

Monitoring Trophic State of Lake Urmia Using Multiple Linear Regression and Artificial Neural Network Based on Landsat-8 and Sentinel-2 Satellite Images

A. Shamloo¹ and S. Sima^{2*}

Abstract

Water quality management in inland lakes requires continuous monitoring of chlorophyll-a (Chl-a) concentration and trophic state. As a critical variable of eutrophication, concentration of Chl-a in the northern part of the Lake Urmia was modeled using Multiple Linear Regression (MLR) and Artificial Neural Networks (ANN) models developed based on Landsat-8 and Sentinel-2 satellite images. Based on Landsat-8 images both models (ANNLandsat-8, MLRLandsat-8) accurately estimated Chl-a concentration in the north of Lake Urmia, while models based on Sentinel-2 images (MLRSentinel-2 and ANNSentinel-2) showed poor performances. Moreover, the ANN models performed slightly better than MLR models based on both Landsat-8 and Sentinel-2 images. According to the better performance, the optimum ANNlandsat-8 model (with a hidden layer) was used to analyze the spatiotemporal variation of Chl-a concentration and the trophic state index (TSI). In the northern part of the Lake Urmia, analysis of the spatial pattern of Chl-a concentration showed an increase towards the central deeper parts and a decrease towards the causeway. Furthermore, the average concentration of Chl-a and TSI in the northern section of the lake increased significantly from February to July followed by a drop between July to September and then a rise between September and October. Based on the optimum ANNlandsat-8 model, northern Lake Urmia experienced acute mesotrophic conditions in February and September of 2016, and mild eutrophic conditions in July, August, and October.

Keywords: Trophic State, Chlorophyll-a, Carlson Trophic Index, Atmospheric Correction.

Received: May 16, 2022

Accepted: September 24, 2022

پایش سطح تغذیه‌گرایی در دریاچه ارومیه با استفاده از الگوریتم‌های رگرسیون خطی چند متغیره و شبکه عصبی مصنوعی مبتنی بر تصاویر ماهواره‌ای لندست-۸ و سنتینل-۲

امیر سپهر شاملو^۱ و سمیه سیما^{۲*}

چکیده

پایش پیوسته غلظت کلروفیل و تعیین سطح تغذیه‌گرایی در دریاچه‌ها به منظور مدیریت کیفیت آب آن‌ها ضروری است. هدف این پژوهش مدل‌سازی غلظت کلروفیل-آ به عنوان متغیر کلیدی مرتبط با تغذیه‌گرایی در بخش شمالی دریاچه ارومیه با استفاده از تصاویر ماهواره‌های لندست-۸ و سنتینل-۲ و الگوریتم‌های رگرسیون خطی چند متغیره (MLR) و شبکه عصبی مصنوعی (ANN) است. نتایج نشان داد در حالی که هر دو مدل مبتنی بر تصاویر لندست-۸ (ANNLandsat-8 و MLRLandsat-8) از دقت بالایی در پایش غلظت کلروفیل-آ برخوردار بودند، عملکرد مدل‌های منتخب مبتنی بر تصاویر سنتینل-۲ (ANNSentinel-2 و MLRSentinel-2) رضایت بخش نبودند. در هر دو سری مدل‌های کلروفیل-آ مبتنی بر داده‌های لندست-۸ و سنتینل-۲، مدل ANN (با یک لایه مخفی) نسبت به مدل MLR اندکی برتری داشت. با توجه به عملکرد مناسب مدل منتخب ANNLandsat-8 از این مدل برای تحلیل الگوی تغییرات مکانی و زمانی غلظت کلروفیل-آ و سطح تغذیه‌گرایی در شمال دریاچه ارومیه استفاده شد. تحلیل الگوی تغییرات مکانی غلظت کلروفیل-آ در تمامی ماه‌ها، افزایش غلظت به سمت مرکز و نواحی عمیق شمال دریاچه و کاهش به سمت پل میان‌گذر را نشان داد. همچنین، میانگین غلظت کلروفیل-آ و سطح تغذیه‌گرایی در شمال دریاچه، از فوریه تا جولای به صورت قابل توجهی افزایش، از جولای تا سپتامبر کاهش و از سپتامبر تا اکتبر افزایش یافت. نتایج مدل منتخب (ANNLandsat-8)، نشان داد که شمال دریاچه در ماه‌های فوریه و سپتامبر سال ۲۰۱۶ در شرایط مزوتروفیک حاد و در ماه‌های جولای، آگوست و اکتبر در شرایط پوتروفیک خفیف قرار داشته است.

کلمات کلیدی: شرایط مغذی، کلروفیل-آ، شاخص تغذیه‌گرایی کارلسون، تصحیح جوی.

تاریخ دریافت مقاله: ۱۴۰۱/۲/۲۶

تاریخ پذیرش مقاله: ۱۴۰۱/۷/۲

1- M.Sc. Graduate of Engineering and Water Resource Management, Civil & Environmental Engineering Department, Tarbiat Modares University, Tehran, Iran. Email: amirsepehr.shamloo@modares.ac.ir

2- Assistant Professor, Civil & Environmental Engineering Department, Tarbiat Modares University, Tehran, Iran. Email: s.sima@modares.ac.ir

*- Corresponding Author

Dor: [20.1001.1.17352347.1402.19.2.2.9](https://doi.org/10.1001.1.17352347.1402.19.2.2.9)

۱- کارشناس ارشد مهندسی و مدیریت منابع آب، گروه مهندسی آب، دانشکده عمران و محیط زیست، دانشگاه تربیت مدرس.

۲- استادیار گروه مهندسی آب، دانشکده عمران و محیط زیست، دانشگاه تربیت مدرس.

*- نویسنده مسئول

بحث و مناظره (Discussion) در مورد این مقاله تا پایان تابستان ۱۴۰۲ امکانپذیر است.



۱- مقدمه

تغذیه‌گرایی فرایندی است که در آن پهنه آبی، به علت افزایش غلظت مواد مغذی ورودی، تغییر در سطح بهره‌وری را تجربه می‌کند. پدیده تغذیه‌گرایی به شکل طبیعی در پهنه‌های آبی رخ می‌دهد و علت آن افزایش سن پهنه‌های آبی در مقیاس زمانی زمین‌شناسی آن‌ها می‌باشد (Torbick et al., 2008). تغذیه‌گرایی فرهنگی یا انسانی^۱ مطابق با تعریف اتحادیه اروپا، غنی شدن بدنه‌های به وسیله مواد مغذی به ویژه ترکیبات فسفر و نیتروژن است که منجر به تسریع رشد جلبک‌ها و گونه‌های گیاهی شده و در تعادل موجودات و کیفیت آب اختلال نامطلوب ایجاد می‌کند (Directive, 1991). تغذیه‌گرایی اصلی‌ترین مشکل کیفی آب‌های سطحی است. در بین انواع پهنه‌های آبی، دریاچه‌های بسته که عموماً در نقطه انتهایی حوضه آبریز واقع شده‌اند، به علت زمان ماند بیشتر مواد مغذی و گردش محدود جریان، در مقایسه با آب‌های آزاد از خطر بیشتری برای مغذی شدن برخوردارند. از جمله مهم‌ترین تبعات نامطلوب تغذیه‌گرایی می‌توان به: (۱) افزایش زیست توده فیتوپلانکتون و ماکروفیت‌های گیاهی، (۲) افزایش زیست‌توده گونه‌های مصرف‌کننده، (۳) تغییر گونه‌های جلبکی به سمت سمی یا غیرقابل خوردن شدن، (۴) کاهش تنوع گونه‌ها، (۵) افزایش وقوع پدیده‌ی مرگ ماهیان، (۶) کاهش شفافیت آب، (۷) کاهش اکسیژن محلول، (۸) کاهش ارزش‌های زیبایی‌شناختی پهنه‌ی آب و غیره اشاره کرد (Smith and Schindler, 2009). علاوه بر آثار مخرب زیست‌محیطی، تغذیه‌گرایی اثرات نامطلوب اقتصادی متعددی نیز به همراه دارد. از اصلی‌ترین جنبه‌های اقتصادی تغذیه‌گرایی می‌توان به: (۱) افزایش هزینه تصفیه آب، (۲) از دست رفتن ارزش رفاهی و زیان به صنعت گردشگری، (۳) کاهش درآمد فعالیت‌های مربوط به شیلات و غیره اشاره کرد. پدیده تغذیه‌گرایی تنها در اتحادیه اروپا سالانه حدود ۱ میلیارد دلار (Hoagland and Scatista, 2006) و در ایالات متحده آمریکا سالانه حدود ۲/۲ میلیارد دلار (Dodds et al., 2009) زیان اقتصادی را موجب شده است.

تاکنون در مطالعات متعددی برای تعیین کمی سطح تغذیه‌گرایی در پهنه‌های آبی از شاخص تجربی کارلسون (TSI^2) استفاده شده است (Aizaki, 1981; Swanson, 1998; Lin et al., 2022). شاخص تجربی TSI ارائه شده توسط کارلسون عددی پیوسته بین صفر تا ۱۰۰ است و با استفاده از متغیرهای کیفی غلظت کلروفیل-آ، عمق دیسک سشی و غلظت فسفرکل قابل محاسبه است. با توجه به شاخص کارلسون می‌توان پهنه‌های آبی را از نظر سطح تغذیه‌گرایی به چهار دسته کلی الیگوتروفیک، مزوتروفیک، یوتروفیک و هایپرتروفیک

تقسیم کرد. در شرایط الیگوتروفیک ($TSI < 30$)، پهنه آبی شفاف بوده و در تمام طول سال اکسیژن محلول در تمامی لایه‌ها بالا می‌باشد. در شرایط مزوتروفیک خفیف ($30 < TSI < 40$)، دریاچه‌های عمیق همچنان در شرایط الیگوتروفیک می‌باشند. با این حال طی فصل تابستان در دریاچه‌های کم عمق امکان رخ دادن شرایط بی‌هوازی در زیر لایه وجود دارد. در شرایط مزوتروفیک حاد ($40 < TSI < 50$)، آب نسبتاً شفاف می‌باشد. با این وجود طی فصل تابستان امکان رخ دادن شرایط بی‌هوازی در زیر لایه (فارغ از عمق دریاچه) وجود دارد. در شرایط یوتروفیک خفیف ($50 < TSI < 60$)، کاهش شفافیت، شرایط بی‌هوازی در فصل تابستان و مشکلات ماکروفیتی قابل مشاهده می‌باشد. در شرایط یوتروفیک حاد ($60 < TSI < 70$)، غلبه جلبک‌های سبز-آبی، وجود توده جلبکی در سطح آب و مشکلات شدید ماکروفیتی مشهود است. شرایط هایپرتروفیک خفیف ($70 < TSI < 80$)، شکوفایی جلبکی گسترده در سرتاسر تابستان، تراکم بالای ماکروفیت‌ها در بستر و نفوذ محدود نور را موجب می‌شود. در شرایط هایپرتروفیک شدید ($TSI > 80$)، وجود توده جلبکی گسترده، مرگ ماهیان در تابستان و غلبه ماهیان خشن‌تر را می‌توان در پهنه آبی مشاهده کرد (Sharma et al., 2010). علی‌رغم وجود متغیرهای عمق دیسک سشی و غلظت فسفرکل در شاخص کارلسون، کلروفیل-آ را می‌توان محبوب‌ترین متغیر برای تخمین زیست توده فیتوپلانکتون‌ها دانست و علت این موضوع این است که غلظت کلروفیل-آ، مخصوص جلبک‌ها و متناسب با زیست‌توده آن‌ها می‌باشد. این موضوع حتی در صورت حضور ذرات آلی و غیرآلی غیرجلبکی نیز صادق است (Carlson, 1977). بر این اساس می‌توان اصلی‌ترین متغیر برای تخمین سطح تغذیه‌گرایی در پهنه‌های آبی را غلظت کلروفیل-آ دانست.

دریاچه ارومیه بزرگترین دریاچه ایران و دومین دریاچه بزرگ فوق‌شور جهان است (Dehghanipour et al., 2020). علی‌رغم اهمیت بسیار بالا و اکوسیستم بسیار حساس این دریاچه (به واسطه شوری بالای آن) (Jellison and Melack, 2001)، تاکنون مطالعات اندکی به بررسی سطح تغذیه‌گرایی در این دریاچه پرداخته‌اند (Parsinejad et al., 2021). به عنوان نمونه (Azari, 1991)، در مطالعه خود دریاچه ارومیه را دریاچه‌ای با شرایط الیگوتروفیک طبقه‌بندی کرد. Esmaeili et al. (2010) در فواصل جولای ۲۰۰۵ تا فوریه ۲۰۰۶ به صورت ماهانه متغیرهای فسفات، نترات و نیتريت را در دریاچه ارومیه پایش کردند. دامنه تغییرات متغیرهای مذکور به ترتیب ۱۰۴ تا ۸۷۵، ۳۳۰ تا ۵۱۰۴ و ۴ تا ۲۱٫۵ میلی‌گرم بر لیتر ذکر شدند. با این وجود مشخص نیست که اعداد ذکر شده در این مطالعه نشان دهنده

برخوردار بوده و پایش غلظت کلروفیل-آ در آن‌ها دشوارتر است. علت این موضوع این است که بر خلاف آب‌های نوع اول، آب‌های نوع دوم علاوه بر فیتوپلانکتون، حاوی متغیرهای دیگری همچون رسوبات معلق، مواد محلول آلی و مواد تولید شده انسانی هستند (Morel and Prieur, 1977) که در آن غلظت سایر مواد فعال نوری (OAS⁵) با غلظت کلروفیل-آ همبستگی نداشته و در عین حال برهمکنش‌های پیچیده‌ای با این متغیر دارند. برای نمونه وجود غلظت‌های بالای رسوبات معلق، مشخصات طیفی غلظت کلروفیل-آ را پنهان می‌کند (Sváb et al., 2005).

مطالعات تحلیلی انجام شده روی رفتار طیفی آب حاوی کلروفیل-آ نشان می‌دهد که اثر کلروفیل-آ نسبت به آب شفاف و تمیز، منجر به بازتابش کمتر در محدوده‌ی طیفی ۴۰۰ تا ۵۰۰ نانومتر، و بازتابش بیشتر در حداصل ۵۰۰ تا ۹۰۰ نانومتر می‌شود. با توجه به مقادیر حداکثر و حداقل بازتابش طیفی در آب حاوی کلروفیل، محدوده‌های طیفی سبز (حدود ۵۵۰ نانومتر) و لبه‌ی قرمز^۶ (حدود ۷۱۰ نانومتر) برای پایش کلروفیل مناسب شناخته شده‌اند (Jensen, 2011; Watanabe et al., 2015). همچنین، بررسی‌ها نشان می‌دهد که در هر دو آب‌های با و بدون کلروفیل، در اثر افزایش غلظت جامدات معلق، بازتابش در تمام محدوده ۴۰۰ تا ۹۰۰ نانومتر افزایش می‌یابد (Jensen, 2011; Doxaran et al., 2002).

یکی از پرکاربردترین روش‌های تخمین غلظت کلروفیل-آ در آب‌های داخلی، استفاده از نسبت‌های باندی است. نسبت‌های باندی، تأثیرات ایرادیانس و جو بر روی سیگنال‌های دریافت شده توسط سنجنده را کاهش می‌دهند (Dekker and Peters, 1993). به کارگیری نسبت‌های باندی در کنار مدل‌های رگرسیونی، در مطالعات متعددی برای مدل‌سازی غلظت کلروفیل-آ در پهنه‌های آبی داخلی استفاده شده و بعضاً نتایج بسیار مناسبی نیز از خود نشان داده‌اند. در این زمینه می‌توان به نسبت نواحی طیفی سبز و قرمز (Ha et al., 2017a; Hellweger et al., 2004; Wang et al., 2006; Allan et al., 2007; Ha et al., 2017b; Han and Jordan, 2015; Lailia et al., 2005) آبی و سبز (Chavula et al., 2009) و قرمز و مادون قرمز نزدیک (NIR⁷) (Kallio et al., 2001; Kutser et al., 1999; Lins et al., 2017; Strömbeck et al., 2003) اشاره کرد (جدول ۱).

