



## Comparing the Performance of Deep Learning and Machine Learning Methods in Predicting Dissolved Oxygen Content

**Kiyoumars Roushangar<sup>1✉</sup>, Sina Davoudi<sup>2</sup>**

1. Corresponding Author, Department of Water Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran. Email: [kroshangar@yahoo.com](mailto:kroshangar@yahoo.com)

2. Department of Water Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran, Email: [sinadavoudi24@gmail.com](mailto:sinadavoudi24@gmail.com)

---

### Article Info

**Article type:** Research Article

**Article history:**

**Received:** June. 6, 2022

**Revised:** Sep. 2, 2022

**Accepted:** Sep. 5, 2022

**Published online:** Oct. 23, 2022

**Keywords:**

Dissolved Oxygen,  
Long Short-Term Memory,  
Water Quality,  
Support Vector Machine,  
Gaussian Process Regression.

---

### ABSTRACT

Water quality forecasting plays an important role in environmental monitoring, ecosystem sustainability and aquaculture. Traditional forecasting methods cannot show the non-linearity and instability of water quality well. In the present study, the water quality parameter of dissolved oxygen was modeled using intelligent Support Vector Machine (SVM), Gaussian Process Regression (GPR) and Long Short-Term Memory (LSTM) methods on three consecutive stations on Savanah River located in USA. For this purpose, six different flow hydraulic and hydrological parameters including water temperature, turbidity, discharge, mean water velocity, pH and specific conductivity were used daily for seven years (2021-2015) as input parameters to model dissolved oxygen. The results showed the complete superiority of the deep learning method over the machine learning methods. According to the results, the long short-term memory method for the last model, which included all parameters, in the third station with correlation coefficient, coefficient of determination and root mean square error, respectively  $R = 0.981$ ,  $DC = 0.956$  and  $RMSE = 0.034$  for test data performed better. Finally, by performing sensitivity analysis, by removing the water temperature parameter, it was found that DC evaluation criteria decreased by 14% and RMSE increased by 100%. Therefore, water temperature was introduced as the most influential parameter in predicting dissolved oxygen in water.

---

Cite this article: Roushangar, K., & Davoudi, S. (2022). Comparing the Performance of Deep Learning and Machine Learning Methods in Predicting Dissolved Oxygen Content. *Iranian Journal of Soil and Water Research*, 53 (8), 1885-1900

© The Author(s).

Publisher: University of Tehran Press.

DOI: <http://doi.org/10.22059/ijswr.2022.344088.669288>



## مقایسه عملکرد روش‌های یادگیری عمیق و یادگیری ماشین در پیش‌بینی میزان اکسیژن محلول

کیومرث روشنگر<sup>۱</sup>، سینا داودی<sup>۲</sup>۱. نویسنده مسئول، گروه مهندسی آب، دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران، ایمیل: [kroshangar@yahoo.com](mailto:kroshangar@yahoo.com)۲. گروه مهندسی آب، دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران، ایمیل: [sinadavoudi24@gmail.com](mailto:sinadavoudi24@gmail.com)

## اطلاعات مقاله

## چکیده

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۱/۳/۱۶

تاریخ بازنگری: ۱۴۰۱/۶/۱۱

تاریخ پذیرش: ۱۴۰۱/۶/۱۴

تاریخ انتشار: ۱۴۰۱/۸/۱

## واژه‌های کلیدی:

پارامتر اکسیژن محلول،

حافظه طولانی کوتاه‌مدت،

رگرسیون فرآیند گاوسی،

کیفیت آب،

ماشین بردار پشتیبان.

پیش‌بینی کیفیت آب نقش مهمی در پایش زیست-محیطی، پایداری اکوسیستم و آبریزی‌پروری ایفا می‌کند. روش‌های پیش‌بینی سنتی نمی‌توانند غیر خطی و غیر ثابت بودن کیفیت آب را به خوبی نشان دهند. در مطالعه حاضر پارامتر کیفی اکسیژن محلول در آب با استفاده از روش‌های هوشمند ماشین بردار پشتیبان (SVM)، رگرسیون فرآیند گاوسی (GPR) و روش حافظه طولانی کوتاه-مدت (LSTM) بر روی سه ایستگاه متوالی بر روی رودخانه ساواناه واقع در ایالات متحده آمریکا مدل‌سازی شد. بدین منظور شش پارامتر هیدرولیکی و هیدرولوژیکی جریان شامل دمای آب، کدورت، دی، میانگین سرعت جریان، pH و رسانایی ویژه در مدت هفت سال (۲۰۱۵-۲۰۲۱) به صورت روزانه به عنوان پارامترهای ورودی، جهت مدل‌سازی اکسیژن محلول به کار گرفته شدند. نتایج نشان‌دهنده برتری کامل روش یادگیری عمیق بر روش‌های یادگیری ماشین بود. با توجه به نتایج بدست آمده روش حافظه طولانی کوتاه-مدت برای مدل آخر که شامل تمامی پارامترها بود در ایستگاه سوم با دارا بودن ضریب همبستگی و ضریب تبیین و جذر میانگین مربعات خطا به ترتیب  $R=0.981$  و  $DC=0.956$  و  $RMSE=0.034$  برای داده‌های آزمون از عملکرد بهتری برخوردار بود. در نهایت با انجام تحلیل حساسیت، با حذف پارامتر دمای آب، مشخص گردید معیارهای ارزیابی DC، به میزان ۱۴٪ کاهش و RMSE، به میزان ۱۰۰٪ افزایش داشت. بنابراین دمای آب به عنوان تأثیرگذارترین پارامتر در پیش‌بینی اکسیژن محلول در آب معرفی شد.

استناد: روشنگر، کیومرث؛ داودی، سینا. (۱۴۰۱). مقایسه عملکرد روش‌های یادگیری عمیق و یادگیری ماشین در پیش‌بینی میزان اکسیژن محلول. *مجله تحقیقات آب و خاک ایران*، ۵۳ (۸)، ۱۹۰۰-۱۸۸۵.DOI: <http://doi.org/10.22059/ijswr.2022.344088.669288>

© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

## مقدمه

تفسیر سریع کیفیت آب رودخانه یک امر اجباری است زیرا رودخانه یک اکوسیستم پویا است که تحت تأثیر فعالیت‌های مختلف در اطراف خود می‌باشد. زندگی جانوران آبی به آب و اکسیژن محلول در آب بستگی دارد. اکسیژن محلول در آب (DO) برای همه موجودات آبی و زندگی آن‌ها مهم است. میزان اکسیژن محلول در آب مستقیماً با کیفیت آب خوب ارتباط داشته و عوامل زیادی بر میزان DO آب تأثیر دارد. بنابراین، تعیین میزان DO در محیط زیست آبی، مانند رودخانه‌ها، دریاها، اقیانوس‌ها، حوضچه‌های پرورش آبزیان، تصفیه خانه‌های آب و پساب‌های صنعتی، از اهمیت زیادی برخوردار است. تاکنون تلاش‌هایی برای پیش‌بینی میزان اکسیژن محلول در آب انجام گرفته است که اغلب با استفاده از نرم افزارهای مدل‌سازی کیفیت آب بوده و یا با استفاده از روش‌های هوش مصنوعی می‌باشند. دو رویکرد اصلی برای توضیح روش‌های هوش مصنوعی وجود دارد. در یک رویکرد از الگوریتم‌های جعبه سیاه می‌باشند که قادر به توضیح نتیجه‌گیری‌های خود نیستند و رویکرد دیگر راهی برای روشن کردن منطق درونی آن‌ها می‌باشد. بدین ترتیب پژوهشگران می‌توانند یک الگوریتم دیگر، به نام توضیح‌دهنده، به این جعبه سیاه اضافه کنند که مجموعه‌ای از سوالات از جعبه سیاه می‌پرسد و نتیجه را با ورودی مربوطه مقایسه می‌کند. الگوریتم توضیح‌دهنده که جعبه سفید نام دارد از این طریق می‌تواند طرز کار سیستم جعبه سیاه را بازسازی کند. بنابراین استفاده از یک الگوریتم جدید مبتنی بر یادگیری عمیق که زیرمجموعه یادگیری ماشین می‌باشد جهت تخمین میزان اکسیژن محلول در آب مفید به نظر می‌رسد.

کیفیت آب مانند مدل کیفیت آب رودخانه و جریان (QUAL2K) و برنامه شبیه‌سازی تجزیه و تحلیل کیفیت آب (WASP) بسیار پیچیده و نیازمند به اطلاعات ورودی فراوان از سیستم رودخانه هستند (Pelletier et al., 2006; Wool et al., 2020). با توجه به وابستگی شدید کیفیت آب‌های سطحی (یعنی ویژگی‌های شیمیایی، فیزیکی و بیولوژیکی آن) به ماهیت و وسعت فعالیت‌های کشاورزی، صنعتی و سایر فعالیت‌های انسانی در حوضه‌های آبریز یک منطقه، ضروری است که تحت سناریوهای مختلف که در مدل‌سازی کیفیت آب اجرا می‌شوند، پیش‌بینی دقیقی ارائه دهند (Haidary et al., 2013; Najah et al., 2013; Singh et al., 2009). اکسیژن محلول (DO)، به عنوان یک معیار کلیدی مهم در محیط‌های آبی، اغلب برای ارزیابی سلامت اکوسیستم‌های آبی مانند رودخانه‌ها، دریاچه‌ها و اقیانوس‌ها استفاده می‌شود. در سال‌های گذشته، بسیاری از روش‌های مدل‌سازی از جمله مدل‌های خطی، مدل‌های غیرخطی، برای پیش‌بینی اکسیژن محلول (DO) مورد استفاده قرار گرفتند. بسیاری از محققان در پیش‌بینی میزان اکسیژن محلول کارهای زیادی انجام داده‌اند و به دستاوردهای بزرگی دست یافته‌اند. روش‌های اصلی پیش‌بینی شامل سیستم ارزیابی خبره، روش آمار ریاضی، سری‌های زمانی، روش تئوری خاکستری، روش شبکه عصبی مصنوعی و ماشین رگرسیون بردار پشتیبان است (Liu et al., 2014; Liu et al., 2012; Xue et al., 2013). شبکه عصبی بازگشتی (RNN<sup>2</sup>) دسته‌ای دیگر از شبکه‌های عصبی هستند. جهت مدل‌سازی داده‌های توالی از جمله سری‌های زمانی، RNN‌ها از سایر مدل‌های مبتنی بر هوش مصنوعی بهتر عمل می‌کنند (Csábrági et al., 2017; Sun et al., 2016). با این حال، از آنجا که یک RNN فقط می‌تواند اطلاعات را در مراحل زمانی رمزگذاری کند، چالش‌های گرادیان در حین آموزش دنباله‌های طولانی ناپدید می‌شوند. شبکه‌های عصبی حافظه طولانی کوتاه-مدت (LSTM<sup>3</sup>) پیشرفت جدیدی در RNN‌ها هستند که می‌توانند از حافظه برای کنترل وضعیت خروجی از دروازه‌ها استفاده کنند که باید برای مدت طولانی نگه داشته شوند و در عین حال مواد غیر ضروری را فراموش کنند (Chen et al., 2018).

