

قیاس روش‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان در پیش‌بینی پارامترهای کیفیت آب رودخانه دیناچال

سینا اسدپور لمر^۱، کیومرث ابراهیمی^{*۲}

۱ فارغ التحصیل کارشناسی ارشد مهندسی منابع آب، گروه مهندسی آبیاری و آبادانی، دانشگاه تهران. Sina.Asadpour@ut.ac.ir
*۲ استاد گروه مهندسی انرژی‌های نو و منابع پایدار، دانشکده‌گان علوم و فناوری‌های میان رشته‌ای، دانشگاه تهران * نویسنده مسئول
(EbrahimiK@ut.ac.ir)

چکیده

پیش‌بینی پارامترهای کیفیت آب نقش بسیار مهمی در پایش اکوسیستم رودخانه‌ها و پایداری آن ایفا می‌کند. از طرفی، مدل‌های پیش‌بینی سنتی به‌خوبی ذات غیرخطی و غیرایستای متغیرهای کیفیت آب را نشان نمی‌دهند. در سال‌های اخیر، توسعه سریع شبکه‌های عصبی مصنوعی بحث‌های مرتبط با پیش‌بینی کیفیت آب را متحول نموده است. در این مطالعه، پارامترهای کیفی رودخانه دیناچال به‌عنوان یکی از رودخانه‌های حیاتی در استان گیلان مورد ارزیابی و پیش‌بینی قرار گرفته است. دو مدل مبتنی بر شبکه عصبی مصنوعی و ماشین بردار پشتیبان رگرسیونی، نه پارامتر کیفی کل مواد جامد محلول، هدایت الکتریکی، اسیدیته، Cl، SO₄، HCO₃، Ca، Mg و Na با گام‌های زمانی یک ماه طی سال‌های ۱۳۸۵ تا ۱۳۹۷ پیش‌بینی شد و کارایی مدل‌ها توسط آماره‌های ارزیابی RMSE، MSE و MAPE بررسی و مقایسه شد. طبق نتایج به‌دست آمده، مدل SVR به‌ترتیب با (RMSE=۲/۰۳) و (RMSE=۰/۰۶۲) کارایی بهتری در پیش‌بینی کل مواد جامد محلول و غلظت منیزیم نسبت به مدل شبکه عصبی مصنوعی نشان داد. از طرف دیگر، مدل شبکه عصبی مصنوعی در پیش‌بینی پارامترهای دیگر نسبتاً موفق‌تر بود. باین‌حال، کارایی هر دو مدل در پیش‌بینی پارامترهای کیفی رودخانه دیناچال مناسب ارزیابی شد. همچنین مدل SVR با ضریب MAPE برابر با ۰/۰۰۷ و مدل شبکه عصبی مصنوعی با ضریب MAPE برابر با ۰/۰۰۱ در پیش‌بینی پارامترهای کل مواد جامد محلول و هدایت الکتریکی بهترین کارایی را داشتند. در مقابل، هر دو مدل SVR و ANN در پیش‌بینی پارامتر کلر ضعیف‌ترین کارایی را با وجود RMSE ۰/۰۵۵ و ۰/۰۵۲ از خود نشان دادند. روش‌های به‌کار گرفته شده در این مطالعه می‌تواند در پیش‌بینی کیفیت آب دیناچال مؤثر واقع شود.

کلیدواژه: پیش‌بینی کیفیت آب، شبکه عصبی مصنوعی، ماشین بردار پشتیبان، رود دیناچال

Comparison of Artificial Neural Network Methods and Support Vector Machine in Predicting Water Quality Parameters of Dinachal River, IRAN

S. Asadpour Lomer¹ , K. Ebrahimi^{*2} 

1. Graduated MSc Student of Water Resources Engineering, Irrigation and Reclamation Engineering Department, Faculty of Agricultural Engineering, College of Agriculture & Natural Resources, University of Tehran, Karaj, Iran

(Sina.Asadpour@ut.ac.ir)

*2. Professor, Department of Renewable Energies and Sustainable Resources Engineering, University of Tehran, Tehran, Iran.

(EbrahimiK@ut.ac.ir) (Corresponding Author)

Abstract

Predicting water quality parameters plays a crucial role for monitoring of ecosystems of rivers and their sustainability. Alongside this, conventional prediction models are not able to capture the non-linearity and non-stationary inherence of water quality datasets. In recent years, the rapid development of machine learning methods has transformed the water quality prediction fields. In this study, water quality parameters for the Dinachal River in Guilan province have been assessed and predicted. Two models based on Artificial Neural Networks (ANN) and Support Vector Regression (SVR) were utilized to predict nine water quality parameters as TDS, EC, Ph, Cl, SO₄, HCO₃, Ca, Mg, and Na with monthly timesteps between 2006 and 2018. Then, the model's performance was evaluated using RMSE, MSE, and MAPE indices. According to the results, the SVR model was superior in predicting TDS and Mg parameters with an RMSE Index of 2.03 and 0.062, respectively. Simultaneously, ANN had a slightly better accuracy in the prediction of remaining parameters. However, prediction results for both models in the case study were satisfactory. In addition, the SVR model predicted TDS with a MAPE of 0.007, which was the best compared to other parameters.

At the same time, the ANN model had better performance in predicting EC with a MAPE of 0.001. Prediction results for CI had also the lowest accuracy among water quality parameters with an RMSE of 0.055 and 0.052 for SVR and ANN, respectively. Methods utilized in this study can be effective in predicting water quality parameters of Dinachal river.

Keywords: ANN, Dinachal River, SVR, Water Quality Prediction.

