

بهبود عملکرد مدل شبکه عصبی مصنوعی با کمک تبدیل موجک و روش PCA برای مدل سازی و پیش بینی اکسیژن مورد نیاز بیولوژیکی (BOD)

فریدون رادمنش^{۱*}، امیر پورحقی^۲، اباذر سلگی^۳

۱. دانشیار گروه هیدرولوژی و منابع آب، دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز

۲ و ۳. دانشجوی دکتری مهندسی منابع آب، دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز

(تاریخ دریافت ۱۳۹۵/۰۸/۲۰؛ تاریخ تصویب ۱۳۹۵/۱۰/۰۱)

چکیده

در دهه های اخیر، توسعه مدل های هوش مصنوعی برای پیش بینی پدیده های هیدرولوژیکی کاربرد زیادی پیدا کرده است. در این مطالعه، توانایی مدل های شبکه عصبی مصنوعی به منظور مدل سازی و پیش بینی اکسیژن مورد نیاز بیولوژیکی (BOD) در رودخانه کارون واقع در غرب کشور ایران ارزیابی شد. به منظور بهبود نتایج شبیه سازی از آنالیز موجک به عنوان مدل ترکیبی استفاده شد. سری زمانی ماهانه شاخص BOD رودخانه کارون در ایستگاه ملاثانی به مدت ۱۳ سال (۱۳۸۱-۱۳۹۳) و با استفاده از متغیرهای کمکی اکسیژن محلول (DO)، جریان رودخانه و دمای ماهانه شبیه سازی شد. بهترین ورودی مدل های به کار گرفته شده با استفاده از روش تجزیه و تحلیل مؤلفه های اصلی (PCA) انتخاب شد. برای ارزیابی و مقایسه عملکرد مدل ها از جذر میانگین مربعات خطا (RMSE)، ضریب تعیین (R^2) و معیار اطلاعاتی آکائیک (AIC) استفاده شد. نتایج به دست آمده بیانگر آن بود که شبکه عصبی مصنوعی میزان خطای ۰/۰۴۱۲ و ضریب تعیین ۰/۷۶ دارد و اعمال تبدیل موجک روی داده های ورودی مدل، سبب بهبود نتایج تا ضریب تعیین ۰/۸۹ و میزان خطای ۰/۰۲۷۳ شد.

کلیدواژگان: تبدیل موجک، رودخانه کارون، BOD، PCA.

مقدمه

آب به‌عنوان بنیان‌گذار همه تمدن‌های بشری شناخته شده است و رودخانه‌ها نیز یکی از منابع اصلی تأمین آب این تمدن‌ها بوده‌اند [۱]. در همه اهداف بشر برای استفاده از رودخانه، کیفیت آب می‌تواند مهم‌ترین عامل محدودکننده در استفاده از این منابع به‌شمار آید [۲]. امروزه رشد صنعت و توسعه شهری از دلایل مهم افزایش آلودگی رودخانه‌هاست. رودخانه‌ها همواره علاوه بر تأمین آب مورد نیاز جوامع، به‌عنوان منبعی سهل‌الوصول و تجدیدپذیر برای تخلیه آلودگی‌ها نیز مد نظر بوده‌اند [۱].

BOD از مهم‌ترین شاخص‌ها برای بررسی سلامت رودخانه به‌شمار می‌آید [۲]. BOD مقدار اکسیژن مورد نیاز میکروارگانیسم‌های هوازی موجود در نمونه برای اکسیداسیون مواد آلی است [۳].

مقدار بیش از حد BOD سبب کاهش غلظت اکسیژن محلول و ایجاد شرایط نامناسب زندگی برای گیاهان و جانوران رودخانه می‌شود [۴]. مواد مغذی و نور سبب رشد فیتوپلانکتون‌ها و افزایش غلظت اکسیژن محلول می‌شود که این می‌تواند مقدار BOD آب را کاهش دهد [۵]. فرایند اندازه‌گیری مقدار BOD موجود در آب نیازمند زمان و فراهم کردن شرایط مورد نیاز اندازه‌گیری است. در این فرایند که پنج روز به طول می‌انجامد مقدار اکسیژن مصرف شده میکروارگانیسم‌های موجود در آب در دمای ۲۰ درجه سانتی‌گراد اندازه‌گیری می‌شود [۶].

مدل‌های مختلفی در سال‌های اخیر برای مدیریت کیفی رودخانه ارائه شده است. اغلب این مدل‌ها به داده‌های ورودی مختلفی نیاز دارند که اندازه‌گیری آنها زمان‌بر و هزینه‌بر است [۷]. با این حال، از آنجا که متغیرهای زیادی روی پارامترهای کیفیت آب مؤثر هستند و یک رابطه غیرخطی و پیچیده بین آنها برقرار است، روش‌های معمول به‌خوبی نمی‌توانند مسئله مدیریت کیفی منابع آب را حل کنند [۸ و ۹]. در دهه‌های اخیر، تکنیک‌های هوش مصنوعی برای پیش‌بینی پدیده‌های مختلف هیدرولوژیکی تحول بزرگی را ایجاد کرده‌اند [۱۰]. این مدل‌ها توانایی خود را در مدیریت منابع آب به‌خوبی نشان داده‌اند [۱۱]. تحقیقات اخیر نشان می‌دهد مدل‌های جعبه‌سیاه همچون ANN می‌توانند جایگزین خوبی برای روش‌های معمول به‌شمار آیند [۲، ۱۲، ۱۳ و ۱۴]. تحقیقات خوبی در دنیا در زمینه استفاده از مدل ANN ارائه شده است.

چریستو و همکارانش [۱۵] یک مدل ANN و همچنین یک سری معادلات طراحی برای پیش‌بینی حذف BOD در جریان زیرسطحی در تالاب‌های مصنوعی ارائه دادند. نتایج مدل ANN نسبت به مقادیر مشاهده‌ای همبستگی خوبی داشته است. نتایج نشان داد حذف COD به‌شدت به حذف BOD وابسته است و یک معادله برای پیش‌بینی حذف COD نیز ارائه شد. نجاه و همکارانش [۱۶] توانایی زیاد شبکه‌های عصبی را در تخمین شاخص‌های کیفی آب رودخانه Johor مالزی و برآورد مقدار EC و کل جامدات محلول (TDS) و کدورت در این حوضه را تأکید کردند.

اسدالله فردی و همکارانش [۱۷] توانایی دو مدل شبکه عصبی مصنوعی و شبکه عصبی بازگشتی را در تخمین شاخص کیفی آب رودخانه تلخه‌رود در آذربایجان شرقی برای برآورد پارامتر TDS بررسی کردند. ون و همکارانش [۱۸] اکسیژن محلول رودخانه Heihe چین را با استفاده از شبکه عصبی مصنوعی پیش‌بینی کردند. نتایج پژوهش آنها بیانگر دقت و توانایی زیاد مدل پیشنهادی برای پیش‌بینی و شبیه‌سازی پارامتر اکسیژن محلول بود.

پارما و بهاردواج [۱۹] تجزیه و تحلیل آماری و موجک پارامترهای کیفی آب COD (تقاضای شیمیایی اکسیژن)، BOD (نیاز بیوشیمیایی به اکسیژن)، DO (اکسیژن محلول)، WT (دمای آب)، AMM (آمونیاک آزاد)، TKN (نیتروژن کجلدال)، TC (کل کلیرم)، FC (کلیرم مدفوعی) و PH (پتانسیل هیدروژن) رودخانه Yamuna در هند را برای داده‌های ماهانه یک دوره ده‌ساله بررسی کردند؛ در این مطالعه از تابع موجک Db5 استفاده شده است.

در یک تحقیق به‌صورت مروری روش‌های استفاده شده برای نیاز BOD ارائه شده است [۲۰].

روش بهینه‌سازی پارامترها برای مدل پویای کیفیت آب براساس تئوری مبتنی بر داده (data-based driven theory) توسط لیانگ و همکارانش [۲۱] ارائه شده است. علیایی و همکارانش [۲۲] شبیه‌سازی تغییرات شاخص‌های BOD و DO را برای رودخانه دره مرادبیگ همدان با استفاده از شبکه عصبی مصنوعی بررسی کردند. نتایج پژوهش آنها بیانگر کارایی زیاد شبکه عصبی در تخمین شاخص‌های کیفی یادشده داشت.

دقت در پیش‌بینی، از آنالیز موجک به‌عنوان مدل ترکیبی استفاده شد. با توجه به استفاده از متغیرهای کمکی و تبدیل موجک برای افزایش دقت مدل، از الگوریتم PCA به‌منظور انتخاب ورودی مناسب و بهینه به مدل استفاده شد. در آخر به‌منظور بررسی عملکرد مدل‌ها، معیارهای ارزیابی R^2 و RMSE برای هر یک از مدل‌ها محاسبه شد.