آب رودخانه علاوه بر تأثیر بر اقلیم محلی، به عنوان منبع مهم آب آشامیدنی و تغذیه آب زیرزمینی عمل می‌کند (Adamowski et al., 2014; Emamgholizadeh et al., 2010). روش‌های مدل‌سازی زیادی برای پیش‌بینی داده‌های سری زمانی استفاده می‌شود (Kayacan et al., 2010). روش تحلیل رگرسیون، مدل‌های مارکوف، مدل خاکستری، مدل ماشین بردار پشتیبان از جمله این روش‌ها می‌باشند (Chung et al., 2010; Khotimah, 2015; Li & Song, 2020). در یک مطالعه یک مدل ترکیبی از مدل آریمای فصلی و مدل انتشار برگشتی عقب شبکه عصبی برای پیش‌بینی پارامترهای کیفیت آب ماهانه ارائه شد و مدل ترکیبی نتایج بهتری نسبت به آریمای شبکه عصبی مصنوعی داشت (Ömer Faruk, 2010). در پژوهشی مدل شبکه عصبی برای پیش‌بینی غلظت اکسیژن محلول در حالت

1 Dissolved Oxygen

2 Recurrent Neural Network

3 Long Short-Term Memory

ثابت و وابسته به فضای شبه پایدار در سه مخزن مختلف استفاده شد. ضریب همبستگی هم برای متغیرهای خروجی اندازه گیری شده و هم برای مدل بیش از ۰/۹۵ بود (Soyupak *et al.*, 2003). همچنین در پژوهشی دیگر پارامترهای کیفیت آب در مخزن سد ماماسین را مدل سازی شد. نتایج توانایی ANN<sup>۱</sup> را برای پیش بینی اکسیژن محلول در مناطق شارژ و تخلیه در سایت سد ماماسین نشان داد (Elhatip & Kömür, 2008). در یک مطالعه ANN برای تخمین DO پیشنهاد شد و از سیستم استنتاج فازی عصبی تطبیقی برای پیش بینی اکسیژن محلول رودخانه سورما استفاده شد. نتایج حاکی از توانایی شبکه عصبی مصنوعی نسبت به سیستم فازی بود (Huan *et al.*, 2016; Huan & Liu, 2018). در پژوهشی دیگر از دو شبکه ANN، پرسپترون چند لایه (MLP<sup>۲</sup>) و عملکرد پایه شعاعی (RBF<sup>۳</sup>) برای محاسبه غلظت کل جامد محلول (TDS<sup>۴</sup>) برای رودخانه جاجروود ایران استفاده شد. نتیجه آن شد که MLP و RBF قادر به شبیه سازی متغیرهای کیفیت آب رودخانه جاجروود با دقت بیش از ۹۰٪ هستند (Niroobakhsh, 2012). همچنین در یک پژوهش میزان اکسیژن محلول در آب رودخانه سورما با استفاده از شبکه عصبی پیشخور و تابع پایه شعاعی تخمین زده شد. نتایج نشان داد تفاوت بین دو شبکه عصبی در هر دو حالت تک متغیره و دومتغیره مشابه بود (ضریب همبستگی به ترتیب ۰/۷۹ و ۰/۸۸ شد) (Ahmed, 2017). در پژوهشی از BPNN<sup>۵</sup>، شبکه عصبی رگرسیون عمومی (GRNN<sup>۶</sup>) و شبکه عصبی مکرر (RNN) برای تخمین محتوای DO در رودخانه دانوب (شمال صربستان)، استفاده شد که نتایج کارایی مدل RNN را برای پیش بینی DO نشان می دهد (Antanasijević *et al.*, 2013). در سال های اخیر، توجه زیادی به RNN شده است. RNN می تواند به صورت پویا روابط مکانی-زمانی را بیاموزد و بهترین نتایج را در پیش بینی تک مرحله ای سری های زمانی چند متغیره ارائه دهد (Qin *et al.*, 2017). در مطالعه ای دیگر در سنگاپور برای تخمین هفتگی میزان اکسیژن محلول در آب دریا از دو شبکه عصبی پرسپترون چند لایه با قابلیت پس انتشار خطا و شبکه عصبی رگرسیون تعمیم یافته استفاده شد. نتیجه نشان داد شبکه عصبی رگرسیون تعمیم یافته نتایج بهتری داشت (Palani *et al.*, 2009). برای پیش بینی اکسیژن محلول در استخرهای کشت خرچنگ، یک الگوریتم IPSO-LSSVR<sup>۷</sup> را برای ساخت یک مدل پیش بینی غیر خطی اتخاذ شد-IPSO. LSSVR مورد آزمایش قرار گرفت و با الگوریتم های دیگر مقایسه شد. نتایج آزمایش نشان می دهد که مدل پیشنهادی IPSO-LSSVR می تواند دقت پیش بینی را افزایش دهد و عملکرد تعمیم را بهتر از رگرسیون بردار پشتیبانی استاندارد (SVR) و شبکه عصبی BP انجام دهد (Liu *et al.*, 2014). در یک روش جدید مبتنی بر خوشه (CSELM<sup>۸</sup>) برای پیش بینی دقیق و کارآمد تغییر اکسیژن محلول از داده های سری زمانی ارائه شد و نتیجه آن شد که CSELM از نظر دقت و کارایی در پیش بینی محتوای اکسیژن محلول در دنیای واقعی، نتایج پیش بینی بهتری نسبت به مدل های PLS-ELM و ELM بدست می آورد (Shi *et al.*, 2019).

در مورد ادبیات پیشین، تحقیقات بسیار محدودی در زمینه پیش بینی اکسیژن محلول با استفاده از یادگیری عمیق یافت شد. هدف مطالعه حاضر ارائه ی یک روش نوین (LSTM) مبتنی بر یادگیری عمیق و همچنین تعیین پارامترهای ایده آل شبکه های LSTM برای بهبود دقت پیش بینی غلظت DO در آب رودخانه ساواناه می باشد. نتایج به دست آمده در نهایت با مدل های سنتی مبتنی بر هوش مصنوعی مقایسه می شوند. در این راستا دو روش ماشین بردار پشتیبان (SVM) و رگرسیون فرآیند گاوسی (GPR) برای پیش بینی غلظت DO در رودخانه ارئه شدند. مدل های پیش بینی کننده با داده های هیدروشیمیایی روزانه شامل دبی، دمای آب، کدورت، سرعت متوسط، pH و هدایت ویژه برای پیش بینی اکسیژن محلول در رودخانه ساواناه استفاده شدند. در نهایت دقت و کاربرد روش های LSTM، SVM و GPR از طریق شاخص های ارزیابی آماری مختلف مورد ارزیابی قرار گرفتند.

## مواد و روش ها

### موقعیت و ویژگی منطقه مورد مطالعه

رودخانه ساواناه<sup>۹</sup> یکی از رودخانه های ایالات متحده آمریکا است که به اقیانوس اطلس می ریزد. این رودخانه بزرگ در جنوب شرقی ایالات

1 Artificial Neural Network

2 Multilayer Perceptron

3 Radial Basis Function

4 Total Dissolved Solids

5 Back Propagation Neural Network

6 General Regression Neural Network

7 Improved Particle Swarm Optimization-Least Squares Support Vector Regression

8 Composite Semi-supervised Extreme Learning Machine

9 Savannah River

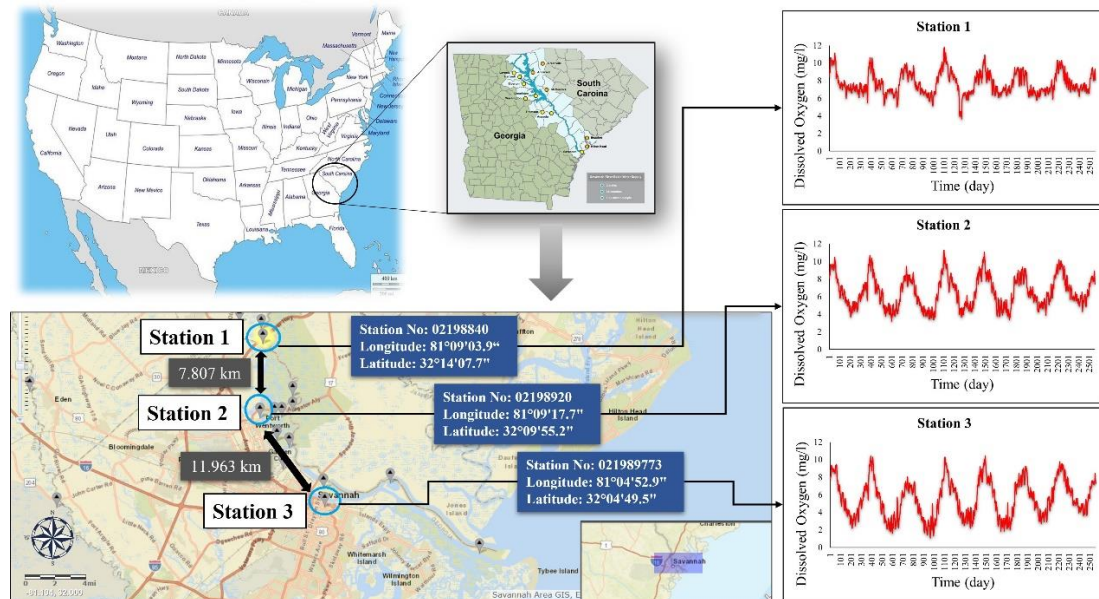
متحده است که بیشترین مرز بین ایالت‌های کارولینای جنوبی و جورجیا را تشکیل می‌دهد. رودخانه ساواناه در طول مسیر خود از میان آب و هواها و اکوسیستم‌های مختلف می‌گذرد. این یک رودخانه آبرفتی در نظر گرفته می‌شود که یک حوضه زهکشی به مساحت ۱۰۵۷۷ مایل مربع (۲۷۳۹۰ کیلومتر مربع) را تخلیه می‌کند و مقادیر زیادی رسوب را به اقیانوس می‌برد. دو شاخه از ساواناه، رودخانه توگالو و رودخانه چاتوگا، شمالی‌ترین قسمت مرز را تشکیل می‌دهند. حوضه زهکشی رودخانه ساواناه به سمت جنوب شرقی کوه‌های آپالاچی در داخل کارولینای شمالی، که توسط شکاف قاره شرقی محدود می‌شود، گسترش می‌یابد. طول این رودخانه حدود ۳۰۱ مایل (۴۸۴ کیلومتر) است. ساواناه از تلاقی رودخانه توگالو و رودخانه سنکا تشکیل شده است. امروزه این محل تلاقی در زیر دریاچه هارتول غوطه ور است. تنگه تالولاه که بر روی رودخانه تالولاه واقع شده است، شاخه‌ای از رودخانه توگالو است که شاخه شمال غربی رودخانه ساوانا را تشکیل می‌دهد. در شکل و جدول (۱) منطقه مورد مطالعه، موقعیت ایستگاه‌ها و همچنین مشخصات ایستگاه نمایش داده شده است.