مقدمه

با توجه به افزایش روزافزون جمعیت و گسترش شهرها و روستاها و در نتیجه افزایش نیاز مصرف و برداشت از آب سطحی و زیرزمینی، توجه به حفاظت و صیانت از این منابع ارزشمند بیش از گذشته اهمیت پیدا کرده است (ستاری و همکاران، ۱۳۹۲). رودخانه‌ها همواره از مهم‌ترین منابع تأمین آب شرب و کشاورزی هستند که نقش به‌سزایی در تأمین سلامت انسان و محیط‌زیست دارند؛ اما امروزه با تخلیه انواع مختلف آلاینده‌های کشاورزی، صنعتی و پساب‌های شهری به رودخانه‌ها موجب شده که این منابع مهم، گاهی اوقات به‌عنوان یکی از مراکز بحرانی آلودگی‌ها مطرح باشند (شاهی نژاد و همکاران، ۱۴۰۰). به‌طور معمول آب‌های سطحی بیش‌تر از بقیه آب‌ها در برابر آلودگی‌های محیطی آسیب‌پذیر هستند؛ بنابراین به‌دلیل افزایش معنادار منابع آلودگی، پایش مستمر و پیش‌بینی وضعیت کیفیت این منابع از اهمیت به‌سزایی برخوردار است (ویسی و همکاران، ۱۳۹۶). به‌منظور ارزیابی کیفیت آب‌های سطحی در دوره‌های زمانی گوناگون، از این منابع نمونه‌برداری می‌شود و سپس در آزمایشگاه‌های سنجش کیفیت آب، میزان پارامترهای کیفی مختلف در آن‌ها اندازه‌گیری و مورد ارزیابی قرار می‌گیرند. به‌عبارتی‌دیگر سنجش و ارزیابی پارامترهای کیفی حوضه‌های آبریز امری ضروری است (Huang et al., 2018). از طرفی، مدل‌های پیش‌بینی سنتی به‌خوبی ذات غیرخطی و غیر ایستای متغیرهای کیفیت آب را نشان نمی‌دهند. در این خصوص تمرکز بر روش‌های مختلف پایش و پیش‌بینی کیفی رودخانه‌ها که مبتنی بر الگوهای گوناگون ریاضی هستند و با کمک یادگیری ماشین‌ها توسعه داده شده است (Mahapatra et al., 2011).

در ادامه، سوابق مطالعاتی داخلی و خارجی مرتبط با تحقیق حاضر تشریح می‌شود و پس از معرفی منطقه مطالعاتی، مواد و روش‌های به‌کاررفته در این پژوهش بیان می‌شود. در انتها نیز نتایج به‌همراه نتیجه‌گیری نهایی این پژوهش ارائه می‌شود.

وضعیت خشک‌سالی ایستگاه سینوپتیک شهر سقز را به‌عنوان یکی از مهم‌ترین ایستگاه‌های جنوبی حوضه آبریز دریاچه ارومیه، با استفاده از شاخص بارش - تبخیر و تعرق استاندارد شده^۱ (SPEI) و مدل ماشین بردار پشتیبان (SVM) بررسی شد. نتایج نشان داد در هر دو روش مذکور، با استفاده از پنج گام زمانی خروجی‌های مدل دقیق‌تر و بهینه‌تر است. همچنین دقت پیش‌بینی هر دو مدل رابطه مستقیمی با افزایش مقیاس شاخص تبخیر و تعرق استاندارد شده دارد (عباسی و همکاران، ۱۳۹۷).

برای پیش‌بینی فصلی پارامترهای هدایت الکتریکی و یون کلر، از مدل خود هم‌بسته متحرک فصلی انباشته^۲ (SARIMA) استفاده شد. نتایج نشان داد که پارامترهای هدایت الکتریکی و غلظت یون کلر، دارای تناوب فصلی ۱۲ ماهه و فاقد مؤلفه روند هستند. همچنین پیش‌بینی‌های این مدل از لحاظ آماری با مقادیر ثبت‌شده، تفاوت معناداری ندارد (جمالی و ابراهیمی، ۱۳۹۰).

با استفاده از پارامترهای نسبت جذب سدیم و یون کلر، روش‌های ماشین بردار پشتیبان و شبکه عصبی را یکدیگر مقایسه شدند. نتایج نشان داد که مدل بردار پشتیبان نسبت به روش شبکه عصبی ضریب همبستگی بالاتری دارد و همچنین ریشه میانگین مربعات خطا

^۱ Standardized Precipitation Evapotranspiration Index

^۲ Seasonal Autoregressive Integrated Moving Average

کمتری دارد و در نهایت مدل بردار پشتیبان برای پیش‌بینی کیفیت و مقادیر پارامترهای کیفی رودخانه سفیدرود پیشنهاد می‌شود (حسین‌پناهی و همکاران، ۱۴۰۰).

به‌منظور پیش‌بینی غلظت اکسیژن محلول رودخانه ساواناه امریکا، از روش‌های یادگیری عمیق و یادگیری ماشین استفاده شد و نتایج حاصل از هر دو روش با یکدیگر قیاس شد. نتایج نشان داد با حذف پارامتر دمای آب؛ سنج‌های ارزیابی به میزان ۱۴ درصد کاهش و مقدار خطا ۱۰۰ درصد افزایش داشته است. بنابراین دمای آب به‌عنوان تأثیرگذارترین پارامتر در پیش‌بینی اکسیژن محلول در آب معرفی شد (روشنگر و داودی، ۱۴۰۱).

جریان رودخانه باراندوزچای با روش‌های برنامه‌ریزی ژنتیک و ماشین بردار پشتیبان پیش‌بینی شد. نتایج نشان داد که میزان دقت پیش‌بینی در هر دو روش تفاوت معناداری نداشته و همچنین میزان دقت در هر دو روش رابطه غیرمستقیمی با افزایش مقدار جریان عبوری رودخانه دارد. به این مفهوم که با افزایش مقدار جریان عبوری رودخانه، میزان دقت در هر دو روش کاهش می‌یابد. به دلیل عدم تفاوت معنادار در میزان دقت در هر دو مدل، روش بردار پشتیبان به دلیل سهولت در اجرا نسبت به روش برنامه‌ریزی ژنتیک، برای استفاده پیشنهاد می‌شود (احمدی و همکاران، ۱۳۹۳).

غلظت پتاسیم موجود در شورابه‌های پلائیای شهرستان خور بیابانک اصفهان، با استفاده از روش بردار پشتیبان و جنگل تصادفی پیش‌بینی شد و میزان تأثیر پارامترهای مختلف بر یکدیگر، مورد بررسی قرار گرفت. نتایج نشان داد ضریب تعیین برای هر دو مدل به ترتیب ۰/۹۹ و ۰/۹۷ بوده که بیانگر دقت بالا در هر دو روش است (ایرجی و همکاران، ۱۴۰۲).

با ترکیب مدل‌های ماشین بردار پشتیبان و الگوریتم‌های بهینه‌سازی، پارامترهای کیفیت آب رودخانه کلانگ مالزی مطالعه شد. در این پژوهش برای نخستین بار شاخص کیفیت آب (WQI) با ترکیب مدل‌های مذکور بهینه‌سازی شد که نتایج نشان داد، مدل بردار پشتیبان نسبت به سایر روش‌های مورد استفاده در این تحقیق، ریشه میانگین مربعات خطای کمتر و سهولت اجرای بیشتری دارد (SeeLeng et al., 2018).