مواد و روش‌ها

منطقه مطالعه‌شده

رودخانه کارون از رشته‌کوه زاگرس سرچشمه می‌گیرد و پس از عبور از مسیر کوهستانی در نزدیکی شهر گتوند به دشت خوزستان وارد می‌شود. رودخانه کارون در شمال شوشتر به دو شاخه تقسیم می‌شود که در جنوب شوشتر با یکدیگر پیوند می‌خورند. در این مسیر پر از پیچ‌وخم آب مورد نیاز شرب، کشاورزی و صنعت ده‌ها شهر و روستا، هزاران هکتار اراضی کشاورزی، تولید انرژی برق‌آبی، چندین طرح پرورش ماهی و طرح‌ها و کارخانه‌های صنعتی را تأمین می‌کند. شکل ۱ موقعیت رودخانه کارون و ایستگاه ملاثانی را نشان می‌دهد. ایستگاه ملاثانی در مختصات $48^{\circ}52'40''$ شمالی و $31^{\circ}35'01''$ شرقی قرار دارد. جدول ۱ پارامترهای استفاده‌شده در این تحقیق را ارائه می‌دهد.

به‌علت اینکه وارد کردن داده‌ها به‌صورت خام سبب کاهش سرعت و دقت می‌شود، از روش استانداردسازی داده‌ها استفاده شده است که این کار مانع کوچک‌شدن بیش از حد وزن‌ها و سبب جلوگیری از اشباع زود هنگام نرون‌ها می‌شود. با روش استانداردسازی هر عدد به عددی بین صفر تا یک تبدیل می‌شود [۳۰]. با توجه به پیشنهاد سلگی [۳۱] از رابطه ۱ برای نرمال‌سازی (استانداردسازی) استفاده شده است.

$$y = \frac{x - \bar{x}}{x_{max} - x_{min}} \quad (1)$$

که در این رابطه X داده مد نظر، \bar{X} میانگین داده‌ها، X_{max} بیشترین داده‌ها، X_{min} حداقل داده‌ها و y داده استاندارد شده است. در این تحقیق از ۷۵ درصد داده‌های BOD برای آموزش و ۲۵ درصد برای شبیه‌سازی استفاده شده است.

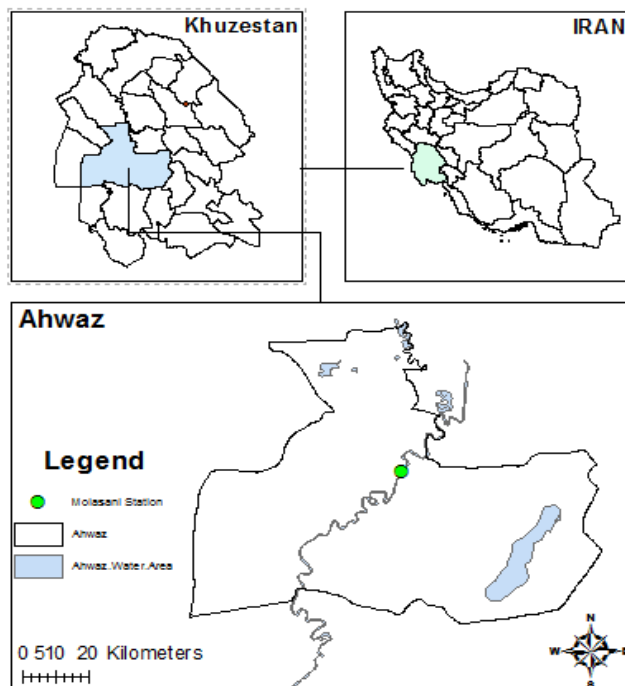
هر چند از این مدل‌ها به‌طور گسترده استفاده شده است، ولی هنگامی که رفتار دینامیکی یک سیستم هیدرولوژیکی با گذشت زمان تغییر می‌کند، مدل‌های یادشده برای پیش‌بینی پارامترهای منابع آب توانایی کافی ندارند و مدل‌های مناسبی نیستند [۲۳]. سری‌های زمانی هیدرولوژیکی دارای مشخصات غیرایستا، پرش، روند و تغییرات ناگهانی در بسامد هستند که برای مدل‌سازی آنها استفاده از الگوریتم‌ها، معادلات غیرخطی و نظریه‌های جدید ریاضی ضروری به‌نظر می‌رسد [۲۴]. در حالت کلی برای آنالیز مشخصات مخفی در سری‌های زمانی باید از تبدیل‌کننده‌های ریاضی استفاده کرد [۲۵].

تبدیل موجک تابعی است که نسخه بهبودیافته تبدیل فوریه را تداعی می‌کند. تبدیل فوریه در آنالیز سیگنال‌های ناپایستا به شکست منجر می‌شود. در حالی که تبدیل موجک اجازه می‌دهد سیگنال‌های ناپایستا نیز به‌خوبی آنالیز شوند [۲۶]. ترکیب موجک با مدل‌های هیبریدی اخیراً به‌عنوان نوعی روش جایگزین در شبیه‌سازی فرایندهای هیدرولوژیکی به‌کار برده می‌شود. در این مدل‌ها، علاوه بر وزن‌ها، موقعیت و مقیاس موجک‌ها نیز بهینه‌سازی می‌شوند [۲۷]. اخیراً تبدیل موجک به‌عنوان نوعی تکنیک پیش‌پردازنده عملکرد بسیارخوبی با توجه به توان خود در آنالیز فرکانس داده‌ها برای مدل‌سازی‌های هیدرولوژیکی از خود نشان داده است [۲۸].

علیزاده و کاویانپور [۲۹] استفاده از مدل ترکیبی WANN را برای پیش‌بینی پارامترهای کیفی در اقیانوس آرام، خلیج Hilo انجام دادند. ترکیب‌های مختلفی از پارامترها به‌عنوان ورودی به مدل برای پیش‌بینی مقدار شوری، دما و DO روزانه و مقادیر ساعتی DO وارد شد. نتایج نشان داد مدل WANN عملکرد بهتری نسبت به مدل ANN دارد.

هدف از این مطالعه، بررسی توانایی مدل ANN به‌منظور پیش‌بینی پارامتر ماهانه BOD براساس داده‌های موجود دما، DO و جریان رودخانه است. با توجه به رفتار دینامیکی سیستم‌های هیدرولوژیکی و به‌منظور افزایش

1. Non Stationary
2. Drift
3. Trend
4. Wavelet Transform



شکل ۱. موقعیت رودخانه کارون در استان خوزستان و ایران

جدول ۱. پارامترهای ماهانه استفاده شده در این تحقیق

نام ایستگاه	کد ایستگاه	متغیر اقلیمی	میانگین	حداکثر	حداقل	طول (درجه، دقیقه، ثانیه)	عرض (درجه، دقیقه، ثانیه)	ارتفاع از سطح دریا (متر)
ملائتی	۲۱-۳۰۷	دما (درجه سانتی گراد)	۲۱/۰۰	۲۵/۰۰	۱۲/۰	۴۸ ۵۲ ۴۰	۳۱ ۳۵ ۰۱	۱۷
ملائتی	۲۱-۳۰۷	اکسیژن محلول (میلی گرم بر لیتر)	۷/۱۹	۹/۷۲	۵/۰	۴۸ ۵۲ ۴۰	۳۱ ۳۵ ۰۱	۱۷
ملائتی	۲۱-۳۰۷	جریان (مترمکعب در ثانیه)	۴۰۳/۰۳	۱۶۲۶/۶۳	۱۱۱/۶	۴۸ ۵۲ ۴۰	۳۱ ۳۵ ۰۱	۱۷
ملائتی	۲۱-۳۰۷	اکسیژن مورد نیاز بیولوژیکی (میلی گرم بر لیتر)	۲/۷۱	۵/۲۲	۱/۱۴	۴۸ ۵۲ ۴۰	۳۱ ۳۵ ۰۱	۱۷

پدیده‌های هیدرولوژیکی را با استفاده از روابط پیچیده ریاضی مدل‌سازی کند [۳۴ و ۳۵]. ساختار شبکه عصبی معمولاً از لایه ورودی، لایه میانی و لایه خروجی تشکیل شده است. لایه ورودی لایه‌ای انتقال‌دهنده و وسیله‌ای برای تهیه کردن داده‌ها، لایه خروجی شامل مقادیر پیش‌بینی شده توسط شبکه و لایه میانی یا مخفی محل پردازش داده‌هاست. هر لایه از چند نرون یا گره تشکیل شده است [۳۶]. سیگنال‌ها با عبور از نرون‌ها به وسیله وزن‌ها و توابع انتقال بهینه یا اصلاح می‌شود. این فرایند تا جایی که لایه خروجی reached شود تکرار می‌شود [۳۷].

