



دانشگاه گواران و منابع آب

نشریه پژوهش‌های حفاظت آب و خاک
جلد بیست و دوم، شماره ششم، ۱۳۹۴
<http://jwsc.gau.ac.ir>

ارزیابی کارایی مدل تلفیقی شبکه عصبی مصنوعی و آنالیز موجک در پیش‌بینی غلظت شاخص کیفی اکسیژن محلول در مخزن سد بولدر

ظاهر رجایی^۱ و *امیر برومند^۲

^۱دانشیار گروه مهندسی عمران، دانشگاه قم، آدانشجوی دکتری گروه مهندسی عمران، دانشگاه قم

تاریخ دریافت: ۹۲/۱۲/۵؛ تاریخ پذیرش: ۹۳/۹/۲۴

چکیده

سابقه و هدف: مدیریت کمی و کیفی منابع آب به‌منظور تأمین تقاضا برای کاربری‌های مختلف از رویکردهای مهم سیاست‌گذاری در هر کشور است. در این راستا پیش‌بینی کیفیت آب مخازن سدها به‌عنوان یک گام اساسی در مدیریت این منابع با ارزش اهمیت ویژه‌ای دارد. مطالعات قبلی که در این مقاله تشریح می‌شوند، نشان می‌دهند که مدل‌ها مبتنی بر شبکه عصبی مصنوعی به‌طور مؤثری می‌تواند جهت پیش‌بینی مقادیر شاخص‌های کیفی در منابع آب، به‌کار برده شود. هدف اصلی این مطالعه، ارائه یک مدل کارآمد به‌منظور پیش‌بینی غلظت شاخص کیفی اکسیژن محلول در مخزن سد می‌باشد.

مواد و روش‌ها: داده‌های مورد استفاده در این پژوهش مقادیر اندازه‌گیری شده اکسیژن محلول به‌مدت ۱۲۰ ماه، از ماه ژانویه سال ۱۹۹۸ تا ماه دسامبر سال ۲۰۰۷ در مخزن سد بولدر واقع در ایالت کلرادو آمریکا می‌باشد. در این پژوهش مدل‌های شبکه عصبی مصنوعی، رگرسیون خطی چندمتغیره و مدل تلفیقی شبکه عصبی مصنوعی با تبدیل موجک به‌منظور پیش‌بینی غلظت اکسیژن محلول در مخزن سد به‌کار گرفته شد. در مدل تلفیقی، سری زمانی داده‌های اندازه‌گیری شده شاخص کیفی اکسیژن محلول با استفاده از تبدیل موجک در سطوح مختلف تجزیه شد و زیرسری‌های مؤثر در غلظت اکسیژن محلول در یک ماه آینده به‌عنوان ورودی‌های شبکه عصبی به‌کار گرفته شد.

یافته‌ها: نتایج نشان داد که مدل تلفیقی نتایج دقیق‌تری را نسبت به مدل‌های عصبی و رگرسیونی به‌دست می‌دهد و استفاده از تبدیل موجک به مقدار قابل‌توجهی دقت نتایج حاصل از مدل‌سازی را بهبود می‌بخشد. مقادیر E و $RMSE$ داده‌های آزمایشی برای این مدل به ترتیب ۰/۹۶ و ۰/۲۲ حاصل شده است. همچنین نتایج نشان داد که مدل‌های تلفیقی و عصبی نقاط مینیمم را که شرایط بی‌هوازی را در مخزن ایجاد می‌کند، به خوبی پیش‌بینی می‌کند ولی مدل رگرسیونی عملکرد خوبی در پیش‌بینی شرایط بی‌هوازی ندارد.

نتیجه‌گیری: نتایج نشان داد که استفاده از تبدیل موجک در ترکیب با شبکه عصبی مصنوعی نتایج مدل‌سازی را بهبود می‌بخشد و به‌طور کلی، مطالعه موردی انجام شده با استفاده از مدل تلفیقی مذکور در مخزن سد بولدر نتایج امیدوارکننده‌ای را در زمینه پیش‌بینی مقادیر شاخص کیفی اکسیژن محلول در مخازن سدها نشان می‌دهد.

واژه‌های کلیدی: اکسیژن محلول، تبدیل موجک، شبکه عصبی مصنوعی، کیفیت آب، مخزن سد

* مسئول مکاتبه: a.broumand@stu.qom.ac.ir

مقدمه

حفظ و استفاده بهینه از منابع آب از اصول توسعه پایدار هر کشور است. می‌توان بیان کرد که اغلب برنامه‌ریزی‌های منابع آب در کشورها بر اساس پتانسیل بالقوه منابع آب آن کشور است. آگاهی از وضعیت کیفیت منابع آب یکی از نیازمندی‌های مهم در برنامه‌ریزی و توسعه منابع آب و همچنین حفاظت و کنترل آن می‌باشد. به‌طور کلی شناسایی مشکلات کمی و کیفی موجود در سیستم‌های پایش منابع آب مورد مطالعه یکی از مهم‌ترین گام‌های تدوین ساختار طرح‌های مدیریت سیستم‌های منابع آب و اجرای طرح‌های زیست‌محیطی کاهش آلودگی می‌باشد. در این راستا کیفیت آب مخازن سدها به‌عنوان منابع تامین آب به‌منظور کابری‌های مختلف، دارای اهمیت ویژه‌ای است. بنابراین شناخت شاخص‌های مؤثر بر کیفیت این منابع با ارزش و پیش‌بینی رفتار آینده آن‌ها به‌عنوان یک گام اساسی در مدیریت کیفیت آب مخازن سدها، ضرورت دارد. مطالعات قبلی که در این بخش تشریح می‌شوند، نشان می‌دهند که مدل شبکه عصبی مصنوعی به‌طور مؤثری می‌تواند جهت پیش‌بینی مقادیر شاخص‌های کیفی در منابع آب، به‌کار برده شود.

کارول و همکاران (1999) شبکه عصبی مصنوعی را به‌منظور مدل‌سازی کلرفیل آ به‌عنوان شاخص تغذیه‌گرایی در مخزن سد کبان ترکیه به‌کار بردند. آن‌ها از یک شبکه سه لایه با عملکرد پیشرو استفاده نمودند. در این پژوهش داده‌های ورودی شامل PO_4 ، NO_3 ، Alkalinity، TSS، PH، دما، هدایت الکتریکی، اکسیژن محلول و عمق دیسک سچی بوده و کلرفیل آ لایه خروجی را تشکیل می‌داد (6). آن‌ها در ادامه این کار (2000) سدهای مگان و ایمیر را مورد مطالعه قرار دادند و در نهایت نتایج به‌دست آمده برای سه سد را با هم مقایسه نمودند (7). والتر و همکاران

