ | ۵ |
| ۰/۲۸۲۳ | ۰/۱۱۰۲ | ۰/۸۱۹۲ | ۰/۱۸۲۱ | ۰/۰۹۴۶ | ۰/۹۹۷۴ | ۶ |
| ۰/۱۳۴۱ | ۰/۰۹۹۶ | ۰/۹۳۸۹ | ۰/۱۴۸۳ | ۰/۱۰۶۴ | ۰/۹۹۸۳ | ۹ |
| ۰/۱۳۵۶ | ۰/۰۹۹۰ | ۰/۹۳۹۳ | ۰/۱۸۲۸ | ۰/۱۳۹۵ | ۰/۹۹۷۷ | ۱۰ |

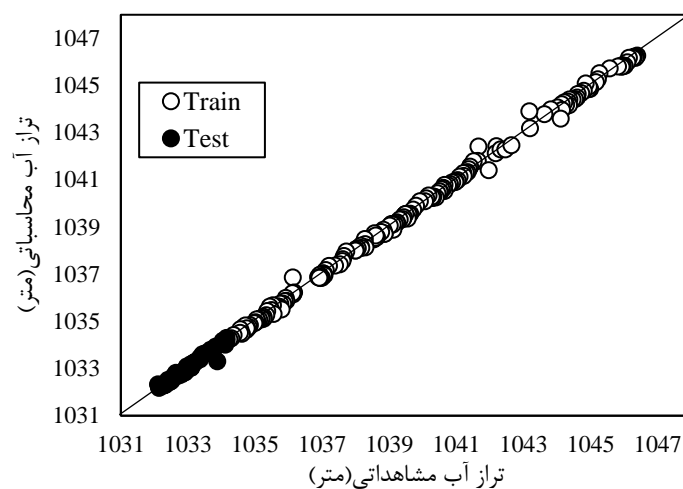
در جدول (۱) تمامی آموزش‌ها در یادگیری لونیبرگ-

مارکوآرت صورت گرفته است. نمودارهای شکل (۳)

مربوط به نتایج شبکه عصبی مصنوعی می‌باشد:



(الف)



(ب)

شکل (۳): منحنی تغییرات تراز آب زیرزمینی در پیژومتر مرحمت آباد الف- با استفاده از الگوریتم ANN. ب- مقایسه داده‌های مشاهده‌ای و پیش‌بینی تراز آب زیرزمینی در دو مرحله آموزش و آزمایش.

مشاهده می‌شود، با افزایش تعداد نرون‌ها، دقت مدل-سازی نیز افزایش یافته است. بطوریکه اگر فراتر از این بازه نیز پیش‌رفته شود، نتایج به مراتب بهبود یابد. نتایج نشان داد که معیارهای ارزیابی در مرحله آزمون و آزمایش با ۴۵ نرون در لایه میانی شبکه شعاع مینا، بازدهی بهتری داشته است. در جدول (۲) نتایج مربوط به شبکه آورده شده است:

برآورد تراز آب زیرزمینی با استفاده از RBF


نظر به اینکه در پژوهش‌های مختلف کمترین میزان از تعداد نرون لایه میانی شبکه شعاع مینا ۲۰ عدد بوده (Sujatha and Kumar, 2007)؛ (نیک-منش، ۱۳۸۸)، سعی شد از تعداد ۲۰ نرون در لایه میانی تا تعداد ۴۵ نرون برای مدل‌سازی شبکه استفاده شود.

جدول (۲): نتایج مدل‌سازی RBF با تعداد متفاوت نرون لایه میانی

| مرحله آزمایش (تست) | | | مرحله آموزش | | | تعداد نرون |
|--------------------|--------|----------------|-------------|--------|----------------|------------|
| RMSE | MAE | R ² | RMSE | MAE | R ² | |
| ۲/۳۲۳۲ | ۱/۶۹۴۳ | ۰/۸۰۹۸ | ۰/۰۲۷۹ | ۰/۰۰۷۶ | ۰/۹۹۹۵ | ۲۰ |
| ۱/۹۵۲۹ | ۱/۴۴۴۳ | ۰/۸۵۷۹ | ۰/۰۲۳۴ | ۰/۰۰۶۹ | ۰/۹۹۹۹۶ | ۲۱ |
| ۱/۴۲۵۷ | ۱/۰۲۰۴ | ۰/۹۱۵۹ | ۰/۰۳۱۳ | ۰/۰۱۶۰ | ۰/۹۹۹۹۴ | ۲۵ |
| ۱/۱۹۳۲ | ۰/۷۹۸۳ | ۰/۹۳۳۶ | ۰/۰۰۹۲ | ۰/۰۰۳۸ | ۰/۹۹۹۹۹ | ۳۰ |
| ۰/۹۱۸۵ | ۰/۶۲۵۶ | ۰/۹۶۰۴ | ۰/۰۲۹۴ | ۰/۰۱۸۳ | ۰/۹۹۹۹۴ | ۳۵ |
| ۰/۷۶۸۴ | ۰/۵۰۸۲ | ۰/۹۷۱۳ | ۰/۰۳۱۶ | ۰/۰۱۸۲ | ۰/۹۹۹۹۳ | ۴۰ |
| ۰/۷۹۲۰ | ۰/۴۶۹۱ | ۰/۹۶۹۶ | ۰/۰۱۶۶ | ۰/۰۰۹۱ | ۰/۹۹۹۹۸ | ۴۵ |

که داده‌ها مربوط به بخش آزمایش هستند، تراز آب پیش‌بینی شده دارای اختلاف با تراز آب مشاهده‌ای می‌باشد که این امر کاملاً طبیعی است.

با دقت در شکل (۴) نیز مشاهده می‌شود که در ابتدای نمودارها، انطباق خوبی بین تراز آب مشاهده‌ای و تراز آب پیش‌بینی شده وجود دارد، اما در انتهای نمودارها



شکل (۴): منحنی تغییرات تراز آب زیرزمینی در پیزومتر مرحمت آباد با استفاده از RBF.