غلظت فسفر و نیتروژن بودند یا اینکه غلظت یون‌های اکسید شده را نمایش می‌دادند. با توجه به غلظت بسیار بالای مواد مغذی پایش شده در مطالعه مذکور، دریاچه ارومیه می‌بایست شرایط هایپرتروفیک را تجربه کرده باشد، حال آنکه به دلیل محدودیت محیطی موجود (به دلیل غلظت بالای شوری)، چنین شرایطی در سطح بهره‌وری دریاچه مشهود نمی‌باشد. در سال ۲۰۰۷ با توجه به پایش متغیر غلظت کلروفیل-آ، دریاچه ارومیه در ماه‌های آپریل، می، آگوست و سپتامبر در شرایط الیگوتروفیک و در ماه‌های ژوئن، جولای، اکتبر و نوامبر در شرایط مزوتروفیک خفیف قرار داشت (Dahesht et al., 2013). میانگین غلظت کلروفیل-آ در دریاچه ارومیه (به عنوان مهم‌ترین شاخص برای تعیین سطح تغذیه‌گرایی) در سال ۲۰۱۶ حدود ۱۰/۱۵ میکروگرم بر لیتر بود (IWPCO, 2018). بر این اساس در سال ۲۰۱۶، دریاچه در شرایط یوتروفیک خفیف قرار داشت. در مطالعه دیگری که در سال ۲۰۱۸ منتشر شد، غلظت کلروفیل-آ در دریاچه ارومیه طی فصول پاییز و زمستان بین ۴ تا بیشتر از ۱۰ میکروگرم بر لیتر متغیر بود. بر این اساس طی فصول مذکور، دریاچه شرایط مزوتروفیک حاد و یوتروفیک خفیف را تجربه کرد (IWPCO, 2018). با توجه به گسسته بودن مطالعات در خصوص پایش سطح تغذیه‌گرایی، تفاوت قابل توجه در سطح تغذیه‌گرایی تعیین شده در مطالعات مختلف و تأثیر تغذیه‌گرایی بر زنجیره غذایی دریاچه و فراوانی آرتیمیا به عنوان گونه با ارزش، پایش و بررسی پیوسته سطح تغذیه‌گرایی در دریاچه ارومیه لازم و ضروری به نظر می‌رسد.

به‌منظور پایش متغیرهای کیفی آب، نیاز به نمونه‌برداری در محل و سپس آنالیزهای آزمایشگاهی می‌باشد. علی‌رغم دقت بسیار بالای نمونه‌برداری در محل، استفاده از این روش‌ها در دریاچه‌های وسیع نیازمند صرف زمان و هزینه نمونه‌برداری بالاست. ضمن اینکه دسترسی دشوار به برخی نواحی باتلاقی و کم عمق دریاچه نیز مانع از نمونه‌برداری و اندازه‌گیری متغیرهای کیفی می‌شود. استفاده از فناوری سنجنش از دور در پایش کیفی منابع آبی نسبت به نمونه‌برداری سنتی، مزایایی دارد که از جمله می‌توان به (۱) کاهش هزینه‌ها، (۲) امکان اخذ داده همزمان از کل سطح دریاچه‌های وسیع، (۳) بررسی تغییرات مکانی-زمانی متغیرهای کیفی، (۴) امکان بررسی چندین بدنه آبی در یک منطقه و (۵) امکان بررسی تاریخچه روندهای متغیرهای کیفی اشاره کرد (Kallio, 2000).

آب‌های نوع دوم^۴ (آب‌های داخلی و ساحلی) نسبت به آب‌های نوع اول^۳ (آب‌های اقیانوسی یا دور از ساحل) از پیچیدگی نوری بالاتری

از بزرگترین دریاچه‌های فوق‌شور جهان می‌باشد. بین سال‌های ۱۹۹۶ تا ۲۰۱۶ میلادی، تراز آب دریاچه ارومیه حدوداً ۸ متر کاهش یافت. طی این مدت مساحت دریاچه از ۵۸۱۶ کیلومتر مربع در سال ۱۹۹۶ به ۱۸۰۲ کیلومتر مربع در سال ۲۰۱۶ رسید (Danesh-Yazdi and Zeinodini et al., 2019). بین سال‌های ۱۹۷۹ تا ۱۹۹۲ پل شهید کلاتری بر روی دریاچه ارومیه ساخته شد (Tarh-e-Noandishan, 2020). وجود این پل بر روی نرخ تبادل جریان بین دو بخش شمالی و جنوبی تأثیر گذاشته (Safavi et al., 2020). تفاوت غلظت شوری در بخش‌های شمالی و جنوبی دریاچه موجب این شده که مشخصات کیفی آب در این دو بخش نیز با یکدیگر متفاوت باشند. علی‌رغم غلظت بسیار بالای فسفرکل، همچنان فسفر عامل محدودکننده تغذیه‌گرایی (عنصر کلیدی در تعیین شرایط تغذیه‌گرایی) در دریاچه ارومیه است که علت این موضوع را می‌توان غلظت بسیار بالاتر نیتروژن کل نسبت به فسفرکل در دریاچه دانست (IWPCO, 2018). همچنین با وجود غلظت بسیار بالای فسفر در دریاچه ارومیه، شرایط هایپرتروفیک در دریاچه مشاهده نمی‌شود که این موضوع را می‌توان ناشی از محدودیت محیطی شدید شوری و امکان حضور تنها جنس فیتوپلانکتونی *Dunaliella* دانست. با شیرین‌تر شدن آب (در اثر افزایش تراز آب دریاچه) امکان رخ دادن شکوفایی فیتوپلانکتونی در دریاچه بسیار محتمل است. لازم به ذکر است که در حال حاضر در فصول گرم سال شکوفایی فیتوپلانکتونی در دریاچه رخ می‌دهد. همانند سایر پهنه‌های آبی با استرس شدید محیطی نظیر بحرالमित و دریاچه بزرگ آمریکا (GSL^{16}), در دریاچه ارومیه نیز تنها یک دوره شکوفایی فیتوپلانکتونی رخ می‌دهد (IWPCO, 2018).

۲-۲- داده‌های مورد استفاده

۲-۲-۱- داده‌های کیفی آب

در این مطالعه از داده‌های موجود در گزارش مطالعات کیفی و لیمنولوژی دریاچه ارومیه (IWPCO, 2018) استفاده شد. مطالعه مذکور شامل یک سال نمونه‌برداری ماهیانه (از فوریه ۲۰۱۶ تا فوریه ۲۰۱۷) از شش ایستگاه (چهار ایستگاه در شمال دریاچه، یک ایستگاه در مجاورت پل میانگذر و یک ایستگاه در جنوب دریاچه) در سه عمق سطحی، میانی و مجاور بستر (به ترتیب اعماق ۲۰، ۵۰ و ۱۰۰ سانتی‌متری از سطح آب) می‌باشد (شکل ۱). در این برنامه نمونه‌برداری، بیشتر از ۴۰ متغیر فیزیکی، شیمیایی و زیستی از دریاچه

مدل‌های مبتنی بر یادگیری ماشین نیز در مطالعات متعددی برای پیش‌بینی غلظت کلروفیل-آ بکار گرفته شده‌اند. ورودی این مدل‌های باندهای طیفی (Guo et al., 2016; Sudheer et al., 2006)، ترکیبات باندی (Zhang et al., 2020) و یا هر دوی این موارد بودند (Prasad et al., 2020; Saberioon et al., 2020). رگرسیون خطی چند متغیره (MLR^8) یکی از پرکاربردترین و در عین حال نیز ساده‌ترین مدل‌های یادگیری ماشین برای پیش‌بینی غلظت کلروفیل-آ در آب‌های نوع دوم (آب‌های داخلی و ساحلی) بوده است (Alparlan et al., 2007; Giardino et al., 2001; Karaoui et al., 2019; Wang et al., 2006). از دیگر مدل‌های پرکاربرد یادگیری ماشین در تخمین غلظت کلروفیل-آ می‌توان به مدل‌های شبکه عصبی مصنوعی (ANN^9) (Guo et al., 2016; Prasad et al., 2020; Sudheer et al., 2006)، رگرسیون ماشین بردار پشتیبان (SVR^{10}) (Zhang et al., 2020) و کوپیسیت^{۱۱} (Saberioon et al., 2020) اشاره کرد (جدول ۱). بررسی‌ها نشان می‌دهد که با توجه به دسترسی رایگان و قدرت تفکیک مکانی به نسبت بالای تصاویر دو ماهواره لندست-۸ و سنتینل-۲، استفاده از داده‌های این دو سنجنده در مطالعات کیفی پهنه‌های آبی داخلی در نقاط مختلف جهان به ویژه در سالهای اخیر رو به گسترش بوده است.

مهم‌ترین اهداف پژوهش حاضر عبارت از: (۱) بررسی قابلیت تصاویر لندست-۸ و سنتینل-۲ در مدل‌سازی سطح تغذیه‌گرایی در بخش شمالی دریاچه ارومیه، (۲) بررسی ساختار و ترکیب پهنه متغیرهای ورودی به مدل شبکه‌ی عصبی مصنوعی پیش‌بینی غلظت کلروفیل-آ، (۳) مقایسه عملکرد مدل‌های رگرسیون خطی چند متغیره و شبکه عصبی مصنوعی در مدل‌سازی غلظت کلروفیل-آ در بخش شمالی دریاچه ارومیه و (۴) بررسی عملکرد مدل منتخب پیش‌بینی غلظت کلروفیل-آ در پیش‌بینی الگوهای زمانی و مکانی غلظت کلروفیل-آ و سطح تغذیه‌گرایی در بخش شمالی دریاچه ارومیه می‌باشند. پژوهش حاضر از معدود مطالعاتی است که روی توسعه مدل‌های پیش‌بینی غلظت کلروفیل-آ و سطح تغذیه‌گرایی در دریاچه‌های شور با تلفیق روش‌های آماری داده محور و تصاویر ماهواره‌ای با قدرت تفکیک مکانی بالا (به ویژه سنتینل-۲) انجام شده است.

۲- روش انجام کار و مطالعه موردی

۲-۱- منطقه مورد مطالعه

دریاچه ارومیه با بیشترین مساحت ثبت شده ۵۷۰۰ کیلومتر مربع (در سال ۱۹۹۶) (Alipour, 2006) در شمال غربی ایران واقع شده و یکی

ارومیه برداشت شد که از جمله‌ی این متغیرها می‌توان به غلظت کلروفیل-آ اشاره کرد. کلیه آنالیزهای آزمایشگاهی متغیرها بر اساس استانداردهای معتبر ملی و بین‌المللی آب‌های شور انجام پذیرفت. در نمونه‌برداری مذکور برای تعیین غلظت کلروفیل-آ از دو روش اسپکتروفتومتری و ¹⁷HPLC استفاده شد.

Table 1- Review of some chlorophyll-a monitoring studies using remote sensing data
جدول ۱- مرور برخی از مطالعات پایش غلظت کلروفیل-آ با استفاده از داده‌های سنجنش از دوری

Reference	Sensor	Data Range (µg/l)	Algorithms/Bands	Modeling technique	Performance	Study Area	Country
(Hellweger et al., 2004)	TM	5 - 50	Green to Red band ratio	LLR ¹²	R ² = 0.78	New York Harbor	USA
(Wang et al., 2006)		66 - 188.59		LR	R ² = 0.53	Reelfoot Lake	USA
(Ha et al., 2017a)	OLI	42 - 258	Blue to Red band ratio	ER ¹³	MSE = 0.2 µg/l R ² = 0.77	West Lake	Vietnam
(Han and Jordan, 2005)	ETM+	1.14 - 23.23		LT-LR ¹⁴	SE = 1.55 µg/l R ² = 0.67	Pensacola Bay	USA
(Allan et al., 2007)		-		LLR	R ² = 0.83 - 0.91	Rotorua Lakes (12 Lakes)	New Zealand
(LAILIA et al., 2015)	OLI	254 - 459		PR ¹⁵	RMSE = 51.94 µg/l R ² = 0.59	Poteran island	Indonesia
(Ha et al., 2017b)	MSI	1.58 - 23.2		ER	SE = 0.14 µg/l R ² = 0.68	Ba Be Lake	Vietnam
(Chavula et al., 2009)	MODIS	0.1 - 0.4	Blue to Green band ratio	LR	R ² = 0.58	Malawi Lake	Malawi
(Giardino et al., 2001)	TM	5.5 - 7.7	R485, R560	MLR	R ² = 0.99 RMSE = 0.054 µg/l	Lake Iseo	Italy
(Wang et al., 2006)		66 - 188.59	R560, R660		R ² = 0.705	Reelfoot Lake	USA
(Alparslan et al., 2007)	ETM+	1.2 - 2.5	R485, R560, R660, R830		SE = 0.48 µg/l R ² = 0.58	ömerli dam	Turkey
(Karaoui et al., 2019)	MSI	0.54 - 1.89	R560, R665, R705, R740		R ² = 0.78 RMSE = 0.03 µg/l	Bin El Ouidane Reservoir	Morocco
(Sudheer et al., 2006)	TM	-	R485, R560		R ² = 0.53 RMSE = 12.5 µg/l	Beaver Reservoir	USA
(Guo et al., 2016)	OLI	-	R440, R480, R560, R665, R865, R1610, R2200	ANN	MSE = 410.17 µg/l, R ² = 0.95	Haihe River	China
(Prasad et al., 2020)		2.05 - 82.1	R865, R480/R665, R560/R665, R865 / R480, R865 / R665		R ² = 0.97 RMSE = 1.52 µg/l	Gang River	India
(Saberion et al., 2020)	MSI	3 - 672.58	19 Spectral indices + 10 MSI bands (except B1, B3, B8a)	Cubist	R ² = 0.85 RMSE = 46.3 µg/l	14 Lakes	Central Europe and Czech Republic

۲-۲-۲- تصاویر ماهواره‌ای

تصاویر سطح اول لندست-۸ (Landsat-8 Level-1) از طریق سامانه اینترنتی سازمان زمین‌شناسی ایالات متحده به نشانی <https://earthexplorer.usgs.gov/> و تصاویر Level-1C سنتینل-۲ نیز از طریق سامانه اینترنتی <https://scihub.copernicus.eu> دانلود شده و مورد استفاده قرار گرفتند. در این مطالعه سعی شد تا از تصاویری با پوشش ابری کم و ناچیز (کمتر از ۱۵ درصد) استفاده شود. همچنین حداکثر فاصله زمانی بین داده‌های زمینی و تصاویر ماهواره‌ای، پنج روز در نظر گرفته شد (شکل ۳). در ارتباط با لندست-۸ در ماه نوامبر و در ارتباط با سنتینل-۲ در ماه‌های آپریل و ژانویه (سال ۲۰۱۷) تنها تصویر بخش جنوبی دریاچه موجود است. بنابراین در این ماه‌ها تنها داده‌های مربوط به ایستگاه نمونه‌برداری شماره ۵ (S5) واقع در پل میان‌گذر) موجود می‌باشد.