(2001) از شبکه عصبی مصنوعی به‌منظور مدل‌سازی پدیده تغذیه‌گرایی در مخزن سد Burrinjuck استرالیا استفاده نمودند و نتایج حاصل را با نتایج مدل SALMO مقایسه کردند. مدل SALMO یک مدل زیست‌محیطی است که مخزن سد را به‌عنوان یک اکوسیستم مورد بررسی قرار می‌دهد. نتایج پژوهش‌های آن‌ها نشان داد که هر دو مدل توانایی قابل‌قبولی در بررسی تغییرات کیفی آب مخزن دارند با این تفاوت که مدل SALMO در پیش‌بینی‌های بلندمدت عملکرد بهتری از شبکه عصبی مصنوعی داشت و شبکه عصبی نیز در کوتاه‌مدت نتایج خوبی به‌دست می‌داد (18). میتاکی و محمدی (2003) مدل شبکه عصبی مصنوعی را جهت مدل‌سازی پارامترهای کیفی در رودخانه زاینده‌رود به‌کار بردند. آن‌ها نتایج به‌دست آمده از مدل پیشنهادی خود را با نتایج مدل کیفی QUAL2E مقایسه نمودند و به این نتیجه رسیدند که شبکه‌های عصبی مصنوعی به‌طور مؤثری می‌تواند در مدل‌سازی کیفی رودخانه‌ها به‌کار برده شود (11). دیامانتپولو و همکاران (2005) از مدل شبکه عصبی مصنوعی به‌منظور مدل‌سازی ماهانه شاخص‌های کیفی در رودخانه استریمون در یونان استفاده کردند. نتایج کار آن‌ها بیانگر توانایی شبکه‌های عصبی مصنوعی در پیش‌بینی مقادیر شاخص‌های کیفی با در نظر گرفتن وابستگی آن‌ها به سایر پارامترهای اندازه‌گیری شده بود. نتایج پژوهش‌های آن‌ها نشان داد که این مدل‌ها می‌توانند به‌عنوان ابزار مفیدی جهت بازسازی داده‌ها به‌کار روند (3). دیامانتپولو و همکاران (2005) در پژوهشی دیگر، مدل شبکه عصبی مصنوعی را جهت مدل‌سازی ماهانه شاخص‌های کیفی رودخانه اکیوس در شمال یونان به‌کار بردند و بار دیگر بر کارایی این مدل‌ها در پیش‌بینی مقادیر شاخص‌های کیفی در رودخانه‌ها تأکید کردند (4). تای‌کوا و همکاران (2007) از شبکه عصبی برای مدل‌سازی

(17). مردون و شینار (2010) از مدل‌های رگرسیون خطی چندمتغیره و شبکه عصبی پیش‌خور با الگوریتم پس‌انتشار خطا جهت مدل‌سازی غلظت شاخص کیفی کلرفیل آ در خور سنگینا و در ایالت میشیگان امریکا استفاده کردند. نتایج آن‌ها نشان داد که علی‌رغم ماهیت غیرخطی سیستم‌های منابع آب، رگرسیون خطی چندمتغیره نتایج بهتری را نسبت به شبکه عصبی مصنوعی در آن مطالعه به دست می‌دهد (10). بانژاد و اولیایی (2011) شبکه عصبی مصنوعی را به منظور مدل‌سازی پارامترهای DO و BOD در رودخانه مرادیگ هم‌دان به کار بردند. آن‌ها در کار خود از الگوریتم پس‌انتشار خطا برای آموزش شبکه استفاده کردند و به این نتیجه رسیدند که یک شبکه با ۱۰ پارامتر ورودی و تعداد ۶ نرون در لایه پنهان، بهترین نتایج را در پیش‌بینی غلظت اکسیژن محلول خواهد داشت. همچنین برای شاخص BOD نیز همان شبکه ولی با ۱۰ نرون در لایه پنهان بهترین نتایج را به دست می‌دهد (1). شاکری عبدالمالکی و همکاران (2013) از یک شبکه عصبی مصنوعی سه‌لایه جهت پیش‌بینی غلظت فلز سنگین مس در مخزن دریاچه مصنوعی چاه‌نیمه در استان سیستان و بلوچستان استفاده کردند. آن‌ها از شاخص‌های pH، TDS، EC^۳ و دما به عنوان ورودی‌های مدل و از الگوریتم لونیبرگ مارکوات جهت آموزش شبکه استفاده نمودند. آن‌ها به این نتیجه رسیدند که شبکه پیشنهادی با پارامترهای ورودی یادشده و تعداد ۷ نرون در لایه مخفی نتایج دقیقی را به دست می‌دهد (16). نورانی و همکاران (2013) از شبکه عصبی مصنوعی به منظور مدل‌سازی پارامترهای آب شرب استفاده کردند. آن‌ها برای ارزیابی مدل پیشنهادی خود از داده‌های رودخانه زربینه رود قبل و بعد از تصفیه آب

فرایند تغذیه‌گرایی در مخزن سد Te-Chi تایوان بهره گرفتند. آن‌ها در پژوهش خود از شاخص کارلسون که بر اساس چهار پارامتر اصلی فسفر کل، بار معلق، اکسیژن محلول و کلرفیل آ تعریف شده است و یکی از شاخص‌های مطرح در تعیین وضعیت تغذیه‌گرایی مخازن سدها می‌باشد، استفاده نمودند. آن‌ها از چهار شبکه عصبی مختلف برای به دست آوردن پارامترهای مؤثر در شاخص کارلسون استفاده کردند و نتایج آن‌ها را در معادله خطی کارلسون قرار دادند (5). موهیتینو همکاران (2008) به طور همزمان از شبکه عصبی و سیستم استنتاج فازی به منظور شبیه‌سازی مخزن سد ایمیر در ترکیه استفاده نمودند و نتایج آن‌ها را با هم مقایسه کردند. آن‌ها بر خلاف سایر پژوهش‌ها که غالباً کلرفیل آ را به عنوان شاخص قرار می‌دادند از شاخص کیفی اکسیژن محلول به منظور مدل‌سازی کیفی مخزن سد استفاده نمودند. آن‌ها از سناریوهای مختلف در ترکیب پارامترهای ورودی استفاده نمودند و به این نتیجه رسیدند که نتایج مدل‌سازی به انتخاب دقیق پارامترهای ورودی وابسته بوده و همچنین مدل شبکه عصبی مصنوعی به مقدار قابل توجهی دقیق‌تر از سیستم استنتاج فازی است (12). سانگ و زی (2009) دو مدل شبکه عصبی پیش‌خور با الگوریتم پس‌انتشار خطا و شبکه عصبی با تابع فعال‌ساز RBF^۱ را برای مدل‌سازی کیفی رودخانه یانگ‌تسه و شاخه فرعی آن جیالینگ در محل تلاقی آن‌ها در شهر چونگ کینگ چین استفاده نمودند. آن‌ها نتیجه گرفتند که مدل‌های پیشنهادی عملکرد بهتری نسبت به مدل‌های سنتی یک‌بعدی دارد. همچنین نشان دادند که شبکه عصبی با تابع فعال‌ساز RBF برای دستیابی به دقت مطلوب نیاز به تکرار بیشتری در فرایند آموزش دارد و به طور کلی مدل شبکه عصبی پیش‌خور با الگوریتم پس‌انتشار خطا نتایج بهتری به دست می‌دهد

2- Total Dissolved Solids

3- Electrical Conductivity

1- Radial Basis Function

مدل شبکه عصبی با الگوریتم پس‌انتشار خطا جهت پیش‌بینی غلظت کلرفیل آ به‌کار بردند. آن‌ها در این مدل‌ها از ترکیبات مختلف شاخص‌های کیفی و هیدرولوژیکی آب به‌عنوان ورودی‌های شبکه استفاده نمودند و بهترین مدل را از بین مدل‌های یاد شده انتخاب کرده و با تبدیل موجک ترکیب نمودند. در نهایت از مدل ترکیبی جهت پیش‌بینی غلظت شاخص کیفی کلرفیل آ در ۱، ۳ و ۷ روز آینده، استفاده نمودند. مقایسه نتایج نشان داد که استفاده از ترکیب شبکه عصبی مصنوعی با تبدیل موجک نتایج دقیق‌تری نسبت به مدل شبکه عصبی مصنوعی دارد (9).

در پژوهش حاضر برای اولین بار مدل تلفیقی شبکه عصبی مصنوعی و تبدیل موجک (WANN)^۱ به‌منظور پیش‌بینی غلظت شاخص کیفی اکسیژن محلول در مخزن سد بولدر واقع در ایالت کلرادو آمریکا به‌کار برده شده است. داده‌های ماهانه اکسیژن محلول از سال ۱۹۹۸ تا ۲۰۰۷ به‌مدت ۱۲۰ ماه، مورد استفاده قرار گرفت و با توجه به عدم اندازه‌گیری مقادیر شاخص مورد مطالعه در بعضی از ماه‌ها، به‌طور هم‌زمان با توسعه مدل WANN پیشنهادی، از خود مدل به‌منظور ترمیم و بازسازی داده‌ها در سری زمانی استفاده گردید. در این پژوهش همچنین مدل‌های شبکه عصبی مصنوعی (ANN)^۲ و رگرسیونی (MLR)^۳ نیز به‌عنوان مدل‌های رقیب به‌کار گرفته شد و کارایی مدل‌های ارائه شده با در نظر گرفتن معیارهای ضریب نش^۴ و ریشه دوم میانگین مربعات خطا^۵ مورد ارزیابی قرار گرفت.

