

بررسی توزیع مکانی کیفیت آب زیرزمینی با استفاده از مدل‌های MLP، LS-SVM و زمین آماری

عباس خاشعی سیوکی^۱

محبوبه سربازی^۲

(دریافت ۹۲/۶/۱۲)

(پذیرش ۹۳/۱/۲۹)

چکیده

کنترل کیفیت آب زیرزمینی به علت کمبود آب در مناطق خشک و نیمه خشک از اهمیت ویژه‌ای برخوردار است. مدل‌های زمین آماری، روش‌های توسعه یافته پهنه‌بندی برای پیش‌بینی مکانی و میان‌بازی پارامترهای آب زیرزمینی محسوب می‌شود. در این پژوهش روش‌های IDW، کریجینگ و کوکریجینگ در زمین آمار با مدل‌های پرسپترون چند لایه و مدل حداقل مربعات ماشین بردار پشتیبان برای پیش‌بینی توزیع مکانی پارامتر EC آب زیرزمینی بررسی و با یکدیگر مقایسه شد. داده‌ها از ۱۲۰ چاه در دشت مشهد جمع‌آوری شد. بعد از نرمال کردن داده‌ها به منظور استفاده در مدل‌های زمین آماری، واریوگرام‌ها ترسیم و برای انتخاب مدل مناسب، کمترین RSS استفاده شد. سپس با استفاده از اعتبارسنجی متقابل و معیار RMSE، بهترین مدل درونیابی انتخاب شد. برای مقایسه سه مدل از ۲۵ درصد داده‌های مشاهده‌ای استفاده و پارامترهای آماری RMSE، R^2 و MAE تعیین شدند. نتایج نشان داد که برای درونیابی کیفیت آب زیرزمینی روش کوکریجینگ نسبت به کریجینگ ارجحیت دارند. مدل پرسپترون چند لایه با دقت RMSE برابر ۳۶۹/۹ میکروموس بر سانتی‌متر، R^2 برابر ۰/۹۳۲ و MAE برابر ۲۶۵/۷۸ میکروموس بر سانتی‌متر نسبت به دیگر مدل‌ها از دقت بیشتری برخوردار است.

واژه‌های کلیدی: واریوگرام، پرسپترون چند لایه، حداقل مربعات ماشین بردار پشتیبان

Study of Spatial Distribution of Groundwater Quality Using LS-SVM, MLP, and Geostatistical Models

A. Khasheie Siyuki¹

M. Sarbazi²

(Received Sep. 3, 2013

Accepted Apr. 18, 2014)

Abstract

Groundwater quality control is of great importance in (semi-)arid zones due to the water deficit in these regions. Geostatistical models are techniques commonly developed for the interpolation and spatial prediction of groundwater quality parameters. In this study, IDW, Kriging, and CoKriging methods were used in the geostatistical, LS-SVM, and MLP models to predict the spatial distribution of groundwater EC. The models were then compared in terms of their efficiency. For the purposes of this study, data were collected from 120 wells in the Mashhad plain. Variograms were then drawn after normalizing the data for application in the geostatistical models. In the next stage, the lowest RSS value was used for selecting the one model that was suitable for fitting the experimental variogram while cross-validation and RMSE were used to select the best method for interpolation. Comparison of the three models in question was accomplished by using 25% of the observation data and the statistical parameters of RMSE, R^2 , and MAE were determined. Results showed that the CoKriging method outperformed its Kriging counterpart in the geostatistical model for interpolating groundwater quality. Finally, the most accurate values for the quality parameters (i.e., $R^2=0.932$, RMSE=367.9, MAE=265.78($\mu\text{mos/cm}$) were obtained with the MLP model.

Keyword: Variogram, Multilayered Perceptron (MLP), Least Squares Support Vector Machine (LS-SVM).

1. Assist. Prof. of Water Resources Engineering, Birjand University, Birjand
(Corresponding Author) (+98 561) 2254041 abbaskhashei@birjand.ac.ir
2. MSc in Deserts Management, Dept. of Natural Resources, Tehran
University, Tehran

۱- استادیار گروه مهندسی آب، دانشگاه بیرجند (نویسنده مسئول) (۰۵۶۱)۲۲۵۴۰۴۱
abbaskhashei@birjand.ac.ir
۲- کارشناس ارشد مدیریت مناطق بیابانی، دانشکده منابع طبیعی، دانشگاه تهران

و مدل شبکه عصبی مصنوعی مقایسه شد که در نهایت بیانگر دقت این مدل نسبت به روش‌های دیگر بود.

سیفی و ریاحی مدوار در سال ۲۰۱۲، در پیش‌بینی تبخیر و تعرق پتانسیل در اقلیم‌های مختلف ایران از مدل LS-SVM استفاده نمودند و نتایج مدل را با شبکه عصبی مصنوعی و شبکه استنتاج عصبی فازی مقایسه نمودند. نتایج، دقت مدل LS-SVM را نسبت به مدل‌های دیگر نشان داد [۱۳].

آصفا و همکاران در سال ۲۰۰۴ و ۲۰۰۵، به ترتیب از روش ماشین بردار پشتیبان^۱ کلاسیک در ارزیابی شبکه بلندمدت پیش‌گامی آب زیرزمینی و طراحی نقاط کشف آلودگی آب زیرزمینی استفاده کردند. در نهایت، نتایج نشان دهنده قدرت و دقت این روش در طراحی نقاط بهینه بود. عملکرد موفقیت‌آمیز این روش می‌تواند به کاربرد آن در دیگر بخش‌های هیدرولوژی منجر شود [۱۴ و ۱۵].

اسمی‌خانی و همکاران در سال ۱۳۸۹، بر اساس پژوهشی، بهره‌برداری بهینه از منابع آب سطحی و آب زیرزمینی را در محدوده مطالعاتی کوهپایه سگزی در حوضه آبریز زاینده‌رود مطالعه کردند [۱۶]. مدل مدیریتی با تلفیق مدل شبیه‌سازی مبتنی بر روش ماشین بردار پشتیبان و فناوری بهینه‌سازی الگوریتم ژنتیک تدوین شد. نتایج مبین توانایی بسیار ماشین بردار پشتیبان در یادگیری داده‌های آموزشی و همچنین دقت مدل شبیه‌سازی طراحی شده بود. رضایی در سال ۱۳۹۲، در پژوهشی با استفاده از اطلاعات کمی چاه‌های مشاهداتی و پارامترهای هواشناسی دشت رامهرمز در استان خوزستان در دوره‌ای هفت ساله، عملکرد آزمون گاما در امر پیش‌پردازش ورودی مدل‌های هوشمند و بررسی عملکرد مدل LS-SVM را در طراحی شبکه برداشت چاه‌های مشاهداتی آب زیرزمینی ارزیابی کرد [۱۷]. نتایج نشان داد که ترکیب بهینه مدل LS-SVM با تابع کرنل RBF دارای پارامترهای عملکرد MAPE برابر ۰/۳۲۹۳، MAE برابر ۰/۳۴۰۵، RMSE برابر ۰/۷۷۵۸ و R^۲ برابر ۰/۹۹۹۲ است.

خلقی و حسینی قابلیت کریجینگ^۲ معمولی یا OK و شبکه‌های مبتنی بر سیستم ANFIS را در درون‌یابی سطح آب‌های زیرزمینی در یک سفره آزاد در شمال ایران بررسی نمودند. نتایج نشان داد مدل ANFIS در برآورد سطح آب زیرزمینی از کریجینگ معمولی یا OK کارآمدتر است [۱۸].