شبکه عصبی مصنوعی (ANN)

تئوری مدل‌های شبکه عصبی مصنوعی برای نخستین بار توسط مک کولاج^۱ و والتر پیتز^۲ در سال ۱۹۴۳ مطرح شد [۳۲] و بعد از آن روزنبلات^۳ در سال ۱۹۶۲ ایده پرسپترون را پیشنهاد داد [۳۳]. امروزه شبکه عصبی مصنوعی در مطالعات هیدرولوژی و مدیریت منابع آب کاربرد وسیعی دارد. مدل ANN می‌تواند ارتباط پیچیده و غیرخطی بین

1. McCulloch
2. Walter Pitts
3. Rosenblatt

این کار ابتدا سری‌های زمانی DO, BOD, دما و جریان رودخانه در چند مرحله (تا جایی که بسامد سری داده‌ها از بین برود) به چند زیرسری تجزیه و بعد به‌عنوان ورودی مدل در نظر گرفته شد. هر چه تعداد مراحل منتخب برای تجزیه بیشتر باشد، سیگنال به همان تعداد به بسامدهای بالاگذر و پایین‌گذر تجزیه می‌شود و دقت کار افزایش می‌یابد، اما از مرحله‌ای به بعد مقادیر بسامدها تقریباً ثابت باقی می‌مانند. بعد از تجزیه‌شدن زیرسیگنال‌ها از روش تجزیه و تحلیل مؤلفه‌های اصلی استفاده و زیرسیگنال‌های مهم به‌عنوان ورودی به مدل‌های مختلف استفاده می‌شوند.

تجزیه و تحلیل مؤلفه‌های اصلی (PCA)

تجزیه و تحلیل مؤلفه‌های اصلی (PCA) نوعی تجزیه و تحلیل آماری است که تعداد کمتری از عوامل را به نام مؤلفه‌های اصلی از میان عوامل اولیه گزینش می‌کند، به طوری که تعدادی اطلاعات کم‌اهمیت حذف می‌شود. در صورتی که فاکتور تست KMO^۲ مختص به این روش کمتر از ۰/۵ باشد، داده‌ها برای تجزیه و تحلیل عوامل اصلی مناسب نخواهد بود و اگر مقدار آن بین ۰/۵ تا ۰/۶۹ باشد باید با احتیاط بیشتر به تجزیه و تحلیل عوامل پرداخت. اما در صورتی که مقدار آن بزرگ‌تر از ۰/۷ باشد، همبستگی‌های موجود در بین داده‌ها برای تجزیه و تحلیل مناسب خواهد بود [۴۳].

با استفاده از این روش، ترکیباتی از P متغیر اولیه x_1, x_2, \dots, x_p برای ایجاد حداکثر P مؤلفه مستقل به صورت PC_1, PC_2, \dots, PC_p ایجاد می‌شود [۴۴]. هر یک از مؤلفه‌های اصلی می‌تواند با دنباله ارائه شده در رابطه ۴ مشخص شود.

$$\begin{aligned} PC_1 &= w_{11}x_1 + w_{12}x_2 + \dots + w_{1p}x_p \\ PC_2 &= w_{21}x_1 + w_{22}x_2 + \dots + w_{2p}x_p \\ &\dots \end{aligned} \quad (4)$$

که در آن $PC_p = w_{p1}x_1 + w_{p2}x_2 + \dots + w_{pp}x_p$ معرف مؤلفه مد نظر، w_{ij} ضریب مختص به متغیرهای اولیه و x_i نیز متغیر اولیه است. ضرایب w_{ij} طوری تخمین زده می‌شوند که اولین مؤلفه

برای مطالعه بیشتر به مطالعات آپوستولوفولو و همکارانش [۳۸]، مینسکی و پارپرت [۳۹]، جونز و همکارانش [۴۰] و نورانی و همکارانش [۴۱] مراجعه شود.

تبدیل موجک

به کمیت‌های متغیر در زمان یا مکانی سیگنال گویند که قابل اندازه‌گیری باشد. برای تحلیل سیگنال‌ها، مبدل‌های ریاضی استفاده می‌شود تا بتوان اطلاعاتی را به دست آورد که از سیگنال‌های خام به‌آسانی به دست نمی‌آید. تبدیل موجک یکی از تبدیل‌های ریاضی کارآمد در زمینه پردازش سیگنال است. تبدیل موجک سیگنال را به مجموعه‌ای از توابع اساسی سیگنال تجزیه می‌کند و در حقیقت مجموعه‌ای تابع اساسی از تأخیر و تغییر در مقیاس موجک مادر به دست می‌آید. مزیت مهم تبدیل موجکی این است که اطلاعات زمان و فرکانس را به‌طور مؤثری از سیگنال متغیر در زمان استخراج می‌کند. تابع موجک $\psi(t)$ موجک مادر نامیده می‌شود که سه مشخصه تعداد نوسان محدود، بازگشت سریع به صفر در هر دو جهت مثبت و منفی در دامنه خود و میانگین صفر دارد (این سه ویژگی شرط لازم است که تابعی بتواند به‌عنوان تبدیل موجکی عمل کند) که شرط مقبولیت نامیده می‌شود. تابع موج $\psi(t)$ به شکل ریاضی زیر تعریف می‌شود [۴۲].

$$\int_{-\infty}^{+\infty} \psi(t) d(t) = 0 \quad (2)$$

از انواع موجک‌های مادر که برای آنالیز سیگنال استفاده می‌شوند، می‌توان به موجک Haar, Sym, Morlet, Daubechies (db), Meyer و غیره اشاره کرد $\psi_{(a,b)}(t)$. با استفاده از تأخیر و تغییر مقیاس موجک مادر از فرمول ۳ به دست می‌آید [۴۲].

$$\psi_{(a,b)}(t) = |a|^{-1/2} \psi\left(\frac{t-b}{a}\right), a \in R, b \in R, a \neq 0 \quad (3)$$

تبدیل‌های موجکی به دو دسته پیوسته و گسسته تقسیم می‌شوند. برای کاربردهای عملی، هیدرولوژیست‌ها اغلب سیگنال‌های زمانی پیوسته در اختیار ندارند، بلکه بیشتر سیگنال‌های زمانی گسسته در اختیار آنهاست. اگر انتخاب‌های مقیاس و موقعیت مبنی بر مزیت‌های هر دو (مقیاس‌ها و موقعیت‌های دوتایی) باشد، تحلیل‌ها دقیق خواهد بود. تبدیل موجک گسسته از بانک‌های فیلتر برای بازسازی سطح چندتفکیکی زمان-فرکانس بهره می‌برد. برای

حل رابطه ۱۰ که در آن I ماتریس واحد است، مقادیر ویژه λ_n محاسبه می‌شوند.

$$\det(R - \lambda I) = 0 \quad (10)$$

مقدار واریانس هریک از مؤلفه‌های اصلی با استفاده از رابطه ۱۱ محاسبه می‌شود.

$$\det(R - \lambda I) = V_h \quad (11)$$

ه) تعیین معیار استخراج تعداد عامل‌ها:

معیار مقادیر ویژه ۱ و معیار درصد واریانس و معیار تست بریدگی [۴۶] مهم‌ترین پارامترهای استخراج تعداد عوامل هستند که در این فرایند به کار گرفته می‌شوند. و) اجرای چرخش مناسب روی ماتریس ضرایب مؤلفه‌ها: این مرحله به تجزیه و تحلیل فاکتورهای اصلی ۲ نیز مشهور است. در این مرحله متغیرهایی که ضرایب بالایی در مؤلفه‌های اصلی استخراج شده دارند، به‌عنوان متغیرهای مهم برای ورود به مدل‌سازی انتخاب می‌شوند [۴۷].

ساختارهای مختلف برای مدل‌سازی

برای اجرای مدل ANN با توجه به پارامترهای ورودی هفت نوع معماری مختلف مطابق جدول ۲ بررسی شد. که پارامترهای T_t, DO_t, Q_t, BOD_t به‌ترتیب دما، اکسیژن محلول، جریان و اکسیژن مورد نیاز بیولوژیکی در دوره زمانی ماهانه و $T_{t-1}, T_{t-2}, DO_{t-1}, DO_{t-2}, Q_{t-1}, Q_{t-2}, BOD_{t-1}, BOD_{t-2}$ و به‌ترتیب دما، DO، جریان و BOD در دوره‌های زمانی گذشته و BOD_{t+1} سطح آب زیرزمینی در دوره آتی است.

برای ترکیب ANN با تبدیل موجک الگوی شکل ۲ طراحی شده که چگونگی ورود داده‌ها و خروجی به‌صورت شماتیک در آن نشان داده شده است. پارامترهایی که در شکل دیده می‌شوند عبارت‌اند از:

$Ta(t), DOa(t), Qa(t), BODa(t)$: سیگنال تقریب ۳

داده‌های دما، جریان، DO و BOD است.

$DO_{d1}(t), Q_{d1}(t), P_{d1}(t)$: سیگنال دیتیل

یا جزئیات ۴ در سطح تجزیه ۱ داده‌های دما، جریان، DO و BOD است.