هدف اصلی در این مطالعه، ارائه مدلی به‌منظور پیش‌بینی غلظت شاخص کیفی اکسیژن محلول در مخزن سد بولدر می‌باشد.

آن استفاده نمودند. آن‌ها ابتدا داده‌های مورد استفاده را مورد ارزیابی آماری قرار دادند و بخشی از آن را به‌منظور آموزش شبکه و بخش دیگر را برای اعتبارسنجی مدل به‌کار بردند. شاخص‌های کیفی دما، کدورت، سختی کل، سطح کلسیم و pH قبل از تصفیه، را به‌عنوان ورودی‌های شبکه و شاخص‌های کیفی TDS و EC بعد از تصفیه را به‌عنوان خروجی‌های مدل در نظر گرفتند. آن‌ها جهت تفسیر نتایج مدل، نتایج آن را با نتایج مدل‌های کلاسیک و کاربردی مقایسه کردند و نتایج کارایی بالای شبکه‌های عصبی مصنوعی را در پیش‌بینی شاخص‌های کیفی آب تصفیه‌شده نشان داد (13).

در سال‌های اخیر با توجه به توانایی آنالیز موجک در استخراج ویژگی، استفاده از مدل‌های تلفیقی تبدیل موجک و مدل‌های هوشمند در علوم آب و محیط زیست متداول شده است. در زمینه کاربرد این مدل‌ها، رجایی و همکاران (2009) از مدل تلفیقی عصبی فازی و تبدیل موجک به‌منظور پیش‌بینی بار معلق رسوب در رودخانه پکوس واقع در ایالات متحده آمریکا استفاده نمودند. نتایج کار آن‌ها نشان داد که مدل ارائه شده نقاط حداکثر و بار معلق تجمعی را در یک دوره به خوبی پیش‌بینی می‌کند و به‌طور کلی نتایج حاصل از پژوهش بیانگر کارایی مدل ارائه شده در پیش‌بینی بار معلق رسوب در رودخانه‌ها بود (14). در پژوهشی دیگر رجایی و همکاران (2011) مدل تلفیقی شبکه عصبی و تبدیل موجک را جهت پیش‌بینی بار معلق رسوب در رودخانه آیووا واقع در ایالت متحده آمریکا به‌کار بردند و بار دیگر بر کارایی این روش‌ها در پیش‌بینی غلظت بار معلق رسوب تأکید کردند (15). کیم و همکاران (2012) از مدل تلفیقی شبکه عصبی و تبدیل موجک به‌منظور پیش‌بینی غلظت شاخص کیفی کلرفیل آ در ۱، ۳ و ۷ روز آینده در مخزن دریاچه استفاده نمودند. آن‌ها در ابتدا ۱۲

- 1- Wavelet Artificial Neural Network
- 2- Artificial Neural Network
- 3- Multi Leaner Regression
- 4- Determination Coefficient (E)
- 5- RMSE

مواد و روش‌ها

مطالعه موردی: داده‌های مورد استفاده در این پژوهش مقادیر اندازه‌گیری شده اکسیژن محلول به مدت ۱۲۰ ماه، از ماه ژانویه سال ۱۹۹۸ تا ماه دسامبر سال ۲۰۰۷ در مخزن سد بولدر می‌باشد. سد مخزنی بولدر در سال ۱۹۹۵ با اهداف تأمین آب شرب و کشاورزی در قسمت شمال شرقی شهر بولدر واقع در ایالت کلرادو آمریکا احداث گردیده است. موقعیت این سد در شکل ۱ نشان داده شده است. مخزن این سد با عمق ۵/۶ تا ۸/۵ متر و سطح ۷۰۰ هکتار حجمی معادل ۴۱ میلیون مترمکعب دارد و حدود ۲۰ درصد آب شرب شهر بولدر را تأمین می‌کند. دریاچه این سد علاوه بر تأمین آب شرب و کشاورزی کاربری تفریحی نیز دارد. این سد دارای ۷ ایستگاه اندازه‌گیری شاخص‌های کیفی در داخل و محدوده سد می‌باشد

که در پژوهش حاضر از مقادیر اندازه‌گیری شده ایستگاه BR_SDB واقع در قسمت جنوبی سد به منظور مدل‌سازی شاخص کیفی اکسیژن محلول استفاده شده است. اکسیژن محلول یکی از شاخص‌های مورد مطالعه در اکثر برنامه‌های پایش است. از دیدگاه عملیات پایش، شناسایی وضعیت اکسیژن محلول مخزن دارای اهمیت ویژه است. کاهش غلظت اکسیژن محلول به شدت بر کیفیت آب اثر گذاشته و باعث ایجاد محدودیت‌های جدید در قابلیت کاربری آب می‌شود. اکسیژن محلول یکی از مهم‌ترین عناصر در یک اکوسیستم آبی است. اکسیژن ماده‌ای ضروری برای موجودات زنده است و بسیاری از واکنش‌های شیمیایی از طریق اکسیداسیون کنترل می‌شود. به‌طور کلی می‌شود گفت که غلظت اکسیژن نشان‌دهنده سلامت اکوسیستم آبی است.



شکل ۱- موقعیت سد بولدر.

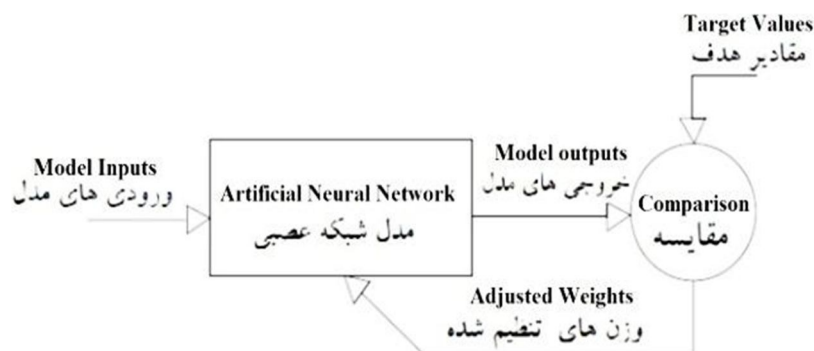
Figure 1. Boulder reservoir.

اتصال بین اجزا تعیین می‌شود. بنابراین یک ساختار مصنوعی به تبعیت از شبکه‌های طبیعی ساخته می‌شود و با تنظیم مقادیر هر اتصال، تحت عنوان وزن هر اتصال، نحوه ارتباط بین اجزای آن تعیین می‌شود. پس از تنظیم یا همان آموزش شبکه عصبی، اعمال

شبکه عصبی مصنوعی: شبکه‌های عصبی مصنوعی از عناصر عملیاتی ساده‌ای ساخته می‌شوند که به صورت موازی در کنار هم عمل می‌کنند. این عناصر از سیستم‌های عصبی زیستی الهام گرفته شده‌اند. در طبیعت، عملکرد شبکه‌های عصبی از طریق نحوه

این که خروجی شبکه و خروجی هدف بر هم منطبق گردد. شکل ۲ ساختار کلی یک شبکه عصبی مصنوعی را نشان می‌دهد (6).

یک ورودی خاص به آن موجب دریافت خروجی خاصی می‌شود. به‌طور کلی، شبکه بر مبنای تطابق و هم‌جنسی بین ورودی و هدف سازگار می‌شود تا



شکل ۲- ساختار کلی شبکه‌های عصبی مصنوعی.

Figure 2. General structure of artificial neural networks.