ساهیونکایا و همکاران در سال ۲۰۰۸، مدل ANN را برای پیش‌بینی غلظت نیترات، شایع‌ترین آلوده‌کننده سفره‌های آب‌های

آب‌های زیرزمینی بزرگ‌ترین ذخیره قابل دسترس آب شیرین در کره زمین را در مناطقی که منابع آب سطحی محدود بوده و یا به راحتی در دسترس نیستند، تشکیل می‌دهند. برداشت بی‌رویه منابع آب زیرزمینی باعث شده است که کیفیت منابع آب زیرزمینی از بین برود و این منابع با گذشت زمان شورتر شوند. در این راستا کنترل و اندازه‌گیری پارامترهای کیفی منابع آب زیرزمینی اهمیت ویژه‌ای دارد. کاربرد سیستم‌های خبره و هوش مصنوعی در مطالعات علوم آب بسیار گسترده است. در پیش‌بینی نوسانات سطح ایستایی با استفاده از سیستم خبره می‌توان به پژوهش‌های ایزدی و همکاران همچنین خاشعی سیوکی و همکاران اشاره کرد که با استفاده از شبکه عصبی مصنوعی^۱ به پیش‌بینی سطح آب زیرزمینی در دشت نیشابور پرداختند و بهترین مدل به دست آمده را ارائه دادند [۱ و ۲]. پژوهش‌هایی که سامانی و همکاران انجام داده‌اند به توانایی شبکه‌های عصبی مصنوعی در پیش‌بینی پارامترهای آبخوان، مانند ضریب انتقال و آبدهی و ویژه اشاره دارد [۳]. در پژوهش‌های دیگری، سطح آب زیرزمینی پیش‌بینی شده است [۴-۸].

آفندی و وطن‌آبه با استفاده از داده‌های روزانه سطح آب، افت آب زیرزمینی را کنترل کرده‌اند [۹]. آنها با استفاده از مدل‌های کرنل پایه‌ای شعاعی^۲، شبکه استنتاج عصبی فازی^۳ و LM سطح آب را بر اساس تأخیر زمانی از یک تا هفت روز بررسی کردند. میرعربی و نخعی دقت سیستم شبکه عصبی مصنوعی را در پیش‌بینی نوسانات سطح آب زیرزمینی، بر اساس اطلاعات پیرومتری در دشت بیرجند بررسی کردند و نتیجه گرفتند که با وارد کردن میزان بارندگی و برداشت با تأخیر زمانی دو ماهه، دقت شبکه افزایش می‌یابد. آنها از برداشت و بارندگی کل دشت، به عنوان ورودی مدل استفاده کردند. در حالی که میزان بارندگی و تخلیه در قسمت‌های مختلف دشت با هم متفاوت است و تأثیر بسزایی بر نوسانات سطح آب دارد [۱۰]. پژوهش‌های متعددی، مانند پژوهش محتشم و همکاران، در مورد کاربرد مدل‌های شبکه عصبی در پیش‌بینی سطح آب زیرزمینی کم‌عمق، با استفاده از پارامترهای هواشناسی و هیدروژئولوژی وجود دارد [۱۱].

کیسی در سال ۲۰۱۲، دقت مدل حداقل مربعات ماشین بردار پشتیبان^۴ را در مدل‌سازی تبخیر و تعرق مرجع در جنوب منطقه کالیفرنیا بررسی کرد [۱۲]. در ادامه مطالعه، نتایج با مدل‌های تجربی

^۱ Artificial Neural Network (ANN)

^۲ Radial Basis Function (RBF)

^۳ Adaptive Neuro-Fuzzy Inference System (ANFIS)

^۴ Least Square Support Vector Machines (LS-SVM)

^۵ Support Vector Machin (SVM)

^۶ Kriging

سطحی در دشت حران^۱ ارائه کردند [۱۹]. پارامترهای قابل اندازه‌گیری از قبیل دما، هدایت الکتریکی، سطح آب‌های زیرزمینی و pH به‌عنوان پارامترهای ورودی در پیش‌بینی نیترات در مدل ANN استفاده می‌شود. بهترین الگوریتم انتشار به عقب^۲ و تعداد نورون‌ها، برای بهینه‌سازی ساختار مدل مشخص شدند. الگوریتم لونیبرگ-مارکوارت^۳ به‌عنوان بهترین الگوریتم‌های ۱۲ BP و تعداد نورون بهینه تا ۲۵ انتخاب شد.

دقت روش‌های درونیابی، برای پیش‌بینی مکانی ویژگی‌های خاک و آب در مطالعات مختلفی تحلیل شده است. پایه این روش در مطالعات احمدی و همکاران یافت می‌شود [۲۰ و ۲۱]. صفری از روش کریجینگ برای برآورد پیش‌بینی مکانی آب‌های زیرزمینی در دشت چمچال در غرب ایران استفاده کرد [۲۲]. نتایج نشان داد روش مناسب زمین آماری برای برآورد یک متغیر، بستگی به نوع متغیرها و عوامل منطقه‌ای دارد که تحت تأثیر این عوامل و روش انتخابی منطقه است و قابل تعمیم نیست.

رضایی و همکاران در سال ۱۳۸۶، به‌منظور بررسی تنوع مکانی برخی از عوامل مهم کیفی آب زیرزمینی از جمله EC، SAR و Na، نمونه‌هایی از ۱۳۵ حلقه چاه منطقه را در طول تابستان برداشت کردند. نتایج نشان داد مدل کروی، بهترین روش برای شبیه‌سازی واریوگرام‌ها است [۲۳].

پژوهش‌های کمی در زمینه قابلیت مدل‌های حداقل مربعات ماشین بردار پشتیبان برای پیش‌بینی پارامترهای مکانی انجام شده است. با توجه به اهمیت مدل‌های پیش‌بینی مکانی کیفیت آب‌های زیرزمینی، توجه به تفاوت‌های احتمالی بین پرسپترون چند لایه^۴ و LS-SVM و مدل‌های زمین آماری در آب و هوای خشک و نیمه‌خشک ضروری است. تاکنون روش‌های زمین آماری یکی از مهم‌ترین روش‌ها محسوب می‌شود که با استفاده از آنها ضمن تعیین ساختار مکانی داده‌ها توزیع مناسبی از پارامترها مشخص می‌شود؛ اما برای این مدل‌ها همواره نیاز به تعداد داده‌های قابل ملاحظه‌ای بود تا دقت مناسبی داشته باشد.

هدف از این پژوهش، ارزیابی کارایی مدل‌های حداقل مربعات ماشین بردار پشتیبان و مدل‌های عصبی در تعیین توزیع مکانی آب‌های زیرزمینی بود. تاکنون پژوهش‌های محدودی در این راستا انجام شده است و پژوهشی که بتواند این مدل‌ها را برای توزیع مکانی پارامترهای کیفی آب زیرزمینی انجام دهد و توانایی آن را با روش‌های مختلف زمین آماری مقایسه کند، صورت نگرفته است.

