



Dissolved Oxygen Modeling Using Deep Learning and Pre-Processor Methods

Kiyomars Roushangar¹ | Sina Davoudi²

1. Corresponding Author, Department of Water Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran. E-mail: roshangari@tabrizu.ac.ir
2. Department of Water Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran. E-mail: s.davoudi99@ms.tabrizu.ac.ir

Article Info

ABSTRACT

Article type:

Research Article

Article history:

Received: 17 July 2022

Received in revised form:

20 September 2022

Accepted: 04 October 2022

Published online:

25 December 2022

Keywords:

Dissolved Oxygen,

Empirical Mode Decomposition,

Long Short-Term Memory,

Wavelet Transform.

Water pollution is a major global problem that requires constant evaluation and revision of water resources policy at all levels. Dissolved oxygen (DO) is one of the most important indicators of water quality. In the present study, the water quality parameter of dissolved oxygen using intelligent Long Short-Term Memory (LSTM) method based on discrete wavelet transform (DWT) and Complementary Ensemble Empirical Mode Decomposition (CEEMD) pre-processor methods in both temporal and spatial modes. It was investigated in five consecutive stations on the Savannah River. The results of analysis of models showed the ability and high efficiency of the method used in estimating the amount of dissolved oxygen in water. On the other hand, pre-processor methods improved the results. It was also observed in the investigations that the results of analysis based on wavelet transformation in spatial modeling reduced the RMSE error by two percent and also the empirical mode decomposition in temporal modeling by 15 percent. The best evaluation for test data was obtained using the empirical mode decomposition in temporal modeling corresponding to the previous day with values of DC=0.977, R=0.988 and RMSE=0.017. Also, in the spatial modeling to estimate dissolved oxygen in the third station, it was found that the results obtained from the inputs of the dissolved oxygen parameter one day before the second station and two days before the first station have the best results.

Cite this article: Roushangar, K., & Davoudi, S. (2022). Dissolved Oxygen Modeling Using Deep Learning and Pre-Processor Methods. *Journal of Water and Irrigation Management*, 12 (4), 873-890.

DOI: <http://doi.org/10.22059/jwim.2022.345864.1005>



© The Author(s).

DOI: <http://doi.org/10.22059/jwim.2022.345864.1005>

Publisher: University of Tehran Press.



مدل‌سازی اکسیژن محلول با استفاده از روش یادگیری عمیق و روش‌های پیش‌پردازنده

کیومرث روشنگر^۱ | سینا داوودی^۲

۱. نویسنده مسئول، گروه مهندسی آب، دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران. رایانame: roshangari@tabrizu.ac.ir

۲. گروه مهندسی آب، دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران. رایانame: s.davoudi99@ms.tabrizu.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	آلدگی آب یک مشکل بزرگ جهانی است که به ارزیابی مداوم و تجدیدنظر در سیاست منابع آبی در همه سطوح احتیاج دارد. اکسیژن محلول (DO) یکی از مهم‌ترین شاخص‌های کیفیت آب است. در مطالعه حاضر، پارامتر کیفی اکسیژن محلول در آب با استفاده از روش هوشمند حافظه طولانی کوتاه‌مدت (LSTM) بر پایه روش‌های پیش‌پردازنده تبدیل موجک گستته (DWT) و روش تجزیه مد تجربی کامل (CEEMD) در دو حالت زمانی و مکانی در پنج ایستگاه متواتی بر روی رودخانه سوانحه مورد بررسی قرار گرفت. نتایج حاصل از تحلیل مدل‌ها قابلیت و کارایی بالای روش به کاررفته را در تخمین میزان اکسیژن محلول در آب به خوبی نشان داد. از طرفی دیگر روش‌های پیش‌پردازنده باعث بهبود نتایج شدند. هم‌چنین در بررسی‌های انجام‌شده مشاهده شد که نتایج حاصل از تجزیه براساس تبدیل موجک در مدل‌سازی مکانی، به میزان ۱۵ درصد میزان خطای RMSE را کاهش داد. بهترین مدل تجربی در مدل‌سازی زمانی، به میزان ۰/۹۷۷ درصد میزان خطای RMSE را کاهش داد. بهترین حالت ارزیابی برای داده‌های آزمون با استفاده از تجزیه مد تجربی در حالت مدل‌سازی زمانی مربوط به یک روز قبل با مقادیر $DC = ۰/۹۷۷$, $R = ۰/۹۸۸$ و $RMSE = ۰/۰۱۷$ به دست آمد. هم‌چنین در مدل‌سازی مکانی جهت تخمین اکسیژن محلول در ایستگاه سوم نیز مشخص شد نتایج حاصل از رودی‌های پارامتر اکسیژن محلول در یک روز قبل ایستگاه دوم و دو روز قبل ایستگاه اول بهترین نتیجه را دارا می‌باشد.
تاریخ دریافت: ۱۴۰۱/۰۴/۲۶	آلدگی آب یک مشکل بزرگ جهانی است که به ارزیابی مداوم و تجدیدنظر در سیاست منابع آبی در همه سطوح احتیاج دارد. اکسیژن محلول (DO) یکی از مهم‌ترین شاخص‌های کیفیت آب است. در مطالعه حاضر، پارامتر کیفی اکسیژن محلول در آب با استفاده از روش هوشمند حافظه طولانی کوتاه‌مدت (LSTM) بر پایه روش‌های پیش‌پردازنده تبدیل موجک گستته (DWT) و روش تجزیه مد تجربی کامل (CEEMD) در دو حالت زمانی و مکانی در پنج ایستگاه متواتی بر روی رودخانه سوانحه مورد بررسی قرار گرفت. نتایج حاصل از تحلیل مدل‌ها قابلیت و کارایی بالای روش به کاررفته را در تخمین میزان اکسیژن محلول در آب به خوبی نشان داد. از طرفی دیگر روش‌های پیش‌پردازنده باعث بهبود نتایج شدند. هم‌چنین در بررسی‌های انجام‌شده مشاهده شد که نتایج حاصل از تجزیه براساس تبدیل موجک در مدل‌سازی مکانی، به میزان ۱۵ درصد و هم‌چنین تجزیه مد تجربی در مدل‌سازی زمانی، به میزان ۰/۹۷۷ درصد میزان خطای RMSE را کاهش داد. بهترین حالت ارزیابی برای داده‌های آزمون با استفاده از تجزیه مد تجربی در حالت مدل‌سازی زمانی مربوط به یک روز قبل با مقادیر $DC = ۰/۹۷۷$, $R = ۰/۹۸۸$ و $RMSE = ۰/۰۱۷$ به دست آمد. هم‌چنین در مدل‌سازی مکانی جهت تخمین اکسیژن محلول در ایستگاه سوم نیز مشخص شد نتایج حاصل از رودی‌های پارامتر اکسیژن محلول در یک روز قبل ایستگاه دوم و دو روز قبل ایستگاه اول بهترین نتیجه را دارا می‌باشد.
تاریخ بازنگری: ۱۴۰۱/۰۶/۲۹	آلدگی آب یک مشکل بزرگ جهانی است که به ارزیابی مداوم و تجدیدنظر در سیاست منابع آبی در همه سطوح احتیاج دارد. اکسیژن محلول (DO) یکی از مهم‌ترین شاخص‌های کیفیت آب است. در مطالعه حاضر، پارامتر کیفی اکسیژن محلول در آب با استفاده از روش هوشمند حافظه طولانی کوتاه‌مدت (LSTM) بر پایه روش‌های پیش‌پردازنده تبدیل موجک گستته (DWT) و روش تجزیه مد تجربی کامل (CEEMD) در دو حالت زمانی و مکانی در پنج ایستگاه متواتی بر روی رودخانه سوانحه مورد بررسی قرار گرفت. نتایج حاصل از تحلیل مدل‌ها قابلیت و کارایی بالای روش به کاررفته را در تخمین میزان اکسیژن محلول در آب به خوبی نشان داد. از طرفی دیگر روش‌های پیش‌پردازنده باعث بهبود نتایج شدند. هم‌چنین در بررسی‌های انجام‌شده مشاهده شد که نتایج حاصل از تجزیه براساس تبدیل موجک در مدل‌سازی مکانی، به میزان ۱۵ درصد و هم‌چنین تجزیه مد تجربی در مدل‌سازی زمانی، به میزان ۰/۹۷۷ درصد میزان خطای RMSE را کاهش داد. بهترین حالت ارزیابی برای داده‌های آزمون با استفاده از تجزیه مد تجربی در حالت مدل‌سازی زمانی مربوط به یک روز قبل با مقادیر $DC = ۰/۹۷۷$, $R = ۰/۹۸۸$ و $RMSE = ۰/۰۱۷$ به دست آمد. هم‌چنین در مدل‌سازی مکانی جهت تخمین اکسیژن محلول در ایستگاه سوم نیز مشخص شد نتایج حاصل از رودی‌های پارامتر اکسیژن محلول در یک روز قبل ایستگاه دوم و دو روز قبل ایستگاه اول بهترین نتیجه را دارا می‌باشد.
تاریخ پذیرش: ۱۴۰۱/۰۷/۱۲	آلدگی آب یک مشکل بزرگ جهانی است که به ارزیابی مداوم و تجدیدنظر در سیاست منابع آبی در همه سطوح احتیاج دارد. اکسیژن محلول (DO) یکی از مهم‌ترین شاخص‌های کیفیت آب است. در مطالعه حاضر، پارامتر کیفی اکسیژن محلول در آب با استفاده از روش هوشمند حافظه طولانی کوتاه‌مدت (LSTM) بر پایه روش‌های پیش‌پردازنده تبدیل موجک گستته (DWT) و روش تجزیه مد تجربی کامل (CEEMD) در دو حالت زمانی و مکانی در پنج ایستگاه متواتی بر روی رودخانه سوانحه مورد بررسی قرار گرفت. نتایج حاصل از تحلیل مدل‌ها قابلیت و کارایی بالای روش به کاررفته را در تخمین میزان اکسیژن محلول در آب به خوبی نشان داد. از طرفی دیگر روش‌های پیش‌پردازنده باعث بهبود نتایج شدند. هم‌چنین در بررسی‌های انجام‌شده مشاهده شد که نتایج حاصل از تجزیه براساس تبدیل موجک در مدل‌سازی مکانی، به میزان ۱۵ درصد و هم‌چنین تجزیه مد تجربی در مدل‌سازی زمانی، به میزان ۰/۹۷۷ درصد میزان خطای RMSE را کاهش داد. بهترین حالت ارزیابی برای داده‌های آزمون با استفاده از تجزیه مد تجربی در حالت مدل‌سازی زمانی مربوط به یک روز قبل با مقادیر $DC = ۰/۹۷۷$, $R = ۰/۹۸۸$ و $RMSE = ۰/۰۱۷$ به دست آمد. هم‌چنین در مدل‌سازی مکانی جهت تخمین اکسیژن محلول در ایستگاه سوم نیز مشخص شد نتایج حاصل از رودی‌های پارامتر اکسیژن محلول در یک روز قبل ایستگاه دوم و دو روز قبل ایستگاه اول بهترین نتیجه را دارا می‌باشد.
تاریخ انتشار: ۱۴۰۱/۱۰/۰۴	آلدگی آب یک مشکل بزرگ جهانی است که به ارزیابی مداوم و تجدیدنظر در سیاست منابع آبی در همه سطوح احتیاج دارد. اکسیژن محلول (DO) یکی از مهم‌ترین شاخص‌های کیفیت آب است. در مطالعه حاضر، پارامتر کیفی اکسیژن محلول در آب با استفاده از روش هوشمند حافظه طولانی کوتاه‌مدت (LSTM) بر پایه روش‌های پیش‌پردازنده تبدیل موجک گستته (DWT) و روش تجزیه مد تجربی کامل (CEEMD) در دو حالت زمانی و مکانی در پنج ایستگاه متواتی بر روی رودخانه سوانحه مورد بررسی قرار گرفت. نتایج حاصل از تحلیل مدل‌ها قابلیت و کارایی بالای روش به کاررفته را در تخمین میزان اکسیژن محلول در آب به خوبی نشان داد. از طرفی دیگر روش‌های پیش‌پردازنده باعث بهبود نتایج شدند. هم‌چنین در بررسی‌های انجام‌شده مشاهده شد که نتایج حاصل از تجزیه براساس تبدیل موجک در مدل‌سازی مکانی، به میزان ۱۵ درصد و هم‌چنین تجزیه مد تجربی در مدل‌سازی زمانی، به میزان ۰/۹۷۷ درصد میزان خطای RMSE را کاهش داد. بهترین حالت ارزیابی برای داده‌های آزمون با استفاده از تجزیه مد تجربی در حالت مدل‌سازی زمانی مربوط به یک روز قبل با مقادیر $DC = ۰/۹۷۷$, $R = ۰/۹۸۸$ و $RMSE = ۰/۰۱۷$ به دست آمد. هم‌چنین در مدل‌سازی مکانی جهت تخمین اکسیژن محلول در ایستگاه سوم نیز مشخص شد نتایج حاصل از رودی‌های پارامتر اکسیژن محلول در یک روز قبل ایستگاه دوم و دو روز قبل ایستگاه اول بهترین نتیجه را دارا می‌باشد.

