دانشگاه علوم کشاورزی و منابع طبیعی ساری
پژوهشنامه مدیریت حوزه آبخیز

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)

عبداله رمضانی چرمهینه[۱] و محمد ذونعمت کرمانی[۲]

۱- دانش‌آموخته کارشناسی ارشد، دانشگاه شهید باهنر کرمان
۲- دانشیار، دانشگاه شهید باهنر کرمان، (نویسنده مسوول: zounemat@uk.ac.ir)
تاریخ دریافت: ۹۳/۵/۲ تاریخ پذیرش: ۹۴/۱/۲۲

چکیده

تراز سطح آب زیرزمینی عاملی است که امکان قضاوت صحیح در مورد روند تغییرات آبخوان و مدیریت لازم در حوزه آبخیز را ایجاد می‌کند. در این تحقیق از اطلاعات ماهانه ۱۸ چاه مشاهده‌ای در دشت شهرکرد طی سال‌های ۱۳۷۹ تا ۱۳۸۹ به منظور شبیه‌سازی و پیش‌بینی سطح آب زیرزمینی با مدل‌های رگرسیون خطی چند متغیره (MLR)، شبکه عصبی پرسپترون چند لایه (MLP) و دو مدل رگرسیونی ماشین بردار پشتیبان (SVR) با توابع کرنل پایه شعاعی (RBF) و خطی (Linear) استفاده‌شده است. با توجه به معیارهای خطای ضریب راندمان (NS) و ریشه میانگین مربعات خطا (RMSE)، مدل MLP در ٥٦ درصد و مدل SVR نیز در ٤٤ درصد موارد عملکرد بهتری نسبت به نتایج کل سایر مدل‌ها داشته‌اند. به‌عنوان نمونه در چاه شماره ۱ (بخش مرکزی دشت)، مدل SVR-RBF با ترکیب ورودی پارامترهای متشکل از تراز سطح آب زیرزمینی، دما، تبخیر و بارش بر سایر مدل‌ها برتری داشته است. همچنین مقایسه کلی نتایج دو روش SVR، حاکی از برتری تابع کرنل RBF بر حالت خطی بوده است. عملکرد کلی مدل‌های MLP، SVR-RBF و SVR-Linear برای معیار NS به ترتیب برابر با ۰/۷۰۳، ۰/٦٥٦ و ۰/٦٥٥ و در شاخص RMSE نیز به ترتیب برابر با ۰/۸۵۷، ۰/۹۰۵ و ۰/۹۱٤ متر به دست آمده است.

واژه‌های کلیدی: پیش‌بینی سطح آب زیرزمینی، رگرسیون بردار پشتیبان، شبکه عصبی پرسپترون، رگرسیون چند متغیره، دشت شهرکرد

مقدمه

امروزه منابع آب یکی از پایه‌های اصلی توسعه‌ی پایدار به شمار می‌روند (۱۶) و در بیشتر مناطق ایران، منابع آب‌های سطحی محدود هستند و حتی در بعضی مناطق، این منابع وجود ندارند (۲). شایان توجه است که قسمت عمده‌ای از کشور ایران با توجه به موقعیت خاص جغرافیایی خود دارای اقلیم خشک تا نیمه‌خشک می‌باشد به‌طوری‌که ۷۴ درصد از سطح کشور دارای بارندگی سالانه کمتر از ۲۵۰ میلی‌متر است. به دلیل کمبود نزولات جوی، عدم پراکنش متعادل آن ازنظر زمانی و مکانی و همچنین عدم وجود رودخانه‌های دائمی در مناطق خشک و نیمه‌خشک، بهره‌برداری از منابع آب زیرزمینی در این مناطق در سطح وسیع و گسترده صورت می‌گیرد (۱۳). ازاین‌رو یکی از مباحث مهم در مدیریت حوزه آبخیز، پیش‌بینی تراز سطح آب زیرزمینی است تا بتوان با توجه به آن، برنامه‌ریزی‌های لازم در این زمینه را انجام داد و مدیریت موفق منابع آب در حوزه آبخیز نیازمند رویکردهای جهت‌دار، جامع و هدفمند می‌باشد تا بتواند باوجود روند تشدید مشکلات مربوط به آب و افزایش رو به رشد تقاضای آن، نیاز مصرف‌کنندگان را برطرف سازد. از طرفی در سال‌های اخیر، رشد روزافزون کاربرد هوش محاسباتی در حل مسائلی مشاهده می‌شود که تأثیر پارامترهای بسیار زیاد در برخی فرآیندهای فیزیکی و وجود روابط کاملاً غیرخطی میان آن‌ها حاکم می‌باشد و مبنای روش‌های هوشمند، استفاده از دانش نهفته در داده‌ها، تلاش برای استخراج روابط ذاتی بین آن‌ها و تعمیم آن در موقعیت‌های دیگر است (۱۴). بنابراین بهره‌گیری از شیوه‌های نوین شبیه‌سازی منابع آب ازجمله روش‌های ماشین بردار پشتیبان (SVM)[۱] و شبکه عصبی مصنوعی (ANN)[۲] از اهمیت ویژه‌ای برخوردار می‌باشد. همچنین جهت مدیریت جامع‌تر آبخوان‌ها، توجه به روش‌های آماری هم خالی از لطف نیست. ازجمله این روش‌ها، رگرسیون خطی چند متغیره (MLR)[۳] را می‌توان نام برد (۲۶). یو و همکاران (۲۵) با استفاده از مدل ماشین بردار پشتیبان به پیش‌بینی تراز آب در رودخانه لانیانگ در تایوان پرداختند. نتایج نشان داد که مدل به‌خوبی سطح آب رودخانه را برای ۱ تا ۶ ساعت بعد پیش‌بینی می‌کند. لیجن و شیکوآن (۱۲) روش حداقل مربعات ماشین بردار پشتیبان را در پیش‌بینی رواناب میان‌مدت و بلندمدت به کار گرفتند و آن را با مدل شبکه عصبی مصنوعی مقایسه کردند. نتایج نشان داد که ماشین بردار پشتیبان عملکرد بهتری داشته است. یون و همکاران (۲۴) روش‌های ماشین بردار پشتیبان و شبکه عصبی مصنوعی را برای پیش‌بینی تراز سطح آب زیرزمینی آبخوان ساحلی در کره جنوبی بررسی کردند. نتایج حاکی از کارایی دو روش بود به‌طوری‌که جذر میانگین مربعات خطا در مدل شبکه عصبی مصنوعی در مراحل آموزش و آزمون کمتر بوده است اما ضریب راندمان بیشتر در ماشین بردار پشتیبان موجب عملکرد بهتر آن شده است. لالاهیم و همکاران (۱۱) شبکه عصبی مصنوعی را در جهت ارزیابی تراز سطح آب زیرزمینی در آبخوانی آهکی در شمال فرانسه به کار گرفتند. نتایج حاکی از این بود که شبکه پرسپترون چندلایه (MLP)[۴] با حداقل نرون میانی در کوتاه‌مدت بهترین پیش‌بینی را انجام می‌دهد.

1- Support Vector 2- Artificial Neural Network 3- Multivariate Linear Regression 4- Multi-Layer Perceptron

[Downloaded from jwmr.sanru.ac.ir on 2026-11-28]
[DOI: 10.29252/jwmr.8.15.1]

سریکنت و همکاران (۲۲) تحقیقی در مورد کاربرد شبکه عصبی در پیش‌بینی نوسان‌های زمانی سطح آب زیرزمینی در حوزه آبخیز مهشوارم در هندوستان انجام دادند. این تحقیق مؤید قابلیت شبکه عصبی مصنوعی در پیش‌بینی تراز سطح آب زیرزمینی با ریشه میانگین مربعات خطای ۴/۵ متر و ضریب تعیین ۰/۹۳ بود. رامیرز و همکاران (۱۸) مدل‌های رگرسیون خطی چند متغیره و شبکه عصبی را برای پیش‌بینی بارش در منطقه سائوپائولو در برزیل به کار گرفتند. دمای پتانسیل، مؤلفه قائم باد، رطوبت ویژه، دمای هوا، آب قابل بارش، چرخندگی نسبی و شار واگرایی رطوبت پارامترهای ورودی به مدل را تشکیل دادند. نتایج کارایی قابل‌قبول هر دو روش را در پیش‌بینی بارش نمایان کرد. محققین مختلفی از روش‌های رگرسیون خطی چند متغیره، شبکه عصبی مصنوعی و ماشین بردار پشتیبان به‌عنوان ابزارهایی مناسب و کارآمد در پژوهش‌های حوزه‌های آبخیز استفاده کرده‌اند. درنتیجه آبخوان‌ها از اهمیت زیادی در حوزه‌های آبخیز برخوردار هستند و تراز سطح آب زیرزمینی عامل مهمی در استفاده از آبخوان‌ها و مدیریت صحیح آن‌ها می‌باشد. تحقیق حاضر به ارزیابی کارایی روش‌های یادشده در پیش‌بینی تراز سطح آب زیرزمینی در دشت شهرکرد می‌پردازد.