همچنین به صورت نزولی کاهش یافته‌اند، پس امکان استفاده از دیگر رویکردهای مبتنی بر قواعد فازی وجود ندارد. و تنها می‌توان از رویکرد خوشه بندی FCM که همان genfis3 است، بهره گرفت. از میان سیستم استنتاج فازی ممدانی و سوگنو، که هر دو را genfis3 ایجاد می‌کند، از سوگنو به دلیل وجود ورودی‌های فازی و خروجی‌هایی که می‌تواند فازی نباشد،

برآورد تراز آب زیرزمینی با استفاده از ANFIS این روش شبکه عصبی مصنوعی و مفاهیم منطق فازی را یکی کرده و می‌تواند از امکانات هر دو در یک قاب استفاده کند. در پژوهش حاضر، به منظور فازی نمودن متغیرهای ورودی از تابع عضویت مثلثی (trimf) با تعداد ۳ تابع عضویت وارد شده است. همچنین به دلیل اینکه تعداد داده‌ها زیاد بوده و

استفاده شده است. در جدول (۳) ساختار نتیجه مربوط به ANFIS آورده شده است:

جدول (۳): نتایج مدل‌سازی ANFIS با تعداد متفاوت از توابع عضویت و تعداد دوره‌های مختلف

| مرحله آزمایش (تست) | | | مرحله آموزش | | | مشخصات مربوط به ساختار ANFIS |
|--------------------|--------|----------------|-------------|--------|----------------|------------------------------|
| RMSE | MAE | R ² | RMSE | MAE | R ² | |
| ۰/۰۴۱۴ | ۰/۰۲۱۵ | ۰/۹۹۴۰ | ۰/۰۱۹۳ | ۰/۰۰۷۶ | ۰/۹۹۹۷ | ۱۰ |
| ۰/۶۴۱۴ | ۰/۲۷۲۵ | ۰/۹۸۰۷ | ۰/۰۲۴۹ | ۰/۰۰۸۲ | ۰/۹۹۹۶ | ۳۰ |
| ۱/۹۸۵۳ | ۱/۱۰۳۹ | ۰/۸۳۳۱ | ۰/۰۸۳۴ | ۰/۰۲۳۱ | ۰/۹۹۹۶ | ۵۰ |
| ۰/۰۴۱۴ | ۰/۰۲۱۵ | ۰/۹۹۴۰ | ۰/۰۱۹۳ | ۰/۰۰۷۶ | ۰/۹۹۹۷ | ۳ |
| ۲/۹۲۵۸ | ۱/۲۱۶۹ | ۰/۷۲۴۵ | ۰/۰۳۰۷ | ۰/۰۱۲۶ | ۰/۹۹۹۹ | ۴ |
| ۸/۴۴۵۲ | ۲/۹۴۲۰ | ۰/۳۴۰۵ | ۲/۵۹۰۹ | ۱/۱۵۶۵ | ۰/۶۷۵۳ | ۵ |

در شکل (۵) نمودار مربوط به الگوریتم ANFIS آورده شده است.



شکل(۵): منحنی تغییرات تراز آب زیرزمینی در پیژومتر مرحمت آباد با استفاده از ANFIS.

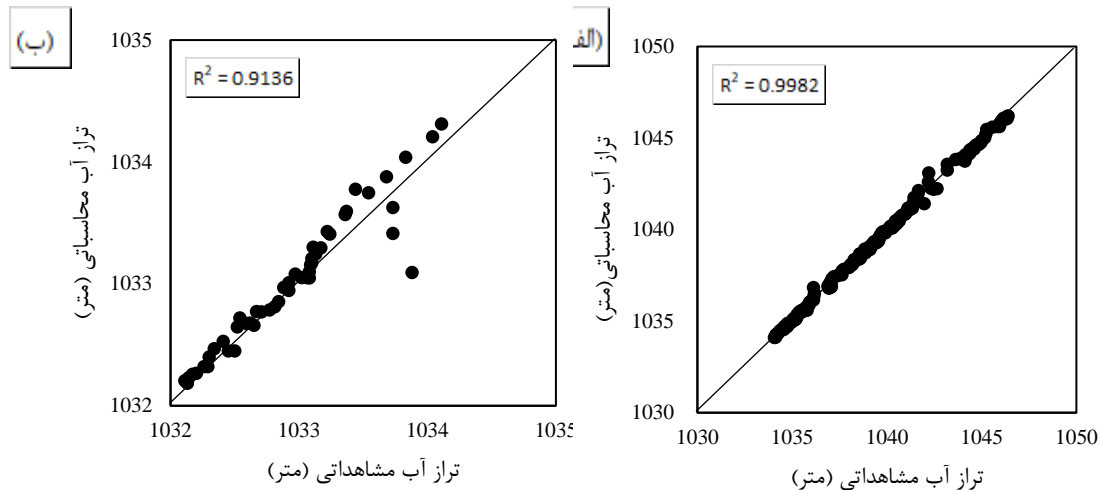
برآورد تراز آب زیرزمینی با استفاده از SVR

مدل‌سازی باید علاوه بر استفاده از کرنل‌ها ضرایب مربوط به σ , C و همچنین ϵ را تغییر داد. این روش هم مانند روش‌های دیگر با سعی و خطا در میزان این ضرایب همراه است. در جدول زیر نتایج و نمودارهای مربوط به مدل‌سازی SVR آورده شده است:

در صورتیکه بتوان داده‌های خطی منفصل پذیر را در مرزهایشان از هم گسست، و خط منفصل‌کننده را بدرستی ترسیم و جدا کرد، از رگرسیون خطی استفاده می‌شود. اما در صورت توزیع غیر خطی داده‌ها باید از کرنل‌ها استفاده کرد. برای بهره‌گیری از نتایج بهینه این

| مرحله آزمایش | | | مرحله آموزش | | | نوع شبکه |
|--------------|--------|----------------|-------------|--------|----------------|----------|
| RMSE | MAE | R ² | RMSE | MAE | R ² | SVR |
| ۰/۱۷۱۷ | ۰/۱۲۰۱ | ۰/۹۱۳۶ | ۰/۱۶۴۳ | ۰/۱۱۶۹ | ۰/۹۹۸۱ | |

شکل (۶) نمایانگر تغییرات تراز آب در مراحل یادگیری و تست می باشد.



