

تخمین پارامترهای کیفی آب خوان دشت گیلان با استفاده از آزمون گاما و مدل- های ماشین بردار پشتیبان و شبکه عصبی مصنوعی

محمد عیسی زاده^۱

سید مصطفی بی آزار^{۲*}

seyedmostafa.b@gmail.com

افشین اشرف زاده^۳

رضوان خانجانی^۴

تاریخ پذیرش: ۹۵/۱۰/۱۵

تاریخ دریافت: ۹۵/۰۷/۱۳

چکیده

زمینه و هدف: اطلاع از نحوه توزیع پارامترهای کیفی و کمی از مهم ترین پارامترهای اولیه مدیریت جامع منابع آب زیرزمینی می باشد. بنابراین در این تحقیق سعی گردید، مدل و ترکیب ورودی مناسب جهت تخمین پارامترهای کیفی هدایت الکتریکی (EC)، یون کلسیم (Ca) و یون سدیم (Na) آبخوان های دشت گیلان تعیین گردد.

روش بررسی: در این تحقیق از داده های ۱۳۲ چاهک مشاهداتی در دوره آماری ۱۳۸۱ تا ۱۳۹۳ و مدل های شبکه عصبی مصنوعی (ANN) و ماشین بردار پشتیبان (SVM) استفاده گردیده است. در رویکرد اول، تخمین ها به ازای پنج ترکیب مختلف حاصل از پارامترهای تراز آب، فاصله از دریا، مجموع بارش های شش ماه و مختصات چاهک های مشاهداتی انجام گرفته است. در رویکرد دوم، تخمین ها براساس ترکیب پارامترهای کیفی منتخب آزمون گاما با ترکیب های ورودی برتر بخش اول صورت گرفته است.

یافته ها: مقایسه نتایج بخش اول نشان داد که مدل SVM در تخمین هر یک از پارامترهای Na، Ca، EC عملکرد بهتری نسبت به مدل ANN داشته است. مقادیر خطای ماشین بردار پشتیبان برای تخمین متغیرهای Na، Ca و EC در دوره تست به ترتیب برابر با $1/218$ (meq/l)، $0/867$ (meq/l) و $175/742$ ($\mu\text{mos/cm}$) بوده است و این مقادیر برای مدل شبکه عصبی مصنوعی به ترتیب برابر با $1/268$ (meq/l)، $0/933$ (meq/l) و $186/448$ ($\mu\text{mos/cm}$) می باشد. نتایج این بخش نشان داد اضافه شدن ورودی فاصله از دریا

۱- دکتری رشته مهندسی منابع آب دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران.

۲- دکتری رشته علوم و مهندسی آب -منابع آب، دانشکده کشاورزی دانشگاه تبریز، تبریز، ایران. *مسئول مکاتبات

۳- استادیار گروه مهندسی منابع آب دانشکده کشاورزی، دانشگاه گیلان، گیلان، ایران.

۴- کارشناسی ارشد، مدیریت دولتی دانشگاه پیام نور گیلان، گیلان، ایران.

در کلیه موارد باعث بهبود نتایج مدل‌ها گردیده است. در بخش دوم با استفاده از آزمون گاما از بین نه پارامتر کیفی اندازه‌گیری شده، بهترین ترکیب پارامترهای کیفی برای تخمین هر یک سه پارامتر Na، Ca و EC تعیین گردید. نتایج تخمین‌ها در بخش دوم نشان داد که هر یک از دو مدل ANN و SVM عملکرد بسیار مناسبی در تخمین هر سه پارامتر کیفی داشته‌اند. مقدار خطای مدل ANN برای متغیرهای Na، Ca و EC در دوره صحت‌سنجی به ترتیب برابر با ۰/۶۶۲ (meq/l)، ۰/۳۰۵ (meq/l) و ۴۷/۳۴۶ ($\mu\text{mos/cm}$) بوده است و این مقادیر برای مدل SVM به ترتیب برابر با ۰/۶۷۱ (meq/l)، ۰/۳۵۶ (meq/l) و ۵۵/۴۱۲ ($\mu\text{mos/cm}$) می‌باشد. البته در این بخش نتایج مدل ANN نسبت به مدل SVM بهتر بوده است.

بحث و نتیجه‌گیری: نتایج نشان داد که هر یک از دو مدل SVM و ANN توانایی بسیار زیادی در تخمین پارامترهای کیفی آب‌خوان‌ها دارند. همچنین عملکرد مدل SVM نسبت به مدل ANN، به‌ازای تعداد ورودی کمتر بهتر است و در تعداد ورودی بیشتر برعکس می‌باشد. نتایج بخش دوم نشان داد که آزمون گاما می‌تواند به‌صورت کاملاً کابردی و دقیق در تعیین ترکیب‌های ورودی موثر مورد استفاده قرار گیرد.

واژه‌های کلیدی: آزمون گاما، تخمین پارامترهای کیفی، دشت گیلان، شبکه عصبی مصنوعی، ماشین بردار پشتیبان.

Estimation of Aquifer Qualitative Parameters in Guilans Plain Using Gamma Test and Support Vector Machine and Artificial Neural Network Models

Mohammad Isazadeh ¹

Seyed Mostafa Biazar ^{2*}

seyedmostafa.b@gmail.com

Afshin Ashrafzadeh ³

Rezvan Khanjani ⁴

Admission Date: January 4, 2017

Data Received: October 4, 2016

Abstract

Background and Objective: Having information about qualitative and quantitative parameters distribution of groundwater supplies is one of most important parameters in integrated groundwater management. Thus, in this study it has been attempted to determine a proper model and input combination for estimation of quality parameters including electrical conductivity (EC), calcium (Ca) and sodium (Na) ions in aquifers of Guilans plain.

Method: In this study, the data from 132 observation wells during 2001 to 2013 were used and artificial neural network (ANN) and support vector model (SVM) were applied. In the first approach, estimations were conducted according to five different combinations, including water level, distance from sea, total precipitation of six months and coordinates of observation wells. In the second approach, estimations were conducted based on combination of the selected qualitative parameters of gamma test with combinations of the best input in the first part.

Findings: Comparison of the results from the first part indicated that SVM model outperformed the ANN mode in the estimation of Ca, Na and EC parameters. Support vector machine error values for estimating Ca, Na and EC variables at the test period were 1.218 (meq/l), 0.867 (meq/l), and 175.742 ($\mu\text{mos/cm}$), while for artificial neural network these values were 1.268 (meq/l), 0.933 (meq/l), and 186/448 ($\mu\text{mos/cm}$) respectively. The results from this part showed that adding the distance from sea input improves the estimation of models in all cases. In the second part, using gamma test for measuring the nine quality parameters, the best combination of quality parameters was determined to estimate the three parameters: Ca, Na and EC. The results from the second part show that both ANN and SVM models have an excellent performance in the estimation of the three qualitative parameters. ANN model error values in estimating Ca, Na and EC variables in validation period were 0.662

1- PhD of Water Resources Engineering, Faculty of Agriculture of Tabriz University, East Azerbaijan, Tabriz, Iran.

2- PhD of Water Resources Engineering, Faculty of Agriculture of Tabriz University, East Azerbaijan, Tabriz, Iran.

* (Corresponding Author)

3- Assistant Professor of Water Resources Engineering, Faculty of Agriculture of Guilan University, Rasht, Iran.

4- Master of Public Management, Guilan Payam Nour University, Rasht, Guilan, Iran.

(meq/l), 0.305(meq/l), and 47.346 ($\mu\text{mos/cm}$), while these values were 0.671 (meq/l), 0.356 (meq/l), and 55.412 ($\mu\text{mos/cm}$) for SVM model respectively. Obviously, the results from ANN model in this section were better than those from SVM model.

Discussion and Conclusion: Results showed that both ANN and SVM models have a great ability in predicting qualitative parameters in the aquifers. Also, in less inputs, the results of SVM model are better than those of ANN model and in more inputs it is vice versa. Results of the second section showed that gamma test is fully practical and accurate in determining the effective input combinations.

Keywords: Artificial Neural Network, Gamma Test, Guilan Plains, Qualitative Parameters Prediction, Support Vector Machine.

مقدمه

غلامی و جعفری (۴) در پژوهشی با استفاده از روش رگرسیون خطی چند گانه (MLR) و شبکه عصبی مصنوعی (ANN) شوری آب زیرزمینی سواحل استان مازندران را شبیه‌سازی کردند. نتایج بدست آمده از هر دو روش نشان داد که عوامل نوع تشکیلات آب‌خوان، فاصله از دریا و شوری آب‌های سطحی از عوامل اصلی میزان شوری آب زیرزمینی می‌باشند. البته کارایی شبکه عصبی مصنوعی در برآورد شوری آب زیرزمینی مناسب‌تر از روش رگرسیون خطی چند گانه بوده است. مهردادی و همکاران (۵) تغییرات رسانایی الکتریکی در آب زیرزمینی شهر تهران را با کمک مدل شبکه عصبی مصنوعی پیش‌بینی نموده‌اند. آن‌ها جهت بررسی کیفیت آب زیرزمینی از داده‌های هیدروشیمیایی ۱۰ ساله مربوط به ۷۱ نقطه مختلف شهر تهران استفاده نموده‌اند. نتایج نشان دهنده عملکرد مناسب مدل شبکه عصبی مصنوعی بوده است. میرزاوند و همکاران (۶) تغییرات کیفی آب‌زیرزمینی را با مدل شبکه عصبی مصنوعی در آبخوان کاشان مورد بررسی قرار دادند. متغیرهای ورودی مدل شامل تراز سطح ایستابی، ارتفاع بارندگی سالیانه و غلظت کلر در سال قبل و متغیر خروجی مدل، غلظت کلر در سال جاری بوده است. نتایج نشان داد که مدل شبکه عصبی پرسپترون چند لایه (MLP) نسبت به مدل تابع پایه شعاعی (RBF) نتیجه بهتری در پیش‌بینی غلظت کلر داشته است. ندیری و همکاران (۷) با استفاده از مدل‌های هوش مصنوعی مرکب نظارت شده، سطح آب زیرزمینی دشت مشکین شهر را مورد بررسی قرار دادند. در این تحقیق از چهار مدل شبکه عصبی پیش‌رو، شبکه عصبی برگشتی، منطق فازی، ساکتو و ماشین بردار پشتیبان (SVM) برای پیش‌بینی سطح آب زیرزمینی استفاده شده است. با توجه به اینکه مدل‌های مختلف در مراحل