اهداف این پژوهش عبارت بودند از: ۱- ارزیابی مدل‌های MLP و LS-SVM برای پیش‌بینی مکانی کیفیت آب‌های زیرزمینی در آب و هوای خشک و نیمه‌خشک، با استفاده از داده‌های UTM، ۲- مقایسه نتایج به‌دست‌آمده از مدل‌های MLP و LS-SVM با مدل‌های زمین آماری.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

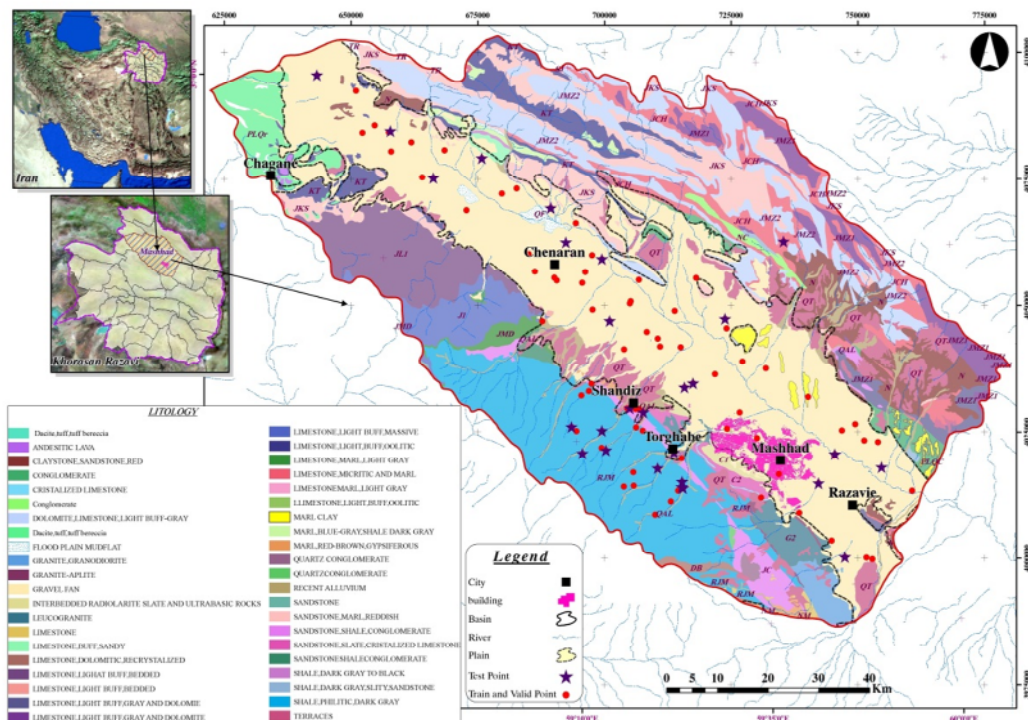
دشت مشهد با وسعت ۱۶۵۰۰ کیلومتر مربع در شمال شرق استان خراسان رضوی واقع شده است. این منطقه بین طول‌های جغرافیایی ۲۰'۵۸ تا ۸'۶۰ و عرض‌های ۴۰'۳۵ تا ۳'۳۶ ایران قرار دارد (شکل ۱). دشت مشهد از سمت شمال به ارتفاعات هزار مسجد (کپه داغ) و از جنوب به کوه‌های بینالود، همچنین از شمال غرب توسط حوضه رودخانه اترک و جنوب شرق با حوضه رودخانه جامرود محدود شده است. جهت کشیدگی هر دو رشته کوه از شمال غرب به جنوب شرق است. به سمت جنوب شرق شیب ملایم زمین دشت را شکل داده است. قله بینالود، مرتفع‌ترین نقطه با ارتفاع ۳۳۰۰ متر از سطح دریا است که در جنوب شرق واقع شده و تنگل شور به‌عنوان خروجی حوضه، با ارتفاع ۸۸۰ متر از سطح دریا پایین‌ترین نقطه است. آب و هوای منطقه، با روش دومارتن اصلاح شده، سرد و خشک است. میانگین بارندگی ۶۲/۱ میلی‌متر و ETP ۳۴۸۳ میلی‌متر است.

داده‌های کیفی ۱۲۲ حلقه چاه این دشت در این مطالعه استفاده شد. داده‌ها توسط وزارت نیروی ایران جمع‌آوری شد. این داده‌ها از ۱ تا ۳۱ اردیبهشت ۸۸ اندازه‌گیری شده‌اند. همه داده‌ها به سه قسمت یعنی، ۶۰ درصد برای آموزش، ۱۵ درصد برای تست و سایر داده‌ها برای اعتبارسنجی، تقسیم شدند. طراحی ساختار مدل‌های MLP توسط توابع سیگموئید و لایه مخفی انجام شد. تعداد بهینه سلول‌های عصبی مخفی توسط روش آزمون و خطا انتخاب شد. همچنین تعداد توابع عضو و پارامترهای مدل نیز توسط روش آزمون و خطا تعیین شد.

در این مطالعه از مدل پیشنهادی حداقل مربعات ماشین بردار پشتیبان استفاده شد. این روش ابتدا تحت عنوان ماشین بردار پشتیبان توسط وپنیک بر پایه تئوری یادگیری آماری^۵ که از حداقل‌سازی ریسک ساختاری^۶ تبعیت می‌کند، ارائه شده است [۲۴].

⁵ Statistical Learning Theory
⁶ Structure Risk Minimization

¹ Harran
² Back Propagation (BP)
³ Levenberg-Marquardt
⁴ Multi-Layer Perceptron (MLP)



شکل ۱- منطقه مورد مطالعه و محل سایت نمونه برداری در فرایند آموزش، اعتبارسنجی و آزمون

به عنوان بردار ورودی و $y_i \in \mathbb{R}$ به عنوان بردار خروجی معرفی می شوند. تابع رگرسیون غیر خطی در مسائل تخمین به صورت رابطه ۱ است

$$y(x) = w^T \cdot \varphi(x) + b \quad (1)$$

که در این رابطه w ، b و T به ترتیب مقادیر وزن ها، بایاس تابع رگرسیون و نشان دهنده تراننده هستند. $\varphi(x)$ ترسیم غیر خطی ورودی ها در فضای ویژگی با ابعاد بالا است. حال مسئله رگرسیون غیر خطی بر اساس رابطه بهینه سازی ۲ حل می شود

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

بر اساس محدودیت

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

که در این روابط γ پارامتر تطبیق کننده بخش خطا است و e میزان خطا را نشان می دهد. حل با استفاده از شکل لاگرانژی از تابع هدف اصلی در رابطه ۴ آمده است

در واقع یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه سازی مقید است که از اصل استقرایی کمینه سازی خطای ساختاری استفاده کرده و منجر به یک جواب بهینه کلی می شود [۲۵]. این روش یک کلاس جدید از مدل هایی است که به منظور طبقه بندی و پیش بینی در علوم مختلف استفاده می شوند. SVM روشی برای طبقه بندی دوتایی در فضای ویژگی های دلخواه است و از این رو، روشی مناسب برای مسائل پیش بینی به شمار می رود. وندوال و سویکنس مدل حداقل مربعات ماشین بردار پشتیبان را معرفی کردند [۲۶]. این مدل محدودیت های یکسانی با روش SVM کلاسیک دارد، اما نسبت به این روش، پیچیدگی محاسباتی کمتر و دقت و سرعت بالاتری دارد. الگوریتم LS-SVM در دو مرحله استفاده شده است: ۱- آموزش و اعتبارسنجی و ۲- طراحی.

