



بخش از دور

GIS ایران



سنجش از دور و GIS ایران  
Iranian Remote Sensing & GIS

سال دهم، شماره اول، بهار ۱۳۹۷  
Vol.10, No. 1, Spring 2018

۹۱-۱۰۸

## تخمین کدورت و غلظت کلروفیل-آ در بخش جنوبی دریای خزر، از طریق آنالیز چندزمانه تصاویر ماهواره‌ای مادیس مبتنی بر شبکه‌های عصبی موجکی

ملیکا حق پرست<sup>۱\*</sup> و مهدی مختارزاده<sup>۲</sup>

۱. دانشجوی کارشناسی ارشد، گروه سنجش از دور، دانشگاه صنعتی خواجه نصیرالدین طوسی

۲. دانشیار گروه فتوگرامتری و سنجش از دور، دانشگاه صنعتی خواجه نصیرالدین طوسی

تاریخ پذیرش مقاله: ۱۳۹۶/۱۱/۲۵

تاریخ دریافت مقاله: ۱۳۹۶/۷/۱۴

### چکیده

با توجه به وسعت منابع آبی در سراسر جهان، اندازه‌گیری‌های میدانی از پارامترهای کیفیت آب بسیار پرهزینه و زمان‌بر است. همچنین، امکان اندازه‌گیری میدانی در مناطقی که دسترسی به آنها دشوار است امکان‌پذیر نیست. در همین زمینه، فناوری سنجش از دور، با ظهور سنجنده‌های نوین ماهواره‌ای، امکان نظارت پویا و دقیقی را بر منابع آب فراهم کرده است. با توجه به توانایی بالای شبکه‌های عصبی در مدل‌سازی توابع غیرخطی، استفاده از این شبکه‌ها امکان برآورد پارامترهای کیفیت آب با دقت بالا را فراهم می‌کند. اما این شبکه‌ها، برای آموزش مدل، نیاز به تعداد مناسبی از داده‌های آموزشی دارند و به دلیل وجود مشکلاتی در تهیه تعداد بسیاری از داده‌های آموزشی در محیط‌های آبی، استفاده از شبکه‌های ترکیبی مقاوم‌تری، همچون شبکه عصبی موجکی، پیشنهاد شده است. در این مقاله، به منظور برآورد کدورت و غلظت کلروفیل-آ، از ۵۵ ایستگاه در بخش جنوبی دریای خزر نمونه‌برداری شده است و نمونه‌ها، به منظور آموزش و ارزیابی، به مدل شبکه عصبی داده شده‌اند. انواع گوناگونی از توابع موجک به منزله تابع محرک شبکه به کار رفت. بهترین شبکه برای برآورد غلظت کلروفیل-آ و کدورت، به ترتیب، شبکه‌های عصبی موجکی با تابع محرک مولت و کلاه مکزیکی بودند. داده‌های ماهواره‌ای مورد استفاده محصول بازتاب اقیانوسی سنجنده مادیس است. به دلیل به کارگیری تصاویر چندزمانه، نرمال‌سازی رادیومتریک داده‌ها انجام شد و نتایج، با توجه به زمانی که تصاویر نرمال نشده به کار رفت، بهبود چشمگیری داشت. در حالت چندزمانه، افزون بر افزایش تعداد داده‌های آموزشی، امکان تعمیم پذیری شبکه به سایر روزهایی که در آن داده میدانی کافی موجود نیست، فراهم شده و دقت شبکه در این حالت، در مقایسه با حالت تک‌زمانه، افزایش یافته است. در نهایت، RMSE برای بهترین مدل به منظور برآورد کدورت و غلظت کلروفیل، به ترتیب، ۰/۰۴۷ و ۰/۰۷۱ به دست آمد که، در مقایسه با دقت اندازه‌گیری میدانی ۰/۱، قابل قبول بوده است و می‌تواند جایگزین مناسبی برای اندازه‌گیری‌های میدانی باشد.

**کلیدواژه‌ها:** سنجش از دور، سنجنده مادیس، غلظت کلروفیل-آ، کدورت، شبکه عصبی موجکی.

\* نویسنده عهده‌دار مکاتبات: تهران، خیابان ولیعصر، تقاطع میرداماد، دانشگاه صنعتی خواجه نصیرالدین طوسی، دانشکده مهندسی نقشه‌برداری، کدپستی ۱۹۹۶۷-۱۵۴۳۳. تلفن:

## ۱- مقدمه

فیتوپلانکتون‌ها موجودات بسیار ریزی‌اند که ۸۵-۵۰٪ اکسیژن جهان را تولید می‌کنند و یکی از منابع تغذیه‌ای برای آبزیان به‌شمار می‌آیند. اما اگر تعداد بسیار زیادی از آنها در آب تجمع داشته باشند، ممکن است بیشتر اکسیژن محلول در آب را مصرف کنند و برای زیست‌بوم‌های آبی خطرآفرین باشند. از آنجاکه منابع آبی دارای رنگدانه فعال فتوسنتزی کلروفیل-آ محل تجمع فیتوپلانکتون‌هاست؛ غلظت کلروفیل-آ یکی از مهم‌ترین پارامترهای کیفیت آب محسوب می‌شود (Huang et al., 2010). بررسی دقیق میزان کلروفیل-آ می‌تواند اطلاعات مناسبی را، در زمینه میزان آلودگی و کدورت، فراهم آورد. کدورت در آب معمولاً بر اثر مواد معلق مانند گل‌ولای، مواد آلی و معدنی ریز، ترکیبات آلی رنگی محلول، پلانکتون‌ها و دیگر میکروارگانیسم‌ها ایجاد می‌شود و نفوذ نور در آب را کاهش می‌دهد و در زندگی گیاهان آبی تأثیر می‌گذارد. تغییرات کدورت ممکن است با روند فرسایش ساحلی مرتبط باشد؛ به همین دلیل، اندازه‌گیری آن اهمیت بسیاری دارد (Yu et al., 2012).

با توجه به وسعت منابع آبی در سراسر جهان، اندازه‌گیری‌های میدانی پارامترهای کیفیت آب و استفاده از روش‌های رایج بسیار وقت‌گیر و پرهزینه است. در همین زمینه، فناوری سنجش از دور، با ظهور سنجنده‌های نوین ماهواره‌ای، امکان نظارتی پویا و دقیق بر منابع آب را فراهم کرده است. افزون‌بر آن، توسعه روش‌ها و دسترسی آسان‌تر به داده‌ها سبب توسعه روزافزون کاربردهای سنجش از دور، از جمله نظارت عملیاتی بر آب‌ها، شده است (Palmer et al., 2015). چالشی که در ارتباط با نظارت بر کیفیت آب وجود دارد انتخاب روش مناسب برای پیدا کردن رابطه‌ای قوی میان پارامترهای کیفیت آب و داده‌های سنجش از دور است. این روش‌ها، به‌طور کلی، سه دسته می‌شوند: روش‌های تجربی، روش‌های تحلیلی و

روش‌های نیمه‌تجربی (نیمه‌تحلیلی) که ترکیب دو روش تجربی و تحلیلی است (Chang et al., 2015). روش‌های تحلیلی برای بازیابی اطلاعات در سیستم‌های محیطی، مبتنی بر مدل‌های تحلیلی، همچون مدل انتقال تابش‌اند. پارامترهای کیفی قابل بازیابی در این روش‌ها اساس مدل‌های زیستی-نوری دارند که رابطه میان ویژگی‌های ذاتی، مانند ضریب جذب کل و ضریب باز پراکنش کل، و ویژگی‌های ظاهری، مانند ضریب میرایی و تابش و بازتاب نور زیرآب، را توصیف می‌کنند (Ibid.). این روش‌ها به دانش اولیه در مورد رفتار طیفی پارامترهای کیفی در آب نیاز دارند تا محدوده طیفی حساس به آن پارامتر را تعیین کنند؛ بنابراین، بخشی از اطلاعات طیفی موجود را به کار می‌گیرند. همچنین، نیازمند تعیین باند طیفی بهینه‌اند زیرا به طول موج خاصی ثابت می‌شوند. این نکته در آب‌های پیچیده مشکل محسوب می‌شود زیرا، در چنین آب‌هایی، طیف بازتابی تحت تأثیر دیگر ترکیبات فعال نوری نیز قرار دارد. بنابراین، برای آب‌های پیچیده، الگوریتم‌هایی مورد نیاز است که کاملاً از اطلاعات پیوسته طیفی، در مقیاس‌های متفاوت، بهره‌برداری کنند، در تشخیص ویژگی‌های طیفی، انعطاف‌پذیرتر عمل کند (Ampe et al., 2015).

روش‌های تجربی روابط آماری میان پارامترهای اندازه‌گیری‌شده کیفیت آب و مقادیر طیفی را تعیین می‌کنند. این روش‌ها شامل رگرسیون‌های آماری خطی، انطباق منحنی و رگرسیون غیرخطی، با محاسبه تکنیک‌هایی همانند شبکه عصبی مصنوعی (ANN) می‌شوند (Chang et al., 2015). رابطه غیرخطی، در برآورد پارامترهای کیفی آب، نشان‌دهنده ناتوانی روش‌های رگرسیون خطی برای شناسایی دقیق پارامترهاست. چالش مرتبط با روش‌های تجربی پیدا کردن رابطه میان پارامترهای کیفیت آب و مقادیر طیفی باندها از طریق رگرسیون‌های آماری است و

## 1. Artificial Neural Network

توسعه داده شده است. نتایج نشان می‌دهد که مقادیر اندازه‌گیری‌شده و برآوردشده از هر دو روش انطباق مطلوبی دارند و معادلات تجربی انتخاب‌شده با رگرسیون خطی ساده‌تر است؛ در حالی که شبکه عصبی دقت بیشتری حاصل می‌کند. RMSE به‌دست‌آمده برای مدل رگرسیون، به‌ترتیب برای نیتروژن و فسفر، ۲/۵ و ۰/۱۷ حاصل شده و برای شبکه عصبی مصنوعی،

به‌ترتیب، ۰/۶۳ و ۰/۰۶ است (Liu et al., 2015).