با استفاده از روش بردار پشتیبان و با بهره‌گیری از پانزده پارامتر کیفیت آب رودخانه وادی صف صف واقع در کشور الجزایر، میزان دقت پیش‌بینی پارامترهای مختلف و عملکرد مدل ارزیابی شد. **طبق خروجی‌های مدل با اعداد (همبستگی در مرحله آموزش ۰/۸۲) و (ریشه میانگین مربعات خطا در مرحله آموزش ۵/۱۷) و (همبستگی در مرحله آزمون ۰/۸۱) و (ریشه میانگین مربعات خطا در مرحله آزمون ۵/۵۵)، می‌توان به پیش‌بینی بهینه مدل در هر دو مرحله آموزش و آزمون اذعان داشت.** همچنین با کاهش تعداد متغیرهای ورودی، دقت مدل افزایش می‌یابد (Sakka et al., 2022).

از مدل بردار پشتیبان، برای پیش‌بینی کیفیت آب رودخانه لگات در کشور مالزی استفاده شد. از طریق تجزیه و تحلیل شش پارامتر کیفی، تحت دو سناریوی متفاوت، مقادیر اکسیژن محلول (DO) را پیش‌بینی شد. نتایج نشان داد ضریب همبستگی بین پارامترهای پیش‌بینی شده ۰/۹۱ تا ۰/۹۴ است و میزان خطا در این مدل‌سازی برابر با ۰/۰۱۶ است (Yahya et al., 2019).

برای پایش و حفاظت از کیفیت آب رودخانه و مدل‌سازی کیفیت آب، از مدل ماشین بردار پشتیبان (SVM) و شبکه عصبی مصنوعی (ANN)، جهت پیش‌بینی کل مواد جامد و کل جامدات معلق استفاده شد. نتایج نشان داد که میزان ریشه میانگین مربعات خطا در روش بردار پشتیبان نسبت به روش شبکه عصبی مصنوعی کمتر و میزان همبستگی خروجی برای پارامتر کل مواد جامد معلق در روش شبکه عصبی مصنوعی بیشتر از روش ماشین بردار پشتیبان است (Rizal et al., 2022).

با به‌کارگیری یک رویکرد مبتنی بر ماشین بردار پشتیبان با ادغام الگوریتم شبکه عصبی جهت طبقه‌بندی کیفی رودخانه چائو فرامیا با استفاده از پارامترهای کیفیت آب از جمله نیترات و شوری و کل مواد جامد، توابع ریاضی بهینه و مناسب این امر بررسی شد. نتایج نشان داد، با افزایش تعداد توابع ریاضی به‌کاررفته در مدل‌سازی، میزان دقت طبقه‌بندی کیفیت آب نیز افزایش می‌یابد. همچنین کم‌ترین میزان دقت شبیه‌سازی مربوط به پارامتر نیترات عنوان شد (Sillberg et al., 2021).

به‌منظور پیش‌بینی پارامترهای کیفیت آب رودخانه داهیتینگ، از روش شبکه عصبی مصنوعی استفاده شد. با داشتن مقادیر پارامترهای کیفی آب رودخانه، مقادیر کل نیتروژن و کل فسفر پیش‌بینی شد. نتایج نشان داد میزان همبستگی پارامتر کل نیتروژن از مقدار همبستگی پارامتر کل فسفر بیشتر و برابر با ۰/۹۴ است (Yan et al., 2021).

با استفاده از روش شبکه عصبی مصنوعی، امکان پیش‌بینی پارامترهای کیفیت آب و تاثیر پذیری از ویژگی‌های کاربری زمین، با رویکردی تحقیقی بررسی و ارزیابی شد. نتایج نشان داد که میزان خطای پیش‌بینی پارامترهای کیفیت آب با این روش برابر با ۰/۶۷ است (Gorashi et al., 2012).

به‌منظور بررسی و پیش‌بینی کیفیت آب رودخانه هایبه و با استفاده از روش شبکه عصبی مصنوعی، پارامترهای کیفیت آب این رودخانه بررسی و شبیه‌سازی شد. در اولین ارزیابی کیفی رودخانه، برخلاف انتظار، مقادیر اکسیژن محلول کم‌تر و نیتروژن کل بیشتر از تصور بود که دلیل آن وقوع پدیده دنیتریفیکاسیون اعلام شد. نتایج نشان داد، ضریب همبستگی برای پارامتر اکسیژن محلول از بقیه پارامترها بیشتر و برابر با ۰/۷۹ است (Li et al., 2023).


با توجه به وابستگی فعالیت‌های صنعتی، کشاورزی، تأمین آب شرب و زیست‌محیطی شهرستان رضوانشهر و شهر پره‌سر به جریان‌های آبی رودخانه دیناچال، پایش و پیش‌بینی شاخصه‌های کیفی این رودخانه از اهمیت ویژه‌ای برای ساکنان این منطقه برخوردار است. در این راستا در تحقیق حاضر از روش‌های پیشرفته مبتنی بر یادگیری ماشین‌ها و به‌منظور تدقیق بیشتر از دو روش شبکه عصبی مصنوعی^۱ (ANN) با کمک کد نویسی متلب و روش ماشین بردار پشتیبان^۲ (SVM) با کمک کد نویسی پایتون استفاده شده است. سپس نتایج با داده‌های مشاهداتی مقایسه و ارزیابی شده است. در این مطالعه، ارزیابی مقایسه‌ای کارایی دو مدل ماشین بردار پشتیبان و شبکه عصبی مصنوعی در پیش‌بینی پارامترهای کیفی رودخانه دیناچال مورد بحث است که در آن نه پارامتر کیفی مورد پیش‌بینی قرار گرفته و توسط شاخص‌های مختلف ارزیابی شده است.

^۱ Artificial Neural Network

^۲ Support Vector Machine

مواد و روش‌ها

همانطور که در بخش پیشینه پژوهش مطرح شد، در پژوهش حاضر نه پارامتر مهم کیفی از رودخانه دیناچال مورد ارزیابی قرار گرفته است. در این خصوص از دو روش مبتنی بر یادگیری ماشین استفاده شده است. نتایج پیش‌بینی به‌وسیله داده‌های ارزیابی با یکدیگر مقایسه شد. در این بخش ضمن تشریح منطقه مطالعاتی، جمع‌آوری داده و هر دو روش شبکه عصبی مصنوعی (ANN) با کمک کدنویسی متلب و روش ماشین بردار پشتیبان (SVM) با کمک کدنویسی پایتون تشریح شده است. شکل ۱ مراحل تحقیق حاضر را نمایش می‌دهد.