در این مطالعه سعی شد از روشی با تقریب دقیق کیفیت آب زیرزمینی استفاده شود تا این روش بتواند خطای پیش بینی را حداقل سازد. از مدل LS-SVM در مسائل طبقه بندی و هم مسائل رگرسیونی استفاده شد. البته در مسائل رگرسیونی به ویژه مسائل علوم آب، پژوهش های کمی صورت گرفته است. چارچوب رگرسیون حداقل مربعات ماشین بردار پشتیبان به صورت زیر توضیح داده می شود.

مجموعه داده های $\{x_i, y_i\}_{i=1}^N = 1$ وجود دارد که $x_i \in \mathbb{R}^n$

به منظور به دست آوردن پایداری مدل، مجموعه داده‌ها برای بار اول در محدوده صفر تا ۱ نرمال شدند و بعد از شبیه‌سازی با استفاده از رابطه مذکور به مقادیر اولیه برگشتند

$$X_{\text{norm}} = \left[\frac{X - X_{\min}}{X_{\max} - X_{\min}} \right] \times 0.8 + 0.1 \quad (8)$$

که در این رابطه

X مقدار اولیه، X_{\min} و X_{\max} به ترتیب مقادیر حداقل و حداکثر، X_{norm} مقدار نرمال شده و $0/1$ و $0/8$ عوامل سنجش‌اند. برای عوامل سنجش مقادیر مختلفی ممکن است تعیین شود، با این حال هیچ قانون پیشنهادی در روش استاندارد وجود ندارد که بتواند در شرایط خاص استفاده شود. در این مطالعه عوامل سنجش به ترتیب $0/1$ و $0/8$ انتخاب شدند [۸].

روش‌های میان‌یابی زمین آماری استفاده شده، در صورتی که داده‌ها دارای توزیع نرمال باشند، بهترین نتایج را می‌دهند. برای تعیین نرمال بودن یا نبودن EC آب‌های زیرزمینی، روش‌های مختلف استفاده شده است [۲۹]. هیستوگرام EC آب‌های زیرزمینی با منحنی توزیع نرمال با داده‌های تغییر نیافته و تغییر یافته به صورت لگاریتمی ترسیم شده است [۳۰]. از مجموعه داده‌های قسمت، برای آزمون و مقایسه مدل‌های MLP و LS-SVM و زمین آماری و انتخاب مدل‌های مناسب، استفاده شد. این مقایسه با استفاده از سه شاخص آماری انجام شد؛ ضریب تعیین یا R^2 ، ریشه متوسط مربعات خطا یا RMSE و متوسط مطلق خطا یا MBE.

(۹)

$$R^2 = \left[\frac{\sum_{i=1}^N (P_i - \bar{P})(O_i - \bar{O})}{\sum_{i=1}^N (P_i - \bar{P})^2 (O_i - \bar{O})^2} \right]^{-1} \quad (10)$$

$$RMSE = \left[N^{-1} \sum_{i=1}^N (P_i - O_i)^2 \right]^{0.5} \quad (11)$$

که در این رابطه N تعداد مشاهدات، P_i مقادیر برآورد شده با استفاده از MLP و LS-SVM، O_i داده‌های مشاهده شده و \bar{P} و \bar{O} به ترتیب مقادیر متوسط P_i و O_i هستند.

۳- نتایج و بحث


علی‌رغم تغییرات زیاد هدایت الکتریکی آب زیرزمینی از مکانی به مکان دیگر، همبستگی بالا بین پارامترهای مکانی وجود دارد. شکل ۳ همبستگی بین طول و عرض جغرافیایی و میزان کلر با شوری آب زیرزمینی را نشان می‌دهد. میزان شوری با افزایش طول

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

که در این رابطه

α_i ضریب لاگرانژ است. بر اساس شرایط کان-تاکر (KKT)، مدل LS-SVM نتیجه شده در شکل ۲، به منظور تابع تخمین به صورت رابطه ۵ نوشته می‌شود [۲۷]

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



شکل ۲- معماری مدل LS-SVM [۲۷]

تابع کرنل نامیده می‌شود که با تبعیت از شرایط Mercer به عنوان تابعی با ایجاد ضرب داخلی در فضای ویژگی معرفی می‌شود [۲۸]

$$i, j = 1, \dots, N \quad (6)$$

برای حل $K(x_i, x_j) = \langle \varphi(x_i), \varphi(x_j) \rangle$ تعیین پارامتر تنظیم‌کننده بخش خطا (γ) و تعیین σ کوچک‌تر از صفر پارامتر مربوط به تابع کرنل پایه‌ای شعاعی در رابطه ۷ نیاز است

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

محاسبه واریوگرام‌های تجربی و مدل‌سازی تنوع مکانی هدایت الکتریکی آب‌های زیرزمینی با استفاده از تحلیلگر زمین آمار نرم‌افزار ArcGIS 9.3 انجام شد. برای این کار از آموزش و اعتبارسنجی داده‌ها برای مدل MLP و داده‌های آزمون برای مدل زمین آماری استفاده شد. برای آزمون مدل زمین آماری، ابتدا نقشه‌های میان‌یابی هدایت الکتریکی با استفاده از نرم‌افزار ArcGIS 9.3 آماده و معادل EC در نقطه تعیین شد و با داده‌های واقعی یعنی داده‌های آزمون مقایسه شد. برای جلوگیری از بیش‌انطباقی^۱، یک معیار توقف به موقع به منظور بهبود سرعت و کارایی آموزش شبکه پذیرفته شد [۸]. دو toolbox از MLP و LS-SVM در نرم‌افزار متلب^۲ برای این پژوهش استفاده شد.




¹ Overfitting
² MATLAB

مخفی، آموزش پرسپترون چند لایه انجام شد. بعد از آموزش هر یک برای داده‌های آزمون، $RMSE$ ، R^2 ، AME محاسبه و بهترین تعداد گره مخفی هر یک از مجموعه داده‌های ورودی تعیین شد [۸]. جدول ۲ بهترین تعداد گره برای یک لایه مخفی بر روی شبکه انتخاب شده را نشان می‌دهد که در آن تعداد گره‌های ۵ و ۱۴ به ترتیب برای مدل MLP3، با ورودی X ، Y و کلر و مدل MLP2، با ورودی X و Y تعیین شد. کمترین $RMSE$ و AME به ترتیب $۳۶۷/۹$ و $۲۶۵/۷$ بود که علت آن به بیشتر بودن تعداد متغیرهای مستقل مدل MLP3 برمی‌گردد. این نتیجه با نتایج خاشعی سیوکی و همکاران که نشان دادند در مدل شبکه عصبی با افزایش تعداد ورودی دقت مدل افزایش می‌یابد، نیز مطابقت دارد [۸].

جغرافیایی افزایش و سپس کاهش می‌یابد و این مسئله دقیقاً برای عرض جغرافیایی برعکس است و این امر به موقعیت شهر مشهد در جنوب غربی دشت برمی‌گردد. رابطه EC با کلر به علت اثر کلر بر شوری آب، مستقیم است. تغییرات آماری پارامترهای مورد مطالعه در این پژوهش، در جدول ۱ ارائه شده است.