مواد و روش‌ها

منطقه مورد مطالعه

دشت شهرکرد با وسعتی نزدیک به ۵۵۱ کیلومترمربع در ناحیه زاگرس بلند و استان چهارمحال و بختیاری و نیز در طول جغرافیایی ′۳۸ °۵۰ تا ′۱۰ °۵۱ شرقی و عرض جغرافیایی ′۰۷ °۳۲ تا ′۳۵ °۳۲ شمالی قرارگرفته است. این دشت دارای ۴۱۷ حلقه چاه کشاورزی، ۵۹ حلقه چاه آب شرب، ۱۵۹ حلقه چاه صنعتی، ۷۹ رشته قنات و ۴۰ دهنه چشمه فعال است که سالانه حدود ۲۳۰ میلیون مترمکعب از منابع آب زیرزمینی دشت را تخلیه کرده و به مصارف گوناگون می‌رساند. درصد بسیار بالایی از آن (بیش از ۹۰ درصد) در بخش کشاورزی در فصل زراعی استفاده می‌شود. بخشی از آب شرب مردم شهرستان شهرکرد نیز از همین چاه‌ها تأمین می‌شود (۱۰). موقعیت جغرافیایی دشت شهرکرد در شکل ۱ نشان داده‌شده است.

روش‌های مورداستفاده در این تحقیق

رگرسیون خطی چند متغیره

رگرسیون خطی چند متغیره از روش‌هایی است که برای پیش‌بینی پدیده‌ها استفاده می‌شود (۹). این روش رابطه یک متغیر وابسته و مجموعه‌ای از متغیرهای مستقل را به‌طور همزمان مورد تجزیه و تحلیل قرار می‌دهد (۸). شکل کلی این مدل به‌صورت رابطه ۱ می‌باشد.

$$Y = a + B_1X_1 + B_2X_2 + ... + B_nX_n + e \qquad (۱)$$

Y: متغیر وابسته، a: عدد ثابت مدل، $X_1, X_2, ..., X_n$ متغیرهای مستقل، $B_1, B_2, ..., B_n$ ضرایب مربوط به هر یک از متغیرهای مستقل و e: خطای مدل رگرسیون می‌باشند.

شبکه عصبی پرسپترون چندلایه

در شبکه‌های چندلایه یک‌لایه ورودی وجود دارد که اطلاعات را دریافت می‌کند و دارای تعدادی لایه مخفی است که اطلاعات را از لایه‌های قبلی می‌گیرد. در اصل وجود لایه پنهان زمانی مفید است که تابع فعال‌سازی غیرخطی باشد و درنهایت یک‌لایه خروجی نیز وجود دارد که نتیجه محاسبات وارد آن و خروجی شبکه حاصل می‌شود (۱). در این شبکه‌ها مقادیر خروجی با مقادیر واقعی مقایسه شده و میزان خطا مشخص می‌گردد. سپس خطای محاسبه‌شده جهت تنظیم وزن‌ها و مقادیر بایاس شبکه پخش می‌شود که این روش به پس انتشار خطا موسوم است (۱۵،۲۷،۲۸).

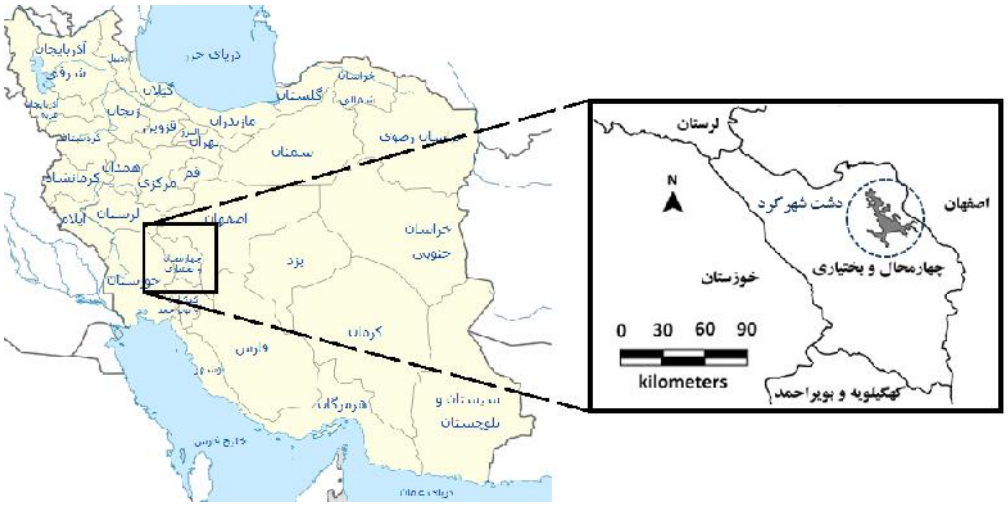

شکل ۱- موقعیت جغرافیایی دشت شهرکرد
Figure 1. Geographical location of the Shahrekord Plain

[Downloaded from jwmr.sanru.ac.ir on 2026-11-28]

[DOI: 10.29252/jwmr.8.15.1]

ماشین بردار پشتیبان

SVM یک نوع سیستم یادگیری نظارت‌شده است که هم برای گروه‌بندی و هم برای تخمین و برآورد تابع برازش داده‌ها در مسائل رگرسیون به کار می‌رود به‌طوری‌که کمترین خطا در گروه‌بندی داده‌ها یا تابع برازش رخ دهد. این روش بر مبنای تئوری یادگیری آماری[1] استوار است که از اصل کمینه‌سازی خطای ساختاری (SRM)[2] بهره می‌جوید و موجب یک جواب بهینه کلی می‌گردد (۲۳). هدف رگرسیون بردار پشتیبان (SVR)[3] که مدل رگرسیونی SVM می‌باشد این است که تابع $f(x)$ را برای الگوهای آموزشی x طوری تشخیص دهد که بیشینه حاشیه را از مقادیر آموزشی y داشته باشد. به‌عبارت‌دیگر مدل SVR مدلی است که منحنی باضخامت ε را به داده‌ها برازش می‌دهد به‌نحوی‌که کمترین خطا در داده‌های آزمون صورت گیرد (۲۰). در مدل SVM از مجموعه توابع به فرم $f(x) = w.x + b$ برای پیش‌بینی استفاده می‌شود که w وزن بردار x و b مقدار بایاس می‌باشند. برای کمینه کردن خطای آزمون باید عبارت پیچیدگی حداقل شود که مستلزم کمینه‌سازی نرم بردار وزن است. این شرایط می‌تواند به‌راحتی برای SVR با حاشیه نرم[4] گسترش داده شود. در حقیقت، وپنیک برای کاربرد ماشین بردار پشتیبان در مسائل رگرسیون از تابع خطای جدیدی استفاده کرد که خطاهایی را که در یک‌فاصله معین از مقادیر واقعی می‌باشند، نادیده می‌گیرد (۲۱). این موضوع بدان معناست که باید مقداری انحراف[5] از ε را قابل‌قبول دانست. انحراف اشاره‌شده به‌صورت رابطه ۲ تعریف می‌شود و بامنظور نمودن متغیرهای کمبود[6] ξ_i^+ و ξ_i^- در رابطه ۳ لحاظ می‌شود که درنهایت بر اساس اصل کمینه‌سازی خطای ساختاری، محدوده خطا به‌وسیله مسئله بهینه‌سازی[7] در رابطه ۳ مطلوب و بهینه می‌گردد.