براساس دقت‌های به‌دست‌آمده در مطالعات سانگ و همکاران (۲۰۱۲) و لیو و همکاران (۲۰۱۵)، شبکه‌های عصبی عملکردی بهتر از رگرسیون‌های آماری دارند و در مطالعات محیطی، از جمله مطالعات منابع آب، به‌صورت گسترده به‌کار رفته‌اند زیرا، با به‌کارگیری کرنل غیرخطی، می‌توانند هر تابع غیرخطی را مدل‌سازی کنند. اما این شبکه‌ها، برای آموزش، به تعداد بیشتری از داده‌های آموزشی نیاز دارند و در صورت اندک‌بودن تعداد داده‌های آموزشی، شبکه به‌خوبی آموزش نمی‌بیند و یا پایداری لازم را ندارد. از سوی دیگر، با توجه به پیچیدگی محیط‌های آبی و مشکلات موجود در برداشت داده‌های میدانی در منطقه و همچنین، هزینه ناشی از افزایش تعداد داده‌های میدانی، استفاده از شبکه‌های عصبی مقاوم‌تر، از طریق ترکیب شبکه عصبی با مدل‌هایی همچون موجک، پیشنهاد این است که، با تعداد کمتری از داده‌های میدانی، امکان دستیابی به برآوردی مطلوب از داده‌های کیفی فراهم شود.

موجک یکی از ابزارهای قوی در پردازش سیگنال است. پس از اعمال تبدیل موجک روی سیگنال سنجش از دور، سیگنال در مقیاس‌های متفاوتی تجزیه می‌شود. هر مقیاس نماینده‌ای از سیگنال اصلی خواهد بود و استخراج ویژگی‌های طیفی در مقیاس‌های متفاوت موجک امکان‌پذیر است. قابلیت موجک در کاهش نویز و نداشتن حساسیت در برابر تغییرات طیفی پس‌زمینه، در سنجش از دور، برای استخراج ویژگی‌های

همین سبب رشد روش‌های جدیدی شده است. در این زمینه، برخی از مدل‌های محاسباتی مانند شبکه عصبی مصنوعی، الگوریتم ژنتیک، الگوریتم ماشین بردار پشتیبان و ترکیب آنها با دیگر مدل‌ها، به‌منظور بازیابی پارامترهای کیفیت آب از باندهای متفاوت داده‌های سنجش از دور، به‌کار گرفته شدند (Chang et al., 2015).

روش‌های نیمه‌تجربی بر تلفیق روش‌های تجربی و تحلیلی متکی‌اند. این روش‌های ترکیبی به‌صورت معادلات تجربی، برپایه تئوری نوری و فیزیکی، بیان می‌شوند. مدل نسبت‌های باندهای در این دسته از روش‌ها قرار می‌گیرد. این مدل‌ها بخشی از طیف الکترومغناطیس را به‌منزله ورودی می‌پذیرند و به دانش قبلی، در زمینه رفتار پارامتر مورد مطالعه، نیاز دارند (Ibid.). براساس محدودیت‌های موجود برای روش‌های تحلیلی و نیمه‌تجربی، روش‌های تجربی از پرکاربردترین شیوه‌های برآورد پارامترهای کیفیت آب شمرده می‌شوند.

سانگ<sup>۱</sup> و همکاران (۲۰۱۲)، با استفاده از داده‌های لندست ۵، پارامترهای کیفی همچون غلظت رسوبات معلق و کلروفیل-ا، در یک منبع آب آشامیدنی در هند، برآورد کردند. دو روش رگرسیون خطی و شبکه عصبی مصنوعی، با استفاده از داده‌های میدانی و اطلاعات طیفی به‌دست‌آمده از ماهواره، به‌کار رفت و ترکیبات متفاوت باندها و نسبت‌های گوناگون باندهای به‌منزله ورودی، به هر دو مدل داده شد. نتایج نشان داد که برآورد غلظت رسوبات معلق، با استفاده از رگرسیون آماری، دقتی بیشتر از غلظت کلروفیل به‌دست می‌دهد و مدل شبکه عصبی، برای برآورد هر دو متغیر، به دقت مطلوبی رسیده است (Song et al., 2012). لیو<sup>۲</sup> و همکاران (۲۰۱۵)، با استفاده از تصاویر دارای قدرت تفکیک مکانی بالای ایکونوس<sup>۳</sup> که با چهار باند طیفی تصویربرداری می‌کنند، فسفر کل و نیتروژن کل در دریاچه سی‌هیو<sup>۴</sup> در چین را تعیین کردند. با استفاده از اندازه‌گیری‌های محلی، در این مطالعه، دو روش رگرسیون خطی چندگانه و شبکه عصبی مصنوعی

1. Song  
3. IKONOS

2. Liu  
4. Cihu

(۲۰۱۵) صورت دادند، در ترکیب موجک و شبکه عصبی، آنالیز موجک همچون روشی پیش‌پردازشی برای ورودی شبکه استفاده شد. داده‌های به‌کاررفته نیز اندازه‌گیری‌های زمینی از غلظت پارامترهای کیفی‌اند و تابع موجک در ساختار شبکه عصبی نقشی نداشته است. اما در این مقاله، موجک وارد ساختار شبکه شده و به‌منزله تابع محرک، کاربرد داشته است. همچنین، داده‌های مورد استفاده داده‌های ماهواره‌ای‌اند که، با عنوان ورودی، به شبکه عصبی موجکی معرفی شدند. اندازه‌گیری‌های میدانی از پارامترهای کیفی نیز، به‌منزله خروجی مورد انتظار، به شبکه داده شده است تا شبکه با تابع محرک موجکی، براساس این ورودی‌ها و خروجی‌ها، آموزش داده شود. به‌طور کلی، شبکه عصبی آنالیز موجک، در حالتی که جداگانه در مسائل مربوط به مدیریت آب و محیط‌زیست به‌کار روند، عملکرد مناسبی ارائه داده‌اند. نتایج شبیه‌سازی‌های صورت‌گرفته در منطقه مورد مطالعه نشان می‌دهد که استفاده از روشی ترکیبی، با بهره‌گیری از مزیت هر دو روش، نتایج مناسبی دربر داشته است.

در این مقاله، در بخش ۲، منطقه مورد مطالعه و داده‌های ورودی معرفی شده و سپس، مبانی تئوری تحقیق بیان شده است. در بخش ۳، نتایج مطرح و بحث و بررسی شده و در نهایت، در بخش ۴، نتیجه‌گیری‌ها بیان شده است.

## ۲- مواد و روش‌ها

### ۲-۱- منطقه مورد مطالعه

منطقه مورد مطالعه، در این تحقیق، دریاچه خزر است که از قسمت جنوبی به ایران محدود می‌شود. این دریاچه مساحتی حدود ۳۹۰۰۰۰ کیلومتر مربع و حجمی حدود ۷۸۰ هزار کیلومتر مکعب دارد. سطح

چشمگیر طیفی از داده‌های ماهواره‌ای با کاربردهای بسیاری نشان داده شده است (Ampe et al., 2015). کاربرد موجک در شبکه عصبی موجکی، در جایگاه تابع آموزش، به‌تازگی روش جایگزینی در شبکه‌های عصبی محسوب شده است. با ترکیب تئوری موجک و شبکه‌های عصبی مصنوعی، شبکه‌ای ترکیبی به نام شبکه عصبی موجکی مطرح می‌شود که پارامترهای ورودی کمتر از شبکه عصبی پرسپترون را می‌طلبد (Lekutai, 1997). از جمله تحقیقات صورت‌گرفته در زمینه کاربرد شبکه عصبی موجکی، می‌توان به مطالعه شنار و کیسی<sup>۱</sup> (۲۰۰۸)، برای مدل‌سازی جریان رودخانه مالاپراپها، اشاره کرد. آنها مدل تلفیقی عصبی موجکی را با دو مدل شبکه عصبی مصنوعی و رگرسیون مقایسه کردند. نتایج این تحقیق نشان می‌دهد مدل عصبی موجکی نتایج بهتری حاصل می‌کند. زنگ<sup>۲</sup> و همکاران (۲۰۰۵) کیفیت دریاچه دانگ تینگ در چین را، با استفاده از مدل تلفیقی تبدیل موجکی و شبکه‌های عصبی مصنوعی، در دو دوره، ارزیابی کردند و طبق نتایج در هر دو دوره، کیفیت آب وضعیت نامطلوبی داشت. علیزاده و کاویان‌پور<sup>۳</sup> (۲۰۱۵) مدل شبکه عصبی کلاسیک و شبکه عصبی موجکی را، برای پیش‌بینی پارامترهای متفاوت کیفیت آب در خلیج هیلو، و ترکیبات گوناگون پارامترهای کیفی آب را، به‌منزله متغیرهای ورودی برای پیش‌بینی مقادیر روزانه شوری و دما و DO، به‌کار بردند. نتایج نشان داد که مدل‌های موجکی برتر از مدل‌های کلاسیک‌اند.