$DO_{di}(t), Q_{di}(t), T_{di}(t)$: سیگنال جزئیات

در سطح تجزیه i داده‌های دما، جریان، DO و BOD است.

حداکثر واریانس داده‌ها را در نظر گرفته و دومین مؤلفه حداکثر واریانس در نظر گرفته نشده توسط اولین مؤلفه را پیش‌بینی می‌کند و این روند ادامه می‌یابد تا آخرین مؤلفه همه واریانس مد نظر را دربرگیرد.

$$w_{i1}^2 + w_{i2}^2 + \dots + w_{ip}^2 = \lambda_i = 1, \dots, p \quad (5)$$

$$w_{i1}w_{j1} + w_{i2}w_{j2} + \dots + w_{ip}w_{jp} = 0 \quad (6)$$

for all $i \neq j$

برای انجام روش تجزیه و تحلیل عوامل اصلی مراحل زیر انجام می‌گیرد:

الف) استاندارد کردن متغیرهای ورودی: در این مرحله داده‌های ورودی به‌گونه‌ای استاندارد می‌شوند که میانگین صفر و انحراف معیار یک داشته باشند. ماتریس Z که شامل مقادیر استاندارد شده پارامترهاست از رابطه ۷ به‌دست می‌آید [۴۵].

$$Z_{ij} = \left(\frac{x_{ij} - \bar{x}_j}{s_j} \right) \text{ for } i = 1, 2, \dots, n \text{ and } j = 1, 2, \dots, q \quad (7)$$

که در این رابطه، \bar{x}_j میانگین داده‌ها و s_j مقدار انحراف معیار است.

ب) محاسبه فاکتور KMO: شاخص KMO استفاده‌شده در دامنه صفر تا یک قرار دارد. این شاخص از رابطه ۸ به دست می‌آید که در این رابطه r_{ij} ضریب همبستگی بین متغیرهای i و j و a_{ij} ضریب همبستگی جزئی بین آنهاست [۴۳].

$$KMO = \frac{\sum \sum r_{ij}^2}{\sum \sum r_{ij}^2 + \sum \sum a_{ij}^2} \quad (8)$$

ج) محاسبه ماتریس همبستگی (کوواریانس) برای متغیرهای اولیه: این ماتریس میزان همبستگی بین هریک از متغیرهای اولیه استفاده‌شده را نشان می‌دهد. مقدار هریک از درایه‌های این ماتریس a_{ij} بیانگر همبستگی بین متغیرهای i و j است که از رابطه ۹ به‌دست می‌آید [۴۵].

$$R = \frac{1}{n} Z Z^T \quad (9)$$

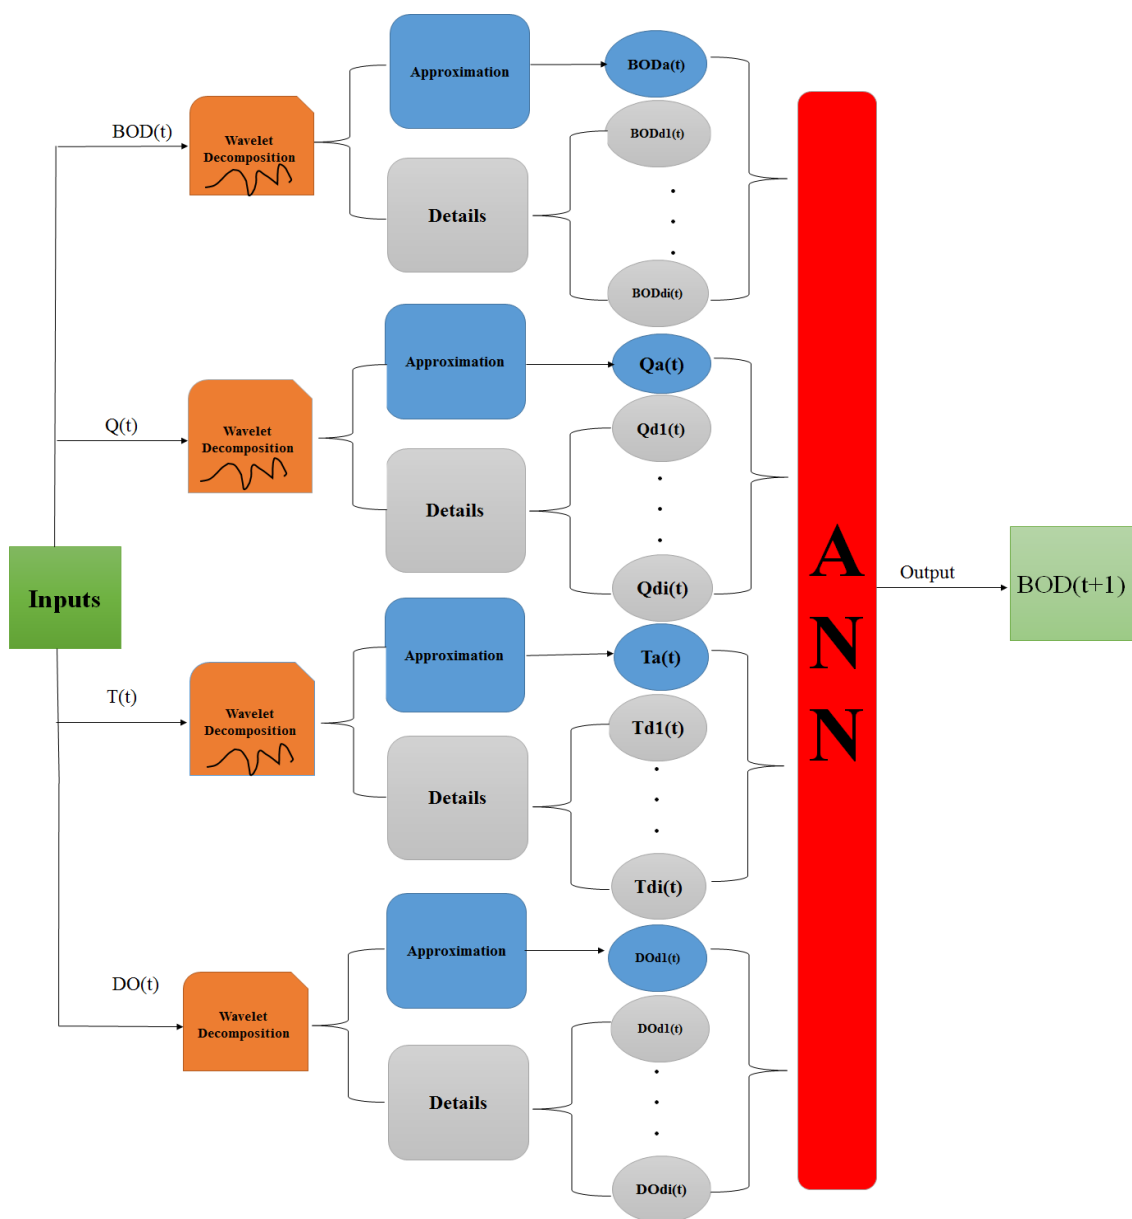
د) محاسبه مقادیر ویژه λ و بردارهای ویژه مربوط به آن از ماتریس همبستگی [۴۵].

با حل رابطه‌های ۱۰ و ۱۱ مقادیر ویژه و بردارهای ویژه معادل هر مقدار ویژه محاسبه می‌شوند. بردارهای ویژه به‌دست‌آمده، به‌ازای هر مقدار ویژه نیز به‌عنوان ضرایب متغیرهای اولیه در تشکیل مؤلفه مربوط به آن هستند. از

1. Eigenvalue criterion
2. Principal Factor Analysis
3. Approximate
4. Detail


جدول ۲. معماری‌های مختلف مدل ANN

معماری	ورودی	خروجی
۱	$BOD_{t-2}, BOD_{t-1}, BOD_t$	BOD_{t+1}
۲	T_{t-2}, T_{t-1}, T_t	BOD_{t+1}
۳	DO_{t-2}, DO_{t-1}, DO_t	BOD_{t+1}
۴	Q_{t-2}, Q_{t-1}, Q_t	BOD_{t+1}
۵	T_t, DO_t, Q_t, BOD_t	BOD_{t+1}
۶	$T_{t-1}, T_t, DO_{t-1}, DO_t, Q_{t-1}, Q_t, BOD_{t-1}, BOD_t$	BOD_{t+1}
۷	$T_{t-2}, T_{t-1}, T_t, DO_{t-2}, DO_{t-1}, DO_t, Q_{t-2}, Q_{t-1}, Q_t, BOD_{t-2}, BOD_{t-1}, BOD_t$	BOD_{t+1}



شکل ۲. نمایش شماتیک مدل WANN

تجزیه شده به عنوان ورودی به مدل ANN وارد شد تا مدل ترکیبی WANN به دست آید. پس از اجرای متعدد این برنامه و در حالت های خاص و مقایسه آنها با یکدیگر نتایج به دست آمد. یکی از نکات مهم و اساسی درباره انتخاب موجک های مادر، طبیعت رخداد پدیده و نوع سری زمانی آن است. بنابراین، الگویی هایی از توابع موجک مادر که بتواند به لحاظ شکل هندسی به خوبی بر منحنی سری زمانی منطبق شوند بهتر می توانند عمل نگاشت را انجام دهند و نتایج نیز بهتر خواهند بود. در این تحقیق با توجه به آزمایش موجک های مادر مختلف و توجه به نکته گفته شده چهار تابع موجک زیر انتخاب شدند (شکل ۳).