$$|\xi|_\varepsilon = \begin{cases} 0 & \text{if } |\xi| \le \varepsilon \\ |\xi| - \varepsilon & \text{otherwise} \end{cases} \qquad (۲)$$

$$\varepsilon \quad \begin{cases} \text{Minimize}: \frac{1}{2}(w.w) + C\sum_{i=1}^{N}(\xi_i^+ + \xi_i^-) \\ \text{Constraints}: \begin{cases} w.x_i + b - y_i \le \varepsilon + \xi_i^+ & i = 1,2,3,...,N \\ y_i - (w.x_i + b) \le \varepsilon + \xi_i^- & i = 1,2,3,...,N \\ \xi_i^+ \ge 0 \ , \ \xi_i^- \ge 0 & i = 1,2,3,...,N \end{cases} \end{cases} \qquad (۳)$$

محدوده لوله تقریب را تعیین می‌کند و C[8] که ثابت گنجایش است خطای مربوط به انحراف بیشتر از ε را کنترل می‌کند. به‌طورکلی رگرسیون‌گیری داده‌ها به شیوه خطی به‌ندرت اتفاق می‌افتد و در عمل نحوه قرارگیری داده‌ها به‌صورت غیرخطی است. در این شرایط از روش غیرخطی رگرسیون بردار پشتیبان استفاده می‌شود. در این حالت الگوهای ورودی به فضایی با ابعاد بیشتر نگاشت می‌یابند به‌طوری‌که در فضای نگاشت یافته می‌توان به‌صورت خطی رگرسیون‌گیری کرد. معمولاً یافتن نگاشتی که مربوط به تابع کرنل خاصی باشد و یا پیدا کردن تابع کرنل[9] مربوط به نگاشتی ویژه، سخت و حتی غیرممکن می‌باشد. انتخاب تابع کرنل موضوع مهمی است که بر اساس آزمون، اطلاع از مسائل طبقه‌بندی و رگرسیون و همچنین ملاحظات نظری است (۶). از توابع کرنل شناخته‌شده در SVM می‌توان کرنل‌های خطی[10] و پایه شعاعی (RBF)[11] را نام برد (۴). معادله کرنل خطی به‌صورت رابطه ۴ می‌باشد. کرنل گوسی[12] که به‌عنوان تابع RBF شناخته می‌شود (۶) در رابطه ۵ مشخص‌شده است. طرح کلی از مدل‌های ماشین بردار پشتیبان و شبکه عصبی مصنوعی در شکل ۲ نشان داده‌شده است.

$$k(u,v) = u.v \qquad (۴)$$

$$k(u,v) = \exp\left(-\frac{\|u-v\|^2}{2\sigma^2}\right) \ , \ \frac{1}{2\sigma^2} = \gamma \qquad (۵)$$

پیش‌بینی تراز سطح آب زیرزمینی دشت شهرکرد

به‌منظور مدیریت و برنامه‌ریزی منابع آب در دشت شهرکرد می‌توان از پیش‌بینی تراز سطح آب زیرزمینی بهره گرفت. پیش‌بینی تراز سطح آب دشت می‌تواند پایه بسیاری از تصمیم‌گیری‌ها در فرآیندهای هیدرولوژیکی و بهره‌برداری از منابع آب در حوزه آبخیز باشد. بنابراین پارامترهای مجموع بارندگی ماهانه، مجموع تبخیر ماهانه، متوسط دمای ماهانه و تراز سطح آب زیرزمینی در ماه‌های قبل (بین ۱ تا ۱۳ ماه با توجه به تأخیر زمانی) به‌عنوان ورودی برای مدل‌های MLR، MLP و SVR در نظر گرفته‌شده است. جهت پیش‌بینی تراز سطح آبخوان از اطلاعات ۱۸ چاه مشاهده‌ای طی سال‌های ۱۳۷۹ تا ۱۳۸۹ استفاده‌شده است. در همه مدل‌ها از ۸۰ درصد اول داده‌ها برای آموزش و از ۲۰ درصد باقی‌مانده برای آزمون استفاده‌شده است.

موقعیت چاه‌های مشاهده‌ای مورداستفاده در شکل ۳ و ویژگی‌های آن‌ها در جدول ۱ مشخص‌شده است. وضعیت توپوگرافی نشان داده‌شده در شکل ۳، بیانگر مرتفع بودن نواحی شمال غربی و شرقی است. درحالی‌که نواحی مرکزی و جنوبی دشت دارای کمترین ارتفاع می‌باشند.

نحوه رفتار تغییرات تراز سطح آب زیرزمینی مربوط به ۴ چاه مشاهده‌ای در نواحی شمال غربی، مرکزی، شرقی و جنوبی دشت شهرکرد در شکل ۴ مشخص‌شده است که نشان‌دهنده نوسانات قابل‌توجه تراز سطح آب زیرزمینی در این دشت است.

پارامترهای ورودی به مدل

پارامترهای ورودی به مدل‌ها عبارت‌اند از: P (مجموع بارندگی ماهانه برحسب میلی‌متر)، E (مجموع تبخیر ماهانه برحسب میلی‌متر)، T (متوسط دمای ماهانه برحسب درجه سانتی‌گراد) و G (تراز سطح آب زیرزمینی برحسب متر). با استفاده از این پارامترها برای هر چاه مدل‌سازی انجام‌شده است.

تأخیر زمانی

با توجه به این‌که داده‌های موجود تشکیل سری زمانی می‌دهند در ابتدا تأخیر زمانی بر روی پارامترهای ورودی لحاظ شده است که به‌صورت $X-a$ مشخص‌شده است. X پارامتر ورودی و a تعداد ماه تأخیر می‌باشد. برای به دست آوردن مقدار تأخیر از توابع خودهمبستگی (ACF) و همبستگی متقابل (CCF) استفاده‌شده است. لازم به ذکر است با توجه به

1- Statistical learning theory
2- Structural Risk Minimizatio
3-Support Vector Regression
4- Soft margin
5-Deviation
6- Slack variables
7-Optimization problem
8- Capacity
9- kernel function
10- Linear
11- Radial Basis Function
12- Gaussian kernel

[Downloaded from jwmr.sanru.ac.ir on 2026-11-28]

[DOI: 10.29252/jwmr.8.15.1]

اهمیت و تأثیر زیاد تراز سطح آب زیرزمینی در ماه‌های قبل در مدل‌سازی، این پارامتر تا ۳ مرتبه تأخیر داده‌شده است. به‌عنوان نمونه، نمودارهای ACF و CCF برای چاه مشاهده‌ای شماره ۱ در شکل ۵ آورده شده‌اند.

همان‌طور که در نمودارهای شکل ۵، میزان بیشینه همبستگی بین پارامترهای ورودی به مدل (G، P، E و T) با خروجی از مدل (G) با علامت پیکان مشخص‌شده است، پیشنهاد می‌شود که پارامتر ورودی G (با توجه به نمودار الف) به‌اندازه ۱، ۲ و ۳ ماه تأخیر $(G-1\ ,\ G-2\ ,\ G-3)$ برای مدل‌سازی در نظر گرفته شود. به همین ترتیب با توجه به نمودارهای ب، ج و د پیشنهاد می‌شود که پارامترهای P به‌اندازه ۳ ماه $(P-3)$، E به‌اندازه ۸ ماه $(E-8)$ و T به‌اندازه ۳ ماه $(T-3)$ برای مدل‌سازی تأخیر یابند.