آب یک عنصر ضروری برای زندگی است و ما در جهانی زندگی می‌کنیم که دچار کمبود آب می‌باشد. در سراسر دنیا آب‌های سطحی و زیرزمینی نقش مهمی را در زندگی بشریت برای تامین آب با کیفیت بازی می‌کنند (۱). اکثر فعالیت‌های انسانی همچون فعالیت‌های کشاورزی، صنعتی و ... بر کیفیت آب زیرزمینی تاثیر منفی می‌گذارند. به دلیل اثرات منفی فعالیت‌های انسانی، آب‌های زیرزمینی به‌عنوان یک منبع حساس آبی شناخته شده است. بنابراین اطلاع از کمیت و کیفیت این آب‌ها در مدیریت و مهندسی منابع آب و همچنین توزیع آب شهری، روستایی، صنعت و کشاورزی بسیار مهم می‌باشد. به علت هزینه بالای احداث، بررسی و آزمایش‌های کیفی آب چاهک‌های مشاهداتی، نمی‌توان برای دستیابی به مقادیر کیفی آب‌خوان در کلیه نقاط آن چاهک مشاهداتی احداث کرد. جهت برطرف کردن این مشکل، در دهه‌های اخیر مدیران و محققان با استفاده از روش‌های ریاضی، آماری، هوشمند و ... مقادیر کمی و کیفی آب‌خوان‌ها را با دقت قابل قبولی مورد تخمین قرار می‌دهند. مدل‌سازی و تخمین پارامترهای کیفی آب‌خوان‌ها دارای فوایدی همچون کاهش هزینه، صرفه‌جویی در زمان، کاهش نیاز به آزمایشگاه و تجهیزات اندازه‌گیری، کاهش تعداد نیروهای اجرایی و فنی، تولید داده‌های مصنوعی با دقت بالا و در گستره مکانی بیشتر و بازسازی اطلاعات از دست رفته می‌باشد (۲). تاکنون مدل‌های متعددی به طور گسترده برای بررسی و حل مشکلات مربوط به کیفیت آب استفاده شده است (۳). با توجه به اینکه هر یک از این روش‌ها نتایج خاص خود را دارا هستند، تعیین روش بهتر برای تخمین هر یک از پارامترهای هدف در هر یک از آب‌خوان‌های کشور ضروری می‌باشد. این مدل‌ها می‌توانند بیشتر پارامترهای کیفی را با استفاده از پارامترهای ورودی مناسب با دقت قابل قبولی شبیه‌سازی کنند. در زمینه تخمین پارامترهای کیفی آب‌خوان‌ها در داخل و خارج از کشور مطالعات زیادی انجام گرفته است که در ادامه به بخشی از آن‌ها اشاره می‌گردد.

1- Multiple Linear Regression

2- Artificial Neural Network

3- Multilayer Perceptron Neural Network

4- Radial Basis Function

5- Forward Neural Network

6- Return Neural Networks

7- Fuzzy Logic

8- Support Vector Machine

هوش مصنوعی با نام‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان استفاده نموده‌اند. همچنین در این تحقیق تاثیر روش خوشه بندی در مدل سازی نیز مورد بررسی قرار گرفته است. در این مطالعه از داده‌های ۲۲ حلقه چاه شهرداری منطقه ساحلی غزه واقع در فلسطین استفاده شده است. طول دوره‌ی آماری داده‌ها از سال ۲۰۰۰ تا ۲۰۱۰ می‌باشد. نتایج نشان‌دهنده عملکرد خوب هر دو مدل و تاثیر مثبت خوشه‌بندی داده‌ها قبل از مدل سازی بوده است. خردپیشه و همکاران (۱۱) کیفیت آب زیرزمینی بهاباد یزد را با استفاده از شبکه عصبی مصنوعی مورد بررسی قرار دادند. در این پژوهش از شبکه عصبی مصنوعی برای تخمین پارامترهای کیفی غلظت یون کلر، غلظت یون سولفات، غلظت یون نیترات و هدایت الکتریکی استفاده شده است. نتایج نشان دهنده این موضوع بود که مدل شبکه عصبی مصنوعی در تخمین پارامترهای کلرید، هدایت الکتریکی و سولفات عملکرد مناسبی داشته است، ولی برای نیترات عملکرد این مدل مناسب نبوده است. خاکی و همکاران (۱۲) کاربرد شبکه عصبی مصنوعی و سیستم نروفازی را در تخمین کیفیت آب زیرزمینی مورد بررسی قرار دادند. در این تحقیق از شبکه عصبی مصنوعی و مدل سیستم استنتاجی عصبی- فازی تطبیقی برای پیش‌بینی مقدار هدایت الکتریکی و مجموع مواد جامد حل شده در آب به‌دست آمده از پنج ایستگاه نمونه‌برداری واقع در حوضه لنگت مالزی استفاده شده است. نتایج حاکی از عملکرد بهتر مدل سیستم استنتاجی عصبی- فازی تطبیقی بوده است. گنگ^۵ و همکاران (۱۳) عملکرد شبکه عصبی مصنوعی، ماشین بردار پشتیبان و سیستم استنتاجی فازی- عصبی تطبیقی را در پیش‌بینی سطح آب زیرزمینی در نزدیکی دریاچه اوکیچوبی فلوریدا مقایسه کردند. آن‌ها از این سه مدل برای داده‌های دو حلقه چاه استفاده کردند. داده‌های ورودی مدل‌ها شامل ده سال داده ماهانه، شامل دمای آب، سطح آب زیرزمینی، بارندگی و سطح آب رودخانه بوده است. نتایج بیانگر دقت بالای مدل‌های ماشین بردار پشتیبان و سیستم استنتاج فازی-عصبی تطبیقی نسبت به شبکه عصبی مصنوعی می‌باشد.

مختلف مدل‌سازی نتایج متفاوتی ارائه دادند و توانایی آن‌ها متفاوت بوده است، لذا جهت تقویت پیش‌بینی‌ها، از توانایی مدل‌های مختلف به‌طور همزمان استفاده گردیده است. در این روش خروجی مدل‌های منفرد به‌عنوان ورودی برای مدل مرکب استفاده شد و سطح آب زیرزمینی دوباره توسط یک شبکه عصبی مصنوعی پیش‌بینی گردید. با توجه به اینکه همه مدل‌ها توانایی پیش‌بینی سطح آب زیرزمینی را دارا می‌باشند اما نتایج نشانگر برتری مدل هوش مصنوعی مرکب نسبت به هر یک از مدل‌های منفرد هوش مصنوعی بوده است. دهقانی و همکاران (۸) کارایی روش‌های سیستم استنتاج فازی-عصبی تطبیقی^۱، شبکه عصبی مصنوعی و برنامه‌ریزی بیان‌ژن^۲ در تخمین سختی آب زیرزمینی را با یکدیگر مقایسه کردند. در این پژوهش مقادیر هیدروژن، کربنات، کلرید، سولفات، منیزیم و کلسیم در مقیاس زمانی ماهانه و طی دوره آماری (۱۳۷۳-۱۳۹۳) به‌عنوان ورودی مدل‌ها و میزان سختی آب دشت مازندران به‌عنوان خروجی مدل‌ها انتخاب گردیده است. در مجموع نتایج نشان‌دهنده برتری مدل برنامه‌ریزی بیان‌ژن در تخمین میزان سختی آب زیرزمینی بوده است. چو و همکاران (۹) پتانسیل آلودگی آب‌های زیرزمینی را با استفاده از مدل شبکه عصبی مصنوعی پیش‌بینی کرده‌اند. در این تحقیق از چهار روش مختلف برای مدل‌سازی استفاده شده است. مدل‌ها شامل رگرسیون خطی چند گانه، رگرسیون مولفه‌های اصلی (PCR)^۳، شبکه عصبی مصنوعی و ترکیبی از مولفه‌های اصلی و شبکه عصبی مصنوعی (PC-ANN) بوده‌اند. مدل-سازی برای کشورهای جنوب شرقی آسیا شامل کامبوج، لائوس و تایلند انجام شده است. نتایج نشان می‌دهد که مدل شبکه عصبی مصنوعی مبتنی بر مولفه‌های اصلی عملکرد مناسب‌تری نسبت به مدل‌های دیگر داشته است. آلاقا^۴ و همکاران (۱۰) تمرکز نیترات را در آب زیرزمینی با استفاده روش‌های هوش مصنوعی مدل‌سازی نموده‌اند. آن‌ها در این تحقیق از دو روش

- 1- Adaptive Neural-Fuzzy Inference System
- 2- Gene Expression Planning
- 3- Principal component regression
- 4- Alagha

مدل و ترکیب برتر جهت تخمین هر یک از پارامترهای کیفی غلظت یون کلسیم، غلظت یون سدیم و هدایت الکتریکی آب-خوان استان گیلان می‌باشد.

