

طراحی شبکه پایش سطح آب زیرزمینی با استفاده از مدل حداقل مربعات ماشین بردار پشتیبان (LS-SVM)

الهام رضایی^{۱*}، عباس خاشعی سیوکی^۲، علی شهیدی^۳

۱. دانشجوی کارشناسی ارشد منابع آب دانشگاه بیرجند

۲. استادیار گروه مهندسی آب دانشگاه بیرجند

۳. استادیار گروه مهندسی آب دانشگاه بیرجند

(تاریخ دریافت: ۱۳۹۲/۷/۹ - تاریخ تصویب: ۱۳۹۳/۴/۱۴)

چکیده

این مطالعه روشهای طراحی شبکه‌های پایش کمی آب زیرزمینی به منظور کاهش نقاط مکانی اضافی ارائه می‌کند؛ چاههای اضافی، که اگر نمونه‌گیری نشوند، خطای تخمین سطح آب زیرزمینی آن‌ها قابل چشم‌پوشی است. این روش مبتنی بر روش ماشین بردار پشتیبان بر پایه تئوری یادگیری آماری است. در این مطالعه، با استفاده از اطلاعات کمی ۶۳ چاه مشاهداتی و پارامترهای هواشناسی (بارندگی و تبخیر) دشت رامهرمز، در دوره ۷ ساله، عملکرد مدل حداقل مربعات ماشین بردار پشتیبان (LS-SVM) در طراحی شبکه برداشت چاههای مشاهداتی آب زیرزمینی بررسی شد. ترکیب‌های مختلف پارامترهای اثرگذار بر تراز سطح آب زیرزمینی با استفاده از مدل LS-SVM ارزیابی شد. ترکیب برتر مدل LS-SVM در برگیرنده شاخص‌های عملکرد $MAE = 0.3405$ و $R^2 = 0.9992$ است. سپس، با استفاده ازتابع تقریب بهینه، ۴۲ عدد چاه مشاهداتی به منظور پایش مکانی مناسب در منطقه دشت رامهرمز مشخص شد.

کلیدواژگان: تابع تقریب، دشت رامهرمز، مدل‌سازی آب زیرزمینی، نقاط پایش

مقدمه

محدودیت‌های آبی منابع آب سطحی و زیرزمینی اعمال مدیریت صحیح منابع آب را اجتناب‌ناپذیر می‌کند. برای مدیریت پایدار منابع آب تجدیدپذیر در سطح یک آبخوان شبکه‌ای از چاههای مشاهداتی (پایش) آب زیرزمینی، به منظور اندازه‌گیری سطح آب به طور دقیق، ضروری است. به طور کلی دقت و اعتبار هر تخمین به کیفیت و کمیت پارامتر مورد سنجش بستگی دارد. منظور از پایش سنجش رفتار کمی و کیفی منابع آب تحت تأثیر عوامل طبیعی و مصنوعی است.

از اهداف اکتشاف پیزومتری به دست آوردن اطلاعات درباره خصوصیات هیدرولوژیکی، مهندسی زمین‌شناسی و هیدرولوژیکی، تعیین نفوذپذیری سنگ، اندازه‌گیری نوسانات سطح آب زیرزمینی، تعیین حرکت آب زیرزمینی، و بررسی کیفیت آب است. این شبکه‌ها باید طوری طراحی شوند که توزیع مکانی متغیرها در آبخوان معرف نسبتاً کاملاً از رفتار آبخوان باشد.

طراحی شبکه‌های مشاهداتی از مسائل بهینه‌سازی چنددهدله است. اندازه‌گیری، از لحاظ فراوانی مکانی و زمانی،

بسیار مورد توجه قرار می‌گیرد. تراکم زیاد و فراوانی زمانی مستلزم صرف هزینه و وقت در اندازه‌گیری میدانی خواهد شد. هر چه تراکم شبکه بالاتر باشد، محاسبات با دقت بیشتری انجام می‌پذیرد. اما از نگاهی دیگر انجامدادن این محاسبات، در بازه‌های زمانی مکرر، به حجم انبوهی از داده‌ها نیازمند است. در نتیجه هزینه‌ها بالاتر می‌رود و به همان اندازه نیز وقت صرف می‌شود. بدین منظور شبکه باید تا حدی بهینه شود که به طور کافی میان شرایط هیدرولوژیکی در منطقه مورد نظر باشد. به طور کلی، کاهش اطلاعات مازاد می‌تواند در کاهش هزینه‌های سامانه، بدون کاهش میزان و دقت اطلاعات حاصل، تأثیری قابل توجه بگذارد. به منظور تعمیم نتایج اندازه‌گیری از چاههای موجود به سایر نقاط فاقد آمار، باید شبکه چاهها تراکمی متناسب با منطقه مورد نظر داشته باشد.

برای اجرای این مطالعات مدل‌ها و روش‌های ایفای نقش کرده‌اند؛ از روش‌های زمین‌آماری الگوریتم‌های بهینه‌سازی و مدل‌های هوشمند را می‌توان نام برد. از میان این روش‌ها مدل‌های هوشمند، به دلیل سرعت پردازش و دقت بالا و صرف وقت نسبتاً کم، نسبت به روش‌های دیگر توسعه بیشتری یافته‌اند.