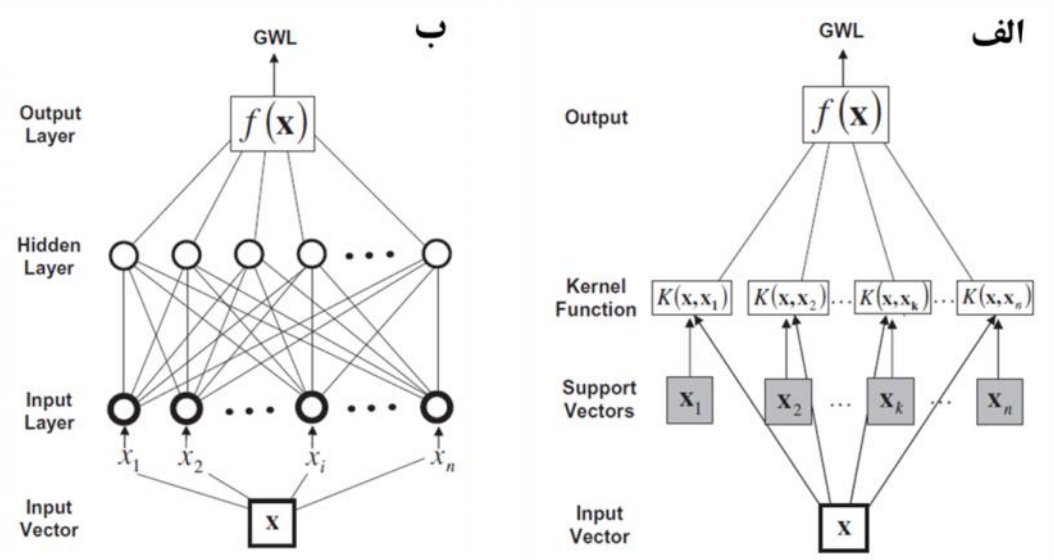

شکل ۲- طرح کلی از مدل‌های مورداستفاده در مطالعه حاضر، الف): ماشین بردار پشتیبان، ب): شبکه عصبی مصنوعی (۲۴)
Figure 2. A schematic diagram of the models used in this study: (a) SVM, (b) ANN [24]

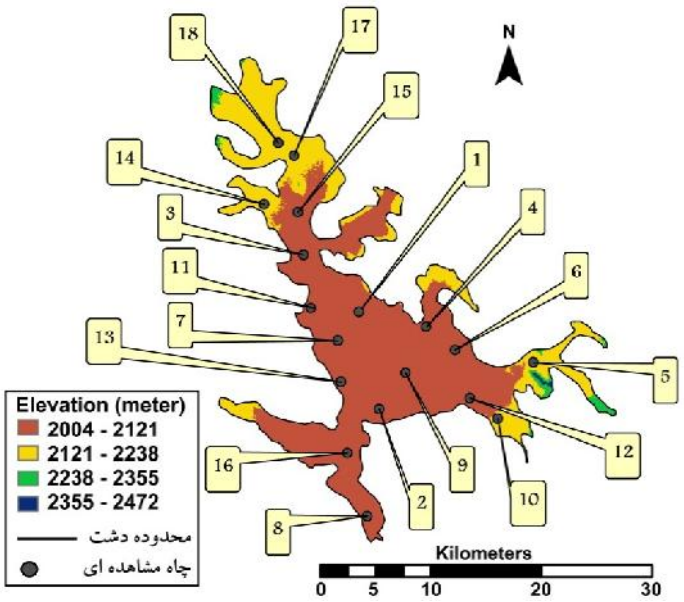

شکل ۳- نقشه پراکنش چاه‌های مشاهده‌ای مورداستفاده در مدل‌های MLR، MLP و SVR طی سال‌های ۱۳۷۹ تا ۱۳۸۹
Figure 3. Map of distribution of observational wells used in MLR, MLP and SVR models during 2000 to 2010

[Downloaded from jwmr.sanru.ac.ir on 2026-11-28]

[DOI: 10.29252/jwmr.8.15.1]

جدول ۱- مشخصات چاه‌های مشاهده‌ای به‌کاررفته در مدل‌های MLR، MLP و SVR طی سال‌های ۱۳۷۹ تا ۱۳۸۹

Table 1. Characteristics of observational wells used in MLR, MLP and SVR models during 2000 to 2010

شماره	نام محل	X_{UTM} (متر)	Y_{UTM} (متر)	تراز دهانه چاه (متر)
۱	اول قلنگان جاده کمربندی	۴۸۴۳۸۶	۳۵۷۶۸۶۸	۲۰۴۹/۴۲
۲	بهرام آباد	۴۸۶۲۱۹	۳۵۶۸۰۴۵	۲۰۴۰/۳۰
۳	چالشتر – نرسیده به مزرعه ستوده	۴۷۹۳۴۹	۳۵۸۲۰۲۳	۲۰۸۲/۶۹
۴	دوتوه شهرکرد	۴۹۰۴۷۹	۳۵۷۵۵۱۲	۲۰۵۹/۷۴
۵	دوراهی بروجن – اصفهان	۵۰۰۲۴۵	۳۵۷۲۲۸۰	۲۱۳۵/۴۳
۶	روبروی انبار نفت	۴۹۳۱۳۲	۳۵۷۳۴۰۸	۲۰۶۳/۳۸
۷	سه راه هفشجان	۴۸۲۴۶۵	۳۵۷۴۲۶۱	۲۰۵۳/۷۵
۸	شمس آباد	۴۸۵۱۴۳	۳۵۵۸۳۲۲	۲۰۲۰/۲۰
۹	شهرک	۴۸۸۶۲۷	۳۵۷۱۳۳۰	۲۰۴۴/۸۰
۱۰	شورابچه	۴۹۷۰۰۵	۳۵۶۷۱۸۳	۲۱۳۲/۳۷
۱۱	قلنگان – جاده گاز	۴۸۰۰۱۲	۳۵۷۷۲۰۱	۲۰۷۱/۶۴
۱۲	گود قرق فرخشهر	۴۹۴۴۷۷	۳۵۶۹۰۳۰	۲۰۸۵/۱۲
۱۳	مزرعه استکی	۴۸۲۷۴۹	۳۵۷۰۵۱۷	۲۰۵۰/۸۸
۱۴	نافچ – پیر بلوط	۴۷۵۷۵۸	۳۵۸۶۶۳۵	۲۱۳۹/۲۴
۱۵	نافچ – کوره آجر پزی	۴۷۸۸۳۳	۳۵۸۵۸۹۹	۲۱۰۵/۷۲
۱۶	نوآباد	۴۸۳۳۳۸	۳۵۶۴۰۵۱	۲۰۲۹/۴۶
۱۷	وردنجان – نافچ	۴۷۸۴۸۴	۳۵۹۱۰۳۸	۲۱۳۹/۹۲
۱۸	وردنجان – هرچگان	۴۷۷۰۶۱	۳۵۹۲۱۸۸	۲۱۵۰/۲۵

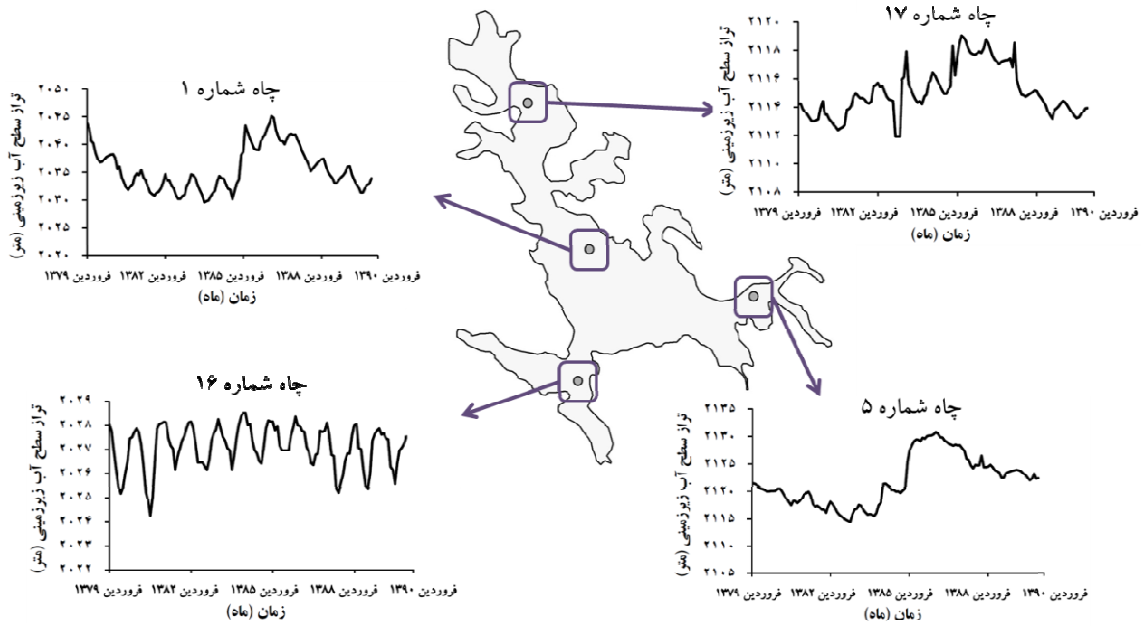

شکل ۴- نمودار تراز سطح آب زیرزمینی چاه‌های مشاهده‌ای شماره‌های ۱، ۵، ۱۶ و ۱۷ به ترتیب در نواحی مرکزی، شرقی، جنوبی و شمال‌غربی دشت طی سال‌های ۱۳۷۹ تا ۱۳۸۹