داده‌های مورد استفاده در این پژوهش مربوط به سه ایستگاه هیدرولوژیکی متوالی در طول هفت سال (۲۰۱۵ تا ۲۰۲۱) به صورت سری زمانی بر روی رودخانه ساواناه می‌باشد. داده‌های مربوطه شامل دمای آب (WTE<sup>۱</sup>)، کدورت (TUR<sup>۲</sup>)، دبی (DIS<sup>۳</sup>)، متوسط سرعت جریان (MWV<sup>۴</sup>)، میزان pH، رسانایی ویژه (SC<sup>۵</sup>) و اکسیژن محلول (DO) می‌باشند. جهت مدل‌سازی اکسیژن محلول در آب با استفاده از سه روش LSTM، SVM و GPR در رودخانه ساواناه از داده‌های مربوط به پنج سال اول از سال ۲۰۱۵ تا ۲۰۱۹ (تقریباً ۷۰٪ کل داده‌ها) برای قسمت آموزش و از داده‌های مربوط به ۲۰۲۰ و ۲۰۲۱ (تقریباً ۳۰٪ کل داده‌ها) به عنوان داده‌های آزمون استفاده شده است. جدول (۱) خلاصه‌ای از مشخصات داده‌های به کار رفته را نشان می‌دهد. داده‌های روزانه اکسیژن محلول مربوط به رودخانه ساواناه برای سه ایستگاه هیدرومتریک منتخب در وب سایت سازمان زمین‌شناسی آمریکا (USGS) موجود می‌باشد.

جدول ۱- مشخصات داده‌های به کار رفته در تحقیق

متغیر	واحد	ایستگاه	ماکزیمم	مینیمم	میانگین	انحراف معیار
دمای آب (WTE)	°C	ایستگاه اول	۳۰/۵۱	۵/۴۱	۲۰/۲۷	۶/۳۲
		ایستگاه دوم	۳۰/۳۳	۵/۶۷	۲۰/۵۳	۶/۳۷
		ایستگاه سوم	۳۰/۶۹	۵/۷۳	۲۰/۹۶	۶/۴۵
کدورت (TUR)	FNU	ایستگاه اول	۵۷/۰۹	۶/۹۰	۱۸/۲۰	۷/۷۸
		ایستگاه دوم	۱۸۶/۶۴	۵/۷۲	۴۴/۵۵	۲۸/۴۶
		ایستگاه سوم	۱۶۵/۲۷	۴/۷۸	۳۰/۳۳	۲۳/۳۱
دبی (DIS)	m <sup>3</sup> .s <sup>-1</sup>	ایستگاه اول	۱۳۴۸/۵۸	۱۰/۵۶	۲۹۹/۲۳	۲۱۸/۳۵
		ایستگاه دوم	۱۲۳۰/۲۴	۳/۴۴	۲۷۱/۵۶	۱۸۹/۸۰
		ایستگاه سوم	۱۸۹۱/۸۵	۳/۱۴	۴۱۱/۰۸	۲۸۵/۹۷
میانگین سرعت آب (MWV)	m. s <sup>-1</sup>	ایستگاه اول	۱/۰۴	۰/۰۳	۰/۲۸	۰/۱۷
		ایستگاه دوم	۰/۷۵	۰/۰۱	۰/۲۰	۰/۱۱
		ایستگاه سوم	۰/۶۱	۰/۰۰۰۶	۰/۱۳	۰/۰۸
pH	-	ایستگاه اول	۷/۴۱	۶/۳۰	۶/۹۳	۰/۲۰
		ایستگاه دوم	۷/۶۰	۶/۲۶	۶/۹۵	۰/۲۲
		ایستگاه سوم	۷/۹۳	۶/۵۷	۷/۲۰	۰/۲۵
رسانایی ویژه (SC)	μS.cm <sup>-1</sup>	ایستگاه اول	۴۲۴/۳۳	۴۶/۵۸	۸۸/۸۵	۲۷/۸۶
		ایستگاه دوم	۱۵۳۱۵/۰۳	۴۷/۳۶	۳۷۶۶/۸۲	۳۱۳۲/۲۸
		ایستگاه سوم	۲۵۷۱۳/۵۴	۷۳/۵۶	۱۲۱۷۸/۵۸	۵۷۸۷/۲۸
اکسیژن محلول (DO)	mg. L <sup>-1</sup>	ایستگاه اول	۱۱/۸۱	۳/۶۵	۷/۶۹	۱/۲۵
		ایستگاه دوم	۱۱/۲۸	۳/۲۰	۶/۵۲	۱/۷۶
		ایستگاه سوم	۱۰/۴۴	۱/۰۸	۵/۵۲	۲/۱۲

- 1 Water Temperature
- 2 Turbidity
- 3 Discharge
- 4 Mean Water Velocity
- 5 Specific Conductance



شکل ۱- منطقه مورد مطالعه و موقعیت ایستگاه‌ها (https://maps.waterdata.usgs.gov/mapper)

### حافظه طولانی کوتاه-مدت (LSTM)

لفظ یادگیری عمیق عموماً در حوزه شبکه‌های عصبی مصنوعی به کار می‌رود؛ که نخستین بار در سال ۲۰۰۰ میلادی در حوزه یاد شده استفاده شد (Aizenberg *et al.*, 2000). شبکه عصبی بازگشتی (RNN) نوعی شبکه عصبی در زمینه یادگیری عمیق است. شبکه عصبی مکرر، همان RNN ساده، یکی از رویکردهای شبکه عصبی بازگشتی است که برای مدل‌سازی داده‌های دنباله دار استفاده می‌شود. در شبکه‌های عصبی سنتی، همهی ورودی‌ها و خروجی‌ها از یکدیگر مستقل هستند و شبکه قادر به یادآوری اطلاعات قبلی نیست در حالی که شبکه RNN این مشکل را با کمک یک لایه مخفی حل می‌کند (Graves & Schmidhuber, 2005). ویژگی اصلی RNN، بازگشت تاخیر شبکه است که موجب می‌شود شبکه به توصیف عملکرد پویای سیستم قادر باشد. بازگشت تاخیر سیگنال باعث می‌شود خروجی شبکه در زمان  $t$  نه تنها با ورودی در زمان  $t$ ، با سیگنال‌های بازگشتی قبل از زمان  $t$  مرتبط شود. با وجود این توانایی آن در پردازش داده‌های دنباله‌ای کوتاه مدت است. ضعف RNN، در هنگام یادگیری وابستگی‌های دوربرد یا به خاطر سپردن بستر طولانی مدت، در برنامه‌های پیش بینی سری زمانی است (Sagheer & Kotb, 2019).

سلول‌های حافظه طولانی کوتاه-مدت در سال ۱۹۹۷ معرفی شد که عملکردهای RNN را به طرز چشمگیری بهبود می‌بخشند (Hochreiter & Schmidhuber, 1997). مدل حافظه طولانی کوتاه-مدت (LSTM) یک نوع RNN است که از سلول حافظه ساخته شده به منظور نشان دادن وابستگی‌های طولانی مدت در داده‌های سری زمانی استفاده می‌کند. علاوه بر این، LSTM برای حل مسئله گرایان ناپدید شده RNN در صورت وجود حفظ زمینه طولانی مدت، مورد نیاز است (Bengio *et al.*, 1994). تغییر عمده LSTM نسبت به سلول RNN معمولی، روش محاسبه فعال سازی است. فعال سازی در مرحله  $t$ ، بر اساس چهار نوع دروازه محاسبه می‌شود که دروازه اطلاعات، دروازه فراموشی، دروازه خروجی و دروازه سلول شناخته می‌شود (Fang & Yuan, 2019).

ورودی دروازه اطلاعات (در مرحله  $t$ ) با رابطه زیر محاسبه می‌شود:

$$i_t = \sigma(W_{ia} \cdot h_{t-1} + W_{ix} \cdot x_t) \quad \text{رابطه (۱)}$$

که در آن  $\sigma$  تابع غیر خطی مثل تابع سیگموئید است.  $W_{ix}$  و  $W_{ia}$  ماتریس‌هایی اند که به ترتیب  $h_{t-1}$  را با  $h_t$  و  $x_t$  را با  $h_t$  متصل می‌کنند. به طور مشابه، ورودی دروازه فراموشی و ورودی دروازه خروجی به صورت زیر محاسبه می‌شود:

$$f_t = \sigma(W_{fa} \cdot h_{t-1} + W_{fx} \cdot x_t) \quad \text{رابطه (۲)}$$

$$o_t = \sigma(W_{oa} \cdot h_{t-1} + W_{ox} \cdot x_t)$$

ورودی دروازه سلولی به صورت زیر محاسبه می‌شود:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot K_t \quad \text{رابطه (۳)}$$

در آن  $C_{t-1}$  اطلاعات وضعیت سلول از مرحله قبل و  $K_t$  به صورت زیر محاسبه می‌شود:

$$K_t = \tanh(W_{ca} \cdot h_{t-1} + W_{cx} \cdot x_t) \quad \text{رابطه ۴}$$

که در آن  $\tanh$  تابع مماس مضراب است. در آخر، فعال سازی در مرحله  $t$  به صورت زیر محاسبه می‌شود:

$$h_t = o_t \cdot \tanh(C_t) \quad \text{رابطه ۵}$$

### رگرسیون فرآیند گاوسی (GPR)

مدل‌های رگرسیون فرآیند گاوسی بر مبنای این فرض هستند که مشاهدات تنظیم باید حامل اطلاعاتی درباره همدیگر باشد. فرآیندهای گاوسی راهی برای مشخص کردن اولویت به صورت مستقیم روی فضای تابع هستند. این کار تعمیم طبیعی توزیع گاوسی است که میانگین و کوواریانس آن به ترتیب بردار و ماتریس هستند (Yang et al., 2018). توزیع گاوسی روی بردارها است در حالی که فرآیند گاوسی روی توابع است. در نتیجه، مدل‌های فرآیند گاوسی به دلیل دانش قبلی درباره وابستگی‌های تابعی و داده‌ها، برای تعمیم به هیچ فرایند اعتبار سنجی نیاز ندارند و مدل‌های رگرسیون فرآیند گاوسی قادر به درک توزیع پیش بینی متناظر با ورودی آزمون هستند (Pal & Deswal, 2010). فرآیند گاوسی  $f(x)$  توسط توابع میانگین  $m(x)$  و کوواریانس به شکل زیر تعریف می‌شود (Rasmussen, 2004):

$$m(x) = E(f(x)) \quad \text{رابطه ۶}$$

$$k(x, x') = E((f(x) - m(x))(f(x') - m(x')))) \quad \text{رابطه ۷}$$

که در روابط فوق،  $k(x, x')$  تابع کوواریانس (یا کرنل) بوده که در نقاط  $x$  و  $x'$  محاسبه می‌شود. فرآیند گاوسی  $f(x)$  می‌تواند به صورت زیر بیان گردد:

$$f(x) \approx GP(m(x), k(x, x')) \quad \text{رابطه ۸}$$

که جهت ساده سازی، مقدار تابع میانگین برابر با صفر در نظر گرفته می‌شود. در فرآیند گاوسی، رابطه بین بردار ورودی و هدف به فرم زیر است:

$$y_i = f(x_i) + \varepsilon \quad \text{رابطه ۹}$$

که در آن  $f(x)$  بیانگر تابع رگرسیون دلخواه و  $\varepsilon$  نیز مقدار نویز گاوسی با میانگین صفر و واریانس  $\sigma^2$  می‌باشد، یعنی  $\varepsilon \sim N(0, \sigma^2)$ . علاوه بر این چنین فرض می‌گردد که  $f = [f(x_1), f(x_2), \dots, f(x_n)]^T$  رفتاری بر مبنای فرآیند گاوسی داشته به نحوی که  $p(f | X) = N(0, K)$ ، که در آن  $K$  ماتریس کوواریانس با درایه‌های  $k_{i,j} = k(x_i, x_j)$  است.

