

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

الهام رضایی<sup>۱\*</sup>، عباس خاشعی سیوکی<sup>۲</sup>، علی شهیدی<sup>۳</sup>

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 روشی برای طراحی شبکه‌های پایش کمی آب زیرزمینی به منظور کاهش نقاط پایش 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 دربرگیرنده شاخص‌های عملکرد ( $MAE=0.3405$  و  $R^2=0.9992$ ) است. سپس، با استفاده از تابع 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 پیرومتری به دست آوردن اطلاعات درباره خصوصیات هیدرولوژیکی، مهندسی زمین‌شناسی و هیدروژئولوژیکی، 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 کاملی از رفتار آبخوان باشد.

طراحی شبکه‌های مشاهداتی از مسائل بهینه‌سازی چندهدفه 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 انجام دادن 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 مبین 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 روش‌هایی ایفای نقش کرده‌اند؛ از روش‌های زمین‌آماري 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 مشاهده‌ای سطح آب زیرزمینی

«ماشین بردار پشتیبان»، در سال ۱۹۹۵ تا ۱۹۹۸، بر پایهٔ تئوری یادگیری آماری<sup>۵</sup>، که از حداقل‌سازی ریسک ساختاری<sup>۶</sup> تبعیت می‌کند، ارائه کرد. در سال ۱۹۹۹ وندوال<sup>۷</sup> و سویکنس<sup>۸</sup> 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 صورت گرفته 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 هوا و رطوبت نسبی، پرداخته شد. نتایج این تحقیق با نتایج به‌دست‌آمده 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). همچنین دقت مدل LS-SVM در مدل‌سازی تبخیر 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<sup>۱</sup> 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). در زمینه طراحی شبکه مشاهده سطح آب زیرزمینی Guo et al (2011) به مقایسه چند روش، نمونه‌گیری، تجزیه و تحلیل هیدرولوژیکی، و روشی همراه رویکرد سطح میانگین غیر همگن<sup>۲</sup> (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 روش، ابتدا با کمک مدل‌های MODFLOW و MT3D شبیه‌سازی انجام شد. سپس، از نتایج مدل بهینه‌سازی تک‌هدفه و شبیه‌سازی تجزیه و تحلیل مونت کارلو 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). همچنین، در مطالعه‌ای، کارایی سامانه پایش کیفی منابع آب زیرزمینی دشت تهران با استفاده از تئوری آنتروپی گسسته ارزیابی شد. نتایج نشان‌دهنده کارایی مناسب الگوریتم پیشنهادی در ارزیابی و به‌هنگام‌سازی سامانه‌های پایش کیفی منابع آب زیرزمینی بود (Masoumi and Kerachian, 2007). تحقیقاتی در زمینه پایش کیفی به منظور حداکثرسانی 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 کارآمد بودن این روش در مقایسه با روش کریجینگ بود (Asefa et al, 2004).

در این مطالعه از مدل پیشنهادی حداقل مربعات ماشین بردار پشتیبان<sup>۳</sup> استفاده شد. این روش را ابتدا وپنیک<sup>۴</sup>، 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. Vapnik

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

مجموعه داده‌های آموزشی را خواهیم داشت. که  $\vec{x}_i \in R^n$  به عنوان بردار ورودی و  $\vec{y}_i \in R$  به عنوان بردار خروجی معرفی می‌شوند.

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

$$y(x) = w^T \cdot \varphi(x_i) + b \quad (\text{رابطه ۱})$$

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:

$$\min_{w, e, b} j(w, e) = \frac{1}{2} w^T w + \frac{\gamma}{2} \sum_{i=1}^N e_i^2 \quad (\text{رابطه ۲})$$

بر اساس محدودیت:

$$y_i = w^T \varphi(x_i) + b + e_i \quad (\text{رابطه ۳})$$

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

حل با استفاده از شکل لاگرانژی از تابع هدف اصلی:

$$L(w, b, e; \alpha) = j(w, e) - \sum_{i=1}^N \alpha_i \{w^T \varphi(x_i) + b + e_i - y_i\} \quad (\text{رابطه ۴})$$

$\alpha_i$  ضریب لاگرانژ است.