شکل (۶): نمودار تغییرات مقادیر تراز آب محاسباتی در مقابل مقادیر واقعی با استفاده از الگوریتم SVR. الف- مرحله آموزش، ب- مرحله آزمایش.

بررسی از نمودار Residual ACF استفاده می شود. نتایج حاصل نمایانگر نایستایی سری مورد بررسی است. لذا بایستی از سری دیفرانسیل گیری شود. این کار را تا $d = 1.2$ ادامه داده که مشخص می شود الگوی افزایشی و کاهش برای $d = 2$ ، وجود دارد و حاکی از نامناسب بودن این پارامتر است. نتیجتاً مقدار پارامتر d ، یک در نظر گرفته می شود. در ادامه برای تعیین پارامتر-های مدل از ضرایب $p, q = 0.1.2.3.4$ استفاده می-شود. در پایان با در نظر گرفتن معیارهای ارزیابی، بهترین مدل برای پیش بینی توسط ARIMA انتخاب می شود. نتایج مربوطه در جدول (۵) آورده شده است:

برآورد تراز آب زیرزمینی با استفاده از مدل -

سازی ARIMA


از مدل خود رگرسیون میانگین متحرک، به منظور پیش بینی سری های زمانی تراز آب زیرزمینی استفاده شده است. چنین فرآیندی در نرم افزار IBM SPSS Statistics 22 انجام گرفته است. با فرض وابستگی تراز آب زیرزمینی به ماه پیشین، مدل $ARIMA(p, d, q)$ برای پیش بینی تراز آب زیرزمینی در نظر گرفته شده است. با تعیین درجه تفاضل گیری پیش فرض نرم افزار، باید ایستایی الگوی سری زمانی بررسی شود. که تحت

جدول (۵): نتایج مربوط به مدل خود رگرسیون میانگین متحرک

| مرحله آزمایش | | | مرحله آموزش | | | ARIMA (p,d,q) |
|--------------|--------|----------------|-------------|--------|----------------|---------------|
| RMSE | MAE | R ² | RMSE | MAE | R ² | |
| ۰/۱۱۸۵ | ۰/۰۵۵۷ | ۰/۹۴۷۲ | ۰/۱۴۶۸ | ۰/۰۸۷۳ | ۰/۹۹۸۴ | (۴,۱,۳) |
| ۰/۱۱۸۲ | ۰/۰۵۷۳ | ۰/۹۴۷۵ | ۰/۱۴۷۴ | ۰/۰۸۸۵ | ۰/۹۹۸۳ | (۴,۱,۱) |
| ۰/۱۱۷۷ | ۰/۰۵۷۹ | ۰/۹۴۷۷ | ۰/۱۴۶۷ | ۰/۰۸۷۳ | ۰/۹۹۸۴ | (۴,۱,۲) |
| ۰/۱۱۷۳ | ۰/۰۵۷۵ | ۰/۹۴۸۳ | ۰/۱۴۸۸ | ۰/۰۸۸۴ | ۰/۹۹۸۳ | (۳,۱,۲) |
| ۰/۱۱۵۹ | ۰/۰۶۱۰ | ۰/۹۴۸۷ | ۰/۱۴۵۸ | ۰/۰۸۷۳ | ۰/۹۹۸۴ | (۴,۱,۴) |

نمودار مربوط به صحت‌سنجی تراز آب زیرزمینی بر حسب زمان در شکل (۷) آورده شده است:

در جدول (۵) مشاهده می‌شود، بهترین نتیجه مربوط به ARIMA (4,1,4) می‌باشد.



شکل (۷): منحنی تراز آب زیرزمینی بر حسب زمان در مرحله آزمون با استفاده از ARIMA

در جدول مشخص و معلوم است، ANFIS دارای دقت بالاتر و خطای کمتر نسبت به مدل‌سازی‌های دیگر می‌باشد. بنابراین الگوریتم ANFIS با تعداد ۳ تابع عضویت مثلثی، به عنوان مدل برتر جهت تخمین زمانی تراز آب زیرزمینی دشت سمنان انتخاب می‌شود.

انتخاب بهترین روش برای مدل‌سازی تغییرات زمانی سطح آب زیرزمینی
جدول (۶) نتایج مربوط به مدل‌سازی‌های روش‌های هوشمند و ARIMA را نشان می‌دهد. همان‌طور که