در تحقیقی با به کارگیری نقشه‌های رژیم‌های منطقه آب زیرزمینی به بهینه‌سازی شبکه مشاهداتی سطح آب زیرزمینی

* نویسنده مسئول: e.rezaei66@yahoo.com

«ماشین بردار پشتیبان»، در سال ۱۹۹۵ تا ۱۹۹۸، بر پایهٔ تئوری یادگیری آماری^۵، که از حداقل سازی ریسک ساختاری^۶ تبعیت می‌کند، ارائه کرد. در سال ۱۹۹۹ وندوال^۷ و سویکنس^۸ مدل حداقل مربعات ماشین بردار پشتیبان را معرفی کردند. این مدل محدودیت‌های یکسانی با روش SVM کلاسیک دارد؛ اما نسبت به این روش از پیچیدگی محاسباتی کمتر و دقت و سرعت بالاتری برخوردار است؛ سیستمی کارآمد است بر مبنای تئوری بهینه‌سازی، که از اصل استقرایی کمینه‌سازی خطای ساختاری استفاده می‌کند و به یک جواب بهینه کلی منجر می‌شود (Cristianini and Shawe-Taylor, 2000).

چند نمونه از تحقیقات صورت‌گرفته در زمینه کاربرد مدل حداقل مربعات ماشین بردار پشتیبان LS-SVM در ادامه می‌آید.

در تحقیقی با استفاده از مدل LS-SVM به پیش‌بینی کوتاه‌مدت سری زمانی هواشناسی، مثل تابش خورشیدی و دمای هوای رطوبت نسبی، پرداخته شد. نتایج این تحقیق با نتایج به دست آمده از روش‌های مختلف شبکه‌های عصبی مصنوعی مقایسه و در نهایت مدل LS-SVM به عنوان مدل برتر معرفی شد (Mellit et al., 2013). در مطالعه‌ای دیگر نیز امکان‌سنجی استفاده از مدل LS-SVM در پیش‌بینی سری زمانی هیدرولوژیکی غیر خطی در مقایسه با روش‌های آماری رگرسیون خطی چندگانه (MLR) و روش اکتشافی، مانند شبکه عصبی (NNBP)، بررسی شد. نتایج نشان‌دهنده دقت پیش‌بینی بالای این مدل پیشنهادی بود (Hwang et al., 2012). همچنانی دقت مدل LS-SVM در مدل‌سازی تبخر و تعرق مرجع در جنوب منطقه کالیفرنیا بررسی شد. نتایج بیان‌کننده دقت این مدل نسبت به روش‌های دیگر بود (Kisi, 2012).

در این تحقیق، در طراحی شبکه پایش بلندمدت مشاهده تراز سطح آب زیرزمینی، از مدل LS-SVM به منزله مدلی با قدرت شبیه‌سازی تراز سطح آب زیرزمینی استفاده شد.

مواد و روش‌ها

موقعیت جغرافیایی دشت رامهرمز

دشت رامهرمز در استان خوزستان با مساحت حدود ۵۴۸

در منطقه پکن^۱ در چین پرداخته شد. نتایج نشان داد این نقشه‌ها می‌توانند مناطقی را که مشخصات زمانی و مکانی منحصر به فرد دارند از بقیه مناطق متمایز کنند و برای طراحی شبکه می‌توان از این نقشه‌ها استفاده کرد (Zhou et al., 2013). Guo et al. (2011) به مقایسه چند روش، نمونه‌گیری، تجزیه و تحلیل هیدرولوژیکی، و روشنی همراه رویکرد سطح میانگین غیر همگن^۲ (ترکیبی از روش‌های کریجینگ بلوک‌بندی شده و نمونه‌گیری لایه‌ای مکانی) در بهینه‌سازی شبکه مشاهداتی آب زیرزمینی پرداختند، که نتایج برتری روش MSN را بر دیگر روش‌ها نشان داد. Bashi Azghadi and Kerachian (2010) در تحقیقی دیگر روش جدیدی را برای بهینه‌سازی مکان چاهه‌ای مشاهداتی جهت تعیین منابع آلاینده ناشناخته پیشنهاد دادند. در این MT3D و MODFLOW، ابتدا با کمک مدل‌های شبیه‌سازی انجام شد. سپس، از نتایج مدل بهینه‌سازی تک‌هدفه و شبیه‌ساز تجزیه و تحلیل مونت‌کارلو مدل PSVMs را واسنجی کردند و در پایان، بر اساس نتایج SVM، محل و میزان نشت آلودگی را به صورت احتمالاتی مشخص کردند (Bashi Azghadi and Kerachian, 2010) کارایی سامانه پایش کیفی منابع آب زیرزمینی دشت تهران با استفاده از تئوری آتروبوی گسسته ارزیابی شد. نتایج نشان‌دهنده کارایی مناسب الگوریتم پیشنهادی در ارزیابی و بهنگام‌سازی Masoumi سامانه‌های پایش کیفی منابع آب زیرزمینی بود (and Kerachian, 2007). تحقیقاتی در زمینه پایش کیفی به منظور حداکثرسازی احتمال کشف آلودگی به روش SVM انجام شد. نتایج حاکی از عملکرد امیدوارکننده این روش بود (Asefa et al., 2005).

در امریکا برای طراحی شبکه بلندمدت مشاهده آب زیرزمینی، به منظور کاهش بخش‌های اضافی، از روشی استفاده شد که بر محاسبه بردارهای پشتیبان استوار است. نتایج نشان‌دهنده کارآمدی بودن این روش در مقایسه با روش کریجینگ بود (Asefa et al., 2004).