ترکیب تئوری موجک با شبکه عصبی مصنوعی به دو صورت اجرایی است: نخست، استفاده از موجک به‌منزله تابع محرک شبکه؛ دوم، استفاده از تبدیل موجک به‌منزله روشی پیش‌پردازشی برای ورودی شبکه عصبی مصنوعی؛ به این صورت که ابتدا سیگنال سری زمانی غلظت، با استفاده از تبدیل موجک، تجزیه می‌شود. سپس سیگنال تجزیه‌شده، به‌صورت ورودی، به شبکه عصبی معرفی می‌شود. در مطالعاتی که شنار و کیسی (۲۰۰۸)، زنگ و همکاران (۲۰۰۵) و علیزاده و کاویان‌پور

1. Chenard and Caissie

2. Zeng

3. Alizadeh & Kavianpour

### ۲-۳- جمع آوری داده‌های ماهواره‌ای

داده‌های ماهواره‌ای مورد استفاده در این تحقیق از جدیدترین محصولات سنجنده مادیس (MYDOCGA) هستند که تمامی تصحیحات رادیومتریک و هندسی روی آنها اعمال شده و ارزش‌های تصویری آنها انعکاس سطح زمین است که از سایت [reverb.echo.nasa.gov](http://reverb.echo.nasa.gov) دریافت شده‌اند. این محصول اقیانوسی از سنجنده مادیس دارای قدرت تفکیک زمانی و مکانی، به ترتیب، یک روز و یک کیلومتر است. برای انجام‌دادن این تحقیق، از داده‌های روزانه این تصاویر طی ۷ ژوئیه ۲۰۱۱ تا ۱۵ سپتامبر ۲۰۱۱، منطبق با زمان نمونه‌برداری آب، استفاده شده است.

### ۲-۴- نرمال‌سازی تصاویر

با توجه به اینکه داده‌های به کاررفته حاصل مادیس‌اند که تصحیحات رادیومتریک و هندسی روی آنها انجام شده است؛ این تصاویر چندزمانه‌اند و در نظر گرفتن این نکته ضروری است که، در زمان‌های متفاوت تصویربرداری، شرایط جوی و سنسور تغییر می‌کند و لازم است نرمال‌سازی رادیومتریک<sup>۲</sup> صورت گیرد.

از جمله روش‌های نرمال‌سازی رادیومتریک تصاویر سری زمانی روش عوارض شبه ثابت<sup>۳</sup> محسوب می‌شود. در این روش فرض بر این است که، در تصاویر دریافتی طی زمان‌های متفاوت، عوارضی وجود دارند که در طول زمان، از نظر بازتابندگی، دچار تغییر نمی‌شوند (Philpot and Ansty, 2011)؛ برای نمونه، عوارض ساخت بشر مانند پشت‌بام‌ها و آسفالت خیابان. این عوارض را می‌توان نقاط کنترل در دو تصویر در نظر گرفت و در نهایت، با استفاده از آنها تصویر هدف، به نسبت تصویر مرجع، تصحیح رادیومتریکی خواهد شد. در این روش، مرحله اصلی انتخاب پیکسل‌های مناسب در نقش عوارض شبه ثابت است که به صورت دستی و خودکار صورت می‌پذیرد (de Carvalho et al., 2013).

1. Conductivity, Temperature, Depth
2. radiometric normalization
3. pseudo invariant features


دریاچه خزر نزدیک به ۲۷ متر پایین‌تر از سطح آب‌های آزاد است. با توجه به اینکه دریای خزر محیط زیست مناسبی برای ماهی‌های گوناگون است؛ مطالعه کیفیت آب، با هدف نظارت بر آن، اهمیت بسیاری دارد (de Mora et al., 2004).

### ۲-۲- گردآوری داده‌های میدانی

برای جمع‌آوری داده‌های میدانی، نخست، وضعیت اقلیمی منطقه بررسی شد و روزهای بدون ابر، که گذر مادیس نیز وجود داشته باشد، تعیین شد. سپس نمونه‌برداری هم‌زمان با گذر ماهواره و دامنه ۴۵ تا ۶۰ دقیقه از گذر آن، با فاصله ۳ کیلومتری ایستگاه‌ها از هم، صورت گرفت. با استفاده از سنسور فلورومتر نصب‌شده در دستگاه CTD<sup>۱</sup>، با دقت اندازه‌گیری ۰/۱ میکروگرم بر لیتر، در منطقه نور و بابلرود، از غلظت کلروفیل-ا در ۵۵ ایستگاه نمونه‌برداری میدانی شد. همچنین، برای اندازه‌گیری کدورت، دستگاه Seapoint Turbidity Meter به کار رفت. تاریخ روزهای نمونه‌برداری، مطابق با گذر ماهواره، در جدول ۱ نشان داده شده است. در هر روز، یازده نمونه و در مجموع، طی پنج روز نمونه‌برداری، ۵۵ نمونه برداشت شد.

جدول ۱. روزهای نمونه‌برداری

تاریخ نمونه‌برداری	تعداد نمونه‌ها
۲۰۱۱-۷-۷	۱۱
۲۰۱۱-۷-۹	۱۱
۲۰۱۱-۷-۳۱	۱۱
۲۰۱۱-۸-۱	۱۱
۲۰۱۱-۹-۱۵	۱۱



شکل ۱. نقشه منطقه و ایستگاه‌های نمونه‌برداری

## ۲-۶- شبکه عصبی مصنوعی


شبکه عصبی مصنوعی، با الهام گرفتن از فرایند یادگیری مغز انسان، می‌تواند مدل‌سازی کند و روابط ریاضی غیرخطی برای درون‌یابی پدیده آورد و در حل مسائل غیرخطی پیچیده، بسیار کارآمد است (Adamowski and Chan, 2011).

توپولوژی شبکه متشکل از نرون‌هایی، شامل یک تابع جمع‌کننده خطی و یک تابع فعال‌ساز، است که شبکه را برای پردازش داده‌ها فعال می‌کنند و با اتصال به لایه‌های شبکه، سازماندهی می‌شوند (Lekutai, 1997). هر لایه خروجی لایه قبل را، که وزن‌دار شده، دریافت و پردازش می‌کند و جمع وزن‌دار از ورودی‌ها، از طریق تابع فعال‌ساز، به خروجی تبدیل می‌شود. بیشتر شبکه‌های عصبی از سه لایه اصلی تشکیل شده‌اند: یک لایه ورودی که برای عرضه داده‌ها به شبکه استفاده می‌شود، یک یا تعداد بیشتری لایه‌های میانی و یک لایه خروجی که، برای تولید پاسخ مناسب از ورودی‌های داده‌شده، به کار می‌رود (Sudheer et al., 2006).

$$net = \sum_{i=1}^{n_0} w_i x_i + w_0 \quad \text{رابطه (۲)}$$

$$y = f(net) \quad \text{رابطه (۳)}$$

در رابطه (۲)،  $x_i$  ها سیگنال‌های ورودی و  $w_i$  وزن‌ها به‌شمار می‌روند. خروجی جمع‌کننده ترکیب خطی سیگنال‌های وزن‌دار ورودی و بایاس یا، به عبارت بهتر، مجموع ورودی‌های وزن‌دار است. در رابطه (۳)، تابع  $f$  نیز تابع فعال‌سازی سیگنال خروجی نرون است.



شکل ۲. ساختار کلی شبکه عصبی سه‌لایه

1. fine 2. coarser 3. net

در اینجا، با توجه به اینکه قدرت تفکیک مکانی محصولات به‌کاررفته از سنجنده مادیس یک کیلومتر است، امکان انتخاب دستی پیکسل‌های نمونه وجود ندارد و می‌توان، با بررسی طیف‌نگار دوبعدی تصاویر به‌صورت باندبه‌باند، پیکسل‌های مناسب را انتخاب کرد. بدیهی است پیکسل‌هایی که روی خط قطری قرار گرفته‌اند، در طول زمان، بازتابندگی ثابتی دارند و می‌توان، برای برآزش خط، از آنها به‌منزله نقاط کنترل در دو تصویر استفاده کرد؛ بنابراین، یک تصویر را تصویر مرجع در نظر می‌گیریم و تصاویر دیگر، به‌نسبت آن، تصحیح نسبی می‌شوند.

## ۲-۵- تبدیل موجک

موجک، به‌معنای موج کوچک، توابع ریاضی با ویژگی‌های منحصربه‌فردی به‌شمار می‌روند که امکان پردازش و تحلیل داده‌ها را، در رزولوشن‌های متفاوت، فراهم می‌آورند. این موج کوچک باید دارای کمترین نوسان و برگشت سریع به صفر، در هر دو جهت مثبت و منفی دامنه، باشند. موجک‌ها قابلیت جداسازی و تجزیه سیگنال به بست‌های گوناگون فرکانسی در بعد زمان را دارا هستند. در حالت کلی، برای حل هر مسئله‌ای، یکی از انواع توابع موجک استفاده می‌شود که به آن «موجک مادر» می‌گویند. موجک‌های مورد استفاده دیگر، در حل مسئله، نسخه‌های انتقال‌یافته و شیف‌ت‌یافته از موجک مادرند که «موجک فرزند» یا «موجک دختر» نامیده می‌شوند (Ampe et al., 2014).