شکل ۱. مراحل تحقیق

منطقه مطالعاتی

رودخانه دیناچال یکی از رودخانه‌های دائمی غرب استان گیلان و در محدوده شهر پره‌سر از شهرستان رضوانشهر است. موقعیت جغرافیایی این شهرستان با طول شرقی ۴۸ درجه و ۴۰ دقیقه تا ۴۹ درجه و ۱۳ دقیقه و عرض شمالی بین ۳۷ درجه و ۲۵ دقیقه تا ۳۷ درجه و ۴۰ دقیقه است (امینی و همکاران، ۱۳۹۳). این رودخانه در حوضه اصلی دریای کاسپین و در حوضه درجه دو تالش و مرداب انزلی واقع شده است. محدوده مطالعاتی تحقیق حاضر، شامل بخشی از رودخانه دیناچال واقع در حدفاصل پل اتوبان رشت به آستارا و بین روستاهای دیناچال و سیمبرخاله است. حوضه آبریز رودخانه دیناچال بین حوضه‌های آبریز سفارود و ناورود واقع شده است. در این حوضه ایستگاه‌های تبخیرسنجی، باران‌سنج معمولی، باران‌سنج ذخیره‌ای ثابت و ایستگاه‌های برف‌سنجی فعال است.

(محمدی قلعه‌نی و همکاران، ۱۳۹۴). طبق شکل ۲ و جدول شماره ۱، موقعیت مکانی دقیق ایستگاه نمونه‌برداری نمایش داده شده است.



شکل ۲. نقشه موقعیت مکانی ایستگاه نمونه برداری در رودخانه دیناچال

جدول ۱. اطلاعات موقعیت مکانی ایستگاه نمونه‌برداری در رودخانه دیناچال

ارتفاع از سطح دریا (متر)	عرض جغرافیایی	طول جغرافیایی
۱۰	۳۷°۳۷'۳۰"	۴۹°۰۲'۲۷"

در مطالعه حاضر، داده‌های ماهانه کیفیت آب رودخانه دیناچال در دوره‌ی آماری موجود از سال ۱۳۸۵ تا ۱۳۹۷ از شرکت مدیریت منابع آب ایران تهیه شد و به‌منظور پیش‌بینی نه پارامتر کیفی TDS، EC، pH، یون سدیم، کلسیم، منیزیم، سولفات، کلر و کربنات با دو روش مبتنی بر یادگیری ماشین: ۱. شبکه عصبی مصنوعی (ANN) و ۲. ماشین بردار پشتیبان (SVM) مورد استفاده قرار گرفت. در این مطالعه از ۷۰ درصد داده‌ها برای آموزش مدل و از ۳۰ درصد باقیمانده برای صحت سنجی مدل استفاده شد. در ضمن، برای پیش‌بینی هر یک از پارامترهای معرفی شده، تعداد هشت پارامتر به‌عنوان ورودی مدل و پارامتر دیگر به‌عنوان خروجی یا هدف در نظر گرفته شد. ایستگاه مورد استفاده جهت استخراج داده‌ها و بررسی آماری آن، ایستگاه دیناچال به طول و عرض جغرافیایی "۳۷°۳۷'۳۰" و "۴۹°۰۲'۲۷" و ارتفاع ۱۰ متر از سطح آب‌های آزاد است. خصوصیات آماری داده‌های کیفی رودخانه در دوره آماری موردنظر در جدول ۲ قابل مشاهده است.

جدول ۲. ویژگی‌های آماری پارامترهای کیفی داده‌های ماهانه ایستگاه دیناچال در رودخانه دیناچال (۱۳۸۵-۱۳۹۷)

TDS	EC	pH	HCO ₃	Cl	SO ₄	Ca	Mg	Na	پارامتر
mg/l	ds/m	-	mg/l	mg/l	mg/l	mg/l	mg/l	mg/l	واحد
				۱۴۴					تعداد
۲۰۸/۵۹	۳۳۱/۱۵۳	۷/۷۳۸	۲/۷۸۰	۰/۲۲۷	۰/۲۹۸	۲/۳۸۱	۰/۶۵۰	۰/۲۵۲	میانگین
۴۳/۵۹	۶۹/۱۶۸	۱/۲۳۲	۰/۵۹۷	۰/۰۸۵	۰/۱۴۵	۰/۵۶۲	۰/۳۷۵	۰/۰۶۵	انحراف معیار
۹۹/۵۴	۱۵۸	۶/۷۰	۱/۰۰۰	۰/۱۰۰	۰/۰۸۰	۱/۲۰۰	۰/۱۹۰	۰/۰۴۰	کمینه
۱۸۲/۹۲	۲۹۳	۷/۱۵	۲/۵۰۰	۰/۱۹۸	۰/۲۰۸	۱/۹۹۳	۰/۴۵۰	۰/۲۲۰	%۲۵
۲۱۱/۵۲	۳۳۵/۵	۷/۵۶	۲/۸۶۵	۰/۲۰۰	۰/۲۷۰	۲/۴۳۰	۰/۶۱۰	۰/۲۶۰	%۵۰
۲۲۹/۰۰	۳۶۳/۲۵	۷/۹۱	۳/۰۶۰	۰/۲۵۰	۰/۳۳۳	۲/۷۰۰	۰/۸۱۰	۰/۲۹۰	%۷۵
۳۸۰/۰۰	۶۰۲	۱۵/۲۹	۴/۹۰۰	۰/۶۰۰	۰/۹۸۰	۴/۵۵۰	۱/۵۶۰	۰/۴۸۰	بیشینه

شبکه عصبی مصنوعی (ANN)

در این مطالعه، برای تخمین پارامترهای کیفی رودخانه دیناچال از یک شبکه عصبی مصنوعی استفاده شد. در واقع ANN شبکه‌ای از عناصر به هم پیوسته است که از مطالعات شبیه‌سازی مغز بیولوژیکی الهام گرفته شده است و می‌تواند با شناسایی الگوهای مشابه، سری زمانی را پیش‌بینی کند (Gorashi et al., 2012). شبکه‌های عصبی مدل‌های انعطاف‌پذیری هستند که کاربرد خود را در طیف گسترده‌ای از مسائل منابع آب نشان داده‌اند. مطابق بسیاری از مطالعات، شبکه‌های عصبی از مدل‌های کلاسیک عملکرد بهتری ارائه داده‌اند (Banejad et al., 2011). در پژوهش حاضر، از نرم‌افزار MATLAB 2019-a برای توسعه شبکه عصبی استفاده شد. یک شبکه عصبی پیش‌خور ۱ دلیله‌ای با دو تابع انتقال مختلف توسط الگوریتم لونیبرگ-مارکواریت آموزش داده شد؛ به طوری که از تابع سیگموئید در لایه پنهان و از تابع خطی در لایه پنهان خروجی استفاده شد. شبکه عصبی پیش‌خور از ساده‌ترین انواع شبکه عصبی است و به شبکه‌ای از لایه‌ها و نورون‌ها اطلاق می‌شود که اطلاعات در آن فقط روبه‌جلو حرکت می‌کند و حلقه‌ای تشکیل نمی‌شود. ساختار شبکه عصبی استفاده‌شده در این مطالعه شامل هشت ورودی، ۱۰ نورون در لایه پنهان، یک نورون در لایه پنهان خروجی و یک خروجی است که همان متغیر پیش‌بینی شده است. ساختار شبکه مطابق شکل ۲ است. برای آموزش مدل از ۷۰٪ داده‌ها به صورت تصادفی و برای صحت سنجی و آزمودن مدل به ترتیب ۱۵٪ و ۱۵٪ داده‌ها بکار گرفته شد.