استناد: روشنگر، ک. و داوودی، س. (۱۴۰۱). مدل‌سازی اکسیژن محلول با استفاده از روش یادگیری عمیق و روش‌های پیش‌پردازنده. نشریه مدیریت آب و آبیاری، ۱۲، (۴)، ۸۷۳-۸۹۰. DOI: <http://doi.org/10.22059/jwim.2022.345864.1005>



© نویسندهان

ناشر: مؤسسه انتشارات دانشگاه تهران

۱. مقدمه

پیش‌بینی هیدرولوژیکی و آب‌وهایی با پیچیدگی بالا، پویایی و عدم ایستایی، همیشه یک چالش برای هیدرولوژیست‌هایی است که نقش اساسی آن را در مدیریت محیط زیست و منابع آب و همچنین در کاهش بلایای مریبوط به آب تشخیص می‌دهند. در سال‌های اخیر افزایش قابل توجهی در تعداد رویکردهای علمی اعمال شده در مدل‌سازی و پیش‌بینی هیدرولوژیک، از جمله رویکردهای "مبتنی بر داده" یا "داده‌محور" مشاهده می‌شود. چنانی رویکردهای مدل‌سازی شامل معادلات ریاضی است که نه از فرایند فیزیکی حوزه، بلکه از تجزیه و تحلیل سری‌های زمانی مؤثر در پدیده به عنوان ورودی و خروجی هم‌زمان گرفته شده است (Nourani *et al.*, 2014). برای درک صحیح از آب‌های سطحی شناختن پارامترهای کیفیت آب که توسط داده‌های شبکه‌های نظارتی ارائه می‌شود، امری حیاتی است. عملکرد یک شبکه نظارت با توجه به معیارهای مختلف (به عنوان مثال بازده هزینه) می‌تواند بهبود یابد، یا با تخمین پارامترهای خاص از سایر پارامترها تسهیل شود (Csábrági *et al.*, 2017). مدل‌های 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).

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. به همین منظور پژوهش‌های متعددی در این زمینه با استفاده از روش‌های یادگیری ماشین انجام شده است. (Soyupak *et al.*, 2003) در یک مطالعه از مدل شبکه عصبی برای پیش‌بینی غلظت اکسیژن محلول در حالت ثابت و وابسته به فضای شبکه‌پایدار در سه مخزن مختلف استفاده کردند. ضریب همبستگی هم برای متغیرهای خروجی اندازه‌گیری شده و هم برای مدل بیش از ۰/۹۵ بود. Elhatip and Kömür (2008) پارامترهای کیفیت آب در مخزن سد ماماسین را مدل‌سازی کردند. نتایج توانایی ANN^۱ را برای پیش‌بینی اکسیژن محلول در مناطق شارژ و تخلیه در سایت سد ماماسین نشان داد. Palani *et al.* (2009) در مطالعه دیگری در سنگاپور برای تخمین هفتگی میزان اکسیژن محلول در آب دریا از دو شبکه عصبی پرسپترون چند لایه با قابلیت پس‌انتشار خطأ و شبکه عصبی رگرسیون تعیین یافته استفاده کردند. نتیجه نشان داد شبکه عصبی رگرسیون تعیین یافته نتایج بهتری داشت. Niroobakhsh (2012) جهت محاسبه غلظت کل جامد محلول در آب (TDS) از دو شبکه ANN، پرسپترون چند لایه (MLP)^۲ و عملکرد پایه شعاعی (RBF)^۳ برای رودخانه جاجرود ایران استفاده کرد که نتایج نشان داد MLP و RBF قادر به شبیه‌سازی متغیرهای کیفیت آب رودخانه جاجرود با دقت بیش از ۹۰ درصد هستند. در مورد مدل‌های هیبریدی Liu *et al.* (2013) یک الگوریتم IPSO-LSSVR^۴ برای ساخت یک مدل پیش‌بینی غیرخطی اتخاذ شد. IPSO-LSSVR مورداً مایش قرار گرفت و با استفاده از الگوریتم‌های دیگر برای پیش‌بینی محتوا اکسیژن محلول در استخراج‌های کشت خرچنگ رودخانه مقایسه شد. نتایج آزمایش نشان می‌دهد که مدل پیشنهادی IPSO-LSSVR می‌تواند دقت پیش‌بینی را افزایش دهد و عملکرد تعیین را بهتر از رگرسیون بردار پشتیبانی استاندارد (SVR)^۵ و شبکه عصبی BP^۶ انجام دهد. Ji *et al.* (2017) به منظور پیش‌بینی غلظت DO در یک رودخانه کم اکسیژن در جنوب شرقی چین از ماشین بردار پشتیبانی (SVM) استفاده کردند. چهار مدل کالیبراسیون مختلف، به طور خاص، رگرسیون خطی چندگانه، شبکه عصبی انتشار عقب، شبکه عصبی رگرسیون عمومی و SVM ایجاد شد. نتایج نشان داد که مدل SVM در پیش‌بینی غلظت DO در رودخانه ون-روی تانگ نسبت به مدل‌های دیگر برتر است. Ahmed (2017) میزان اکسیژن محلول در آب رودخانه سورما را با استفاده از شبکه عصبی پیشخور و تابع پایه شعاعی

موردمطالعه قرار داد. نتایج نشان داد تفاوت بین دو شبکه عصبی در هر دو حالت تک متغیره و دو متغیره مشابه بود (ضریب همبستگی بهترتب ۷۹/۰ و ۸۸/۰ شد). Shi *et al.* (2019) همچنین در یک روش جدید مبتنی بر خوشة (CSELM)^۸ برای پیش‌بینی دقیق و کارآمد تغییر اکسیژن محلول از داده‌های سری زمانی استفاده کردند و نتیجه نشان داد که CSELM از نظر دقت و کارایی در پیش‌بینی محتوای اکسیژن محلول در دنیای واقعی، نتایج پیش‌بینی بهتری نسبت به مدل‌های ELM و PLS-ELM به دست می‌آورد. Hosseinpahani *et al.* (2021) عملکرد روش‌های ماشین بردار پشتیبان و شبکه عصبی تابع پایه شعاعی در پیش‌بینی کیفیت آب سیمینه رود مقایسه کردند. برای این منظور پارامترهای نسبت جذب سدیم و یون کلر به عنوان شاخص‌های کیفیت آب در مصارف کشاورزی در نظر گرفته شد. براساس نتایج مدل ماشین بردار پشتیبان نسبت به مدل شبکه عصبی تابع پایه شعاعی از دقت و عملکرد بهتری برای پیش‌بینی پارامترهای کیفیت آب رودخانه سیمینه رود برخوردار بود.