۲-۳- پردازش تصاویر ماهواره‌ای

در این مطالعه برای انجام تصحیحات رادیومتریکی و جوی تصاویر لندست-۸ و سنتینل-۲، از الگوریتم ACOLITE استفاده شد که یک الگوریتم تصحیح جوی مختص پهنه‌های آبی است (Ilori et al., 2019). ACOLITE یک الگوریتم تصحیح جوی مبتنی بر تصویر می‌باشد که با استفاده از روش توسعه داده شده در مطالعه Gordon and Wang (1994)، اقدام به تصحیح پخش ناشی از ذرات معلق^{۱۸} جو کرده و تابش خروجی از ستون آب (L_w) را تخمین می‌زند. این الگوریتم بازتابش ناشی از ذرات معلق را با تعیین نوع آن از نسبت

در این مطالعه برای مدل‌سازی غلظت کلروفیل-آ از داده‌های نمونه‌برداری ۲۰ سانتی متری آب سطح آبی استفاده شد. شکل ۲ سری زمانی دامنه تغییرات غلظت کلروفیل-آ در ایستگاه‌های نمونه‌برداری و همچنین مقادیر حداقل، حداکثر، میانگین و انحراف معیار این متغیر (در عمق سطحی) را نشان می‌دهد.

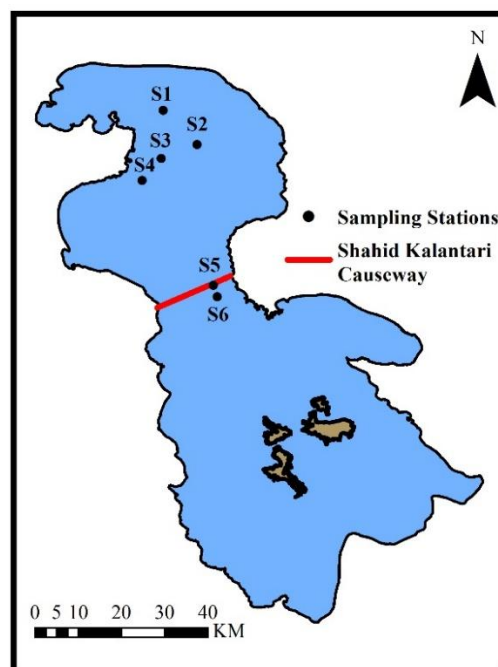


Fig. 1- Geographical location of sampling stations in Lake Urmia

شکل ۱- موقعیت جغرافیایی ایستگاه‌های نمونه‌برداری در دریاچه ارومیه

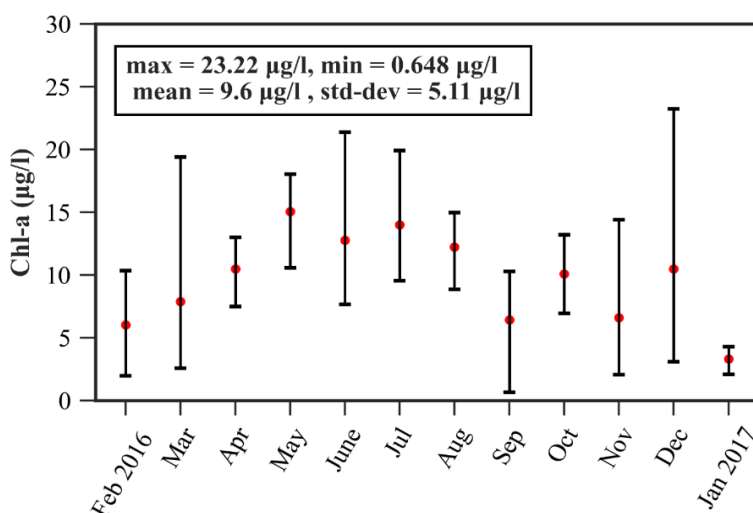


Fig. 2- Time series of chlorophyll-a concentration changes in Lake Urmia sampling stations

شکل ۲- سری زمانی دامنه تغییرات غلظت کلروفیل-آ در ایستگاه‌های نمونه‌برداری دریاچه ارومیه




Fig. 3- The number of ground data almost simultaneously with the passage of Landsat-8 and Sentinel-2 satellites

شکل ۳- تعداد داده‌های زمینی تقریباً همزمان با گذر ماهواره‌های لندست-۸ و سنتینل-۲

۲-۴- شناسایی و حذف داده‌های پرت

در مسائل کیفی آب، تشخیص داده‌های پرت^{۲۳} موضوعی بسیار دشوار و چالش برانگیز می‌باشد. در این نوع مسائل امکان این وجود دارد که حتی با وجود تغییر مکانی نه چندان زیاد، مقدار متغیر کیفی تغییرات قابل توجهی را از خود نشان دهد بی‌آنکه خطایی در پایش متغیر صورت گرفته باشد. با این وجود، در این پژوهش تمامی مدل‌سازی‌ها یکبار برای داده‌ها پیش از حذف نمونه‌های پرت و یکبار برای داده‌ها پس از حذف نمونه‌های پرت صورت پذیرفت و نتایج آن‌ها با یکدیگر مقایسه شد. برای حذف داده‌های پرت از یک روش مبتنی بر فاصله که توسط Ramaswamy et al. (2000) توسعه یافت، استفاده شد. در این روش دو پارامتر اصلی k و n وجود دارند که به ترتیب تعداد نزدیک‌ترین همسایه به هر داده و تعداد داده‌های پرت را نشان می‌دهند. در این مطالعه براساس سعی و خطاهای انجام شده، عدد ۱۰ برای پارامتر k انتخاب شد. همچنین، برای داده‌های مربوط به تصاویر لندست-۸ و سنتینل-۲ به ترتیب اعداد ۴ و ۶ برای پارامتر n مناسب تشخیص داده شدند. جدول ۲ جزئیات آماری داده‌های غلظت کلروفیل-آ تقریباً همزمان با تصاویر ماهواره‌ای مورد استفاده (پیش و پس از حذف داده‌های پرت) در این پژوهش را نشان می‌دهد.

بازتابش‌ها در دو باند مادون قرمز موج کوتاه (SWIR¹⁹) (که در آن بازتابش بر روی پیکسل‌های آب را می‌توان صفر فرض کرد) تخمین می‌زند. بر اساس این فرض، الگوریتم ACOLITE قادر به بازیابی بازتابش خروجی از سطح آب در هر دو محدوده مرئی و NIR می‌باشد (Ilori et al., 2019). ACOLITE به صورت پیش‌فرض تصحیح جوی را با استفاده از روش برازش طیف تاریک (DSF²⁰) انجام می‌دهد، اما می‌توان آن را به روش برون‌یابی نمایی (EXP²¹) نیز انجام داد (Vanhellemont and Ruddick, 2014). در مطالعه حاضر برای اعمال الگوریتم ACOLITE از کد پایتون (acolite_py_win_20190326.0) استفاده شد و از روش پیش‌فرض یعنی DSF استفاده و تصاویر لندست-۸ و سنتینل-۲ تصحیح جوی شدند.

پس از اعمال تصحیحات جوی، تصاویر سنتینل-۲ به دلیل دارا بودن باندهای طیفی مرئی و مادون قرمز با قدرت تفکیک مکانی متفاوت (۱۰ و ۲۰ متر) نیاز به بازنمونه‌برداری داشتند. بدین منظور از روش بازنمونه‌برداری نزدیک‌ترین همسایه^{۲۲} استفاده شد و توان تفکیک مکانی تمامی باندها به ۲۰ متر تغییر یافت. در انتها نیز یک فیلتر میانگین ۳×۳ پیکسل بر روی تصاویر هر دو ماهواره اعمال و مقادیر بازتابش سطح استخراج شدند. علت استفاده از این فیلتر کاهش نویزها و تعدیل اختلاف ناشی از موقعیت مکانی واقعی ایستگاه پایش و پیکسل معادل آن در تصاویر ماهواره‌ای می‌باشد.

Table 2- Details of chlorophyll-a concentration of the northern Lake Urmia in 2016 corresponding to the satellite images used in the present study

جدول ۲- جزئیات داده‌های غلظت کلروفیل-ا ناحیه شمالی دریاچه ارومیه در دوره مورد بررسی در سال ۲۰۱۶، متناظر با تصاویر ماهواره‌ای مورد استفاده در مطالعه حاضر

Sensor	Data filtering	Number of paired data	Chl-a statistics [$\mu\text{g l}^{-1}$]			
			Mean	Max	Min	Std Dev
Landsat 8-OLI	Before Removing Outliers	25	10.03	19.92	0.65	4.68
	After Removing Outliers	21	10.21	18.50	0.65	4
Sentinel 2-MSI	Before Removing Outliers	41	9.88	23.22	0.65	5.13
	After Removing Outliers	35	9.78	23.22	0.65	5.01

۲-۵- رگرسیون خطی چندمتغیره

در مدل MLR مقدار متغیر وابسته یا همان متغیر هدف (بردار y)، برحسب متغیرهای مستقل یا همان متغیرهای ورودی به مدل (ماتریس X) و بر اساس برآورد بردار ضرایب ثابت مرتبط با ویژگی‌ها و مقدار ثابت رگرسیون (بردار Θ)، محاسبه می‌شود (رابطه ۱).

$$y = h_{\Theta}(x) = \Theta_0 + \Theta_1 x_1 + \Theta_2 x_2 + \dots + \Theta_n x_n = \Theta^T X \quad (1)$$

به منظور برآورد مقادیر بردار ضرایب ثابت و مقدار ثابت رگرسیون، نیاز به حداقل کردن تابع هزینه^{۲۴} است. تابع هزینه مطابق با رابطه با رابطه ۲ محاسبه می‌شود. در این رابطه $y^{(i)}$ و $h_{\Theta}(x^{(i)})$ به ترتیب مقدار واقعی داده i ام و مقدار تخمین زده شده داده i ام بر اساس مدل MLR ساخته شده می‌باشند. لازم به ذکر است که m و n به ترتیب تعداد داده‌های مورد استفاده برای مدل‌سازی و تعداد ویژگی‌ها را نشان می‌دهند. همچنین، در این مطالعه برای بهینه‌سازی مقادیر ضرایب ثابت مرتبط با ویژگی‌ها و مقدار ثابت رگرسیون (بردار Θ) از الگوریتم گرادینت کاهشی^{۲۵} استفاده شد.

$$J(\Theta) = \sum_{i=1}^m \frac{1}{2} (y^{(i)} - h_{\Theta}(x^{(i)}))^2 \quad (2)$$

در این مطالعه برای مدل‌سازی غلظت کلروفیل-ا از باندهای B1 تا B5 تصاویر لندست-۸ و باندهای B1 تا B8a تصاویر سنتینل-۲ استفاده شد. این باندها منطبق بر باندهای حساس به کلروفیل-ا در آب (باندهای سبز، قرمز و لبه قرمز) هستند. به منظور انتخاب بهترین ترکیب ورودی از باندها به مدل MLR، کلیه ترکیبات ممکن و منحصر به فرد باندهای طیفی بررسی شده (برای تصاویر لندست-۸ و سنتینل-۲ به ترتیب ۳۱ و ۵۱۱ ترکیب باندی مختلف) و با توجه به عملکرد آن‌ها، ترکیبی که بالاترین دقت را از خود نشان داد، به عنوان ترکیب باندی منتخب انتخاب شد.

۲-۶- شبکه عصبی مصنوعی

در مطالعه حاضر از یک مدل شبکه‌ی عصبی پیش‌خور^{۲۶} یا همان پرسپترون چندلایه (MLP^{۲۷}) که از الگوریتم پس انتشار خطا (BP^{۲۸}) برای آموزش بهره می‌برد، استفاده شده است. با توجه به سعی و خطاهای انجام شده، در تمامی شبکه‌های عصبی ساخته شده در این پژوهش، برای تخمین غلظت کلروفیل-ا تنها از یک لایه مخفی استفاده شد (شکل ۴). در این شکل، B_i باندهای ورودی به شبکه را نشان می‌دهد. لازم به ذکر است که حداکثر مقدار i در سنجنده‌های OLI و MSI به ترتیب ۵ و ۹ تعیین شدند. همچنین ز نشان‌دهنده نورون‌های موجود در لایه مخفی می‌باشد. بر اساس سعی و خطاهای صورت گرفته، حداکثر مقدار z برابر با ۵۰ تعیین شد. در ادامه مقادیر نورون‌ها مطابق با رابطه ۳ مقداردهی شده و سپس با توجه به یک تابع فعالیت^{۲۹} غیرخطی (تابع سیگموئید)، مقدار خروجی از هر نورون تعیین گردید (رابطه ۴). در انتها نیز با توجه به رابطه ۵، مقدار متغیر غلظت کلروفیل-ا بر اساس مدل ANN تخمین زده شد. لازم به ذکر است که در مرحله یادگیری شبکه‌ی عصبی، هدف پیدا کردن مقادیر مقادیر W_{ij} ، W_j و b_j و ϵ بوده و تابع هزینه مورد استفاده در این شبکه نیز مطابق با رابطه ۲ تعیین شد.

در این مطالعه با توجه به تأثیر بسیار زیاد انتخاب مجموعه ویژگی‌های ورودی بر روی دقت مدل، از سه ترکیب متفاوت از باندهای مربوط به هر سنجنده به عنوان ورودی مدل ANN برای تخمین غلظت کلروفیل-ا استفاده شد. ترکیب باندی اول شامل کلیه باندهای مربوط به هر سنجنده بود (برای تصاویر لندست-۸ و سنتینل-۲ به ترتیب تمامی باندهای B1 تا B5 و B1 تا B8a). ترکیب باندی دوم هر سنجنده برابر با ترکیب باندی مدل منتخب MLR مربوط به همان سنجنده انتخاب شد. برای انتخاب ترکیب باندی سوم مربوط به هر سنجنده در ابتدا با توجه به مقادیر پیش فرض نرخ یادگیری، مومنتوم و تعداد چرخه آموزشی^{۳۰} ($\alpha = 0.01$ ، $m = 0.9$ و $tc = 200$) که α ، m

۷-۲- روش اعتبارسنجی مدل‌ها

برای ارزیابی عملکرد مدل‌ها از روش LOOCV³² استفاده شد. این روش یک حالت ویژه و خاص از روش اعتبارسنجی تقاطعی^{۳۳} است که در آن تعداد دسته‌ها^{۳۴} برابر با تعداد نمونه‌ها در مجموعه داده می‌باشد. در این روش ابتدا داده اول به عنوان داده‌ی آزمایشی و باقی داده‌ها به عنوان داده‌ی آموزشی، مدل آموزش می‌بیند و سپس با استفاده از داده آزمایشی، خطای مربوط به پیش‌بینی داده اول محاسبه می‌شود (E_1). در گام بعد داده دوم به عنوان داده‌ی آزمایشی و باقی داده‌ها به عنوان داده آموزشی تعیین و مراحل ذکر شده در گام قبل عیناً تکرار و خطای مربوط به پیش‌بینی داده دوم محاسبه می‌شود (E_2). در روش LOOCV مراحل مذکور برای کلیه داده‌ها تکرار شده و میانگین خطاهای محاسبه شده به عنوان خطای مدل شناخته می‌شود (رابطه ۶). در رابطه ۶، E_i و m به ترتیب به خطای مدل، خطای مربوط به پیش‌بینی داده‌ی i ام و تعداد کل داده‌ها اشاره دارند.

$$E = \frac{1}{m} \sum_{i=1}^m E_i \quad (6)$$

هنگامی که تعداد نمونه‌ها در مجموعه داده کم باشند، بهتر است تا برای حصول نتایج دقیق‌تر از عملکرد مدل، از روش LOOCV برای اعتبارسنجی استفاده شود (Wong, 2015). این روش مخصوصاً در شرایطی که تعداد داده‌های موجود محدود است (نظیر مطالعه حاضر) و به کارگیری اعتبارسنجی به شیوه معمول (تقسیم داده‌ها به دو بخش داده‌های آموزشی و آزمایشی) منجر به از دست رفتن بخش قابل توجهی از داده‌ها می‌شود، توصیه می‌شود (Cawley and Talbot, 2003).