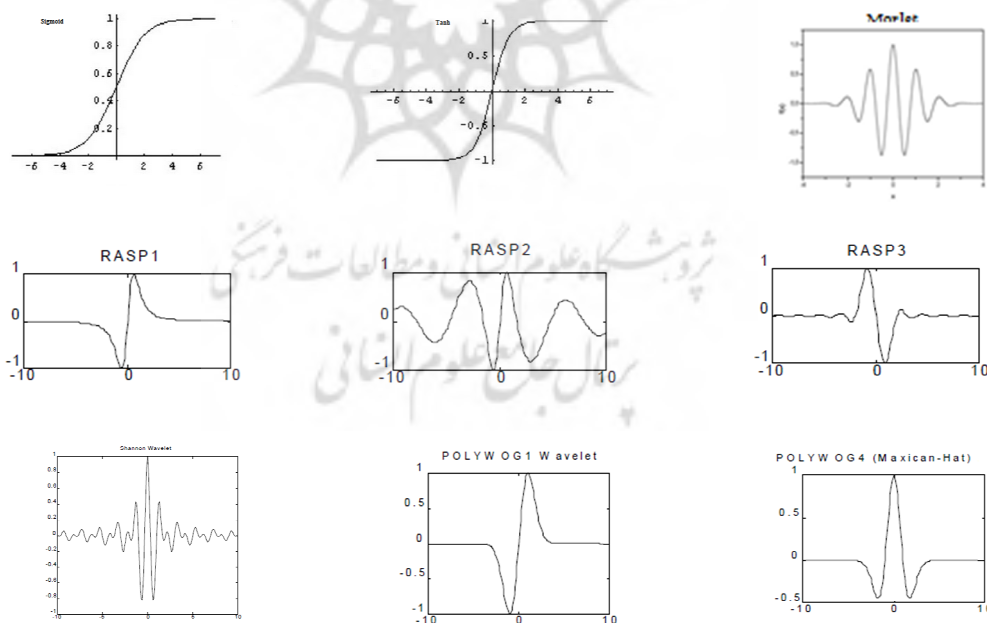
$$\psi_{a,b}(\lambda) = \frac{1}{\sqrt{a}} \psi\left(\frac{\lambda - b}{a}\right) \quad \text{رابطه (۱)}$$

در رابطه (۱)،  $a$  و  $b$  به‌ترتیب پارامترهای مقیاس و انتقال را نشان می‌دهند. منظور از مقیاس فشردگی یا کشیدگی در طول محور زمان است که معکوس فرکانس است. مقیاس پایین<sup>۱</sup> موجک ویژگی‌های فرکانس بالا و مقیاس بالای<sup>۲</sup> موجک ویژگی‌های فرکانس پایین را استخراج می‌کند (Ampe et al., 2014).

یا گسترش می‌کند؛ بنابراین، شبکه‌ای از توابع با موقعیت‌های مکانی و زمانی گوناگون روبه‌روست و احتمال رسیدن به پاسخ مطلوب افزایش می‌یابد (Alizadeh and Kavianpour, 2015).

در این تحقیق، به منظور تعیین بهترین مدل برای برآورد هر دو پارامتر مورد مطالعه، انواع گوناگونی از توابع محرک به‌کاررفته در هر دو شبکه عصبی پرسپترون و موجکی بررسی شدند. توابع سیگموئید و تانژانت هایپربولیک در شبکه‌های عصبی پرسپترون به‌منزله تابع محرک لایه میانی به شبکه معرفی شده‌اند. موجک‌های مادر گوناگون (شکل ۳) نیز، به‌منزله تابع محرک لایه میانی، در شبکه عصبی موجکی به‌کار رفتند تا عملکرد هریک از آنها در مدل‌سازی داده‌های موجود بررسی شود و تابعی با بهترین عملکرد، در جایگاه تابع محرک لایه میانی، انتخاب شود.

ترکیب موجک و شبکه عصبی مصنوعی مفهوم جدیدی از شبکه عصبی را، با عنوان شبکه عصبی موجکی، تشکیل می‌دهد. الگوریتم شبکه عصبی موجکی شامل دو مرحله است: خودساماندهی شبکه و کاهش خطا. در مرحله اول، ساختار شبکه، با استفاده از موجک، به‌منزله تابع محرک تعیین می‌شود. پارامترهای شیفت و مقیاس نیز وارد فرایند آموزش می‌شوند و شبکه نیز، با تعیین مقدار مناسب پارامترهای خود و با در نظر گرفتن ورودی‌ها و خروجی، این پارامترها را به‌روزرسانی می‌کند. در فرایند دوم، برآوردکننده خطای شبکه خطای شبیه‌سازی را، بر مبنای الگوریتم‌های موجود در ساختار شبکه عصبی، کاهش می‌دهد. هر تابع موجک، در جایگاه تابع محرک در ساختار شبکه، با تغییر در موقعیت مکانی و زمانی، اقدام به فشرده‌سازی



شکل ۳. تابع‌های محرک گوناگون در شبکه عصبی پرسپترون و شبکه عصبی موجکی

## ۲-۷- پارامترهای ارزیابی دقت

ارزیابی دقت مدل پیشنهادی با استفاده از داده‌های آزمایشی و براساس شاخص‌های ریشه میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE)، انحراف معیار RMSE در اجراهای چندگانه و دقت نسبی مطابق با روابط (۲) و (۳) و (۴) صورت گرفت و میانگین صد اجرا به صورت نتیجه نهایی در نظر گرفته شد. در رابطه (۲)،  $X_{esti,i}$  بیانگر مقدار برآورد شده از طریق شبکه و  $X_{meas,i}$  مقدار اندازه‌گیری شده است. همچنین در رابطه (۴)،  $\varepsilon_i$  خطای شبکه را بیان می‌کند.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (X_{esti,i} - X_{meas,i})^2}{N-1}} \quad \text{رابطه (۲)}$$

$$stdev(RMSE) \quad \text{رابطه (۳)}$$

$$MAE = \text{mean}(|\varepsilon_i|) \quad \text{رابطه (۴)}$$

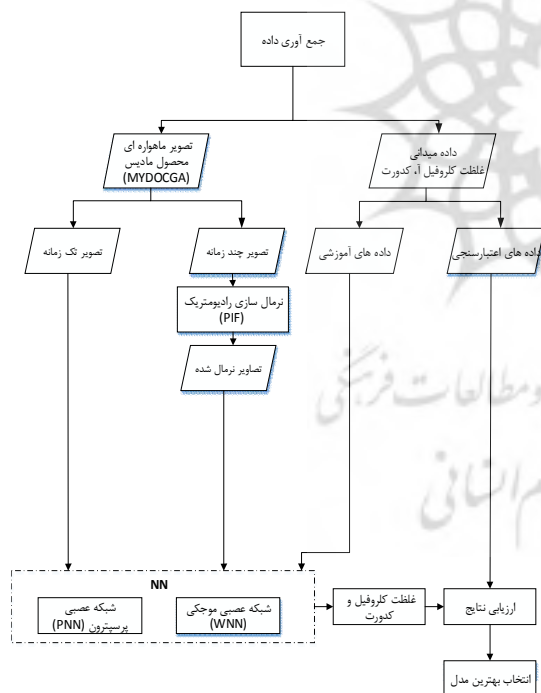
شاخص RMSE، که معیار ارزیابی متناسب با واحد اندازه‌گیری به شمار می‌رود، متغیر است و مقایسه مقدار آن بین مدل‌های ساخته شده، برای دو پارامتر مورد مطالعه با واحدهای متفاوت، مانند کلروفیل با واحد میکروگرم بر لیتر و کدورت با واحد NTU، درست نخواهد بود؛ اما به‌طور کلی، مقدار پایین RMSE بیانگر عملکرد مناسب و مقدار بالای آن نشان‌دهنده اختلاف بین مقدار مشاهده شده و مقدار محاسبه شده با استفاده از مدل است. چنانچه داده‌های نرمال شده به کار روند، مقدار RMSE نیز بدون واحد خواهد بود. (Chai and Draxler, 2014).

داده‌های مورد استفاده در شبکه عصبی، به صورت تصادفی، به سه مجموعه داده آموزشی و آزمایشی و اعتبارسنجی تقسیم شدند. تقسیم‌بندی داده‌ها تصادفی بود؛ به گونه‌ای که ۷۰٪ داده‌ها برای آموزش، ۱۵٪ برای آزمایش و ۱۵٪ برای اعتبارسنجی به کار رفتند. به منظور دستیابی به نتایج قطعی، روند آموزش مدل تکرار می‌شود تا تقسیم‌بندی‌های گوناگونی از داده‌های آموزشی و آزمایشی به کار رود.

در اجراهای صدگانه، میانگین و انحراف معیار RMSE محاسبه می‌شود. میانگین مبنایی برای دقت و انحراف معیار نشان‌دهنده میزان پراکندگی مقادیر به دست آمده است که مقدار پایین آن پایداری مدل را نشان می‌دهد. خطای نسبی شبکه نیز، به منزله معیاری برای ارزیابی، از تقسیم مقدار RMSE بر میانگین داده‌های مشاهده شده به دست می‌آید (Chai and Draxler, 2014).

## ۳- روش‌شناسی و اجرا

روند کلی تحقیق در شکل ۴ نشان داده شده است. طبق شکل، روش تحقیق سه بخش اصلی دارد: ۱. آماده‌سازی داده‌ها؛ ۲. آموزش شبکه‌های عصبی پرسپترون و موجکی؛ ۳. ارزیابی نتایج و انتخاب بهترین مدل.