جدول (۶): ارزیابی عملکرد روش‌های هوشمند و ARIMA

| مرحله آزمایش (تست) | | | مرحله آموزش | | | مدل |
|--------------------|-----------|----------------|-------------|-----------|----------------|--------|
| RMSE | MAE | R ² | RMSE | MAE | R ² | |
| ۰.۱۱۶۸۴۳۹ | ۰.۰۷۸۶۴۱۶ | ۰.۹۵۳۴ | ۰.۱۴۳۷۴۳۳ | ۰.۰۹۱۹۳۶۵ | ۰.۹۹۸۴ | ANN |
| ۰.۷۹۲۰۰۷۷ | ۰.۴۶۹۰۷۸۸ | ۰.۹۶۹۶۲۲۳ | ۰.۱۶۶۱۹۹ | ۰.۰۹۱۳۰۴ | ۰.۹۹۹۹۸۳۲ | RBF |
| ۰.۰۷۰۳۱۱۷ | ۰.۰۴۸۵۳۲۵ | ۰.۹۸۹۰۳۲۷ | ۰.۰۶۶۷۷۴ | ۰.۰۲۹۸۲۵۷ | ۰.۹۹۹۷۰۴۶ | ANFIS |
| ۰.۸۳۸۹۹۶۸ | ۰.۵۷۷۰۲۹۲ | ۰.۹۶۴۳۵۱۸ | ۰.۵۵۲۶۰۵۳ | ۰.۳۷۸۳۲۷۹ | ۰.۹۸۷۵۸۷۶ | LS-SVM |
| ۰.۱۷۱۷۵۷۵ | ۰.۱۲۰۱۴۹۴ | ۰.۹۱۳۶۰۲۱ | ۰.۱۶۴۳۳۲ | ۰.۱۱۶۹۷۷۶ | ۰.۹۹۸۱۵۷۹ | SVR |
| ۰.۱۱۵۹۶۰۹ | ۰.۰۶۱۰۲۰۴ | ۰.۹۴۸۷۲۰۵ | ۰.۱۴۵۸۰۵۴ | ۰.۰۸۷۳۱۳۴ | ۰.۹۹۸۴۱۵۸ | ARIMA |

آنالیز حساسیت

زمان‌های $[t_0, t_0-1, t_0-2, t_0-3]$ بر خروجی داشته است. همچنین با توجه به انجام این آنالیز پارامترهای دیگر تأثیر کمتری نسبت به تراز آب زیرزمینی داشته‌اند.

تأثیرگذارترین پارامتر در انجام این آنالیز، که بیشترین خطا و کمترین همبستگی را در بر داشته مربوط به پارامتر تراز آب زیرزمینی است که در جدول (۷) مشاهده می‌شود.

پس از انتخاب برترین روش در پیش‌بینی زمانی به منظور تعیین میزان ضرورت و تأثیر متغیرهای ورودی بر متغیر خروجی از این آنالیز استفاده می‌شود. در این فرآیند با حذف یک به یک متغیرهای ورودی تغییرات بر خروجی مورد بررسی قرار می‌گیرد. که مشاهده می‌شود، بیشترین تأثیر را تراز آب زیرزمینی در تمامی

جدول (۷): نتیجه مربوط به حذف تأثیرگذارترین پارامتر در الگوریتم برتر (ANFIS)

| مرحله آزمایش (تست) | | | مرحله آموزش | | | مدل |
|--------------------|-------------|----------------|-------------|-----------|----------------|--------|
| RMSE | MAE | R ² | RMSE | MAE | R ² | |
| ۲.۳۴۱۴۲۷۸ | ۲.۱۴۳۱۸۸۷۳۶ | ۰.۴۶۶۴۷۱۰۲۴ | ۴.۴۸۶۰۱۹۰۰۲ | ۳.۵۰۹۰۸۶۹ | ۰.۳۵۰۱ | non Wt |

کریجینگ شامل کریجینگ خطی و گوسین و روش عکس فاصله IDW-2، IDW-3 و IDW4 می‌باشد. برای برآورد عملکرد روش‌های زمین آماری از روش ارزیابی متقاطع استفاده گردید. با توجه به جدول (۸) مشخص می‌شود که روش کریجینگ خطی نسبت به روش‌های دیگر دارای دقت بالاتری می‌باشد. بنابراین، روش کریجینگ را می‌توان بعنوان روش برتر در پیش‌بینی مکانی تراز آب زیرزمینی دشت سمنان انتخاب کرد. شکل (۸) نتایج حاصل از پهنه‌بندی مکانی تراز آب زیرزمینی دشت سمنان با روش کریجینگ خطی را نشان می‌دهد.

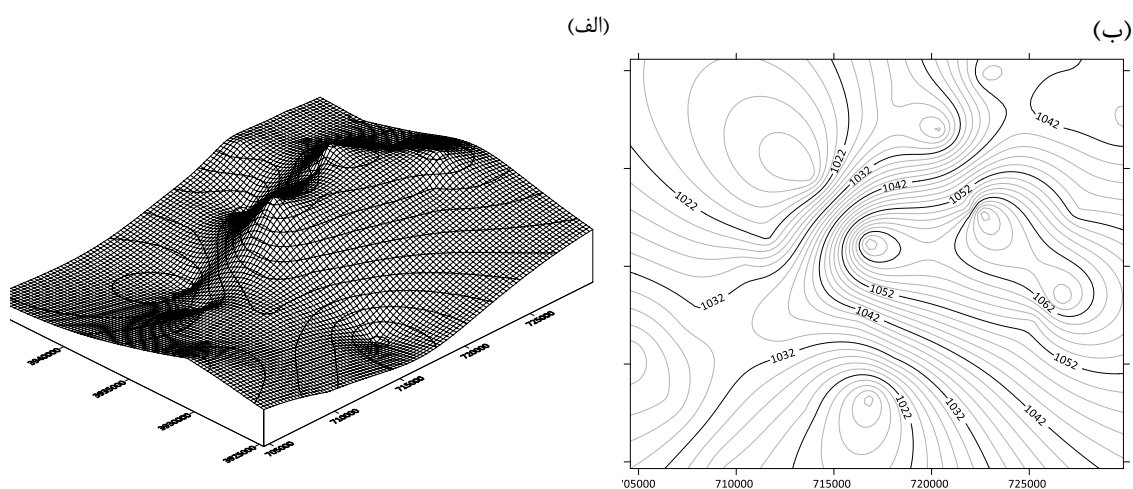
باتوجه به نتایج بدست آمده، می‌توان از الگوریتم ANFIS به منظور تعمیم برای سایر پیرومترهای دشت سمنان استفاده کرد.