ماشین بردار پشتیبان (SVM)

مفهوم ماشین بردار پشتیبان (SVM) برای اولین بار توسط Vapnik و همکارانش در سال ۱۹۹۵ ارائه شد. کاربرد اصلی SVM در مسائل کلاسه‌بندی و پیش‌بینی داده‌ها است. در ادبیات فنی، وقتی از الگوریتم‌های SVM به منظور طبقه‌بندی داده‌ها استفاده شود اختصاراً SVC و زمانی که برای کاربردهای رگرسیونی استفاده شود آن را SVR نامیده‌اند. بردارهای پشتیبان در واقع نقاطی هستند که ضرایب لاگرانژ^۳ غیر صفر دارند. مفهوم تابع زیان ϵ -insensitive در SVR برای ارزیابی تابع رگرسیونی استفاده می‌شود.

^۱ Feed Forward

^۲ Levenberg-Marquardt Algorithm

^۳ Lagrange Multiplier

اصلی‌ترین هدف SVR یافتن تابع $f(x)$ است که در آن ϵ دارای بیشترین انحراف از داده‌های هدف y_i بوده و از داده‌های آموزشی به‌دست‌آمده باشد (Rohmah et al., 2021). زمانی که اپسیلون برابر با صفر شود بهترین رگرسیون به دست خواهد آمد. بالعکس، مقادیر زیاد اپسیلون بیانگر دقت پایین رگرسیون است. فرمولاسیون SVR به‌صورت تابع (۱) است.

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

$\phi(x)$ نتایج نگاشته شده‌ی تابع T در فضای داده‌های ورودی است. همچنین w بعد بردار وزنی و b میزان انحراف است. ضرایب w و b از طریق کمینه‌سازی تابع ریسک تعریف‌شده در معادله‌ی (۲) تخمین زده می‌شوند.

$$R = \min \|w\|^2 + C \frac{1}{l} \left(\sum_{i=1}^l L_{\epsilon}(y_i, f(x_i)) \right) \quad (2)$$

که R تابع ریسک و C مقدار خطا است.

برای حل مسائل رگرسیونی، هنگامی که داده‌ها الگوی غیرخطی دارند از توابع کرنل استفاده می‌شود.

برخی از توابع کرنل رایج عبارت‌اند از کرنل خطی^۱، چندجمله‌ای^۲ و تابع پایه شعاعی گاوسی^۳ که در این مدل از تابع کرنل خطی مطابق رابطه‌ی ۳ استفاده شد.

$$K(x_i, x) = (x_i^T \cdot x + 1)^d, \quad d = 1, 2, \dots \quad (3)$$

که در آن d نشان‌دهنده درجه‌ی چندجمله‌ای است.

به‌منظور تشکیل مدل SVR جهت پیش‌بینی پارامترهای کیفی موردنظر، از کتابخانه scikit-learn استفاده شد (Pedregosa et al., 2021).

معیارهای ارزیابی کارایی مدل

پس از پیش‌بینی پارامترهای کیفی، کارایی مدل‌ها توسط معیارهای مختلفی از جمله^۴ MSE،^۵ RMSE و^۶ MAPE ارزیابی شد. معیار میانگین مربعات خطا MSE یک مقدار همیشه مثبت است که از مربع فاصله‌ی اقلیدسی بین مقادیر پیش‌بینی‌شده و داده‌های مشاهداتی به دست می‌آید. هرچه مقدار MSE کوچک‌تر باشد، دقت مدل پیش‌بینی کننده بیشتر است و داده‌های پیش‌بینی‌شده همخوانی بیشتری با مقادیر مشاهداتی دارند. مقدار MSE از رابطه (۴) به دست می‌آید:

$$MSE = \frac{1}{n} \sum (X - X')^2 \quad (4)$$

^۱ Linear

^۲ Polynomial

^۳ Gaussian radial basis function

^۴ Mean Squared Error

^۵ Root Mean Square Error

^۶ Mean Absolute Percentage Error

که در آن n تعداد داده‌ها، X مقدار مشاهداتی و X' مقدار پیش‌بینی شده پارامتر موردنظر است. ریشه دوم میانگین مربعات خطا (RMSE) نیز مجذور MSE است که تمرکز داده‌ها پیرامون بهترین خط برازش داده‌شده را اندازه‌گیری می‌کند و از رابطه‌ی (۵) محاسبه می‌شود.

$$RMSE = \sqrt{\frac{1}{n} \sum (X - X')^2} \quad (5)$$

علاوه بر موارد فوق، شاخص MAPE به‌منظور قیاس عملکرد مدل‌ها در مقیاس پارامترهای کیفی به‌کاررفته گرفته شد و مطابق رابطه (۶) است.

$$MAPE = \frac{1}{n} \sum \frac{|X - X'|}{X} \quad (6)$$

نتایج و بحث

مدل‌های پیش‌بینی SVR و ANN به ترتیب توسط کتابخانه پایتون SK-Learn و نرم‌افزار متلب ایجاد شدند و نه پارامتر کیفی TDS، EC، pH، HCO₃، Cl، SO₄، Ca و Mg و Na از داده‌های ماهانه رودخانه دیناچال – ایستگاه دیناچال مورد پیش‌بینی قرار گرفت. سپس عملکرد هر مدل برای هر یک از پارامترها توسط معیارهای ارزیابی RMSE، MSE و MAPE مقایسه شد. برای پیش‌بینی هر پارامتر، هشت پارامتر دیگر به‌عنوان ورودی مدل‌ها در نظر گرفته شد و پارامتر موردنظر به‌عنوان تابع هدف به مدل معرفی شد. برای مثال به‌منظور پیش‌بینی پارامتر TDS، پارامترهای EC، pH، HCO₃، Cl، SO₄، Ca، یون کلسیم، منیزیم و سدیم به‌عنوان ورودی و جهت آموزش مدل استفاده شد. همان‌طور که ذکر شد، در هر دو مدل ANN و SVR از ۷۰٪ داده‌ها برای آموزش مدل و ۳۰٪ داده‌ها به‌صورت کاملاً تصادفی برای صحت‌سنجی و آزمودن مدل در نظر گرفته شد. در جدول ۳ نتایج کارایی هر مدل برای پیش‌بینی پارامترهای فوق‌الذکر قابل مشاهده است.