مواد و روش‌ها

داده‌ها و منطقه مورد مطالعه

استان گیلان به مرکزیت رشت در شمال کشور ایران قرار گرفته است که از شمال به دریای خزر، از شرق به استان مازندران، از جنوب به رشته کوه‌های البرز و استان‌های زنجان و قزوین و از غرب به استان اردبیل محدود می‌باشد. توزیع ناهماهنگ نزولات جوی و حجم جریانات سطحی در طول سال و از طرفی نقش آب در کشاورزی منطقه خصوصا تولید محصول استراتژی برنج ضرورت بررسی و مطالعه سیستماتیک منابع آب اعم از سطحی و زیرزمینی را ایجاب نموده است. متوسط بارندگی استان گیلان ۱۱۰۰ میلی‌متر و میانگین حجم بارش ۱۵۰۲۷ میلیون مترمکعب می‌باشد که از حجم فوق میزان ۷۸۸۷ میلیون مترمکعب جز منابع غیرقابل دسترس (تبخیر و تعرق) و حجمی معادل ۷۱۴۰ میلیون مترمکعب قابل دسترس و تجدیدپذیر می‌باشد. به‌طوریکه سهم آب زیرزمینی از منابع آب تجدیدپذیر ۴۷۳ میلیون مترمکعب و سهم آب‌های سطحی قابل دسترس از منابع آب تجدید شونده ۶۶۶۷ میلیون مترمکعب می‌باشد. در این تحقیق جهت تخمین سه پارامتر کیفی آب زیرزمینی هدایت الکتریکی، غلظت یون سدیم و غلظت یون کلسیم از داده های کیفی، تراز آب، فاصله از دریا، مجموع بارش شش ماهه و مختصات جغرافیایی (UTM) چاهک‌های مشاهداتی آب‌خوان استان گیلان استفاده شده است. نزدیک‌ترین فاصله هر چاهک مشاهداتی از دریا با استفاده از نرم افزار Google Earth محاسبه گردید. داده‌های بارندگی مربوط به هر چاهک مشاهداتی براساس پلیگون‌های تیسن ایستگاه‌های سینوپتیک و باران‌سنجی تعیین گردید. بدین منظور از ایستگاه‌های سینوپتیک فرودگاه رشت، آستارا، تالش و منجیل و ایستگاه‌های باران‌سنجی آب‌ویر، آستانه، پارودبار، پیرکوه، چوبر شفت،

احتشامی و همکاران (۱۴) از دو شبکه عصبی پس‌انتشار خطا و تابع پایه شعاعی برای تخمین نیترات آب‌زیرزمینی بابل استفاده کرده‌اند. در این تحقیق از پارامترهای هیدروژئولوژی، نیتروژن خاک، مواد معدنی خاک و کربن خاک به‌عنوان متغیرهای ورودی برای پیش‌بینی نیترات آب زیرزمینی استفاده شده است. نتایج نشان داد که هر دو شبکه نتایج قابل قبولی در پیش‌بینی نیترات آب زیرزمینی داشته‌اند، و می‌توانند به‌عنوان ابزاری مناسب برای شبیه‌سازی پارامترهای ذکر شده استفاده گردند. عرب‌گل و همکاران (۱۵) پیش‌بینی تمرکز نیترات و توزیع آن در آب‌های زیرزمینی را با استفاده از مدل ماشین بردار پشتیبان مورد بررسی قرار دادند. آن‌ها مدل ماشین بردار را برای پیش‌بینی نیترات آب‌های زیرزمینی در اراک توسعه دادند. در این تحقیق از پارامترهای دمای آب، هدایت الکتریکی آب، تراز آب زیرزمینی، مجموع مواد جامد محلول، اکسیژن محلول، PH، کاربری اراضی و ماه اندازه‌گیری کیفیت آب زیرزمینی به‌عنوان متغیرهای ورودی استفاده شده است. نتایج حاکی از عملکرد مناسب مدل ماشین بردار پشتیبان می‌باشد.

در این تحقیق پنج هدف اصلی زیر دنبال می‌گردد. هدف اول تعیین دو مجموعه ترکیب ورودی کمی (بخش اول) و کمی-کیفی (بخش دوم) می‌باشد. ترکیب‌های ورودی کمی براساس پژوهش‌های مرتبط و ترکیب‌های ورودی کمی-کیفی نیز براساس ادغام نتایج بخش اول و آزمون گاما تعیین می‌گردد. آزمون گاما با استفاده از پارامترهای کیفی چاهک‌های مشاهداتی مورد بررسی انجام گرفته است. هدف دوم تخمین پارامترهای کیفی غلظت یون کلسیم، غلظت یون سدیم و هدایت الکتریکی به‌وسیله مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان می‌باشد. این تخمین‌ها براساس دو مجموعه ترکیب ذکر شده انجام گرفته است. هدف سوم مقایسه عملکرد هر یک از مدل‌ها در تخمین مقادیر هر یک از سه پارامتر کیفی مذکور به‌ازای هر یک از مجموعه ترکیب‌های ورودی است. هدف چهارم تحلیل و بررسی تاثیر هر یک از متغیرهای ورودی بر عملکرد مدل‌های مورد بررسی در تخمین سه پارامتر کیفی مدنظر می‌باشد. در نهایت هدف پنجم تعیین

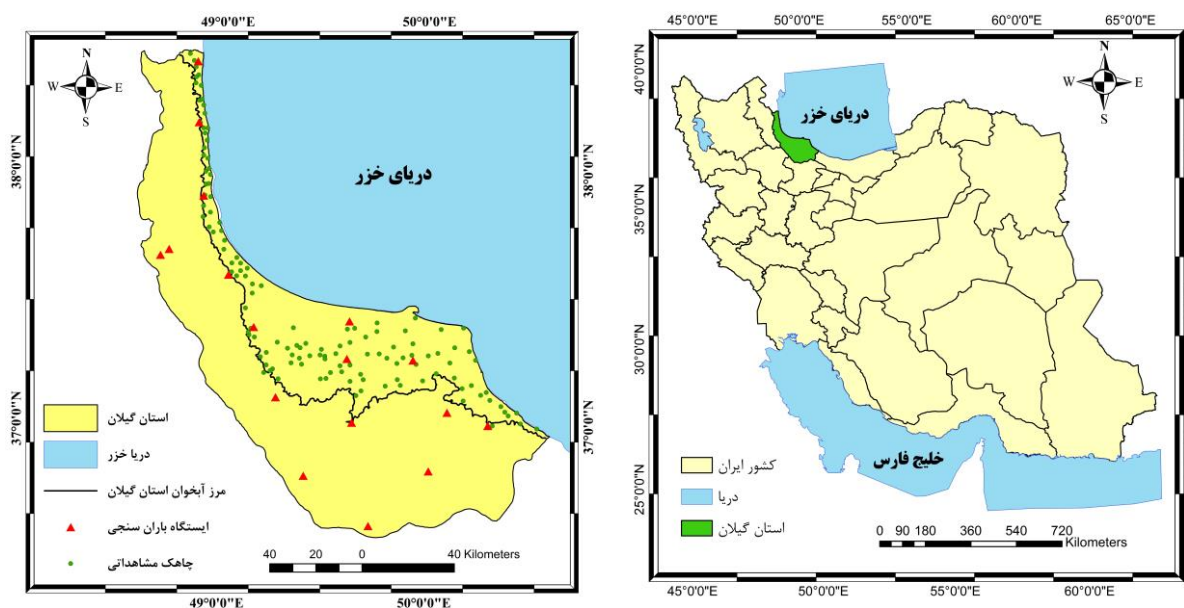
(شکل ۱). بدین منظور از ۲۹۵۴ رکورد ثبت شده که دارای اطلاعات صحیح و کامل بودند، استفاده گردید. این داده‌ها به دو بخش صحت‌سنجی و آموزش تقسیم گردیده‌اند که ۷۵ درصد داده‌ها برای آموزش (۲۲۱۶) و ۲۵ درصد دیگر (۷۳۸) برای بخش صحت‌سنجی استفاده شده است.

خلیان، رشت، شهربیجار، قلعه رودخان، کسما، ماسال، ناو، هراتبر و کاکرود استفاده گردیده است. در جدول ۱ مشخصات آماری پارامترهای ورودی و خروجی داده‌های چاهک‌های مشاهداتی مورد استفاده در این تحقیق آورده شده است. در این تحقیق از داده‌های ۱۳۲ چاهک مشاهداتی آب‌خوان استان گیلان در دوره آماری ۱۳۸۱ تا ۱۳۹۳ استفاده گردیده است

جدول ۱- مشخصات آماری متغیرها و پارامترهای ورودی و خروجی استفاده شده.

Table 1- The statistical characteristics of the variables and input and output parameters are used

متغیرها و پارامترها							شاخص های آماری
مجموع بارش شش ماه	فاصله از سطح دریا	تراز آب	Ca(meq/l)	Na(meq/l)	EC(μmos/cm)		
۱۴۳۸	۳۸۹۳۰/۸۹	۸۶/۹۰۶	۱۱/۵	۱۲/۳	۲۶۳۹	حداکثر	
۶۹/۳	۱۶۶/۳	-۲۵/۹۸۳	۰/۰۱	۰/۰۲	۱۲۴	حداقل	
۶۲۲/۲۱	۱۲۹۳۰/۲۱	۰/۸۸	۳/۸۱	۱/۷۲	۷۵۸/۴۴	متوسط	
۲۶۰/۰۴	۱۱۴۷۸/۳۷	۲۲/۸۹	۱/۶۵	۱/۸۵	۳۷۲/۵۶۷	انحراف معیار	



شکل ۱- منطقه مورد مطالعه به همراه چاهک‌های مشاهداتی، مرز آب‌خوان و ایستگاه‌های باران‌سنجی

Figure 1- The study area, along with observation wells, drainage border and rain-storm stations

ترکیب‌های اولیه ورودی هر یک از مدل‌های تخمین‌گر تعیین گردید.


با توجه به ورودی‌های مورد نظر، جدول ۲ به‌عنوان مجموعه

جدول ۲- ترکیب‌های ورودی هر یک از مدل‌های تخمینگر

شماره ترکیب	پارامترهای ورودی		
۱	UTMX	UTMY	
۲	UTMX	UTMY	فاصله از دریا
۳	UTMX	UTMY	تراز آب چاهک
۴	UTMX	UTMY	فاصله از دریا تراز آب چاهک
۵	UTMX	UTMY	مجموع بارش شش ماهه

که در مسائل هیدرولوژی کاربرد دارد شبکه‌های پیشرو هستند (۱۷). معماری معمول این شبکه متشکل از سه لایه ورودی، پنهانی و خروجی است. تعداد نرون‌های موجود در لایه ورودی و خروجی بستگی به نوع مسئله دارد ولی تعداد گره‌های لایه پنهان با سعی و خطا بدست می‌آید (شکل ۲).

مدل شبکه عصبی پیشرو با آموزش لونیبرگ - مارکواریت از اوایل دهه ۱۹۹۰ تاکنون، شبکه‌های عصبی مصنوعی در زمینه هیدرولوژی نیز به طور موفقیت‌آمیز بکار گرفته شده است که از آن جمله می‌توان به مدل کردن فرآیندهای بارش-رواناب، پیش‌بینی جریان رودخانه، مدل کردن آب زیرزمینی، کیفیت آب، پیش‌بینی بارندگی و ... اشاره کرد (۱۶). حدود ۹۰٪ شبکه‌هایی



شکل ۲- الف) شمای کلی شبکه‌های پیشرو سه لایه، ب) شمای زام گره از آن (۱۸)

Figure 2-A) The general schema of the three-layer pre-network; B) The jm node of it (18)

این مطالعه از آن برای نگاشت اطلاعات از لایه ورودی به لایه پنهان و همچنین برای نگاشت اطلاعات از لایه پنهان به لایه خروجی استفاده شد.