مدل‌سازی مکانی

به منظور تبدیل داده‌های نقطه‌ای به منطقه‌ای از روش میان‌یابی کریجینگ و وزن‌دهی عکس فاصله استفاده می‌شود (طباطبائی و غزالی، ۱۳۹۰). در این مطالعه برای پیش‌بینی مکانی از نرم افزار surfer15 استفاده شده است. بدین طریق که خروجی پیش‌بینی زمانی به عنوان ورودی نرم‌افزار قرار می‌گیرد. روش‌های

جدول (۸): نتایج مربوط به مدل‌سازی با روش‌های زمین آمار

| RMSE | MAE | R ² | نوع روش زمین-آماری | |
|------------|------------|----------------|--------------------|---------|
| ۶.۸۲۰۹۲۴۹۲ | ۴.۹۶۲۸۴۸۶۳ | ۰.۵۸۹۳۸۱۷ | IDW-2 | IDW |
| ۶.۱۵۰۵۲۲۳ | ۴.۷۸۱۱۱۳۳۵ | ۰.۶۱۹۷۹۵۹ | IDW-3 | |
| ۵.۹۵۱۱۸۵۷۹ | ۴.۶۶۰۲۱۱۱۴ | ۰.۶۳۱۶۳۹۱ | IDW-4 | |
| ۵.۳۵۹۸۶۱۲ | ۳.۲۷۱۹۵۵۶۱ | ۰.۸۹۶۸۹۳۶ | Linear | KRIGING |
| ۳.۲۱۷۶۱۱۲۷ | ۱.۹۵۲۳۴۲۹۳ | ۰.۸۶۱۰۴۵ | Gaussian | |



شکل (۸): نمایش سه بعدی (الف) و (ب) خطوط توپوگرافی پهنبندی مکانی تراز آب زیرزمینی دشت سمنان در مهرماه ۱۳۹۵ با روش کریجینگ خطی

دارای دقت مناسب و ضریب همبستگی بالا در مدل-سازی آب زیرزمینی دشت سمنان می‌باشد. با توجه به این جدول دقت خوب روش کریجینگ خطی قابل مشاهده است.

به منظور بررسی میزان دقت و کارایی مدل ایجاد شده، از تلفیق ANFIS و روش‌های زمین‌آماری، مقادیر خروجی روش‌های زمین‌آماری با مقادیر واقعی تراز آب زیرزمینی مقایسه شد. که نتایج آن در جدول (۹) آورده شده است. همان‌طور که مشاهده می‌شود چنین تلفیقی

جدول (۹): مقایسه روش‌های زمین‌آمار و مقادیر واقعی تراز آب زیرزمینی

| RMSE | MAE | R ² | نوع روش زمین-آماری | |
|-------------|-------------|----------------|--------------------|---------|
| ۶.۸۱۶۱۲۸۵۲ | ۴.۴۹۰۶۷۹۱۱۸ | ۰.۶۳۴۸۱۲۸۰۸ | IDW-2 | IDW |
| ۵.۹۹۹۶۵۵۲۹۸ | ۴.۱۷۰۴۶۶۸۹۸ | ۰.۶۳۸۸۵۴۵۸۴ | IDW-3 | |
| ۵.۷۳۷۹۱۳۶۷۹ | ۴.۱۷۲۹۵۳۲۳۵ | ۰.۶۳۵۰۰۵۶۹۷ | IDW-4 | |
| ۴.۷۶۸۴۰۶۷۵۴ | ۲.۶۴۱۷۰۵۱۷۹ | ۰.۸۸۹۵۰۱۵۳۹ | Linear | KRIGING |
| ۳.۳۷۶۵۷۴۵۰۴ | ۱.۱۹۱۶۱۲۰۸ | ۰.۸۸۸۹۰۹۹۵۷ | Gaussian | |

نتیجه گیری

در این مطالعه از روش‌های مبتنی بر هوش مصنوعی همچون شبکه عصبی مصنوعی، شبکه توابع مبنا شعاعی، سیستم استنتاجی عصبی-فازی تطبیقی و رگرسیون بردار پشتیبان و از سوی دیگر مدل‌سازی خود رگرسیون میانگین متحرک استفاده شد. توانایی روش و مدل‌های زمین‌آمار برای پیش‌بینی زمانی و مکانی سطح ایستابی آبخوان دشت سمنان مورد ارزیابی قرار گرفت. با توجه به نتایج بدست آمده، مشخص گردید که

در پیش‌بینی زمانی سطح آب زیرزمینی آبخوان دشت سمنان، گرچه تمامی مدل‌سازی‌ها پیش‌بینی مناسبی را همراه داشته است. اما روش ANFIS، بهترین نتایج را بدست آورده است. برای پیش‌بینی مکانی سطح ایستابی آبخوان دشت سمنان روش کریجینگ خطی نسبت به روش‌های دیگر دارای دقت بالاتری می‌باشد. بنابراین می‌توان گفت که با استفاده از تلفیق سیستم استنتاجی عصبی- فازی تطبیقی و روش‌های زمین-آمار، یک ابزار مطمئن جهت پیش‌بینی زمانی و مکانی تراز آب زیرزمینی بدست می‌آید.