$$K(x, x) = \begin{pmatrix} k(x_1, x_1) & \dots & k(x_1, x_n) \\ \vdots & \ddots & \vdots \\ k(x_n, x_1) & \dots & k(x_n, x_n) \end{pmatrix} \quad \text{رابطه ۱۰}$$

$K_{i,j}$  کوواریانس بین مقادیر توابع نهان  $f(x_i)$  و  $f(x_j)$  می‌باشد. رگرسیون فرآیند گاوسی به منظور محاسبه توزیع پیش بینی شده برای مقادیر تابع  $f^*$  در نقاط تست  $X^* = [x_1^*, x_2^*, \dots, x_m^*]$  به کار می‌رود.

### ماشین بردار پشتیبان (SVM)

روش ماشین بردار پشتیبان روشی امیدوارکننده در زمینه پیش بینی مبتنی بر داده است. اخیراً، SVM به طور گسترده برای رسیدگی به مشکلات مختلف منابع آب، مانند پیش بینی جریان، پیش بینی سطح آب و شبیه سازی پارامتر کیفیت آب به کار گرفته شده است. در یک مدل رگرسیونی SVM لازم است وابستگی تابعی متغیر وابسته  $y$  به مجموعه ای از متغیرهای مستقل  $x$  همانند رابطه ۶ مشخص گردد (Vapnik, 1995). تابع  $f$  به وسیله آموزش مدل SVM بر روی یک مجموعه داده به عنوان مجموعه آموزش که شامل فرآیندی به منظور بهینه سازی دائمی تابع خطا است، قابل دسترسی است. برای این مدل، تابع خطا به صورت رابطه ۱۲ تعریف می‌شود (Roushangar & Joulazadeh, 2022):

$$y = f(x(k)) + \varepsilon \quad \text{رابطه ۱۱}$$

$$\frac{1}{2} W^T W + C \sum_{i=1}^N \xi_i + C \sum_{i=1}^N \zeta_i \quad \text{رابطه ۱۲}$$

تابع خطای مذکور لازم است که با توجه به محدودیت‌های زیر کمینه گردد:

$$\begin{aligned} W^T \phi(X_i) + b - y_i &\leq \varepsilon + \xi_i \\ y_i - W^T \phi(X_i) - b &\leq \varepsilon + \xi_i \\ \xi_i, \xi_i &\geq 0, \quad i = 1, \dots, N \end{aligned} \quad \text{رابطه (۱۳)}$$

که در این روابط:  $C$  ثابت گنجایش،  $W$  بردار ضرایب،  $W^T$  ترانهاده بردار ضرایب،  $\xi_i$  و  $\xi_i$  ضرایب کمبود،  $b$  ضریبی ثابت،  $N$  الگوی آموزش مدل و  $\phi$  تابع کرنل است. ضمن اینکه پارامترهای  $C$  و  $\gamma$  و  $\varepsilon$  نیز در نرم افزار Statistica با استفاده از روش سعی و خطا بهینه شده‌اند به نحوی که میانگین مربعات خطا را کمینه و مقادیر مربوط به ضریب همبستگی و ضریب تبیین را بیشینه کنند. هر دو الگوریتم ماشین بردار پشتیبان و رگرسیون فرآیند گاوسی از روش‌های یادگیری ماشین با فرمول متفاوت می‌باشند. مفهوم تابع کوواریانس در رگرسیون فرآیند گاوسی مشابه تابع کرنل می‌باشد. در میان توابع کرنل مختلف که در جدول (۲) ارائه شده، کرنلتابع پایه شعاعی به عنوان بهترین انتخاب از بین دیگر توابع کرنل گزارش شده است. بنابراین در این تحقیق از تابع مذکور به عنوان تابع کرنل استفاده گردید.

جدول ۲- انواع تابع کرنل

تابع کرنل	نوع کرنل
$K(x_i, x_j) = (x_i, x_j)$	Linear
$K(x_i, x_j) = ((x_i, x_j) + 1)^d$	Polynomial
$K(x_i, x_j) = \exp\left(-\frac{\ x_i - x_j\ ^2}{2\gamma^2}\right)$	RBF
$K(x_i, x_j) = \exp\left(-\frac{\ x_i - x_j\ }{2\gamma^2}\right)$	ERBF

به منظور استفاده از روش‌های کرنل محور، انتخاب مقادیر بهینه پارامترهای مربوط به تابع کرنل به دلیل تاثیر مستقیم در دقت نتایج به دست آمده از اهمیت بالایی برخوردار می‌باشد. همچنین در رگرسیون فرآیند گاوسی نیز به مشخص کردن مقدار بهینه نویز گاوسی نیاز می‌باشد که در این تحقیق تمامی پارامترهای مذکور با استفاده از روش آزمون خطا بهینه سازی شدند.

#### معیارهای ارزیابی

به منظور ارزیابی کارایی روش‌های استفاده شده در تخمین میزان اکسیژن محلول روزانه، از سه پارامتر آماری ضریب همبستگی ( $R$ )، ضریب تبیین ( $DC$ ) و ریشه میانگین مربعات خطاها ( $RMSE$ ) استفاده گردید. هرچه مقدار  $R$  و  $DC$  برای یک مدل به یک نزدیکتر و مقدار  $RMSE$  کوچکتر باشد به معنی مطلوب بودن آن مدل است. روابط این پارامترهای آماری به صورت زیر است (Roushangar & Chamani, 2020):

$$\begin{aligned} DC &= 1 - \frac{\sum_{i=1}^N (V_o - V_p)^2}{\sum_{i=1}^N (V_o - \bar{V}_p)^2} \\ R &= \frac{\sum_{i=1}^N (V_o - \bar{V}_o) \times (V_p - \bar{V}_p)}{\sqrt{\sum_{i=1}^N (V_o - \bar{V}_o)^2 \times \sum_{i=1}^N (V_p - \bar{V}_p)^2}} \\ RMSE &= \sqrt{\frac{\sum_{i=1}^N (V_o - V_p)^2}{N}} \end{aligned} \quad \text{رابطه (۱۴)}$$

که در روابط بالا  $V_o$  و  $V_p$  به ترتیب مقادیر مشاهداتی و پیش بینی شده،  $\bar{V}_o$  و  $\bar{V}_p$  متوسط مقادیر مشاهداتی و پیش بینی شده و  $N$  تعداد داده‌ها می‌باشد.

#### نرمالیزه کردن داده‌ها

یکی از مراحل اصلی در استفاده از روش‌های هوشمند پیش پردازش داده‌ها می‌باشد. با توجه به دامنه وسیع داده‌های ورودی و به منظور



افزایش دقت و سرعت مدل‌سازی، داده‌های مورد استفاده در این تحقیق با استفاده از رابطه (۱۵) در بازه [۰/۱ تا ۱] نرمال شده‌اند و در نهایت مجموع داده‌های فوق برای مدل‌سازی به کار گرفته شده‌اند.

$$X_{istd} = 0.1 + 0.9 \times \left( \frac{X_i - X_{i\min}}{X_{i\max} - X_{i\min}} \right) \quad \text{رابطه (۱۵)}$$

که در آن  $X_{i\max}$  و  $X_{i\min}$  کمترین و بیشترین داده از نظر مقدار است (Roushangar & Shahnazi, 2019).

## نتایج و بحث

### تعریف مدل‌های ورودی

در این پژوهش جهت مدل‌سازی اکسیژن محلول در آب (DO) به صورت سری زمانی از پارامترهای دمای آب (WTE)، کدورت (TUR)، دبی (DIS)، متوسط سرعت جریان (MWV)، میزان pH و رسانایی ویژه (SC) در مدت ۷ سال (۲۰۱۵ تا ۲۰۲۱) به صورت روزانه در سه ایستگاه متوالی بر روی رودخانه ساوانا استفاده شد. با توجه به آزمون و خطاهای انجام گرفته، در مورد اهمیت هر یک از پارامترها و میزان تاثیر آن‌ها در پیش بینی اکسیژن محلول مشخص گردید که دمای آب تاثیرگذاری بیشتری در مدل‌سازی دارد که در مرحله صحت‌سنجی این مورد به اثبات رسید. لذا ۶ ترکیب مختلف با توجه به تعداد پارامترها از تک پارامتر با شروع از پارامتر دمای آب و اضافه کردن تک تک پارامترها تا ترکیب همگی پارامترها در مدل‌سازی اکسیژن محلول مطابق جدول (۳) به کار گرفته شد.

جدول ۳- مدل‌های به کار رفته در پیش بینی اکسیژن محلول

ورودی	مدل
WTE	DO(I)
WTE, pH	DO(II)
WTE, pH, SC	DO(III)
WTE, pH, SC, MWV	DO(IV)
WTE, pH, SC, MWV, DIS	DO(V)
WTE, pH, SC, MWV, DIS, TU	DO(VI)

با توجه به مقادیر معیارهای ارزیابی (R, DC و RMSE) مشخص شد روش حافظه طولانی کوتاه-مدت (LSTM) برتری کاملی نسبت به روش‌های ماشین بردار پشتیبان (SVM) و رگرسیون فرآیند گاوسی (GPR) دارد. همچنین با توجه به نتایج می‌توان برتری روش SVM نسبت به GPR را مشاهده کرد. از سوی دیگر مشخص شد مدل DO(VI) در ایستگاه‌های دوم و سوم با دارا بودن همگی پارامترهای کیفیت آب و مدل DO(V) در ایستگاه اول، بیشترین ضریب تبیین و کمترین میزان خطا را در تمامی روش‌ها داشت. نتایج مربوط به مدل‌سازی اکسیژن محلول با سه روش ذکر شده و هاپیرپارامترهای مربوط به هر روش در جدول (۴) آورده شده است.