شکل ۳. الف) تابع موجک db7؛ ب) تابع موجک sym4؛ ج) تابع موجک db2؛ د) تابع موجک Haar

پارامتر از جمله نوع تابع موجک، توابع انتقال، قوانین آموزش، توابع عضویت و درجه تجزیه موجک روی عملکرد مدل ها از این عامل استفاده شده است. همچنین پارامتر RMSE جذر میانگین مربع خطاهای داده های محاسباتی و مشاهداتی را بیان می کند. واضح است که هر چه مقدار این عدد کمتر باشد، آموزش و شبیه سازی داده ها بهتر صورت گرفته است. درباره AIC معیار آکائیک نیز می توان گفت که هر چه ضریب آکائیک مختص به مدل کمتر باشد، آن مدل عملکرد بهتری دارد. کم تر بودن ضریب آکائیک از دو عامل خطای مدل و تعداد پارامترها ناشی می شود، پس معیار خوبی برای بررسی مدل هاست.

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

$$R^2 = 1 - \frac{\sum_{i=1}^N (T_o - T)^2}{\sum_{i=1}^N (T_o - \bar{T})^2} \quad (14)$$

$$AIC = m \times \ln(RMSE) + 2(Npar) \quad (15)$$

تعداد گره های لایه ورودی به درجه تجزیه وابسته است. همان طور که در شکل ۲ دیده می شود تعداد گره های ورودی برای شبکه برابر "m(i+1)" است که i درجه تجزیه موجک و m تعداد پارامترهای ورودی است. به طور مثال، برای سطح تجزیه ۱ در این تحقیق چون m برابر ۴ است (دما، جریان، DO و BOD) تعداد گره های ورودی برابر ۸ است. خروجی اکسیژن مورد نیاز بیولوژیکی، BOD_{t+1} است. بنابراین، لایه خروجی یک نرون دارد.

برای دستیابی به نتایج مدل ترکیبی WANN برای مدل سازی ابتدا با استفاده از تبدیل موجک پارامترهای ورودی به زیرسیگنال هایی تجزیه شده سپس زیرسیگنال های

برای به دست آوردن درجه تجزیه مناسب برای توابع موجک، رابطه پیشنهادی زیر ارائه شد.

$$L = \text{Int} \left[\log(N) \right] \quad (12)$$

در این رابطه L درجه تجزیه پیشنهادی و N تعداد سری زمانی اعداد است [۴۸]. در این پژوهش با $N=156$ ، $L=2$ است که برای دقت بیشتر، درجات تجزیه ۱ تا ۳ بررسی شد.

معیارهای ارزیابی مدل

با توجه به اینکه در ارزیابی عملکرد مدل در پیش بینی نتایج باید پارامترهای کمی و کیفی مختلفی بررسی شود تا میزان تأثیرگذاری هر پارامتر ورودی روی نتایج به وضوح مشاهده شود، از پارامترهای زیر در ارزیابی کارایی روش ها استفاده شده است.

ضریب R^2 میزان انطباق داده هایی که توسط مدل به وجود می آیند و داده های واقعی را نشان می دهند و هر چقدر این ضریب به عدد یک نزدیک تر باشد، بیانگر آن است که این انطباق بهتر صورت گرفته و میزان خطای آن کمتر است. بنابراین، در همه حالات برای بررسی میزان تأثیرگذاری هر

از تک تک پارامترها استفاده شده بود. به همین دلیل در معماری‌های ۶ و ۷ باز از همه پارامترها ولی با زمان تأخیرهای یک و دو ماهه استفاده شد تا بتوان مقایسه بهتری برای دستیابی به معماری و ساختار برتر به دست آورد.

در معماری ۶ از همه پارامترها با یک زمان تأخیر استفاده شد. در این معماری، ساختاری که از تابع انتقال Tansig و قوانین آموزش LM استفاده شده بود با ضریب همبستگی ۰/۸۷۲ و جذر میانگین مربعات خطای شبیه‌سازی ۰/۰۴۱۲ بهترین عملکرد را داشت. در معماری ۷ از همه پارامترها با دو زمان تأخیر استفاده شد. در این معماری، ساختاری که از تابع انتقال Satlin و قوانین آموزش LM استفاده شده بود با ضریب همبستگی ۰/۸۶۷ و جذر میانگین مربعات خطای شبیه‌سازی ۰/۰۴۰۶ بهترین عملکرد را داشت. در جدول ۳ بهترین نتیجه هریک از معماری‌های هفت‌گانه ارائه شده است. براساس این جدول معماری ۶ بهترین عملکرد برای مدل ANN را داشته است و بعد از آن معماری ۷ نتیجه بهتری داشته یعنی افزایش تعداد تأخیرهای زمانی بیشتر از یک گام سبب کاهش عملکرد مدل شده است.

شکل ۴ مقایسه مقادیر مشاهداتی را با مقادیر برآوردی برای ساختار برتر روش ANN در مرحله تست نشان می‌دهند. با توجه به این شکل عملکرد مدل در مرحله تست تقریباً مناسب بوده است.

N تعداد داده‌ها؛ T_0 داده‌های مشاهداتی؛ \bar{T} میانگین داده‌های مشاهداتی؛ T_i داده‌های محاسباتی؛ m تعداد پارامترها؛ Npar تعداد داده‌های آموزش دیده است.

نتایج و بحث

ساختارهای مختلف در هریک از معماری‌های مختلف مدل ANN به این صورت که هر یک از ساختارها با توابع انتقال، قوانین آموزش، تعداد نرون‌های لایه‌های میانی، لایه‌های میانی و تعداد تکرارهای مختلف بررسی شد. نتایج بررسی معماری‌ها، به خصوص معماری ۱ که فقط از داده‌های BOD استفاده شده است، نشان داد بهترین عملکرد مختص به تابع انتقال Tansig و قوانین آموزش LM با ضریب همبستگی ۰/۷۵۰ و جذر میانگین مربعات خطای ۰/۰۵۹۶ است (جدول ۳).


در معماری‌های ۲ و ۳ که به ترتیب از داده‌های دما و DO استفاده شده است عملکرد مدل با توجه به ضریب همبستگی و جذر میانگین مربعات به دست آمده ضعیف بوده است. در معماری ۴ هم که از داده‌های جریان استفاده شد عملکرد مدل باز ضعیف بود و نشان می‌داد فقط استفاده از پارامترهای DO، BOD، و یا جریان به هیچ وجه مناسب نیست و در نتیجه باید از معماری‌هایی استفاده کرد که ترکیبی از پارامترهای یاد شده هستند.

در معماری ۵ که از داده‌های دما، جریان، DO و BOD استفاده شده است عملکرد مدل نسبت به زمانی بهتر شد که

جدول ۳. بهترین ساختار مدل ANN

معمار ی	قوانین آموزش	توابع انتقال	بهترین ساختار	تعداد تکرار	ضریب همبستگی		جذر میانگین مربعات خطا	
					تست	آموزش	تست	آموزش
۱	LM*	Tansig*	۳-۴-۱	۱۰۰	۰/۹۲۸	۰/۷۵۰	۰/۰۳۹۵	۰/۰۵۹۶
۲	LM	Tansig	۳-۴-۱	۳۵۶	۰/۷۴۷	۰/۴۱۱	۰/۰۷۱۲	۰/۰۹۵۵
۳	LM	Satlin	۳-۳-۱	۱۰۰۰	۰/۸۸۲	۰/۶۶۶	۰/۰۵۱۵	۰/۰۶۷۶
۴	LM	Satlins	۳-۴-۱	۱۳۴	۰/۸۴۰	۰/۷۱۱	۰/۰۵۷۰	۰/۰۶۱۳
۵	LM	Tansig	۴-۳-۱	۴۵۰	۰/۹۰۶	۰/۷۹۸	۰/۰۴۴۶	۰/۰۵۱۶
۶	LM	Tansig	۸-۳-۱	۱۰۰۰	۰/۹۴۵	۰/۸۷۲	۰/۰۳۴۴	۰/۰۴۱۲
۷	LM	Satlin	۱۲-۳-۱	۷۸۰	۰/۹۴۸	۰/۸۶۶	۰/۰۳۳۴	۰/۰۴۳۹

*LM=Levenberg-Marquardt•Tansig=Hyperbolic Tangent Sigmoid•Satlin=Saturating Linear•Satlins= Symmetric Saturating Linear



شکل ۴. مقایسه نتایج مدل ANN با مقادیر مشاهده‌ای، مرحله تست

درصد پراکندگی از متغیرهای اولیه ارائه شده است که توسط هر مؤلفه نشان می‌شود. همان طور که مشاهده می‌شود ۹ مؤلفه اول نزدیک به ۹۷ درصد کل پراکندگی و اطلاعات متغیرهای اصلی را بیان می‌کنند؛ در حالی که ۱۲ مؤلفه اول حدود ۹۹ درصد کل پراکندگی و اطلاعات متغیرهای اصلی را بیان می‌کنند. با توجه به اینکه با افزایش تعداد مؤلفه‌های ورودی از ۱۰ به بالا تأثیر زیادی بر درصد کل پراکندگی و اطلاعات متغیرهای اصلی نشان نمی‌دهد، تصمیم بر استفاده از ۱۰ مؤلفه اول در این مطالعه برای دوره ماهانه گرفته شد. در شکل ۵ هم مقادیر ویژه و درصد واریانس هریک از آنها به صورت نموداری نشان داده شده است که نتایج یادشده را تأیید می‌کند.