جدول ۳. قیاس عملکرد روش SVM و ANN به‌منظور پیش‌بینی پارامترهای کیفی رودخانه دیناچال با استفاده از معیارهای RMSE، MSE و MAPE

ماشین بردار پشتیبان (SVM)			شبکه عصبی مصنوعی (ANN)			پارامتر کیفی
MAPE	MSE	RMSE	MAPE	MSE	RMSE	
۰/۰۰۷۵	۴/۱۴	۲/۰۳	۰/۰۱۶	۱۹/۱	۴/۳۷	TDS
۰/۰۰۷۷	۸/۴۷	۲/۹۱	۰/۰۰۱۸	۰/۵۳۸	۰/۷۳۳	EC
۰/۱۰۴	۲/۳	۱/۵۱	۰/۱۱۷	۰/۹۴۳	۰/۹۷۱	pH
۰/۰۲۵	۰/۰۰۸	۰/۰۸۹	۰/۰۲	۰/۰۰۵۳	۰/۰۷۳	HCO ₃
۰/۲۰۱	۰/۰۰۳	۰/۰۵۵	۰/۲	۰/۰۰۳	۰/۰۵۲	Cl
۰/۰۱۸	۰/۰۰۸	۰/۰۸۷	۰/۰۱۴	۰/۰۰۲	۰/۰۴۶	SO ₄
۰/۰۲۱	۰/۰۰۵	۰/۰۶۸	۰/۰۱۷	۰/۰۰۳	۰/۰۵	Ca
۰/۰۸۲	۰/۰۰۳۹	۰/۰۶۲	۰/۰۸۲	۰/۰۰۴	۰/۰۶۳	Mg
۰/۱۴۴	۰/۰۰۲	۰/۰۴۵	۰/۰۸۹	۰/۰۰۰۷	۰/۰۲	Na

مطابق اطلاعات جدول ۳، پارامتر کل مواد جامد محلول با RMSE=۲/۰۳ توسط مدل SVR با دقت بهتری نسبت به شبکه عصبی مصنوعی با RMSE=۴/۳۷ پیش‌بینی شد. همچنین مدل SVR در پیش‌بینی یون منیزیم اندکی بهتر عمل کرد. در باقی موارد شبکه

عصبی مصنوعی پیش‌بینی‌های بهتری در خصوص پارامترهای دیگر ارائه داد. اگرچه هر دو مدل از دقت مناسبی برخوردار بودند و تفاوت کارایی آن‌چنانی نداشتند. علاوه بر قیاس دو مدل توسط شاخص‌های RMSE و MSE که توضیح داده شد؛ معیار MAPE برای قیاس کارایی هر یک از مدل‌ها در پیش‌بینی پارامترهای کیفی مناسب است. مطابق نتایج به‌دست‌آمده، شبکه عصبی مصنوعی، به ترتیب در پیش‌بینی پارامترهای هدایت الکتریکی، کل مواد جامد محلول، یون کلسیم، کربنات، یون منیزیم، یون سدیم، اسیدیته، سولفات و کلر بهترین کارایی را داشته است. در مقابل، پارامتر کل مواد جامد محلول دارای بیشترین دقت توسط مدل SVR هست و پارامترهای EC، سولفات، کلسیم، کربنات، منیزیم، pH، سدیم و کلر به ترتیب دارای بهترین رتبه مطابق نتایج مدل SVR می‌باشند. بیشترین خطای تولیدشده بین مقادیر مشاهداتی و پیش‌بینی‌شده در هر دو مدل مربوط به کلر است. **همچنین EC و TDS پارامترهایی بودند نسبت به سایر پارامترهای کیفی با خطای کمتری پیش‌بینی شدند.**


در شکل‌های ۳، ۴ و ۵، گراف‌های استنتاج شده از پیش‌بینی مدل‌ها برای پارامترهای TDS، SO₄ و Mg نشان داده شده است. مطابق شکل ۳، هر دو مدل ANN و SVM به خوبی آموزش دیده‌اند و تطابق خوبی با داده‌های مشاهداتی از خود نشان داده‌اند، اگرچه مدل SVM در پیش‌بینی TDS طبق شاخص RMSE اندکی از مدل دیگر دقیق‌تر بوده است. در این نمودار، خطوط طوسی رنگ نشان دهنده نتایج با مدل ANN و خطوط نارنجی رنگ نشانگر داده‌های پیش‌بینی شده توسط مدل SVM است. همچنین خطوط آبی رنگ بیانگر داده‌های مشاهداتی است. در این نمودار محور عمودی نماینده میزان غلظت مواد جامد محلول بر حسب ppm و محور افقی بیانگر زمان بر حسب ماه است.



شکل ۳. نمودار مقایسه پیش‌بینی TDS توسط مدل ANN و SVM در قیاس با مقادیر مشاهداتی در دوره صحت‌سنجی


همچنین بر اساس شکل ۴، کارایی مدل‌ها را در پیش‌بینی سولفات در دوره صحت‌سنجی نشان می‌دهد که نسبت به کارایی ضعیف‌تری از خود نشان داده‌اند. با این وجود، پیش‌بینی‌های استنتاج شده از مدل ANN تطابق بیشتری با داده‌های مشاهداتی دارد.

همچنین در این نمودار رنگ‌های طوسی، نارنجی و آبی به ترتیب نشانگر داده‌های پیش‌بینی شده توسط مدل‌های ANN، SVM و SVM داده‌های مشاهده‌ای است. محور عمودی نشان‌دهنده میزان غلظت سولفات و محور افقی زمان برحسب ماه را نشان می‌دهد.



شکل ۴. نمودار مقایسه پیش‌بینی یون سولفات توسط مدل ANN و SVM در قیاس با مقادیر مشاهده‌ای در دوره صحت سنجی

در شکل ۵ نیز، کاتیون منیزیم مورد پیش‌بینی قرار گرفته که هر دو مدل کارایی بسیار مشابه با RMSE به ترتیب برابر با ۰/۰۶۳ و ۰/۰۶۲ برای ANN و SVM داشته‌اند.