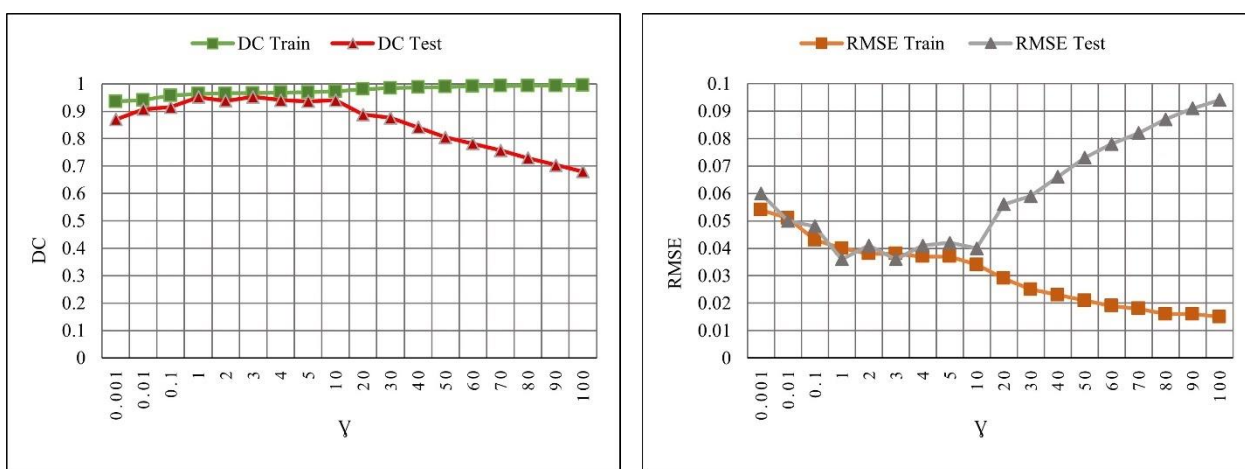
با توجه به جدول ۴ می‌توان نتیجه گرفت مدل DO(VI) به عنوان برترین مدل شناخته می‌شود. بنابراین همگی پارامترهای به کار رفته در این مدل‌سازی (دمای آب، pH، رسانایی ویژه، متوسط سرعت جریان، دبی و کدورت) نقش مؤثری در پیش بینی اکسیژن محلول ایفا می‌کنند. در مدل DO(I) که مدل تک پارامتریک می‌باشد، در همگی روش‌ها عدم قطعیت زیادی به دست می‌دهد. برای مثال: در روش SVM مقدار پارامتر بهینه گاما (γ) در مدل اول در همگی ایستگاه‌ها مقدار بسیار زیادی در مقایسه با مدل‌های دیگر داشت. این در حالی است که این پارامتر با افزایش تعداد ورودی‌های مربوط به کیفیت آب به طور کلی کاهش یافته است. برای نمونه مدل DO(I) در ایستگاه سوم با دارا بودن پارامترهای (δ = ۵۵ و ε = ۰/۰۰۱ و C = ۱) به میزان ۳۴٪ در معیار ارزیابی DC افزایش و ۶۰٪ در میزان RMSE کاهش، در مقایسه با مدل DO(VI) با پارامترهای (γ = ۳ و ε = ۰/۱۰۱ و C = ۱) در همین ایستگاه داشته است. در روش رگرسیون فرآیند گاوسی (GPR) هنگام استفاده از تابع کرنل RBF مقدار پارامتر نویز فرآیند گاوسی بین ۰/۰۱ تا ۰/۱ در نظر گرفته شد و ملاحظه گردید پارامتر نویز ۰/۱ بهترین نتیجه را در پی داشت. همچنین برخلاف روش SVM تغییرات چندانی در پارامتر گاما (γ) در مدل‌های مختلف مشاهده نمی‌شود. از سوی دیگر در همگی روش‌ها برخلاف انتظار، الزاماً با افزایش تعداد پارامترهای ورودی در مدل‌های مختلف نتایج بهتر نمی‌شود و در ایستگاه‌های متفاوت نتایج متفاوتی بدست می‌آید. برای مثال در روش GPR، مدل DO(V) در ایستگاه اول با دارا بودن معیار DC = ۰/۸۷۴ با کاهش ۹ درصدی در مدل DO(VI) در ایستگاه ذکر شده به میزان DC = ۰/۷۹۲ رسیده است که غیرخطی بودن و پیچیده بودن مدل‌سازی اکسیژن محلول در آب را نشان می‌دهد.



جدول ۴- نتایج حاصل از مدل سازی اکسیژن محلول با استفاده از سه مدل LSTM و GPR، SVM

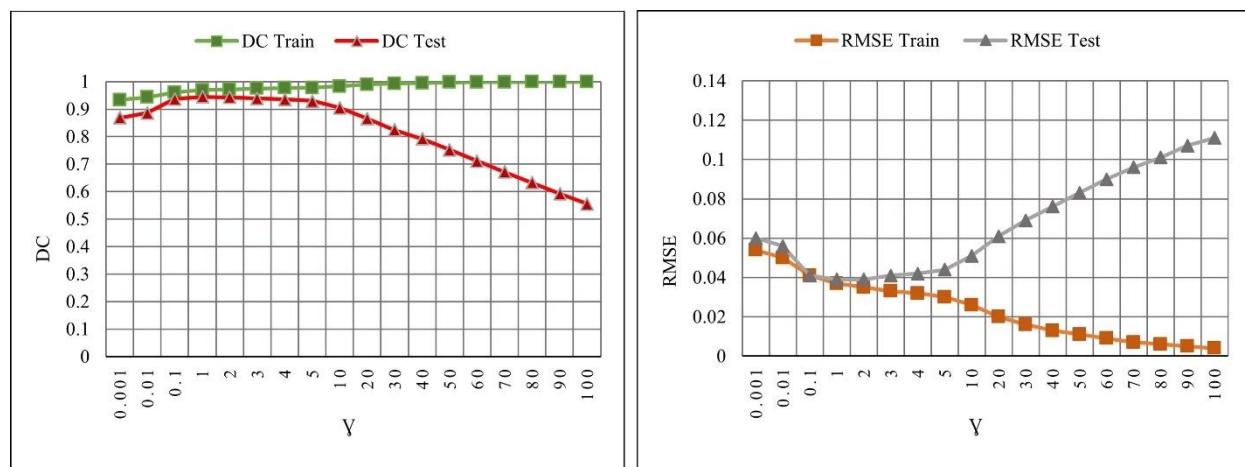
روش	مدل	ایستگاه	پارامترهای بهینه			آموزش			آزمون			
			لايه‌ها	نويز	$\gamma$	$\epsilon$	C	R	DC	RMSE	R	DC
SVM	DO(I)	اول	-	-	۳۲	۰/۲۰۱	۱	۰/۷۴۶	۰/۷۳۸	۰/۸۶۷	۰/۷۳۳	۰/۵۹
		دوم	-	-	۴۵	۰/۰۰۱	۱	۰/۸۸۲	۰/۸۰۸	۰/۹۳۶	۰/۷۰	۰/۷۱
		سوم	-	-	۵۵	۰/۰۰۱	۱	۰/۸۸۷	۰/۷۰۷	۰/۹۴۴	۰/۷۱	۰/۹۰
		اول	-	-	۹	۰/۱۰۱	۱	۰/۹۵۱	۰/۸۵۱	۰/۹۴۷	۰/۴۵	۰/۴۴
		دوم	-	-	۴	۰/۲۰۱	۱	۰/۹۵۸	۰/۸۰۲	۰/۹۵۱	۰/۵۹	۰/۷۲
		سوم	-	-	۷	۰/۱۰۱	۱	۰/۹۶۵	۰/۷۶۴	۰/۹۶۰	۰/۵۸	۰/۸۱
	DO(II)	اول	-	-	۵	۰/۱۰۱	۱	۰/۹۵۱	۰/۸۸۲	۰/۹۵۰	۰/۴۵	۰/۳۹
		دوم	-	-	۶	۰/۱۰۱	۱	۰/۹۷۰	۰/۸۶۲	۰/۹۶۲	۰/۵۱	۰/۶۰
		سوم	-	-	۴	۰/۱۰۱	۱	۰/۹۷۴	۰/۸۳۷	۰/۹۷۲	۰/۴۸	۰/۶۵
		اول	-	-	۶	۰/۱۰۱	۱	۰/۹۷۲	۰/۸۳۶	۰/۹۴۷	۰/۳۴	۰/۴۷
		دوم	-	-	۲	۰/۱۰۱	۱	۰/۹۷۱	۰/۸۷۰	۰/۹۴۲	۰/۴۹	۰/۵۸
		سوم	-	-	۴	۰/۱۰۱	۱	۰/۹۷۸	۰/۸۷۳	۰/۹۵۵	۰/۴۴	۰/۵۹
	DO(III)	اول	-	-	۳	۰/۱۰۱	۱	۰/۹۷۱	۰/۸۲۹	۰/۹۴۹	۰/۳۴	۰/۴۶
		دوم	-	-	۲	۰/۱۰۱	۱	۰/۹۷۳	۰/۸۹۱	۰/۹۷۰	۰/۴۷	۰/۵۳
		سوم	-	-	۱	۰/۱۰۱	۲	۰/۹۷۶	۰/۸۴۶	۰/۹۷۰	۰/۴۸	۰/۶۵
		اول	-	-	۹	۰/۰۰۱	۱	۰/۹۸۴	۰/۸۱۶	۰/۹۲۴	۰/۲۷	۰/۴۹
		دوم	-	-	۲	۰/۱۰۱	۱	۰/۹۷۹	۰/۹۲۴	۰/۹۶۴	۰/۴۲	۰/۴۴
		سوم	-	-	۳	۰/۱۰۱	۱	۰/۹۸۴	۰/۹۵۲	۰/۹۸۱	۰/۳۸	۰/۳۶
GPR	DO(I)	اول	-	-	۲	-	-	۰/۷۵۸	۰/۷۲۷	۰/۶۷	۰/۷۱	۰/۶۰
		دوم	-	-	۲	-	-	۰/۹۰۹	۰/۸۴۹	۰/۹۵۹	۰/۶۲	۰/۶۳
		سوم	-	-	۵	-	-	۰/۹۵۳	۰/۷۳۲	۰/۹۶۳	۰/۶۰	۰/۸۶
		اول	-	-	۱	-	-	۰/۹۵۷	۰/۸۱۱	۰/۹۵۲	۰/۵۹	۰/۷۰
		دوم	-	-	۱	-	-	۰/۹۶۴	۰/۷۴۷	۰/۹۶۳	۰/۵۶	۰/۸۴
		سوم	-	-	۳	-	-	۰/۹۵۴	۰/۸۵۶	۰/۹۵۱	۰/۴۳	۰/۴۴
	DO(II)	اول	-	-	۲	-	-	۰/۹۷۰	۰/۸۵۷	۰/۹۶۸	۰/۵۰	۰/۶۱
		دوم	-	-	۴	-	-	۰/۹۷۵	۰/۸۳۴	۰/۹۷۲	۰/۴۶	۰/۶۸
		سوم	-	-	۳	-	-	۰/۹۷۷	۰/۸۴۹	۰/۹۴۵	۰/۳۱	۰/۴۵
		اول	-	-	۳	-	-	۰/۹۷۷	۰/۸۵۸	۰/۹۶۲	۰/۴۳	۰/۶۱
		دوم	-	-	۳	-	-	۰/۹۷۹	۰/۸۶۷	۰/۹۷۳	۰/۴۲	۰/۶۱
		سوم	-	-	۴	-	-	۰/۹۸۰	۰/۸۷۴	۰/۹۴۵	۰/۲۹	۰/۴۱
	DO(III)	اول	-	-	۳	-	-	۰/۹۷۵	۰/۸۷۳	۰/۹۶۲	۰/۴۱	۰/۵۷
		دوم	-	-	۱	-	-	۰/۹۷۸	۰/۸۳۹	۰/۹۷۴	۰/۴۳	۰/۶۷
		سوم	-	-	۱	-	-	۰/۹۸۰	۰/۷۹۲	۰/۹۳۵	۰/۲۸	۰/۵۳
		اول	-	-	۲	-	-	۰/۹۸۳	۰/۹۱۶	۰/۹۵۹	۰/۳۷	۰/۴۶
		دوم	-	-	۱	-	-	۰/۹۸۴	۰/۹۴۵	۰/۹۸۲	۰/۳۷	۰/۳۹
		سوم	-	-	-	-	-	-	-	-	-	-
LSTM	DO(I)	اول	۱۰	-	-	-	-	۰/۸۷۳	۰/۷۴۷	۰/۸۷۰	۰/۷۲	۰/۵۸
		دوم	۱۰	-	-	-	-	۰/۹۶۰	۰/۸۵۴	۰/۹۵۳	۰/۶۱	۰/۶۲
		سوم	۶	-	-	-	-	۰/۹۶۳	۰/۷۶۴	۰/۹۵۸	۰/۶۱	۰/۸۱
		اول	۱۰	-	-	-	-	۰/۹۵۰	۰/۸۶۰	۰/۹۴۹	۰/۴۵	۰/۴۳
		دوم	۱۰	-	-	-	-	۰/۹۵۸	۰/۸۱۰	۰/۹۴۹	۰/۵۹	۰/۷۰
		سوم	۶	-	-	-	-	۰/۹۶۶	۰/۷۵۵	۰/۹۵۹	۰/۵۴	۰/۸۳
	DO(II)	اول	۱۰	-	-	-	-	۰/۹۵۰	۰/۸۶۱	۰/۹۳۶	۰/۴۳	۰/۴۶
		دوم	۱۲	-	-	-	-	۰/۹۷۲	۰/۸۸۸	۰/۹۶۵	۰/۴۹	۰/۵۴
		سوم	۷	-	-	-	-	۰/۹۷۵	۰/۸۵۸	۰/۹۷۲	۰/۴۷	۰/۶۳
		اول	۱۲	-	-	-	-	۰/۹۷۵	۰/۸۴۳	۰/۹۴۱	۰/۳۴	۰/۴۶
		دوم	۱۲	-	-	-	-	۰/۹۷۶	۰/۸۷۷	۰/۹۶۳	۰/۴۴	۰/۵۷
		سوم	۸	-	-	-	-	۰/۹۸۰	۰/۸۷۷	۰/۹۷۲	۰/۴۴	۰/۵۸
	DO(III)	اول	۱۲	-	-	-	-	۰/۹۷۷	۰/۸۸۹	۰/۹۵۲	۰/۳۲	۰/۳۸
		دوم	۱۴	-	-	-	-	۰/۹۷۸	۰/۸۹۵	۰/۹۶۵	۰/۴۳	۰/۵۲
		سوم	۱۰	-	-	-	-	۰/۹۸۱	۰/۸۵۹	۰/۹۷۴	۰/۴۱	۰/۶۲
		اول	۱۲	-	-	-	-	۰/۹۸۴	۰/۷۷۶	۰/۹۲۵	۰/۲۶	۰/۵۵
		دوم	۱۴	-	-	-	-	۰/۹۸۲	۰/۹۲۸	۰/۹۶۵	۰/۳۸	۰/۴۳
		سوم	۱۲	-	-	-	-	۰/۹۸۴	۰/۹۵۶	۰/۹۸۱	۰/۳۸	۰/۳۴