جدول ۴. مقدار آماره آزمون در روش PCA

Kaiser-Meyer-Olkin Measure of Sampling Adequacy.	۰/۷۰۱
Approx. Chi-Square	۲۵۸/۰۱۹
Bartlett's Test of Sphericity	Df ۱۲۰
	Sig. ۰/۰۰۰

همان طور که از بررسی معیارهای ارزیابی برای بهترین ساختار هریک از معماری‌های هفت‌گانه مشخص شد تابع انتقال، نوع Tansig و قانون آموزش نوع LM بهترین عملکرد را داشته است.


نتایج مختص به روش PCA

بعد از استفاده از تبدیل موجک، چون تعداد زیرسیگنال‌های زیادی با توجه به نوع تابع موجک و سطح تجزیه به‌دست آمد، زیرسیگنال‌های مهم به کمک روش PCA تعیین شد. با توجه به به‌دست‌آمدن مقدار KMO برابر ۰/۷۰۱ (جدول ۴)، امکان استفاده از PCA بر متغیرهای استفاده‌شده قابل تأیید است. برای اجرای PCA پس از استاندارد کردن متغیرهای ورودی، ماتریس متقارن همبستگی R از مرتبه ۱۶ (معادل با بیشترین تعداد ورودی‌ها در دوره ماهانه) تشکیل شد.

۱۶ مقدار ویژه و به‌ازای هر مقدار ویژه ۱۶ بردار ویژه و با استفاده از آنها ۱۶ مؤلفه یعنی به تعداد متغیرهای ورودی به‌دست آمد. مشخصات این مؤلفه‌ها در جدول ۵ ارائه شده است. در جدول ۵ اطلاعات ارزش هر مؤلفه و

جدول ۵. درصد اطلاعاتی از متغیرهای اولیه که توسط هر مؤلفه بیان می‌شود

مؤلفه	مقدار ویژه	واریانس (%)	واریانس تجمعی (%)
۱	۱/۰۸۸۹۱۴	۲۹/۶۹۸۲۷	۲۹/۶۹۸۲۷
۲	۰/۸۰۷۵۴۵	۱۶/۹۵۶۸۹	۴۶/۶۵۵۱۶
۳	۰/۵۰۰۵۴۶	۱۳/۳۸۲۰۹	۶۰/۰۳۷۲۵
۴	۰/۳۱۵۱۱۷	۱۰/۵۲۷۹۵	۷۰/۵۶۵۲
۵	۰/۲۰۱۰۳۶	۶/۷۱۶۵۱۹	۷۷/۲۸۱۷۲
۶	۰/۱۷۷۲۸۷	۵/۹۲۳۰۸۵	۸۳/۲۰۴۸۱
۷	۰/۱۵۷۷۸۱	۵/۲۷۱۴	۸۸/۴۷۶۲۱
۸	۰/۱۵۵۷۸۴	۵/۲۰۴۶۶۹	۹۳/۶۸۰۸۷
۹	۰/۱۰۸۴۲۹	۳/۶۲۲۵۷۱	۹۷/۳۰۳۴۵
۱۰	۰/۰۵۳۷۰۱	۱/۷۹۴۱۳۹	۹۹/۰۹۷۵۸
۱۱	۰/۰۱۰۸۷۱	۰/۳۶۳۱۸۶	۹۹/۴۶۰۷۷
۱۲	۰/۰۰۶۰۴۳	۰/۲۰۱۹۰۸	۹۹/۶۶۲۶۸
۱۳	۰/۰۰۴۱۳۸	۰/۱۳۸۲۵۲	۹۹/۸۰۰۹۳
۱۴	۰/۰۰۲۳۶۱	۰/۰۷۸۸۶۷	۹۹/۸۷۹۸
۱۵	۰/۰۰۲۰۹۷	۰/۰۷۰۰۴۵	۹۹/۹۴۹۸۴
۱۶	۰/۰۰۱۵۰۱	۰/۰۵۰۱۵۸	۱۰۰



شکل ۵. نمودار پراکنندگی و مقادیر ویژه در مقابل تعداد مؤلفه‌ها و واریانس (دوره ماهانه)

شود. در این مدل‌سازی علاوه بر بررسی توابع موجک مختلف، بهترین حالت برای پارامترهای مورد نیاز در مدل (مانند تعداد نرون‌ها، توابع انتقال، توابع آموزش و...) نیز انتخاب شد تا بهترین عملکرد مدل ترکیبی به دست آید. نتایج به دست آمده از مدل‌سازی با مدل ترکیبی WANN به‌ازای توابع موجک مختلف برای درجه

در مدل ترکیبی سیگنال‌های اصلی پارامترهای ورودی با استفاده از تبدیل موجک به زیرسیگنال‌هایی تجزیه شده است. این زیرسیگنال‌ها توسط کدنویسی در نرم‌افزار متلب به عدد تبدیل شد و بعد از تجزیه و تحلیل مؤلفه‌های اصلی (PCA) به‌عنوان ورودی به مدل ANN استفاده شد تا مدل ترکیبی شبکه عصبی مصنوعی- موجک (WANN) ایجاد

نتایج مدل سازی این ساختار برتر برای مرحله تست در شکل ۶ ارائه شده است. با بررسی شکل ۶ این نتیجه به دست می آید که عملکرد مدل در مرحله تست مناسب است و از این مدل می توان برای پیش بینی مقادیر آتی استفاده کرد.

تجزیه های مختلف در جدول ۶ ارائه شده است. با توجه به جدول ۶ مشاهده می شود که درجه تجزیه ۲ دارای بهترین عملکرد بوده است. در این ساختار برتر از تابع انتقال Tansig، قانون آموزش LM با ضریب همبستگی ۰/۹۴۶ و جذر میانگین مربعات خطای شبیه سازی ۰/۰۲۷۳ استفاده شده است.

جدول ۶. نتایج مدل WANN به ازای توابع موجک و درجات تجزیه مختلف

تابع موجک	درجه تجزیه	قوانین آموزش	توابع انتقال	بهترین ساختار	ضریب همبستگی		جذر میانگین مربعات خطا	
					تست	آموزش	تست	آموزش
	۱	*LM	*Satlins	۴-۴-۱	۰/۹۶۰	۰/۹۱۲	۰/۰۳۴۲	۰/۰۳۰۴
*Db2	۲	LM	Tansig	۵-۳-۱	۰/۹۵۳	۰/۹۴۶	۰/۰۲۷۳	۰/۰۳۱۹
	۳	BFGS Q-N	Satlins	۶-۴-۱	۰/۹۵۶	۰/۹۲۳	۰/۰۳۲۹	۰/۰۳۱۰
	۱	LM	Satlins	۴-۳-۱	۰/۹۵۴	۰/۹۱۶	۰/۰۳۳۹	۰/۰۳۱۶
Db7	۲	LM	Tansig	۵-۳-۱	۰/۹۷۲	۰/۹۴۲	۰/۰۲۸۱	۰/۰۲۴۹
	۳	LM	Tansig	۶-۵-۱	۰/۹۵۹	۰/۹۲۳	۰/۰۳۳۸	۰/۰۲۹۸
	۱	BFGS Q-N	Satlin	۴-۴-۱	۰/۹۶۶	۰/۹۱۹	۰/۰۳۳۲	۰/۰۲۷۱
Sym4	۲	LM	Tansig	۵-۴-۱	۰/۹۶۵	۰/۹۳۳	۰/۰۳۵۰	۰/۰۲۷۶
	۳	BFGS Q-N	Satlin	۶-۴-۱	۰/۹۶۱	۰/۹۲۵	۰/۰۳۱۷	۰/۰۲۹۲
	۱	LM	Satlin	۴-۳-۱	۰/۹۶۷	۰/۹۱۲	۰/۰۳۵۷	۰/۰۲۸۰
Haar	۲	LM	Satlins	۵-۳-۱	۰/۹۶۵	۰/۹۳۶	۰/۰۲۹۶	۰/۰۲۷۶
	۳	LM	Satlins	۶-۶-۱	۰/۹۶۳	۰/۹۱۷	۰/۰۳۳۴	۰/۰۲۸۳

* Satlins= Symmetric Saturating Linear, Satlin= Saturating Linear, Tansig= Hyperbolic Tangent Sigmoid, LM= Levenberg-Marquardt, BFGS Q-N= BFGS Quasi-Newton, Db= Daubechies, Sym= Symlet.