۳-۱- مدل‌های MLP

در این بخش، پارامترهای آماری برای دقت مدل MLP ارائه شده است. کولی بالی و همکاران نشان دادند که برای پدیده‌های طبیعی، یک لایه پنهان برای پیش‌بینی مسائل، کارایی مناسبی دارد [۳۱]. بنابراین در این پژوهش برای مدل MLP در شبکه عصبی مصنوعی از یک لایه پنهان استفاده شد. سپس با استفاده از ۱ تا ۵۰ گره



شکل ۳- همبستگی شوری برحسب $\mu\text{mos/cm}$ با
الف- عرض جغرافیایی (Y)، ب- طول جغرافیایی (X) و ج- میزان کلر (Cl)

جدول ۱- دامنه و خصوصیات آماری داده‌های جمع‌آوری شده

پارامترها	حداکثر	حداقل	میانگین	انحراف از معیار	ضریب تغییرات	چولگی	میان
۱ X (طول جغرافیایی)	۷۶۰۷۵۰	۶۴۳۳۰۰	۷۰۶۷۳۹	۲۷۲۶۷/۷۸	۲۵/۹۱۸۴۷	-۰/۲۲۵۶۹	۷۰۶۱۸۲/۵
۲ Y (عرض جغرافیایی)	۴۰۹۵۵۵۰	۳۹۹۹۸۲۲	۴۰۴۰۱۹۴	۲۴۴۶۶/۹۵	۱۶۵/۱۲۸۷	۰/۴۸۶۲۳	۴۰۳۴۱۱۳
۳ کلر (meq/lit)	۳۸	۰/۲	۴/۹۰۳۳۰۶	۷/۳۵۵۲۹۲	۰/۶۶۶۶۳۶	۲/۴۰۶۳۲۳	۱/۳
۴ EC ($\mu\text{mos/cm}$)	۵۸۹۰	۱۶۹	۱۴۲۱/۸۹۴	۱۳۳۳/۲۶۶	۱/۰۶۶۴۷۴	۱/۴۱۴۰۵۵	۸۵۱

جدول ۲- عملکرد آماری مدل MLP برای برآورد شوری آب زیرزمینی

نوع مدل	پارامترهای ورودی	بهترین تعداد گره مخفی	ایبوج
(MLP3)	X - Y- CL	۵	۱۸
(MLP2)	X-Y	۱۴	۴۴

۲-۳- مدل LS-SVM

در مرحله ورود داده‌ها به مدل LS-SVM، تمامی ترکیب‌های بهینه پس از نرمال‌سازی داده‌ها آزموده شدند. در قسمت آموزش برای ثابت بودن شرایط در تعیین پارامترهای تابع تخمین از روش بهینه‌سازی Simplex، Gridsearch، Linsearch، برای سه تابع کرنل انتخابی یعنی RBF، خطی و چندجمله‌ای استفاده شد. نتایج ارزیابی عملکرد آموزش و آزمایش داده‌ها در مدل LS-SVM با استفاده از شاخص‌های آماری معتبر در جدول ۳ آورده شده است. در جدول ۳ نیز مقادیر پارامترهای بهینه از جمله پارامتر γ ، آورده شده‌اند.

بر این اساس مدل حداقل مربعات ماشین بردار با سه ورودی، دقت مناسب تری نسبت به مدل LS-SVM3 دارد. بر اساس جدول ۳ در تمامی توابع صریح و بهینه این امر اتفاق افتاده است. بین توابع بهینه بهترین مدل توابع Simplex است که تابع صریح خطی از دقت مناسبی تری نسبت به دیگر توابع برخوردار است؛ یعنی RMSE برابر $354/5$ و R^2 برابر $0/967$.

مدل LS-SVM2 با همان تابع Simplex و تابع صریح خطی، کمترین دقت را در برآورد کیفیت آب زیرزمینی دارد. بر اساس شکل ۴ به وضوح دریافت می‌شود که مقادیر شوری آب زیرزمینی مدل ۳ ورودی نسبت به مدل‌هایی با ۲ ورودی تطابق بیشتری با داده‌های مشاهده‌ای دارند. با توجه به رابطه انطباق داده شده $Y=a+bx$ ضرایب a و b برای مدل‌های ۳ ورودی به ترتیب به صفر و ۱ انطباق بیشتری دارند.

۳-۳- مدل‌های زمین آماری

کارایی شش مدل دایره‌ای، کروی، پایدار، نمایی و گوسین بر طبق روش اعتبارسنجی متقابل مقایسه شد. نتایج نشان داد که شش مدل مذکور از کارایی نسبتاً مناسبی برخوردار بودند. ریشه میانگین استاندارد خطاها در مدل کروی به ۱ نزدیک‌تر و از بقیه بهتر بود.

مدل تطبیقی به واریوگرام تجربی مدل کروی بود که این مطلب از اعتبارسنجی متقابل، اثر قطعه‌ای استنتاج می‌شود. اگر اثر قطعه‌ای کمتر از $0/25$ باشد، می‌توان گفت که وابستگی مکانی شدیدی وجود دارد و اگر بین $0/25$ تا $0/75$ باشد، وابستگی مکانی نسبی و متعادل وجود دارد. بر این اساس نتیجه گرفته می‌شود مدل کروی دارای وابستگی مکانی بالایی است [۳۲].

در این مطالعه نسبت اثر قطعه‌ای، نشان از وجود وابستگی مکانی شدید $0/36$ برای مدل کروی بود. مدل نیمه‌تغییرنا و پارامترهای زمین آماری در جدول ۴ نشان داده شد. رضایی و همکاران تأیید کردند که مدل کروی بهترین نتیجه را به شبیه‌سازی واریوگرام شوری آب زیرزمینی ارائه می‌دهد [۲۳].

در مطالعه حاضر از روش کریجینگ معمولی و کوکریجینگ^۱ برای برآورد شوری آب زیرزمینی استفاده شد. کوکریجینگ شبیه به کریجینگ است و به منظور بهتر کردن برآورد و کاهش واریانس برآورد، یک زیرنمونه متغیر دیگر که وابستگی زیادی به نمونه مورد مطالعه دارد، استفاده می‌کند. در این مطالعه از پارامتر کلر برای این امر استفاده شد (شکل ۴).

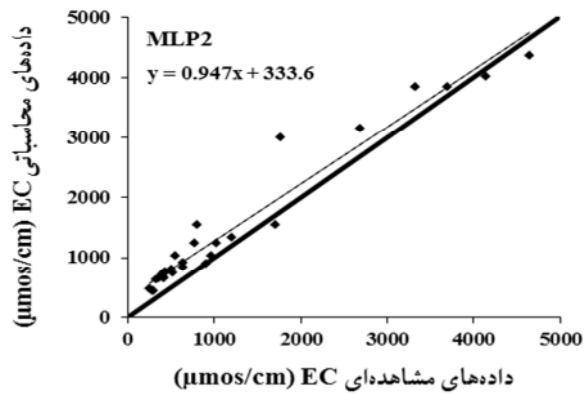
نتایج جدول‌های ۴ و ۵ نشان داد که دقت مدل کوکریجینگ از مدل کریجینگ بیشتر است. این نتایج با نتایج داکستینو و همکاران مطابقت دارد. آنها ثابت کردند شیوه کوکریجینگ در افزایش دقت برآورد غلظت نترات دستاورد بهتری دارد [۳۳]. ریزو و موسر ثابت کردند روش کوکریجینگ به منظور برآورد کیفیت آب زیرزمینی دقت مناسبی دارد [۳۴]. در این پژوهش میزان افزایش دقت برای پارامترهای RMSE و MAE مدل کوکریجینگ نسبت به کریجینگ به ترتیب ۱۸۵ درصد و ۹۹ درصد بود.