شکل ۵. نمودار مقایسه پیش‌بینی یون منیزیم توسط مدل ANN و SVM در قیاس با مقادیر مشاهده‌ای در دوره صحت سنجی

نتیجه گیری

در پژوهش حاضر، دو مدل مبتنی بر یادگیری ماشین، شبکه عصبی مصنوعی (ANN) و ماشین بردار پشتیبان رگرسیونی (SVR) به منظور پیش بینی پارامترهای کیفی رودخانه دیناچال، در دوره‌ی ۱۲ ساله منتهی به سال ۱۳۹۷، با گام‌های زمانی یک ماه طی سال‌های ۱۳۸۵ تا ۱۳۹۷ به مدل آموزش داده شد. در این مطالعه، نه پارامتر شامل TDS، EC، pH، HCO₃، Cl، SO₄، Ca، Mg و Na مورد بررسی و پیش بینی قرار گرفتند. به منظور ارزیابی کارایی مدل‌های پیش بینی از شاخص‌های RMSE، MSE و MAPE استفاده شد. در نهایت مطابق نتایج به دست آمده مشخص شد که در رودخانه دیناچال عملکرد مدل ماشین بردار پشتیبان در خصوص پیش بینی پارامترهای TDS و Mg نسبت به مدل شبکه عصبی مصنوعی مطلوب‌تر بود؛ اما مدل مبتنی بر شبکه عصبی مصنوعی در پیش بینی هفت پارامتر دیگر شامل EC، pH، HCO₃، Cl، SO₄، Ca و Na عملکرد نسبتاً بهتری نسبت به مدل ماشین بردار پشتیبان از خود نشان داد. **با این وجود**، هر دو مدل کارایی مناسبی در پیش بینی پارامتر Cl نداشتند و ضریب MAPE به صورت مشابه برای هر دو مدل برابر با ۰/۲ محاسبه شد. بطور کلی عملکرد هر دو مدل در پیش بینی پارامترها، مناسب ارزیابی می‌شود. در نهایت پیشنهاد می‌شود در مطالعات آینده علت دقت پایین مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان در پیش بینی پارامتر کلر بررسی شده و راهکار مناسب ارائه شود. همچنین، کارایی مدل‌های پیشرفته‌تر مبتنی بر یادگیری عمیق در پیش بینی پارامترهای کیفی می‌تواند مورد بررسی و مطالعه قرار بگیرد.

تشکر و قدردانی

بدین وسیله از دانشگاه تهران و شرکت آب منطقه‌ای استان گیلان به دلیل تأمین امکانات لازم جهت انجام این تحقیق و تهیه مقالات مربوطه تشکر و قدردانی می‌شود.

"هیچ گونه تعارض منافی بین نویسندگان وجود ندارد"

مراجع

- احمدی، فرشاد؛ رادمنش، فریدون و میرعباسی نجف‌آبادی، رسول (۱۳۹۳). مقایسه روش‌های برنامه‌ریزی ژنتیک و ماشین بردار پشتیبان در پیش بینی جریان روزانه رودخانه (مطالعه موردی: رودخانه باراندوزچای). *نشریه آب و خاک (علوم و صنایع کشاورزی)*، ۱۱۷۱-۱۱۶۲ و ۲۸(۶)
- امینی، عباس؛ نوری، سید هدایت اله و اصلانی سنگده، بیتا. (۱۳۹۳). ارزیابی و سنجش پایداری زراعت برنج با استفاده از روش‌های تصمیم‌گیری چند معیاره (مورد مطالعه: شهرستان رضوانشهر). *علوم ترویج و آموزش کشاورزی ایران*، ۱۲۶-۱۰۱(۱)۱۱.
- ایرجی، مریم؛ موحدی نائینی، سید علیرضا؛ کمکی، چوقی بایرام؛ ابراهیمی، سهیلا و یغمایی، بامشاد. (۱۴۰۲). ارزیابی پارامترهای موثر جهت پیش بینی عیار پتاسیم شورابه با استفاده از الگوریتم‌های ماشین بردار پشتیبان و جنگل تصادفی (مطالعه موردی: پلایای شهرستان خورو بیابانک، استان اصفهان). *مجله تحقیقات آب و خاک ایران*.
- جمالی، بهزاد و ابراهیمی، کیومرث. (۱۳۹۰). پیش بینی سری‌های زمانی کیفیت آب رودخانه سفیدرود با استفاده از مدل‌های خطی تصادفی. *مجله تحقیقات مهندسی کشاورزی*، ۳۱-۴۴ و ۱۲(۳).
- حسین‌پناهی، بهاره؛ نیک‌مهر، سامان و ابراهیمی، کیومرث. (۱۴۰۰). مقایسه مدل‌های ماشین بردار و شبکه عصبی تابع پایه شعاعی در پیش بینی کیفیت آب سیمینه رود. *مدیریت آب و آبیاری*، ۴۱۹-۴۰۹ و ۱۱(۳).

روشنگر، کیومرث و داودی، سینا. (۱۴۰۱). مقایسه عملکرد روش‌های یادگیری عمیق و یادگیری ماشین در پیش‌بینی میزان اکسیژن محلول. *مجله تحقیقات آب و خاک ایران*, ۱۹۰۰-۱۸۸۵(۸)۵۳.

ستاری، محمدتقی؛ عباسقلی نایب زاد، مهدی و میر عباسی نجف‌آبادی، رسول. (۱۳۹۳). پیش‌بینی کیفیت آب‌های سطحی با استفاده از روش درخت تصمیم. *نشریه علمی پژوهشی مهندسی آبیاری و آب ایران*, ۸۸-۸۶(۳)۴.

شاهی‌نژاد، بابک؛ ایزدی؛ زهره و جوادی، بهزاد. (۱۴۰۰). ارزیابی مدل Qual2Kw در شبیه‌سازی کیفی رودخانه خرم‌آباد. *نشریه هیدروژئومورفولوژی*، دوره ۸، شماره ۲۶.

عباسی، عباس؛ خللی، کیوان؛ بهمنش، جواد و شیرزاد، اکبر. (۱۳۹۹). کاربرد روش ماشین بردار پشتیبان و شبکه بیزین در پیش‌بینی خشک‌سالی کشاورزی. *مهندسی و مدیریت آبخیز* ۱۲۴-۱۰۷ و ۱۲(۱).

محمدی قلعه‌نی، مهدی؛ ابراهیمی، کیومرث و امید، محمدحسین. (۱۳۹۴). برآورد ضریب هوادهی در مدیریت کیفی آب رودخانه دیناچال، با استفاده از روابط تجربی و روش‌های عددی. *مدیریت آب و آبیاری*، ۷۹-۶۹(۱)۵.

ویسی، محمد؛ محمدی روزبهانی، مریم و ظهراپی، نرگس. (۱۳۹۶). بررسی کیفیت آب رودخانه شاوور با استفاده از شاخص‌های کیفی آب (مطالعه موردی: روستای حمزه تا سد شاوور). *فصلنامه علوم و تکنولوژی محیط‌زیست*، ۹۳-۸۱(۵)۲۳.