بررسی منابع انجام شده، نشان از کاربرد بالای روش‌های هوشمند مانند شبکه عصبی مصنوعی در زمینه پیش‌بینی اکسیژن محلول در آب می‌باشد. با این حال، در مورد ادبیات فنی مسئله مطالعات چندانی در رابطه با کاربرد یادگیری عمیق در پیش‌بینی میزان اکسیژن محلول در آب صورت نگرفته است. از طرفی در سال‌های اخیر استفاده از روش‌های تجزیه سیگنال به عنوان روشی نوین و بسیار مؤثر در زمینه تحلیل سیگنال‌ها و سرهای زمانی موردن توجه قرار گرفته است. در این روش سیگنال اصلی به چندین زیرسیگنال تجزیه شده و داده‌های حاصل از تجزیه با معادلات مناسب برآش می‌شود. از جمله این روش‌ها روش تبدیل موجک و روش جدید تجزیه مذکوری کامل است که در روند تجزیه‌سازی آن، حجم محدودی از نویز سفید وارد سیگنال اصلی شده و با استفاده از جنبه‌های مثبت آماری نویز سفید که توزیع متوازن در حوزه فرکانس دارد، اثر نویز متناوب از روند تجزیه حذف می‌شود. لذا در این پژوهش سعی خواهد شد با استفاده از روش نوین شبکه‌های بازگشتهای عمیق و روش‌های پیش‌پردازنه اکسیژن محلول در آب بررسی و مدل‌سازی شود.

۲. مواد و روش‌ها

۲.۱. موقعیت و ویژگی‌های منطقه مورد مطالعه

رودخانه ساواناه^۹ یکی از رودخانه‌های ایالات متحده آمریکا است که به اقیانوس اطلس می‌ریزد. این رودخانه بزرگ در جنوب شرقی ایالات متحده است که بیشتر میان ایالت‌های کارولینای جنوبی و جورجیا را تشکیل می‌دهد. 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 ۳۰ مایل (۴۸۴ کیلومتر) است. ساواناه از تلاقی رودخانه توگالو و رودخانه سنکا تشکیل شده است. امروزه این محل تلاقی در زیر دریاچه هارتل غوطه‌ور است. تنگه تالولا که بر روی رودخانه تالولا واقع شده است، شاخه‌ای از رودخانه توگالو است که شاخه شمال غربی رودخانه ساواناه را تشکیل می‌دهد. داده‌های مورداستفاده در این پژوهش مربوط به پنج ایستگاه هیدرولوژیکی متواالی در طول هفت سال (۲۰۱۵ تا ۲۰۲۱) بر روی رودخانه ساواناه می‌باشد که توسط سازمان زمین‌شناسی آمریکا (USGS) گردآوری شده است. در شکل (۱) منطقه موردمطالعه، موقعیت ایستگاه‌ها و میزان تغییرات اکسیژن محلول در پنج ایستگاه متواالی در طول هفت سال به صورت روزانه نشان داده شده و همچنین در جدول (۱) مشخصات ایستگاه‌ها نمایش داده شده است.

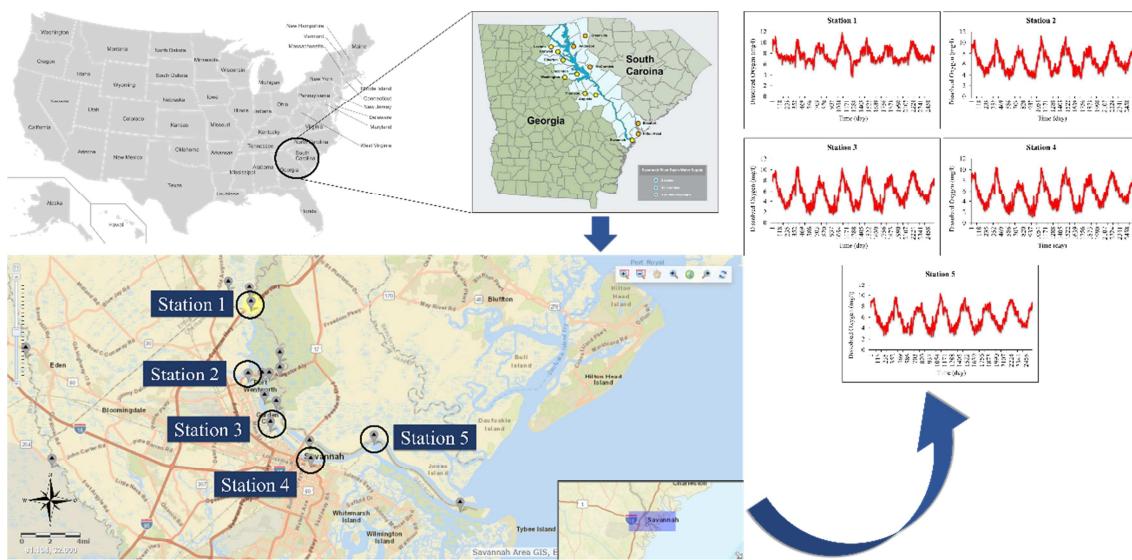


Figure 1. Study area and location of stations

Table 1. Stations specifications

Hydrometric station	Station no.	Station Specifications			Dissolved Oxygen (mg/l)		
		Longitude	Latitude	Distance to previous station (km)	Min.	Max.	Ave.
Station 1	02198840	81°09'03.9"	32°14'07.7"	-	3.656	11.814	7.697
Station 2	02198920	81°09'17.7"	32°09'55.2"	7.807	3.202	11.286	6.527
Station 3	021989715	81°07'42.0"	32°06'57.9"	6.021	1.522	10.602	5.631
Station 4	021989773	81°04'52.9"	32°04'49.5"	5.942	1.083	10.445	5.527
Station 5	0219897993	81°00'25"	32°06'11"	7.449	2.454	10.350	5.993

۱.۲. تبدیل موجک (WT)

تبدیل موجک ابزاری مؤثر برای استخراج اطلاعات داده با تجزیه سیگنال اصلی به حوزه‌های فرکانس پایین و فرکانس بالا است (Yadav and Eliza, 2017). موجک (Wavelet) یکسری از توابع ریاضی است که جهت تجزیه سیگنال پیوسته به مؤلفه‌های فرکانسی آن به کار می‌رود که سطح تفکیک هر مؤلفه برابر با مقیاس آن است. موجک‌ها (که به عنوان موجک مادر شناخته می‌شوند) نمونه‌های انتقال یافته و مقیاس شده یک تابع (موجک مادر) با طول متناهی و نوسانی بهشت میرا هستند. تابع موجک تابعی است که دو ویژگی مهم نوسانی بودن و کوتاه مدت بودن را دارد (Roushangar and Ghasempour, 2020).

تابعی موجک است اگر و فقط اگر تبدیل فوریه آن (ω) شرط زیر را ارضاء کند (Lau and Weng, 1995):

$$\int_{-\infty}^{+\infty} \frac{|\psi(\omega)|}{|\omega|^2} d\omega < +\infty \quad (1)$$

این شرط با عنوان شرط پذیرفتگی برای موجک (Ψ) شناخته می‌شود. (Ψ) تابع موجک مادر است (رابطه ۲) که ضرایب a و b در آن نقش انتقال و مقیاس سیگنال مورد نظر را دارند (Lau and Weng, 1995).

رابطه ۲

$$\varphi_{a,b}(x) = \frac{1}{\sqrt{a}} \psi\left(\frac{x-b}{a}\right) \quad (2)$$

تابعی موجک دارای انواع بسیاری هستند که مهم‌ترین و پرکاربردترین آن‌ها شامل هار، مورلت، کلاه مکزیکی، سیملت، گوسین است. تبدیل موجک پیوسته به عنوان روش جایگزین تبدیل فوریه زمان-کوتاه ارائه شد و هدف آن، فائق‌آمدن بر مشکلات مربوط به تفکیک‌پذیری در تبدیل فوریه زمان-کوتاه است. در عمل اکثر سری‌های زمانی هیدرولوژیکی به صورت گسسته در زمان‌هایی مشخص اندازه‌گیری می‌شوند. بنابراین کاربرد موجک گسسته می‌تواند

تناسب بهتری با این نوع سری زمانی داشته باشد. تبدیل موجک گسسته در عمل همان تبدیل موجک پیوسته است (نسخه گسسته شده آن) که در آن یکسری موجک از تبدیل موجک پیوسته نمونه گرفته است و سیستم‌های کامپیوتری قابلیت محاسبه آن را با هزینه زمانی کمتر داراست. اصول تبدیل موجک گسسته به روشنی تحت عنوان کدینگ زیرباند برمری گردد که در سال ۱۹۷۶ سنگبنای اولیه آن گذارده شد و در آن نوعی توصیف زمان-مقیاس از سیگنال گسسته با استفاده از فیلترهای دیجیتال ارائه می‌شود. تبدیل موجک، حاصل شباهت‌سنجدی (کوروولیشن) بین محتوای فرکانسی (مقیاسی) سیگنال وتابع موجک در مقیاس‌های مختلف است (Adamowski *et al.*, 2009). تجزیه کردن سری‌های زمانی با استفاده از فیلترهای مشخص (موجک و توابع مقیاس‌گذاری شده) دو نوع زیرسری را به وجود می‌آورند؛ بردارهای تقریبی یا باقیمانده و بردارهای جزئیات. این ضرایب حاصل از درهم‌پیچیدن سری زمانی اصلی با فیلتر پایین‌گذر همان تابع مقیاس‌گذاری است و فیلتر بالاگذر همان تابع موجک است. تابع تبدیل موجک قابلیت تجزیه سری زمانی به چندین زیرسری زمانی با مقیاس‌های مختلف را دارد و با بررسی زیر سری‌های زمانی منتجه از سری زمانی کلی، رفتار کوچک‌مقیاس و بزرگ‌مقیاس یک فرایند هیدرولوژیکی را آنالیز می‌کند. روابطی که بیشتر برای تخمین سطح تجزیه مورداستفاده قرار می‌گیرد به صورت زیر است:

$$L = \text{int}[\log(N)], L = \frac{\log\left(\frac{N}{2p-1}\right)}{\log 2} \quad (3)$$

که در آن، L سطح تجزیه، N تعداد نقاط داده در سری زمانی و p برابر با زمان محو شونده برای موجک مادر انتخاب شده است (Chou, 2014).