الگوریتم تکاملی تفاضلی

استراتژی تکاملی تفاضلی یک روش بهینه‌سازی احتمالاتی مبتنی بر جمعیت است. در اصول پایه تولید جمعیت اولیه و ادامه تکامل نسل‌های آینده و نگاه به ارزش‌دهی تابع ارزیاب مطابق با الگوریتم ژنتیک است.

مدل ماشین بردار پشتیبان

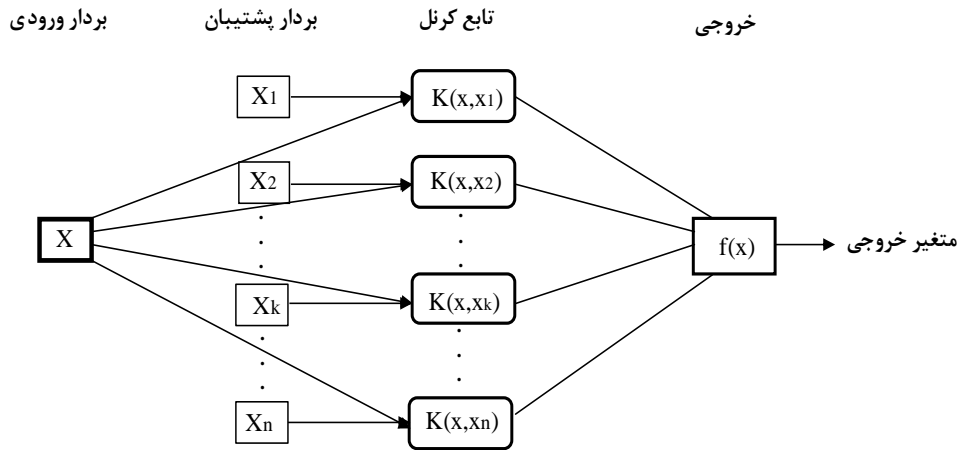
اولین کاربرد این روش در مسائل آب توسط دیباک و همکاران (۱۹) با شبیه‌سازی بارش-رواناب ارائه شد. ماشین بردار

در شکل ۲، $X = (x_1, \dots, x_i, \dots, x_n)$ بردار ورودی‌ها، w_{ij} وزن اتصالی از آامین گره به زامین گره در لایه بعد، b_j بایاس مربوط به گره زام، z_j ها خروجی‌های هر لایه، Y خروجی نهایی شبکه عصبی مصنوعی است. در شبکه‌های پیشرو، اتصالات میان گره‌هایی وجود دارد که در لایه‌های متفاوت قرار دارند. همچنین ورودی‌ها در لایه ورودی شبکه نمایش داده شده و عمل تحریک از ورودی به سمت خروجی شبکه شروع می‌شود (۱۸).

لازم به ذکر است که در تحقیق حاضر از تعداد نرون‌های ۱ تا ۲۰ برای لایه پنهان شبکه استفاده گردید تا از این طریق تاثیر ساختار مختلف شبکه بر عملکرد آن در شبیه‌سازی مقادیر کیفی آبخوان مورد ارزیابی قرار گیرد. از آنجا که متداول‌ترین نوع توابع محرک تابع تانژانت سیگموئید می‌باشد بنابراین در

میگردد. شکل (۳) ساختار ماشین بردار پشتیبان را نشان می-دهد.

پشتیبان یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه-سازی مقید است که از اصل استقرای کمینه سازی خطای ساختاری استفاده کرده و منجر به یک جواب بهینه کلی



شکل ۳- ساختار ماشین بردار پشتیبان (۲۰)

Figure 3- Backup vector machine structure (20)

در معادلات بالا C عددی صحیح و مثبت است که عامل تعیین جریمه در هنگام رخ دادن خطای واسنجی مدل است، $\phi(x)$ تابع کرنل، N تعداد نمونه‌ها و دو مشخصه ε_i^* و ε_i متغیرهای کمبود هستند (۲۱). در نهایت، تابع رگرسیون بردار پشتیبان را می‌توان به فرم زیر باز نویسی کرد:

$$f(x) = \sum_{i=1}^N \bar{\alpha}_i \cdot \phi(x_i)^T \cdot \phi(x) + b \quad (5)$$

در معادله (۵)، $\bar{\alpha}_i$ میانگین ضرایب لاگرانژ است. محاسبه $\phi(x)$ در فضای مشخصه آن ممکن است بسیار پیچیده باشد. برای حل این مشکل روند معمول در مدل رگرسیون بردار پشتیبان انتخاب یک تابع کرنل است. با توجه به اینکه در ماشین بردار پشتیبان معمولاً از تابع کرنل پایه شعاعی استفاده می‌گردد، در این تحقیق نیز از این تابع استفاده گردیده است. فرمول کرنل پایه شعاعی در زیر آورده شده است (۲۲).

$$k(x, x_i) = \exp\left(-\|x - x_i\|^2 / \sigma^2\right) \quad (6)$$

لازم به ذکر است فرآیند محاسبات ماشین بردار پشتیبان، بر اساس کدنویسی در محیط متلب انجام و پارامترهای تابع کرنل از طریق سعی و خطا بهینه شدند.

در مدل رگرسیون بردار پشتیبان تابعی مرتبط با متغیر وابسته y که خود تابعی از چند متغیر مستقل x است، برآورد می‌شود. مشابه سایر مسائل رگرسیونی فرض می‌شود رابطه میان متغیرهای مستقل و وابسته با تابع جبری مانند $f(x)$ به علاوه مقداری اغتشاش (خطای مجاز ε) مشخص شود.

$$f(x) = W^T \cdot \phi(x) + b \quad (1)$$

$$y = f(x) + noise \quad (2)$$

چنانچه W بردار ضرایب، b ثابت مشخصه‌های تابع رگرسیونی و $\phi(x)$ نیز تابع کرنل باشد، آنگاه هدف پیدا کردن فرم تابعی برای $f(x)$ است. این مهم با واسنجی مدل ماشین بردار پشتیبان توسط مجموعه‌ای از نمونه‌ها (مجموعه واسنجی) محقق می‌شود. برای محاسبه W و b لازم است تابع خطا (معادله ۳) در مدل ماشین بردار پشتیبان رگرسیونی با در نظر گرفتن شرایط مندرج (قیود) در معادله (۴) بهینه شود.

$$W^T \cdot \phi(x_i) + b - y_i \leq \varepsilon + \varepsilon_i^* \quad (3)$$

$$\frac{1}{2} W^T \cdot w + C \sum_{i=1}^N \varepsilon_i + C \sum_{i=1}^N \varepsilon_i^* y_i \quad (4)$$

$$-W^T \cdot \phi(x_i) - b \leq \varepsilon + \varepsilon_i$$

$$\varepsilon_i, \varepsilon_i^* \geq 0, i = 1, 2, \dots, N$$

آزمون گاما

آزمون گاما یک روش غیر متغیری است که نتایج آن صرف نظر از روش‌های خاص برای مدل‌سازی به کار برده می‌شود (۲۳). در این آزمون فرض می‌شود که مجموعه داده‌های مشاهداتی به صورت رابطه ۷ است.

$$\{(x_i - y_i), 1 \leq i \leq M\} \quad (7)$$

که در آن x_i بردار مشاهداتی ورودی (مانند رواناب، بارش، درجه حرارت هوا با تاخیرهای مختلف و هر متغیر موثر دیگر)، y_i خروجی مشاهداتی (مانند میانگین دبی رواناب روزانه) و M تعداد کل مشاهدات می‌باشد.

از بردار x_i (در فضای m بعدی) برای مدل‌سازی y_i (در فضای R) استفاده می‌شود. بنابراین، با توجه به فرض فوق رابطه‌ی بین ورودی و خروجی به شرح زیر در نظر گرفته می‌شود.

$$y = f(x) + r \quad (8)$$

که در آن f یک تابع هموار و r متغیر تصادفی نشان‌دهنده‌ی خطا بوده، همچنین فرض شده است میانگین توزیعی که r از آن پیروی کرده، صفر و واریانس خطا، کران‌دار است. به این ترتیب مدل نشان داده شده با رابطه ۸ به مدلی هموار با مشتقات جزئی مرتبه اول محدود می‌گردد و آماره گاما (Γ)، واریانس بخشی از داده‌ها که تابع f قادر به توجیه آن نیست را نشان می‌دهد. برای بردار ورودی x_i مجموعه $N[i,k]$ ($1 \leq k \leq p$)، مجموعه نزدیک‌ترین همسایگی است. پایه و اساس آزمون گاما بر مبنای مجموعه $N[i,k]$ می‌باشد. $x_{N[i,k]}$ به عنوان k امین نزدیک‌ترین همسایگی‌ها برای بردار مشاهداتی ورودی x_i تعریف شده، به طوری که ($1 \leq k \leq p$) و ($1 \leq i \leq M$) می‌باشد. P حداکثر تعداد همسایگی‌ها است که معمولاً بین ۱۰ تا ۵۰ در نظر گرفته می‌شود (دورانت ۲۴). به منظور به دست آوردن مقدار آماره گاما (Γ)، ابتدا مقدار ($\delta_M(k)$)، با توجه به داده‌ی ورودی به شرح زیر محاسبه می‌شود.

$$\delta_M(k) = \frac{1}{M} \sum_{i=1}^M |x_{N[i,k]} - x_i|^2 \quad 1 \leq k \leq p \quad (9)$$

که در آن نماد $|...|$ به عنوان فاصله اقلیدسی بردار $x_{N[i,k]}$ از بردار همسایگی‌های آن می‌باشد. همچنین مقدار آماره‌ی گامای کوچک، ($\gamma_M(k)$) با استفاده از داده‌های خروجی به شرح زیر به دست می‌آید.