در این مطالعه از مدل پیشنهادی حداقل مربعات ماشین بردار پشتیبان^۳ استفاده شد. این روش را ابتدا وپنیک^۴، با نام

5. Statistical Learning Theory
6. Structure Risk Minimization
7. Vandewalle
8. Suykens

1. Beijing
2. Mean of Surface with Non-homogeneity
3. Least Square Support Vector Machines
4. Vapnic

صورت بهینه از شبکه چاههای مشاهداتی حذف کند. از مدل LS-SVM در مسائل رگرسیونی، به ویژه مسائل علوم آب، در تحقیقات کمتری استفاده شده است. چارچوب رگرسیون حداقل مربعات ماشین بردار پشتیبان بدین صورت است:

$$\vec{x}_i \in R^n$$

مجموعه‌داده‌های آموزشی را خواهیم داشت. که \vec{x}_i به عنوان بردار ورودی و $R \in \vec{R}$ به عنوان بردار خروجی معرفی می‌شوند.

تابع رگرسیون غیر خطی در فضای وزن‌دهی اولیه به صورت رابطه ۱ است (Suykens *et al*, 2002):

$$y(x) = w^T \cdot \varphi(x_i) + b \quad (\text{رابطه } 1)$$

w و b به ترتیب مقادیر وزن‌ها و بایاس تابع رگرسیون و $\varphi(x_i)$ ترسیم غیر خطی ورودی‌ها در فضای ویژگی با ابعاد بالاست (Shiloh Shah, 2007).

رگرسیون غیر خطی بر اساس رابطه بهینه‌سازی ۲ حل می‌شود:

$$\min_{w, e, b} j(w, e) = \frac{1}{2} w^T w + \frac{\gamma}{2} \sum_{i=1}^N e_i^2 \quad (\text{رابطه } 2)$$

بر اساس محدودیت:

$$y_i = w^T \varphi(x_i) + b + e_i \quad (\text{رابطه } 3)$$

حداقل‌سازی ترم اول رابطه با حداقل‌سازی فاصله اطمینان از ماشین یادگیری و حداقل‌سازی ترم دوم مطابق حداقل‌سازی ریسک تجربی است (Seifi, 2010). γ پارامتر تنظیم‌کننده بخش خطاست و e میزان خطا را نشان می‌دهد. مقدار γ همواری^۱ تابع تقریب را کنترل می‌کند. مقدار γ بزرگ‌تر خطا بیشتری ایجاد می‌کند و ماشین یادگیری را پیچیده‌تر می‌سازد و مقدار γ کوچک‌تر به خطاهای منجر می‌شود که روا دانسته می‌شوند، اما ممکن است ماشین یادگیری با تقریب ضعیف را ایجاد کند (Seifi, 2010).

حل با استفاده از شکل لاغرانژی از تابع هدف اصلی:

$$L(w, b, e; \alpha) = j(w, e) - \sum_{i=1}^N \alpha_i \{w^T \varphi(x_i) + b + e_i - y_i\} \quad (\text{رابطه } 4)$$

α_i ضریب لاغرانژ است.

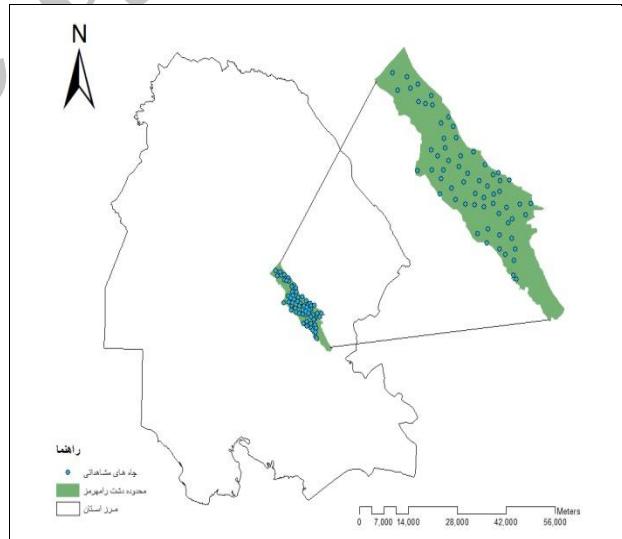
بر اساس شرایط کان-تاکر^۲ (KKT) مدل LS-SVM به منظور تابع تقریب به صورت رابطه ۵ نوشته می‌شود (Mellit *et al*, 2013):

$$y(x) = \sum_{i=1}^N \alpha_i K(x, x_i) + b \quad (\text{رابطه } 5)$$

کیلومتر مربع محدوده اصلی طراحی شبکه بلندمدت را تشکیل می‌دهد. محدوده اصلی دشت تحت مطالعه بین عرض‌های جغرافیایی $31^{\circ}04'$ تا $31^{\circ}23'$ شمالی و طول‌های جغرافیایی $49^{\circ}25'$ تا $49^{\circ}42'$ شرقی قرار دارد (شکل ۱). به طور کلی، آبخوان دشت رامهرمز از نوع آزاد است که از سمت شرق تغذیه می‌شود (مقاطع ورودی به دشت) و خروجی‌های آن در بخش‌های غربی و جنوبی دشت قرار دارند (Hatef, 2007).