رگرسیون خطی چندمتغیره (MLR): مدل رگرسیون خطی از مدل‌های سنتی متداول است که ارتباط بین یک متغیر مستقل را با چند متغیر وابسته ایجاد می‌کند و رابطه ریاضی آن به شکل رابطه ۱ تعریف می‌شود.

$$Y = A_0 + \sum_{i=1}^n A_i X_i \quad (1)$$

که در آن، Y متغیر مستقل بوده و مقادیر $X_1 \dots X_n$ متغیرهای وابسته می‌باشند. A_0 ثابت رگرسیون بوده و مقادیر $A_1 \dots A_n$ ضرایب تنظیم شده رابطه می‌باشد.

مدل WANN: به‌منظور مدل‌سازی شاخص کیفی اکسیژن محلول در مخزن سد بولدر از مدل‌های رگرسیونی (MLR)، شبکه عصبی مصنوعی (ANN) و مدل تلفیقی شبکه عصبی مصنوعی با آنالیز موجک (WANN) بهره گرفته شد. در این پژوهش ابتدا مدل WANN توسعه داده شد و سپس نتایج دو مدل دیگر با نتایج WANN مقایسه شد. در مدل WANN،

تبدیل موجک: موجک (Wavelet) در لغت به معنی یک موج کوچک است. موجک یک شکل موج است که دارای طول محدود و میانگین صفر در آن طول می‌باشد. در صورت مقایسه موجک با موج سینوسی ملاحظه می‌گردد که موج سینوسی از منفی بی‌نهایت تا مثبت بی‌نهایت ادامه دارد در حالی که موجک دارای طول محدودی است. همچنین موج سینوسی دارای رفتار قابل پیش‌بینی است اما موجک حالت نامنظم و غیرقابل پیش‌بینی دارد.

در ساختار شبکه عصبی موجکی توابع گوناگونی وجود دارند که با توجه به عملکردهای مختلف آن‌ها نتایج متفاوتی نیز حاصل می‌شود. از این‌رو لازم است موجک‌های گوناگون مورد بررسی قرار گیرند تا موجکی که بهترین نتایج را به‌دست می‌دهد انتخاب گردد. در این پژوهش از موجک‌های هار، داوچیچیز، کویفلت و سیملت استفاده شده است. شرح تئوری موجک در کتاب چوی (1992) آمده است (2).

دقیق‌ترین مدل WANN، مدلی است که از بهترین ترکیب تابع موجک، سطح تجزیه سری اصلی با تبدیل موجک، تابع انتقال و تعداد نرون‌های لایه پنهان حاصل می‌شود. برای دستیابی به دقیق‌ترین مدل WANN موارد یاد شده به شرح جدول ۱ متغیر در نظر گرفته شد. در جدول ۱ توابع موجک هار، داوبیچیز ۲ تا ۸، سیملت ۲ تا ۸ و کویفلت ۱ تا ۵ به‌عنوان توابع تبدیل موجک در نظر گرفته شده است. همچنین سطح تجزیه سری اصلی به زیرسری‌های مؤثر از ۱ تا ۵ و تعداد نرون‌های لایه پنهان از ۱ تا ۱۵ متغیر در نظر گرفته شده است. در این جدول توابع لوگ سیگموئید و تانزانت سیگموئید، تابع انتقال لایه میانی را در مدل WANN پیشنهادی نشان می‌دهد.

خروجی‌های تبدیل موجک ورودی‌های شبکه عصبی مصنوعی را تشکیل می‌دهد. برای توسعه مدل، سری زمانی اصلی با استفاده از تبدیل موجک گسسته به چند زیرسری جزئیات و یک زیرسری تقریب تجزیه شد. هر یک از این زیرسری‌ها رفتار متفاوتی با زیرسری دیگر دارد و نقش خاص خود را در سری زمانی اصلی ایفا می‌کند. در نتیجه استفاده از این زیرسری‌ها به‌عنوان ورودی‌های شبکه عصبی مصنوعی، دقت فرایند آموزش را بهبود می‌بخشد. یک شبکه پیش‌خور سه لایه با تابع انتقال سیگموئید در لایه پنهان و تابع انتقال خطی در لایه خروجی با الگوریتم آموزش لونبرگ مارکوات، معماری پیشنهاد شده شبکه عصبی مصنوعی در این پژوهش است.

جدول ۱- دامنه تغییرات آیتم‌های مؤثر در عملکرد مدل WANN.

Table 1. Variation of WANN model parameters.

1-5	سطح تجزیه Decomposition level		Wavelet function
1-15	تعداد نرون در لایه پنهان Hidden layer nodes	haar	
		db2-8	
Logsig	تابع انتقال لایه میانی	Sym2-8	
Tansig	Transfer Function	coif1-5	

محلول تابعی از غلظت آن در ۳، ۶ و ۱۲ ماه قبل و در مدل WANN3 غلظت شاخص مورد مطالعه تابعی از غلظت آن در سه ماه قبل در نظر گرفته شده است. در این پژوهش تعداد ۹۰۰۰ مدل WANN مورد بررسی قرار گرفته و دقیق‌ترین مدل از بین آن‌ها انتخاب شده است.

به‌منظور شناسایی وضعیت وابستگی زمانی شاخص کیفی اکسیژن محلول به گام‌های زمانی گذشته سه حالت به شرح جدول ۲ در نظر گرفته شد. در مدل WANN1 غلظت اکسیژن محلول تابعی از غلظت آن در ۱ و ۱۲ ماه قبل (وضعیت مشابه سال گذشته) در نظر گرفته شده است. در مدل WANN2 به‌منظور در نظر گرفتن اثرات فصلی، غلظت اکسیژن

جدول ۲- مدل‌های پیشنهادی.

Table 2. Proposed models.

متغیرهای وابسته		متغیر مستقل	مدل
Dependent variables		Independent variable	Model
DO _{t-12}	DO _{t-1}	DO _t	WANN1
DO _{t-12}	DO _{t-6}	DO _t	WANN2
DO _{t-3}	DO _{t-2}	DO _t	WANN3

باشد و مقدار عددی منفی برای این شاخص آماری به معنی تخمین مدل، کم‌تر از مقدار متوسط اندازه‌گیرها می‌باشد. جدول‌های ۳ تا ۵ نتایج مدل‌های WANN1-3 را نشان می‌دهد.

در ردیف‌های جداول ۳ تا ۵ به‌ازای هر تابع موجک، با در نظر گرفتن دو معیار حداکثر E و حداقل RMSE بهترین ترکیب سطح تجزیه موجک، تابع انتقال لایه میانی و تعداد نرون‌های لایه پنهان از بین حالت‌های بررسی شده نشان داده شده است. مقایسه این جداول نشان می‌دهد که وضعیت اکسیژن محلول در ایستگاه مورد مطالعه به مقادیر آن در سه ماه گذشته بیش‌ترین وابستگی را دارد و مدل WANN3 با تابع موجک db8، با سطح تجزیه ۳ و با تابع انتقال لوگ‌سیگموئید و تعداد ۸ نرون در لایه میانی بهترین نتایج را به‌دست می‌دهد. مقادیر E و RMSE داده‌های آزمایشی برای این حالت به‌ترتیب ۰/۹۱ و ۰/۲۳ حاصل شده است. همچنین مشاهده می‌شود که برای سه تابع موجک داوچیچیز، کویفلت و سیملت با افزایش درجه تابع موجک عملکرد مدل‌ها بهبود می‌یابد.