۲.۳. روش تجزیه مدل تجربی (EMD)^{۱۱}

روش تجزیه مدل تجربی روشی برای تجزیه سیگنال‌های گوناگون است که این عمل در فرایندی تحت عنوان غربال‌کردن صورت می‌گیرد. طی این فرایند سیگنال اصلی به تعدادی مؤلفه با محتوای بسامدی متفاوت تجزیه می‌شود. روش EMD طبق رابطه (۴) سیگنال اصلی (x) را به تعدادی مدل ذاتی (IMF)^{۱۲} تجزیه می‌کند (Amirat *et al.*, 2018):

$$x(n) = \sum_{i=1}^n c_i(x) + r_n(x) \quad (4)$$

که ($r_n(x)$ همان مؤلفه باقی‌مانده، بعد از n تعداد IMFs و ($c_i(x)$ است. یک داده ممکن است در یک زمان دارای چندین مدل ذاتی باشد. این مدهای نوسانی، تابع‌های مدل ذاتی (IMF) نام دارند و دارای دو شرایط هستند: ۱- در کل داده‌ها، تعداد نقاط فرین (اکسترمم) و نقاط صفر با هم برابر و یا حداکثر دارای یک واحد اختلاف هستند، ۲- در هر نقطه میانگین پوش برآش داده شده بر نقاط بیشینه محلی و پوش برآش داده شده بر نقاط کمینه محلی باید صفر باشد. به علت وجود تنابع و نویز در سیگنال‌ها، در برخی موارد به علت اختلاط مدها؛ توزیع حوزه زمان-فرکانس دچار انقطاع می‌شود و عملکرد EMD دچار نقص می‌شود (چون میانگین IMF‌ها حالتی نامشخص به خود می‌گیرد). جهت رفع این ایراد، روشی متفاوت با عنوان روش تجزیه مدل تجربی یکپارچه (EEMD)^{۱۳} پیشنهاد شد. در روند تجزیه‌سازی آن، حجم محدودی از نویز سفید وارد سیگنال اصلی می‌شود. با استفاده از جنبه‌های مثبت آماری نویز سفید که توزیع متوازن در حوزه فرکانس دارد، اثر نویز متناوب از روند تجزیه حذف می‌شود. در روش تجزیه مدل تجربی یکپارچه کامل (CEEMD)^{۱۴} نویز سفید به صورت دوتایی (یکی مثبت و دیگری منفی) به داده اصلی اضافه می‌شود تا دو سری IMF مجموع ساخته شود. بنابراین ترکیبی متشکل از داده اصلی و نویز اضافی داریم که مجموع IMF‌ها برابر سیگنال اصلی می‌شود و نویز اضافی دامنه موجی از مرتبه pm خواهد بود (Wu and Huang, 2004).

۴.۲. حافظه طولانی کوتاه‌مدت (LSTM)^{۱۵}

شبکه عصبی مکرر، همان RNN ساده، یکی از رویکردهای شبکه عصبی بازگشتی است که برای مدل‌سازی داده‌های دنباله‌دار استفاده می‌شود. ویژگی اصلی RNN، بازگشت تأخیر شبکه است که موجب می‌شود شبکه به توصیف عملکرد پویای سیستم قادر باشد. بازگشت تأخیر 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 کوتاه‌مدت است. ضعف RNN، در هنگام یادگیری وابستگی‌های دوربرد یا به خاطرسپردن بستر طولانی‌مدت، در برنامه‌های پیش‌بینی سری زمانی است (Sagheer and Kotb, 2019).

سلول‌های حافظه طولانی کوتاه‌مدت در سال ۱۹۹۷ معرفی شد که عملکردهای RNN را به طرز چشمگیری بهبود می‌بخشنند (Hochreiter and Schmidhuber, 1997). مدل حافظه طولانی کوتاه‌مدت (LSTM) یک نوع RNN است که از سلول حافظه LSTM ساخته شده بهمنظور نشان دادن وابستگی‌های طولانی‌مدت در داده‌های سری زمانی استفاده می‌کند. علاوه بر این، LSTM برای حل مسئله گرادیان ناپذیدشده RNN در صورت وجود حفظ زمینه طولانی‌مدت، موردنبیاز است (Bengio et al., 1994). تغییر عمدۀ LSTM نسبت به سلول RNN معمولی، روش محاسبه فعال‌سازی است. فعال‌سازی در مرحله t ، براساس چهار نوع دروازه محاسبه می‌شود که دروازه اطلاعات، دروازه فراموشی، دروازه خروجی و دروازه سلول شناخته می‌شود (Fang and Yuan, 2019).

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

$$i_t = \sigma(W_{ia} \cdot h_{t-1} + W_{ix} \cdot x_t) \quad (5)$$

که در آن σ تابع غیرخطی مثل تابع سیگموید است. W_{ia} و W_{ix} ماتریس‌هایی هستند که به ترتیب h_{t-1} را با x_t و h_t متصل می‌کنند. به‌طور مشابه، ورودی دروازه فراموشی و ورودی دروازه خروجی به صورت زیر محاسبه می‌شود:

$$f_t = \sigma(W_{fa} \cdot h_{t-1} + W_{fx} \cdot x_t) \quad (6)$$

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

ورودی دروازه سلولی به صورت زیر محاسبه می‌شود:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot K_t \quad (7)$$

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

$$K_t = \tanh(W_{ca} \cdot h_{t-1} + W_{cx} \cdot x_t) \quad (8)$$

که در آن \tanh تابع مماس مضرب است. در آخر، فعال‌سازی در مرحله t به صورت زیر محاسبه می‌شود:

$$h_t = o_t \cdot \tanh(C_t) \quad (9)$$

۴.۳. نرمالیزه کردن داده‌ها

یکی از مراحل اصلی در استفاده از روش‌های هوشمند پیش‌پردازش داده‌ها می‌باشد. با توجه به دامنه وسیع داده‌های ورودی و بهمنظور افزایش دقت و سرعت مدل‌سازی، داده‌های مورداستفاده در این پژوهش با استفاده از رابطه (۱۰) در بازه (۰/۰ تا ۱) نرمال شده‌اند و در نهایت مجموع داده‌های فوق برای مدل‌سازی به کار گرفته شده‌اند.

$$X_{istd} = 0.1 + 0.9 \times \left(\frac{X_i - X_{imin}}{X_{imax} - X_{imin}} \right) \quad (10)$$

که در آن X_{imin} کمترین داده و X_{imax} بیشترین داده از نظر مقدار است (Roushangar and Shahnazi, 2019).

۲.۶. معیارهای ارزیابی

به منظور ارزیابی کارایی روش استفاده شده در تخمین میزان اکسیژن محلول روزانه، از سه پارامتر آماری استفاده شد که عبارتند از ضریب همبستگی بین مقادیر مشاهداتی و محاسباتی (R)^۷، ضریب تبیین که همبستگی بین مقادیر پیش‌بینی شده و واقعی را نشان می‌دهد و یکی از معیارهای مهم ارزیابی قابلیت یک مدل است (DC)^۸ و ریشه میانگین مربعات خطای که بیانگر میزان انحراف بین مقادیر پیش‌بینی شده است ($RMSE$)^۹. هرچه مقدار R و DC برای یک مدل به یک نزدیک‌تر و مقدار $RMSE$ کوچک‌تر باشد به معنی مطلوب‌بودن آن مدل است. روابط این پارامترهای آماری به صورت زیر است:

$$DC = 1 - \frac{\sum_{i=1}^N (V_o - V_p)^2}{\sum_{i=1}^N (V_o - \bar{V}_o)^2} \quad (11)$$

$$R = \frac{\sum_{i=1}^N (V_o - \bar{V}_o) \times (V_p - \bar{V}_p)}{\sqrt{\sum_{i=1}^N (V_o - \bar{V}_o)^2 \times (V_p - \bar{V}_p)^2}} \quad (12)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (V_o - V_p)^2}{N}} \quad (13)$$

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

۳. نتایج و بحث

۳.۱. تعریف مدل‌های ورودی

در مطالعه حاضر جهت مدل‌سازی اکسیژن محلول در آب به صورت زمانی از پارامتر اکسیژن محلول در آب در پنج روز متوالی استفاده شده است. به این ترتیب که اکسیژن محلول در یک روز تابع اکسیژن محلول در یک، دو، سه، چهار و پنج روز قبل از خود باشد. این مدل سازی در پنج ایستگاه متوالی مورد ارزیابی قرار گرفته است. از طرف دیگر، در مدل‌سازی مکانی به ارزیابی و امکان‌سنجی ارتباط اکسیژن محلول در سه ایستگاه هیدرومتریک متوالی پرداخته شده است. به این ترتیب که برای پیش‌بینی اکسیژن محلول در ایستگاه پایین‌دست از داده‌های اکسیژن محلول در بالا دست استفاده شده است. به این منظور برای پیش‌بینی اکسیژن محلول در ایستگاه سوم از اکسیژن محلول در دو روز متوالی در دو ایستگاه اول و دوم استفاده شده است. در تمامی مدل‌سازی‌ها پس از نرم‌الیزه کردن داده‌ها ابتدا سری‌های زمانی توسط تبدیل موجک و تجزیه یکپارچه مد تجربی کامل به زیرسری‌هایی تجزیه شده و سپس این زیر‌سری‌ها به عنوان ورودی مدل LSTM استفاده شد. در شکل (۲) شماتیک مدل‌سازی صورت گرفته در پژوهش نشان داده شده است. همچنین جدول (۲) بیان گر مدل‌های تعریف شده است. لازم به توضیح است که داده‌های سری زمانی اکسیژن محلول از سال ۲۰۱۵-۲۰۱۹ به عنوان داده‌های آموزش و بقیه داده‌ها (۲۰۲۰ و ۲۰۲۱) به عنوان داده‌های آزمون مورد استفاده قرار گرفته‌اند.