مقادیر بهینه منتخب تابع هسته  $\gamma$  RBF SVM از طریق فرآیند آزمون و خطا پیدا شد و پارامترهای استاندارد SVM ( $C$  و  $\epsilon$ ) با استفاده از روش اعتبارسنجی متقاطع ۱۰ برابری برای مقادیر بهینه انتخاب شده  $\gamma$  به دست آمد. فرآیند بهینه‌سازی هایپرپارامترهای SVM نشان داد که تغییرات پارامتر هسته  $\gamma$  که نشان دهنده عرض بهینه تابع هسته است از ۱ تا ۵۵ بوده و همچنین مقادیر  $C$  و  $\epsilon$  در محدوده های ۱-۲ و  $0.001-0.201$  بهینه شده است. به طور کلی، مقادیر  $\gamma$  بزرگتر، مرز تصمیم را هموارتر می‌کند و پیچیدگی مدل را افزایش می‌دهد (Han et al., 2007). شکل (۲) نشان می‌دهد که چگونه دقت پیش بینی با توجه به پارامتر هسته  $\gamma$  برای هسته RBF (تغذیه شده با داده‌های ایستگاه ۳ و مدل DO(VI)) متفاوت است. می‌توان متوجه شد که عملکرد مدل SVM به کار گرفته شده ابتدا به آرامی افزایش می‌یابد و سپس با افزایش پارامتر هسته  $\gamma$  RBF از  $0.001$  به  $100$ ، به طور قابل توجهی کاهش می‌یابد. و بدترین عملکرد را در  $\gamma = 100$  می‌توان مشاهده کرد در حالی که پارامتر بهینه هسته RBF در وسط محدوده آزمایش قرار دارد. به طور کلی، هیچ رابطه مشخصی بین پارامتر هسته RBF و معیارهای عملکرد وجود نداشت و ممکن است برای پارامترهای ورودی مختلف در مکان‌های مختلف رفتار متفاوتی داشته باشد.



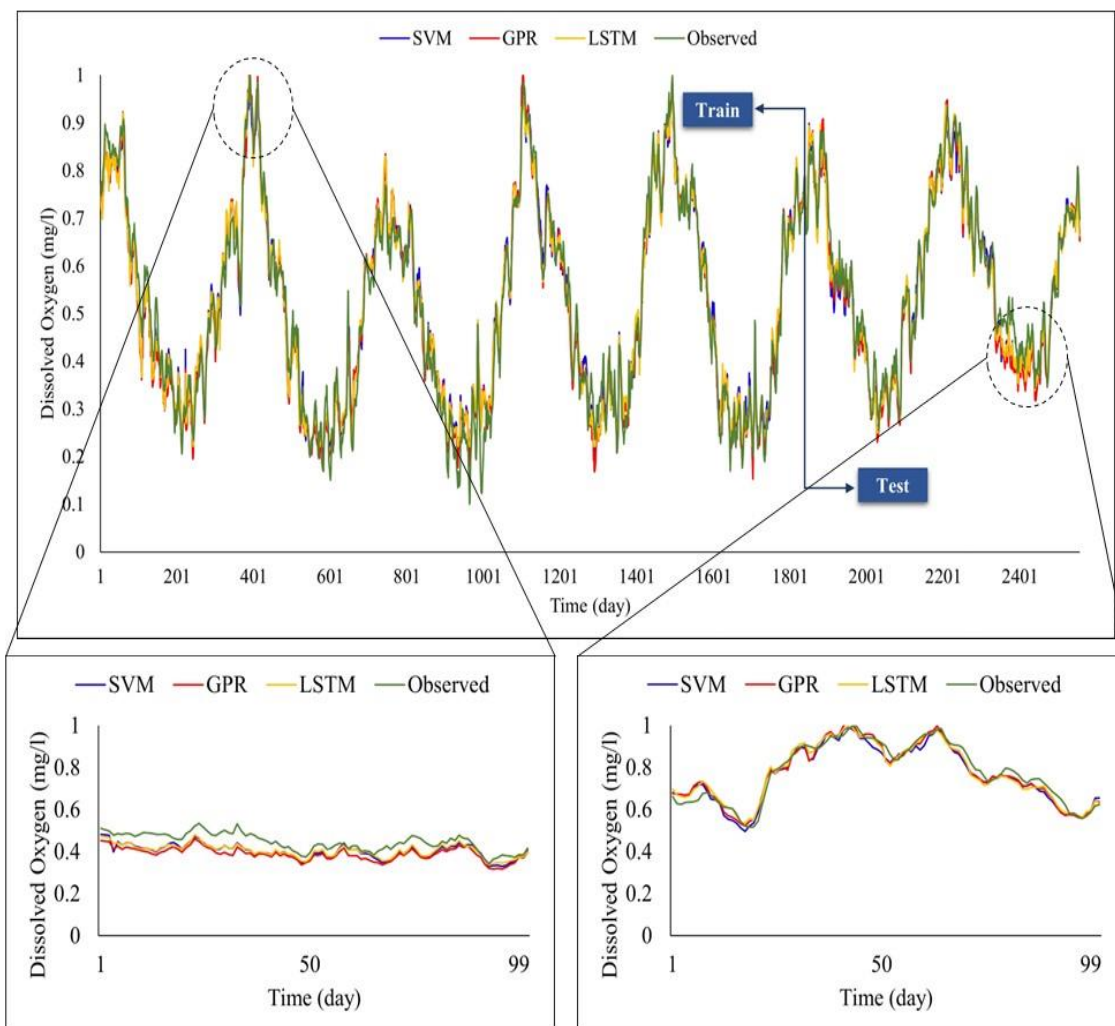
شکل ۲- تأثیر تابع هسته  $\gamma$  RBF بر عملکرد مدل SVM به کار گرفته شده

بر اساس نتایج به دست آمده، مدل‌های مشتق شده از SVM و GPR به همان اندازه خوب عمل کردند. از جدول (۴) می‌توان مشاهده کرد که نوپز بهینه رویکرد GPR برای همه مدل‌ها  $0.1$  است. در مقایسه با SVM، مدل GPR به مقادیر کمتری از پارامتر هسته RBF برای دستیابی به بهترین عملکرد خود نیاز دارد. تغییرات شاخص‌های آماری (DC و RMSE) برای مقادیر مختلف مقادیر  $\gamma$  در مدل GPR در شکل (۳) نشان داده شده است. مدل GPR حساسیت بیشتری به تغییرات گاما نشان می‌دهد و بین بهترین عملکرد ( $\gamma = 1$ ) و بدترین حالت ( $\gamma = 100$ ) تفاوت ۷۰ درصدی مشاهده می‌شود.