$$\gamma_M(k) = \frac{1}{2M} \sum_{i=1}^M |y_{N[i,k]} - y_i|^2 \quad , 1 \leq k \leq p \quad (10)$$

که در آن $y_{N[i,k]}$ مقدار خروجی نظیر k امین نزدیک‌ترین همسایگی برای بردار x_i می‌باشد. به این ترتیب p مقدار برای $\delta_M(k)$ و $\gamma_M(k)$ مقدار برای $\gamma_M(k)$ به دست آورده می‌شود. سپس بین زوج مرتب $\{\delta_M(k), \gamma_M(k)\}$ رابطه رگرسیونی خطی ساده به شرح رابطه ۱۱ برقرار خواهد شد، به طوری که در آن δ و γ به ترتیب به عنوان متغیرهای وابسته و مستقل در نظر گرفته شده است.

$$\gamma = A \delta + \Gamma \quad (11)$$

مقدار آماره‌ی Γ در واقع عرض از مبدا خط رگرسیون فوق می‌باشد. A شیب خط رگرسیون بوده که نشان‌دهنده پیچیدگی مدلی است که از روی داده‌های مشاهداتی ایجاد می‌شود. متغیر دیگری که معمولاً در آزمون گاما به کار برده می‌شود متغیر بدون بعد V_{ratio} نام دارد که مقدار آن بین صفر و یک بوده و مقدار آن از رابطه ۱۲ محاسبه می‌شود (۲۵).

$$V_{ratio} = \frac{\Gamma}{\sigma^2(y)} \quad (12)$$

که در آن $\sigma^2(y)$ واریانس داده‌های مشاهداتی می‌باشد. هر چه مقدار V_{ratio} به صفر نزدیک‌تر باشد ترکیب انتخابی برای مدل‌سازی، ترکیب مناسب‌تری است. ثابت شده است که اگر این مقدار از یک کم شود مقدار ضریب تبیین مدل به دست می‌آید.

معیارهای ارزیابی

با استفاده از روش‌های مختلفی می‌توان عملکرد مدل‌ها را مورد ارزیابی و مقایسه قرار داد، یکی از این روش‌ها استفاده از معیارهای ارزیابی می‌باشد. از جمله معیارهای ارزیابی پرکاربرد در علوم مهندسی آب، ضرایب همبستگی^۱ (CC)، ریشه

ماشین بردار پشتیبان و شبکه عصبی مصنوعی است. مرحله چهارم: ارزیابی عملکرد این مدل‌ها و سپس تعیین ترکیب بهینه کمی برای تخمین هر یک از سه پارامتر کیفی می‌باشد. مرحله پنجم: استفاده از آزمون گاما جهت تعیین ترکیب‌های بهینه کیفی برای تخمین هر یک از سه پارامتر کیفی EC، NA و Ca است. مرحله ششم: استفاده همزمان از ترکیب بهینه کمی و ترکیب بهینه ارائه شده توسط آزمون گاما جهت تخمین هر یک از سه پارامتر کیفی می‌باشد. مرحله هفتم: تخمین مقادیر کیفی مدنظر توسط دو مدل ماشین بردار پشتیبان و شبکه عصبی مصنوعی به‌ازای ورودی‌های مرحله ششم می‌باشد. مرحله هشتم: ارزیابی عملکرد مدل‌ها و ترکیب‌های بکار رفته در مرحله هفتم و سپس تعیین ترکیب بهینه نهایی برای تخمین هر یک از سه پارامتر کیفی می‌باشد.

نتایج و بحث

شبیه‌سازی و تخمین پارامترهای کیفی به‌ازای مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان و ۵ ترکیب جدول ۲ انجام گرفته است و آماره‌های ضریب همبستگی، مجذور میانگین مربعات خطا و ضریب نش-ساتکلیف در دوره‌های واسنجی و صحت‌سنجی بدست آمده است. خلاصه نتایج برگزیده هر یک از ترکیب‌ها و مدل‌ها در جدول ۳ نشان داده شده است.

میانگین مربعات خطا^۱ (RMSE) و معیار نش-ساتکلیف^۲ (NS) می‌باشند که به ترتیب در روابط ۱۳، ۱۴ و ۱۵ آورده شده‌اند. دقیق‌ترین مدل با توجه به این معیارها، مدلی خواهد بود که مقدار این سه معیار برای آن به ترتیب نزدیک به یک، صفر و یک باشد.

$$CC = \sqrt{\frac{(\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y}))^2}{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad (13)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (14)$$

$$NS = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{x})^2} \quad (15)$$

در روابط بالا \bar{x} و \bar{y} به ترتیب مقادیر مشاهداتی جریان و میانگین مقادیر مشاهداتی، y_i مقادیر محاسباتی جریان، \bar{y} میانگین مقادیر محاسباتی و N تعداد داده‌ها می‌باشد (۲۶).

مراحل انجام کار

مراحل انجام شبیه‌سازی و سپس تخمین مقادیر کیفی آبخوان استان گیلان به‌ازای دو مجموعه ترکیب کمی و کمی-کیفی صورت گرفته است که در ادامه به مراحل کلی آن اشاره می‌گردد. مرحله اول: داده‌های کمی و کیفی اشاره شده در طول سال‌های ۱۳۸۱ تا ۱۳۹۳ که دارای اطلاعات درست و کاملی بوده‌اند، جهت شبیه‌سازی انتخاب گردیدند. مرحله دوم: تعیین مجموعه ورودی‌های کمی می‌باشد که ویژگی مهم این مجموعه، استقلال ورودی‌ها از اطلاعات کیفی چاهک‌های مشاهداتی می‌باشد. مرحله سوم: تخمین مقادیر کیفی مدنظر توسط دو مدل

جدول ۳- نتایج مدل‌های ANN و SVM در تخمین پارامترهای کیفی Ca، Na و EC.

Table 3- The results of ANN and SVM models in estimating the quality parameters of Ca, Na and EC

تعداد نرون بهینه	صحت‌سنجی			واسنجی			شماره ترکیب	مدل	پارامتر
	CC	RMSE	NS	CC	RMSE	NS			
۱۸	۰/۵۹۶	۱/۳۱۳	۰/۳۴۷	۰/۶۶۶	۱/۲۴۲	۰/۴۴۳	۱	ANN	Ca
۱۶	۰/۶۲۲	۱/۲۷۴	۰/۳۸۵	۰/۶۷۲	۱/۲۳۲	۰/۴۵۲	۲		
۲۰	۰/۶۲	۱/۲۸۵	۰/۳۷۴	۰/۶۸۵	۱/۲۱۲	۰/۴۶۹	۳		
۲۰	۰/۶۳	۱/۲۶۸	۰/۳۹۱	۰/۶۸۷	۱/۲۱	۰/۴۷۲	۴		
۱۳	۰/۵۶۲	۱/۳۴۶	۰/۳۱۴	۰/۵۹۸	۱/۳۳۵	۰/۳۵۷	۵		
-	۰/۶۶۲	۱/۲۲	۰/۴۳۷	۰/۷۲۹	۱/۱۴۱	۰/۵۳	۱	SVM	
-	۰/۶۶۴	۱/۲۱۸	۰/۴۳۹	۰/۷۳۲	۱/۱۳۶	۰/۵۳۴	۲		
-	۰/۶۵۸	۱/۲۲۷	۰/۴۳۱	۰/۷۳۹	۱/۱۲۴	۰/۵۴۳	۳		
-	۰/۶۶	۱/۲۲۴	۰/۴۳۴	۰/۷۴۳	۱/۱۱۶	۰/۵۵	۴		
-	۰/۵۶۲	۱/۳۴۹	۰/۳۱۱	۰/۸۳۱	۰/۹۷۸	۰/۶۵۴	۵		
۱۵	۰/۷۹۳	۱/۰۴۸	۰/۶۲۶	۰/۸۰۸	۱/۱۲۱	۰/۶۵۳	۱	ANN	Na
۱۶	۰/۸۴	۰/۹۳۳	۰/۷۰۴	۰/۸۵	۱/۰۰۳	۰/۷۲۲	۲		
۱۷	۰/۸۲۹	۰/۹۶۳	۰/۶۸۴	۰/۸۴۲	۱/۰۲۷	۰/۷۰۹	۳		
۱۸	۰/۸۳۱	۰/۹۶۲	۰/۶۸۵	۰/۸۵۲	۰/۹۹۷	۰/۷۲۶	۴		
۱۶	۰/۷۰۷	۱/۲۱۸	۰/۴۹۵	۰/۷۲۶	۱/۳۰۹	۰/۵۲۷	۵		
-	۰/۸۶۳	۰/۸۶۷	۰/۷۴۴	۰/۸۷۴	۰/۹۲۴	۰/۷۶۴	۱	SVM	
-	۰/۸۶۳	۰/۸۶۷	۰/۷۴۴	۰/۸۷۵	۰/۹۲۴	۰/۷۶۵	۲		
-	۰/۸۶۱	۰/۸۷۳	۰/۷۴۱	۰/۸۷۶	۰/۹۱۸	۰/۷۶۷	۳		
-	۰/۸۶۴	۰/۸۶۷	۰/۷۴۴	۰/۸۷۸	۰/۹۱۳	۰/۷۷	۴		
-	۰/۶۸۲	۱/۲۶	۰/۴۶	۰/۶۹۹	۱/۳۶۱	۰/۴۸۸	۵		
۱۹	۰/۸۲۵	۲۰۳/۱۶۷	۰/۶۷۹	۰/۸۴۹	۱۹۹/۵۵۶	۰/۷۲	۱	ANN	EC
۲۰	۰/۸۵۵	۱۸۶/۴۴۸	۰/۷۳	۰/۸۸۱	۱۷۸/۱۴۷	۰/۷۷۷	۲		
۱۸	۰/۸۴	۱۹۵/۸۷۷	۰/۷۰۲	۰/۸۶۱	۱۹۱/۷۱۹	۰/۷۴۲	۳		
۱۶	۰/۸۵۱	۱۸۸/۶۷۲	۰/۷۲۳	۰/۸۷۸	۱۸۰/۴۲۳	۰/۷۷۱	۴		
۱۰	۰/۸۰۹	۲۱۱/۴۳۷	۰/۶۵۲	۰/۸۳۸	۲۰۵/۷۸۲	۰/۷۰۲	۵		
-	۰/۸۷۱	۱۷۶/۶۷۹	۰/۷۵۸	۰/۸۹۴	۱۶۸/۶۶۳	۰/۸	۱	SVM	
-	۰/۸۷۱	۱۷۶/۵۵۴	۰/۷۵۸	۰/۸۹۵	۱۶۸/۱	۰/۸۰۱	۲		
-	۰/۸۷	۱۷۶/۹۸۴	۰/۷۵۷	۰/۹۰۱	۱۶۳/۹۱۶	۰/۸۱۱	۳		
-	۰/۸۷۲	۱۷۵/۷۴۲	۰/۷۶	۰/۹۰۱	۱۶۳/۴۲۳	۰/۸۱۲	۴		
-	۰/۷۵۱	۲۳۶/۸۱۴	۰/۵۶۴	۰/۹۳۸	۱۳۹/۶۶۳	۰/۸۶۳	۵		