جمع‌آوری اطلاعات

با استفاده از اطلاعات ۶۳ حلقه چاه مشاهده‌ای از سال ۱۳۸۴ تا ۱۳۹۰ تراز سطح آب دشت بررسی شد. بدین منظور از آمار تراز سطح ایستابی، تراز سطح زمین، اطلاعات هواشناسی (بارندگی ماهیانه و تبخیر ماهانه) در این سال‌ها استفاده شد. در این تحقیق از اطلاعات تراز سطح آب ماهیانه دوره آماری سال ۱۳۸۴ تا سال ۱۳۸۹ به منظور تعیین تابع تخمین تراز سطح آب در منطقه استفاده شد. در بخش طراحی شبکه بلندمدت مشاهده سطح آب زیرزمینی از اطلاعات تراز سطح آب زیرزمینی مهرماه سال ۱۳۹۰ به دلیل افت آب در دشت استفاده شد.



شکل ۱. موقعیت مکانی دشت رامهرمز (سفره آب زیرزمینی) و پراکندگی چاه‌ها در سطح دشت در استان خوزستان

مدل حداقل مربعات ماشین بردار پشتیبان (LS-SVM) در این تحقیق از جعبه‌ابزار LS-SVM1.8 در محیط متلب ۲۰۰۹ استفاده شد. الگوریتم LS-SVM در دو مرحله به کار رفت: ۱. آموزش و اعتبارسنجی و ۲. طراحی.

در این مطالعه از روش LS-SVM با قدرت تقریب دقیق سطح آب زیرزمینی استفاده شد تا این روش بتواند خطای پیش‌بینی را به حداقل برساند و چاههای اضافی را با دقت به

1. Flatness

2. Karush-Kuhn-Tucker

در ارزیابی مدل استفاده شد (Seifi, 2010). هر چه میزان R^2 به ۱ نزدیکتر باشد بهتر است. کمتر بودن دو شاخص دیگر نیز عملکرد بهتر و دقت بالای مدل را نشان می‌دهند.

یافته‌ها و بحث

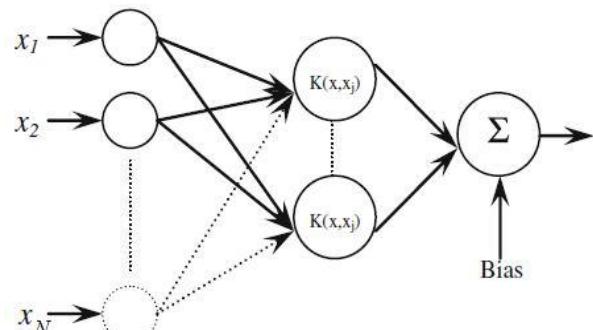
مرحله آموزش و اعتبارسنجی

در این مطالعه آثار حذف هر یک از پارامترها بر تقریب تراز سطح آب زیرزمینی بررسی شد. ترکیب‌ها با پارامترهای ورودی مورد نظر در جدول ۱ می‌آید.

مرحله طراحی

در جدول ۲ شاخص‌های ارزیابی عملکرد هر یک از ترکیب‌های ورودی می‌آید.

از آنجا که مقدار ضریب تبیین (R^2) برای ارزیابی مدل اکتفا نمی‌کند، باید همه شاخص‌های آماری محاسبه و در کنار L هم بررسی شوند. با توجه به مقدار R^2 بالای تخمین ترکیب LS در حدود ۰/۹۹۹۲ و در کنار آن مقادیر پایین MAE و RMSE به ترتیب حدود ۰/۳۴۰۵ و ۰/۷۷۵۸ نسبت به شاخص‌های ارزیابی تخمین مدل LS-SVM با ورودی ترکیب‌های دیگر، می‌توان ترکیب L را با ورودی پارامترهای تراز سطح آب زیرزمینی یک ماه قبل، بارندگی دو ماه قبل، تراز سطح زمین، مختصات و تبخیر به عنوان ترکیب برتر معرفی کرد. البته میزان شاخص‌های برآورده شده در اکثر ترکیب‌ها به غیر از ترکیب F نزدیک هماند. این نشان دهنده اثر بالای مقادیر اندازه‌گیری شده تراز سطح آب یک ماه قبل بر تخمین تراز سطح ایستابی است. با توجه به نتایج ترکیب‌های B , H , K , O , N و P که در آن‌ها تراز سطح زمین در نظر گرفته نشده است می‌توان به اهمیت تراز سطح زمین بر شبیه‌سازی سطح آب زیرزمینی اشاره کرد. با توجه به خطای بالاتر این ترکیب‌ها نسبت به ترکیب‌های دیگر می‌توان گفت تراز سطح آب از تراز سطح زمین تعیین می‌کند. در تحقیق Khashei- Siuki et al (2013) نیز بهترین ترکیب‌های تخمین تراز سطح آب زیرزمینی ترکیب‌هایی بودند که تراز سطح زمین در آن‌ها در نظر گرفته شده بود. تعیین و راپارامترهای بهینه بهترین ترکیب تخمین تراز سطح آب زیرزمینی بسیار ضرورت دارد. با توجه به پارامترهای محاسبه شده مدل L , به منزله مدل برتر، مرحله طراحی شبکه چاه‌های آب زیرزمینی در منطقه دشت رامهرمز انجام پذیرفت. در این زمینه از مزایای بردارهای پشتیبان استفاده شد. برخلاف مدل کلاسیک SVM همه داده‌های ورودی به مدل LS-SVM



شکل ۲. معماری مدل LS-SVM (Mellit, 2013)