۷۰ درصد داده‌های اندازه‌گیری شده به‌منظور آموزش، ۱۵ درصد برای صحت‌سنجی و ۱۵ درصد باقیمانده به‌عنوان داده‌های آزمایشی مورد استفاده قرار گرفت. مقادیر اندازه‌گیری نشده در طول دوره مورد مطالعه در گام اول با میانگین مقادیر ماه‌های نظیر در سال‌های دیگر ترمیم شد. جهت ارزیابی مدل‌ها از دو معیار ضریب نش و ریشه دوم میانگین مربعات خطا استفاده گردید که به‌ترتیب مطابق رابطه‌های ۲ و ۳ تعریف می‌شود.

$$E = 1 - \frac{\sum_{i=1}^n (DO_{measurd} - DO_{predicted})^2}{\sum_{i=1}^n (DO_{measurd} - DO_{measurd Ave})^2} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (DO_{measurd} - DO_{predicted})^2}{n}} \quad (3)$$

مقدار ضریب نش در بازه +۱ و -∞ تغییر می‌کند. مقدار عددی +۱ برای E زمانی حاصل می‌شود که مقادیر اندازه‌گیری شده با مقادیر پیش‌بینی مدل برابر باشد که در این حالت مقدار RMSE برابر صفر است. مقدار عددی صفر برای ضریب نش زمانی حاصل می‌شود که مقادیر پیش‌بینی مدل برابر با متوسط مقادیر اندازه‌گیری شده

جدول ۳- نتایج مدل WANNI

Table 3. Results of WANNI model.

معیار خطا	ضریب تبیین	تعداد گره لایه خروجی	تعداد گره لایه میانی	تعداد گره لایه ورودی	تعداد انتقال لایه میانی	سطح تجزیه	نوع موجک	مدل
RMSE	E	Output Layer (Size)	Hidden Layer (Size)	Input Layer (Size)	ANN Function	Decomposition level	Wavelet Type	Model
0.58	0.62	1	3	6	tansig	2	haar	$(2^{1-1}0a^{1-1}0a)^20a$
0.60	0.58	1	3	8	logsig	3	db2	
0.50	0.71	1	7	10	logsig	4	db3	
0.58	0.61	1	1	4	tansig	1	db4	
0.58	0.62	1	4	10	logsig	4	db5	
0.59	0.60	1	5	8	tansig	3	db6	
0.48	0.72	1	7	10	logsig	4	db7	
0.56	0.64	1	13	10	logsig	4	db8	
0.66	0.51	1	3	4	logsig	1	coif1	
0.68	0.49	1	2	6	logsig	2	coif2	
0.57	0.62	1	5	10	tansig	4	coif3	
0.55	0.65	1	3	10	tansig	4	coif4	
0.56	0.63	1	9	10	logsig	4	coif5	
0.52	0.68	1	5	8	logsig	3	sym1	
0.63	0.55	1	2	8	tansig	3	sym2	
0.59	0.58	1	7	6	tansig	2	sym3	
0.63	0.55	1	13	8	logsig	3	sym4	
0.63	0.55	1	3	4	logsig	1	sym5	
0.57	0.62	1	1	10	logsig	4	sym6	
0.54	0.66	1	9	8	logsig	3	sym7	
0.59	0.60	1	10	12	logsig	5	sym8	

جدول ۴- نتایج مدل WANN2.

Table 4. Results of WANN2 model.

معیار خطا RMSE	ضریب تنبین E	تعداد گره لایه خروجی Output Layer (Size)	تعداد گره لایه میانی Hidden Layer (Size)	تعداد گره لایه ورودی Input Layer (Size)	تابع انتقال لایه میانی ANN Function	سطح تجزیه Decomposition level	نوع موجک Wavelet Type	مدل Model
0.77	0.35	1	5	15	tansig	4	haar	$DO_t(DO_{t-3}, DO_{t-6}, DO_{t-12})$
0.51	0.69	1	14	12	tansig	3	db2	
0.53	0.67	1	12	12	logsig	3	db3	
0.53	0.67	1	15	12	tansig	3	db4	
0.47	0.73	1	5	12	tansig	3	db5	
0.62	0.56	1	8	12	logsig	3	db6	
0.43	0.77	1	9	12	logsig	3	db7	
0.42	0.78	1	6	15	logsig	4	db8	
0.54	0.66	1	3	18	logsig	5	coif1	
0.55	0.65	1	11	18	tansig	5	coif2	
0.49	0.72	1	7	15	logsig	4	coif3	
0.50	0.70	1	3	12	logsig	3	coif4	
0.39	0.80	1	8	12	logsig	3	coif5	
0.62	0.57	1	10	18	tansig	5	sym1	
0.67	0.50	1	2	15	logsig	4	sym2	
0.49	0.72	1	15	18	logsig	5	sym3	
0.49	0.71	1	9	15	logsig	4	sym4	
0.52	0.68	1	6	15	tansig	4	sym5	
0.43	0.77	1	13	15	logsig	4	sym6	
0.56	0.63	1	1	15	tansig	4	sym7	
0.45	0.75	1	5	15	logsig	4	sym8	

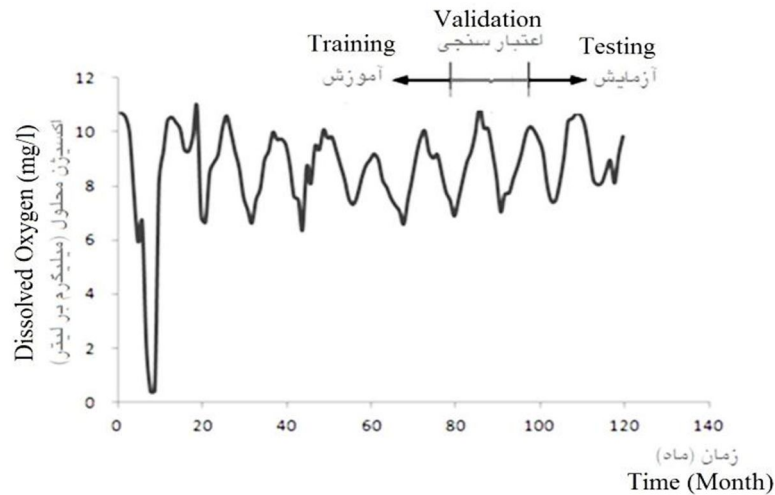
جدول ۵- نتایج مدل WANN3.

Table 5. Results of WANN3 model.

معیار خطا RMSE	ضریب تنبین E	تعداد گره لایه خروجی Output Layer (Size)	تعداد گره لایه میانی Hidden Layer (Size)	تعداد گره لایه ورودی Input Layer (Size)	تابع انتقال لایه میانی ANN Function	سطح تجزیه Decomposition level	نوع موجک Wavelet Type	مدل Model
0.39	0.82	1	9	6	logsig	1	haar	$DO_t(DO_{t-1}, DO_{t-2}, DO_{t-3})$
0.36	0.84	1	6	6	tansig	1	db2	
0.34	0.85	1	4	9	tansig	2	db3	
0.33	0.86	1	6	6	tansig	1	db4	
0.35	0.85	1	8	9	logsig	2	db5	
0.28	0.89	1	1	12	tansig	3	db6	
0.27	0.89	1	1	9	tansig	2	db7	
0.23	0.91	1	8	12	logsig	3	db8	
0.38	0.83	1	2	15	tansig	4	coif1	
0.33	0.86	1	3	15	logsig	4	coif2	
0.28	0.89	1	1	12	logsig	3	coif3	
0.26	0.90	1	3	9	logsig	2	coif4	
0.24	0.90	1	2	9	logsig	2	coif5	
0.38	0.83	1	10	12	logsig	3	sym1	
0.34	0.85	1	3	12	tansig	3	sym2	
0.34	0.85	1	10	12	logsig	3	sym3	
0.32	0.87	1	1	12	logsig	3	sym4	
0.26	0.90	1	14	12	logsig	3	sym5	
0.30	0.88	1	2	18	logsig	5	sym6	
0.26	0.90	1	2	18	tansig	5	sym7	
0.25	0.90	1	2	18	logsig	5	sym8	

داده‌های بازسازی شده را نمایش می‌دهد. همچنین نتایج آنالیز آماری داده‌های بازسازی شده در جدول ۶ نشان داده شده است.