Table 2. Defined models

Temporal Modelling			Spatial Modelling		
Model	Input	Target	Model	Input	Target
T(I)	DO(t-1)	DO(t)	S(I)	DO ₁ (t-1)	DO ₃ (t)
T(II)	DO (t-1, t-2)	DO(t)	S(II)	DO ₁ (t-2)	DO ₃ (t)
T(III)	DO (t-1, t-2, t-3)	DO(t)	S(III)	DO ₂ (t-1)	DO ₃ (t)
T(IV)	DO (t-1, t-2, t-3, t-4)	DO(t)	S(IV)	DO ₂ (t-2)	DO ₃ (t)
T(V)	DO (t-1, t-2, t-3, t-4, t-5)	DO(t)	S(V)	DO ₁ (t-1), DO ₁ (t-2)	DO ₃ (t)
			S(VI)	DO ₂ (t-1), DO ₂ (t-2)	DO ₃ (t)
			S(VII)	DO ₂ (t-1), DO ₁ (t-2)	DO ₃ (t)

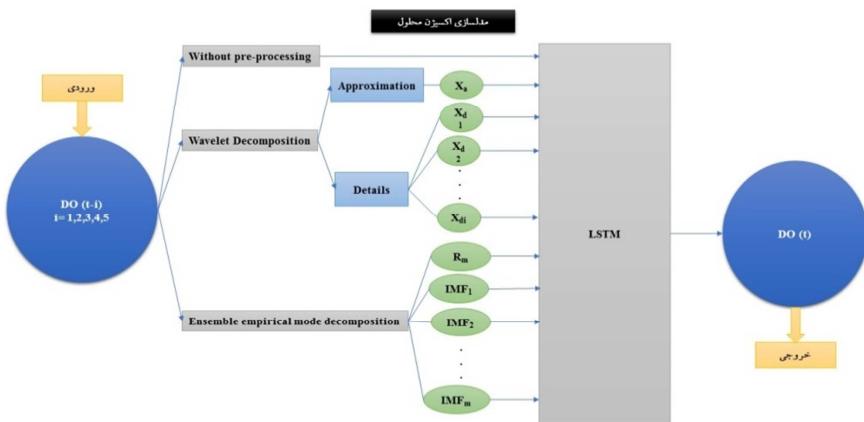


Figure 2. The schematic view of considered modeling in the study

۲.۳. نتایج به دست آمده برای مدل LSTM بدون تجزیه داده‌ها

۲.۳.۱. مدل‌سازی زمانی

جهت تخمین میزان اکسیژن محلول در آب براساس سری زمانی اصلی و بدون تجزیه آن به چندین زیرسری، پنج مدل براساس داده‌های روزانه اکسیژن محلول مربوط به روزهای قبل تعریف شد و کارایی روش حافظه طولانی کوتاه‌مدت مورد بررسی قرار گرفت. بنابراین این مدل‌ها با روش LSTM آنالیز شد و نتایج حاصله از تحلیل مدل‌ها در جدول (۳) و شکل (۳) نشان داده شد. با توجه به نتایج به دست آمده از سه معیار ارزیابی مدل برای داده‌های آموزش و آزمون، مشاهده می‌شود که نتایج برای همه مدل‌ها در همه ایستگاه‌ها تقریباً یکسان است. بنابراین نتیجه می‌شود اکسیژن محلول در یک روز تا حد زیادی تابع اکسیژن محلول در روز قبل می‌باشد. همان‌طور که مشاهده می‌شود افزایش تعداد روزها تغییر چندانی در نتایج به دست نمی‌دهد. به دلیل مشابه بودن نتایج در پنج ایستگاه بررسی شده، نتایج مربوط به ایستگاه اول برای سری داده‌های آموزش و آزمون در شکل (۴) نشان داده شده است.

Table 3. Results of temporal modeling evaluation without data decomposition

Model	Station	Train			Test		
		R	DC	RMSE	R	DC	RMSE
T(I)	St1	0.991	0.981	0.019	0.979	0.961	0.020
	St2	0.991	0.982	0.031	0.980	0.963	0.036
	St3	0.995	0.985	0.032	0.981	0.965	0.034
	St4	0.996	0.986	0.035	0.981	0.965	0.038
	St5	0.996	0.988	0.024	0.982	0.971	0.029
T(II)	St1	0.981	0.972	0.022	0.969	0.952	0.023
	St2	0.983	0.973	0.031	0.971	0.958	0.035
	St3	0.991	0.988	0.032	0.978	0.969	0.034
	St4	0.988	0.979	0.033	0.975	0.961	0.033
	St5	0.994	0.979	0.036	0.981	0.964	0.031
T(III)	St1	0.990	0.972	0.022	0.976	0.958	0.022
	St2	0.988	0.976	0.041	0.969	0.947	0.044
	St3	0.988	0.977	0.035	0.978	0.954	0.039
	St4	0.991	0.989	0.031	0.980	0.975	0.035
	St5	0.996	0.979	0.031	0.984	0.965	0.036
T(IV)	St1	0.992	0.975	0.024	0.978	0.949	0.023
	St2	0.991	0.981	0.034	0.979	0.969	0.036
	St3	0.989	0.977	0.033	0.979	0.959	0.038
	St4	0.993	0.978	0.033	0.979	0.965	0.035
	St5	0.995	0.989	0.025	0.981	0.974	0.031
T(V)	St1	0.990	0.976	0.020	0.975	0.958	0.021
	St2	0.983	0.978	0.033	0.972	0.958	0.035
	St3	0.991	0.981	0.034	0.979	0.968	0.036
	St4	0.989	0.979	0.035	0.974	0.967	0.036
	St5	0.995	0.979	0.038	0.981	0.969	0.039

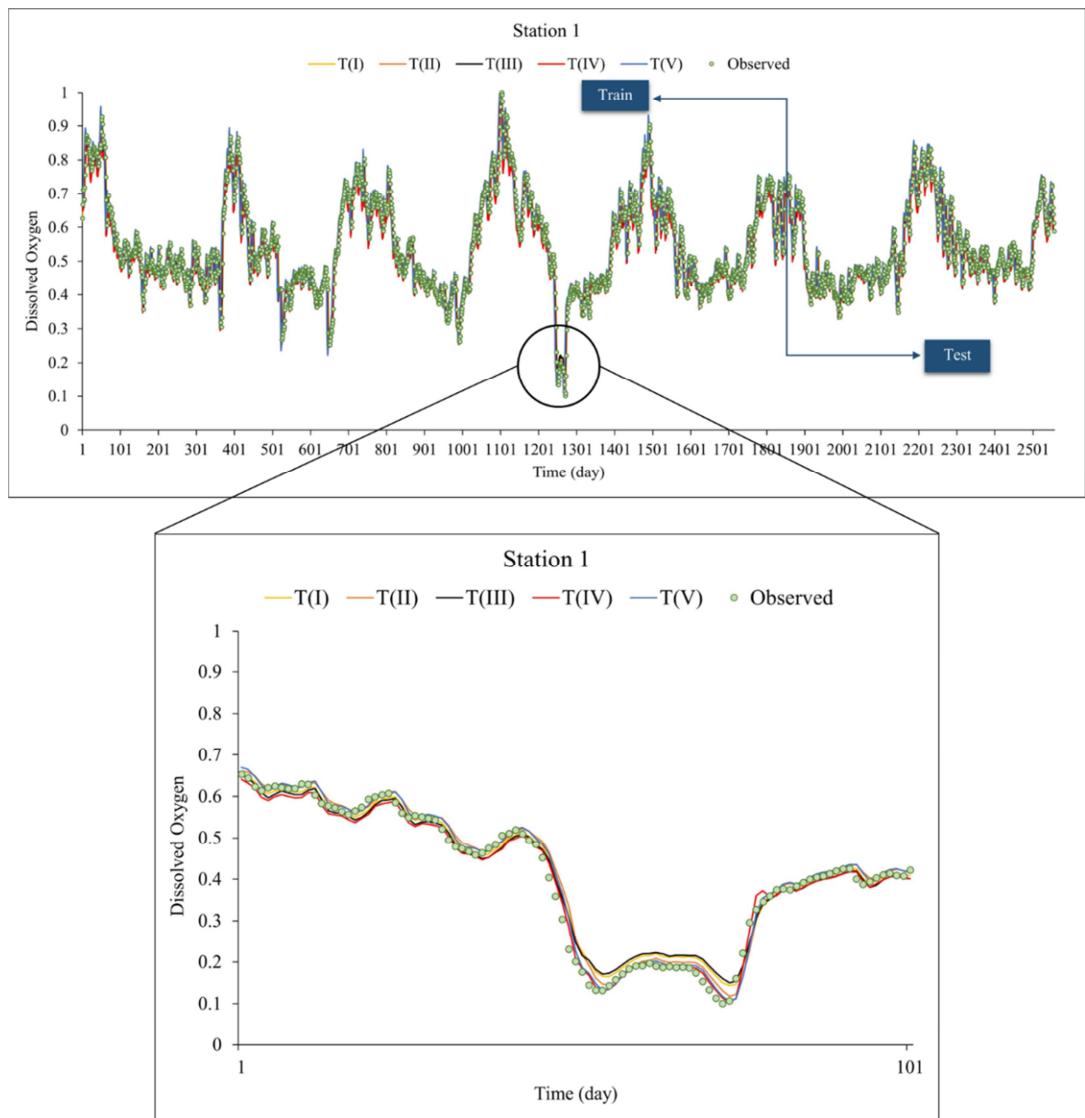


Figure 3. Results of training and testing steps of all models for the station 1 in temporal modeling without data decomposition

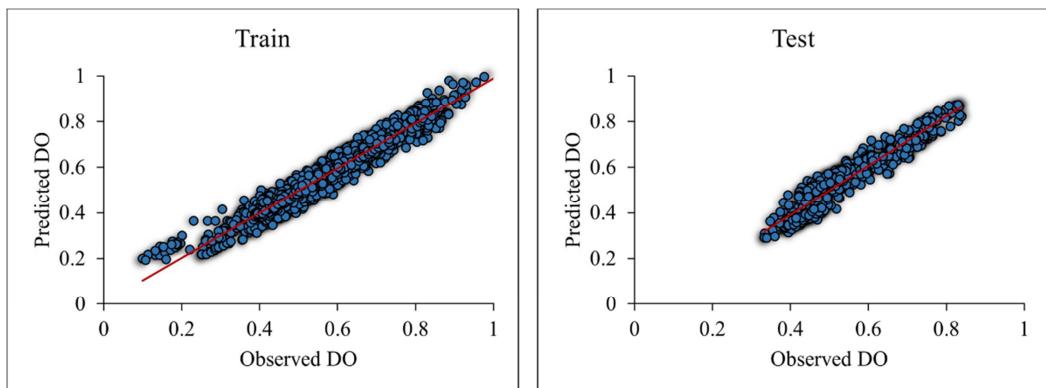


Figure 4. Results of the training and testing steps of model T(I) for the station 1 in temporal modeling without data decomposition

۲.۲.۰.۳ مدل‌سازی مکانی

جهت پیش‌بینی اکسیژن محلول و بررسی ارتباط بین ایستگاهی آن، هفت مدل براساس پارامتر اکسیژن محلول در دو ایستگاه قبل و دو روز متولی تعریف شده و کارایی روش حافظه طولانی کوتاه‌مدت بررسی شد. نتایج معیارهای ارزیابی در جدول (۴) آورده شده است. همان‌طور که مشاهده می‌شود نتایج حاصل از ورودی دو روز قبل اکسیژن محلول در ایستگاه اول و یک روز قبل ایستگاه دوم بهترین نتیجه را در پی داشته است. نتایج مدل برتر جهت پیش‌بینی اکسیژن محلول ایستگاه سوم برای سری داده‌های آموزش و آزمون در شکل (۵) نشان داده شده است.