($K(x_i, x_j)$)تابع کرنل نامیده می‌شود که با تعییت از شرایط مرس^۱ تابعی با ایجاد ضرب داخلی در فضای ویژگی معرفی می‌شود (Shiloh Shah, 2007)

$$K(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle \quad i, j = 1, \dots, N \quad (\text{رابطه } 6)$$

در این تحقیق از تابع کرنل پایه شعاعی^۲ برای حل استفاده شد. تعیین پارامتر تنظیم‌کننده بخش خطا (ϵ) و تعیین σ پارامتر تابع کرنل پایه شعاعی با رابطه ۷ امکان‌پذیر است:

$$K(x_i, x_j) = \exp\left(-\frac{|x_i - x_j|^2}{2\sigma^2}\right) \quad (\text{رابطه } 7)$$

تجزیه و تحلیل داده‌ها

وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه‌ها می‌شود. به منظور افزایش کارایی مدل LS-SVM، همه داده‌ها ابتدا به شکل نرمال بین دو عدد ۰/۱ و ۰/۹ استاندارد شدند (رابطه ۸). سپس اعداد نرمال شده در خروجی به مقادیر اولیه برگردانده شدند (Seifi, 2010)

$$x_i = 0.8 \left[\frac{x - x_{\min}}{x_{\max} - x_{\min}} \right] + 0.1 \quad (\text{رابطه } 8)$$

x_{\min} و x_{\max} مقدار استاندارد شده، χ مقدار واقعی، و بهتر ترتیب مقادیر حداکثر و حداقل داده‌هاست.

در بخش مدل‌سازی ۷۵ و ۲۵ درصد داده‌ها به ترتیب به داده‌های آموزشی و داده‌های بخش آزمون تعلق گرفت. در بخش اعتبارسنجی از Crossvalidate-10fold و تابع بهینه‌سازی Simplex برای تعیین مقادیر و راپارامترهای^۳ بهینه^۴ و R^2 استفاده شد. شاخص‌های آماری R^2 (ضریب تبیین)، RMSE (ریشه میانگین مربعات خطای مطلق) و MAE (میانگین مربعات خطای مطلق)

1. Mercer

2. Radial Basis

3. Slack Variable

تخمين را محاسبه کرد. بر اساس نظریه سویکنس می‌توان با حذف ۵ درصد از کمترین مقادیر ضرایب لاغرانژ در هر بار آموزش تعداد بردارهای پشتیبان را بر اساس تعريف کاربر محاسبه کرد (Suykens *et al.*, 2002). مقادیر میانگین خطای مطلق (MAE) مربوط به عملکرد پیش‌بینی مدل LS-SVM در مقابل تعداد چاههای مشاهداتی بهینه در شکل ۳ برآورد داده شده‌اند.

بردارهای پشتیبان درنظر گرفته می‌شوند؛ به این معنا که در SVM با مقادیر مختلف خطای تعداد بردارهای پشتیبان متفاوت است و همه داده‌های ورودی بر تابع تصمیم یا تابع رگرسیونی تخمین اثرگذار نیستند. در واقع هر چه بردارهای پشتیبان بیشتر باشند تخمین از دقت بالاتری برخوردار خواهد بود. با توجه به دقت بالای مدل LS-SVM همه داده‌های ورودی جهت آموزش بردار پشتیبان درنظر گرفته می‌شوند. اما می‌توان بر اساس مقادیر ضرایب لاغرانژ بردارهای پشتیبان مؤثرتر بر تابع

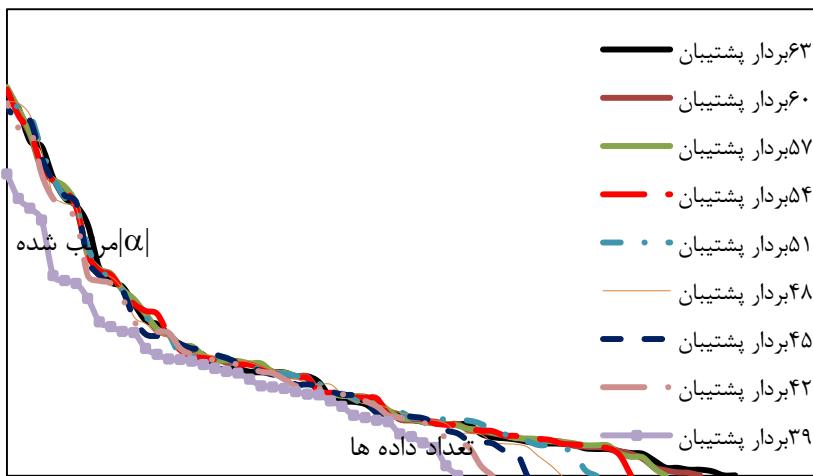
جدول ۱. تعیین ترکیب پارامترهای ورودی به مدل LS-SVM

| پارامترهای ورودی | | | | | | | | ترکیب |
|-------------------------|------------------------------|------------|-------------------------|---------------------------|---------------|--------|---|-------|
| بارندگی دو ماه قبل (mm) | تراز سطح ایستایی ماه قبل (m) | تبخیر (mm) | بارندگی یک ماه قبل (mm) | بارندگی ماه مورد نظر (mm) | تراز زمین (m) | مختصات | | |
| * | * | * | * | * | * | * | * | A |
| * | * | * | * | * | * | * | * | B |
| * | * | * | * | * | * | * | * | C |
| * | * | * | * | * | * | * | * | D |
| * | * | * | * | * | * | * | * | E |
| * | * | * | * | * | * | * | * | F |
| * | * | * | * | * | * | * | * | G |
| * | * | * | * | * | * | * | * | H |
| * | * | * | * | * | * | * | * | K |
| * | * | * | * | * | * | * | * | L |
| * | * | * | * | * | * | * | * | M |
| * | * | * | * | * | * | * | * | N |
| * | * | * | * | * | * | * | * | O |
| * | * | * | * | * | * | * | * | P |

* نشان‌دهنده ورود پارامتر مورد نظر در ترکیب است.