¹ Cokriging

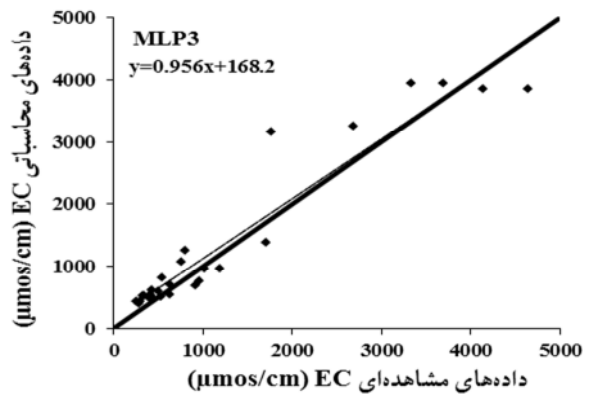
جدول ۳- عملکرد آماری مدل‌های حداقل مربعات ماشین بردار پشتیبان برای برآورد شوری

نوع ورودی	تابع صریح	تابع بهینه	R^2	RMSE	MAE	گاما
LS-SVM2	RBF	simplex	$0/678$	$739/78$	$540/01$	$4/33$
LS-SVM3	*RBF	simplex	$0/949$	$393/67$	$307/34$	$44/52$
LS-SVM3	Polynomial	simplex	$0/641$	$1096/2$	$605/06$	$123/46$
LS-SVM2	**Polynomial	simplex	$0/623$	$789/54$	$579/33$	$0/098$
LS-SVM2	***Linear	simplex	$0/079$	$1203/36$	$938/56$	$1/44$
LS-SVM3	Linear	simplex	$0/967$	$351/81$	$305/28$	$0/23$
LS-SVM3	Linear	linsearch	$0/967$	$354/50$	$305/79$	$0/308$
LS-SVM3	RBF	gridsearch	$0/948$	$392/79$	$308/51$	$342/24$

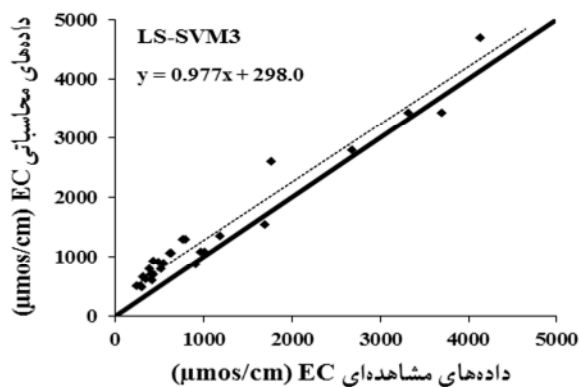
*کرنل پایه‌ای شعاعی، **کرنل چندجمله‌ای، ***کرنل خطی



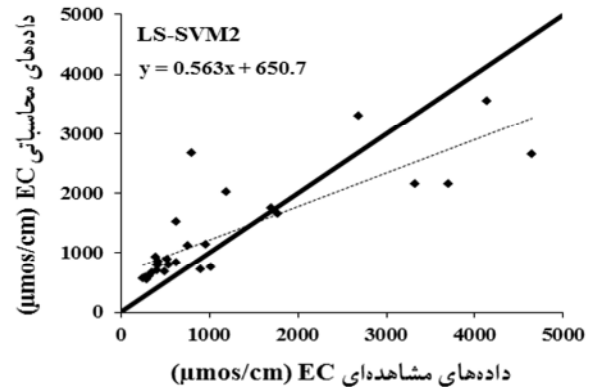
(ب)



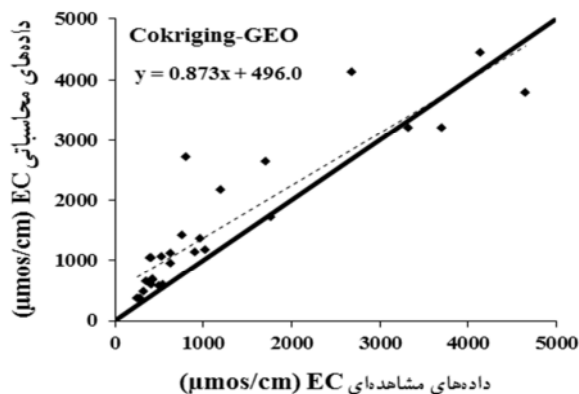
(الف)



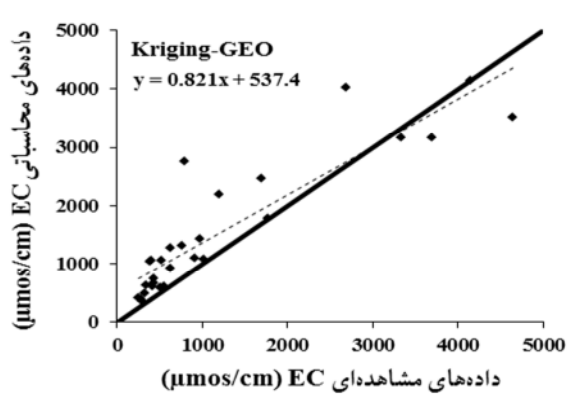
(د)



(ج)



(و)



(ه)

شکل ۴- نمودار پراکنش مقادیر مشاهده شده در برابر مقادیر برآورد شده از ضریب هدایت الکتریکی آب زیرزمینی برای مجموعه داده‌های تست برای MLP2 و MLP3 و LS-SVM2 و LS-SVM3 و مدل‌های کوکریجینگ، برای متغیرهای مستقل (X و Y) و کالر). خط ضخیم نشان رگرسیون و خط نازک نشان بهترین خط برازش شده برای شوری مشاهده شده (محور X) و محاسبه شده (محور Y)

جدول ۴- پارامترهای نیم‌واریوگرام برای شوری آب زیرزمینی در مدل کوریجینگ

خطای پیش‌بینی		نیم‌تغییرنما		مدل زمین آماری	
RMSS	RMSE	آستانه	Lag size	اثر قطعه	کوریجینگ معمولی
۰/۷۴۵۱	۱۱۶۸	۱/۰۷۸	۹۲۸۷/۵	۰/۰۴۲۱۷۲	دایره‌ای
۰/۷۴۶۷	۱۱۸۳	۱/۰۹۶۴	۹۲۸۷/۵	۰/۰۳۶۳۶۱	کروی
۰/۷۳۹۶	۱۱۹۶	۱/۱۱۰۴	۹۲۸۷/۵	۰	مدل نمایی
-۰/۰۰۶۶۳	-۲۸/۸۹	۱/۰۷۸۲	۹۲۸۷/۵	۰/۱۶۱۲۳	گوسین
-۰/۰۱۰۲۱	-۷/۹۵۴	۱/۳۵۲۲	۹۲۸۷/۵	۰/۱۵۳۵۹	ثابت