۸-۲- معیارهای ارزیابی عملکرد مدل‌ها

برای بررسی عملکرد مدل‌سازی‌های انجام شده از سه معیار خطای R^2 ، $R^2_{Adjusted}$ و RMSE به عنوان سه معیار پرکاربرد در مسائل مربوط به رگرسیون استفاده شد (روابط ۷ تا ۹). در روابط زیر X_i ، Y_i ، \bar{X} و \bar{Y} به ترتیب مقدار مشاهداتی شده داده i ام، مقدار مدل‌سازی شده داده i ام، متوسط مقادیر مشاهداتی داده‌ها و متوسط مقادیر مدل‌سازی شده داده‌ها هستند. همچنین m و p به ترتیب تعداد کل نمونه‌ها و تعداد ویژگی‌های مورد استفاده در مدل را نشان می‌دهند.

$$R^2 = \frac{(\sum (X_i - \bar{X})(Y_i - \bar{Y}))^2}{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2} \quad (7)$$

و tc به ترتیب نرخ یادگیری، مومنتوم و تعداد چرخه‌ی آموزشی هستند) و ۱۱ مقدار مختلف $\{1, 5, 10, 15, \dots, 50\}$ برای اندازه لایه‌ی مخفی، کلیه‌ی ترکیبات ممکن و منحصر به فرد از باندهای طیفی بررسی شده (برای تصاویر لندست-۸ و سنتینل-۲ به ترتیب ۳۴۱ و ۵۶۲۱ ترکیب باندی مختلف) و با توجه به عملکرد آن‌ها، ترکیبی که بالاترین دقت را از خود نشان داد، به عنوان ترکیب باندی منتخب انتخاب شد.

پس از تعیین مجموعه ویژگی‌های ورودی مربوط به هر سنجنده برای تخمین غلظت کلروفیل- a (برای هر سنجنده، سه ترکیب باندی متفاوت)، اقدام به آموزش شبکه‌های عصبی مورد نظر از طریق تنظیم مقادیر ابرپارامتر^{۳۱}های آن‌ها شد. مهم‌ترین ابرپارامترهای مورد نظر در این مطالعه، اندازه‌ی لایه مخفی (تعداد نورون‌های موجود در لایه مخفی)، نرخ یادگیری، مومنتوم و تعداد چرخه آموزشی بودند. برای تعیین اندازه لایه مخفی با توجه به مقادیر پیش‌فرض اولیه ($\alpha = 0.01$ ، $m = 0.9$ و $tc = 200$) اعداد بین ۱ تا ۵۰ مورد آزمون قرار گرفته و بهترین مقدار برای آن تعیین گردید. در ادامه و پس از تشخیص اندازه مناسب لایه‌ی مخفی، اقدام به تعیین مقدار بهینه تعداد چرخه آموزشی شد. در انتها نیز به صورت توأمان مقادیر مناسب برای نرخ یادگیری و مومنتوم تعیین شدند.

$$I_j = \sum_i W_{ij} B_i + b_j \quad (3)$$

$$O_j = \frac{1}{1 + \exp(-I_j)} \quad (4)$$

$$Chl-a = \sum_j W_j O_j + \varepsilon \quad (5)$$




Fig. 4- ANN model structure used in this study
شکل ۴- ساختار مدل شبکه عصبی مورد استفاده در این

پژوهش

۳- نتایج و تحلیل نتایج

۳-۱- مدل رگرسیون خطی چندمتغیره

مدل‌های منتخب MLR مبتنی بر تصاویر لندست-۸ ساخته شده با داده‌های پیش و پس از حذف داده‌های پرت به ترتیب عملکردهای متوسط ($R^2 = 0.36$ و $RMSE = 3.85 \mu g l^{-1}$) و بسیار خوبی ($R^2 = 0.74$ و $RMSE = 2.04 \mu g l^{-1}$) را در مدل‌سازی غلظت کلروفیل-آ در شمال دریاچه ارومیه از خود نشان دادند (جدول ۳). مدل منتخب MLR مبتنی بر داده‌های لندست-۸ پیش از حذف داده‌های پرت از باندهای B2 و B5 (باندهای آبی و NIR) برای ساخت مدل تخمین‌زننده غلظت کلروفیل-آ استفاده کرده و افزون بر آن در مدل مذکور با افزایش بازتابش در باند آبی، غلظت کلروفیل-آ کاهش و با افزایش بازتابش در باند NIR، غلظت کلروفیل-آ، افزایش یافت (رابطه ۱۱). از طرف دیگر مدل منتخب MLR مبتنی بر داده‌های لندست-۸ پس از حذف نمونه‌های پرت از باندهای B2، B4 و B5 (آبی، قرمز و NIR) برای تخمین غلظت کلروفیل-آ استفاده کرد. در مدل مذکور با افزایش بازتابش در باندهای آبی و قرمز، غلظت کلروفیل-آ کاهش و با افزایش بازتابش در باند NIR، غلظت کلروفیل-آ افزایش یافت (رابطه ۱۲).

$$RMSE = \sqrt{\frac{1}{m} \sum_1^m (Y_i - X_i)^2} \quad (8)$$

$$R_{Adjusted}^2 = 1 - \frac{(1 - R^2)(m-1)}{m-p-1} \quad (9)$$

۹-۲- تعیین سطح تغذیه گرای

برای محاسبه سطح تغذیه‌گرایی پس از ارزیابی، اعتبارسنجی و انتخاب مدل منتخب برای تخمین متغیر غلظت کلروفیل-آ، از شاخص کارلسون TSI استفاده شد (Carlson, 1977). این شاخص مطابق با رابطه‌ی ۱۰ محاسبه شده و عددی پیوسته بین صفر تا ۱۰۰ می‌باشد.

$$TSI (Chl-a) = 30.56 + 9.81 \ln (Chl-a) \quad (10)$$

۱۰-۲- جداسازی سطح پهنه آبی

در این مطالعه برای جداسازی سطح پهنه‌ی آبی شمال دریاچه ارومیه (به منظور تولید نقشه‌های کیفی)، از نتایج پژوهش Darzi and Sima (2021) استفاده شد. آن‌ها در پژوهش خود با توجه به عملکرد مناسب شاخص $NDWI^{35}$ در جداسازی سطح آب در دریاچه ارومیه، از روش حد آستانه‌گذاری روی این شاخص استفاده کردند.

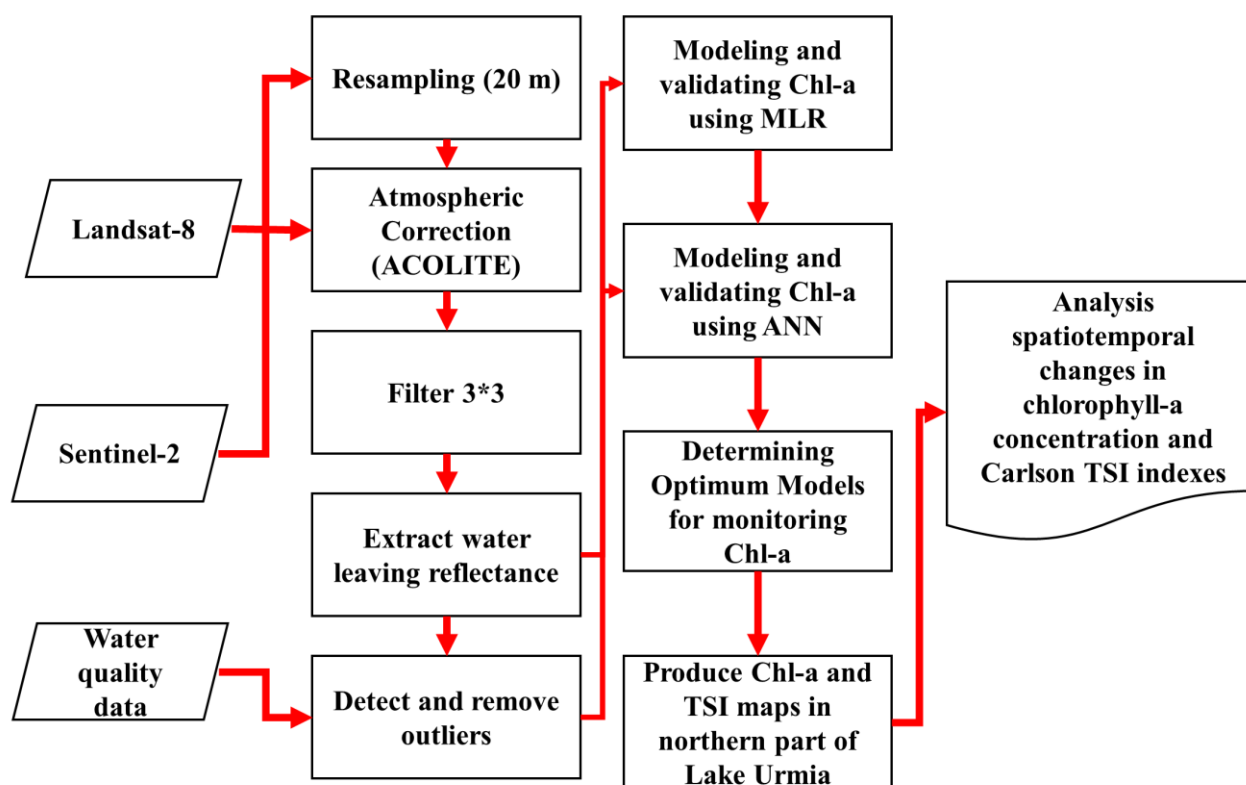


Fig. 5- Work process flowchart

شکل ۵- روندنمای مراحل انجام کار

کوچکتر از ۱۰ میکروگرم بر لیتر و کم‌برآورد در بازه‌ی بزرگتر از ۱۰ میکروگرم بر لیتر را مشاهده کرد (شکل a-۶). از طرف دیگر مدل منتخب MLR مبتنی بر داده‌های لندست-۸ پس از حذف نمونه‌های پرت در تمام بازه ۰ تا ۲۰ میکروگرم بر لیتر عملکرد نسبتاً خوبی را از خود نشان داد. با این حال در بازه کوچکتر از ۱۰ میکروگرم بر لیتر اندکی بیش برآورد و در بازه بزرگتر از ۱۰ میکروگرم بر لیتر اندکی کم‌برآورد مشهود بود (شکل b-۶). در مدل‌های منتخب MLR مبتنی بر تصاویر لندست-۸، حذف داده‌های پرت به طرز قابل توجهی دقت مدل تخمین‌زننده غلظت کلروفیل-آ را افزایش داد.

با توجه نمودارهای پراکندگی مقادیر واقعی و مدل‌سازی شده‌ی غلظت کلروفیل-آ مبتنی بر مدل‌های منتخب MLR مبتنی بر داده‌های سنتینل-۲ پیش و پس از حذف داده‌های پرت می‌توان به وضوح بیش‌برآورد و کم‌برآورد قابل توجه را به ترتیب در بازه کوچکتر از ۱۰ میکروگرم بر لیتر و بزرگتر از ۱۰ میکروگرم بر لیتر مشاهده کرد (شکل‌های c-۶ و d-۶). علت این امر این است که بیشتر داده‌های مورد استفاده در مدل‌سازی حول و حوش میانگین مقدار غلظت کلروفیل-آ هستند (برای داده‌های لندست-۸ و سنتینل-۲ مقدار میانگین غلظت کلروفیل-آ تقریباً ۱۰ میکروگرم بر لیتر می‌باشد). بنابراین در بازه کمتر از ۱۰ تا حدودی بیش برآورد و در بازه بزرگتر از ۱۰ تا حدودی کم برآورد (به منظور میل به میانگین مقادیر) مشهود است که با آموزش مدل با طیف وسیعتری از مقادیر داده‌های مشاهداتی دقت مدل را می‌توان بهبود داد. در مدل‌های منتخب MLR مبتنی بر تصاویر سنتینل-۲ بر خلاف لندست-۸، حذف داده‌های پرت به طرز قابل توجهی دقت مدل تخمین‌زننده غلظت کلروفیل-آ را افزایش نداد.

مدل‌های منتخب MLR مبتنی بر تصاویر سنتینل-۲ ساخته شده با داده‌های پیش و پس از حذف داده‌های پرت به ترتیب عملکردهای نه چندان رضایت‌بخش ($R^2 = 0.23$ و $RMSE = 4.52 \mu g l^{-1}$) و متوسطی ($R^2 = 0.34$ و $RMSE = 4.52 \mu g l^{-1}$) را در مدل‌سازی غلظت کلروفیل-آ در شمال دریاچه ارومیه از خود نشان دادند (جدول ۳). مدل منتخب MLR مبتنی بر داده‌های سنتینل-۲ پیش از حذف داده‌های پرت از باندهای B2 و B3 (باندهای آبی و سبز) برای ساخت مدل تخمین‌زننده غلظت کلروفیل-آ استفاده کرده و افزون بر آن در مدل مذکور با افزایش بازتابش در باند آبی، غلظت کلروفیل-آ کاهش و با افزایش بازتابش در باند سبز، غلظت کلروفیل-آ، افزایش یافت (رابطه ۱۳). از طرف دیگر مدل منتخب MLR مبتنی بر داده‌های سنتینل-۲ پس از حذف نمونه‌های پرت از باندهای B2، B3، B5، B6 و B8a برای تخمین غلظت کلروفیل-آ استفاده کرد. در مدل مذکور با افزایش بازتابش در باندهای B2، B5 و B8a، غلظت کلروفیل-آ کاهش و با افزایش بازتابش در باندهای B3 و B6، غلظت کلروفیل-آ افزایش یافت (رابطه ۱۴).

$$Chl-a (\mu g l^{-1})_{Landsat-8(before\ remove\ outliers)} = -248.948 B2 + 306.584 B5 + 11.621 \quad (11)$$

$$Chl-a (\mu g l^{-1})_{Landsat-8(after\ remove\ outliers)} = -358.07 B2 - 215.983 B4 + 847.498 B5 + 20.576 \quad (12)$$

$$Chl-a (\mu g l^{-1})_{Sentinel-2(before\ remove\ outliers)} = -306.401 B2 + 244.06 B3 + 6.005 \quad (13)$$