Figure 4. Plot of groundwater level in wells No. 1, 5, 16 and 17 in the Central, Eastern, Southern and Northwestern plain parts respectively during 2000 to 2010

[Downloaded from jwmr.sanru.ac.ir on 2026-11-28]

[DOI: 10.29252/jwmr.8.15.1]

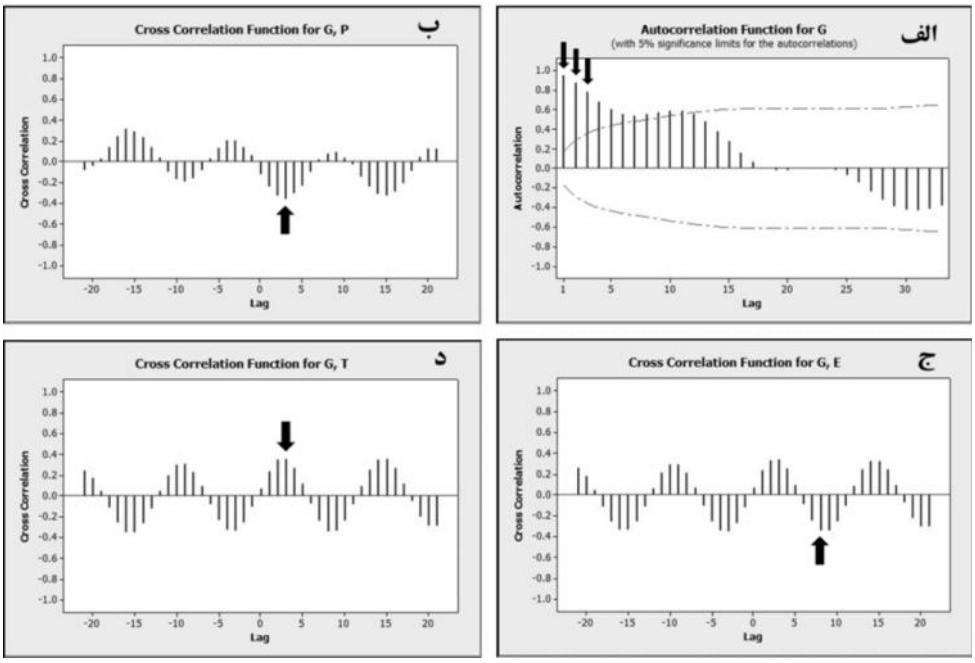

شکل ۵- نمودارهای ACF و CCF چاه مشاهده‌ای شماره ۱، الف): نمودار ACF تراز سطح آب زیرزمینی، ب): نمودار CCF بارندگی و تراز سطح آب زیرزمینی، ج): نمودار CCF تبخیر و تراز سطح آب زیرزمینی، د): نمودار CCF دما و تراز سطح آب زیرزمینی

Figure 5. Plot of ACF and CCF in observational well No. 1: (a) ACF of groundwater level, (b) CCF of precipitation and groundwater level, (c) CCF of evaporation and groundwater level, (d) CCF of temperature and groundwater level

روش رگرسیون گام‌به‌گام

زمانی که تعداد داده‌های پیش‌بینی کننده زیاد می‌شود روش گام‌به‌گام می‌تواند بهترین متغیرها را انتخاب کند (۱۷). بنابراین با این روش پارامترهای ورودی موردبررسی قرارگرفته‌اند. برای روشن شدن مطلب، نمودار آماره‌ی Mallow's Cp برای پارامترهای تأخیر یافته ورودی به مدل و همچنین ترکیب‌های آن‌ها برای چاه مشاهده‌ای شماره ۱ در شکل ۶ آورده شده است. همان‌طور که در شکل ۶-الف مشخص است بیشترین رابطه خطی بین پارامتر ورودی با خروجی مدل را $G-1$ دارد که با اضافه شدن سایر پارامترها این رابطه کاهش می‌یابد. بنابراین محور افقی در نمودار Mallow's Cp مبنای ترتیب اضافه شدن پارامترهای تأخیر یافته‌ی ورودی به مدل قرارگرفته است. به‌عبارت‌دیگر نحوه اضافه شدن پارامترها به ورودی مدل و درنتیجه ایجاد ترکیب‌های ورودی به همین ترتیب انتخاب‌شده است (شکل ۶-ب). مزیت چنین روشی این است که کشف روابط غیرخطی پارامترهای ورودی با خروجی مدل به عهده روش‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان قرار می‌گیرد. پس میزان کارایی این روش‌ها به‌خوبی مشخص می‌شود.

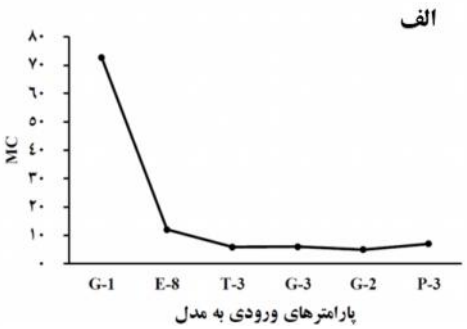

ب

شماره ترکیب	آرایش ترکیب
۱	G-1
۲	G-1 , E-8
۳	G-1 , E-8 , T-3
۴	G-1 , E-8 , T-3 , G-3
۵	G-1 , E-8 , T-3 , G-3 , G-2
۶	G-1 , E-8 , T-3 , G-3 , G-2 , P-3

شکل ۶- مدل‌سازی چاه مشاهده‌ای شماره ۱، الف) نمودار Mallow's Cp برای پارامترهای تأخیر یافته‌ی ورودی به مدل، ب)ترکیب‌های ورودی به مدل

Figure 6. Modeling of observational well No. 1: (a) Plot of Mallow's Cp in lagged inputs to the model, (b) Input combinations to the model

[Downloaded from jwmr.sanru.ac.ir on 2026-11-28]

[DOI: 10.29252/jwmr.8.15.1]

استانداردسازی داده‌ها

در این تحقیق استانداردسازی داده‌های ورودی به مدل با استفاده از رابطه ۶ صورت گرفته است و داده‌ها در دامنه $[0,1]$ قرارگرفته‌اند.

$$X_s = \frac{X - X_{min}}{X_{max} - X_{min}} \qquad (۶)$$

جایی که X_s مقدار استانداردشده، X مقدار واقعی، X_{min} کمترین مقدار و X_{max} بیشترین مقدار داده موردنظر می‌باشند.

مدل MLR

در پژوهش حاضر از رگرسیون خطی چند متغیره بر پایه متغیرهای مجموع بارندگی ماهانه، مجموع تبخیر ماهانه، متوسط دمای ماهانه و تراز سطح آب زیرزمینی در ماه‌های قبل به‌عنوان متغیرهای مستقل و تراز سطح آب زیرزمینی به‌عنوان متغیر وابسته بهره گرفته‌شده است.

مدل MLP

در این مقاله از شبکه عصبی پرسپترون چندلایه استفاده‌شده است. این شبکه یکی از مهم‌ترین شبکه‌های عصبی در مدل‌سازی و حل مسائل پیچیده غیرخطی است (۳). این مدل دارای یک‌لایه ورودی، یک‌لایه پنهان و یک‌لایه خروجی بوده است. توابع فعال‌سازی سیگموئید لجستیک و تانژانت هیپربولیک به کار گرفته‌شده‌اند چرا که دامنه داده‌های استانداردشده در دامنه این توابع قرار دارد و سبب بهبود عملکرد شبکه می‌شوند. همچنین از الگوریتم آموزش BFGS استفاده‌شده است.

مدل SVR

در این نوشتار توابع کرنل RBF و خطی به کار گرفته‌شده‌اند چرا که تابع RBF به‌عنوان یکی از بهترین توابع کرنل گزارش‌شده است (۵) و جهت امکان مقایسه بهتر نتایج تابع خطی نیز آورده شده است. پارامتر γ برابر با $\frac{1}{k}$ در نظر گرفته‌شده است که k برابر با تعداد پارامترهای ورودی به مدل است. پارامترهای C و ε با استفاده از سعی و خطا به‌دست‌آمده‌اند.