Table 4. Results of spatial modeling evaluation without data decomposition

Model	Train			Test		
	R	DC	RMSE	R	DC	RMSE
S(I)	0.888	0.780	0.103	0.870	0.355	0.132
S(II)	0.887	0.785	0.102	0.866	0.350	0.132
S(III)	0.986	0.949	0.049	0.985	0.752	0.082
S(IV)	0.980	0.958	0.044	0.979	0.924	0.045
S(V)	0.883	0.777	0.104	0.867	0.359	0.131
S(VI)	0.988	0.972	0.036	0.987	0.885	0.055
S(VII)	0.990	0.977	0.033	0.985	0.939	0.040

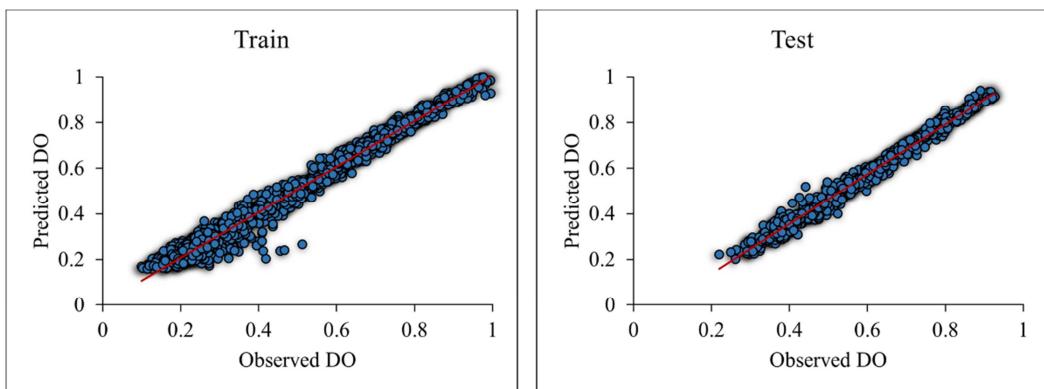


Figure 5. Results of the training and testing steps of superior model (S(VII)) in spatial modeling without data decomposition

۳.۰.۳ نتایج بدستآمده برای مدل LSTM پس از تجزیه داده‌ها

در این قسمت با استفاده از دو روش تجزیه یکپارچه مد تجربی کامل و تبدیل موجک گسسته ابتدا سری‌های زمانی تجزیه شد و سپس زیرسیری‌های به‌دست‌آمده به‌عنوان ورودی به مدل LSTM داده شد. مدل‌سازی نیز در دو حالت زمانی و مکانی انجام شد. اولین قدم برای تجزیه سیگنال با تبدیل موجک انتخاب موجک مادر است. در این پژوهش از موجک مادر db2 با سه سطح تجزیه استفاده شد. اساس روش CEEMD نیز تجزیه سیگنال به IMF‌های مختلف و یک سیگنال باقیمانده است که در نهایت مجموع این‌ها، همان سیگنال اصلی خواهد بود. روش تشکیل IMF‌ها براساس تفریق تابع پایه از سیگنال اصلی است. این پروسه تا وقتی ادامه می‌یابد که تقریباً سیگنال باقی‌مانده ثابت شود. در نهایت زیرسیری‌های به‌دست‌آمده از هر دو روش، به‌عنوان ورودی به مدل LSTM داده شد. به‌عنوان مثال، پیش‌پردازش سری‌های زمانی ایستگاه اول در مقیاس روزانه تبدیل موجک و هم‌چنین تجزیه مد تجربی در شکل‌های (۶) و (۷) نشان داده شده است.

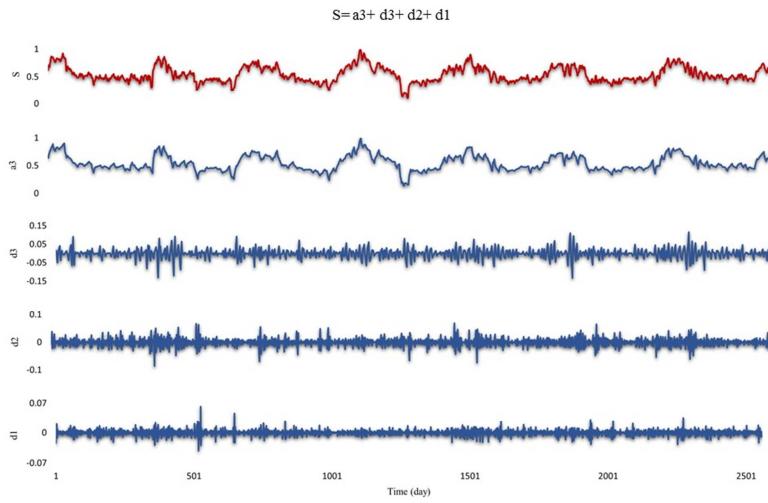


Figure 6. The subheading of the first station decomposes by discrete wavelet transform

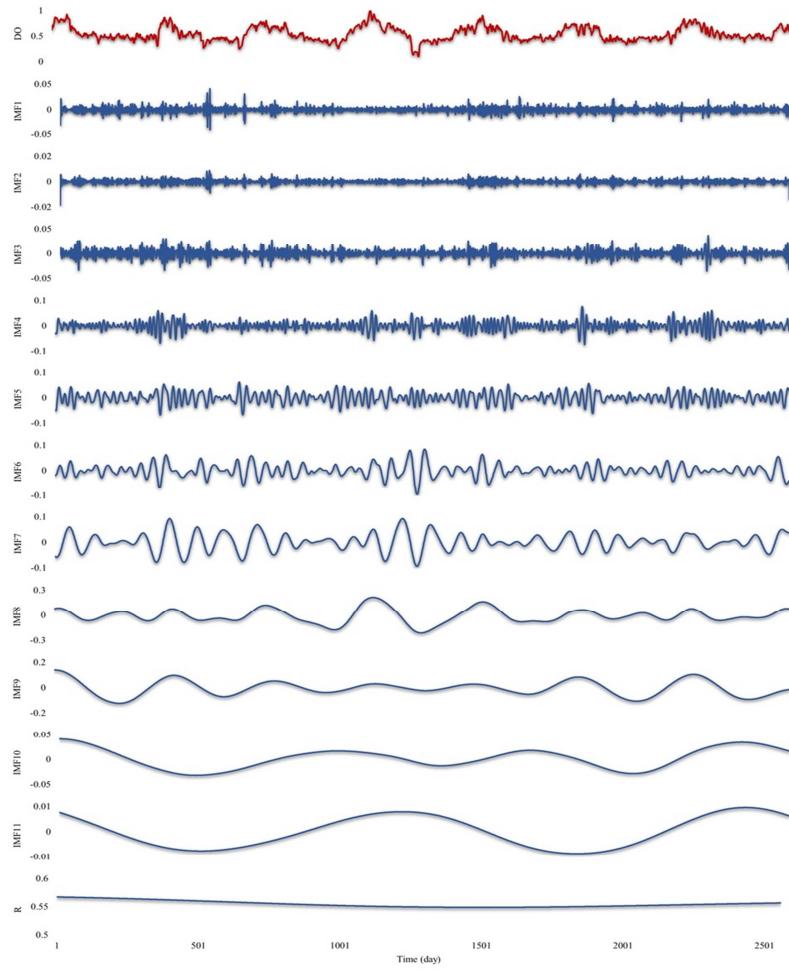


Figure 7. The subheading of the first station decomposes by complementary ensemble empirical mode decomposition

۱.۳.۱. مدل‌سازی زمانی

نتایج حاصل از مدل‌سازی زمانی پس از پردازش داده‌ها توسط تبدیل موجک گسسته و تجزیه مد تجربی در جدول (۵) آورده شده است. همان‌طورکه در نتایج نیز مشاهده می‌شود تجزیه سری‌های زمانی تا حدودی باعث بهبود نتایج شده‌اند و تأثیر تجزیه با استفاده از تجزیه یکپارچه مد تجربی کامل بیش‌تر از روش تبدیل موجک گسسته است. مطابق نتایج بدست‌آمده تقریباً در همه ایستگاه‌ها نتایج یکسان است و طبق نتایج بدون پیش‌پردازش افزایش تعداد روزها تأثیر چندانی بر نتایج ندارد. بنابراین نتیجه می‌شود اکسیژن محلول در یک روز تابع اکسیژن محلول در روز قبل خواهد بود. لذا جهت مقایسه نتایج، نتایج ایستگاه اول هم بدون پیش‌پردازش داده‌ها و هم پس از پردازش داده‌ها به دو روش ذکر شده در شکل‌های (۸) و (۹) آورده شده است. با توجه به نتایج، تجزیه مد تجربی در مدل T(I) در ایستگاه اول باعث افزایش یک درصدی در معیار ارزیابی DC و کاهش ۱۵ درصدی در میزان خطای RMSE شد.