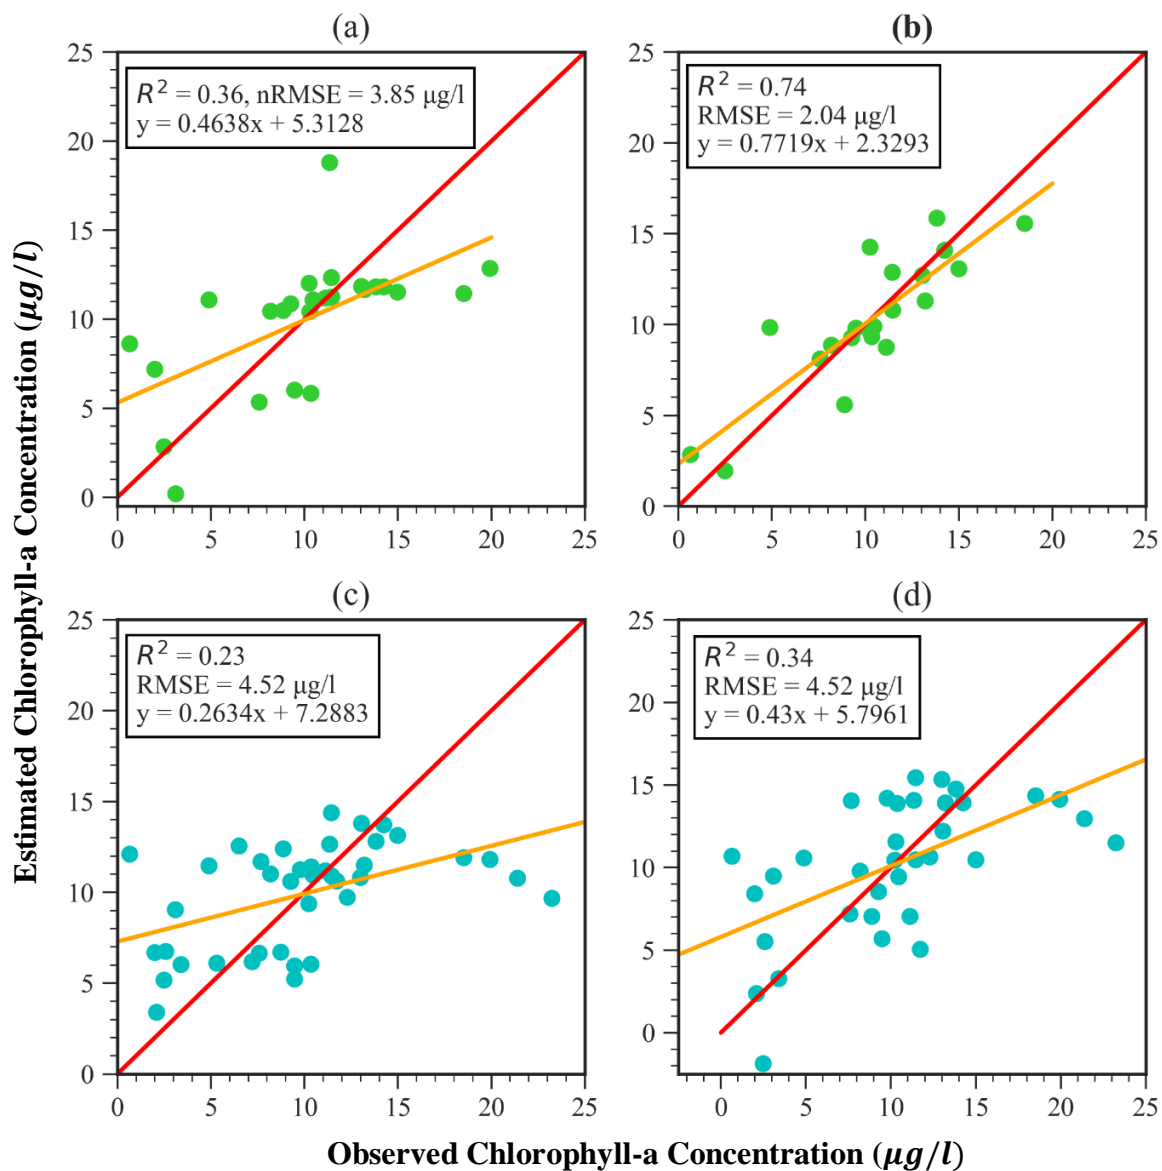
$$Chl-a (\mu g l^{-1})_{Sentinel-2(after\ remove\ outliers)} = -887.934 B2 + 677.976 B3 - 562.154 B5 + 1973.338 B6 - 1391.782 B8a + 6.584 \quad (14)$$

با توجه نمودار پراکندگی مقادیر واقعی و مدل‌سازی شده‌ی غلظت کلروفیل-آ مبتنی بر مدل منتخب MLR مبتنی بر داده‌های لندست-۸ پیش از حذف داده‌های پرت می‌توان به وضوح بیش‌برآورد در بازه‌ی

Table 3- Results of Chl-a concentration modeling with optimum MLR models based on Landsat-8 and Sentinel-2 images

جدول ۳- نتایج مدل‌سازی غلظت کلروفیل-آ با مدل‌های منتخب MLR مبتنی بر تصاویر لندست-۸ و سنتینل-۲

Sensor	Data filtering	Number of paired data	Input Bands	R ²	R ² _{Adj}	RMSE (μg l ⁻¹)
Landsat 8-OLI	All data	25	{B2, B5}	0.36	0.30	3.85
	Outliers removed	21	{B2, B4, B5}	0.74	0.69	2.04
Sentinel-2 -MSI	All data	41	{B2, B3}	0.23	0.19	4.52
	Outliers removed	35	{B2, B3, B5, B6, B8a}	0.34	0.23	4.52



Observed Chlorophyll-a Concentration ($\mu\text{g/l}$)
in the north part of the Lake Urmia using MLR Fig. 6- Evaluation of the modeled Chl-a concentration based on Landsat-8 (a) all data and (b) outliers removed; and Sentinel-2 (c) all data and (d) outliers removed

شکل ۶- ارزیابی نتایج مدل‌سازی غلظت کلروفیل-آ در شمال دریاچه ارومیه با مدل‌های MLR مبتنی بر تصاویر لندست-۸ (a) بدون حذف و (b) با حذف داده‌های پرت و سنتینل-۲ (c) بدون حذف و (d) با حذف داده‌های پرت

بر داده‌های لندست-۸ نسبت به سنتینل-۲ را در مدل‌سازی غلظت کلروفیل-آ در شمال دریاچه ارومیه مشاهده کرد (جدول ۴). با توجه به مقادیر واریانس خطای کم ذکر شده می‌توان نسبت به عدم بیش‌برازش^{۳۶} در مدل‌های منتخب اطمینان حاصل کرد. اختلاف کم واریانس مشاهداتی و پیش‌بینی نیز نشان‌دهنده عملکرد خوب مدل منتخب با داده‌های لندست-۸ است که در شرایط حذف داده‌های پرت

افزون بر این موارد بر اساس مدل منتخب MLR مبتنی بر تصاویر لندست-۸، مقادیر واریانس مقادیر خطای مدل، داده‌های مشاهداتی و داده‌های مدل‌سازی شده به ترتیب ۱/۸۶، ۱۶ و ۱۲/۹ میکروگرم بر لیتر بودند. این مقادیر برای مدل منتخب MLR مبتنی بر تصاویر سنتینل-۲ به ترتیب ۸/۴، ۲۹/۴۹ و ۱۶/۳۳ میکروگرم بر لیتر بودند. بر این اساس می‌توان عملکرد به مراتب بهتر مدل منتخب MLR مبتنی

عملکرد آن بهبود می‌یابد (جدول ۴). بر خلاف لندست-۸، هیچکدام از مدل‌های MLR مبتنی بر تصاویر سنتینل-۲ قابلیت مدل‌سازی غلظت کلروفیل-آ با دقت قابل قبول را نداشتند و از این رو در مدل‌سازی سطح تغذیه‌گرایی در بخش شمالی دریاچه ارومیه به کار گرفته نشدند.

۳-۲- مدل شبکه عصبی مصنوعی

مدل ANN ساخته شده با داده‌های بر اساس ورودی کلیه باند‌های تصاویر لندست-۸ و پیش از حذف نمونه‌های پرت، عملکرد نسبتاً قابل قبولی در تخمین غلظت کلروفیل-آ از خود نشان داد ($R^2 = 0.53$) و $RMSE = 3.43 \mu g l^{-1}$. از طرف دیگر ویژگی‌های مربوط به مدل منتخب MLR و ویژگی‌های اختصاصی مدل ANN یکسان بوده (B2 و B5) و مدل ANN ساخته شده بر اساس ورودی مذکور عملکرد نسبتاً قابل قبولی در تخمین غلظت کلروفیل-آ را از خود ارائه داده ($R^2 = 0.59$ و $RMSE = 3.22 \mu g l^{-1}$) و افزون بر آن نسبت به مدل ANN ساخته شده بر اساس کلیه ویژگی‌های ورودی، اندکی بهتر عمل کرد.

پس از حذف داده‌های پرت، عملکرد مدل ANN ساخته شده بر اساس ورودی کلیه باند‌ها تصاویر لندست-۸، بهبود قابل توجهی یافت (جدول ۴). همچنین مدل ANN ساخته شده با ورودی معادل مدل منتخب MLR (B2, B4, B5) نیز در مدل‌سازی غلظت کلروفیل-آ بسیار موفق عمل کرد ($R^2 = 0.79$ و $RMSE = 1.87 \mu g l^{-1}$). با این حال مدل ANN ساخته شده با ویژگی‌های اختصاصی مدل ANN (B1, B4 و B5)، بهترین عملکرد را در میان تمامی مدل‌های تخمین زنده‌ی غلظت کلروفیل-آ با داده‌های لندست-۸ داشته ($R^2 = 0.81$) و $RMSE = 1.77 \mu g l^{-1}$) و به عنوان مدل منتخب ANN مبتنی بر تصاویر لندست-۸ انتخاب شد. لازم به ذکر است که مدل منتخب ANN مبتنی بر تصاویر لندست-۸ در تمام بازه‌ی ۰ تا ۲۵ میکروگرم بر لیتر، غلظت کلروفیل-آ را به خوبی تخمین زد (شکل f-۷).

در میان مدل‌های مبتنی بر تصاویر لندست-۸ برای تخمین غلظت کلروفیل-آ در شمال دریاچه ارومیه، علی‌رغم برتری مدل منتخب ANN نسبت به مدل منتخب MLR ($R^2_{MLR} = 0.74$, $RMSE_{MLR} = 2.04 \mu g l^{-1}$ و $R^2_{ANN} = 0.81$ و $RMSE_{ANN} = 1.77 \mu g l^{-1}$)، عملکرد مدل‌های MLR و ANN نسبتاً به یکدیگر نزدیک بودند و از این رو قابلیت بسیار بالای مدل منتخب MLR مبتنی بر تصاویر لندست-۸ در تخمین غلظت کلروفیل در شمال دریاچه ارومیه را می‌توان استنباط کرد.

از طرف دیگر می‌توان به وضوح مشاهده کرد که در مدل‌های ANN مبتنی بر لندست-۸، حذف داده‌های پرت دقت مدل‌های تخمین زنده غلظت کلروفیل-آ را به طرز قابل توجهی افزایش دادند. در خصوص علت این موضوع می‌توان اشاره کرد که با توجه به اینکه زمان بازدید مجدد ماهواره لندست و سنتینل متفاوت است، تعداد داده‌های همزمان زمینی و ماهواره‌ای که برای آموزش و اعتبار مدل‌ها می‌توان استفاده کرد در مدل‌سازی با سنتینل بیشتر است (شکل ۳). در نتیجه مدل‌های توسعه داده شده بر مبنای ماهواره سنتینل-۲ اساساً با داده‌های بیشتری آموزش می‌بینند و با توجه به الگوریتم شناسایی و حذف داده‌های پرت، در میان داده‌های بیشتر ممکن است داده‌های همزمان (اندازه‌گیری و مدل) که برای ماهواره لندست پرت شناسایی می‌شوند در ارزیابی بین داده‌های موجود همزمان سنتینل (که بازه زمانی گسترده‌تری را از نظر مقادیر کلروفیل شامل می‌شود) اساساً پرت تشخیص داده نشوند. مطابق جدول ۲، داده‌های پرت شناسایی شده در هر دو سنجنده داده‌های حدی کلروفیل (غلظت‌های بالا) بوده‌اند و در داده‌های سنتینل حذف بیشتری صورت گرفته اما این حذف به گونه‌ای نبوده که انحراف معیار داده‌ها را به طرز قابل توجهی تغییر دهد. اما برای داده‌های لندست حذف داده حدی منجر به کاهش انحراف معیار (تا ۱۵ درصد) و در نتیجه همگنی بیشتر داده‌ها و در نتیجه بهبود عملکرد مدل شده است.

در ارتباط با داده‌های سنتینل-۲ پیش از حذف نمونه‌های پرت، مدل ANN ساخته شده بر اساس ورودی کلیه باند‌ها، عملکرد چندان مناسبی در تخمین غلظت کلروفیل-آ از خود نشان نداد ($R^2 = 0.23$) و $RMSE = 4.53 \mu g l^{-1}$. به طور مشابه مدل‌های ANN ساخته شده با ورودی‌های معادل مدل منتخب MLR (B2 و B3) و ویژگی‌های اختصاصی مدل ANN (B2, B3 و B8a) نیز قادر به مدل‌سازی غلظت کلروفیل-آ در شمال دریاچه ارومیه با دقت بالایی نبودند (مقادیر R^2 به ترتیب ۰/۲۷ و ۰/۲۶ و مقادیر RMSE به ترتیب ۴/۳۹ و ۴/۴۲ میکروگرم بر لیتر). علاوه بر موارد مذکور می‌توان استنباط کرد که علی‌رغم برتری مدل ANN ساخته شده با ورودی معادل مدل منتخب MLR، به کارگیری مقادیر مختلف ورودی به شبکه منجر به تفاوت چشمگیر در دقت مدل‌ها نشد.

مدل ANN ساخته شده بر اساس ورودی کلیه باند‌های سنتینل-۲ و بعد از حذف داده‌های پرت، عملکرد نامناسبی را در مدل‌سازی غلظت کلروفیل-آ از خود نشان داد. همچنین، مدل ANN ساخته شده با ورودی معادل مدل منتخب MLR (B2, B3, B5, B6 و B8a) نیز

تصاویر سنتینل-۲ انتخاب شد، با این وجود این مدل نیز عملکرد متوسطی را از خود نشان داد و نتایج حاصل از آن رضایت‌بخش نبود. لازم به ذکر است که مدل منتخب ANN مبتنی بر تصاویر سنتینل-۲ در بازه کمتر از ۱۰ میکروگرم بر لیتر، بیش‌برآورد و در بازه بزرگتر از ۱۰ میکروگرم بر لیتر، کم‌برآورد از خود نشان داد (شکل ۱-۷).

در مدل‌سازی غلظت کلروفیل-آ ناموفق عمل کرد (جدول ۴). علی‌رغم اینکه مدل ANN ساخته شده با ویژگی‌های اختصاصی مدل ANN (B2 و B3)، بهترین عملکرد را در میان تمامی مدل‌های تخمین زنده غلظت کلروفیل-آ با داده‌های سنتینل-۲ داشته ($R^2 = 0.43$) و $RMSE = 4.13 \mu g l^{-1}$ و به عنوان مدل منتخب ANN مبتنی بر

Table 4- Results of Chl-a concentration modeling with ANN models based on Landsat-8 and Sentinel-2 images

جدول ۴- نتایج مدل‌سازی غلظت کلروفیل-آ با مدل‌های ANN مبتنی بر تصاویر لندست-۸ و سنتینل-۲

Sensor	Data filtering	Number of paired data	Feature selection method	Input Bands	n	α	m	tc	R^2	R^2_{Adj}	RMSE ($\mu g l^{-1}$)
Landsat8-OLI	All data	25	All bands	{B1, B2, B3, B4, B5}	31	0.0116	0.903	170	0.53	0.41	3.43
			Based on optimum MLR	{B2, B5}	50	0.0095	0.9	175	0.59	0.55	3.22
			Based on optimum ANN	{B2, B5}	50	0.0095	0.9	175	0.59	0.55	3.22
	Outlier removed	21	All bands	{B1, B2, B3, B4, B5}	16	0.01175	0.905	75	0.74	0.65	1.99
			Based on optimum MLR	{B2, B4, B5}	17	0.0145	0.935	70	0.79	0.75	1.87
			Based on optimum ANN	{B1, B4, B5}	43	0.0128	0.914	335	0.81	0.78	1.77
Sentinel2-MSI	All data	41	All bands	{B1, B2, B3, B4, B5, B6, B7, B8, B8a}	31	0.0035	0.9	100	0.23	0.01	4.53
			Based on optimum MLR	{B2, B3}	4	0.01	0.94	175	0.27	0.23	4.39
			Based on optimum ANN	{B2, B3, B8a}	14	0.013	0.885	200	0.26	0.2	4.42
	Outlier removed	35	All bands	{B1, B2, B3, B4, B5, B6, B7, B8, B8a}	7	0.0275	0.94	105	0.35	0.12	4.6
			Based on optimum MLR	{B2, B3, B5, B6, B8a}	25	0.01375	0.9	170	0.3	0.18	4.58
			Based on optimum ANN	{B2, B3}	14	0.0265	0.78	220	0.43	0.39	4.13

α = Learning Rate, m = Momentum, tc = training cycle and n = Number of neurons in hidden layer