Abbasi, A., Khalili, K., Bahmanesh, J & Shirzad, A. (2020). Application of Support Vector Machine and Bayesian Network for Agricultural Drought Prediction. *Journal of Watershed Engineering and Management*, 107-124 and (1)12. (In Persian)

Abobakr Yahya, A. S. Ahmed, A. N. Binti Othman, F. Ibrahim, R. K. Afan, H. A. El-Shafie, A. & Elshafie, A. (2019). Water Quality Prediction Model-Based Support Vector Machine Model for ungauged River Catchment under Dual Scenarios. *Water*, 11(6), 1231.

Ahmadi, F., Radmanesh, F & Mirabbasi Najaf Abadi, R. (2015). Comparison between Genetic Programming and Support Vector Machine Methods for Daily River Flow Forecasting (Case Study: Barandoozchay River). *Journal of Water and Soil*, 1162-1171 and 28 (6). (In Persian)

Amini, A., Nouri, HA & Aslani Sangdeh, B. (2015). Evaluation of Rice Production Sustainability Using Multi-Criteria Decision Making Methods: the Case of Razvanshahr County. *Agricultural Education and Extension Sciences of Iran*, 126-101(1)11. (In Persian)

Banejad, H. and E. Olyaie (2011). "Application of an Artificial Neural Network Model to Rivers Water Quality Indexes Prediction—A Case Study." *Journal of American Science Journal of American Science*, 77: 60-65.

Chia, S. L. Chia, M. Y. Koo, C. H. & Huang, Y. F. (2022). Integration of Advanced Optimization Algorithms into Least-Square Support Vector Machine (LSSVM) for Water Quality Index Prediction. *Water Supply*, 22(2), 1951-1963.

Cortes, C. and V. Vapnik (1995). "Support-vector networks." *Machine Learning* 20(3): 273-297.

Gorashi, F. & Abdullah, A. (2012). Prediction of Water Quality Index Using Back Propagation Network Algorithm Case Study: Gombak River. *Journal of Engineering Science and Technology*, 7(4), 447-461.

- Hosseiniapanahi, B., Nikmehr, S & Ebrahimi, K. (2021). Comparison of the Support Vector Machine Models and Radial Function Neural Network in Predicting SiminehRood River Water Quality Iran. *Water and Irrigation Management*, 409-419 and (3)11. (In Persian)
- Huang, M. Tian, D. Liu, H. Zhang, C. Yi, X. Cai, J., & Ying, G. (2018). A Hybrid Fuzzy Wavelet Neural Network Model with Self-Adapted Fuzzy c-means Clustering and Genetic Algorithm for Water Quality Prediction in Rivers. *Complexity*, 2018, 1-11.
- Iraji, M., Movahedi Naeini, SA., Komaki, CB., Ebrahimi, S & Yaghmaei, B. (2023). Evaluation of the Effective Parameters for Predicting the Potassium Grade of Saline Water by Using Support Vector Machine and Random Forest Algorithms (Case Study: Playa of Koor and Biabank Area City, Isfahan Province). *Iran water and soil research*. (In Persian)
- Jamali, B & Ebrahimi, K. (2011). Time Series Forecasting of Sefidrood River Water Quality Using Linear Stochastic Models. *Journal of Agricultural Engineering Research*, 31-44 and (3)12. (In Persian)
- Li, Q., Yang, Y., Yang, L., & Wang, Y. (2023). Comparative Analysis of Water Quality Prediction Performance Based on LSTM in the Haihe River Basin, China. *Environmental Science and Pollution Research*, 30(3), 7498-7509.
- Mahapatra, S. S., Nanda, S. K., & Panigrahy, B. K. (2011). A Cascaded Fuzzy Inference System for Indian River Water Quality Prediction. *Advances in Engineering Software*, 42(10), 787-796.
- Mohammadi Ghaleni, M., Ebrahimi, K & Omid, MH. (2015). Estimation of Rearation Rate Coefficient on Dinachal River Numerical Methods in Water Quality Management. *Water and Irrigation Management*, 79-69(1)5. (In Persian)
- Najwa Mohd Rizal, N., Hayder, G., Mnzool, M., Elnaim, B. M., Mohammed, A. O. Y., & Khayyat, M. M. (2022). Comparison between Regression Models, Support Vector Machine (SVM), and Artificial Neural Network (ANN) in River Water Quality Prediction. *Processes*, 10(8), 1652.
- Pedregosa, F., et al. (2012). "Scikit-learn: Machine Learning in Python." *Journal of Machine Learning Research* 12.
- Rohmah, M. F., et al. (2021). "Comparison Four Kernels of SVR to Predict Consumer Price Index." *Journal of Physics: Conference Series* 1737(1): 012018.
- Roshangar, K & Davoudi, S. (2022). Comparing the Performance of Deep Learning and Machine Learning Methods in Predicting Dissolved Oxygen Content. *Iran soil and water research*, 1885-1900(8)53. (In Persian)
- Sakaa, B., Elbeltagi, A., Boudibi, S., Chaffaï, H., Islam, A. R. M. T., Kulimushi, L. C., & Wong, Y. J. (2022). Water Quality Index Modeling Using Random Forest and Improved SMO Algorithm for Support Vector Machine in Saf-Saf River Basin. *Environmental Science and Pollution Research*, 29(32), 48491-48508.
- Sattari, M., Abbasgoli Naebzad, M & Mirabbasi Najafabadi. (2014). Surface Water Quality Prediction Using Decision Tree Method. *Iranian Journal of Irrigation and Water Engineering*, 88-86(3)4. (In Persian)
- Shahinejad, B., Izadi, Z & Javadi, B (2021). Evaluation of Qual2Kw Model in Qualitative Simulation of Khorramabad River. *Hydrogeomorphology*. Volume 8, Number 26. (In Persian)

Sillberg, C.V., Kullavanijaya, P., & Chavalparit, O. (2021). Water Quality Classification by Integration of Attribute-Realization and Support Vector Machine for the Chao Phraya River. *Journal of Ecological Engineering*, 22 (9), 70-86

Veisi, M & Mohammadi Rouzbahani, M. (2021). Survey on Shavoor River Using Water Quality Indexes (Hamzeh village to Shavoor dam). *Environmental Science and Technology Quarterly*, 23-81(5)-93. (In Persian)

Yan, J., Liu, J., Yu, Y., & Xu, H. (2021). Water Quality Prediction in the Luan River based on 1-drcnn and bigru Hybrid Neural Network Model. *Water*,13 (9), 1273.