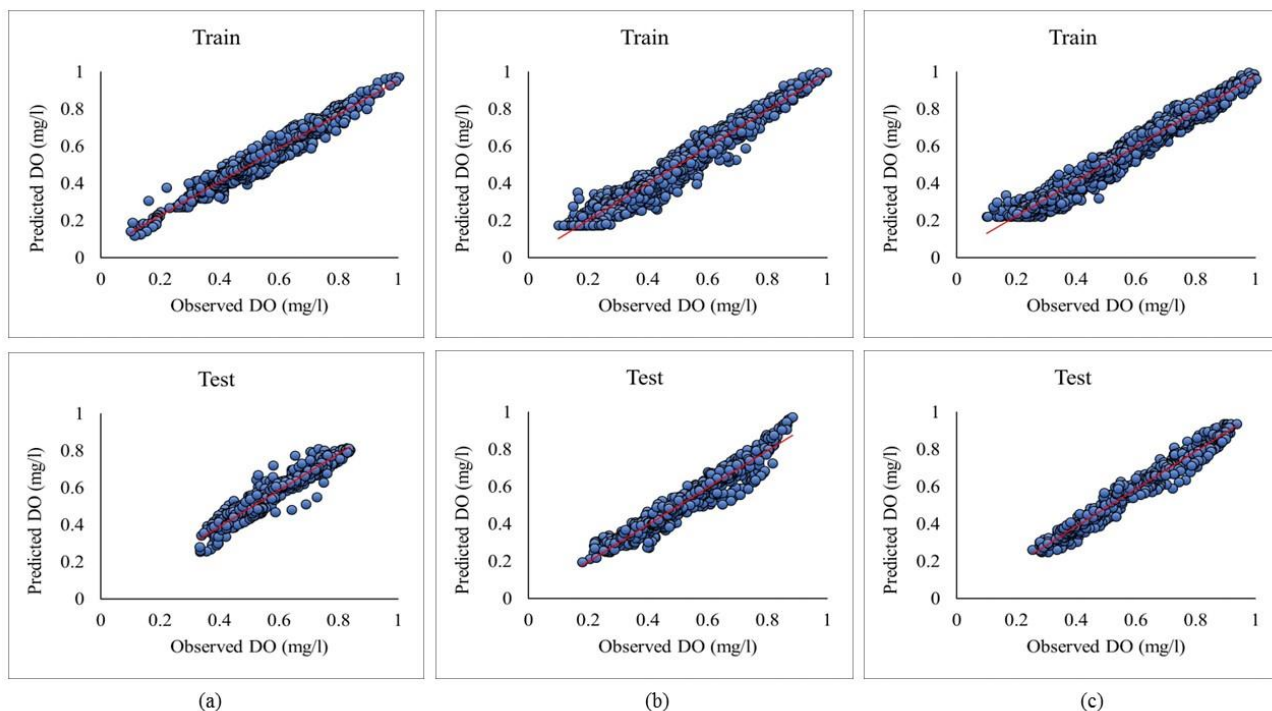


شکل ۳- تأثیر تابع هسته  $\gamma$  RBF بر عملکرد مدل GPR به کار گرفته شده

در روش حافظه طولانی کوتاه-مدت (LSTM) با افزایش تعداد پارامترهای ورودی، تعداد نرون‌ها و نیز معیارهای  $R$  و  $DC$  افزایش داشته و معیار  $RMSE$  به طور کلی روند کاهشی داشت به طوری که در ایستگاه سوم در همه‌ی مدل‌ها نتایج خوبی نسبت به ایستگاه‌های دیگر بدست آمد و مدل  $DO(VI)$  با تعداد ۱۲ نرون و دارا بودن معیارهای ارزیابی  $R=0.981$  و  $DC=0.956$  و  $RMSE=0.034$  برترین مدل در میان همه‌ی مدل‌ها و ایستگاه‌ها و روش‌ها شد. طبق نظر برخی پژوهشگران، روش‌های الحاقی به شبکه عصبی زمانی سبب بهبود ضریب همبستگی می‌شوند که تعداد داده‌ها اندک باشند و توسعه این روش‌ها، برای کاهش تعداد نمونه برداری و کاهش تعداد متغیرهای ورودی و در نتیجه سهولت جمع‌آوری داده‌های ورودی است (Sadeghi et al., 2013). البته برخی دیگر از پژوهشگران نظر متفاوتی دارند و اعتقاد دارند که مدل مناسب بستگی به نوع داده‌ها دارد و مدل‌های مختلف باید مقایسه شوند تا مدل مناسب مشخص شود (Heddami, 2014). به کارگیری مدل LSTM به عنوان یکی از روش‌های یادگیری عمیق نشان داد نتایج حاصل از یادگیری عمیق با وجود زیاد بودن نوع پارامترهای ورودی و همچنین تعداد نمونه‌ها کارایی خوبی در پیش‌بینی کوتاه مدت و بلند مدت اکسیژن محلول دارد. به طور کلی بررسی نتایج مدل‌سازی نشان‌دهنده کارایی بالای روش یادگیری عمیق حافظه طولانی کوتاه-مدت نسبت به روش‌های یادگیری ماشین (SVM و GPR) در پیش‌بینی اکسیژن محلول در رودخانه ساواناه می‌باشد. جهت مقایسه نتایج مربوط به سه روش ذکر شده نمودار سری زمانی مربوط به مدل برتر  $DO(VI)$  در ایستگاه سوم برای داده‌های آموزش و آزمایش در شکل (۴) آورده شده است. همچنین نمودار پراکنش بین داده‌های مشاهداتی و پیش‌بینی شده مدل  $DO(VI)$  برای ایستگاه‌های دوم و سوم و مدل  $DO(V)$  برای ایستگاه اول در روش LSTM برای داده‌های آزمون و صحت‌سنجی در شکل (۵) نمایش داده شده است.



شکل ۴- مقایسه داده‌ای سه روش SVM، GPR و LSTM در پیش‌بینی اکسیژن محلول در مدل برتر



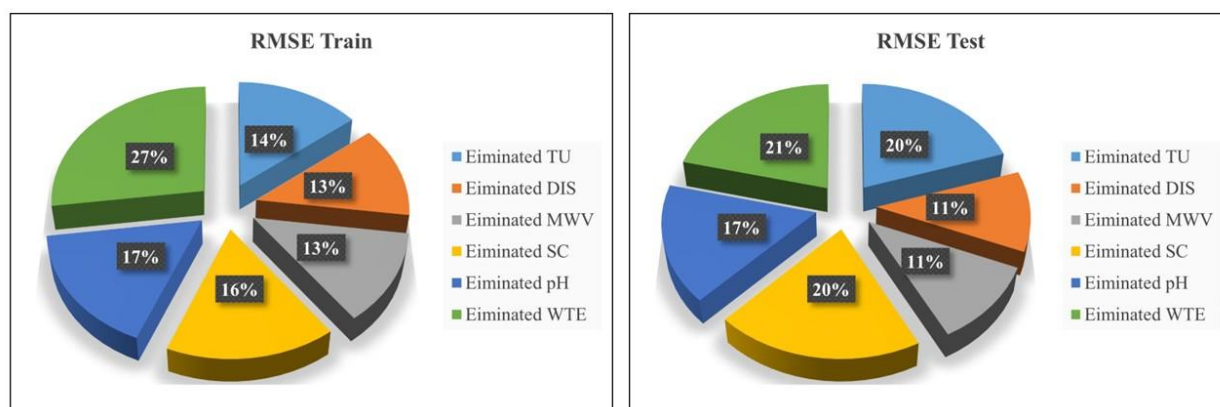
شکل ۵- نمودار پراکنش بین داده‌های مشاهداتی و پیش بینی شده مدل‌های برتر در روش LSTM: (a) DO(V) St1 (b) DO(VI) St2 (c) DO(VI) St3

آنالیز حساسیت

جهت بررسی تأثیر پارامترهای به کار رفته در مدل برتر (DO(VI) در ایستگاه سوم) آنالیز حساسیت انجام گرفت. برای این منظور با حذف تک تک پارامترهای مدل برتر و اجرای دوباره مدل در روش SVM و تعیین معیارهای ارزیابی، میزان تأثیر پارامتر حذف شده در کاهش دقت مدل مورد بررسی قرار گرفت. نتایج حاصل از آنالیز حساسیت به صورت جدول (۵) و شکل (۶) ارائه گردیده است.

جدول ۵- نتایج حاصل از آنالیز حساسیت

آزمون			آموزش			پارامتر حذف شده	مدل
RMSE	DC	R	RMSE	DC	R		
۰/۰۶۸	۰/۸۳۴	۰/۹۷۳	۰/۰۴۳	۰/۹۵۷	۰/۹۷۹	TU	DO(VI)
۰/۰۳۸	۰/۹۴۸	۰/۹۸۱	۰/۰۳۸	۰/۹۶۷	۰/۹۸۴	DIS	
۰/۰۳۸	۰/۹۴۸	۰/۹۸۲	۰/۰۳۸	۰/۹۶۷	۰/۹۸۴	MWV	
۰/۰۶۸	۰/۸۳۴	۰/۹۶۱	۰/۰۴۹	۰/۹۴۶	۰/۹۷۳	SC	
۰/۰۵۶	۰/۸۸۵	۰/۹۷۰	۰/۰۵۰	۰/۹۴۴	۰/۹۷۲	pH	
۰/۰۷۲	۰/۸۱۳	۰/۹۰۷	۰/۰۸۱	۰/۸۵۳	۰/۹۲۵	WTE	



شکل ۶- تأثیر نسبی هر یک از پارامترهای ورودی مدل برتر

همانطور که از شکل و جدول مشخص است با حذف پارامتر دمای آب (WTE) معیار ارزیابی RMSE افزایش ۱۰۰ درصدی داشته و مقدار DC به میزان ۱۴٪ کاهش یافته است. بنابراین می‌توان نتیجه گرفت که پارامتر دمای آب بیشترین تأثیر را در تخمین میزان اکسیژن محلول دارد. همچنین مشاهده می‌شود سرعت متوسط آب (MWV) و دبی جریان (DIS) با توجه به ماهیت و ارتباط نزدیک به هم تأثیر یکسان و کمترین تأثیر را در مدل‌سازی داشته‌اند. از سوی دیگر پارامتر pH نیز تأثیر کمی در پیش‌بینی میزان اکسیژن محلول داشته است. کدورت (TU) و رسانایی ویژه (SC) نیز با افزایش ۸۸ درصدی در میزان RMSE، هردو به عنوان دومین پارامتر تأثیرگذار شناخته شدند.