جدول ۲. ارزیابی مدل LS-SVM بر اساس شاخص‌های آماری

| آزمایش | آموزش | | | شماره ترکیب | | |
|--------|--------|----------------|--------|-------------|----------------|---|
| MAE | RMSE | R ² | MAE | RMSE | R ² | |
| ۰,۶۱۵۶ | ۱,۰۳۴۴ | ۰,۹۹۹۱ | ۰,۴۲۱۹ | ۰,۹۹۹۶ | ۰,۹۹۸۸ | A |
| ۰,۴۱۳۶ | ۰,۸۳۹۱ | ۰,۹۹۹۳ | ۰,۳۱۸۱ | ۱,۰۱۸۲ | ۰,۹۹۸۷ | B |
| ۰,۳۸۳ | ۰,۷۷۹۴ | ۰,۹۹۹۳ | ۰,۲۶۱۳ | ۰,۵۳۰۹ | ۰,۹۹۹۶ | C |
| ۰,۳۵۱۴ | ۰,۷۹۱۵ | ۰,۹۹۹۲ | ۰,۳۱۹۸ | ۰,۶۲۵۷ | ۰,۹۹۹۵ | D |
| ۰,۶۲۲ | ۰,۹۹۵۵ | ۰,۹۹۹۲ | ۰,۳۶۸۵ | ۰,۶۶۲۹ | ۰,۹۹۹۵ | E |
| ۱,۷۰۰۵ | ۲,۴۳۶۱ | ۰,۹۹۵۲ | ۱,۱۳۸۹ | ۱,۵۹۸۲ | ۰,۹۹۷۲ | F |
| ۰,۶۰۲۱ | ۰,۹۳۶ | ۰,۹۹۹۲ | ۰,۲۷۶ | ۰,۵۴۷۳ | ۰,۹۹۹۶ | G |
| ۰,۶۲۳۸ | ۱,۰۳۲۸ | ۰,۹۹۹۲ | ۰,۳۶۱۸ | ۰,۶۵۴۸ | ۰,۹۹۹۵ | H |
| ۰,۸۳۳۱ | ۱,۲۹۸۷ | ۰,۹۹۹۱ | ۰,۶۲۶۹ | ۰,۹۴۱۵ | ۰,۹۹۹۵ | K |
| ۰,۳۴۰۵ | ۰,۷۷۵۸ | ۰,۹۹۹۲ | ۰,۳۶۲۳ | ۰,۶۷۷۲ | ۰,۹۹۹۵ | L |
| ۰,۵۱۲۴ | ۰,۹۳۷۶ | ۰,۹۹۹۲ | ۰,۳۹۴۸ | ۰,۶۸۹ | ۰,۹۹۹۵ | M |
| ۰,۴۵۹۳ | ۰,۸۸۰۴ | ۰,۹۹۹۱ | ۰,۴۳۸۱ | ۰,۶۸۴۲ | ۰,۹۹۹۵ | N |
| ۰,۴۴۸۳ | ۰,۸۶۹۹ | ۰,۹۹۹۲ | ۰,۳۲۹۴ | ۰,۵۵۷۶ | ۰,۹۹۹۶ | O |
| ۰,۸۳۳۱ | ۱,۲۹۸۷ | ۰,۹۹۹۱ | ۰,۶۲۶۹ | ۰,۹۴۱۵ | ۰,۹۹۹۵ | P |



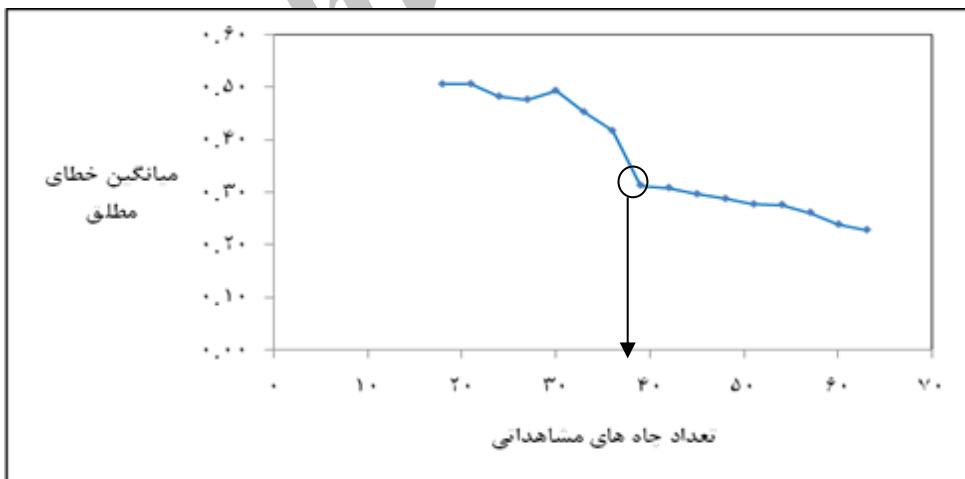
شکل ۳. نمودار ضرایب لگاریتم مرتب شده به ازای تعداد بردارهای پشتیبان (چاهها)

تقریباً نزدیک به ۰ است. البته باید خطای پیش‌بینی چاههای حذف شده را، که از طریق اندازه‌گیری چاههای بهینه به دست می‌آیند، در نظر گرفت. در جدول ۳ مقادیر و راپارامترهای بهینه ترکیب L و در جدول ۴ چاههای حذف شده و خطای پیش‌بینی محاسبه شده این چاهها می‌آید.