مدل شبکه عصبی مصنوعی در تخمین پارامتر غلظت یون کلسیم به‌ازای ترکیب‌های شماره دو و چهار نتایج بهتری را نسبت به سایر ترکیب‌های دیگر داشته است. البته ترکیب شماره چهار با دارا بودن ضریب‌همبستگی و ضریب‌نش-ساتکلیف بیشتر و مجذور میانگین مربعات خطای کمتر، نسبت به چهار ترکیب دیگر به‌عنوان ترکیب برتر در تخمین غلظت یون کلسیم انتخاب گردید. ترکیب شماره چهار در دوره صحت-سنجی دارای ضریب همبستگی برابر $0/630$ ، مجذور میانگین مربعات خطای برابر $1/268$ و ضریب‌نش-ساتکلیف برابر $0/391$ می‌باشد. مدل ماشین بردار پشتیبان با استفاده از ترکیب شماره دو مقادیر پارامتر غلظت یون کلسیم را با دقت مناسبی مورد تخمین قرار داده است. این مدل با استفاده از ترکیب شماره دو، پارامتر غلظت یون کلسیم را با ضریب همبستگی، مجذور میانگین مربعات خطا و ضریب‌نش-ساتکلیف به‌ترتیب برابر با $0/664$ ، $1/218$ و $0/439$ در دوره صحت‌سنجی تخمین زده است. مدل شبکه عصبی مصنوعی به‌ازای دو ترکیب دو و چهار مقادیر پارامتر غلظت یون سدیم را با دقت قابل قبولی تخمین زده است. با توجه به آماره‌های ارزیابی، ترکیب دو با ضریب همبستگی، مجذور میانگین مربعات خطا و ضریب‌نش-ساتکلیف به‌ترتیب برابر $0/840$ ، $0/933$ و $0/704$ در دوره صحت‌سنجی مقادیر پارامتر غلظت یون سدیم را بهتر از سایر ترکیب‌های مورد استفاده تخمین زده است. مدل ماشین بردار پشتیبان نیز با استفاده از ترکیب شماره چهار، مقادیر آماره‌های ضریب همبستگی، مجذور میانگین مربعات خطا و ضریب‌نش-ساتکلیف را در دوره صحت‌سنجی به‌ترتیب برابر با $0/864$ ، $0/867$ و $0/744$ به‌دست آورده است. در تخمین مقدار هدایت الکتریکی آبخوان دشت گیلان، ترکیب شماره دو دارای عملکرد بهتری نسبت به چهار ترکیب دیگر در مدل شبکه عصبی مصنوعی می‌باشد. ترکیب شماره دو دارای ضریب همبستگی $0/855$ ، مجذور میانگین مربعات خطای $186/448$ و ضریب‌نش-ساتکلیف $0/730$ در دوره صحت‌سنجی بوده است. هم-چنین لازم به ذکر است که ترکیب شماره چهار نیز نتیجه نزدیکی به ترکیب شماره دو دارد. مدل ماشین‌بردار پشتیبان

تخمین پارامتر هدایت الکتریکی را به‌ازای ترکیب شماره چهار با دقت بالایی انجام داده است. این مدل با استفاده از ترکیب شماره چهار در دوره صحت‌سنجی مقادیر آماره‌های ضریب همبستگی، مجذور میانگین مربعات خطا و ضریب‌نش-ساتکلیف را به‌ترتیب برابر با $0/872$ ، $175/742$ و $0/760$ به‌دست آورده است. در تخمین پارامتر هدایت الکتریکی، مدل ماشین بردار پشتیبان به‌ازای ترکیب‌های شماره دو و چهار نتایج نسبتاً مشابهی به‌دست آورده است. با توجه به نتایج جدول ۳ اضافه شدن پارامتر فاصله از دریا در تخمین هر یک از سه پارامتر مورد بررسی و در هر یک از مدل‌ها باعث افزایش دقت در تخمین پارامترهای کیفی شده است. بنابراین می‌توان پارامتر فاصله از دریا را به‌عنوان یک پارامتر بسیار مناسب و کارا در تخمین مقادیر کیفی آبخوان‌های ساحلی بکار گرفت. افزودن پارامتر تراز آب چاهک‌ها به ترکیب یک (ترکیب ۳ در جدول ۲) در مدل شبکه عصبی مصنوعی باعث بهبود تخمین هر یک از پارامترهای کیفی گردید، ولی این پارامتر در نتایج مدل ماشین بردار پشتیبان اثر منفی گذاشته است. همچنین نتایج نشان داد، استفاده از پارامتر فاصله از دریا نسبت به پارامتر تراز آب چاهک‌ها، تاثیر بیشتری در بهبود نتایج مدل شبکه عصبی در تخمین هر یک از سه پارامتر غلظت یون کلسیم، غلظت یون سدیم و هدایت الکتریکی داشته است. هم‌چنین در بین ترکیب‌های استفاده شده در تخمین هر یک از سه پارامتر کیفی ترکیب شماره دو و چهار نتیجه بهتری را به‌دست آورده‌اند که تاثیر مثبت متغیر فاصله از دریا در تخمین پارامترهای کیفی ذکر شده را تایید می‌کند. هم‌چنین با توجه به نتایج در هیچ یک از موارد استفاده از متغیر مجموع بارش شش ماهه نمی‌تواند باعث افزایش دقت تخمین پارامترهای کیفی مدنظر گردد. نتایج آماره‌های ارزیابی تخمین‌های صورت گرفته توسط مدل ماشین‌بردار پشتیبان نشان می‌دهد که در اکثر موارد نتایج ترکیب‌های مختلف بسیار به یکدیگر نزدیک می‌باشند. این نزدیکی نتایج حاکی از دقت و قدرت زیاد مدل ماشین‌بردار پشتیبان در تخمین پارامترهای کیفی آبخوان‌های ساحلی و هم‌چنین کارایی این مدل به‌ازای کمترین ورودی می‌باشد. در

آبخوان استان گیلان معرفی کرد.

نتایج آزمون گاما

در ادامه با نظر به زمان‌بر و هزینه‌بر بودن آزمایش‌های تعیین مقادیر پارامترهای کیفی چاهک‌های مشاهداتی، در این قسمت سعی گردید از سایر پارامترهای اندازه‌گیری شده، جهت تخمین پارامترهای کیفی غلظت یون کلسیم، غلظت یون سدیم و هدایت الکتریکی استفاده گردد. بنابراین جهت تعیین ضروری‌ترین پارامترهای کیفی در تخمین پارامترهای غلظت یون کلسیم، غلظت یون سدیم و هدایت الکتریکی از آزمون گاما استفاده گردید که نتایج آن در جدول ۴ نشان داده شده است.

واقع مدل ماشین بردار پشتیبان قادر است تا پارامترهای کیفی آبخوان استان گیلان را بدون دخالت دادن سایر پارامترها و با استفاده از کمترین اطلاعات (مختصات چاهک‌های مشاهداتی) با دقت بالایی مورد تخمین قرار دهد. مقایسه نتایج مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان به‌زای ترکیب‌های برتر نشان داد که مدل ماشین بردار پشتیبان در تخمین هر یک از سه پارامتر کیفی غلظت یون کلسیم، غلظت یون سدیم و هدایت الکتریکی عملکرد بهتری نسبت به مدل شبکه عصبی مصنوعی داشته است. بنابراین در این بخش می‌توان این مدل را به‌عنوان مدل برتر در تخمین کلیه پارامترهای کیفی

جدول ۴- نتایج آزمون گاما در تعیین ترکیب‌های ورودی موثرتر

Table 4- Gamma test results in determining the input composition more effectively

خروجی (EC)		خروجی (Na)		خروجی (Ca)		متغیر غایب در مدل	شماره ترکیب
نسبت v	گاما	نسبت v	گاما	نسبت v	گاما		
۰/۰۱۲۴	۰/۰۰۳۱	۰/۰۲۶۲	۰/۰۰۶۶	۰/۱۲۳۱	۰/۰۳۱۱	-	۱
۰/۰۱۲۶	۰/۰۰۳۲	۰/۰۲۵۸	۰/۰۰۶۵	۰/۱۵۵۲	۰/۰۳۸۸	K	۲
۰/۰۱۷۵	۰/۰۰۴۴	-	-	۰/۲۳۴۵	۰/۰۵۸۶	Na	۳
۰/۰۱۶۳	۰/۰۰۴۱	۰/۰۶۹۵	۰/۰۱۷۴	۰/۲۱۲۷	۰/۰۵۳۲	Mg	۴
۰/۰۱۰۵	۰/۰۰۲۶	۰/۰۳۲۵	۰/۰۰۸۱	۰/۱۶۲۹	۰/۰۴۰۷	SO ₄	۵
۰/۰۱۲۵	۰/۰۰۳۲	۰/۰۴۲۴	۰/۰۱۰۶	۰/۱۴۸۵	۰/۰۳۷۱	Cl	۶
۰/۰۱۲۴	۰/۰۰۳۱	۰/۰۵۳۵	۰/۰۱۳۴	۰/۱۷۵۷	۰/۰۴۳۹	HCO ₃	۷
۰/۰۰۵۰	۰/۰۰۱۳	۰/۰۳۹۲	۰/۰۰۹۸	۰/۱۴۵۰	۰/۰۳۳۱	PH	۸
-	-	۰/۰۳۳۷	۰/۰۰۸۴	۰/۱۳۲۶	۰/۰۳۳۱	EC	۹
۰/۰۱۵۷	۰/۰۰۳۹	۰/۰۹۸۷	۰/۰۲۴۷	-	-	Ca	۱۰