Table 5. Results of temporal modeling evaluation after data decomposition

Model	Station	Train			Test			
		R	DC	RMSE	R	DC	RMSE	
T(I)	St1	DWT	0.993	0.974	0.017	0.987	0.965	0.018
		CEEMD	0.986	0.981	0.015	0.988	0.977	0.017
	St2	DWT	0.974	0.965	0.026	0.973	0.955	0.025
		CEEMD	0.977	0.969	0.015	0.975	0.955	0.017
	St3	DWT	0.977	0.965	0.014	0.976	0.957	0.015
		CEEMD	0.978	0.967	0.018	0.975	0.959	0.020
	St4	DWT	0.977	0.968	0.014	0.976	0.957	0.016
		CEEMD	0.975	0.970	0.016	0.978	0.960	0.016
	St5	DWT	0.977	0.967	0.013	0.976	0.963	0.017
		CEEMD	0.973	0.972	0.015	0.978	0.968	0.017
T(II)	St1	DWT	0.973	0.966	0.015	0.970	0.961	0.016
		CEEMD	0.982	0.978	0.013	0.978	0.976	0.015
	St2	DWT	0.975	0.970	0.026	0.973	0.965	0.024
		CEEMD	0.978	0.978	0.019	0.975	0.968	0.020
	St3	DWT	0.973	0.966	0.023	0.970	0.958	0.025
		CEEMD	0.979	0.974	0.017	0.977	0.961	0.017
	St4	DWT	0.974	0.968	0.020	0.972	0.965	0.022
		CEEMD	0.977	0.976	0.013	0.971	0.968	0.015
	St5	DWT	0.974	0.964	0.019	0.972	0.961	0.022
		CEEMD	0.979	0.967	0.015	0.978	0.964	0.016
T(III)	St1	DWT	0.972	0.963	0.019	0.968	0.952	0.020
		CEEMD	0.975	0.966	0.016	0.971	0.954	0.018
	St2	DWT	0.973	0.966	0.023	0.969	0.958	0.022
		CEEMD	0.978	0.969	0.020	0.978	0.964	0.021
	St3	DWT	0.971	0.963	0.025	0.967	0.954	0.028
		CEEMD	0.978	0.967	0.021	0.978	0.958	0.023
	St4	DWT	0.972	0.970	0.023	0.970	0.969	0.026
		CEEMD	0.979	0.972	0.015	0.978	0.968	0.016
	St5	DWT	0.977	0.964	0.022	0.971	0.963	0.026
		CEEMD	0.977	0.968	0.015	0.976	0.966	0.015
T(IV)	St1	DWT	0.965	0.949	0.023	0.959	0.937	0.025
		CEEMD	0.978	0.976	0.014	0.978	0.975	0.016
	St2	DWT	0.969	0.959	0.031	0.964	0.951	0.032
		CEEMD	0.978	0.969	0.020	0.978	0.961	0.025
	St3	DWT	0.972	0.965	0.025	0.968	0.955	0.027
		CEEMD	0.978	0.972	0.022	0.978	0.968	0.023
	St4	DWT	0.973	0.966	0.021	0.971	0.962	0.024
		CEEMD	0.978	0.969	0.015	0.977	0.965	0.016
	St5	DWT	0.971	0.962	0.023	0.970	0.960	0.028
		CEEMD	0.979	0.969	0.017	0.978	0.964	0.018
T(V)	St1	DWT	0.974	0.963	0.018	0.971	0.955	0.019
		CEEMD	0.971	0.967	0.015	0.978	0.966	0.019
	St2	DWT	0.967	0.953	0.030	0.961	0.938	0.031
		CEEMD	0.978	0.964	0.020	0.978	0.958	0.022
	St3	DWT	0.974	0.969	0.021	0.971	0.962	0.023
		CEEMD	0.976	0.973	0.013	0.975	0.965	0.014
	St4	DWT	0.972	0.964	0.024	0.970	0.958	0.026
		CEEMD	0.977	0.968	0.018	0.977	0.961	0.020
	St5	DWT	0.972	0.963	0.022	0.972	0.960	0.026
		CEEMD	0.977	0.974	0.015	0.973	0.964	0.017

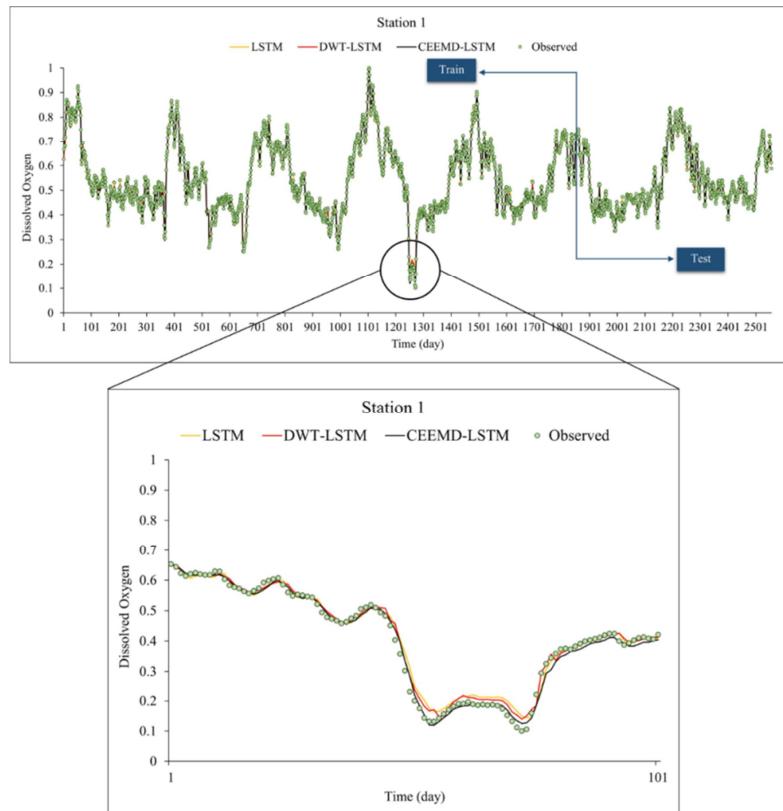


Figure 8. Results of training and testing steps of model T(I) for the first station in temporal modeling after data decomposition

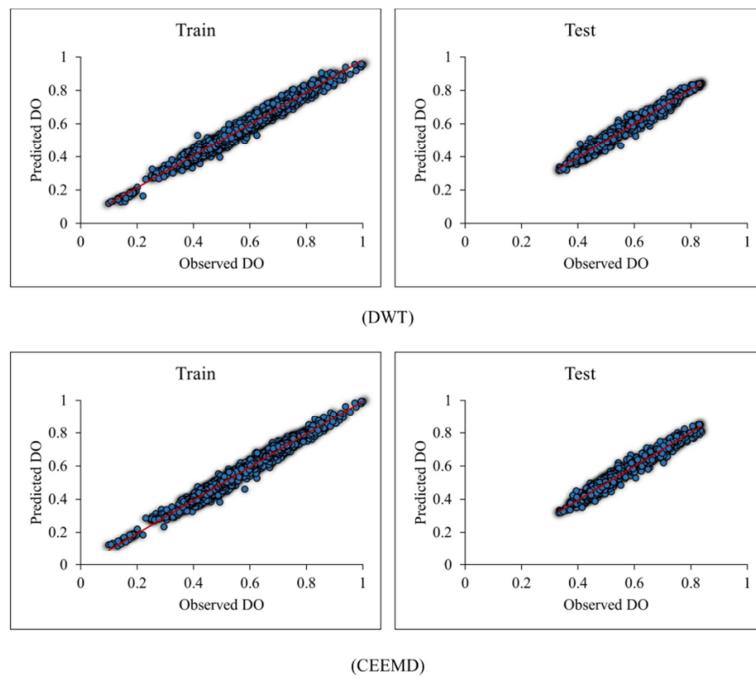


Figure 9. Results of training and testing steps of model T(I) for the station 1 in temporal modeling after data decomposition

۲.۳.۲. مدل‌سازی مکانی

برای پیش‌بینی اکسیژن محلول در ایستگاه سوم با توجه به نتایج جدول (۶) مشاهده می‌شود که بهترین مدل، مدل S(VII) می‌باشد که با دو پارامتر اکسیژن محلول یک روز قبل ایستگاه دوم و اکسیژن محلول دو روز قبل ایستگاه اول نتیجه قابل قبولی داده است. همان‌طور که مشاهده می‌شود در اینجا نیز نتایج حاصل از پیش‌پردازش داده‌ها تا حدودی باعث بهبود نتایج شده است و همچنین نتایج حاصل از تبدیل موجک گستته با افزایش یک درصدی در معیار ارزیابی DC و کاهش دو درصدی در خطای RMSE بهتر از نتایج حاصل از تجزیه مدل تجربی کامل می‌باشد. نتایج آموزش و آزمون برای بهترین مدل در شکل (۱۰) آورده شده است.