جدول ۵- پارامترهای نیم‌واریوگرام برای شوری آب زیرزمینی در مدل کوکریجینگ

مدل زمین آماری		نیم‌تغییرنما		خطای پیش‌بینی	
کریجینگ معمولی	اثر قطعه	Lag size	آستانه	RMSE	RMSS
دایره‌ای	۰/۰۴۰۳۳	۷۳۸۸/۶	۰/۸۴۸۳۸	۴۳۲/۴	۰/۴۲۸۳
کروی	۰/۰۳۳۷۲۲	۷۳۸۸/۶	۰/۸۶۰۱۶	۴۴۵	۰/۴۳۱۳
مدل نمایی	۰	۷۳۸۸/۶	۱/۰۱۸	۷۱۲/۳	۰/۴۹۸۱
گوسین	۰/۱۵۰۳۶	۷۳۸۸/۶	۰/۴۹۱۸۶	۷۴۱	۰/۷۵۸۶
ثابت	۰/۱۵۰۳۸	۷۳۸۸/۶	۰/۵۵۸۸۲	۸۶۵	۰/۷۶۰۲

جدول ۶- عملکرد آماری مدل‌ها از مدل‌های LS-SVM و MLP و زمین آماری برای برآورد شوری آب زیرزمینی

مدل	R ²	RMSE(μmos/cm)	MAE(μmos/cm)
MLP3	۰/۹۳	۳۶۷/۹۸	۲۶۵/۷۵
MLP2	۰/۹۳	۳۶۹/۸۳	۲۶۷/۰۳
COKRIGING	۰/۸۲	۳۴۳/۳۷	۴۵۲/۹
LS-SVM2	۰/۶۷	۷۳۹/۷۸	۵۴۰/۰۱
KRIGING	۰/۸۰	۶۳۵/۵۵	۴۵۰/۰۷
LS-SVM3	۰/۹۶	۳۵۴/۵۰	۳۰۵/۷۹

پرداختند. مطابقت دارد [۱۷].

قابل ذکر است که کوکریجینگ قابلیت برآورد کردن خطاهای متداول را دارد و از برآورد آن می‌توان در پیدا کردن الگوی بهینه و توسعه دادن شبکه مشاهداتی استفاده کرد. این یک مزیت خاص کوکریجینگ نسبت به بقیه روش‌های درون‌یابی است [۱۸].

بدیهی است که مدل‌های سه پارامتری محاسبه شده، بهتر از مدل‌های دو پارامتری برای مدل‌های LS-SVM و MLP جواب دادند و مدل دو پارامتری در MLP پیش محاسبه شده، نتایج بهتری نسبت به دیگر مدل‌ها داشت (شکل ۴).

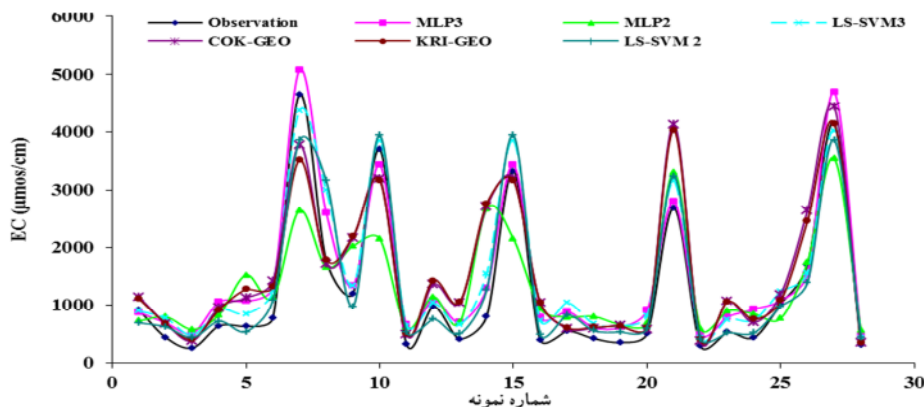
بهترین مدل LS-SVM مدل سه ورودی بود. X و Y و نقاط جغرافیایی پارامترهای مؤثری هستند که در دسترس اند. برای دو پارامتر X و Y سیستم هوشمند نتایج بهتری از مدل‌های زمین آماری داشت؛ اما مدل LS-SVM نتیجه ضعیفی در مقایسه با مدل کریجینگ داشت. نتایج کاربرد مدل‌های غیرخطی و مقایسه آنها با مدل‌های زمین آماری در شکل ۵ نشان داده شده است.

۳-۴- مقایسه نتایج مدل‌های زمین آماری با مدل‌های MLP و

LS-SVM

نمودار پراکنش داده‌های به دست آمده و مقادیر پیش‌بینی شده و بهترین خط برازش در شکل ۴ آورده شده است. نتایج نشان می‌دهد دقت مدل MLP3 بهتر از مدل‌های LS-SVM و کوکریجینگ است. MLP3 بهترین دقت را با ورودی‌های X و Y و CL دارد.

جدول ۶ حاکی از قابلیت پایین پیش‌بینی مدل کوکریجینگ در مقایسه با مدل LS-SVM3 با تعداد لایه‌های ورودی یکسان است. با توجه به نتایج جدول ۳ می‌توان دید در اکثر موارد تابع خطی بهتر از مدل با تابع RBF و مدل با تابع چندجمله‌ای بوده است. در این میان نیز تابع RBF نسبت به تابع کرنل چندجمله‌ای برتری داشته است. این نتایج دربرگیرنده این مطلب هستند که نوع تابع کرنل بهینه برای مجموعه داده‌های مختلف به ماهیت و نوع داده‌ها بستگی دارد. پس در هر پژوهشی، آزمون تمامی توابع کرنل ضرورت خواهد داشت. این نتایج با نتایج رضایی که به بررسی کاربرد روش LS-SVM در بهینه‌سازی شبکه پایش پیژومترهای دشت بیرجند



شکل ۵- اجرای نتایج مدل‌های MLP، LS-SVM و زمین آماری

۴- نتیجه‌گیری

می‌توان نتیجه گرفت مدل MLP قابلیت برآورد دقیق شوری آب زیرزمینی را دارد.

بسیاری از مطالعات پژوهشی که تاکنون منتشر شده، به تعداد مدل‌های غیرخطی محدود شده و یا برای کیفیت آب زیرزمینی استفاده نشده است، بنابراین در این پژوهش مدل‌های مختلف غیرخطی هوشمند، برای برآورد کیفیت آب زیرزمینی استفاده شد و با مدل‌های زمین آماری مقایسه شدند که می‌تواند یک منبع با ارزش اطلاعاتی برای دیگر پژوهشگران باشد.