پس از توسعه مدل WANN با استفاده از خروجی‌های شبکه آموزش‌یافته، بازسازی داده‌ها انجام شد و مقادیر اندازه‌گیری نشده با مقادیر خروجی مدل جایگزین گردید. شکل ۳ سری زمانی



شکل ۳- سری زمانی داده‌های بازسازی شده.

Figure 3. Restructured data time series.

جدول ۶- آنالیز آماری داده‌های بازسازی شده اکسیژن محلول در مخزن سد بولدر.

Table 6. Statistical analysis of restructured DO data in the Boulder reservoir.

دوره	میانگین	ماکزیمم	مینیمم	انحراف معیار	ضریب تغییرات	ضریب چولگی
Period	Mean	Max	Min	S	CV	SK
آموزش	8.38	10.90	0.32	1.87	0.22	-2.19
Train						
اعتبارسنجی	8.83	10.13	6.98	1.06	0.12	-0.21
Validation						
آزمایش	9.07	10.63	7.39	1.06	0.12	0.22
Test						
کل	8.54	10.90	0.32	1.69	0.20	-2.29
Total						

تغذیه‌گرایی در مخزن، از اهداف عملیات پایش کیفیت آب در مخزن سد بولدر می‌باشد. وقوع فرایند تغذیه‌گرایی در مخزن موجب رشد بی‌رویه جلبک‌ها شده و کیفیت آب مخزن را به‌طور کلی کاهش می‌دهد. تغییر رنگ و بوی آب، افزایش احتمال وقوع شرایط

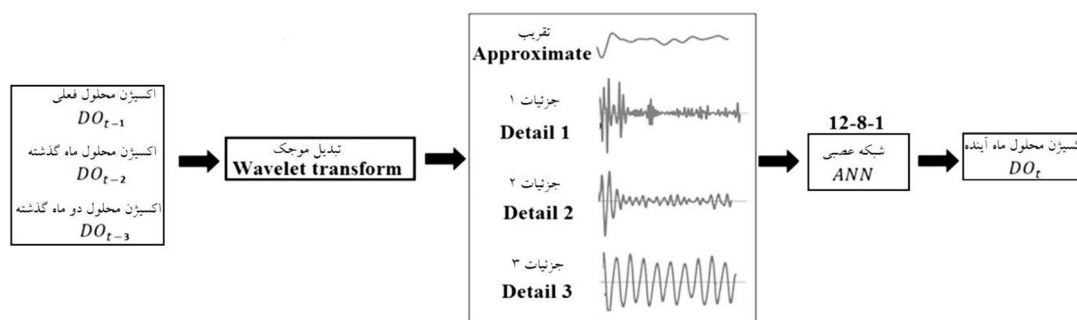
نتایج و بحث

داشتن مبنایی برای مطالعات، شناسایی نقاط آلاینده نقطه‌ای و غیرنقطه‌ای، شناسایی زمان‌هایی که تغییر در کیفیت آب اتفاق می‌افتد و ارائه رهنماهایی جهت حفظ کیفیت آن و همچنین کنترل فرایند

می‌دهد. در نتیجه همان مدل بار دیگر با استفاده از داده‌های بازسازی شده آموزش داده شد.

نتایج مدل WANN: در مدل WANN نهایی، سری زمانی اصلی به سه زیرسری جزئیات و یک تقریب تجزیه شده است و با در نظر گرفتن سه گام تأخیر زمانی مربوط به مقادیر اندازه‌گیری شده در سه ماه گذشته، در مجموع تعداد ۱۲ نرون در لایه ورودی قرار می‌گیرد. شکل ۴ ساختار مدل WANN نهایی ارائه شده در این پژوهش را نمایش می‌دهد.

بی‌هوای و افت سطح اکسیژن محلول در عمق‌های پایین‌تر و همچنین کاهش تعداد ماهی‌ها، موجب افزایش هزینه‌های تصفیه آب و کاهش جاذبه‌های تفریحی مخزن سد بولدر می‌شود. در این پژوهش شاخص کیفی اکسیژن محلول که نشان‌دهنده سلامت اکوسیستم آبی است مورد مطالعه قرار گرفت و نتایج نشان داد که مدل WANN3 با تابع موجک db8، با سطح تجزیه ۳ و با تابع انتقال لوگ‌سیگموئید و تعداد ۸ نرون در لایه میانی دقیق‌ترین نتایج را در پیش‌بینی غلظت اکسیژن محلول در یک ماه آینده به‌دست

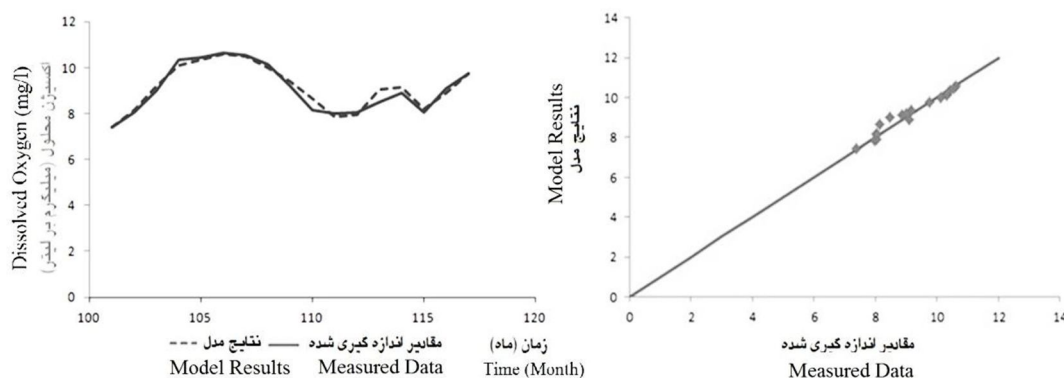


شکل ۴- ساختار مدل WANN.

Figure 4. Structure of WANN model.

آزمایشی برای این مدل به ترتیب ۰/۹۶ و ۰/۲۲ حاصل شده است.

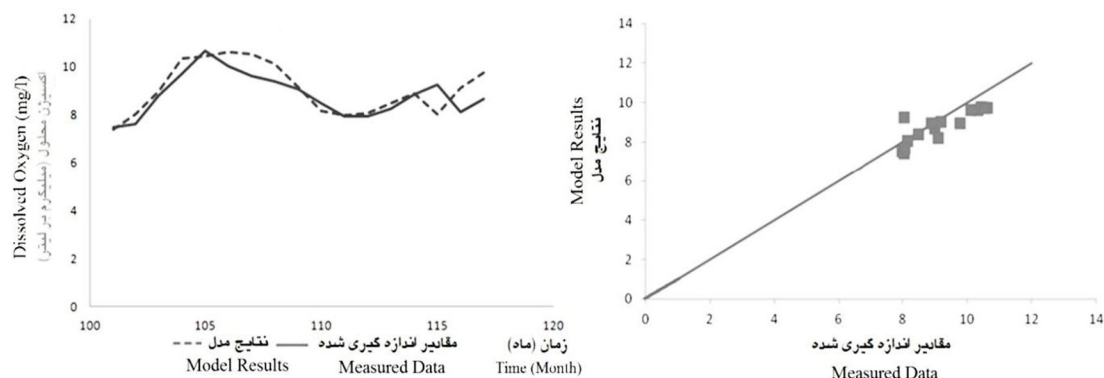
شکل ۵ نشان می‌دهد که مدل WANN غلظت اکسیژن محلول را در یک ماه آینده با دقت بالایی پیش‌بینی می‌کند و مقادیر E و RMSE داده‌های



شکل ۵- نتایج مدل WANN برای داده‌های آزمایشی.

Figure 5. Results of WANN model.