غلظت یون سدیم، غلظت یون منیزیم، غلظت سولفات، غلظت یون کلر، HCO₃، PH، هدایت الکتریکی، غلظت یون کلسیم) می‌باشد. با توجه به مقادیر گاما، در تخمین پارامتر غلظت یون سدیم همه متغیرها به‌غیر از غلظت یون پتاسیم موثر می‌باشند، موثرترین متغیر برای این پارامتر نیز غلظت یون کلسیم است. بنابراین ترکیب مورد استفاده در تخمین پارامتر غلظت یون سدیم شامل غلظت یون کلسیم، غلظت یون منیزیم، HCO₃، غلظت یون کلر، PH، هدایت الکتریکی و غلظت یون سولفات می‌باشد. آزمون گاما پارامترهای غلظت یون سدیم و غلظت یون

نتایج آزمون گاما بیانگر این موضوع است که برای پارامتر خروجی غلظت یون کلسیم، متغیر غلظت یون سدیم با بیشترین مقدار تغییر گاما نسبت به گامای ترکیب اول، به عنوان موثرترین متغیر می‌باشد و پارامترهای غلظت یون منیزیم، HCO₃، غلظت یون سولفات، غلظت یون پتاسیم، غلظت یون کلر، هدایت الکتریکی و PH به‌ترتیب در مرتبه‌های بعدی قرار دارند. طبق نتایج، ترکیب اول که دارای کمترین مقدار گاما می‌باشد، به عنوان ترکیب برتر انتخاب گردیده است. ترکیب اول شامل همه متغیرهای کیفی (غلظت یون پتاسیم،

در ادامه ترکیب‌های برتر هر یک از مدل‌ها در تخمین پارامترهای کیفی غلظت یون کلسیم، غلظت یون سدیم و هدایت الکتریکی (جدول ۴)، با ترکیب کیفی منتخب آزمون گاما برای هر یک از پارامترهای کیفی ادغام گردیده است و ترکیب‌های ورودی جدید را تشکیل داده‌اند (جدول ۵). در این بخش مقادیر پارامترهای کیفی غلظت یون کلسیم، غلظت یون سدیم و هدایت الکتریکی با استفاده از این ترکیب‌های جدید (جدول ۵) مورد تخمین قرار گرفته‌اند که نتایج آنها در جدول ۶ نشان داده شده است.

منیزیم را به ترتیب به‌عنوان موثرترین پارامترها در تخمین هدایت الکتریکی شناسایی کرده است. همانطور که در جدول مشخص شده است، با حذف هر یک از دو متغیر غلظت یون سولفات و PH مقدار ضریب گاما نسبت به حالت مبنا کاهش داشته است. بنابراین بهترین متغیرهای کیفی مورد استفاده در تخمین پارامتر هدایت الکتریکی شامل غلظت یون سدیم، غلظت یون منیزیم، غلظت یون کلسیم، غلظت یون پتاسیم، غلظت یون کلر و HCO_3 می‌باشند.

نتایج مدل‌ها به‌ازای افزودن ترکیب‌های پیشنهادی آزمون گاما

جدول ۵- ترکیب‌های (کمی-کیفی) تعیین شده براساس مدل‌های برتر بخش اول و آزمون گاما

Table 5- Quantitative-qualitative compounds determined on the basis of superior models of the first part and gamma test

متغیرهای ورودی	مدل تخمین‌گر	متغیر خروجی
تراز آب، فاصله از دریا UTMX, UTMY, K, Na, Mg, SO ₄ , Cl, HCO ₃ , PH, EC	ANN	Ca
فاصله از دریا UTMX, UTMY, K, Na, Mg, SO ₄ , Cl, HCO ₃ , PH, EC	SVM	
فاصله از دریا UTMX, UTMY, Mg, SO ₄ , Cl, HCO ₃ , PH, EC, Ca	ANN	Na
تراز آب، فاصله از دریا UTMX, UTMY, Mg, SO ₄ , Cl, HCO ₃ , PH, EC, Ca	SVM	
فاصله از دریا UTMX, UTMY, K, Na, Mg, Cl, HCO ₃ , Ca	ANN	EC
تراز آب، فاصله از دریا UTMX, UTMY, K, Na, Mg, Cl, HCO ₃ , Ca	SVM	

جدول ۶- نتایج مدل‌های ANN و SVM به‌ازای ترکیب‌های به‌دست آمده از ادغام آزمون گاما و ترکیب‌های برتر بخش اول
Table 6- The results of ANN and SVM models for combinations obtained from the integration of gamma test and superior components of the first part


پارامتر	مدل	شماره ترکیب	تعداد نرون بهینه	واسنجی			صحت‌سنجی		
				CC	RMSE	NS	CC	RMSE	NS
Ca	ANN	۴	۸	۰/۸۶۲	۰/۶۱۷	۰/۹۲۹	۰/۸۳۴	۰/۶۶۲	۰/۹۱۴
	SVM	۲	-	۰/۸۵۴	۰/۶۳۷	۰/۹۲۴	۰/۸۳۰	۰/۶۷۱	۰/۹۱۱
Na	ANN	۲	۱۱	۰/۹۸۲	۰/۲۵۶	۰/۹۹۱	۰/۹۶۸	۰/۳۰۵	۰/۹۸۴
	SVM	۴	-	۰/۹۸۳	۰/۲۴۷	۰/۹۹۲	۰/۹۵۷	۰/۳۵۶	۰/۹۷۸
EC	ANN	۲	۱۵	۰/۹۸۱	۵۱/۹۶۳	۰/۹۹۰	۰/۹۸۳	۴۷/۳۴۶	۰/۹۹۱
	SVM	۴	-	۰/۹۸۳	۴۹/۵۵۱	۰/۹۹۱	۰/۹۷۶	۵۵/۴۱۲	۰/۹۸۸

زده‌اند. بنابراین می‌توان از هر یک مدل‌ها با دقت قابل قبولی در تخمین پارامترهای کیفی استفاده کرد. همانطور که در جدول ۶ نشان داده شده است، مدل شبکه عصبی مصنوعی در این بخش عملکرد بهتری را در تخمین مقادیر هر یک از سه پارامتر کیفی

با توجه به جدول ۶ هر یک از دو مدل شبکه عصبی مصنوعی و ماشین بردار پشتیبان به‌ازای ترکیب‌های ورودی جدید معرفی شده، هر یک از پارامترهای کیفی غلظت یون کلسیم، غلظت یون سدیم و هدایت الکتریکی را با دقت بسیار بالایی تخمین

عنوان یک روش خوب و کاربردی در این زمینه معرفی کرد. بنابراین مقادیر هر یک از پارامترهای غلظت یون کلسیم، غلظت یون سدیم و هدایت الکتریکی را می‌توان به‌ازای ترکیب‌های ورودی ذکر شده با دقت بسیار بالا تخمین زد که در این صورت می‌تواند در هزینه‌های آزمایشگاهی تعیین مقادیر این پارامترها صرفه‌جویی گردد. مقادیر مشاهداتی و تخمینی پارامترهای کیفی غلظت یون کلسیم، غلظت یون سدیم و هدایت الکتریکی به‌ازای مدل‌های برتر جدول ۶ در شکل ۴ نشان داده شده است.

مورد مطالعه داشته است. البته تخمین مقادیر غلظت یون سدیم و هدایت الکتریکی نسبت به مقادیر غلظت یون کلسیم با خطای کمتری انجام گرفته است. مقادیر ضرایب نش-ساتکلیف در دوره‌های واسنجی و صحت‌سنجی هر یک از ترکیب‌ها نیز نشان‌دهنده بسیار مناسب بودن تخمین‌های صورت گرفته می‌باشد. همانطور که ذکر گردید یکی از مشکلات اصلی در زمینه تخمین مقادیر کیفی، تعیین تعداد و نوع پارامترهای ورودی می‌باشد که با توجه به نتایج جدول ۶ آزمون گاما را می‌توان به-



شکل ۴- مقادیر مشاهداتی و محاسبه شده پارامترهای کیفی Na، EC و Ca به‌ازای مدل و ترکیب برتر
Figure 4- Observed and calculated values of Na, EC and Ca quality parameters for superior model and composition

نتیجه گیری

با توجه به اهمیت اطلاع از وضعیت و توزیع مقادیر پارامترهای کیفی آبخوان‌ها در مدیریت صحیح منابع آب، در این تحقیق سعی گردید تا با استفاده از مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان مقادیر پارامترهای کیفی غلظت یون کلسیم، غلظت یون سدیم و هدایت الکتریکی آبخوان استان گیلان مورد تخمین قرار گیرد. در این راستا از ساختارهای مختلف مدل‌ها، و دو بخش اصلی ترکیب‌های مختلف ورودی شامل ترکیب‌های ارائه شده در جدول ۲ (بخش اول) و ترکیب‌های کیفی آزمون گاما جدول ۵ (بخش دوم) استفاده گردید.

در تخمین پارامترهای کیفی غلظت یون کلسیم، غلظت یون سدیم و هدایت الکتریکی به ترتیب ترکیب‌های چهار، دو و دو به عنوان ترکیب برتر برای مدل شبکه عصبی مصنوعی انتخاب شد و برای مدل ماشین بردار پشتیبان ترکیب‌های دو، چهار و چهار انتخاب گردید.

مقایسه نتایج مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان به‌ازای ترکیب‌های برتر بخش اول نشان داد که مدل ماشین بردار پشتیبان در تخمین هر یک از سه پارامتر کیفی غلظت یون کلسیم، غلظت یون سدیم و هدایت الکتریکی عملکرد بهتری نسبت به مدل شبکه عصبی مصنوعی داشته است. بنابراین در این بخش می‌توان این مدل را به‌عنوان مدل برتر (ورودی‌های بخش اول) در تخمین کلیه پارامترهای کیفی آبخوان استان گیلان معرفی کرد.