معیارهای ارزیابی مدل

جهت مقایسه و ارزیابی عملکرد مدل‌های موردبررسی در پژوهش حاضر از معیارهای راندمان نش ساکلیف (NS)، ریشه میانگین مربعات خطا (RMSE)، میانگین درصد خطای مطلق (MAPE) و ضریب همبستگی (CORR) استفاده‌شده است (۲۴). رابطه‌های ۷ تا ۱۰ این معیارها را نشان می‌دهند.

$$NS = 1 - \frac{\sum_{i=1}^{n}(O_i - P_i)^2}{\sum_{i=1}^{n}(O_i - \bar{O})^2} \qquad (۷)$$

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(O_i - P_i)^2} \qquad (۸)$$

$$MAPE = 100 \times \frac{1}{n}\left(\sum_{i=1}^{n}\frac{|O_i - P_i|}{O_i}\right) \qquad (۹)$$

$$CORR = \frac{\sum_{i=1}^{n}(O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^{n}(O_i - \bar{O})^2}\sqrt{\sum_{i=1}^{n}(P_i - \bar{P})^2}} \qquad (۱۰)$$

O_i مقدار مشاهداتی، P_i مقدار پیش‌بینی‌شده با مدل، $\bar{O}$ میانگین مقادیر مشاهداتی، $\bar{P}$ میانگین مقادیر پیش‌بینی‌شده با مدل و n تعداد مقادیر مشاهداتی یا پیش‌بینی‌شده می‌باشند. هر اندازه مقادیر NS و CORR به یک و هر چه معیارهای RMSE و MAPE به صفر نزدیک‌تر باشند بیانگر کارایی و دقت بیشتر مدل است (۷).

نتایج و بحث

در مطالعه حاضر با استفاده از روش‌های MLR، MLP و SVR با توابع کرنل RBF و خطی برای ۱۸ چاه مشاهده‌ای در دشت شهرکرد در سال‌های ۱۳۸۸ و ۱۳۸۹ تراز سطح آب زیرزمینی پیش‌بینی‌شده است. با توجه به این‌که NS و RMSE معیارهایی توانمند برای ارزیابی مدل‌های هیدرولوژیکی هستند (۲۴،۴) در این تحقیق از آن‌ها به‌عنوان معیارهای اصلی مقایسه مدل‌ها استفاده‌شده است. به‌عنوان نمونه، نتایج مدل‌سازی برای چاه مشاهده‌ای شماره ۱ در جدول‌های ۲ و ۳ آورده شده است. جدول ۲ ساختار شبکه و توابع فعال‌سازی لایه‌های پنهان و خروجی در مدل MLP و مقادیر γ ، C و ε در مدل SVR را در چاه شماره ۱ نشان داده است. در جدول ۳ با توجه به معیارهای ارزیابی مشخص است که در چاه مشاهده‌ای شماره ۱، مدل MLP بهتر از سایر مدل‌ها آموزش دیده است و مدل SVR با تابع کرنل RBF بهترین عملکرد را داشته است. علت این موضوع، آن است که با افزایش پارامترهای ورودی و پیچیده شدن روابط غیرخطی مدل SVR از توانایی بیشتری نسبت به سایر مدل‌ها برخوردار بوده است.

برای مثال، نمودار پراکنش مقادیر مشاهداتی و پیش‌بینی‌شده با مدل و نمودار تراز سطح آب زیرزمینی مشاهداتی و پیش‌بینی‌شده برای بهترین ترکیب در مرحله آزمون (ترکیب شماره ۳ با مدل MLP) برای چاه مشاهده‌ای شماره ۱ طی سال‌های ۱۳۸۸ و ۱۳۸۹ در شکل ۷ آورده شده‌اند. با توجه به نتایج ارائه‌شده در شکل، توانایی بالای مدل MLP در پیش‌بینی تراز سطح آب زیرزمینی در چاه موردنظر مشخص می‌شود.

همچنین رابطه رگرسیونی برتر مدل MLR در مرحله آزمون متشکل از متغیرهای مستقل تراز سطح آب زیرزمینی در ماه قبل، تبخیر ۸ ماه قبل و دمای ۳ ماه قبل برای چاه مشاهده‌ای شماره ۱ در رابطه ۱۱ آورده شده است.

$$G = 46.7523 + 0.976245\,(G\text{-}1) + 0.00645913\,(E\text{-}8) + 0.0446427\,(T\text{-}3) \qquad (۱۱)$$

توجه به نتایج جدول ۴ نشان می‌دهد که برای ۱۸ چاه مشاهده‌ای موردبررسی در دشت شهرکرد مدل‌های MLP و SVR نتایج قابل قبولی در پیش‌بینی تراز سطح آب زیرزمینی

[Downloaded from jwmr.sanru.ac.ir on 2026-11-28]

[DOI: 10.29252/jwmr.8.15.1]

ارائه کرده‌اند و نسبت به روش رگرسیون خطی چند متغیره برتری داشته‌اند. به‌طوری‌که برتری مدل‌های MLR، MLP، SVR-RBF و SVR-Linear در مرحله آزمون به ترتیب برابر با ۰، ۵۵/۵۵، ۲۷/۷۸ و ۱۶/۶۷ درصد نسبت به نتایج کل مدل‌ها بوده است. یکی از دلایل این موضوع را می‌توان به دلیل وجود رابطه غیرخطی تراز سطح آب زیرزمینی با بارندگی، دما و تبخیر نسبت داد. برتری مدل‌های MLR، MLP، SVR-RBF و SVR-Linear در مرحله آموزش به ترتیب برابر با ۳۷/۰۴، ۵۰، ۱۲/۹۶ و ۰ درصد نسبت به نتایج کل مدل‌ها بوده است. این مسئله بیانگر برتری عملکرد MLP در مراحل آموزش و آزمون در قیاس با مدل SVR می‌باشد. یکی از دلایل بالقوه عدم برتری SVR نسبت به MLP، بزرگ بودن بازه زمانی ماهانه برای پیش‌بینی تراز سطح آب زیرزمینی برای روش SVR است؛ به‌طوری‌که امکان فراگیری کامل اطلاعات در فواصل زمانی ماهانه توسط روش SVR وجود ندارد. در استفاده از ماشین بردار پشتیبان تابع کرنل RBF عملکرد بهتری از حالت خطی در هر دو مرحله آموزش و آزمون داشته است. صحت این موضوع با توجه به عملکرد غیرخطی تابع RBF در پردازش اطلاعات نسبت به تابع خطی نیز دور از انتظار نیست. توجه به نتایج جدول ۴ بیانگر عملکرد مناسب روش رگرسیون خطی چند متغیره در مرحله آموزش در قیاس با روش‌های غیرخطی است (۳۷/۰۴ درصد موارد)، بااین‌وجود به دلیل وجود ماهیت پیچیده و غیرخطی مدل‌سازی سطح آب زیرزمینی، این روش در مرحله آزمون کفایت لازم را نسبت به مدل‌های غیرخطی نشان نداده است (در هیچ‌یک از موارد برتر نبوده است). بنابراین با توجه به یافته‌های حاصل از این تحقیق پیشنهاد می‌شود جهت مدل‌سازی رفتار سری زمانی تغییرات سطح آب زیرزمینی استفاده از روش‌های غیرخطی داده محور نسبت به روش‌های خطی در اولویت قرار داده شوند، که این مسئله با نتایج حاصل از محققان دیگر نیز همسو می‌باشد (۱۹).