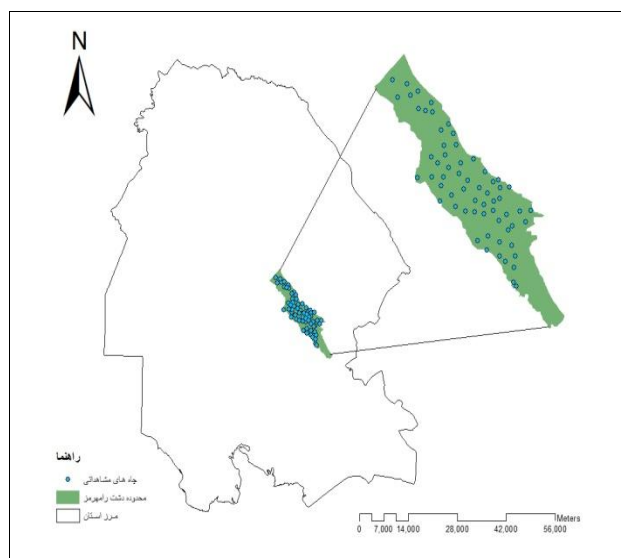
بر اساس شرایط کان-تاکر<sup>۲</sup> (KKT) مدل LS-SVM به منظور تابع تقریب به صورت رابطه ۵ نوشته می‌شود (Mellit et al, 2013):

$$y(x) = \sum_{i=1}^N \alpha_i K(x, x_i) + b \quad (\text{رابطه ۵})$$

کیلومتر مربع محدوده اصلی طراحی شبکه بلندمدت را تشکیل می‌دهد. محدوده اصلی دشت تحت مطالعه بین عرض‌های جغرافیایی ۳۱°۰۴' تا ۳۱°۲۳' شمالی و طول‌های جغرافیایی ۴۹°۲۵' تا ۴۹°۴۲' 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 نزدیک تر باشد بهتر است. کمترین 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 هم بررسی شوند. با توجه به مقدار  $R^2$  بالای تخمین ترکیب L 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 برآورد شده در اکثر ترکیب‌ها به غیر از ترکیب F نزدیک هم‌اند. این نشان‌دهنده 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، N، O، 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 تبعیت 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 واپارامترهای 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)

تابع کرنل نامیده می‌شود که با تبعیت از شرایط مرسر<sup>۱</sup> تابعی با ایجاد ضرب داخلی در فضای ویژگی معرفی می‌شود (Shiloh Shah, 2007):

$$K(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle \quad i, j = 1, \dots, N \quad (\text{رابطه ۶})$$

در این تحقیق از تابع کرنل پایه شعاعی<sup>۲</sup> برای حل استفاده شد. تعیین پارامتر تنظیم‌کننده بخش خطا ( $\gamma$ ) و تعیین  $\sigma < 0$  پارامتر تابع کرنل پایه شعاعی با رابطه ۷ امکان‌پذیر است:

$$K(x_i, x_j) = \exp\left(-\frac{|x_i - x_j|^2}{2\sigma^2}\right) \quad (\text{رابطه ۷})$$

#### 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):

$$x_i = 0.8 \left[ \frac{x - x_{\min}}{x_{\max} - x_{\min}} \right] + 0.1 \quad (\text{رابطه ۸})$$

$x_{\min}$  مقدار استاندارد شده،  $\gamma$  مقدار واقعی، و  $x_{\max}$  و  $x_{\min}$  به 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 واپارامترهای<sup>۳</sup> بهینه  $\gamma$  و  $\sigma$  استفاده شد. شاخص‌های آماری  $R^2$  (ضریب تبیین)، RMSE (ریشه میانگین مربعات خطا)، و MAE (میانگین خطای مطلق)

1. Mercer  
2. Radial Basis  
3. Slack Variable

تخمین را محاسبه کرد. بر اساس نظریه‌ی سویکنس می‌توان با حذف ۵ درصد از کمترین مقادیر ضرایب لاگرانژ در هر بار آموزش تعداد بردارهای پشتیبان را بر اساس تعریف 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 برآزش داده شده‌اند.

بردارهای پشتیبان در نظر گرفته می‌شوند؛ به این معنا که در مدل SVM با مقادیر مختلف خطا تعداد بردارهای پشتیبان متفاوت است و همه‌ی 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 همه‌ی داده‌های ورودی جهت آموزش بردار پشتیبان در نظر گرفته می‌شوند. اما می‌توان بر اساس مقادیر ضرایب لاگرانژ بردارهای پشتیبان مؤثرتر بر تابع