پارامتر فاصله از دریا در تخمین هر یک از سه پارامتر مورد بررسی و در هر یک از مدل‌ها باعث افزایش دقت در تخمین پارامترهای کیفی شده است که با نتایج ارائه شده در مطالعات غلامی و جعفری (۴) و میرزاوند و همکاران (۶) تطبیق دارد. افزودن پارامتر تراز آب چاهک‌ها به ترکیب یک (ترکیب ۳ در جدول ۲) در مدل شبکه عصبی مصنوعی باعث بهبود تخمین هر یک از پارامترهای کیفی گردید که با نتایج میرزاوند و همکاران (۶) همخوانی کامل دارد.

ولی افزودن پارامتر تراز آب در نتایج مدل ماشین بردار پشتیبان اثر منفی داشته است. هم‌چنین نتایج نشان داد،

استفاده از پارامتر فاصله از دریا نسبت به پارامتر تراز آب چاهک‌ها، تاثیر بیشتری در بهبود نتایج مدل شبکه عصبی در تخمین هر یک از سه پارامتر غلظت یون کلسیم، غلظت یون سدیم و هدایت الکتریکی داشته است.

همچنین با توجه به نتایج در هیچ یک از موارد استفاده از متغیر مجموع بارش شش ماهه نمی‌تواند باعث افزایش دقت تخمین پارامترهای کیفی مدنظر گردد. مطالعه غلامی و جعفری (۴) نیز عدم تاثیر بارش در تخمین پارامترهای کیفی را تایید کرده است. مدل ماشین بردار پشتیبان قادر است تا پارامترهای کیفی آبخوان استان گیلان را بدون دخالت دادن سایر پارامترها و با استفاده از کمترین اطلاعات (مختصات چاهک‌های مشاهداتی) با دقت بالاتری نسبت به مدل شبکه عصبی مصنوعی مورد تخمین قرار دهد. در مطالعه آقا و همکاران (۱۰) نیز عملکرد مدل ماشین بردار پشتیبان بهتر از مدل شبکه عصبی بوده است، همچنین عملکرد خوب مدل ماشین بردار پشتیبان در مطالعه عرب‌گل و همکاران (۱۵) در تخمین پارامتر نترات آب-زیرزمینی اراک نیز نشان داده شده است.

نتایج تخمین مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان به‌ازای ترکیب‌های ورودی جدول ۵ (بخش دوم) نشان داد که این مدل‌ها در تخمین هر یک از پارامترهای کیفی غلظت یون کلسیم، غلظت یون سدیم و هدایت الکتریکی دقت بسیار بالایی داشته‌اند. همانطور که در جدول ۶ نشان داده شده است، مدل شبکه عصبی مصنوعی در بخش دوم عملکرد بهتری را نسبت به مدل ماشین بردار پشتیبان در تخمین مقادیر هر یک از سه پارامتر کیفی مورد مطالعه داشته است.

نتایج بخش دوم تخمین‌ها حاکی از عملکرد مناسب آزمون گاما در تعیین ترکیب ورودی پارامترهای کیفی بوده است. با توجه به نتایج بخش دوم، هر یک از پارامترهای غلظت یون کلسیم، غلظت یون سدیم و هدایت الکتریکی را می‌توان به‌ازای ترکیب‌های ورودی جدول ۵ و با دقت بسیار بالاتری نسبت به ترکیب‌های ورودی بخش اول (جدول ۲) تخمین زد. استفاده از مدل‌ها و ترکیب‌های ذکر شده جهت تخمین دقیق و با خطای اندک

- Tabriz University, Vol 10, pp13-25.[In Pearsian]
6. Mirzavand, M, Ghasemiye, H, Akbari. M., Sadatinejad, S., 2015. Simulaytion of Underground Water Quality Changes with Artificial Neural Network Model (Case Study: Kashan Aquifer), Civil Engineering Journal and Environment Engineering Journal of Tabriz University, Vol. 68, pp159-171. [In Persian]
 7. Nadiri, A., Vahedi, F., Asghari Moghadam, A., Kadkhodae, A., 2015, Use of Artificial Intellighence Model Supervised to predicte groundwater level, Civil Engineering and Environmental Engineering Journal of Tabriz University. Vol. 46, pp101-112. [In Persian]
 8. Dehgani, R., Pourhaghi, A., Kheyraei, M., 1395. Compersian of Adaptive Neuro-Fuzzy Inference System Techniques, Artificial Neural Network and Gene Experssion Planning in estimating Groundwater Hardness (Case Study: Mazandaran Plain). New finding in applied geology. 10(19), 51-62.[In Persian]
 9. Cho, K.H., Sthiannopkao, S., Pachepsky, Y.A., Kim, K.W., Kim, J.H., 2011. Prediction of contamination potential of groundwater arsenic in Cambodia, Laos and Thailand using artificial neural network. Journal of Water Research, Vol. 45, PP. 5535-5544.
 10. Alagha, J.S., Said, M.A.M., Mogheir, Y., 2014. Modeling of nitrate concentration in groundwater using artificial intelligence approach- acase study of Gaza coastal aquifer. Vol.186, PP.35-45.
- هر یک از پارامترهای کیفی غلظت یون کلسیم، غلظت یون سدیم و هدایت الکتریکی، می‌تواند باعث کاهش هزینه‌های آزمایشگاهی سازمان‌های مربوطه گردد.
- ### Reference
1. Parmer, K.S., Bhardwaj, R., 2013. Wavelet and statistical analysis of river water quality parameters, Journal of Applied Mthematics and Computation. Vol. 219, PP.10172-10182.
 2. Diamantopoulou, M.J., Antonopoulos, V.Z., Papamichail, D.M., 2005. The use of a neural network technique for the prediction of water quality parameters of Axios River in Northern Greece. Journal of Eur Water, Vol. 11, PP. 55-62.
 3. Mcknight, U.S., Funder, S., Rasmussen, J.J., Finkel, M., Binning, P.J., Bjerg, P.L., 2010. An integrated model for assessing the risk of TCE groundwater contamination to human receptors and surface water ecosystems. Journal of Ecological Engineering, Vol. 36, PP 1126-1137.
 4. Gholami, V., Jafari, M., 2001. Investigating Effective Factors in Groundwater Salinity to Provide Regional Modeling in Mazandaran Shores, Civil Engineering and Environmental Engineering Journal of Tabriz University, Vol. 23, pp 81-87.[In persian]
 5. Mehrdadi, N., Nabi Bid HindI, G., Baghand, A., Zare Abyaneh, H., Abbasi Maedeh, p., 2012. Projection of changes in the electrical conductivity parameter in underground water in Tehran using artificial neural network , Civil engineering and environmental engineering Journal of

- forecasting using artificial neural networks with stopped training approach. *Journal of Hydrology*, Vol. 230, PP. 244-257.
18. ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. 2000. Artificial neural networks in hydrology. I preliminary concepts. *Journal of Hydrologic Engineering*, Vol.5, PP.115-123.
 19. Dibike, Y., Velickov, S., Solomatine, D., Abbott, M., 2001. Model induction with of support vector machines: Introduction and applications. *Journal of Computing in Civil Engineering*, Vol. 15, PP. 208- 216.
 20. Yoon, H., Jun, S.C., Hyun Y., Bae, G.O., Lee, K.K., 2011. A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. *Journal of Hydrology*, Vol. 396, PP. 128-138.
 21. Isazadeh, M., Biazar, S. M., Ashrafzadeh, A., 2017. Support vector machines and feed-forward neural networks for spatial modeling of groundwater qualitative parameters. *Environmental Earth Sciences*, 76(17), 610.
 22. Kavzoglu, T., Colkesen, I., 2009. A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, Vol. 11, PP. 352-359.
 23. Ashrafzadeh, A., Malik, A., Jothiprakash, V., Ghorbani, M. A., Biazar, S. M., 2018. Estimation of daily pan evaporation using neural networks and meta-heuristic approaches. *ISH Journal of Hydraulic Engineering*, 1-9.
 11. Kheradpisheh, Z., Talebi, A., Rafati L., Ghaneian, M.T., Ehrampoush, M.H., 2015. Groundwater quality assessment using artificial neural network: A case study of Bahabad plain. Yazd, Iran. *Journal of Desert*, Vol. 20, PP. 65-71.
 12. Khaki, M., Yusoff, I., Islami N., 2015. Application of the Artificial Neural Network and Neuro-fuzzy System for Assessment of Groundwater Quality. *Journal of Clean Soil Air Water*, Vol. 43, PP. 551-560.
 13. Gong, Y., Zhang, Y., Lan, S., Wang, H., 2016. A Comparative Study of Artificial Neural Networks, Support Vector Machines and Adaptive Neuro Fuzzy Inference System for Forecasting Groundwater Levels near Lake Okeechobee, Florida. *Water Resources Management*, Vol. 30, PP. 375-391.
 14. Ehteshami, M., Dolatabadi Farahani, N., Tavassoli S., 2016. Simulation of nitrate contamination in groundwater using artificial neural networks. *Modeling Earth Systems and Environment*, Vol. 28, PP. 2-10.
 15. Arabgol, R., Sartaj, M., Asghari, A., 2016. Prediction Nitrate Concentration and Its Spatial Distribution in Groundwater Resources Using Support Vector Machines (SVMS) Model. *Journal of Environmental Modeling & Assessment*, Vol. 21, PP. 71-82.
 16. Dawson, C.W., Abrahart, R.J., Shamseldin, A.Y. and Wibly, R.L., 2006. Flood estimation at ungauged sites using artificial neural networks. *Journal of Hydrology*, Vol. 319, PP. 391-409.
 17. Coulibaly, P., Anctil, F., Bobée, B., 2000. Daily reservoir inflow

26. Misra, D., Oommen, T., Agarwal, A., and Mishra, S.K., 2009. Application and analysis of Support Vector machine based simulation for runoff and sediment yield. *Journal of Biosystems Engineering*, Vol.103, PP. 527-535.
24. Durrant, P.J., 2001. Win_Gamma TM A non-linear data analysis and modeling tool with applications to flood prediction. PhD Thesis, Department of Computer Science, Cardiff University Wales, UK.
25. Evans, D., Jone, A., 2002 A proof of the gamma test. *Proceedings of Royal Society, Series A*, Vol. 458, PP. 2759-2799.