جدول ۲- نتایج پارامترهای مدل‌های MLP و SVR برای چاه مشاهده‌ای شماره ۱

Table 2. Results of parameters of MLP and SVR models in observational well No. 1

شماره ترکیب	مدل							
	MLP			SVR-RBF			SVR-Linear	
	ساختار شبکه	تابع لایه پنهان	تابع لایه خروجی	γ	C	ε	C	ε
۱	۱-۴-۱	Logistic Sigmoid	Tanh	۱	۱۰	۰/۱	۱۰	۰/۱
۲	۱-۶-۱	Logistic Sigmoid	Tanh	۰/۵	۱۰	۰/۱	۱۰	۰/۱
۳	۱-۵-۱	Logistic Sigmoid	Tanh	۰/۳۳۳	۱۰	۰/۰۰۱	۱۰	۰/۱
۴	۱-۵-۱	Logistic Sigmoid	Logistic Sigmoid	۰/۲۵	۱۰	۰/۰۰۱	۱۰	۰/۱
۵	۱-۸-۱	Logistic Sigmoid	Logistic Sigmoid	۰/۲	۱۰	۰/۰۰۱	۱۰	۰/۱
۶	۱-۶-۱	Logistic Sigmoid	Logistic Sigmoid	۰/۱۶۷	۱۰	۰/۰۰۱	۱۰	۰/۱

[Downloaded from jwmr.sanru.ac.ir on 2026-11-28]

[DOI: 10.29252/jwmr.8.15.1]

جدول ۳- نتایج ارزیابی مدل‌های MLR، MLP و SVR برای چاه مشاهده‌ای شماره ۱

Table 3. Results of evaluation of MLR, MLP and SVR models in observational well No. 1

شماره ترکیب	مدل	مرحله آموزش				مدل برتر	مرحله آزمون				مدل برتر
		NS	RMSE (m)	MAPE (%)	CORR		NS	RMSE (m)	MAPE (%)	CORR	
۱	MLR	۰/۹۳۱	۱/۰۹۷	۰/۰۴۱	۰/۹۶۵	MLP	۰/۸۱۵	۰/۷۴۶	۰/۰۳۱	۰/۹۱۲	MLP
	MLP	۰/۹۳۱	۱/۰۹۱	۰/۰۴۱	۰/۹۶۵		۰/۸۲۸	۰/۷۲۰	۰/۰۳۱	۰/۹۱۲	
	SVR-RBF	۰/۹۳۰	۱/۱۰۲	۰/۰۴۱	۰/۹۶۵		۰/۸۲۷	۰/۷۲۳	۰/۰۳۲	۰/۹۱۱	
	SVR-Linear	۰/۹۳۰	۱/۱۰۴	۰/۰۴۱	۰/۹۶۵		۰/۸۲۱	۰/۷۳۵	۰/۰۳۲	۰/۹۱۲	
۲	MLR	۰/۹۵۳	۰/۹۰۱	۰/۰۳۱	۰/۹۷۶	MLP	۰/۸۷۱	۰/۶۲۴	۰/۰۲۳	۰/۹۶۳	MLP
	MLP	۰/۹۵۷	۰/۸۶۰	۰/۰۲۹	۰/۹۷۸		۰/۸۹۸	۰/۵۵۵	۰/۰۲۰	۰/۹۶۳	
	SVR-RBF	۰/۹۵۵	۰/۸۷۹	۰/۰۲۹	۰/۹۷۸		۰/۸۸۳	۰/۵۹۴	۰/۰۲۱	۰/۹۵۸	
	SVR-Linear	۰/۹۵۳	۰/۹۰۵	۰/۰۳۱	۰/۹۷۶		۰/۸۸۱	۰/۵۹۹	۰/۰۲۲	۰/۹۶۱	
۳	MLR	۰/۹۵۶	۰/۸۷۵	۰/۰۳۰	۰/۹۷۸	MLP	۰/۸۸۳	۰/۵۹۵	۰/۰۲۲	۰/۹۶۰	MLP
	MLP	۰/۹۶۲	۰/۸۱۶	۰/۰۲۶	۰/۹۸۱		۰/۹۱۱	۰/۵۱۸	۰/۰۱۹	۰/۹۶۵	
	SVR-RBF	۰/۹۵۸	۰/۸۵۷	۰/۰۲۵	۰/۹۷۹		۰/۹۰۵	۰/۵۳۵	۰/۰۲۰	۰/۹۵۸	
	SVR-Linear	۰/۹۵۵	۰/۸۷۸	۰/۰۳۰	۰/۹۷۸		۰/۸۹۵	۰/۵۶۴	۰/۰۲۰	۰/۹۶۱	
۴	MLR	۰/۹۵۷	۰/۸۶۵	۰/۰۳۰	۰/۹۷۸	SVR RBF	۰/۸۸۰	۰/۶۰۲	۰/۰۲۱	۰/۹۵۶	SVR RBF
	MLP	۰/۹۵۸	۰/۸۴۹	۰/۰۳۰	۰/۹۷۹		۰/۸۹۷	۰/۵۵۷	۰/۰۲۱	۰/۹۵۴	
	SVR-RBF	۰/۹۵۹	۰/۸۴۴	۰/۰۲۵	۰/۹۷۹		۰/۹۰۲	۰/۵۴۴	۰/۰۲۱	۰/۹۶۰	
	SVR-Linear	۰/۹۵۳	۰/۸۹۸	۰/۰۳۰	۰/۹۷۷		۰/۸۸۷	۰/۵۸۵	۰/۰۲۲	۰/۹۶۴	
۵	MLR	۰/۹۵۹	۰/۸۴۷	۰/۰۳۱	۰/۹۷۹	SVR RBF	۰/۸۶۲	۰/۶۴۶	۰/۰۲۴	۰/۹۵۰	SVR RBF
	MLP	۰/۹۴۲	۱/۰۰۵	۰/۰۳۵	۰/۹۷۵		۰/۸۹۲	۰/۵۷۱	۰/۰۲۲	۰/۹۵۸	
	SVR-RBF	۰/۹۶۰	۰/۸۳۴	۰/۰۲۴	۰/۹۸۰		۰/۸۹۳	۰/۵۶۷	۰/۰۲۲	۰/۹۵۷	
	SVR-Linear	۰/۹۵۶	۰/۸۷۲	۰/۰۳۱	۰/۹۷۸		۰/۸۷۶	۰/۶۱۲	۰/۰۲۳	۰/۹۵۹	
۶	MLR	۰/۹۵۹	۰/۸۴۷	۰/۰۳۱	۰/۹۷۹	MLP	۰/۸۶۲	۰/۶۴۵	۰/۰۲۴	۰/۹۵۰	SVR RBF
	MLP	۰/۹۶۷	۰/۷۵۲	۰/۰۲۷	۰/۹۸۴		۰/۸۷۴	۰/۶۱۷	۰/۰۲۳	۰/۹۴۶	
	SVR-RBF	۰/۹۶۵	۰/۷۷۹	۰/۰۲۴	۰/۹۸۳		۰/۹۰۹	۰/۵۲۵	۰/۰۲۱	۰/۹۵۹	
	SVR-Linear	۰/۹۵۶	۰/۸۷۳	۰/۰۳۱	۰/۹۷۸		۰/۸۷۲	۰/۶۲۱	۰/۰۲۳	۰/۹۶۰	

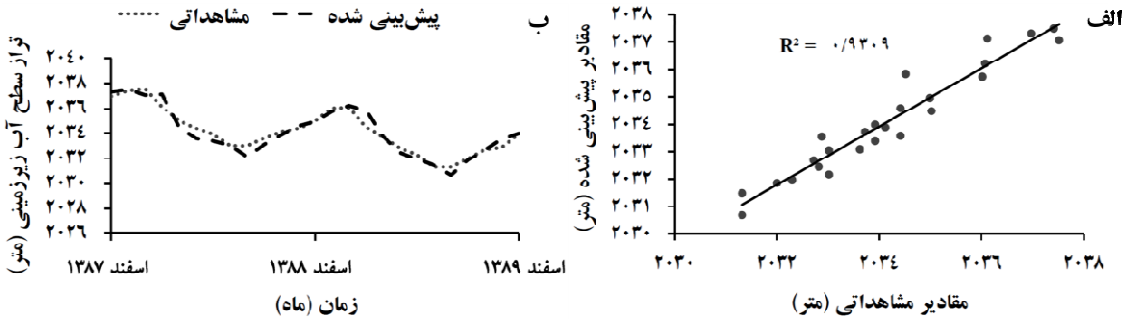

شکل ۷- مقادیر مشاهداتی و پیش‌بینی‌شده مربوط به بهترین ترکیب در چاه مشاهده‌ای شماره ۱ با استفاده از مدل MLP طی سال‌های ۱۳۸۸ و ۱۳۸۹، الف) نمودار پراکنش، ب) نمودار تراز سطح آب زیرزمینی

Figure 7. Observed and predicted values of the best combination in observational well No. 1 using MLP model during 2009 and 2010: (a) Scatter plot, (b) Groundwater level plot

[Downloaded from jwmr.sanru.ac.ir on 2026-11-28]

[DOI: 10.29252/jwmr.8.15.1]

جدول ۴- درصد برتری مدل‌های MLR، MLP و SVR برای ۱۸ چاه مشاهده‌ای موردبررسی در تحقیق حاضر
Table 4. Percentage of superiority of MLR, MLP and1 SVR models in 18 observational wells used in this research