منابع

- جهانشاهی، ا. و ع. مقدم‌نیا. ۱۳۹۰. پیش‌بینی تراز آب زیرزمینی با استفاده از شبکه‌های عصبی مصنوعی (مطالعه موردی دشت شهر بابک استان کرمان). دومین کنفرانس مدیریت و برنامه‌ریزی محیط زیست، دانشگاه تهران، دانشکده محیط زیست.
- چاهکوتاهی، ف. و م. خاشعی. ۱۳۹۸. پیش‌بینی بار الکتریکی با بکارگیری مدل‌های ترکیبی پرسپترون‌های چندلایه و خودرگرسیون میانگین متحرک انباشته فصلی. روش‌های هوشمند در صنعت برق، سال دهم، شماره چهل، ص ۴۴-۳۵.
- حیبی، م. ح. ع. ندیری، ا. اصغری مقدم. ۱۳۹۴. ارائه مدل ترکیبی ژنتیک-کریجینگ برای پیش‌بینی زمانی و مکانی سطح آب زیرزمینی (مطالعه موردی: دشت هادیشهر). تحقیقات منابع آب ایران، سال یازدهم، شماره ۳، ص ۸۵-۹۹.
- حداد، ع. و ا. خراسانی. ۱۳۹۸. اثر تغییرات سطح آب زیرزمینی بر فرونشست دشت سمنان. علوم زمین، سال بیست و هشتم، شماره ۱۱۲، ص ۱۹۰-۱۸۱.
- حسنی‌پاک، ع. ا. ۱۳۷۷. زمین‌آمار. انتشارات دانشگاه تهران.
- دهقانی، ا. ا. م. عسگری و ا. مساعدی. ۱۳۸۸. مقایسه سه روش شبکه عصبی مصنوعی، سیستم استنتاجی فازی-عصبی تطبیقی و زمین‌آمار در میان‌یابی سطح آب زیرزمینی (مطالعه موردی دشت قزوین). مجله علوم کشاورزی و منابع طبیعی، جلد شانزدهم، ویژه‌نامه ۱-ب، ۵۳۶-۵۱۷.
- دهقانی، ر. و ع. نورعلینی. ۱۳۹۵. مقایسه روش‌های زمین‌آمار و شبکه عصبی مصنوعی در تخمین سطح آب زیرزمینی (مطالعه موردی: دشت نورآباد، استان لرستان). فصلنامه علوم و تکنولوژی محیط زیست، دوره هجدهم، شماره ۱، ۳۳-۴۴.
- رضانی چرمهینه، ع. و م. ذونعمت کرمانی. ۱۳۹۶. بررسی کارایی روش‌های رگرسیون بردار پشتیبان، شبکه عصبی پرسپترون چندلایه و رگرسیون خطی چندمتغیره به منظور پیش‌بینی تراز سطح آب زیرزمینی (مطالعه موردی: دشت شهرکرد). پژوهشنامه مدیریت حوزه آبخیز، دوره ۸، شماره ۱۵، ص ۱۲-۱.
- سمنان، شرکت مدیریت منابع آب ایران، شرکت سهامی آب منطقه‌ای سمنان.

- طباطبائی، س. ح. و م. غزالی. ۱۳۹۰. ارزیابی دقت روش‌های میان‌یابی در تخمین سطح ایستابی آب زیرزمینی (مطالعه موردی: آبخوان‌های فارسان، جونقان و سفید دشت). مجله علوم و فنون کشاورزی و منابع طبیعی، سال پانزدهم، شماره پنجاه و هفتم، ص ۲۲-۱۱.
- کارآموز، م. و ش. عراقی‌نژاد. ۱۳۸۹. هیدرولوژی پیشرفته. انتشارات دانشگاه صنعتی امیرکبیر.
- کماسی، م. ح. گودرزی و ا. بهنیا. ۱۳۹۶. بررسی روند نوسانات مکانی-زمانی سطح ایستابی آب‌های زیرزمینی به روش ماشین بردار پشتیبان (SVM) و کریجینگ (kriging) (مطالعه موردی دشت سیلاخور). نشریه پژوهش‌های حفاظت آب و خاک، جلد ۲۴، شماره ۴، ص ۲۰۹-۱۹۵.
- کیا، س. م. ۱۳۹۰. شبکه‌های عصبی در MATLAB. تهران، انتشارات کیان رایانه سبز.
- محمدی، م. ح. کرمی، س. فرزین و ع. ر. فرخی. ۱۳۹۶. پیش‌بینی بارش ماهانه بر اساس سیگنال‌های بزرگ مقیاس اقلیمی با به کارگیری مدل‌های هوشمند و رگرسیون خطی چندگانه (مطالعه موردی: ایستگاه سینوپتیک سمنان). اکو هیدرولوژی، دوره ۴، شماره ۱، ص ۲۱۴-۲۰۱.
- منهاج، م. ب. ۱۳۸۱. مبانی شبکه‌های عصبی و هوش محاسباتی. انتشارات دانشگاه صنعتی امیرکبیر.
- نیک‌منش، م. ر. ۱۳۹۰. کاربرد روش‌های تلفیقی هوش مصنوعی در پیش‌بینی تراز آب زیرزمینی دشت خرامه مرودشت فارس. چهارمین کنفرانس مدیریت منابع آب ایران، اردیبهشت ۱۳۹۰، دانشگاه صنعتی امیرکبیر.
- Anderson, J. A. 1995. An introduction to neural networks. MIT, Cambridge.
- Box, G. E. P & G. M. Jenkins. 1970. Time series analysis: Forecasting and control. San Francisco: Holden-day.
- Chang, F. J & Y. T. Chang. 2005. Adaptive neuron-fuzzy inference system for prediction of water level in reservoir. *Advances in Water Resources*, 29(1): 1-10.
- Chen, S. H., Y. H. Lin, L. C. Chang & F. J. Chang. 2006. The strategy of building a flood forecast model by neuro fuzzy network. *Hydr Proc* 20: 1525-1540.
- Daliakopoulos, I. N., P. Coulibaly & I. K. Tsani. 2008. Improving groundwater level forecasting with a feed forward neural network and linearly regressed projected precipitation. *Journal of hydroinformatics* 10(4): 317-330.
- Das, U. K., P. Roy & D. K. Ghose. 2019. Modeling water table depth using adaptive Neuro-Fuzzy Inference System. *ISH Journal of Hydraulic Engineering*, 25(3): 291-297.
- Dibike, Y.B., D. Solomatine and M. B. Abbott. 1999. On the encapsulation of numerical-hydraulic models in artificial neural network, *Journal of Hydraulic Research*, 37(2): 147-161.
- Jang, J. S. R, C. T. Sun and E. Mizutani. 1997. *Neurofuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Prentice-Hall, New Jersey.
- Jang, J. S. R. 1993. ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on System Management and Cybernetics* 23(3): 665-685.
- Mason, J.C., R. K. Price and A. Temme. 1996. A neural network model of rainfall- runoff using radial basis functions. *J. of Hydraulic Research*, 34: 537-548.
- Millero, F. J., R. Feistel, D. J. Wright and T. J. McDougall. 2008. The composition of Standard Seawater and the definition of the Reference-Composition Salinity Scale. *Deep Sea Research*, 55(1): 50-72.
- Mirarabi, A., H. R. Nassery, M., Nakhaei, J., Adamowski, A. H. Akbarzadeh & F. Alijani. 2019. Evaluation of data-driven models (SVR and ANN) for groundwater-level prediction in confined and unconfined systems. *Environmental Earth Sciences*, 78(15): 489.
- Moghaddamnia, A., R. Remesan, M. Hassanpour Kashani, M. Mohammadi, D. Han & J. Piri. 2009. Comparison of LLR, MLP, Elman, NNARX and ANFIS models with a case study in solar radiation estimation. *J. Atmos. Sol.-Terr. Phys.* 71, 975-982.
- Mokhtarzad, M., F. Eskandari, N. J. Vanjani & A. Arabasadi. 2017. Drought forecasting by ANN ANFIS and SVM and comparison of the models. *Environ Earth Sci* 76(21): 729.