Table 6. Results of spatial modeling evaluation after data decomposition

Model	Train			Test		
	R	DC	RMSE	R	DC	RMSE
S(I)	DWT	0.883	0.739	0.112	0.866	0.592
	CEEMD	0.937	0.872	0.078	0.901	0.546
S(II)	DWT	0.883	0.778	0.104	0.868	0.382
	CEEMD	0.923	0.831	0.090	0.913	0.372
S(III)	DWT	0.988	0.968	0.039	0.987	0.844
	CEEMD	0.990	0.978	0.032	0.989	0.774
S(IV)	DWT	0.983	0.966	0.040	0.981	0.929
	CEEMD	0.986	0.964	0.041	0.985	0.852
S(V)	DWT	0.885	0.776	0.104	0.868	0.436
	CEEMD	0.922	0.849	0.085	0.921	0.437
S(VI)	DWT	0.989	0.977	0.033	0.988	0.920
	CEEMD	0.992	0.981	0.030	0.991	0.814
S(VII)	DWT	0.991	0.981	0.030	0.990	0.953
	CEEMD	0.992	0.979	0.031	0.987	0.941

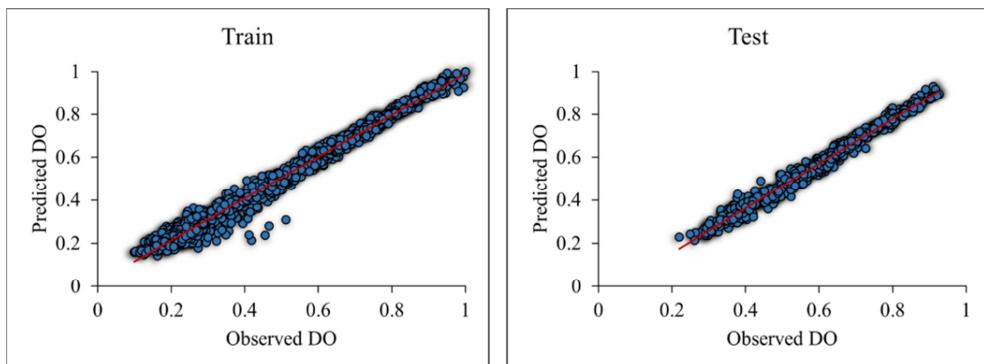


Figure 10. Results of the training and testing steps of superior model in spatial modeling after data decomposition by wavelet transform

۴. مقایسه نتایج

در این مطالعه با استفاده از روش‌های مبتنی بر هوش مصنوعی مانند روش حافظه طولانی کوتاه‌مدت و مدل‌های ترکیبی موجک-حافظه طولانی کوتاه‌مدت و تجزیه مدل تجربی-حافظه طولانی کوتاه‌مدت به پیش‌بینی اکسیژن محلول به صورت زمانی و مکانی پرداخته شد. نتایج معیارهای ارزیابی برای مرحله آزمون مدل‌های بتر با استفاده از روش‌های مذکور در شکل (۱۲) آورده شده است. روش LSTM نتایج بهتری نسبت به سایر روش‌های به کاررفته پیشین (مانند ANN) به دست می‌دهد (Dabrowski *et al.*, 2018). مطابق نتایج مشاهده شده در شکل (۱۱) در مدل‌سازی زمانی مدل T(I) و در مدل‌سازی مکانی مدل S(VII) با داشتن بیشترین DC و کمترین RMSE به عنوان برترین مدل ارزیابی شدند.

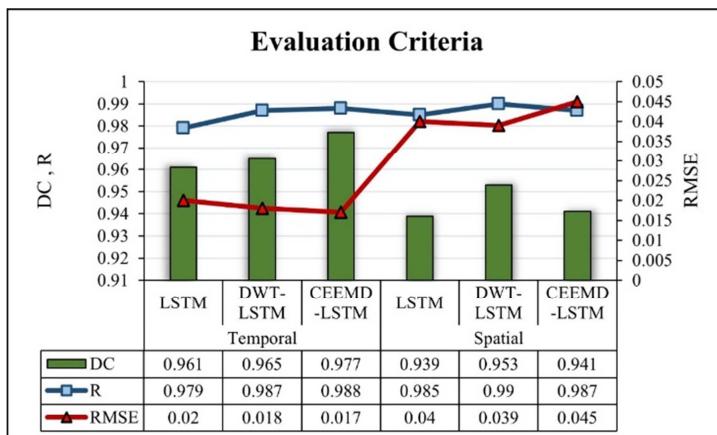


Figure 11. Comparison of evaluation criteria of superior models in two types of temporal and spatial modeling

به طور کلی، چارچوب چند جزوی WT می‌تواند دقیق پیش‌بینی مدل‌های مستقل را تا حدی بهبود ببخشد، در حالی که چارچوب مستقیم هیچ مزیت آشکاری را نشان نمی‌دهد (Xu *et al.*, 2021). هم‌چنین روش‌های ترکیبی با EEMD می‌توانند خطای مدل‌سازی کمتری به دست بدهند (Eze, 2021). اگرچه در هر دو نوع مدل‌سازی پردازش داده‌های باعث بهبود نتایج شده است، اما در مدل‌سازی زمانی تجزیه مدل تجربی باعث بهتر شدن نتایج و از طرفی دیگر در مدل‌سازی مکانی تبدیل موجک باعث بهتر شدن نتایج و افزایش مقدار DC شده است.

۴. نتیجه‌گیری

در این پژوهش از مدل حافظه طولانی کوتاه‌مدت برای مدل‌سازی اکسیژن محلول در آب (DO) در رودخانه ساواناه در دوره هفت‌ساله به صورت داده‌های روزانه استفاده شد. دو نوع مدل‌سازی زمانی و مکانی هم بدون پیش‌پردازش داده‌ها و هم پس از تجزیه داده‌های سری زمانی با استفاده از تبدیل موجک و تجزیه مدل تجربی انجام شد. با توجه به نتایج در مدل‌سازی زمانی در همه ایستگاه‌ها نتیجه شد که افزایش تعداد روزها تأثیری در بهبود عملکرد مدل نداشت، پس می‌توان نتیجه گرفت اکسیژن محلول در یک ایستگاه در یک روز با دقت زیادی تابع اکسیژن محلول در روز قبل می‌باشد. هم‌چنین در مدل‌سازی مکانی مشاهده شد که نتایج حاصل از یک روز قبل ایستگاه دوم و دو روز قبل ایستگاه اول در پیش‌بینی اکسیژن محلول ایستگاه سوم کارآمد خواهد بود. هم‌چنین در هر دو نوع مدل‌سازی پیش‌پردازنهای تأثیر خوبی در بهبود عملکرد مدل داشتند و باعث افزایش میزان DC شدند و هم‌چنین تبدیل موجک در مدل‌سازی مکانی و تجزیه مدل تجربی در مدل‌سازی زمانی بیشترین تأثیر را در بهبود عملکرد مدل LSTM داشت.

۵. پی‌نوشت‌ها

1. Dissolved Oxygen
2. Artificial Neural Network
3. Multi-Layer Perceptron
4. Radial Basis Function
5. Least Squares Support Vector Machine-Improved Particle Swarm Optimization
6. Support Vector Machine
7. Back Propagation
8. Constrained Extreme Learning Machines

9. Savannah River
10. Wavelet Transform
11. Empirical Mode Decomposition
12. Intrinsic Mode Functions
13. Ensemble Empirical Mode Decomposition
14. Complementary Ensemble Empirical Mode Decomposition
15. Long Short-Term Memory
16. Recurrent Neural Network
17. Correlation Coefficient
18. Coefficient of Determination
19. Root Mean Square Error

۶. تعارض منافع

هیچ‌گونه تعارض منافعی بین نویسنده‌گان وجود ندارد.

۷. منابع مورد استفاده

- Adamowski, K., Prokop, A., & Adamowski, J. (2009). Development of a new method of wavelet aided trend detection and estimation. *Hydrological Processes*, 23, 2686-2696.
- 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.
- Amirat, Y., Benbouzid, M. E. H., Wang, T., Bacha, K., & Feld, G. (2018). EEMD-based notch filter for induction machine bearing faults detection. *Applied Acoustics*, 133, 202-209.
- 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.
- Chou, C.-M. (2014). Complexity analysis of rainfall and runoff time series based on sample entropy in different temporal scales. *Stochastic Environmental Research and Risk Assessment*, 28(6), 1401-1408.
- Csábrágí, 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.
- Dabrowski, J. J., Rahman, A., & George, A. (2018). *Prediction of Dissolved Oxygen from pH and Water Temperature in Aquaculture Prawn Ponds* Proceedings of the Australasian Joint Conference on Artificial Intelligence - Workshops, Wellington, New Zealand.
- 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, 1157-1164.
- Eze, E. H. S. A. T. (2021). Developing a Novel Water Quality Prediction Model for a South African Aquaculture Farm *Water*, 13(13).
- Fang, X., & Yuan, Z. (2019). Performance enhancing techniques for deep learning models in time series forecasting. *Engineering Applications of Artificial Intelligence*, 85, 533-542.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-term Memory. *Neural computation*, 9, 1735-1780.
- Hosseinpahahi, B., Nikmehr, S., & Ebrahimi, K. (2021). Comparison of the support vector machine and radial function neural network models in predicting of SiminehRood river water quality Iran. *Water and Irrigation Management*, 11(3), 409-419.(In Persian)
- Ji, X., Shang, X., Dahlgren, R. A., & Zhang, M. (2017). Prediction of dissolved oxygen concentration in hypoxic river systems using support vector machine: a case study of Wen-Rui Tang River, China. *Environmental Science and Pollution Research*, 24(19), 16062-16076.

- Lau, K. M., & Weng, H. (1995). Climate Signal Detection Using Wavelet Transform: How to Make a Time Series Sing. *Bulletin of the American Meteorological Society*, 76(12), 2391-2402.
- Liu, S., Xu, L., Li, D., Li, Q., Jiang, Y., Tai, H., & Zeng, L. (2013). Prediction of dissolved oxygen content in river crab culture based on least squares support vector regression optimized by improved particle swarm optimization. *Computers and Electronics in Agriculture*, 95, 82-91.
- 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.
- Nourani, V., Hosseini Baghanam, A., Adamowski, J., & Kisi, O. (2014). Applications of hybrid wavelet-Artificial Intelligence models in hydrology: A review. *Journal of Hydrology*, 514, 358-377.
- 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.
- Roushangar, K., & Ghasempour, R. (2020). Monthly precipitation prediction improving using the integrated model based on kernel-wavelet and complementary ensemble empirical mode decomposition. *Amirkabir Journal of Civil Engineering*, 52(10), 2649-2660.(In Persian)
- 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(p00814), 1467-1477.(In Persian)
- 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.
- 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.
- 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.
- Wu, Z., & Huang, N. (2004). A study of the characteristics of white noise using the empirical mode decomposition method. *Proceedings of The Royal Society A: Mathematical, Physical and Engineering Sciences*, 460, 1597-1611.
- Xu, C., Chen, X., & Zhang, L. (2021). Predicting river dissolved oxygen time series based on stand-alone models and hybrid wavelet-based models. *Journal of Environmental Management*, 295, 113085.
- Yadav, B., & Eliza, K. (2017). A hybrid wavelet-support vector machine model for prediction of Lake water level fluctuations using hydro-meteorological data. *Measurement*, 103, 294-301.