شکل ۴. فلوچارت روند کلی تحقیق

1. Root Mean Square Error
2. Normalized Mean Absolute Error
3. Nephelometric Turbidity Unit



## ۳-۱- تحلیل تک‌زمانه تصاویر

در این مطالعه، در مرحله نخست، از داده‌های مربوط به یک روز استفاده شد. بدین‌منظور، ابتدا داده‌های ماهواره ای ۳۰ ژوئیه ۲۰۱۱ و یازده داده میدانی متناظر با آن آماده‌سازی شد. سپس برای برآورد غلظت کلروفیل-آ از داده‌های ماهواره‌ای، ۹ باند محصول اقیانوسی مادیس در نقاط نمونه‌برداری، به‌منزله ورودی، به شبکه عصبی داده شد. مقادیر اندازه‌گیری‌شده در محل نیز به‌منزله خروجی مورد انتظار به شبکه معرفی شدند تا شبکه، براساس این مجموعه داده، آموزش داده شود. با توجه به اینکه داده‌های موجود یازده‌تاست؛ به‌دلیل پایین‌بودن تعداد داده‌های آموزشی، برای ارزیابی شبکه، از روش اعتبارسنجی Leave one out استفاده شد. همان‌طور که از نام این شیوه پیداست، در هر مرحله، یکی از داده‌ها برای اعتبارسنجی بیرون گذاشته می‌شود و بقیه داده‌ها برای آموزش به کار می‌روند (Lee et al., 2004).

طبق روش ارزیابی Leave one out، از یازده داده آموزشی، ده نمونه برای آموزش و یک نمونه برای آزمایش به کار رفت. تقسیم‌بندی داده‌ها، در هر بار آموزش، به‌گونه‌ای تغییر می‌کند که تمامی داده‌ها در فرایند آموزش شرکت داشته باشند و یک نمونه نیز

برای آزمایش به کار رود و درنهایت، میانگین نتایج را نتایج نهایی در نظر می‌گیریم. طبق این روش ارزیابی، از آنجاکه فقط یک نمونه را نمونه آزمایشی در نظر می‌گیریم، محاسبه ضریب همبستگی امکان‌پذیر نیست و فقط میانگین مربعات خطا و میانگین خطای مطلق، به‌منزله معیار ارزیابی، محاسبه می‌شوند. برای دستیابی به نتایج مطمئن‌تر و بررسی پایداری شبکه، هر تقسیم‌بندی داده‌های ورودی ده بار اجرا می‌شود که، در مجموع نتایج، حاصل میانگین ۱۱۰ بار اجرای شبکه است.

مقایسه نتایج مربوط به غلظت کلروفیل-آ، براساس داده‌های تک‌زمانه، با به‌کارگیری توابع محرک گوناگون، در جدول ۲ و شکل ۵ نشان داده شده است.

مطابق نتایج جدول ۲ و شکل ۵، بهترین ساختار شبکه عصبی پرسپترون برای برآورد غلظت کلروفیل-آ شبکه‌ای با تابع محرک تانژانت و شش نرون در لایه میانی است. ساختار بهینه، برای شبکه عصبی موجکی نیز، شبکه‌ای با تابع محرک مورلت و یازده نرون در لایه میانی به شمار می‌رود. شایان ذکر است که تعداد نرون‌های بیشتر، در لایه میانی، دقت محاسبات را در آموزش شبکه افزایش می‌دهد اما الزاماً دقت مدل را، در پیش‌بینی داده‌های اعتبارسنجی و آزمون، افزایش نخواهد داد. بهترین عملکرد مدل زمانی است که خطای

جدول ۲. نتایج حاصل از برآورد غلظت کلروفیل-آ براساس داده‌های تک‌زمانه


شبکه	تابع محرک لایه میانی	تعداد نرون	MAE (mean±σ)	RMSE (mean±σ)
شبکه پرسپترون	Sigmoid	۵	۰/۱۸±۰/۱۹	۰/۲۳±۰/۱۹
	Tanh	۶	۰/۱۸±۰/۲	۰/۲۳±۰/۲
	Morlet	۱۱	۰/۰۸۶±۰/۰۳۵	۰/۱۲±۰/۰۴
	RASP1	۱۳	۰/۰۹±۰/۰۲۵	۰/۱۴±۰/۰۴
شبکه موجکی	RASP2	۱۳	۰/۰۹۱±۰/۰۲۴	۰/۱۳±۰/۰۳۶
	RASP3	۱۳	۰/۰۹±۰/۰۴	۰/۱۳±۰/۰۵۷
	SHANNON	۱۷	۰/۱۲±۰/۰۴۲	۰/۱۷±۰/۰۴۷
	POLYWOG1	۱۹	۰/۰۹۲±۰/۰۲۵	۰/۱۳±۰/۰۴
	Mexican hat	۱۸	۰/۲۷±۰/۰۲۶	۰/۳۱±۰/۰۲۸

شبکه‌های عصبی مدل می‌کند. شبکه عصبی موجکی، در مقایسه با شبکه عصبی، دو پارامتر اضافی مقیاس و انتقال را دارد؛ بنابراین، دارای سرعت همگرایی و درجه آزادی بیشتر در تخمین است زیرا، با افزودن دو پارامتر انتقال و مقیاس به پارامترهای تعدیل‌پذیر شبکه، دو درجه آزادی را افزایش می‌دهد و مدل انعطاف بیشتری می‌یابد.

میانگین RMSE، در اجراهای صدگانه، به صورت معیاری برای دقت شبکه و انحراف معیار RMSE به منزله معیار پایداری شبکه استفاده شده است. براساس نتایج به دست آمده، ریشه میانگین مربعات خطا با شبکه عصبی موجکی، با تابع محرک مورلت حاصل شده که بدین ترتیب، در مقایسه با شبکه عصبی پرسپترون با مقدار  $0.12 \pm 0.04$ ، افزون بر بهبود دقت، پایداری شبکه نیز افزایش چشمگیری یافته است. درواقع، هم RMSE از مقدار  $0.23$  به مقدار  $0.12$  کاهش یافته و هم انحراف معیار نتایج، از مقدار  $0.2$  به  $0.04$ ، کاهش چشمگیری داشته که این مسئله بیانگر پایداری شبکه عصبی موجکی است.

هر سه مرحله آموزش، تست و اعتبارسنجی به کمترین میزان برسد چون، در صورت بروز یادگیری اضافی<sup>۱</sup>، خطای داده‌های آموزشی کمینه می‌شود اما خطای داده‌های اعتبارسنجی افزایش می‌یابد. در این مقاله، تعداد نرون بهینه براساس دقت داده‌های تست انتخاب شده است؛ یعنی تعداد نرونی که mse کمتری برای داده‌های تست دارد نرون بهینه در نظر گرفته شد و عملکرد شبکه، پس از اتمام فرایند آموزش، از طریق داده‌های اعتبارسنجی ارزیابی شد.

با مقایسه نتایج، در شبکه عصبی موجکی با به‌کارگیری تابع محرک مورلت، موقعیت و مقیاس موجک‌ها، افزون بر وزن‌ها، بهینه‌سازی می‌شوند و با تغییر پارامترهای شیفت و مقیاس تا مقدار بهینه، قابلیت چنین شبکه‌ای در مدل‌سازی هر رفتار غیرخطی افزایش می‌یابد. به همین دلیل، شبکه عصبی موجکی میانگین مربعات خطای کمتر و پایداری بیشتری از شبکه عصبی پرسپترون دارد. درواقع، شبکه عصبی موجکی، به‌علت ویژگی‌های محلی تابع انتقال موجک، تغییرات ناگهانی و رفتارهای پیچیده غیرخطی را بهتر از



شکل ۵. عملکرد انواع متفاوت تابع محرک در شبکه عصبی پرسپترون و شبکه عصبی موجکی، به‌منظور برآورد غلظت کلروفیل-آ از داده‌های تک‌زمانه

## 1. over training

## ۳-۲- تحلیل چندزمانه تصاویر

با توجه به اندک بودن تعداد داده های آموزشی در یک روز و بررسی قابلیت تعمیم پذیری شبکه آموزش داده شده، داده های چندزمانه به کار رفته است. پس از نرمال سازی تصاویر سری زمانی مادیس، می توان گفت که اگر مجموعه ای داده میدانی از غلظت پارامترهای کیفی و داده های ماهواره ای متناظر با آن، در ماه های متفاوت، موجود باشد و شبکه عصبی با این مجموعه داده آموزش یابد، چنین شبکه ای توانایی تعمیم پذیری به همان دوره زمانی را خواهد داشت و هرچه بازه زمانی داده های ورودی گسترده تر باشد، این توانایی تعمیم پذیری نیز بیشتر خواهد شد.

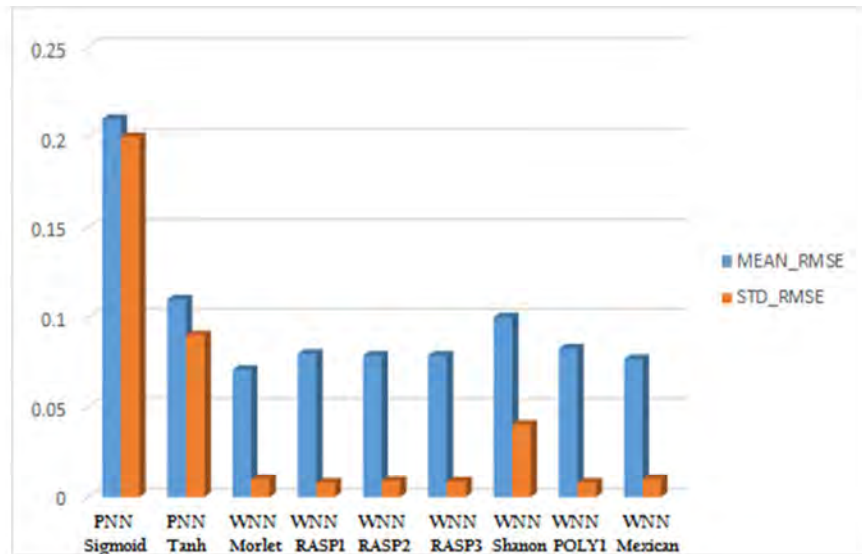
برای دستیابی به نتایج مطمئن از شبکه، براساس روش نمونه گیری چندباره تصادفی، اعتبارسنجی شد. در این نوع اعتبارسنجی، مجموعه داده ها به سه زیرمجموعه آموزشی و آزمایشی و اعتبارسنجی تقسیم می شوند. سپس مدل مورد نظر، با استفاده از داده های آموزشی، آموزش داده می شود و نتیجه، با داده های

تست، اعتبارسنجی می شود. این روال چندین بار تکرار و میانگین نتایج، به منزله تخمین نهایی، در نظر گرفته می شود. با اجرای صدگانه روند آموزش برای هر شبکه و محاسبه میانگین و انحراف معیار RMSE و MAE، نتایج نهایی به دست می آید (جدول ۳).