شکل ۶. مقایسه نتایج مدل WANN با مقادیر مشاهده ای، مرحله تست


با بررسی ساختارهای برتر دو مدل ANN و WANN مشخص می‌شود که مدل ترکیبی WANN عملکرد بهتری دارد و از نظر بررسی همه معیارهای ارزیابی نسبت به ANN دارای عملکرد بهتری است.

با توجه به شکل ۷ که مقایسه این دو مدل را نشان می‌دهد، مشخص است که WANN مدل برتر است. بنابراین، مدل ترکیبی نسبت به مدل ANN بهتر است چون پیش از ورود داده‌ها به مدل روی داده‌ها پردازش صورت می‌گیرد و داده‌ها دسته‌بندی و با فرکانس‌های مختلف وارد مدل ANN می‌شوند. این موضوع را می‌توان از روی مقایسه مقادیری که برای ضریب همبستگی چه در مرحله آموزش و چه در مرحله شبیه‌سازی داده‌ها به دست می‌آید برای روش‌های یادشده یافت.

جدول ۷ مقایسه نتایج مدل‌های استفاده‌شده در این تحقیق را براساس معیارهای ارزیابی مختلف نشان می‌دهد.

با توجه به جدول ۶ در همه سطوح تجزیه، برای مدل WANN تابع موجک Db2 عملکرد بهتری دارد و به‌عنوان موجک‌های برتر شناخته می‌شود.

نکته مهمی که باید بدان توجه داشت اینکه در روش ترکیبی، استفاده از درجات تجزیه بالای سری زمانی BOD تأثیر چندانی در نتایج مطلوب نشان نمی‌دهد و فقط زمان اجرای برنامه را طولانی‌تر می‌سازد. دلیل این امر در ماهیت پدیده BOD است. با توجه به جدول‌ها و نتایج آنها مشخص شد که تجزیه مرتبه بالا اگرچه دقت محاسبات در آموزش شبکه را زیاد می‌کند، نتیجه معکوس روی نتایج داده‌های شبیه‌سازی شده دارد. بنابراین، نیاز به استفاده از درجات بالای تجزیه نیست زیرا فرکانس‌های BOD در مقیاس زمانی معین ماهانه، فصلی است که با انتخاب بیشترین درجه تجزیه ۳ این مهم به دست می‌آید.



شکل ۷. مقایسه عملکرد مدل‌های ANN و WANN با مقادیر مشاهده‌ای


جدول ۷. مقایسه مدل‌های استفاده‌شده در این تحقیق

مدل	ضریب همبستگی		جذر میانگین مربعات خطا		معیار آکائیک	
	آموزش	تست	آموزش	تست	آموزش	تست
ANN	۰/۹۴۸	۰/۸۷۲	۰/۰۳۴۴	۰/۰۴۱۲	۲۰۳/۰۴	۵۰/۴۸
WANN	۰/۹۵۳	۰/۹۴۶	۰/۰۳۱۹	۰/۰۲۷۳	۱۸۸/۶۴	۳۲/۸۰

با بررسی ساختارهای مختلف مشخص شد که از بین توابع انتقال، نوع Tansig، Satlins و Satlin و از بین قوانین آموزش نوع LM بهترین عملکرد را داشته‌اند.

پیش‌بینی BOD برای یک دوره شش‌ماهه با مدل برتر پس از بررسی مدل‌های مختلف مشخص شد که مدل ترکیبی WANN مدل برتر است، به همین دلیل با تعیین بهینه پارامترهای این مدل به پیش‌بینی BOD اقدام شد. نتایج پیش‌بینی BOD از فروردین تا شهریور ۱۳۹۴ در شکل ۸ ارائه شده است. برای بررسی روند تغییر BOD در شکل ۸ مقادیر BOD از فروردین ۱۳۹۳ به بعد آورده شده است.

با توجه به جدول ۷ عملکرد مدل ترکیبی نسبت به شبکه عصبی مصنوعی بهتر بوده است. به طوری که استفاده از مدل ترکیبی سبب بهبود ضریب همبستگی به میزان ۷ درصد شده است. همچنین با توجه به پارامتر جذر میانگین مربعات خطا نیز مشاهده می‌شود که مدل ترکیبی WANN میانگین مربعات خطای شبیه‌سازی کمتر و در نتیجه عملکرد بهتری داشته است. براساس معیار آکائیک که در آن هر مدلی که معیار آکائیک کمتری داشته باشد مدل برتر شناخته می‌شود بنابراین براساس این معیار مشاهده می‌شود که باز مدل ترکیبی WANN معیار آکائیک کمتری دارد و به‌عنوان مدل برتر شناخته می‌شود.



شکل ۸. بررسی روند BOD (از فروردین ۱۳۹۲ تا شهریور ۱۳۹۴)

نتیجه‌گیری

در این تحقیق از مدل شبکه عصبی مصنوعی برای پیش‌بینی BOD در رودخانه کارون در دوره زمانی ماهانه استفاده شد. بعد از استفاده از تبدیل موجک و تجزیه سیگنال اصلی به زیرسیگنال‌هایی از آنها به‌عنوان ورودی به مدل شبکه عصبی مصنوعی استفاده شد تا مدل ترکیبی به‌دست آید. در این تحقیق نتایج بیانگر عملکرد بهتر دو تابع موجک Db7 و Db2 نسبت به دیگر توابع موجک هستند.

ضریب تعیین (R^2) برای داده‌های آموزشی و شبیه‌سازی در مدل ترکیبی (WANN) نسبت به مدل غیرخطی (ANN) بیشتر است که دقت روش ترکیبی را نشان می‌دهد.

بررسی شکل ۸ نشان می‌دهد که مقدار BOD در فصول پاییز و زمستان نوسانات بیشتری نسبت به فصول بهار و تابستان دارد. دلیل این امر را شاید بتوان بارندگی و تغییرات دبی رودخانه در این فصول دانست. شایان یادآوری است که وجود آلاینده‌های متعدد کشاورزی، شهری و صنعتی نیز بر مقدار BOD تأثیر گذارند، اما به‌علت ثابت بودن تقریبی آنها در این فصول، نمی‌تواند دلیل این نوسانات باشد.

در پایان نتایج این تحقیق با نتایج [۲۸، ۴۸ و ۴۹] و [۲۹] منطبق است مبنی بر اینکه استفاده از مدل‌های ترکیبی با موجک عملکرد بهتری نسبت به استفاده از آن مدل‌ها به‌صورت منفرد دارد.

- [8]. Xiang SL, Liu ZM, Ma LP. Study of multivariate linear regression analysis model for ground water quality prediction. *Guizhou Sci.* 2006;24:60-2.
- [9]. Wu HJ, Lin ZY, Guo SL. The application of artificial neural networks in the resources and environment. *Resour Environ Yangtze Basin* 2000;9:237-241.
- [10]. Cobaner M, Unal B, Kisi Ö. Suspended sediment concentration estimation by an adaptive neuro-fuzzy and neural network approaches using hydrometeorological data. *Journal of Hydrology.* 2009;367:52-61.
- [11]. Kişi Ö. Evolutionary fuzzy models for river suspended sediment concentration estimation. *Journal of Hydrology.* 2009;372(1-4):68-79.
- [12]. Ahmed AAM, Shah MA. Application of adaptive neuro-fuzzy inference system (ANFIS) to estimate the biochemical oxygen demand (BOD) of Surma River. *Journal of King Saud University - Engineering Sciences.* 2015:1-7.
- [13]. Sarkara A, Pandey P. River Water Quality Modelling using Artificial Neural Network Technique. *Aquatic Procedia* 2015;4:1070-1077.
- [14]. Safavi HR. Prediction of River Water Quality by Adaptive Neuro Fuzzy Inference System (ANFIS). *Journal of Environmental Studies* 2010;36(53):1-10.
- [15]. Christos S A, Papaspyros. J.N.E., Tsihrintzis VA. An artificial neural network model and design equations for BOD and COD removal prediction in horizontal subsurface flow constructed wetlands. *Chemical Engineering Journal.* 2008;143(1-3):96-110.
- [16]. Najah A, Elshafie A, Karim O, Jaffar O. Prediction of Johor river water quality parameters using artificial neural networks. *European Journal of Scientific Research* 2009;28(3):422-435.
- [17]. Asadollahfardi G, Taklify. A, Ghanbari A. Application of Artificial Neural Network to Predict TDS in Talkheh Rud River. *Journal of Irrigation and Drainage Engineering (ASCE).* 2012;138(4):363-370.
- [18]. Wen X, Fang J, Diao M, Zhang C. Artificial neural network modeling of dissolved oxygen in the Heihe River, Northwestern China. *Environmental monitoring and assessment* 2013;185(5):4361-4371.
- [19]. Parmar KS, Bhardwaj R. Wavelet and statistical analysis of river water quality parameters. *Applied Mathematics and Computation.* 2013;219:10172-10182.