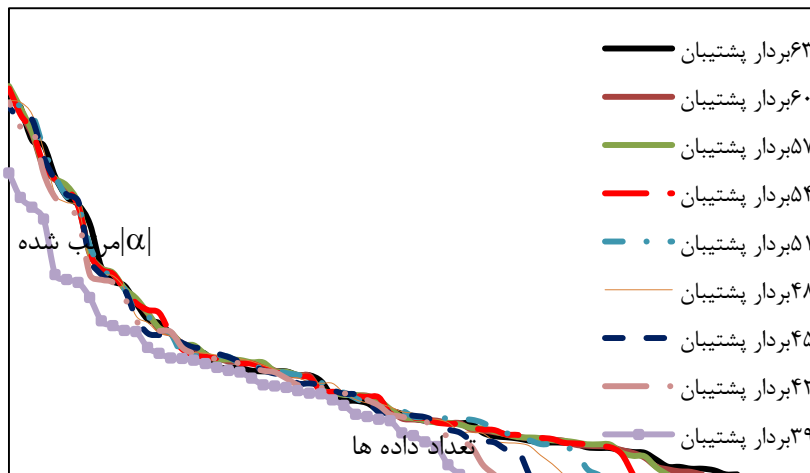
جدول ۱. تعیین ترکیب پارامترهای ورودی به مدل LS-SVM

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

\* نشان‌دهنده‌ی ورود پارامتر مورد نظر در ترکیب است.

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

شماره‌ی ترکیب	آموزش			آزمایش		
	MAE	RMSE	R <sup>2</sup>	MAE	RMSE	R <sup>2</sup>
A	۰٫۹۹۹۶	۱٫۰۱۸۲	۰٫۹۹۸۸	۰٫۴۲۱۹	۰٫۹۹۹۶	۰٫۹۹۹۱
B	۰٫۹۹۹۶	۰٫۵۳۰۹	۰٫۹۹۹۶	۰٫۳۱۸۱	۰٫۸۳۹۱	۰٫۹۹۹۳
C	۰٫۹۹۹۵	۰٫۶۲۵۷	۰٫۹۹۹۵	۰٫۲۶۱۳	۰٫۷۷۹۴	۰٫۹۹۹۳
D	۰٫۹۹۹۵	۰٫۶۶۲۹	۰٫۹۹۹۵	۰٫۳۱۹۸	۰٫۷۹۱۵	۰٫۹۹۹۲
E	۰٫۹۹۹۵	۰٫۶۶۲۹	۰٫۹۹۹۵	۰٫۳۶۸۵	۰٫۹۹۵۵	۰٫۹۹۹۲
F	۰٫۹۹۷۲	۱٫۵۹۸۲	۰٫۹۹۷۲	۱٫۱۳۸۹	۲٫۴۳۶۱	۰٫۹۹۵۲
G	۰٫۹۹۹۶	۰٫۵۴۷۳	۰٫۹۹۹۶	۰٫۲۷۶	۰٫۹۳۶	۰٫۹۹۹۲
H	۰٫۹۹۹۵	۰٫۶۵۴۸	۰٫۹۹۹۵	۰٫۳۶۱۸	۱٫۰۳۲۸	۰٫۹۹۹۲
K	۰٫۹۹۹۵	۰٫۹۴۱۵	۰٫۹۹۹۵	۰٫۶۲۶۹	۱٫۲۹۸۷	۰٫۹۹۹۱
L	۰٫۹۹۹۵	۰٫۶۷۷۲	۰٫۹۹۹۵	۰٫۳۶۲۳	۰٫۷۷۵۸	۰٫۹۹۹۲
M	۰٫۹۹۹۵	۰٫۶۸۹	۰٫۹۹۹۵	۰٫۳۹۴۸	۰٫۹۳۷۶	۰٫۹۹۹۲
N	۰٫۹۹۹۵	۰٫۶۸۴۲	۰٫۹۹۹۵	۰٫۴۳۸۱	۰٫۸۸۰۴	۰٫۹۹۹۱
O	۰٫۹۹۹۶	۰٫۵۵۷۶	۰٫۹۹۹۶	۰٫۳۲۹۴	۰٫۸۶۹۹	۰٫۹۹۹۲
P	۰٫۹۹۹۵	۰٫۹۴۱۵	۰٫۹۹۹۵	۰٫۶۲۶۹	۱٫۲۹۸۷	۰٫۹۹۹۱




شکل ۳. نمودار ضرایب لاگرانژ مرتب‌شده به‌ازای تعداد بردارهای پشتیبان (چاه‌ها)

تقریباً نزدیک به ۰ است. البته باید خطای پیش‌بینی چاه‌های حذف‌شده را، که از طریق اندازه‌گیری چاه‌های بهینه به‌دست می‌آیند، در نظر گرفت. در جدول ۳ مقادیر و پارامترهای بهینه ترکیب L و در جدول ۴ چاه‌های حذف‌شده و خطای پیش‌بینی محاسبه‌شده این چاه‌ها می‌آید.