براساس نتایج جدول ۳، با به کارگیری داده های چندزمانه، شبکه عصبی موجکی با تابع محرک مورلت دقتی بیشتر از شبکه عصبی پرسپترون با تابع محرک تانژانت دارد. علاوه بر آن، پایداری شبکه نیز بسیار افزایش یافته است. در این حالت، خطای پاسخ دهی شبکه برای برآورد غلظت کلروفیل-آ، از تقسیم مقدار میانگین مربعات خطا بر میانگین غلظت کلروفیل اندازه گیری شده در محل، ۱۹٪ به دست آمده است. طبق نتایج جدول ۳ و شکل ۶، بهترین مدل برای برآورد غلظت کلروفیل-آ در دریای خزر مدل شبکه عصبی موجکی با ورودی داده های چندزمانه و تابع محرک مورلت با یازده نرون بهینه محسوب می شود.

جدول ۳. نتایج حاصل از برآورد غلظت کلروفیل-آ طبق داده های چندزمانه

شبکه	تابع محرک لایه میانی	تعداد نرون	MAE (mean±σ)	RMSE (mean±σ)
شبکه پرسپترون	Sigmoid	۵	۰/۱۱±۰/۲	۰/۲۱±۰/۲
	Tanh	۶	۰/۰۸۵±۰/۰۹	۰/۱۱±۰/۰۹
	Morlet	۱۱	۰/۰۵±۰/۰۰۶	۰/۰۷۱±۰/۰۱۱
	RASP1	۱۳	۰/۰۶۲±۰/۰۰۶	۰/۰۸±۰/۰۰۸
	RASP2	۱۳	۰/۰۶±۰/۰۰۵	۰/۰۷۹±۰/۰۰۹
شبکه موجکی	RASP3	۱۳	۰/۰۶۲±۰/۰۰۵	۰/۰۷۹±۰/۰۰۸۶
	SHANNON	۱۷	۰/۰۸±۰/۰۰۲	۰/۱±۰/۰۰۴
	POLYWOG1	۱۹	۰/۰۶۵±۰/۰۰۵۱	۰/۰۸۳±۰/۰۰۸
	Mexican hat	۱۸	۰/۰۵۸±۰/۰۰۵۷	۰/۰۷۷±۰/۰۰۱



شکل ۶. عملکرد تابع‌های محرک گوناگون در شبکه عصبی پرسپترون و شبکه عصبی موجکی، به منظور برآورد غلظت کلروفیل از داده‌های چندزمانه

این قسمت، مربع ضریب همبستگی میان مقادیر اندازه‌گیری شده و محاسبه شده برای غلظت کلروفیل-آ محاسبه شده که مقدار آن، برای شبکه عصبی پرسپترون،  $0/68$  و برای شبکه عصبی موجکی،  $0/81$  به دست آمده است.

با توجه به عملکرد مناسب مدل حاصل برای غلظت کلروفیل-آ و اهمیت نظارت بر کدورت آب‌های ساحلی، مجموعه داده چندزمانه، به منزله ورودی، به شبکه عصبی پرسپترون و موجکی، با انواع متفاوت تابع محرک، داده شد تا عملکرد شبکه برای یکی دیگر از مهم ترین پارامترهای کیفی آب سنجیده شود. با این هدف، از کدورت بخش جنوبی دریای خزر در مناطق نور و بابلرود، داده‌های میدانی گردآوری و آماده سازی شد. نمونه برداری کدورت آب هم‌زمان با غلظت کلروفیل و در همان ایستگاه‌ها صورت گرفت. طی هر روز نمونه برداری، از یازده ایستگاه به فاصله سه کیلومتری از هم، داده برداشت شده و با توجه به اینکه نمونه برداری در پنج روز صورت گرفت، مجموع داده مورد استفاده در تحلیل چندزمانه برابر با ۵۵ داده است. نمونه‌های برداشت شده، به منزله خروجی مورد انتظار، به شبکه‌های عصبی پرسپترون و موجکی معرفی


برای بررسی بهبود دقت تخمین غلظت کلروفیل-آ حاصل از شبکه عصبی موجکی با شبکه عصبی پرسپترون و مقایسه آنها (هر دو، در حالت استفاده از داده‌های چندزمانه)، مقادیر RMSE و ضریب همبستگی حاصل از دو مدل مقایسه شدند. مقدار RMSE نتایج شبکه عصبی موجکی، با ورودی داده‌های چندزمانه،  $0/071 \pm 0/01$  به دست آمده که، در مقایسه با شبکه عصبی پرسپترون با ورودی داده‌های چندزمانه، با مقدار  $0/111 \pm 0/09$ ، دقت و پایداری بیشتری دارد. در واقع، می‌توان گفت که دقت برآورد حاصل از شبکه عصبی موجکی، به نسبت شبکه عصبی پرسپترون،  $36\%$  بهبود به همراه داشته است. همچنین، پایداری شبکه‌های عصبی موجکی، در قیاس با شبکه عصبی پرسپترون، بهبودی معنابه داشته که، براساس مقادیر عددی انحراف معیار اجزاهای متوالی، این بهبود در حدود  $88\%$  برای افزایش برآورد می‌شود. به عبارت دیگر، شبکه عصبی موجکی، با دادن نتایج بسیار پایدار (کمتر تأثیر گرفته از مقادیر اولیه تصادفی در شبکه‌های عصبی)، نتایجی بسیار مورد اعتمادتر از شبکه عصبی پرسپترون حاصل می‌کند. افزون بر معیار RMSE، به منظور اثبات بهبود عملکرد شبکه عصبی موجکی، در

نتایج جدول ۴ و شکل ۷ نشان می‌دهد که شبکه عصبی موجکی، با تابع محرک کلاه مکزیکی و تعداد شش نرون بهینه، دقتی بیشتر از شبکه عصبی پرسپترون دارد؛ بنابراین شبکه عصبی موجکی، به منزله مدل بهینه در برآورد کدورت بخش جنوبی دریای خزر، انتخاب شد.

شدند تا هر دو شبکه، براساس داده‌های کدورت نیز، آموزش داده شوند. نتایج داده‌های اعتبارسنجی نشان داد که، در برآورد کدورت بخش جنوبی دریای خزر نیز، از لحاظ پایداری و دقت، شبکه عصبی موجکی نتایجی بسیار بهتر از شبکه عصبی پرسپترون حاصل کرده و خطای نسبی، در این حالت، ۱۱٪ شده است.


جدول ۴. نتایج حاصل از برآورد کدورت، طبق داده‌های چندزمانه

شبکه	تابع محرک لایه میانی	تعداد نرون	MAE (mean±σ)	RMSE (mean±σ)
شبکه پرسپترون	Sigmoid	۵	۰/۰۸۶±۰/۱۱۸	۰/۵±۰/۴۱
	Tanh	۲۲	۰/۴۲±۰/۵	۰/۱۱±۰/۱۸
	Morlet	۲۴	۰/۰۳±۰/۰۰۵	۰/۰۴۸±۰/۰۱۵
	RASP1	۲۵	۰/۰۳۱±۰/۰۰۳	۰/۰۴۸±۰/۰۱۳
	RASP2	۲۵	۰/۰۳±۰/۰۰۴۸	۰/۰۴۹±۰/۰۱۸
شبکه موجکی	RASP3	۲۵	۰/۰۲۸±۰/۰۰۴	۰/۰۴۸±۰/۰۱۳
	SHANNON	۲۲	۰/۰۷±۰/۱۶	۰/۲±۰/۰۷۴
	POLYWOG1	۵	۰/۰۳۳±۰/۰۰۵	۰/۰۵۶±۰/۰۲۳
	Mexican hat	۶	۰/۰۳±۰/۰۰۳۵	۰/۰۴۷±۰/۰۱۱



شکل ۷. عملکرد تابع‌های محرک گوناگون در شبکه عصبی پرسپترون و شبکه عصبی موجکی، به منظور برآورد کدورت دریای خزر، طبق داده‌های چندزمانه


روزهای نمونه برداری در شکل ۹ و ۱۱ نشان داده شده است.




شکل ۹. روزهای نمونه برداری

### ۳-۳-۱- بررسی اول

در بررسی اول، داده‌های ۳۰ ژوئیه، به منزله یکی از روزهای میانی در طول دوره بررسی، از روند آموزش حذف و فقط برای ارزیابی مدل استفاده شد. زمانی که شبکه با داده‌های تک‌زمانه از غلظت کلروفیل-آ، در تاریخ ۳۰ ژوئیه آموزش داده شد، ریشه میانگین مربعات خطا، برای غلظت کلروفیل-آ و کدورت، ۰/۱۲ به دست آمد اما هنگامی که شبکه با مجموعه داده سری زمانی آموزش دید و داده‌های ۳۰ ژوئیه به صورت داده‌های آزمایشی به شبکه معرفی شد، ریشه میانگین مربعات خطا، به ترتیب، به مقدار ۰/۰۷۴ و ۰/۰۴۶ کاهش یافت. براساس نتایج شکل ۱۰، شبکه با داده‌های سری زمانی بهتر آموزش دیده است زیرا داده‌های مجموعه زمانی، علاوه بر اینکه در یک دوره زمانی جمع آوری شده‌اند و امکان تعمیم پذیر بودن شبکه را فراهم می‌کنند، تعداد داده‌های میدانی بیشتری را نیز شامل می‌شوند.