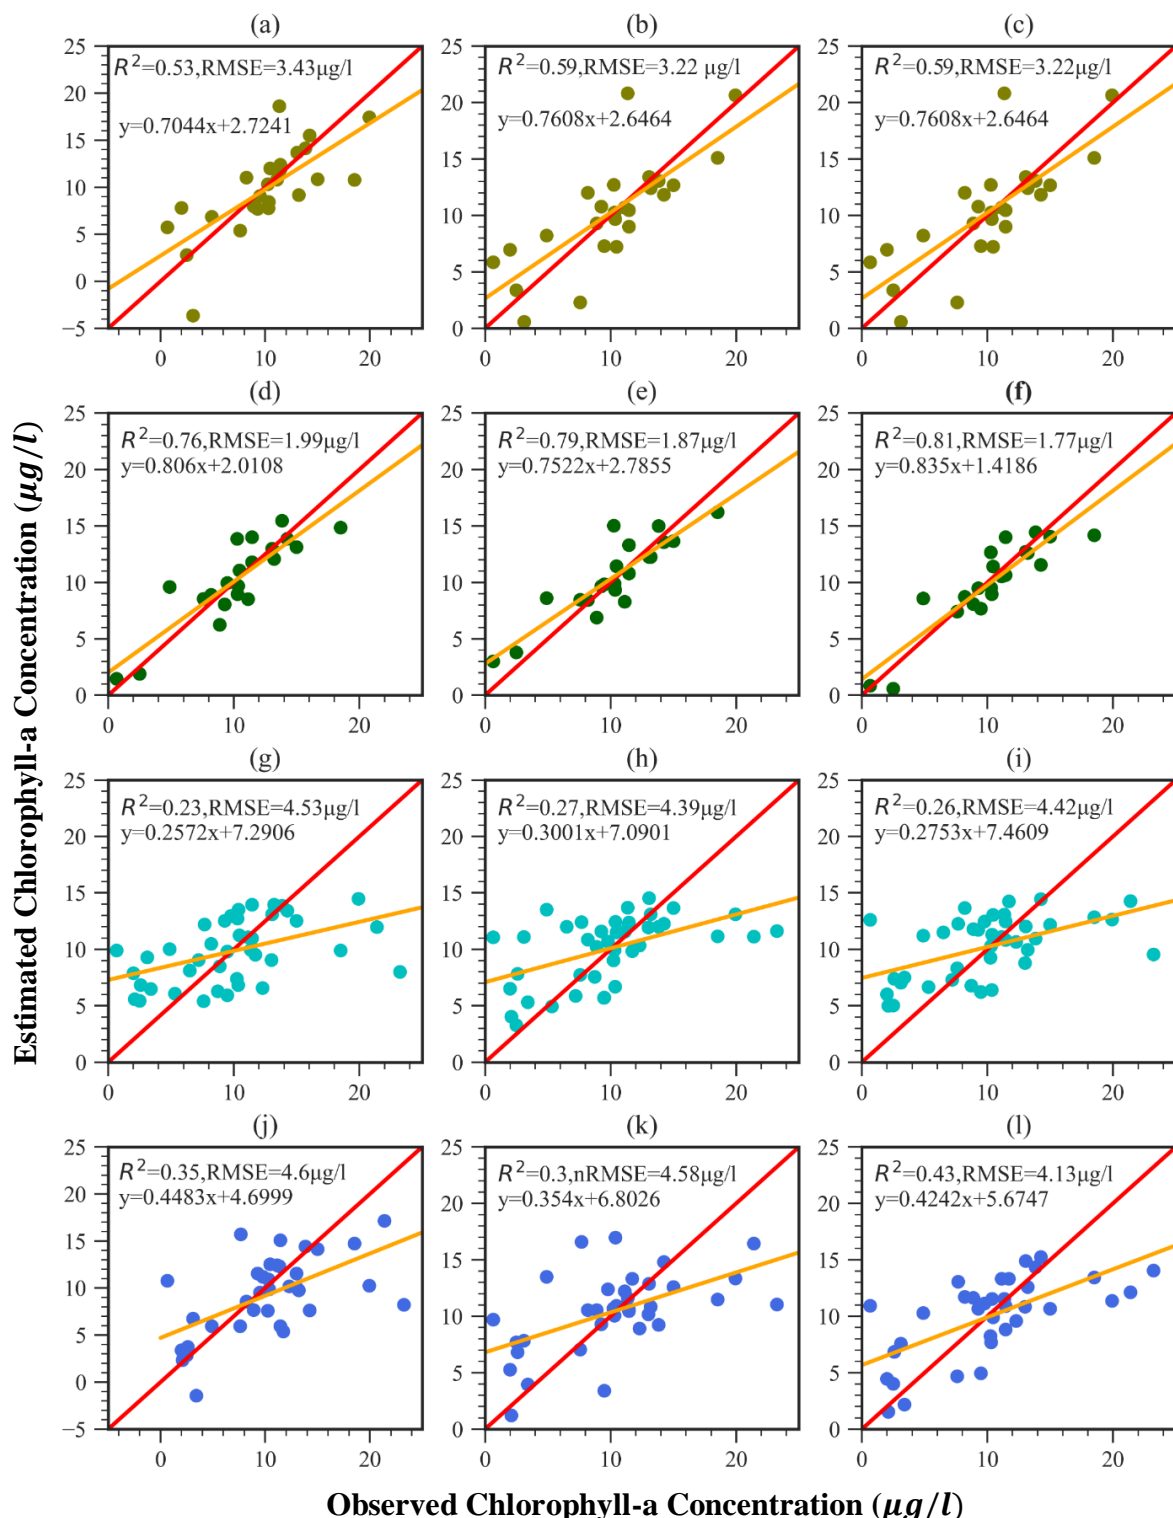


Fig. 7- Evaluation of the modeled Chl-a concentration in the north part of the Lake Urmia using ANN based on Landsat-8 (a-c) all data and (d-f) outliers removed; and Sentinel-2 (g-i) all data and (j-l) outliers removed

شکل ۷- ارزیابی نتایج مدل‌سازی غلظت کلروفیل-آ در شمال دریاچه ارومیه با مدل‌های ANN مبتنی بر تصاویر لندست-۸ (a-c) بدون حذف و (d-f) با حذف داده‌های پرت و سنتینل-۲ (g-i) بدون حذف و (j-l) با حذف داده‌های پرت

در میان مدل‌های مبتنی بر تصاویر سنتینل-۲ برای تخمین غلظت کلروفیل-آ در شمال دریاچه ارومیه، علی‌رغم برتری مدل منتخب ANN نسبت به منتخب MLR ($R^2_{MLR} = 0.34$, $RMSE_{MLR} = 4.52 \mu g l^{-1}$ و $R^2_{ANN} = 0.43$, $RMSE_{ANN} = 4.13 \mu g l^{-1}$)، عملکرد مدل‌های MLR و ANN نسبتاً به یکدیگر نزدیک بودند و هیچکدام از آن‌ها قابلیت مدل‌سازی دقیق غلظت کلروفیل-آ در بخش شمالی دریاچه ارومیه را نداشتند.

بر خلاف مدل‌های ANN مبتنی بر تصاویر لندست-۸ در مدل‌های ANN مبتنی بر تصاویر سنتینل-۲، حذف داده‌های پرت به طرز قابل توجه و معناداری دقت مدل‌ها را افزایش نداده و تصاویر سنتینل-۲ همچنان قادر به مدل‌سازی موفق غلظت کلروفیل-آ در شمال دریاچه ارومیه نبودند. بر خلاف تصاویر سنتینل-۲، تصاویر لندست-۸ با دقت بالایی قادر به مدل‌سازی غلظت کلروفیل-آ و در نتیجه سطح تغذیه‌گرایی در شمال دریاچه ارومیه بودند. افزون بر این موارد بر اساس مدل منتخب ANN مبتنی بر تصاویر لندست-۸، مقادیر واریانس مقادیر خطای مدل، داده‌های مشاهداتی و داده‌های مدل‌سازی شده به ترتیب ۱/۳۲، ۱۶ و ۱۳/۷۵ میکروگرم بر لیتر بودند. این مقادیر برای مدل منتخب ANN مبتنی بر تصاویر سنتینل-۲ به ترتیب ۶/۹۸، ۲۹/۴۹ و ۱۲/۴۵ میکروگرم بر لیتر بودند. بر این اساس می‌توان عملکرد به مراتب بهتر مدل منتخب ANN مبتنی بر داده‌های لندست-۸ نسبت به سنتینل-۲ را در مدل‌سازی غلظت کلروفیل-آ در شمال دریاچه ارومیه مشاهده کرد. همچنین، بر اساس مقادیر واریانس ذکر شده می‌توان نسبت به عدم بیش‌برازش در مدل‌های منتخب نیز اطمینان حاصل کرد.

با توجه به نتایج مرتبط با مدل‌سازی متغیر غلظت کلروفیل-آ با مدل‌های MLR و ANN می‌توان نتیجه گرفت که مدل‌های مبتنی بر تصاویر سنتینل-۲ قابلیت مدل‌سازی مناسب متغیر مذکور را نداشتند و به همین سبب در تهیه نقشه‌های متغیرهای غلظت کلروفیل-آ و شاخص کارلسون TSI در شمال دریاچه ارومیه نیز به کار گرفته نشدند. افزون بر این موارد در ارتباط با مدل‌های مبتنی بر داده‌های لندست-۸، با توجه به عملکرد بهتر مدل منتخب ANN (ساخته شده با ورودی اختصاصی مدل ANN) نسبت به مدل منتخب MLR، در تهیه نقشه‌های کیفی متغیرهای غلظت کلروفیل-آ و شاخص کارلسون TSI از این مدل استفاده شد.

با توجه به نتایج مدل‌سازی متغیر غلظت کلروفیل-آ، بر خلاف انتظار مدل‌های مبتنی بر داده‌های سنتینل-۲ نسبت به لندست-۸ عملکرد ضعیف‌تری را از خود نشان دادند و قابلیت مدل‌سازی دقیق متغیر مذکور در بخش شمالی دریاچه ارومیه را نداشتند. اهمیت این موضوع از این جهت بیشتر است که سنجنده MSI دارای باندهای بیشتری در نواحی طیفی حائز اهمیت برای پایش غلظت کلروفیل-آ نسبت به سنجنده OLI می‌باشد. همچنین توان‌های تفکیک مکانی و طیفی سنجنده MSI نسبت OLI بالاتر می‌باشد. لازم به ذکر است که در مطالعاتی که در آن‌ها عملکرد تصاویر لندست-۸ و سنتینل-۲ در مدل‌سازی متغیر غلظت کلروفیل-آ با یکدیگر مقایسه شدند، در بیشتر آن‌ها سنتینل-۲ عملکرد بهتری نسبت به لندست-۸ از خود نشان داد (Watanabe et al., 2017; Yadav et al., 2019; Buma and Lee, 2020). با این حال اندک مطالعاتی نیز وجود داشتند که در آن‌ها لندست-۸ نسبت به سنتینل-۲ عملکرد مطلوب‌تری داشت (Ouma et al., 2020). به علاوه بر اساس نتایج این مطالعه، مدل بهینه معرفی شده برای پایش غلظت کلروفیل-آ (مدل ANN مبتنی بر تصاویر لندست-۸) بعد از حذف داده‌های پرت و بر اساس ورودی مدل اختصاصی ANN)) از باندهای B1، B4 و B5 به عنوان ورودی استفاده می‌کرد. این باندها در ورودی مربوط به مدل‌های تخمین‌زننده غلظت کلروفیل-آ در برخی مطالعات دیگر نیز به کار رفتند (Guo et al., 2016; Zhang et al., 2020). به علاوه باندهای B4 و B5 سنجنده OLI (باندهای مربوط به محدوده‌های طیفی قرمز و NIR) در مطالعات متعددی به عنوان ورودی مدل‌های پایش‌کننده‌ی غلظت کلروفیل-آ استفاده شدند (Alparslan et al., 2007; Prasad et al., 2020).

۳-۳- بررسی الگوی تغییرات مکانی-زمانی کلروفیل-آ

با توجه به اینکه مدل منتخب مبتنی بر تصاویر لندست-۸، مدل ANN ساخته شده بر اساس ورودی‌های اختصاصی مدل ANN و پس از حذف داده‌های پرت تعیین شد (ورودی مدل باندهای B1، B4 و B5 بود)، در این بخش با توجه به این مدل در ماه‌هایی که تصاویر لندست-۸ موجود بودند (فوریه، جولای، آگوست، سپتامبر و اکتبر سال ۲۰۱۶) نقشه‌های غلظت کلروفیل-آ و شاخص کارلسون TSI ارائه شدند (شکل‌های ۸ و ۹).

با توجه به شکل‌های ۸ و ۹ می‌توان به وضوح مشاهده کرد که روند تغییرات مکانی متغیرهای غلظت کلروفیل-آ و شاخص کارلسون TSI در تمامی ماه‌های مورد بررسی به صورت افزایش به سمت نواحی

باشد. با این حال مدل منتخب مبتنی بر تصاویر لندست-۸ در ماه‌های جولای و آگوست تقریباً در تمامی شمال دریاچه ارومیه قادر به تخمین مثبت غلظت کلروفیل-آ بود. اصلی‌ترین علت تخمین منفی کلروفیل-آ را می‌توان محدودیت شدید داده در مدل‌سازی‌ها در قیاس با مساحت بالای بخش شمالی دریاچه ارومیه دانست.

مرکزی عمیق (بر اساس بسیمتری دریاچه: Karimi et al., 2016) و کاهش به سمت پل میان‌گذر بود. همچنین در ماه‌های فوریه، سپتامبر و اکتبر مدل منتخب مبتنی بر تصاویر لندست-۸ در مناطق ساحلی، کم‌عمق و نزدیک به پل میانگذر، غلظت کلروفیل-آ را منفی تخمین زدند که این امر می‌تواند ناشی از مداخله شدید بازتاب بستر نمکی

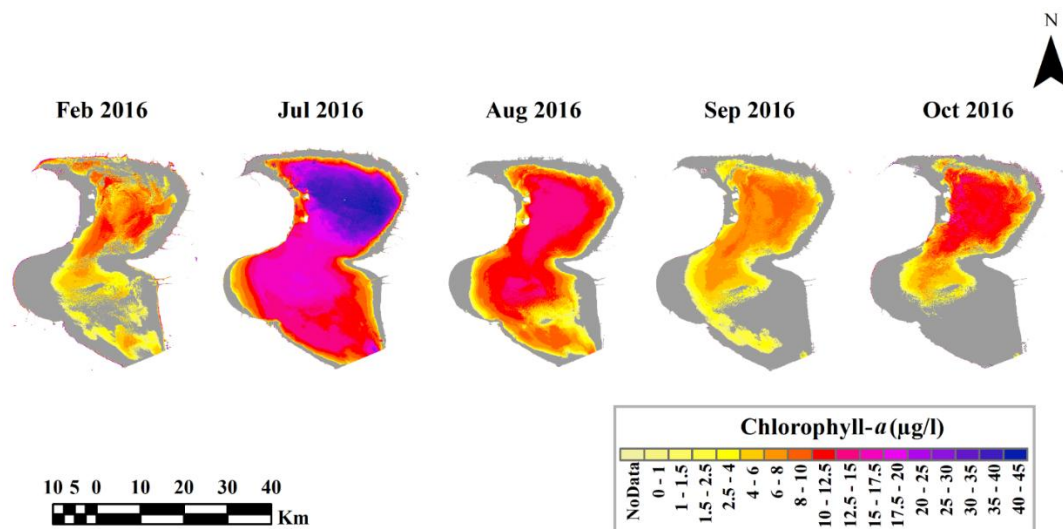


Fig. 8- Maps of Chl-a concentration in the north of Lake Urmia obtained from the optimum ANN- model based on Landsat-8 images for February, July, August, September, and October 2016

شکل ۸- نقشه‌های غلظت کلروفیل-آ حاصل از مدل شبکه عصبی بهینه با داده‌های لندست-۸ در شمال دریاچه ارومیه طی ماه‌های فوریه، جولای، آگوست، سپتامبر و اکتبر سال ۲۰۱۶