Murphy, R. R., F. C. Curriero, W. P. Ball and M. Asce. 2010. Comparison of spatial interpolation methods for water quality evaluation in the Chesapeake Bay. *Journal of Environmental Engineering*, 136: 160-171.

Platt, J. C. 1999. Fast training of support vector machines using sequential minimal optimization. In: Scholkopf B, Burges CJC, Smolar AJ (eds) *Advances in Kernel methods—support vector learning*. MIT Press, Cambridge.

Porte, P., R. K. Isaac, K. Kiran & S. Mahilang. 2018. Groundwater level prediction using artificial neural network model. *Int. J. Curr. Microbiol. Appl. Sci*, 7(02): 2947-2954.

Shiri, J., O. Kisi, H. Yoon, K. K. Lee & A. H. Nazemi. 2013. Predicting groundwater level fluctuations with meteorological effect implications- A comparative study among soft computing techniques. *Comput Geosci* 56: 32– 44.

Smola, J. Alex & B. Scholkopf. 1998. A tutorial on support vector regression. Royal Holloway College, London, UK, NeuroCOLT, Technical Report Series.

Smola. 1996. Regression estimation with support vector learning machines.

Sujatha, P & G. N. Kumar. 2007. Prediction of water level using different artificial neural network architectures and algorithms. *current science*, 93(4): 732-739.

Vapnik, V. N. 1998. *Statistical Learning Theory*, 1st edn. John Wiley, New York.

Woo, S. M., H. Kim & S. S. Chirayath. 2020. Influence of the spatial Pu variation for evaluating the Pu content in spent nuclear fuel using Support Vector Regression. *Annals of Nuclear Energy*, 135: 106997.

Yoon, H., S. C. Jun, Y. Hyun, G. O. Bae & 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(1-2): 128-138.



Estimation of Temporal and Spatial Variations of Groundwater Level by Combining Intelligent Models and Geostatistical Methods (Semnan Plain)

Mobina Rabiee¹, Hojat Karami^{2*}

Abstract

Due to the complexity of the nature of groundwater systems as well as the limitations of borehole drilling, temporal and spatial modeling of groundwater levels are not readily possible. Artificial intelligence methods such as RBF, ANN, SVR, ANFIS and ARIMA modeling and their combination with geostatistical methods have been used to find useful solutions for spatial prediction of groundwater level. The case study of this study is Semnan plain. The first step is the temporal modeling of groundwater level using different methods. The results showed that the ANFIS model provides more accurate prediction of the monthly groundwater level in the experimental stage than other methods ($R^2 = 0.994$ and $RMSE = 0.041$). Next step, the ANFIS output data is used as input data for the geostatistical model and the linear kriging model is selected as the best model for spatial development of groundwater level. ($R^2 = 0.8889$ and $RMSE = 2.376$). The results of this study showed that the combination of ANFIS model and linear kriging model is an appropriate method for temporal and spatial prediction of groundwater level.

Keywords: time forecast, spatial forecast, groundwater level, geostatistical,

¹ MSc student in water resources engineering and management, Faculty of Civil Engineering, Semnan University
mobina.rabiee@semnan.ac.ir

² Associate Professor, Department of Water Engineering and Hydraulic Structures, Faculty of Civil Engineering hkarami@semnan.ac.ir (Author)

Research Paper

Estimation of temporal and spatial variations of groundwater level by combining intelligent models and geostatistical methods

Mobina Rabiee¹,Hojat Karami²

¹ M.Sc Student of Water Resources Engineering and Management, Faculty of Civil Engineering, Semnan University, Semnan, Iran. Email: (mobina.rabiee@semnan.ac.ir).

² Associate Professor, Department of Water Engineering and Hydraulic Structures, Faculty of Civil Engineering. Email: (hkarami@semnan.ac.ir).



10.22125/IWE.2020.217535.1293

Received:
September.28.2019
Accepted:
February.18.2019
Available online:
March.13.2022

Keywords:
**time forecast, spatial
forecast, groundwater
level, geostatistical.**

Abstract

Due to the complexity of the nature of groundwater systems as well as the limitations of borehole drilling, temporal and spatial modeling of groundwater levels are not readily possible. Artificial intelligence methods such as RBF, ANN, SVR, ANFIS and ARIMA modeling and their combination with geostatistical methods have been used to find useful solutions for spatial prediction of groundwater level. The case study of this study is Semnan plain. The first step is the temporal modeling of groundwater level using different methods. The results showed that the ANFIS model provides more accurate prediction of the monthly groundwater level in the experimental stage than other methods ($R^2 = 0.994$ and $RMSE = 0.041$). Next step, the ANFIS output data is used as input data for the geostatistical model and the linear kriging model is selected as the best model for spatial development of groundwater level. ($R^2 = 0.8889$ and $RMSE = 2.376$). The results of this study showed that the combination of ANFIS model and linear kriging model is an appropriate method for temporal and spatial prediction of groundwater level.