این پژوهش چندین مدل را به منظور برآورد ضریب هدایت الکتریکی با استفاده از مجموعه داده‌های طول و عرض جغرافیایی برای آبخوان دشت مشهد که در آب و هوای خشک و نیمه‌خشک موجود است، تحلیل می‌کند. در این مطالعه از نمونه‌گیری نقطه‌ای X و Y که به ترتیب طول و عرض جغرافیایی‌اند و متغیر کلر به علت داشتن همبستگی مناسب با ضریب هدایت الکتریکی استفاده شد. مقایسه مدل‌های مورد مطالعه با مدل‌های زمین آماری نشان داد که عملکرد مدل LS-SVM از کوکریجینگ بهتر بود. به طور کلی

۵- مراجع

1. Izadi, S.A., Davari, K., Alizadeh, A., and Ghahraman, B. (2007). "Using artificial neural network to predict the water table." *J. of Irrigation and Drainage*, 2, 59-71
2. Khashei-Siuki, A., Kouchakzadeh, M., and Ghahraman, B., (2013). "Comparison of artificial neural network models, ANFIS and regression estimation of shallow aquifer in Nishapur." *J. of Irrigation and Drainage*, 2, 59-71. (In Persian)
3. Samani, N., Gohari-Moghadam, M., and Safavi, A.A. (2007). "A simple neural network model for the determination of aquifer parameters." *J. of Hydrology*, 340, 1-11.
4. Nayak, P., Satyaji Rao, Y.R., and Sudheer, K. P. (2006). "Groundwater level forecasting in a shallow aquifer using artificial neural network approach." *J. of Water Resources Management*, 2(1)77-99.
5. Marsily, G.D., and Ahmed, S. (1987). "Application of kriging techniques in groundwater hydrology." *J. of the Geological Society of India*, 29(1), 57-79.
6. Sreekanth, P.D., Geethanjali, N.D., Sreedevi, P.D., Shakeel, A., and Steyl, G. (2009). "Application of artificial neural networks in the field of geohydrology." Institute of Groundwater Studies Faculty of Natural and Agricultural Sciences, University of the Free State.
7. Ahmad-Zadeh, K. (2009). "Modeling daily reference evapotranspiration by using neural-fuzzy inference system." MSc Thesis, Drainage and Irrigation, Faculty of Agriculture, Tarbiat Modarres University, Tehran.
8. Khashei-Siuki, A., Kouchakzadeh, M., and Ghahraman, B. (2011). "Predicting dryland wheat yield from meteorological data using expert system in Khorasan province, I.R. Iran." *J. of Agricultural Science and Technology*, 13, 627-640. (In Persian)
9. Affandi, A., and Watanabe, K. (2007). "Daily groundwater level fluctuation forecasting using soft computing technique." *J. of Nature and Science*, 5(2), 1-10.
10. Meir-Araby, M., and Nakhaei, A. (2008). "Prediction of groundwater level fluctuations smoking using artificial neural networks." *Proceedings of the Twelfth Symposium of Geological Society of Iran*, South Oil Company, Ahvaz. (In Persian)
11. Mohtasham, M., Dehghani, A., Akbarpour, A., Meftah holghi, and Etebari, B. (2010). "Prediction table using Artificial Neural Network (Case Study: Plain smoking)." *J. of Irrigation and Drainage*, 1(4), 1-9. (In Persian)
12. Kisi, O. (2012). "Least squares support vector machine for modeling daily reference evapotranspiration." *Irrig. Sci.*, 31(4), 611-619.
13. Seifi, A., and Riahi-Madvar, H. (2012). "Input variable selection in expert systems based on hybrid gamma test-least square support vector machine ANFIS and ANN models." *Provisional chapter. Intech*, doi: 10.5772/51210.
14. Asefa, T.W., Kemblowski, M., Urroz, G., Mckee, M., and Khalil, A. (2004). "Support vectors machines (SVM) for monitoring network design." *J. of Groundwater*, 43(3), 413-422.

15. Asefa, T.W., Kembrowski, M., Urroz, G., Mckee, M., and Khalil, A. (2005). "Support vectors-based groundwater head observation networks design." *J. of Water Resources Research*, 40(11), doi: 1029/2004 WR003304.
16. ESMI-Khani, M., Safavid, H., and Yazdanipour, M. (2010). "Integrated management of surface water and groundwater methods using support vector machine and genetic algorithms." *The Fifth National Congress on Civil Engineering*, Mashhad, Iran.
17. Rezaie, E. (2013). "Design piezometric well groundwater withdrawals using support vector machine." MSc Thesis Department of Water Resources and Water Engineering, University of Birjand, Birjand.
18. Kholghi, M., and Hosseini, S.M. (2009). "Comparison of groundwater level estimation using neuro-fuzzy and ordinary kriging." *J. of Environ. Model. Assess.*, 14, 729-737.
19. Sahinkaya, E., Muhsin, N., and Ozkaya, B. (2008). "Neural network prediction of nitrate in groundwater of Harran Plain, Turkey M. Irfan Yesilnacar." *J. of Environ. Geol.*, 56, 19-25.
20. Ahmadi, S.H., and Sedghamiz, A. (2007). "Geostatistical analysis of spatial and temporal variations of groundwater level." *J. of Environ. Monit. Assess.*, 129, 277-294.
21. Taghizadeh, M., Zareian Jahromi, M., Mahmodi, Sh., and Heidari, A. (2008). "Spatial distribution of groundwater quality with geostatistics (Case study: Yazd-Ardakan plain)." *World Applied Sciences Journal*, 4(1), 9-17.
22. Safari, M. (2001). "Determination of water filtration using geostatistical Network." MSc Thesis, Faculty of Agriculture, Tarbiat Modarres University, Tehran, Iran. (In Persian)
23. Rezaei, M., Davatgar, N., Tajdari, K., and Abolpour, B. (2010). "Investigation the spatial variability of some important groundwater quality factors in Guilan, Iran." *J. of Water and Soil*, 24(5), 932-941 (In Persian).
24. Vapnic, V.N. (1998). *Statistical learning theory*, Wiley, New York.
25. Cristianini, N., and Shawe-Taylor, J. (2000). *An introduction to support vector machines*, Cambridge University Press, UK.
26. Vandewalle, J., and Suykens, J.A.K. (1999). "Least squares support vector machine classifiers." *J. of Neural Processing Letters*, 9(3), 293-300.
27. Mellit, A., Massi Pavan, A., and Benghanem, M. (2013). "Least squares support vector machine for short-term prediction of meteorological time series." *J. of Theor. Appl. Climatol.*, 111, 297-307.
28. Saifi, A. (2010). "Development of an expert system to predict daily reference evapotranspiration by using Support Vector Machine (SVM) and compare its results with ANFIS, ANN and experimental methods." MSc Thesis Irrigation and Drainage Engineering, Faculty of Agriculture, Tarbiat Modarres University, Tehran. (In Persian)
29. Kardan Moghaddam, H., and Khashe-Siuki, A. (2013). *Zoning in the water sciences by geostatistics*, Astan Qods Press, Mashhad. (In Persian)
30. Gundogdu, K.S., and Guney, I. (2007). "Spatial analyses of groundwater levels using universal kriging." *J. of Earth System Science*, 116(1), 49-55.
31. Coulibaly, P. Anctil, F., and Bobee, B. (1999) "Provision hydrologique par reseaux de neurons artificiels." *Can. J. Civil Eng.*, 26(3), 293-304.
32. Dagostino, V., Greene, E.A., Passarella, G., and Vurro, M. (1998). "Spatial and temporal study of nitrate concentration in groundwater by means of co regionalization." *J. of Environmental Geology*, 36, 285-295.
33. Mouser, J.M., and Rizzo, D.M. (2000). "Evaluation of geostatistics for combined hydrochemistry and microbial community fingerprinting at a waste disposal site." <<ascelibrary. Org/doi/pdf/10.1061/40737 (2004) 106>> (Apr. 2014)
34. Khashei-Siuki, A., and Sarbazi, M. (2014). Evaluation of ANFIS, ANN, and geostatistical models to spatial distribution of groundwater quality (case study: Mashhad plain in Iran)." Saudi Society for Geosciences. Doi: 10.1007/s12517-013-1179-8