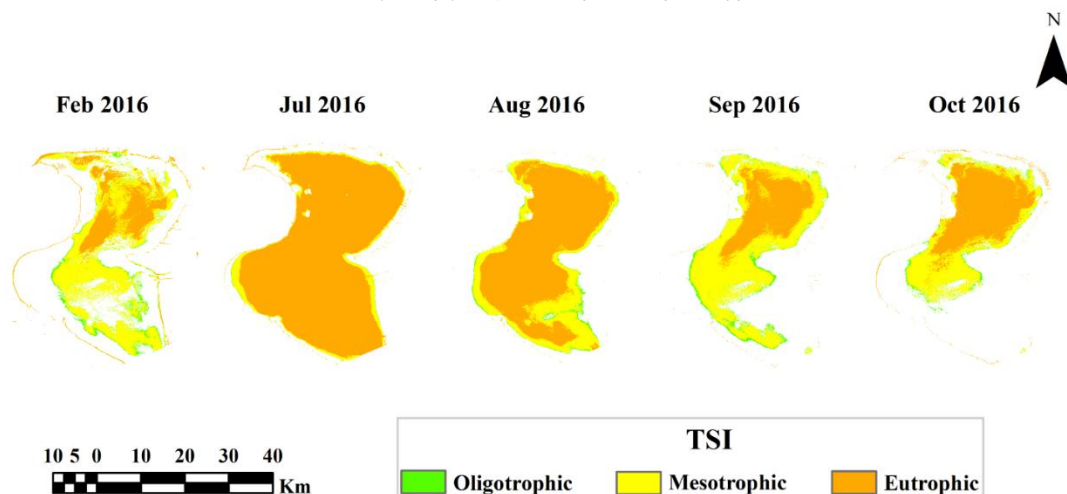


Fig. 9- Carlson TSI index (TSI) based on Landsat-8 images in February, July, August, September, and October 2016 in the northern part of the Lake Urmia

شکل ۹- نقشه‌های شاخص کارلسون TSI مبتنی بر تصاویر لندست-۸ در ماه‌های فوریه، جولای، آگوست، سپتامبر و اکتبر سال ۲۰۱۶ در شمال دریاچه ارومیه

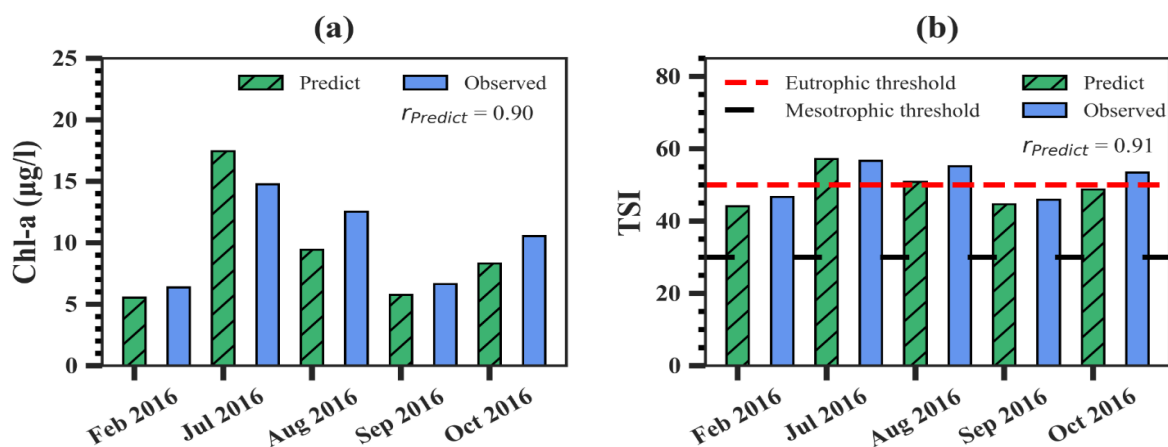


Fig. 10- The average observed and modeled Chl-a concentration and TSI obtained from the optimum ANN model using Landsat-8 images in the northern part of the Lake Urmia

شکل ۱۰- الگوی تغییرات زمانی متغیرهای میانگین غلظت کلروفیل-آ و شاخص کارلسون TSI حاصل از داده‌های مشاهداتی و مدل ANN بهینه مبتنی بر تصاویر لندست-۸ در شمال دریاچه ارومیه

مزوتروفیک حاد و در ماه‌های جولای، آگوست و اکتبر در شرایط یوتروفیک خفیف قرار داشت.

۴- محدودیت‌ها و پیشنهادات برای مطالعات آتی

در مدل‌سازی‌های انجام شده در این مطالعه، محدودیت تعداد داده‌ها (در اثر تعداد کم ایستگاه‌های نمونه‌برداری) محسوس بود. با توجه به وسعت بالای دریاچه ارومیه که در سال ۲۰۱۶ حدوداً ۱۸۰۰ کیلومترمربع وسعت داشت (Danesh-Yazdi and Ataie-Ashtiani, 2019)، تعداد داده‌های برداشت شده در هر دوره نمونه‌برداری در قیاس با مطالعات مشابه بر روی دریاچه‌های وسیع، تفاوت معناداری را از خود نشان داده و به طور قابل توجهی کمتر بود. برای نمونه Wu et al. (2009)، در مطالعه خود بر روی دریاچه Chaohu در کشور چین که حدود ۷۸۰ کیلومترمربع مساحت داشت، از ۱۲ ایستگاه نمونه‌برداری و (Bayati and Danesh-Yazdi (2021) در مطالعه خود بر روی دریاچه ارومیه در دو دوره به ترتیب از ۷۹ و ۵۱ ایستگاه نمونه‌برداری استفاده کردند. بر این اساس لازم است تا در مطالعات آتی با افزایش ایستگاه‌های نمونه‌برداری حجم داده‌های موجود برای مدل‌سازی را افزایش یابد. در نتیجه این موضوع دقت، اطمینان‌پذیری و نیز قابلیت بهبود ساختار مدل‌ها و قدرت تعمیم آن‌ها افزایش خواهند یافت. با افزایش تعداد داده‌ها (به ویژه در نقاط کم عمق) و گسترش پراکندگی مکانی ایستگاه‌های نمونه‌برداری، احتمال تخمین مقادیر منفی کلروفیل-آ در مناطق کم عمق کاهش پیدا خواهد کرد.

شکل ۱۰، الگوی تغییرات زمانی متغیرهای میانگین مشاهداتی و مدل‌سازی شده (حاصل از مدل منتخب مبتنی بر تصاویر لندست-۸) غلظت کلروفیل-آ و شاخص کارلسون TSI را در ناحیه شمالی دریاچه ارومیه نشان می‌دهد. کمترین و بیشترین مقادیر مشاهداتی و مدل‌سازی شده متغیرهای مذکور به ترتیب در ماه فوریه و جولای مشاهده گشت. میانگین متغیرهای غلظت کلروفیل-آ و شاخص کارلسون TSI در بازه زمانی فوریه تا جولای روند افزایشی نسبتاً شدید، از جولای تا سپتامبر روند کاهشی و مجدداً در ماه اکتبر یک افزایش نسبی را از خود نشان داد. در توضیح دلیل این امر با شرایط هیدرولوژیکی دریاچه می‌توان گفت که با توجه به کاهش بارش و ورودی دریاچه در ماه جولای (که منجر به کاهش حجم آب دریاچه می‌شود) و نیز افزایش دما و تابش خورشید (که شرایط مساعد را برای رشد جلبک غالب ناحیه شمالی^{۳۸} دریاچه فراهم می‌کند) می‌توان انتظار افزایش غلظت کلروفیل را نسبت به ماه فوریه داشت.

در مجموع مدل منتخب مبتنی بر تصاویر لندست-۸ توانست با دقت بسیار بالایی روند تغییرات میانگین غلظت کلروفیل-آ و شاخص کارلسون TSI در بخش شمالی دریاچه ارومیه را پیش‌بینی کند ($r_{Chl-a} = 0.9$ و $r_{TSI} = 0.91$). مدل منتخب مبتنی بر تصاویر لندست-۸، میانگین غلظت کلروفیل-آ و شاخص کارلسون TSI را در ماه‌های فوریه، آگوست، سپتامبر و اکتبر با کم‌برآورد نسبتاً کم و در ماه جولای با بیش‌برآورد نسبتاً اندکی تخمین زد. در انتها نیز لازم به ذکر است که بر اساس نقشه‌های حاصل از مدل منتخب مبتنی بر تصاویر لندست-۸ شمال دریاچه ارومیه در ماه‌های فوریه و سپتامبر در شرایط

در مطالعات انجام گرفته در تعریف داده‌های همزمان، باتوجه به شرایط هیدرولوژی و کیفیت آب پهنه آبی مورد مطالعه از فواصل زمانی متفاوتی میان داده‌های زمینی و ماهواره‌ای استفاده شده است. Kutser (2012)، (2016) و Toming et al. (2002) و Kloiber et al. به ترتیب حداکثر اختلاف زمانی ۳، ۵ و ۷ روز را میان داده‌های زمینی و ماهواره‌ای استفاده کردند. در مطالعه حاضر، قید حداکثر فاصله زمانی ۵ روزه بین تصاویر ماهواره‌ای و داده‌های زمینی اعمال شد. موضوع تحلیل حساسیت اثر اختلاف زمانی بین تصاویر ماهواره‌ای و داده‌های زمینی، روی ساختار و عملکرد مدل در مطالعات آتی پیشنهاد می‌گردد.

پیشنهاد می‌شود تا در مطالعات آتی افزون بر باندهای طیفی از نسبت‌های باندی (به عنوان نمونه نسبت باد سبز به آبی) و شاخص‌های طیفی (به عنوان نمونه شاخص $NDCI^{37}$) به عنوان ورودی‌های مدل استفاده شود. همچنین استفاده از داده‌های سنجنده OLCI (ماهواره سنتینل-۳) با توجه به دارا بودن ۲۱ باند طیفی که برخی از آن‌ها در نواحی طیفی حائز اهمیت در پایش غلظت کلروفیل-آ قرار دارند، می‌تواند برای پایش متغیر غلظت کلروفیل-آ در دریاچه مورد توجه قرار گیرد.

تغییرات مکانی-زمانی غلظت شوری در دریاچه‌های فوق‌شور (از جمله دریاچه ارومیه) نقش بسیار مهمی در مدل‌سازی‌های کیفی و هیدرودینامیکی ایفا می‌کند (Bayati and Danesh-Yazdi, 2021). در سال ۲۰۱۶ میانگین تراز آب و غلظت کل جامدات محلول (TDS^{39}) دریاچه ارومیه در ماه‌هایی که تصاویر لندست-۸ و یا سنتینل-۲ تقریباً همزمان با داده‌های زمینی و شامل کل بخش شمالی دریاچه موجود بود (فوریه، مارس، ژوئن، جولای، آگوست، سپتامبر، اکتبر و دسامبر) به ترتیب حدود ۱۲۷۰/۶۵ متر (<http://www.ulrp.ir/fa>) و ۳۰۵ گرم بر لیتر بودند (بر اساس داده‌های اخذ شده از ستاد احیای دریاچه ارومیه و شرکت آب منطقه‌ای آذربایجان غربی) که در قیاس با تراز اکولوژیک دریاچه و TDS آب متناظر آن که به ترتیب ۱۲۷۴/۱ متر و حدود ۲۶۳ گرم بر لیتر می‌باشند (Sima et al., 2021)، تراز آب دریاچه نزدیک به ۳/۵ متر کمتر و غلظت TDS بیش از ۴۲ گرم بر لیتر بیشتر بودند. بر این اساس می‌توان دریافت که مدل‌های ساخته شده در این مطالعه در وضعیتی که دریاچه در شرایط حدی از نظر حجم آب قرار داشته و غلظت شوری نیز در شرایط نزدیک به اشباع بود، توسعه داده شدند. به همین علت ممکن است این مدل‌ها قابلیت تعمیم به شرایط طبیعی و نرمال دریاچه را نداشته باشند. در خصوص داده‌های لندست-۸ همانطور که پیش‌تر بیان شد، افزایش شوری می‌تواند به کاهش

بازتابش در محدوده طیفی منجر شود (Jensen, 2011). در دریاچه ارومیه از طرفی در سال ۲۰۱۶، بین میانگین متغیرهای غلظت‌های شوری و کلروفیل-آ، در شش ماهه نخست سال (فوریه تا جولای) همبستگی معکوس بسیار قوی ($r = -0.95$) و در شش ماهه دوم (آگوست ۲۰۱۶ تا ژانویه ۲۰۱۷) همبستگی معکوس ضعیفی ($r = -0.25$) مشاهده شد (شکل ۱۱). این امر می‌تواند ناشی از اثر عوامل محیطی نظیر شدت تابش خورشید، ورودی مواد مغذی، باد و غیره روی رشد جلبک و غلظت کلروفیل باشد.

در مدل‌های منتخب این پژوهش اثر شوری به صورت غیر صریح لحاظ شد. به این ترتیب که با حضور باند ۴ (باند قرمز) لندست-۸ (باند حساس به شوری) در مدل منتخب تا حدی اثر شوری دریاچه روی پایش غلظت کلروفیل-آ لحاظ شده است. با این وجود نظر به اهمیت موضوع، پیشنهاد می‌شود تا در مطالعات آتی برهمکنش غلظت کلروفیل-آ و سایر متغیرهای کیفی (به ویژه شوری) (به ویژه شوری و TSS^{40}) به صورت صریح در مدل‌سازی لحاظ شود.

۵- خلاصه و جمع‌بندی

در این پژوهش، با استفاده از تصاویر لندست-۸ و سنتینل-۲ و مدل‌های رگرسیون خطی چندمتغیره (MLR) و شبکه عصبی مصنوعی (ANN)، غلظت کلروفیل-آ به عنوان متغیر کیفی مرتبط با تعیین سطح تغذیه‌گرایی در بخش شمالی دریاچه ارومیه مدل‌سازی شد. مهمترین یافته‌های پژوهش فعلی عبارت است از:

۱- در مدل‌های مبتنی بر تصاویر سنتینل-۲ برای تخمین غلظت کلروفیل-آ، مدل منتخب ANN نسبت به مدل منتخب MLR با اختلاف اندکی بهتر عمل کرد ($R^2_{MLR} = 0.34$, $R^2_{ANN} = 0.43$), $RMSE_{MLR} = 4.52 \mu g l^{-1}$, $RMSE_{ANN} = 4.13 \mu g l^{-1}$. با این وجود هیچکدام از این مدل‌ها قابلیت مدل‌سازی دقیق غلظت کلروفیل-آ و در نتیجه تغذیه‌گرایی در شمال دریاچه ارومیه را نداشتند.

۲- بر خلاف سنتینل-۲، مدل‌های منتخب مبتنی بر تصاویر لندست-۸، با دقت بسیار خوبی قادر به مدل‌سازی غلظت کلروفیل-آ و در نتیجه تغذیه‌گرایی در شمال دریاچه بودند. در این میان مدل منتخب ANN نسبت به مدل منتخب MLR اندکی بهتر عمل کرد ($R^2_{MLR} = 0.74$, $R^2_{ANN} = 0.81$, $RMSE_{ANN} = 1.77 \mu g l^{-1}$, $RMSE_{MLR} = 2.04 \mu g l^{-1}$).