نتایج مدل ANN: در این پژوهش به منظور بررسی اثر استفاده از تبدیل موجک بر روی نتایج پژوهش، سری زمانی بازسازی شده به صورت مستقیم به عنوان اطلاعات ورودی همان مدل شبکه عصبی که در حالت تلفیقی به کار برده شده بود استفاده گردید. شکل ۶ نتایج مدل شبکه عصبی تنها را برای داده‌های آزمایشی نمایش می‌دهد. افزایش RMSE داده‌های آزمایشی به ۰/۶۱ و کاهش مقدار E این داده‌ها به ۰/۶۴ در مقایسه با مدل WANN نشان می‌دهد که استفاده از تبدیل موجک نتایج مدل‌سازی را به مقدار قابل توجهی بهبود می‌بخشد. همچنین این شکل نشان می‌دهد که مدل ANN مقادیر غلظت اکسیژن محلول را به صورت دست پایین پیش‌بینی می‌کند.



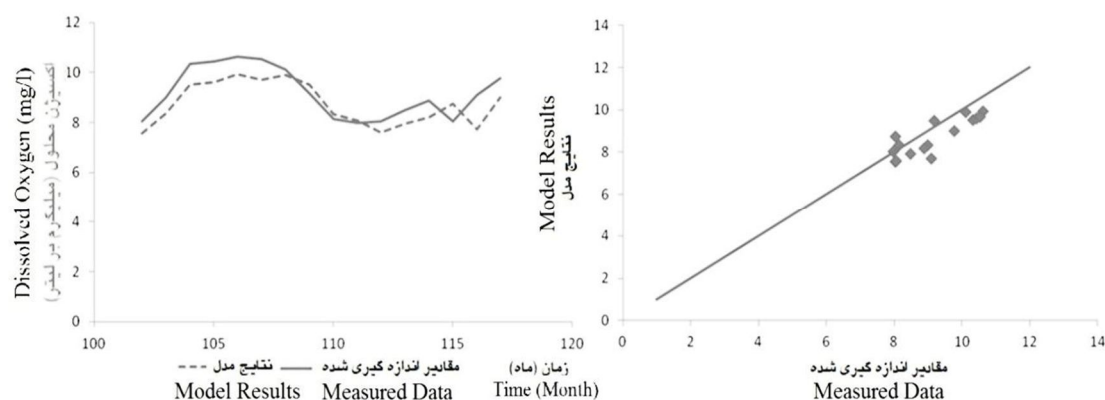
شکل ۶- نتایج مدل ANN برای داده‌های آزمایشی.

Figure 6. Results of ANN model.

این مدل به ترتیب ۰/۸۸ و ۰/۵۶ حاصل شده است. این شکل نشان می‌دهد که مدل MLR مقادیر شاخص کیفی مورد مطالعه را به صورت دست پایین پیش‌بینی می‌کند.

مقایسه نتایج مدل‌های WANN و WANN3 نهایی ارائه شده نشان می‌دهد که استفاده از داده‌های بازسازی شده موجب افزایش مقدار ضریب نش و کاهش مقدار خطا می‌شود و استفاده از مدل تلفیقی شبکه عصبی و تبدیل موجک در بازسازی داده‌ها، نتایج مدل‌سازی را بهبود می‌بخشد. نتایج کارایی مدل WANN ارائه شده را در بازسازی و ترمیم داده‌ها در سری زمانی نشان می‌دهد. شکل ۸ نشان می‌دهد که مدل WANN ارائه شده در این پژوهش می‌تواند به خوبی مقادیر اکسیژن محلول را با استفاده از مقادیر آن در سه ماه گذشته پیش‌بینی کند. همچنین این شکل نشان می‌دهد که مدل ارائه شده، این مقادیر را به صورت دست بالا تخمین می‌زند.

نتایج مدل خطی MLR: در این پژوهش کارایی مدل خطی MLR در پیش‌بینی غلظت اکسیژن محلول مورد بررسی قرار گرفت. شکل ۷ نتایج مدل خطی MLR را برای داده‌های آزمایشی نمایش می‌دهد. مقادیر E و RMSE داده‌های آزمایشی برای



شکل ۷- نتایج مدل MLR برای داده‌های آزمایشی.

Figure 7. Results of MLR model.

اثر می‌گذارد. توانایی مدل‌ها در پیش‌بینی نقاط مینیمم در سری زمانی دارای اهمیت بالایی می‌باشد. جدول ۸ نتایج مدل‌های ارائه شده در این پژوهش را برای ماه‌های آگوست و سپتامبر ۱۹۹۸ نشان می‌دهد.

مقایسه نتایج جدول ۸ نشان می‌دهد که مدل‌های WANN و ANN کارایی بالایی در پیش‌بینی شرایط بی‌هوای در مخزن سد دارند. در حالی که نتایج مدل MLR در این نقاط دارای دقت بسیار پایینی می‌باشد.

مقایسه نتایج مدل‌های ارائه شده: خلاصه نتایج مدل‌های ارائه شده در جدول ۷ آمده است.

مقایسه نتایج نشان می‌دهد که مدل WANN عملکرد بهتری نسبت به دو مدل دیگر دارد و مدل MLR ضعیف‌ترین عملکرد را در پیش‌بینی غلظت اکسیژن محلول در مخزن سد بولدر دارد.

در سری زمانی داده‌های مورد مطالعه در ماه‌های آگوست و سپتامبر ۱۹۹۸ سطح اکسیژن محلول در مخزن به شدت افت پیدا کرده است. از آنجا که شرایط بی‌هوای به شدت بر کیفیت آب مخازن

جدول ۷- نتایج مدل‌ها.

Table 7. Results of the models.

معیار خطا	ضریب تبیین	مدل
RMSE	E	Model
0.22	0.96	مدل تلفیقی موجک-عصبی WANN
0.61	0.64	شبکه عصبی مصنوعی ANN
0.88	0.56	مدل رگرسیون خطی MLR

جدول ۸- نتایج مدل‌ها برای ماه‌های اگوست و سپتامبر ۱۹۹۸.

Table 8. Results of models for August and September 1998.

سپتامبر September		اگوست August		مدل Model
پیش‌بینی شده Predicted	اندازه‌گیری شده Measured	پیش‌بینی شده Predicted	اندازه‌گیری شده Measured	
0.54		0.36		مدل تلفیقی موجک-عصبی WANN
0.35	0.37	0.42	0.32	شبکه عصبی مصنوعی ANN
0.87		1.55		مدل رگرسیون خطی MLR

نتیجه‌گیری

موجک سری زمانی اصلی را به زیرسری‌هایی با فرکانس‌های متفاوت و متناسب با تغییرات زمانی غلظت اکسیژن محلول تجزیه می‌کند. این زیرسری‌ها به صورت مجزا وارد شبکه عصبی می‌شود و این موضوع موجب وزن‌دهی دقیق‌تر و متناسب‌تر با تغییرات زمانی غلظت‌ها در فرایند آموزش می‌شود. در نتیجه استفاده از تبدیل موجک به مقدار قابل‌توجهی نتایج حاصل از مدل‌سازی را بهبود می‌بخشد. غلظت اکسیژن محلول به‌طور مستقیم با کیفیت آب مخازن سدها در ارتباط است و کنترل شرایط بی‌هوازی در مخزن سد دارای اهمیت است. نتایج حاصل از پژوهش نشان می‌دهد که مدل‌های WANN و ANN در قیاس با مدل MLR کارایی بالاتری در پیش‌بینی شرایط بی‌هوازی در مخزن سد دارند. همچنین نتایج نشان می‌دهد که برای سه تابع موجک داوینچی، سیملت و کویفلت، با افزایش درجه تابع که همراه با افزایش پیچیدگی آن می‌باشد، نتایج مدل‌سازی بهبود می‌یابد که علت این موضوع، می‌تواند ماهیت غیرخطی و پیچیده منابع آب باشد. نتایج نشان می‌دهد که غلظت اکسیژن محلول در مخزن سد بولدر از نظر زمانی بیش‌ترین وابستگی را به سه ماه گذشته دارد. از