جدول ۳. وراپارامترهای بهینه مدل برتر

| مدل | نوع تابع کرنل | پارامتر کرنل | پارامتر ۷ |
|------------|----------------------|--------------|-----------|
| ۱۲۲۱۷،۸۱۶۷ | $\sigma^2 = 62,4363$ | RBF | L |

پس چاههایی در پیش‌بینی سطح آب منطقه شرکت می‌کنند که خارج از خطای تعریف شده قرار می‌گیرند، به عبارت دیگر، چاههایی که میزان اتفاق آنها از تابع تخمین حداقل یا مقادیر ضرایب لگاریتم آنها کم باشد به راحتی قابلیت حذف از شبکه را دارند. اگر این چاهها مورد نظرات یا مشاهده قرار نگیرند، خطای پیش‌بینی حداقل و قابل پذیرش خواهد بود (Asefa et al, 2004). اختلاف تخمین تراز سطح آب این چاهها با استفاده از تابع تخمین اعمال شده و مقادیر اندازه‌گیری شده



شکل ۴. تعداد چاههای بهینه

۳۹ حلقه چاه، خطای پیش‌بینی تراز سطح آب چاههای حذف شده بالغ بر ۱ متر خواهد بود. پس در نقطه ۴۲ چاه بهینه عملکرد مدل متوقف می‌شود. در جدول ۴ مقادیر شاخص‌های آماری پیش‌بینی تراز سطح آب در چاههای حذف شده توسط چاههای باقی‌مانده در شبکه می‌آید.

با توجه به شکل ۴، هر چه تعداد چاههای نظارت شده افزایش می‌یابد میانگین خطای مطلق تخمین تراز سطح آب داشت کم می‌شود. از ۳۹ چاه به سمت کاهش چاهها ملاحظه می‌شود میانگین خطای مطلق با شیب تندتری افزایش می‌یابد. در بررسی شاخص‌های آماری برای ۳۹ چاه و چاههای کمتر از

جدول ۴. ارزیابی پیش‌بینی تراز سطح آب در چاههای حذف شده از شبکه

| تعداد چاه بهینه | MAE | RMSE | R ² | چاههای حذف شده |
|--------------------|---------|---------|----------------|--|
| ۶۰ | ۰.۱۰۰۳۲ | ۰.۱۰۰۵۶ | ۱ | R ₁₅ ,R ₁₉ ,R ₄₃ |
| ۵۷ | ۰.۱۰۵۱۸ | ۰.۱۰۶۹۸ | ۱ | R ₁₅ ,R ₁₉ ,R ₄₃ ,R ₄₂ ,R ₄₈ ,R ₇₇ |
| ۵۴ | ۰.۱۲۰۴ | ۰.۱۵ | ۱ | R ₁₅ ,R ₁₉ ,R ₄₃ ,R ₄₂ ,R ₄₈ ,R ₇₇ ,R ₁₁ ,R ₂₉ ,R ₇₆ |
| ۵۱ | ۰.۱۵۵۸ | ۰.۲۳۰۲ | ۱ | R ₁₅ ,R ₁₉ ,R ₄₃ ,R ₄₂ ,R ₄₈ ,R ₇₇ ,R ₁₁ ,R ₂₉ ,R ₇₆ ,R ₆ ,R ₂₇ ,R ₇₈ |
| ۴۸ | ۰.۱۵۰۴ | ۰.۲۵۵۲ | ۰.۹۹۹ | R ₁₅ ,R ₁₉ ,R ₄₃ ,R ₄₂ ,R ₄₇ ,R ₇₇ ,R ₁₁ ,R ₂₉ ,R ₇₅ ,R ₆ ,R ₂₇ ,R ₇₈ ,R ₅ ,R ₂₆ ,R ₄₅ |
| ۴۵ | ۰.۲۷۳۹ | ۰.۳۸۴۳ | ۰.۹۹۹ | R ₁₅ ,R ₁₉ ,R ₄₃ ,R ₄₂ ,R ₄₇ ,R ₇₇ ,R ₁₁ ,R ₂₉ ,R ₇₅ ,R ₆ ,R ₂₇ ,R ₇₈ ,R ₅ ,R ₂₆ ,R ₄₅ ,R ₂ ,R ₈ ,R ₇₀ ,R ₄ ,R ₆₂ ,R ₆₃ |
| ۴۲ | ۰.۳۲۴۳ | ۰.۵۲۶۳ | ۰.۹۹۸ | R ₁₅ ,R ₁₉ ,R ₄₃ ,R ₄₂ ,R ₄₇ ,R ₇₇ ,R ₁₁ ,R ₂₉ ,R ₇₅ ,R ₆ ,R ₂₇ ,R ₇₈ ,R ₅ ,R ₂₆ ,R ₄₅ ,R ₂ ,R ₈ ,R ₇₀ ,R ₄ ,R ₆₂ ,R ₆₃ |