## نتیجه‌گیری

پیش‌بینی میزان اکسیژن محلول در آب (DO) به عنوان یکی از پارامترهای کیفیت آب به دلیل زیاد بودن پارامترهای دخیل در کیفیت آب همواره با عدم قطعیت همراه بوده و این عدم قطعیت از اعتبار مدل‌های پیش‌بینی می‌کاهد. در این تحقیق میزان اکسیژن محلول در آب با استفاده از دو روش یادگیری ماشین یعنی ماشین بردار پشتیبان (SVM) و رگرسیون فرآیند گاوسی (GPR) و یک روش یادگیری عمیق یعنی حافظه طولانی کوتاه-مدت (LSTM) مدل‌سازی شد. مدل‌های مختلفی در سه ایستگاه متوالی بر روی رودخانه ساواناه تعریف گردید. نتایج حاکی از برتری کامل روش حافظه طولانی کوتاه-مدت بر روش‌های یادگیری ماشین بود. علاوه بر این در مدل‌های یادگیری ماشین نیز روش ماشین بردار پشتیبان از رگرسیون فرآیند گاوسی برتر بود. در حالی که پارامتر بهینه گاما ( $\gamma$ ) برای هر دو روش مقایسه شد مدل GPR حساسیت بیشتری به این پارامتر نشان داد. با این وجود هیچ رابطه مشخصی بین پارامتر هسته RBF و معیارهای عملکرد نمی‌توان تعیین کرد و ممکن است برای پارامترهای ورودی مختلف در مکان‌های مختلف رفتار متفاوتی داشته باشد. از سوی دیگر نتایج نشان داد الزاماً با افزایش تعداد پارامترهای ورودی، نتایج بهتر نمی‌شوند. همچنین برترین مدل، مدلی بود که شامل تمامی پارامترهای کیفی آب بود بنابراین همه‌ی پارامترهای به کار رفته در پیش‌بینی اکسیژن محلول تأثیرگذار بودند. با توجه به نتایج آنالیز حساسیت که ترتیب اهمیت پارامترها به این شکل است: دمای آب (WTE)، رسانایی ویژه (SC)، کدورت (TUR)، میزان pH، دبی (DIS) و متوسط سرعت جریان (MWV). بنابراین میزان دمای آب بیشترین تأثیر را در پیش‌بینی پارامتر کیفی اکسیژن محلول در آب دارد.

"هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد"

## REFERENCES

- Adamowski, J., Adamowski, K., & Bougadis, J. (2010). Influence of Trend on Short Duration Design Storms. *Water Resources Management*, 24(3), 401-413 .
- Ahmed, A. A. M. (2017). Prediction of dissolved oxygen in Surma River by biochemical oxygen demand and chemical oxygen demand using the artificial neural networks (ANNs). *Journal of King Saud University - Engineering Sciences*, 29(2), 151-158 .
- Aizenberg, I., Aizenberg, N. N., & Vandewalle, J. P. L. (2000). *Multi-valued and universal binary neurons: Theory, learning and applications*. Springer Science & Business Media
- Antanasijević, D., Pocajt, V., Povrenović, D., Perić-Grujić, A., & Ristić, M. (2013). Modelling of dissolved oxygen content using artificial neural networks: Danube River, North Serbia, case study. *Environmental Science and Pollution Research*, 20(12), 9006-9013 .
- Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 5(2), 157-166 .
- Chen, M., Pennington, J., & Schoenholz, S. (2018, 2018). Dynamical isometry and a mean field theory of RNNs: Gating enables signal propagation in recurrent neural networks .
- Chung, C.-C., Chen, H.-H., & Ting, C.-H. (2010). Grey prediction fuzzy control for pH processes in the food industry. *Journal of Food Engineering*, 96(4), 575-582 .
- Csábrági, A., Molnár, S., Tanos, P., & Kovács, J. (2017). Application of artificial neural networks to the forecasting of dissolved oxygen content in the Hungarian section of the river Danube. *Ecological Engineering*, 100, 63-72 .
- Elhatip, H., & Kömür, M. (2008). Evaluation of water quality parameters for the Mamasin dam in Aksaray City in the central Anatolian part of Turkey by means of artificial neural networks. *Environmental Geology*, 53 . ۱۱۶۴-۱۱۵۷ ,

- Emamgholizadeh, S., Kashi, H., Marofpoor, I., & Zalaghi, E. (2014). Prediction of water quality parameters of Karoon River (Iran) by artificial intelligence-based models. *International Journal of Environmental Science and Technology*, 11(3), 645-655 .
- Fang, X., & Yuan, Z. (2019). Performance enhancing techniques for deep learning models in time series forecasting. *Engineering Applications of Artificial Intelligence*, 85, 533-542 .
- Graves, A., & Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural networks*, 18(5-6), 602-610 .
- Haidary, A., Amiri, B. J., Adamowski, J., Fohrer, N., & Nakane, K. (2013). Assessing the impacts of four land use types on the water quality of wetlands in Japan. *Water Resources Management*, 27(7), 2217-2229 .
- Han, D., Chan, L., & Zhu, N. (2007). Flood forecasting using support vector machines. *Journal of hydroinformatics*, 9(4), 267-276 .
- Heddam, S. (2014). Modeling hourly dissolved oxygen concentration (DO) using two different adaptive neuro-fuzzy inference systems (ANFIS): a comparative study. (1573-2959 (Electronic)) .
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-term Memory. *Neural computation*, 9, 1735-1780 .
- Huan, J., Cao, W., & Qin, Y. (2018). Prediction of dissolved oxygen in aquaculture based on EEMD and LSSVM optimized by the Bayesian evidence framework. *Computers and Electronics in Agriculture*, 150, 257-265 .
- Huan, J., & Liu, X. (2016). Dissolved oxygen prediction in water based on K-means clustering and ELM neural network for aquaculture. *Transactions of the Chinese Society of Agricultural Engineering*, 32(17), 174-181 .
- Kayacan, E., Ulutas, B., & Kaynak, O. (2010). Grey system theory-based models in time series prediction. *Expert systems with applications*, 37(2), 1784-1789 .
- Khotimah, W. N. (2015). Aquaculture water quality prediction using smooth SVM. *IPTEK Journal of Proceedings Series*, 1.(1)
- Li, X., & Song, J. (2020, 2015). A New ANN-Markov chain methodology for water quality prediction .
- Liu, S., Xu, L., Jiang, Y., Li, D., Chen, Y., & Li, Z. (2014). A hybrid WA-CPSO-LSSVR model for dissolved oxygen content prediction in crab culture. *Engineering Applications of Artificial Intelligence*, 29, 114-124 .
- Liu, S., Xu, L., Li, D & ,Zeng, L. (2012). Dissolved oxygen prediction model of eriocheir sinensis culture based on least squares support vector regression optimized by ant colony algorithm. *Transactions of the Chinese Society of Agricultural Engineering*, 28(23), 167-175 .
- Najah ,A., El-Shafie, A., Karim, O. A., & El-Shafie, A. H. (2013). Application of artificial neural networks for water quality prediction. *Neural Computing and Applications*, 22(1), 187-201 .
- Niroobakhsh, M. (2012). Prediction of water quality parameter in Jajrood River basin: Application of multi layer perceptron (MLP) perceptron and radial basis function networks of artificial neural networks (ANNs). *AFRICAN JOURNAL OF AGRICULTURAL RESEARCH*, 7 .
- Ömer Faruk, D. (2010). A hybrid neural network and ARIMA model for water quality time series prediction. *Engineering Applications of Artificial Intelligence*, 23(4), 586-594 .
- Pal, M., & Deswal, S. (2010). Modelling pile capacity using Gaussian process regression. *Computers and Geotechnics - COMPUT GEOTECH*, 37, 942-947 .
- Palani, S., Liong, S.-Y., Tkalich, P., & Palanichamy, J. (2009). Development of a neural network model for dissolved oxygen in seawater. *Indian Journal of Marine Sciences*, 38 .
- Pelletier, G., Chapra, S., & Tao, H. (2006). QUAL2Kw — A Framework for Modeling Water Quality in Streams and Rivers Using a Genetic Algorithm for Calibration. *Environmental Modelling and Software*, 419-425 .
- Qin, Y., Song, D., Chen, H., Cheng, W., Jiang, G., & Cottrell, G. (2017). A dual-stage attention-based recurrent neural network for time series prediction. *arXiv preprint arXiv:1704.02971* .
- Rasmussen, C. E. (2004, 2003). Gaussian processes in machine learning .
- Roushangar, k., & Chamani, m. (2020). Prediction of River Discharge and Assessment its Relationship at Consecutive Hydrometric Stations Using GPR-EEMD Combined Techniques (Case Study: Housatonic River). *Iranian Journal of Soil and Water Research*, 50(10), 2473-2485 .
- Roushangar, K., & Joulazadeh, S. (2022). Investigation of the Effects of Hydraulic and Sedimentary Parameters on the Rate of Bed Load Transport Using Statistical Correlations and Machine Learning Methods. *Iranian Journal of Soil and Water Research*, 53(1), 99-112 .



- Roushangar, K., & Shahnazi, S. (2019). Evaluating the Performance of Data-Driven Methods for Prediction of Total Sediment Load in Gravel-Bed Rivers [Article]. *IRANIAN JOURNAL OF SOIL AND WATER RESEARCH*, 50(6 #p00814), 1467-1477 .
- Sadeghi, H., Sohrabi Vafa, H., & Nouri, F. (2013). Applications of Neural Network Based on Genetic Algorithm for Long Term Energy Demand Forecasting. *Quarterly Journal of Applied Theories of Economics*, 1(2), 29-52 .
- Sagheer, A., & Kotb, M. (2019). Time series forecasting of petroleum production using deep LSTM recurrent networks. *Neurocomputing*, 323, 203-213 .
- Shi, P., Li, G., Yuan, Y., Huang, G., & Kuang, L. (2019). Prediction of dissolved oxygen content in aquaculture using Clustering-based Softplus Extreme Learning Machine. *Computers and Electronics in Agriculture*, 157, 329-338 .
- Singh, K. P., Basant, A., Malik, A & Jain, G. (2009). Artificial neural network modeling of the river water quality—a case study. *Ecological modelling*, 220(6), 888-895 .
- Soyupak, S., Karaer, F., Gürbüz, H., Kivrak, E., Sentürk, E., & Yazici, A. (2003). A neural network-based approach for calculating dissolved oxygen profiles in reservoirs. *Neural Computing & Applications*, 12(3), 166-172 .
- Sun, M., Hassan, S. G., & Li, D. (2016). Models for estimating feed intake in aquaculture: A review. *Computers and Electronics in Agriculture*, 127, 425-438 .
- U.S. Geological Survey. (2020). National Water Information System data available on the World Wide Web (USGS Water Data for the Nation), accessed January 10, 2020, at URL <https://waterdata.usgs.gov/nwis/>
- Vapnik, V. N. (1995). *The nature of statistical learning theory*. Springer-Verlag New York, Inc.
- Wool, T., Ambrose, R., Martin, J., & Comer, A. (2020). WASP 8: The Next Generation in the 50-year Evolution of USEPA's Water Quality Model. *Water*, 12, 1398 .
- Xue, H., Wang, L., & Li, D. (2013, 2013//). Design and Development of Dissolved Oxygen Real-Time Prediction and Early Warning System for Brocaded Carp Aquaculture. *Computer and Computing Technologies in Agriculture VI*, Berlin, Heidelberg.
- Yang, D., Zhang, X., Pan, R., Wang, Y., & Chen, Z. (2018). A novel Gaussian process regression model for state-of-health estimation of lithium-ion battery using charging curve. *Journal of Power Sources*, 384, 387-395 .