با توجه به اینکه آنالیز موجک سری‌های زمانی را به چندین زیرسری تقسیم می‌کند و این زیرسری‌ها وارد شبکه عصبی مصنوعی می‌شوند، این پیش‌پردازش روی داده‌ها سبب می‌شود که شبکه عصبی مصنوعی - موجکی با تعداد تکرار کم و در مدت زمان کمتری به نتایج خوبی دست یابد. مقایسه نتایج مدل‌سازی ماهانه بیانگر آن است که با وجود مناسب بودن مدل شبکه عصبی مصنوعی، استفاده از تبدیل موجک سبب افزایش ۷ درصدی عملکرد شده است. بررسی ساختارهای مختلف و آنالیز حساسیت نشان داد از بین پارامترهای استفاده شده در این تحقیق پارامتر BOD بیشترین اهمیت و سپس پارامترهای جریان، DO و دما در مرحله بعدی اهمیت قرار دارند. یعنی BOD بیشترین تأثیر و دما کمترین تأثیر را دارند.

منابع

- [1]. Farhadian M, Haddad O, Seifollahi-Aghmiuni S, Loáiciga H. Assimilative Capacity and Flow Dilution for Water Quality Protection in Rivers. *Journal of Hazardous, Toxic, and Radioactive Waste (ASCE).* 2014;19(2):04014027-1-8.
- [2]. Dogan E, lent Sengorur B, Koklu R. Modeling biological oxygen demand of the Melen River in Turkey using an artificial neural network technique. *Journal of Environmental Management.* 2009;90:1219-35.
- [3]. Chapman D. *Water Quality Assessments.* ed f, editor. London: Chapman and Hall Ltd; 1992.
- [4]. Radwan M, Willems P, El-Sadek A, Berlamont J. Modelling of dissolved oxygen and biochemical oxygen demand in river water using a detailed and simplified model. *Int J River Basin Manage.* 2003;1(2):97-103.
- [5]. Lopes JF, Dias JM, Cardoso AC, Silva CIV. The water quality of the Ria de Aveiro lagoon, Portugal: from the observations to the implementation of a numerical model. *Mar Environ Res* 2005;60:594-628.
- [6]. Delzer GC, McKenzie SW. *Five-Day Biochemical Oxygen Demand.* Edition T, editor. USGS TWRI Book9-A7 U.S. Geological Survey TWRI Book; 1999.
- [7]. Suen JP, Eheart JW, Asce M. Evaluation of neural networks for modelling nitrate concentration in rivers. *Journal Water Resources Planning Management.* 2003;129:505-10.

- [20]. Jouanneau S, Recoules L, Durand MJ, Boukabache A, Picot V, Primault Y, et al. Methods for assessing biochemical oxygen demand (BOD): A review. *Water Research*. 2014;49:62-82.
- [21]. Liang S, Han S, Sun Z. Parameter optimization method for the water quality dynamic model based on data-driven theory. *Marine Pollution Bulletin*. 2015;98(1-2):137-147.
- [22]. Olyaie E, Banejad H, Samadi MT, AR Rahmani AR, and Saghi MH. Performance Evaluation of Artificial Neural Networks for Predicting Rivers Water Quality Indices (BOD and DO) in Hamadan Morad Beik River. *water and soil science*. 2010;20.1(3):200-210.
- [23]. Bierkens MFB. Modeling water table fluctuations by means of a stochastic differential equation. *Journal of Water Resources Research*. 1988;34(10):2485-2499.
- [24]. Shafaei M, Fakheri Fard A, Darbandi S, and Ghorbani M. Prediction Daily Flow of Vanyar Station Using ANN and Wavelet Hybrid Procedure. *Journal of Irrigation & Water Engineering*. 2014;4(24):113-29.
- [25]. Polikar R. *Fundamental Concept and an Overview of the Wavelet Theory* Wavelet Tutorial Rowan university: Glassbord, NJ.08028; 1996.
- [26]. Sifuzzaman M, Islam MR, and Ali MZ. Application of Wavelet Transform and its advantages Compared to Fourier Transform. *Journal of Physical Sciences*. 2009;13:121-134.
- [27]. Thuillard M. A review of wavelet networks, wavelets, fuzzy wavelets and their application. *ESITin: Presented in Conference*,. 2000.
- [28]. Okkan U. Wavelet neural network model for reservoir inflow prediction. *Scientia Iranica*. 2012;19(6):1445-1455.
- [29]. Alizadeh MJ, Kavianpour MR. Development of wavelet-ANN models to predict water quality parameters in Hilo Bay, Pacific Ocean. *Marine Pollution Bulletin*. 2015;98(1-2):171-178.
- [30]. Riad S, Mania J, Bouchaou L, Najjar Y. Rainfall-runoff model using an artificial neural network approach. *Mathematical and Computer Modelling*. 2004;40(7-8):839-846.
- [31]. Solgi A. Stream flow forecasting using combined Neural Network Wavelet model and comparison with Adaptive Neuro Fuzzy Inference System and Artificial Neural Network methods (Case Study: Gamasyab River, Nahavand). [Persian]. IRAN: Shahid Chamran University of Ahvaz, Iran.; 2014.
- [32]. McCulloch WS, Pitts W. A logic calculus of the ideas imminent in nervous activity. *Bull Math Biophys*. 1943;5:115-33.
- [33]. Rosenblatt F. *Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanics*. Spartan 1962.
- [34]. Gallant SI. *Neural Network Learning and Expert Systems: The MIT press*; 1993.
- [35]. Smith M. *Neural Networks for Statistical Modelling*. Van Nostrand Reinhold. 1994. 235p.
- [36]. Singh KP, Basant A, Malik A, Jain G. Artificial neural network modeling of the river water quality-A case study. *Ecological Modelling* 2009;220:888-895.
- [37]. Govindaraju RS. *Artificial Neural Networks in Hydrology. II: Hydrologic Applications*. *Journal of Hydrologic Engineering*. 2000;5(2):124-137.
- [38]. Apostolopoulou MS, Sotiropoulos DG, Livieris IE, Pintelas P. A memoryless BFGS neural network training algorithm. *7th IEEE International Conference on*. 2009:216 - 221.
- [39]. Minsky M, Papert S. *Perceptrons*. Cambridge: MIT Press.; 1969.
- [40]. Jones AJ, Tsui A, de Oliveira AG. Neural models of arbitrary chaotic systems: construction and the role of time delayed feedback in control and synchronization.. *Complex Int* 2002;9:1-9.
- [41]. Nourani V, Kisi Ö, Komasi M. Two hybrid Artificial Intelligence approaches for modeling rainfall-runoff process. *Journal of Hydrology* 2011;402:41-59.
- [42]. Mallat SG. *A wavelet tour of signal processing*. 2, editor: San Diego; 1998. 557 p.
- [43]. Huetcheson G, and Nick S. *The multivariate social scientist: Introductory statistics using generalized linear models*. Thousand Oaks, CA, Sage Publications. 1999.
- [44]. Johnson RA, and Wichern DW. *Applied multivariate statistical analysis* 3rd Ed, editor. Englewood Cliffs, SA 1982. 590 p.
- [45]. Caliendo C, Parisi A. Principal component analysis applied to crash data on multilane roads. *Third international SIIV Congress*; 20-22 September; Bari, Italy: ANCONA SIIV 2005. p. 1-7.
- [46]. Cattell RB. The scree test for the number of the factor. *Multivariate Behavioral Research*. 1996;1(2):245-76.

- [47]. Singh KP, Malik A, Mohan D, Sinha S. Multivariate statistical techniques for the evaluation of spatial and temporal variations in water quality of Gomti River (India) a case study. *Water Research*. 2004;38(18):3980-3992.
- [48]. Nourani V, Komasi M, Mano A. A Multivariate ANN-Wavelet Approach for Rainfall-Runoff Modeling. *Water Resour Manage* 2009;23:2877-2894.
- [49]. Solgi A, Nourani V, Pourhaghi A. Forecasting Daily Precipitation Using Hybrid Model of Wavelet-Artificial Neural Network and Comparison with Adaptive Neuro Fuzzy Inference System (Case Study: Varayneh Station, Nahavand). *Advances in Civil Engineering*. 2014;2014:1-12.