جدول ۳. واپارامترهای بهینه مدل برتر L

مدل	نوع تابع کرنل	پارامتر تابع کرنل	پارامتر $\gamma$
L	RBF	$\sigma^2 = 62,4363$	۱۲۲۱۷,۸۱۶۷

پس چاه‌هایی در پیش‌بینی سطح آب منطقه شرکت می‌کنند که خارج از خطای تعریف‌شده قرار می‌گیرند. به عبارت دیگر، چاه‌هایی که میزان اتلاف آن‌ها از تابع تخمین حداقل یا مقادیر ضرایب لاگرانژ آن‌ها کم باشد به راحتی قابلیت حذف از شبکه را دارند. اگر این چاه‌ها مورد نظارت 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 اعمال‌شده و مقادیر اندازه‌گیری‌شده



شکل ۴. تعداد چاه‌های بهینه

۳۹ حلقه چاه، خطای پیش‌بینی تراز سطح آب چاه‌های حذف‌شده 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 حذف‌شده توسط چاه‌های باقی‌مانده در شبکه می‌آید.

با توجه به شکل ۴، هر چه تعداد چاه‌های نظارت‌شده افزایش می‌یابد میانگین خطای مطلق تخمین تراز سطح آب دشت 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 حذف‌شده از شبکه

تعداد چاه بهینه	MAE	RMSE	R <sup>2</sup>	چاه‌های حذف‌شده
۶۰	۰٫۰۰۳۲	۰٫۰۰۵۶	۱	R <sub>15</sub> , R <sub>19</sub> , R <sub>43</sub>
۵۷	۰٫۰۵۱۸	۰٫۰۶۹۸	۱	R <sub>15</sub> , R <sub>19</sub> , R <sub>43</sub> , R <sub>42</sub> , R <sub>48</sub> , R <sub>77</sub>
۵۴	۰٫۱۲۰۴	۰٫۱۵	۱	R <sub>15</sub> , R <sub>19</sub> , R <sub>43</sub> , R <sub>42</sub> , R <sub>48</sub> , R <sub>77</sub> , R <sub>11</sub> , R <sub>29</sub> , R <sub>76</sub>
۵۱	۰٫۱۵۵۸	۰٫۲۳۰۲	۱	R <sub>15</sub> , R <sub>19</sub> , R <sub>43</sub> , R <sub>42</sub> , R <sub>48</sub> , R <sub>77</sub> , R <sub>11</sub> , R <sub>29</sub> , R <sub>76</sub> , R <sub>6</sub> , R <sub>27</sub> , R <sub>78</sub>
۴۸	۰٫۱۵۰۴	۰٫۲۵۵۲	۰٫۹۹۹	R <sub>15</sub> , R <sub>19</sub> , R <sub>43</sub> , R <sub>42</sub> , R <sub>47</sub> , R <sub>77</sub> , R <sub>11</sub> , R <sub>29</sub> , R <sub>75</sub> , R <sub>6</sub> , R <sub>27</sub> , R <sub>78</sub> , R <sub>5</sub> , R <sub>26</sub> , R <sub>45</sub>
۴۵	۰٫۲۷۳۹	۰٫۳۸۴۳	۰٫۹۹۹	R <sub>15</sub> , R <sub>19</sub> , R <sub>43</sub> , R <sub>42</sub> , R <sub>47</sub> , R <sub>77</sub> , R <sub>11</sub> , R <sub>29</sub> , R <sub>75</sub> , R <sub>6</sub> , R <sub>27</sub> , R <sub>78</sub> , R <sub>5</sub> , R <sub>26</sub> , R <sub>45</sub> , R <sub>2</sub> , R <sub>8</sub> , R <sub>70</sub>
۴۲	۰٫۳۳۴۳	۰٫۵۲۶۳	۰٫۹۹۸	R <sub>15</sub> , R <sub>19</sub> , R <sub>43</sub> , R <sub>42</sub> , R <sub>47</sub> , R <sub>77</sub> , R <sub>11</sub> , R <sub>29</sub> , R <sub>75</sub> , R <sub>6</sub> , R <sub>27</sub> , R <sub>78</sub> , R <sub>5</sub> , R <sub>26</sub> , R <sub>45</sub> , R <sub>2</sub> , R <sub>8</sub> , R <sub>70</sub> , R <sub>4</sub> , R <sub>62</sub> , R <sub>63</sub>

## 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 داراست. 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 حذف‌شده، با استفاده از اطلاعات چاه‌های باقی‌مانده در شبکه، بود.

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.

## REFERENCES

- Asefa, T., W. Kemblowski, 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. Kemblowski, 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 Neyshaboar 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 Theoty. *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.

- 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. Pie. 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.