1. Introduction:

In order to increase the population, the need for water has increased. With the decline of surface water, humans have been forced to use groundwater, especially in arid and semi-arid regions. Improper use of these resources has led to problems such as drying up water wells, increasing the cost of pumping and landslides. To avoid the mentioned problems, accurate forecasting of the volume of these resources should be done Habibi et al (2015). In recent decades, the use of intelligent models due to high processing speed, high accuracy and cost and time less than other methods have been used in various sciences, especially groundwater. However, the use of geostatistical models is widely used in spatial prediction of groundwater levels. Porte et al (2018) Groundwater level predictions using ANN are considered. Twenty-year rainfall data were used as neural network inputs to predict groundwater levels. Das et al (2019) Water level depth modeling has been done using ANFIS. They also predicted the water

level depth by comparing ANN and ANFIS methods, which was associated with a decrease in membership functions in the fuzzy model. Dehghani et al (2009) compared three methods ANN, ANFIS and geostatistics in groundwater level interception. The geometric coordinates of the observation wells are used as inputs and the groundwater level values are used as outputs. Habibi et al (2015) In order to predict the temporal and spatial groundwater level have presented a combined genetic-kriging model, which has generalized results for generalization in the whole plain and areas without groundwater level measurement. Kamasi et al (2017) spatial-temporal prediction of groundwater level by support vector machine and kriging method. In order to spatially predict the output of temporal modeling, it was used as the input of the geostatistical model. The results showed that the more accurate the selection of models and their fitting, the more accurate the predictions will be. Researchers' studies indicate the optimal accuracy of geostatistical methods, especially linear kriging. Also, ANFIS, SVR, ANN and RBF algorithms have been used to predict the groundwater level. On the other hand, the combination of geostatistical methods and intelligent methods is used to extend the simulation results in the whole study area without piezometer.

2. Methodology:

In the present study, monthly data on groundwater level variation, precipitation, average minimum temperature, and minimum relative humidity have been used to predict groundwater level. Groundwater level in Semnan plain has decreased over time by using algorithms of artificial neural network (ANN), Base radius function (RBF), Support vector regression (SVR), Adaptive neural fuzzy inference system (ANFIS) and Auto Regressive integral moving average (ARIMA). Also, in spatial prediction of groundwater level Geostatistics methods of kriging and Inverse distance weighted (IDW) were used. In this regard, the 1996-2013 is considered as the training period, 2013-2017 is considered as the test period. It worth mentioning that the correlation coefficient (R^2), root mean square error (RMSE), and mean absolute error (MAE) are employed for investigating the accuracy of the algorithms.

3. Results and Conclusion:

Based on the findings, ANFIS algorithm is superior to other algorithms. This better accuracy of ANFIS to other algorithms is because ANFIS makes it possible to extract fuzzy data rules from numerical data and perform them based on rule-based adaptation. One of the advantages of the methods used is that the well water table has not been measured in some months and the proposed model can predict the water level for that time. According to the observational data of the region in the last 20 years, using the mentioned models, the highest correlation coefficient and the lowest error estimation criterion are considered. In order to convert point data to a region, kriging interpolation method and Inverse distance weighted were used that linear kriging method performed better. In order to evaluate the accuracy and efficiency of the created model, by combining ANFIS and geostatistical methods, the output values of geostatistical methods were compared with the actual values of groundwater level. Therefore, it can be said that by using a combination of adaptive neural-fuzzy inference system and geostatistical methods, a reliable tool for temporal and spatial prediction of groundwater level is obtained.

4. The most important references:

1. Dehghanil, A.A., M. Asgare & A. Mosaede. 2009. Comparison of Geostatistics, Artificial Neural Networks and Adaptive Neuro-Fuzzy Inference System Approaches in Groundwater Level Interpolation (Case study: Ghazvin aquifer) Journal of Agricultural Sciences and Natural Resources, Volume 16, Issue 1-B, 536-517.
2. Ramezani-Charmahineh, A. and M. Zounemat-Kermani. 2017. Evaluation of the Efficiency of Support Vector Regression, Multi-Layer Perceptron Neural Network and Multivariate Linear Regression on Groundwater Level Prediction (Case Study: Shahrekord Plain). Journal of Watershed Management, Volume 8, Number 15, Page 12- 1.

3. Daliakopoulos, I. N., P. Coulibaly & I. K. Tsani. 2008 .Improving groundwater level forecasting with a feed forward neural network and linearly regressed projected precipitation. *Journal of hydroinformatics* 10(4): 317-330.

4. Das, U. K., P. Roy & D. K. Ghose. 2019. Modeling water table depth using adaptive Neuro-Fuzzy Inference System. *ISH Journal of Hydraulic Engineering*, 25(3): 291-297.

5. Mohammadi, M., H. Karami, S. Farzin and Farokhi, A.R. 2018. Monthly precipitation forecast based on large scale climatic signals using intelligent models and multiple linear regression) Case study: Semnan Synoptic Station (*Echo Hydrology*, Volume 4, Number 1, pp. 214-201).

6. Mirarabi, A., H. R. Nassery, M., Nakhaei, J., Adamowski, A. H. Akbarzadeh & F. Alijani. 2019. Evaluation of data-driven models (SVR and ANN) for groundwater-level prediction in confined and unconfined systems. *Environmental Earth Sciences*, 78(15): 489.

7. Mokhtarzad, M., F. Eskandari, N. J. Vanjani & A. Arabasadi. 2017. Drought forecasting by ANN ANFIS and SVM and comparison of the models. *Environ Earth Sci* 76(21): 729.

Conflict of Interest

Authors declared no conflict of interest.