نتیجه‌گیری

در این تحقیق کاربرد مدل شبیه‌ساز LS-SVM در تخمین تراز سطح آب زیرزمینی ارائه شد. این مدل توانست شبکه بلندمدت آب زیرزمینی را ارائه کند که قابلیت تخمین سطح آب زیرزمینی منطقه را به طور دقیق دارد. در ادامه این مطالعه بر حل مشکل اندازه‌گیری‌های اضافی مکانی چاههای مشاهداتی در منطقه رامهرمز با پیشنهاد نقاط نمونه‌گیری معین در آینده و تغییر در اندازه شبکه چاههای مشاهداتی پرداخته شد. در این تحقیق معیار حذف چاهها فقط با مدل LS-SVM صورت گرفت و معیار حذف چاهها از شبکه امکان تخمین دقیق سطح ایستابی در چاههای حذف شده، با استفاده از اطلاعات چاههای باقیمانده در شبکه، بود.

REFERENCES

- Asefa, T., W. Kembrowski, M., Urroz, G., McKee, M., and Khalil, A., (2004). Support vectors machines(SVM) for monitoring network design. *Journal of Ground water*.43(3),413-422.
- Asefa, T., W. Kembrowski, M., Urroz, G., McKee, M., and Khalil, A., (2005). Support vectors-based groundwater head observation networks design. *Journal of Water Resources Research*.40.
- Bashi-Azghadi, S. N. and Kerachian, R. (2010). Locating monitoring wells in groundwater systems using embedded optimization and simulation models. *Science of the Total Environment*. 408, 2189–2198.
- Cristianini, N. and Shawe-Taylor, J. (2000). *An Introduction to Support Vector Machines*. Cambridge university press. NEW YORK.
- Guo, Y., Wang, j., Yin, X., (2011). Optimizing the ground water monitoring network using MSN Theory. *Procedia Social and behavioral Sciences*. 21, 240-242.
- H.Hwang, S., H. Ham, D., and H. Kim, J. (2012). Forecasting Performance of LS-SVM For Nonlinear Hydrological Time Series. *Journal of Civil Engineering*, 16(5), 870-882.
- Hatef, M. R. (2007). Final Report of project study Plain RAMHORMOZ hydroclimatology balance, Ahvaz, Khuzestan Water and Power Organization.
- Khashei-Siuki, A., Ghahraman, B., and Kouchakzadeh, M. (2013). Comparison of ANN, ANFIS and Regression models to estimate groundwater level of Neyshaboor aquifer. *Journal of Irrigation and Drainage*, 7(1), 10-22. (In Farsi)
- Kisi, O. (2012). Least squares support vector machine for modeling daily reference evapotranspiration. *Irrig Sci.*
- Masoumi, F. and Kerachian, R. (2007). Optimal Groundwater Monitoring Network Design Using the Entropy Theory. *Journal of Water & Wastewater*,65. (In Farsi).
- Mellit, A., Massi Pavan, A., and Benghanem, M. (2013). Least squares support vector machine for short-term prediction of meteorological time series. *Theor Appl Climatol*,111, 297–307.

با توجه به شکل ۴، وقتی تعداد چاههای مشاهداتی بیشتر باشد مقدار میانگین خطای مطلق کم می‌شود. هر چه تعداد چاههای مشاهداتی کم شود مقدار میانگین خطای مطلق بیشتر می‌شود. اما به دلیل هزینه‌های بالا و صرفه‌جویی در زمان کاهش شبکه مشاهداتی ضرورت می‌یابد. در حقیقت، با توجه به جدول ۴، تا مرحله‌ای که خطای پیش‌بینی چاههای مشاهداتی نظارت‌نشده پایین باشد و در کنار آن مقدار پیش‌بینی تراز سطح آب منطقه از طریق اندازه‌گیری سطح آب در چاههای مشاهداتی بهینه دارای خطای حداقل باشد، می‌توان چاههای اضافی از نظر مکانی را از شبکه مشاهداتی دشت رامهرمز حذف کرد. در این صورت می‌توان با داشتن تعداد ۴۲ حلقه چاه بهینه در منطقه رامهرمز شبکه بلندمدت آب زیرزمینی را تشکیل داد. در این تحقیق مشخص شد که توزیع مکانی چاههای نهایی در دشت رامهرمز پراکندگی خوبی دارد.

- Seifi, A. (2010). Developing an Expert System for Predicting Daily Reference Evapotranspiration Using Support Vector Machines (SVM) in Comparison with ANFIS, ANN and Empirical Methods. M. S. in Irrigation and drainage Engineering, Tarbiat Modares University, Tehran. (In Farsi)
- Shiloh Shah, R. (2007). *Support vector machines for classification and regression*, Master of science, computer science, McGill university Montreal, Quebec.
- Suykens, J. A. K., Gestel, T. V., Brabanter, J. D., Moor, B. D., and Vandewalle, J. (2002). *Least Squares Support Vector Machines*. Copyright by World Scientific Publishing Co. Pte. Ltd. (pp.58,72-75, 98-99).
- Zhou, Y., Dong, D., Lio, and J. Li, W. (2013). Upgrading a regional groundwater level monitoring network for Beijing Plain, China. *GEoSCIENCE FRONTIERS*, 4, 127-138.

Archive of SID