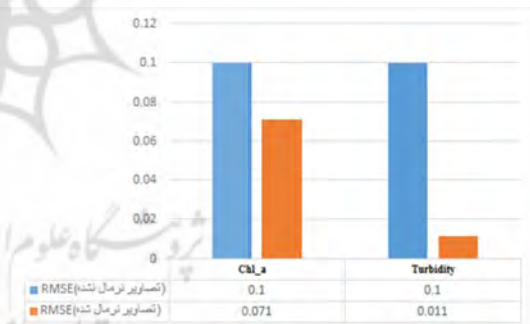
شکل ۱۰. مقایسه نتایج تک‌زمانه و چندزمانه



شکل ۱۱. روزهای نمونه برداری

برای بررسی میزان تأثیر نرمال سازی رادیومتریک تصاویر چندزمانه مادیس محصول با استفاده از روش PIF، تصاویر چندزمانه، بدون نرمال سازی، به بهترین مدل برآورد غلظت کلروفیل-آ و کدورت دریای خزر داده شد و مقدار RMSE برای هر مدل، به ترتیب، ۰/۱±۰/۰۱ و ۰/۲±۰/۰۱ به دست آمد.

در شکل ۸، نتایج حاصل از برآورد غلظت کلروفیل-آ و کدورت دریای خزر، هم در حالتی که نرمال سازی رادیومتریک داده‌های چندزمانه صورت گرفته است و هم در حالتی که داده‌های بدون نرمال سازی به شبکه معرفی شده‌اند، نشان داده شده است. با مقایسه نتایج می‌توان گفت، برای هر دو پارامتر مورد مطالعه، نرمال سازی رادیومتریک داده‌های چندزمانه باعث بهبود نتایج شده است و با وجود تصحیحات رادیومتریک و هندسی محصول اقیانوسی مادیس، در صورت استفاده از تصاویر چندزمانه، تصحیح رادیومتریک نسبی نیز لازم است.



شکل ۸. مقایسه نتایج تصاویر نرمال شده و نرمال نشده


### ۳-۳-۲- بررسی تعمیم پذیری داده‌های چندزمانه

پس از تعیین بهترین مدل برای برآورد غلظت کلروفیل-آ و کدورت دریای خزر با استفاده از داده‌های چندزمانه، تعمیم پذیری مدل آموزش داده شده به سایر روزهایی که در روند آموزش شرکت نکرده‌اند بررسی شد. برای بررسی این مسئله، داده‌های یک روز از روند آموزش حذف شد و فقط در جایگاه آزمون به کار رفت.

## ۳-۲- بررسی دوم

در بررسی دوم، داده‌های مربوط به ۱۵ سپتامبر، به منزله آخرین روز دوره مورد مطالعه، از روند آموزش حذف شد و فقط برای ارزیابی مدل به کار رفت. زمانی که شبکه با داده‌های تک‌زمانه از غلظت کلروفیل-آ در ۱۵ سپتامبر آموزش دید، ریشه میانگین مربعات خطا برای غلظت کلروفیل-آ و کدورت، به ترتیب، ۰/۱۱ و ۰/۰۵۶ به دست آمد. اما هنگامی که شبکه با مجموعه داده سری زمانی آموزش داده شد، مقدار آن به ۰/۰۸۲ و ۰/۰۳۷ کاهش یافت و مانند حالت قبل، دقت مدل برای هر دو پارامتر، با ورودی داده های سری زمانی، افزایش داشت که در شکل ۱۲ نشان داده شده است.

تحلیل داده های چندزمانه به دو صورت بررسی شد؛ در بررسی نخست، شبکه آموزش داده شده برای یک روز میانی در طول دوره آزمایش شد و دقت حاصل از آموزش با داده های چندزمانه، در مقایسه با حالت تک‌زمانه، افزایش یافت. در بررسی دوم، روز مورد آزمایش از انتهای دوره در نظر گرفته شد و باز هم دقت داده‌های چندزمانه بیشتر از حالت تک‌زمانه بود. بنابراین، می توان گفت که شبکه با داده‌های سری زمانی بهتر آموزش دیده و توانایی تعمیم پذیری به سایر روزهای دوره زمانی داده‌های ورودی را داراست.



شکل ۱۲. مقایسه نتایج تک‌زمانه و چندزمانه

از میان اجراهای چندگانه، بهترین نتیجه برای شبکه عصبی موجکی با ورودی باندهای اقیانوسی به

دست آمد. در این حالت، مربع همبستگی به دست آمده میان مقادیر اندازه‌گیری شده و محاسبه شده برای غلظت کلروفیل-آ و کدورت، در بهترین حالت، به ترتیب، ۰/۸۱ و ۰/۹ حاصل شد که نشان از عملکرد مناسب شبکه در برآورد غلظت کلروفیل-آ و کدورت در دریای خزر دارد.

## ۴- نتیجه‌گیری

دریای خزر، در شمال ایران، زیستگاه ماهیان گوناگون و بستری تجاری برای کشور محسوب می شود؛ به همین دلیل، مطالعه کیفیت این دریای پهناور و نظارت بر منابع آلوده کننده آن اهمیت بسیاری دارد. غلظت کلروفیل-آ و کدورت مهم‌ترین پارامترهای کیفیت آب و شاخصی از وضعیت تغذیه منابع آبی شمرده می‌شود که مطالعه آنها امری ضروری است.

اندازه‌گیری‌های میدانی از پارامترهای کیفی پرهزینه و زمان‌بر است. از این رو، استفاده از داده‌های سنجش از دوری، با توجه به فراگیر بودن و دسترسی آسان، بسیار مورد توجه قرار گرفته است. با در نظر گرفتن پیچیدگی‌های ناشی از برهم‌کنش نور با محیط‌های آبی و توانایی شبکه عصبی مصنوعی در مدل‌سازی هر تابع غیرخطی، از میان روش‌های متفاوت اندازه‌گیری پارامترهای کیفی، در سال‌های اخیر، استفاده از شبکه‌های عصبی مصنوعی برای برآورد غلظت کلروفیل-آ و کدورت نتایج خوبی به همراه داشته است. اما به دلیل نیاز شبکه‌های عصبی به تعداد زیادی از داده‌های میدانی به منظور آموزش و ارزیابی شبکه و دشواری نمونه‌برداری میدانی از پارامترهای کیفی در منابع آبی، استفاده از شبکه‌های ترکیبی مقاوم‌تری، همچون ترکیب موجک با شبکه عصبی، پیشنهاد می‌شود.

با هدف افزایش تعداد داده‌های آموزشی و توانایی تعمیم‌پذیری شبکه آموزش‌دیده به دیگر روزها، مجموعه داده سری زمانی، به صورت ورودی، به شبکه داده شد و تعمیم‌پذیری شبکه، برای روزهای میانی و انتهای دوره، بررسی شد. نتایج نشان داد که شبکه آموزش داده‌شده توانایی تعمیم‌پذیری بالایی دارد.

اهواز)، جلد ۸، شماره ۴، صص. ۳۵-۵۴.  
 طباطبایی، م.ر، شاهدهی، ک.، سلیمانی، ک.، ۱۳۹۲،  
 مدل شبکه عصبی مصنوعی برآورد غلظت  
 رسوب معلق رودخانه‌ای به کمک تصاویر  
 سنجنده مودیس (مطالعه موردی: ایستگاه  
 هیدرومتری ملاتانی- رودخانه کارون)، نشریه آب  
 و خاک (علوم و صنایع کشاورزی)، دانشگاه فردوسی  
 مشهد، دوره ۲۷، شماره ۱، صص. ۲۰۴-۱۹۳.

Adamowski, J. & Chan, H.F., 2011. A **Wavelet Neural Network Conjunction Model for Groundwater Level Forecasting**, Journal of Hydrology, 407(1), PP. 28-40.

Alizadeh, M.J. & Kavianpour, M.R., 2015, **Development of Wavelet-ANN Models to Predict Water Quality Parameters in Hilo Bay, Pacific Ocean**, Marine pollution bulletin, 98, PP. 171-178.

Ampe, E.M., Hestir, E.L., Bresciani, M., Salvatore, E., Brando, V.E., Dekker, A., Malthus, T.J., Jansen, M., Triest, L. & Batelaan, O., 2014, **A Wavelet Approach for Estimating Chlorophyll-a from Inland Waters with Reflectance Spectroscopy**, IEEE Geoscience and Remote Sensing Letters, 11(1), PP. 89-93.

Ampe, E.M., Raymaekers, D., Hestir, E.L., Jansen, M., Knaeps, E. & Batelaan, O., 2015, **A Wavelet-Enhanced Inversion Method for Water Quality Retrieval from High Spectral Resolution Data Complex Waters**, IEEE Transactions on Geoscience and for Remote Sensing, 53(2), PP. 869-882.

Chai, T. & Draxler, R.R., 2014, **Root Mean Square Error (RMSE) or Mean Absolute Error (MAE)?-Arguments against Avoiding RMSE in the Literature**, Geoscientific Model Development, 7(3), PP. 1247-1250.