در این پژوهش یک مدل تلفیقی جدید با استفاده از تبدیل موجک و شبکه عصبی مصنوعی به‌منظور پیش‌بینی غلظت اکسیژن محلول در یک ماه آینده در مخزن سد بولدر واقع در ایالت کلرادو آمریکا ارائه گردید. بر اساس مروری که بر مطالعات انجام شده صورت پذیرفته است، این پژوهش برای اولین بار مدل ترکیبی شبکه عصبی و تبدیل موجک را در پیش‌بینی غلظت اکسیژن محلول در مخازن سدها به‌کار گرفته است. همان‌طور که در مروری بر پیشینه مطالعات این پژوهش آمده است در زمینه کاربرد مدل‌های هوشمند در پیش‌بینی مقادیر شاخص‌های کیفی در مخازن سدها، از مدل تلفیقی شبکه عصبی با تبدیل موجک به‌منظور پیش‌بینی شاخص کیفی کلرفیل‌آ استفاده شده است و نتایج پژوهش صورت پذیرفته نشان داده است که تبدیل موجک نتایج حاصل از مدل‌سازی را بهبود می‌بخشد. نتایج حاصل از این پژوهش نیز نشان می‌دهد که استفاده از مدل WANN در پیش‌بینی غلظت اکسیژن محلول در مخزن سد بولدر، نتایج دقیق‌تری را نسبت به مدل‌های ANN و MLR به‌دست می‌دهد. به‌طوری‌که تبدیل

دیگر نتایج این پژوهش می‌توان به توانایی و کارایی مدل WANN ارائه شده در بازسازی و ترمیم داده‌ها در سری زمانی اشاره کرد. پیشنهاد می‌شود که در پژوهش‌های آتی اثرات دما و همچنین تغییرات فصلی بر روی غلظت اکسیژن محلول با استفاده از تبدیل موجک بررسی شود.

منابع

1. Banejad, H., and Olyaie, E. 2011. Application of an Artificial Neural Network Model to Rivers Water Quality Indexes Prediction – A Case Study. *J. Amer. Sci.* 7: 1. 60-65.
2. Chui, C.K. 1992. *An Introduction to Wavelets*: Academic Press.
3. Diamantopoulou, M.J., Antonopoulos, V.Z., and Papamichail, D.M. 2005. The use of neural network technique for the water quality parameters. *Operational Research*. 5: 1. 115-125.
4. Diamantopoulou, M.J., Antonopoulos, V.Z., and Papamichail, D.M. 2005. The use of neural network technique for the water quality parameters of Axiosriver in northern Greece. *European Water E.W Publication*. 11/12: 55-62.
5. Jan-Tai, K. 2007. Using artificial neural network for reservoir eutrophication prediction. *Ecological modeling*. 200: 171-177.
6. Kia, S.M. 2010. *Soft Computing Using MATLAB*. Kian Rayaneh Sabz. (In Persian)
7. Karul, C., Soyupak, S., and Yurteri, C. 1999b. Neural network models as a management tool in lakes. *Hydrobiologia*. 408/409: 139-144.
8. Karul, C., Soyupak, S., and Yurteri, C. 2000. Case studies on the use of neural networks in eutrophication modeling. *Ecological Modeling*. 134: 145-152.
9. Kim, M.E., Shon, T.S., and Shin, H.S. 2012. Forecasting algal bloom (chl-a) on the basis of coupled wavelet transform and artificial neural networks at a large lake. *Desalination and Water Treatment*. 51: 2013. 4118-4128.
10. Merdun, H., and Çinar, Ö. 2010. Artificial neural network and regression techniques in modelling surface water quality. *Environment Protection Engineering*. 36: 2. 95-109.
11. Misaghi, F., and Mohammadi, K. 2003. Estimating water quality changes in the zayandeh_rud river using artificial neural network model. Written for presentation at the CSAE/SCGR 2003 Meeting Montréal, Québec, July 6-9, 2003.
12. Muhittin, A. 2008. Modeling the water quality of lake EMIR using artificial neural networks (ANN) and adaptive neuro fuzzy inference system (ANFIS). Published in METU Library & YOK Thesis Centre Aralık 2008.
13. Nourani, V., Rezapour, T., and Sayyadi, M. 2013. Application of the Artificial Neural Network to monitor the quality of treated water. *Inter. J. Manage. Inf. Technol.* 3: 1. 38-45.
14. Rajaei, T., Mirbagheri, S.A., Zounemat-Kermani, M., and Nourani, V. 2009. Daily suspended sediment concentration simulation using ANN and neuro-fuzzy models. *Sci. Total Environ.* 407: 17. 4916-4927.
15. Rajaei, T., Nourani, V., Zounemat-Kermani, M., and Kisi, O. 2011. River Suspended Sediment Load Prediction: Application of ANN and Wavelet Conjunction Model. *J. Hydrol. Engin.* 16: 8. 613-627.
16. Shakeri-Abdolmaleki, A., Gholamalizadeh, A., and Soltani, J. 2013. Artificial Neural Network (ANN) Approach for Predicting Cu Concentration in Drinking Water of Chahnimeh1 Reservoir in Sistan-Balochistan, Iran. *Health Scope*. Pp: 31-38.
17. Song, G.J., and Zhe, L. 2009. Artificial neural network modeling of water quality of the Yangtze River system: a case study in reaches crossing the city of Chongqing. *J. Chongqing Univ.* 8(1): 1-9.
18. Walter, M., Recknagel, F., Carpenter, C., and Bormans, M. 2001. Predicting eutrophication effects in the Burrinjuck Reservoir (Australia) by means of the deterministic model SALMO and the recurrent neural network model ANNA. *Ecological Modelling*. 146: 97-113.



Gorgan University of Agricultural
Sciences and Natural Resources

J. of Water and Soil Conservation, Vol. 22(6), 2016
<http://jwsc.gau.ac.ir>

Prediction of monthly dissolved oxygen using wavelet and artificial neural network combined model

T. Rajae¹ and *A. Boroumand²

¹Associate Prof., Dept. of Civil Engineering, University of Qom, Qom, Iran,

²Ph.D. Student, Dept. of Civil Engineering, University of Qom, Qom, Iran

Received: 02/24/2014; Accepted: 12/15/2014

Abstract

Background and Objectives: Qualitative and quantitative management of water resources to meet the demand for different usages is the major approach in each country policy. In this regard, dam reservoirs water quality monitoring is an important step in the management of these resources. Previous researches described in this study, show that, artificial neural network based models can be used to predict the qualitative indices of water resources efficiently. The objective of this study is to develop an efficient model in order to predict the concentration of dissolved oxygen in the dam reservoir.

Materials and Methods: The data used in this study consisted of monthly dissolved oxygen data from January 1998 to December 2007 were obtained from Boulder reservoir, Colorado, (USA). This study investigated the prediction of dissolved oxygen in a gauging station in the reservoir by artificial neural network, multi linear regression and conjunction of wavelet analysis and artificial neural network models. In the proposed wavelet analysis and artificial neural network model, observed time series of dissolved oxygen was decomposed at different scales by wavelet analysis. Then, total effective time series of this water quality index was imposed as inputs to the artificial neural network model for prediction of one month ahead dissolved oxygen.

Results: Results showed that the wavelet analysis and artificial neural network combined model performance were better in prediction rather than the artificial neural network and multi linear regression models. Using wavelet analysis improved the modeling results considerably. In the combined model, E, and RMSE is obtained 0.96 and 0.22 respectively. Artificial neural network and the combined wavelet with artificial neural network models produced reasonable predictions for the minimum values that lead anaerobic condition in reservoir.

Conclusion: The results showed that using wavelet analysis in conjunction with artificial neural network, improved the modeling performance. Also the results of this research indicate that the wavelet analysis and artificial neural network combined model is a promising model for dissolved oxygen predicting in reservoirs such as those found in Boulder reservoir.

Keywords: Dissolved oxygen, Wavelet transform, Artificial neural network, Water quality, Dam reservoir

* Corresponding Author; Email: a.broumand@stu.qom.ac.ir