مدل	درصد برتری مدل	
	مرحله آموزش	مرحله آزمون
MLR	۳۷/۰۴	۰
MLP	۵۰	۵۵/۵۵
SVR-RBF	۱۲/۹۶	۲۷/۷۸
SVR-Linear	۰	۱۶/۶۷

منابع

1. Abraham, A. 2005. Artificial neural networks. In: Sydenham, P.H. and R. Thorn (eds.) Handbook of measuring system design, 901-908 pp., John Wiley & Sons, Stillwater, OK, USA.
2. Akbarzadeh, F., H. Hasanpour and S. Emamgholizadeh. 2016. Groundwater level prediction of Shahrood Plain using RBF neural networks. Journal of Watershed Management Research, 7: 104-118 (In Persian).
3. Ardiclioglu, M., O. Kisi and T. Haktanir. 2007. Suspended sediment prediction using two different feed-forward backpropagation algorithms. Canadian Journal of Civil Engineering, 34: 120-125.
4. Chen, S.T. and P.S. Yu. 2007. Pruning of support vector networks on flood forecasting. Journal of Hydrology, 347: 67-78.
5. Dibike, Y.B., S. Velickov, D.P. Solomatine and M.B. Abbott. 2001. Model induction with support vector machines: introduction and applications. Journal of Computing in Civil Engineering, 15: 208-216.
6. Erasto, P. 2001. Support vector machines-backgrounds and practice. BSc Thesis, University of Helsinki, Faculty of Science, Rolf Nevanlinna Institute, Helsinki, Finland. 78 pp.
7. Govindaraju, R.S. 2000. Artificial neural networks in hydrology. I: preliminary concepts. Journal of Hydrologic Engineering, 5: 115-123.
8. Javadi, M.R., H. Tehranipour, Sh.A. Gholami and M.A. Fatahi Ardakani. 2012. Comparing methods of Mora and Varson and multivariate regression in zoning landslide hazard of Kan Watershed. Journal of Watershed Management Research, 3: 92-105 (In Persian).
9. Kiarash, S., A. Enderami, A. Malekian and M. Mahdavi. Investigation of the capability of artificial neural networks for estimating suspended sediment load (Case Study: Silakhor Watershed, Lorestan Province). 9th International River Engineering Conference, 8 pp., Ahwaz, Iran (In Persian).
10. Lalehzari, R. and S.H. Tabatabaei. 2010. Chemical characteristics of groundwater in Shahrekord Plain. Journal of Environmental Studies, 36: 55-62 (In Persian).
11. Lallahem, S., J. Mania, A. Hani and Y. Najjar. 2005. On the use of neural networks to evaluate groundwater levels in fractured media. Journal of Hydrology, 307: 92-111.
12. Lijun, F. and L. Shuquan. 2007. Forecasting the runoff using least square support vector machine. Tianjin Teaching Committee, TJGL06-099: 884-889.
13. Mahdavi, R., J. Abedi Koupaei, M. Rezaei and M. Abdolhosseini. 2004. Identification of appropriate sites for artificial recharge of groundwater resources using RS and GIS. 2nd Students Conference on Soil and Water Resources, 11 pp., Shiraz, Iran (In Persian).
14. Moharampour, M., A. Mehrabi and M. Katouzi. 2010. Evaluation of support vector machine on daily flow prediction. 4th Iran Water Resources Management Conference, 11 pp., Tehran, Iran (In Persian).
15. Mukerji, A., C. Chatterjee and N.S. Raghuwanshi. 2009. Flood forecasting using ANN, neuro-fuzzy, and neuro-GA models. Journal of Hydrologic Engineering, 14: 647-652.
16. Naserabadi, F., A. Esmali Ouri, H. Akbari and R. Rostamian. 2016. River flow simulation using SWAT model (Case study: Ghareh Su River in Ardabil Province-Iran). Journal of Watershed Management Research, 7: 50-59 (In Persian).
17. Pourkerman, M., A. Charkhabi, H. Mosadegh, H. Peyrowan and A. Talebi. 2011. Identification of effective chemical factors on soil resistivity using discriminant analysis stepwise method (case study: marls of Sorkheh Watershed). Iranian Journal of Watershed Management Science and Engineering, 5: 23-32(In Persian).
18. Ramirez, M.C.V., H.F. Campos Velho and N.J. Ferreira. 2005. Artificial neural network technique for rainfall forecasting applied to the Sao Paulo region. Journal of Hydrology, 301: 146-162.
19. Razavi Ghahfarokhi, S.B., Sh. Karimi Googhari and M.B. Rahnama. 2013. Shahr-e-kord Plain groundwater level modeling using artificial neural networks and wavelet analysis. The 2nd International Conference on Plant, Water, Soil and Weather Modeling, 12 pp., Kerman, Iran (In Persian).
20. Sahrai, Sh. and M. Zaker Moshfegh. 2013. Using support vector machines for river flow prediction. 7th National Congress on Civil Engineering, 9 pp., Zahedan, Iran (In Persian).
21. Smola, A.J. and B. Scholkopf. 2004. A tutorial on support vector regression. Statistics and Computing, 14: 199-222.
22. Sreekanth, P.D., N. Geethanjali, P.D. Sreedevi, S. Ahmed, N. Ravi Kumar and P.D. Kamala Jayanthi. 2009. Forecasting groundwater level using artificial neural networks. Current Science, 96: 933- 939.
23. Vapnik, V. 1998. Statistical Learning Theory. John Wiley, New York, USA, 732 pp.

[Downloaded from jwmr.sanru.ac.ir on 2026-11-28]

[DOI: 10.29252/jwmr.8.15.1]

24. Yoon, H., S.C. Jun, Y. Hyun, G.O. Bae and K.K. Lee. 2011. A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. Journal of Hydrology, 396: 128-138.
25. Yu, P.S., S.T. Chen and I.F. Chang. 2006. Support vector regression for real-time flood stage forecasting. Journal of Hydrology, 328: 704-716.
26. Zounemat-Kermani, M. 2013. Hydrometeorological parameters in prediction of soil temperature by means of artificial neural network: case study in Wyoming. Journal of Hydrologic Engineering, 18: 707-718.
27. Zounemat-Kermani, M. 2014. Principal component analysis (PCA) for estimating chlorophyll concentration using forward and generalized regression neural networks. Applied Artificial Intelligence, 28: 16-29.
28. Zounemat-Kermani, M., O. Kisi and T. Rajaee. 2013. Performance of radial basis and LM-feed forward artificial neural networks for predicting daily watershed runoff. Applied Soft Computing, 13: 4633-4644.

[Downloaded from jwmr.sanru.ac.ir on 2026-11-28]

[DOI: 10.29252/jwmr.8.15.1]

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)

Abdollah Ramezani-Charmahineh[1] and Mohammad Zounemat-Kermani[2]

1- Graduated M.Sc. Student, Shahid Bahonar University of Kerman
2- Associate Professor, Shahid Bahonar University of Kerman, (Corresponding author: zounemat@uk.ac.ir)
Received: July 24, 2014 Accepted: April 11, 2015

Abstract

Accurate and reliable simulation and prediction of the groundwater level variation is significant and essential in water resources management of a basin. Models such as ANNs and Support Vector Regression (SVR) have proved to be effective in modeling nonlinear function with a greater degree of accuracy. In this respect, an attempt is made to predict monthly groundwater level fluctuations using Multivariate Linear Regression, Multi-Layer Perceptron neural network models and two SVRs with RBF and linear function. In the present study, monthly data (from 2000 to 2010) of 18 observational wells in Shahrekord Plain were used for simulating and predicting the groundwater level. Regarding to NS efficiency and RMSE criteria, MLP model in 56% and SVR in 44%, have the best performance in comparison with other models. For an instance, in well No. 1, SVR-RBF using input parameters of groundwater level, temperature, evaporation and precipitation is superior to other models. General efficiency of MLP, SVR-RBF, and SVR-Linear for NS criteria is 0.703, 0.656 and 0.655, respectively; and for RMSE criteria is 0.857, 0.905 and 0.914 meter, respectively. Results indicate that MLP and SVR models give better accuracy in predicting groundwater levels in the study area when compared to the linear model.

Keywords: Groundwater level prediction, Multivariate regression, Perceptron neural network, Shahrekord Plain, Support Vector Regression

[Downloaded from jwmr.sanru.ac.ir on 2026-11-28]

[DOI: 10.29252/jwmr.8.15.1]