Chang, N.B., Imen, S. & Vannah, B., 2015, **Remote Sensing for Monitoring Surface Water Quality Status and Ecosystem State in Relation to the Nutrient Cycle: A 40-Year Perspective**, Critical Reviews in Environmental Science and Technology, 45(2), PP. 101-166.

نرمال سازی رادیومتریک به روش PIF روی داده‌های سری زمانی انجام شد و RMSE، در صورتی که داده‌های نرمال شده به منزله ورودی شبکه به کار رفته باشند، برای غلظت کلروفیل-آ و کدورت، به ترتیب، ۰/۰۷۱ و ۰/۰۴۷ به دست می‌آید. در صورتی که پیش از نرمال سازی رادیومتریک محصول بازتاب اقیانوسی مادیس، مقدار ۰/۱ برای هر دو پارامتر حاصل شده است؛ بنابراین، این محصول مادیس، با وجود برخورداری از تصحیحات لازم، به نرمال سازی رادیومتریک روی داده‌های چندزمانه نیاز دارد.

با مقایسه نتایج داده های سنجنده مادیس، شبکه عصبی موجکی بهترین مدل برای برآورد غلظت کلروفیل-آ و کدورت از آب‌های دریای خزر است. طبق نسبت ریشه میانگین مربعات خطا بر میانگین مقادیر اندازه گیری شده، مقدار خطای پاسخ دهی شبکه برای کلروفیل-آ و کدورت، به ترتیب، ۱۹٪ و ۱۱٪ برآورد شده است. با توجه به اینکه دقت اندازه گیری میدانی ۰/۱ است، شبکه عصبی موجکی، با ریشه میانگین مربعات خطای ۰/۰۷۱ و ۰/۰۴۷، مدلی مناسب برای برآورد غلظت کلروفیل-آ و کدورت دریای خزر از داده‌های سنجش از دور است؛ بدین ترتیب، این شبکه می‌تواند جایگزینی مناسب برای اندازه گیری‌های میدانی باشد.

##### ۵- تشکر و قدردانی

از جناب آقای دکتر غلامعلی فرد، به دلیل مساعدت و فراهم آوردن داده‌های میدانی مورد نیاز در این پژوهش، تشکر و قدردانی می‌شود.

##### ۶- منابع

غلامعلی فرد، م.، احمدی، ب.، ۱۳۹۵، **تغییرپذیری مکانی- زمانی کلروفیل-آ و شکوفایی جلبکی با استفاده از داده‌های ماهواره‌ای در حوضه جنوبی دریای خزر**، مجله علمی- پژوهشی زیست‌شناسی دریا (دانشگاه آزاد اسلامی، واحد



- Chawira, M., Dube, T. & Gumindoga, W., 2013, **Remote Sensing Based Water Quality Monitoring in Chivero and Manyame Lakes of Zimbabwe**, Physics and Chemistry of the Earth, Parts A/B/C, 66, PP. 38–44.
- Chebud, Y., Naja, G.M., Rivero, R.G. & Melesse, A.M., 2012, **Water Quality Monitoring Using Remote Sensing and an Artificial Neural Network**, Water, Air, & Soil Pollution, 223(8), PP. 4875–4887.
- Chen, S., Fang, L., Li, H., Chen, W. & Huang, W., 2011, **Evaluation of a Three-Band Model for Estimating Chlorophyll-a Concentration in Tidal Reaches of the Pearl River Estuary, China**, ISPRS Journal of Photogrammetry and Remote Sensing, 66(3), PP. 356–364.
- Chenard, J.F. & Caissie, D., 2008, **Stream Temperature Modeling Using Artificial Neural Networks: Application on Catamaran Brook**, New Brunswick, Canada, Hydrological Processes, 22(17), PP. 3361–3372.
- Curran, P.J. & Novo, E.M.M., 1988, **The Relationship between Suspended Sediment Concentration and Remotely Sensed Spectral Radiance: A Review**, Journal of Coastal Research, PP. 351–368.
- de Carvalho, O.A., Guimarães, R.F., Silva, N.C., Gillespie, A.R., Gomes, R.A.T., Silva, C.R. & de Carvalho, A.P.F., 2013, **Radiometric Normalization of Temporal Images Combining Automatic Detection of Pseudo-Invariant Features from the Distance and Similarity Spectral Measures, Density Scatterplot Analysis, and Robust Regression**, Remote Sensing, 5(6), PP. 2763–2794.
- de Mora, S., Sheikholeslami, M.R., Wyse, E., Azemard, S. & Cassi, R. 2004, **An Assessment of Metal Contamination in Coastal Sediments of the Caspian Sea**, Mar Pollut Bul, 48, PP. 61–77.
- Dlamini, S., Nhapi, I., Gumindoga, W., Nhwatiwa, T. & Dube, T., 2016, **Assessing the Feasibility of Integrating Remote Sensing and In-Situ Measurements in Monitoring Water Quality Status of Lake Chivero, Zimbabwe**, Physics and Chemistry of the Earth, Parts A/B/C.
- Huang, Y., Jiang, D., Zhuang, D. & Fu, J., 2010, **Evaluation of Hyperspectral Indices for Chlorophyll-a Concentration Estimation in Tangxun Lake (Wuhan, China)**, International Journal of Environmental Research and Public Health, 7(6), PP. 2437–2451.
- Huntzinger, E., Boisset, S., Saveanu, C., Benito, Y., Geissmann, T., Namane, A., Lina, G., Etienne, J., Ehresmann, B., Ehresmann, C. & Jacquier, A., 2005, **Staphylococcus Aureus RNAPIII and the ENDORIBONUCLEASE III Coordinately Regulate Spa Gene Expression**, The EMBO journal, 24(4), PP. 824–835.
- Jensen, J.R., 2009, **Remote Sensing of the Environment: An Earth Resource Perspective 2/e**, Pearson Education India.
- Kabbara, N., Benkhelil, J., Awad, M. & Barale, V., 2008, **Monitoring Water Quality in the Coastal Area of Tripoli (Lebanon) Using High-Resolution Satellite Data**, ISPRS Journal of Photogrammetry and Remote Sensing, 63(5), PP. 488–495.
- Kumar, V., Sharma, A., Chawla, A., Bhardwaj, R. & Thukral, A.K., 2016, **Water Quality Assessment of River Beas, India, Using Multivariate and Remote Sensing Techniques**, Environmental Monitoring and Assessment, 188(3), PP. 1–10.
- Lee, M.M., Keerthi, S.S., Ong, C.J. & DeCoste, D., 2004, **An Efficient Method for Computing Leave-one-out Error in Support Vector Machines with Gaussian Kernels**, IEEE Transactions on Neural Networks, 15(3), PP. 750–757
- Lekutai, G., 1997, **Adaptive Self-Tuning Neuro Wavelet Network Controllers**, Virginia Polytechnic Institute PHD thesis, Blacksburg, Virginia.
- Liu, J., Zhang, Y., Yuan, D. & Song, X., 2015, **Empirical Estimation of Total Nitrogen and Total Phosphorus Concentration of Urban Water Bodies in China Using High Resolution IKONOS Multispectral Imagery**, Water, 7(11), PP. 6551–6573.
- Matsushita, B., Yang, W., Yu, G., Oyama, Y., Yoshimura, K. & Fukushima, T., 2015, **A Hybrid Algorithm for Estimating the**

- Chlorophyll-a Concentration across Different Trophic States in Asian Inland Waters**, ISPRS Journal of Photogrammetry and Remote Sensing, 102, PP. 28–37.
- Moridnejad, A., Abdollahi, H., Alavipanah, S.K., Samani, J.M.V., Moridnejad, O. & Karimi, N., 2015, **Applying Artificial Neural Networks to Estimate Suspended Sediment Concentrations along the Southern Coast of the Caspian Sea Using MODIS Images**, Arabian Journal of Geosciences, 8(2), PP. 891–901.
- Palmer, S.C., Kutser, T. & Hunter, P.D., 2015, **Remote Sensing of Inland Waters: Challenges, Progress and Future Directions**, Remote Sensing of Environment, 157, PP. 1–8.
- Philpot, W. & Ansty, T., 2011, **Analytical Description of Pseudo-Invariant Features (PIFs)**, In Analysis of Multi-temporal Remote Sensing Images (Multi-Temp), 2011 6th International Workshop on the (PP. 53–56), IEEE.
- Song, K., Li, L., Wang, Z., Liu, D., Zhang, B., Xu, J., Du, J., Li, L., Li, S. & Wang, Y., 2012, **Retrieval of Total Suspended Matter (TSM) and Chlorophyll-a (Chl-a) Concentration from Remote-Sensing Data for Drinking Water Resources**, Environmental Monitoring and Assessment, 184(3), PP. 1449–1470.
- Sudheer, K.P., Chaubey, I. & Garg, V., 2006, **Lake Water Quality Assessment from Landsat Thematic Mapper Data Using Neural Network: An Approach to Optimal Band Combination Selection 1**, Journal of the American Water Resources Association, 42(6), PP. 1683–1695.
- Yu, Z., Chen, X., Tian, L., Yuan, X., Liu, H. & Wu, K., 2012, **Remote Sensing Retrieval of Turbidity Near Radial Sand Ridges Area in the South Yellow Sea Using HJ-1A/B CCD Imagery**, Future Control and Automation, PP. 121–127.
- Zeng, G.M., Lu, H.W., Jin, X.C. & Xu, M., 2005, **Assessment of the Water Quality and Nutrition of the Dongting Lake with Wavelet Neural Network [J]**, Journal of Hunan University (Natural Science), 1.