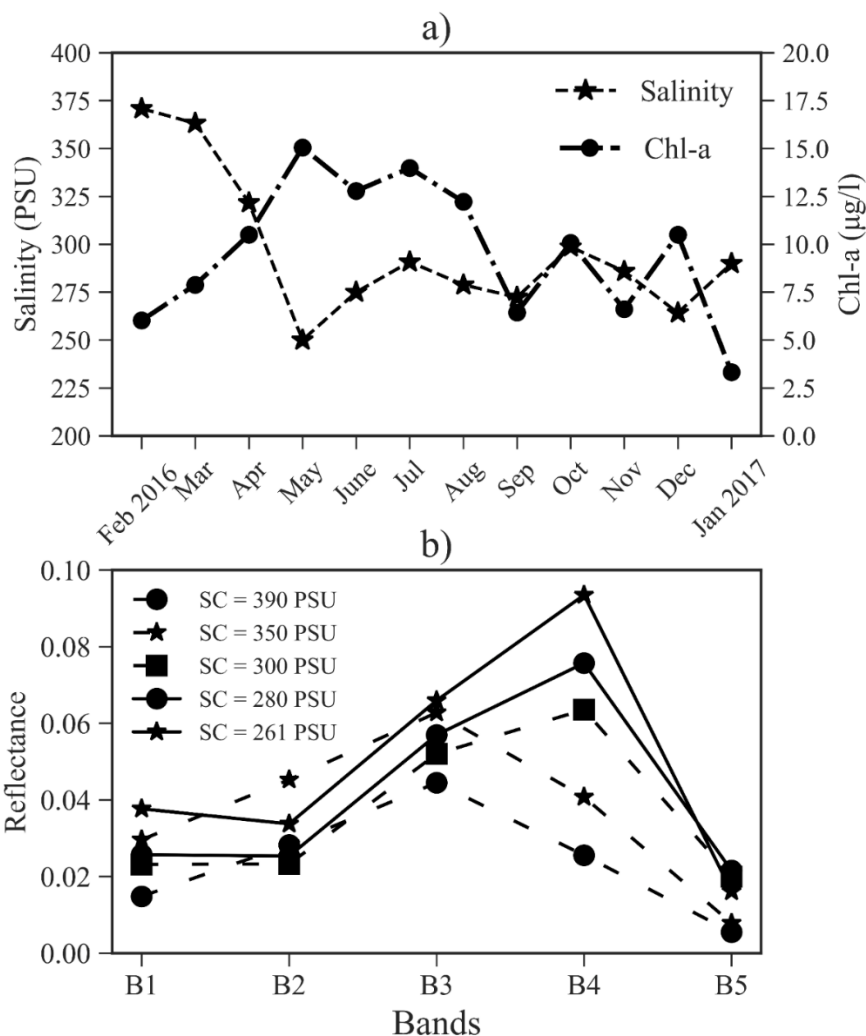


Fig. 11 a) The average observed Salinity and Chl-a Concentration in the north of Lake Urmia (Feb2016 – Jan 2017), b) Spectral behavior of Lake Urmia at different salinity concentrations based on Landsat-8 data

شکل ۱۱- میانگین مقادیر مشاهداتی غلظت‌های شوری و کلروفیل-آ شمال دریاچه ارومیه (فوریه ۲۰۱۶ تا ژانویه

۲۰۱۷) (a) و رفتار طیفی دریاچه ارومیه در غلظت‌های شوری مختلف بر اساس داده‌های لندست-۸ (b)

باند‌های طیفی ممکن است باعث افزایش دقت مدل تخمین‌زنده‌ی غلظت کلروفیل-آ نشود.

۵- مدل منتخب مبتنی بر تصاویر لندست-۸ قادر به تخمین بسیار خوب روند تغییرات زمانی میانگین غلظت کلروفیل-آ و شاخص کارلسون TSI در شمال دریاچه ارومیه در سال ۲۰۱۶ (ماه‌های فوریه، جولای، آگوست، سپتامبر و اکتبر) بود ($r_{Chla} = 0.9$ و $r_{TSI} = 0.91$) بود.

۳- حذف داده‌های پرت در مدل‌های مبتنی بر تصاویر لندست-۸، دقت مدل‌های تخمین‌زنده غلظت کلروفیل-آ را به طور قابل توجهی افزایش داد. اما اثر حذف داده‌های پرت در بهبود عملکرد مدل‌های مبتنی بر تصاویر سنتینل-۲ قابل توجه نبود.

۴- مدل منتخب ANN مبتنی بر تصاویر لندست-۸ بر مبنای باند‌های B1 (حدوده ۴۳۰ تا ۴۵۰ نانومتر)، B4 (محدوده ۶۴۰ تا ۶۷۰ نانومتر) و B5 (محدوده ۸۵۰ تا ۸۸۰ نانومتر) به عنوان ورودی عملکرد بهتری نسبت به استفاده از همه باند‌های محدوده مرئی و مادون قرمز این سنجنده داشت. نتایج این پژوهش نشان داد که الزاماً افزایش تعداد

۶- علی‌رغم عملکرد خوب مدل منتخب مبتنی بر تصاویر لندست-۸

در پیش‌بینی روند تغییرات زمانی غلظت کلروفیل-آ، این مدل در نواحی ساحلی و کم عمق دریاچه قادر به تخمین مناسب غلظت کلروفیل-آ نبود.

نتایج این پژوهش می‌تواند به پایش بهتر متغیر کلیدی کلروفیل آ و تحلیل شرایط تغذیه‌گرایی شمال دریاچه ارومیه کمک کند. در نتیجه ایجاد امکان مدل‌سازی با استفاده از داده‌های ماهواره‌ای با قدرت تفکیک مکانی بالا (۳۰ متر)، الگوی تغییرات مکانی- زمانی تغذیه‌گرایی قابل پایش خواهد بود که این امر برای تحلیل اثرات تغذیه‌گرایی روی زنجیره غذایی دریاچه و به ویژه تراکم آرتیمیا (به عنوان گونه با ارزش اقتصادی) و انجام اقدامات مدیریت کیفیت آب در سطح دریاچه حایز اهمیت است.

۶- تقدیر و تشکر

نویسندگان این مقاله لازم می‌دانند تا از جناب آقای دکتر کوروش کاووسی (مهندسین مشاور آبان پژوه) بابت در اختیار قرار دادن داده‌های کیفی مورد استفاده در این پژوهش کمال تشکر و قدردانی را داشته باشند.

- پی‌نوشت‌ها
- 1- Cultural Eutrophication
 - 2- Trophic State Index
 - 3- Case I Waters
 - 4- Case II Waters
 - 5- Optical Active Substances
 - 6- Red Edge
 - 7- Near Infrared Red
 - 8- Multiple Linear Regression
 - 9- Artificial Neural Network
 - 10- Support Vector Regression
 - 11- Cubist
 - 12- Log-Linear Regression
 - 13- Exponential Regression
 - 14- Log-Transformed Linear Regression
 - 15- Polynomial Regression
 - 16- Great Salt Lake
 - 17- High-Performance Liquid Chromatography
 - 18- Aerosol
 - 19- Shortwave Infrared
 - 20- Dark Spectrum Fit
 - 21- Exponential Extrapolation
 - 22- Nearest Neighbor
 - 23- Outlier
 - 24- Cost Function
 - 25- Gradient Descent
 - 26- Feed Forward
 - 27- Multilayer Perceptron
 - 28- Back Propagation
 - 29- Activation Function
 - 30- Training Cycle
 - 31- Hyperparameter
 - 32- Leave One Out Cross Validation
 - 33- Cross Validation
 - 34- Fold
 - 35- Normalized Difference Water Index
 - 36- Overfitting
 - 37- Normalized Difference Chlorophyll Index
 - 38- Dunaliella tertiolecta
 - 39- Total Dissolved Solids
 - 40- Total Suspended Solids

۷- مراجع

- Aizaki M (1981) Application of modified Carlson's trophic state index to Japanese lake and its relationships to other parameters. related to trophic state. Res. Rep. National Institute for Environmental Studies, Japan 23:13-31
- Alipour S (2006) Hydrogeochemistry of seasonal variation of Urmia Salt Lake, Iran. Saline Systems 2(1):1-19
- Allan MG, Hicks BJ, and Brabyn L (2007). Remote sensing of water quality in the Rotorua lakes. CBER Contract Report
- Alparslan E, Aydoğan C, Tufekci V, and Tufekci H (2007) Water quality assessment at Ömerli Dam using remote sensing techniques. Environmental Monitoring and Assessment 135(1):391-398
- Azari TG (1991) Uromieh lake as a valuable source of Artemia for feeding sturgeon fry. The Journal of Faculty of Veterinary Medicine, Teheran University 47:1-14
- Bayati M and Danesh-Yazdi M (2021) Mapping the spatiotemporal variability of salinity in the hypersaline Lake Urmia using Sentinel-2 and Landsat-8 imagery. Journal of Hydrology 595:126032
- Buma WG and Lee S-I (2020) Evaluation of sentinel-2 and landsat 8 images for estimating chlorophyll-a concentrations in lake Chad, Africa. Remote Sensing, MDPI 12(15):2437
- Carlson RE (1977) A trophic state index for lakes 1. Limnology and oceanography. Wiley Online Library 22(2):361-369
- Cawley GC and Talbot NLC (2003) Efficient leave-one-out cross-validation of kernel fisher discriminant classifiers. Pattern Recognition, Elsevier 36(11):2585-2592
- Chavula G, Brezonik P, Thenkabail P, Johnson T, and Bauer M (2009) Estimating chlorophyll concentration in Lake Malawi from MODIS satellite imagery. Physics and Chemistry of the Earth, Parts A/B/C, Elsevier 34(13-16):755-760
- Dahest LE, Mustafayev Q, Mohebbi F, and Ahmadi R (2013) Relationship between Artemia population dynamics and chlorophyll a fluctuation in Urmia Lake (Iran). Brazilian Journal of Aquatic Science and Technology, Citeseer 17(2):1-6
- Danesh-Yazdi M and Ataie-Ashtiani B (2019) Lake Urmia crisis and restoration plan: Planning without appropriate data and model is gambling. Journal of Hydrology 576:639-651
- Darzi A and Sima S (2021) Monitoring spatiotemporal variation of Lake Urmia Surface Albedo using MODIS Satellite Data. Iran-Water Resources Research 17(2):190-203 (In Persian)
- Dehghanipour AH, Moshir Panahi D, Mousavi H, Kalantari Z, and Tajrishy M (2020) Effects of water level decline in Lake Urmia, Iran, on local climate conditions. Water, Multidisciplinary Digital Publishing Institute 12(8):2153
- Dekker AG and Peters SWM (1993) The use of the thematic mapper for the analysis of eutrophic lakes: a case study in the Netherlands. International Journal of Remote Sensing, Taylor & Francis 14(5):799-821
- Directive EUW (1991) Council Directive of 21. May 1991 concerning urban waste water treatment (91/271/EEC). European Journal of Communication 34:40
- Dodds WK, Bouska WW, Eitzmann JL, Pilger TJ, Pitts KL, Riley AJ, Schloesser JT, and Thornbrugh DJ (2009) Eutrophication of US freshwaters: Analysis of potential economic damages. Environmental Science & Technology 43(1):12-19
- Doxaran D, Froidefond J-M, and Castaing P (2002) A reflectance band ratio used to estimate suspended matter concentrations in sediment-dominated coastal waters. International Journal of Remote Sensing 23(23):5079-5085
- Esmaili Dahest L, Negarestan H, Eimanifar A, Mohebbi F, and Ahmadi R (2010) The fluctuations of physicochemical factors and phytoplankton populations of Urmia Lake, Iran. Iranian Journal of Fisheries Sciences, Agricultural Research, Education and Extension Organization 9(3):361-381
- Giardino C, Pepe M, Brivio PA, Ghezzi P, and Zilioli E (2001) Detecting chlorophyll, Secchi disk depth and surface temperature in a sub-alpine lake using Landsat imagery. Science of the Total Environment 268(1-3):19-29
- Gordon HR and Wang M (1994) Retrieval of water-leaving radiance and aerosol optical thickness over the oceans with SeaWiFS: A preliminary algorithm. Applied optics. Optical Society of America 33(3):443-452
- Guo Q, Wu X, Bing Q, Pan Y, Wang Z, Fu Y, Wang D, and Liu J (2016) Study on retrieval of chlorophyll-a concentration based on Landsat OLI Imagery in the Haihe River, China. Sustainability 8:758

- Ha NTT, Koike K, Nhuan MT, Canh BD, Thao NTP, and Parsons M (2017a) Landsat 8/OLI two bands ratio algorithm for chlorophyll-a concentration mapping in hypertrophic waters: An application to West Lake in Hanoi (Vietnam). *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 10(11):4919–4929
- Ha NTT, Thao NTP, Koike K, and Nhuan MT (2017b) Selecting the best band ratio to estimate chlorophyll-a concentration in a tropical freshwater lake using sentinel 2A images from a case study of Lake Ba Be (Northern Vietnam). *ISPRS International Journal of Geo-Information* 6:290
- Han L and Jordan KJ (2005) Estimating and mapping chlorophyll-a concentration in Pensacola Bay, Florida using Landsat ETM+ data. *International Journal of Remote Sensing*, Taylor & Francis 26(23):5245–5254
- Hellweger FL, Schlosser P, Lall U, and Weissel JK (2004) Use of satellite imagery for water quality studies in New York Harbor. *Estuarine, Coastal and Shelf Science*, Elsevier 61(3):437–448
- Hoagland P and Scatosta S (2006) The economic effects of harmful algal blooms. *Ecology of Harmful Algae*, Springer, 391–402
- Ilori CO, Pahlevan N, and Knudby A (2019) Analyzing performances of different atmospheric correction techniques for Landsat 8: application for coastal remote sensing. *Remote Sensing* 11:469
- Iranian Water and Power Resources Development Company (IWPCO) (2018) Urmia Lake: Results of limnological and biological monitoring of main water body and satellite wetlands of Lake Urmia. *Iranshenasi*, Tehran, Iran (In Persian)
- Jellison R and Melack JM (2001) Nitrogen limitation and particulate elemental ratios of seston in hypersaline Mono Lake, California, USA. *Saline Lakes*. Springer, 1–12
- Jensen JR (2011) Sensoriamento remoto do ambiente: Uma perspectiva em recursos terrestres. Parêntese: São José dos Campos, Brasil (In Portuguese)
- Kallio K (2000) Remote sensing as a tool for monitoring lake water quality. *Hydrological and Limnological Aspects of Lake Monitoring*, John Wiley & Sons, Ltd. Chichester, England 14:237
- Kallio K, Kutser T, Hannonen T, Koponen S, Pulliainen J, Vepsäläinen J, and Pyhälähti T (2001) Retrieval of water quality from airborne imaging spectrometry of various lake types in different seasons. *Science of the Total Environment*, Elsevier 268(1–3):59–77
- Karaoui I, Arioua A, Boudhar A, Hssaisoune M, El Mouatassime S, Ouhamchich KA, Elhamdouni D, Idrissi AEA, and Nouaim W (2019) Evaluating the potential of Sentinel-2 satellite images for water quality characterization of artificial reservoirs: The Bin El Ouidane Reservoir case study (Morocco). *Meteorology Hydrology and Water Management, Research and Operational Applications* 7(1):31–39
- Karimi N, Bagheri MH, Hooshyaripor F, Farokhnia A and Sheshangosht S (2016) Deriving and evaluating bathymetry maps and stage curves for shallow lakes using remote sensing data. *Water Resources Management*, Springer 30(14):5003–5020
- Kloiber SM, Brezonik PL, Olmanson LG, and Bauer ME (2002) A procedure for regional lake water clarity assessment using Landsat multispectral data. *Remote sensing of Environment*, Elsevier 82(1):38–47
- Kutser T (2012) The possibility of using the Landsat image archive for monitoring long time trends in coloured dissolved organic matter concentration in lake waters. *Remote Sensing of Environment*, Elsevier 123:334–338
- Kutser T, Kallio K, Eloheimo K, Hannonen T, Pyhälähti T, Koponen S, and Pulliainen J (1999) Quantitative monitoring of water properties with the airborne imaging spectrometer AISA. *Proceedings of the Estonian Academy of Sciences: Biology, Ecology* 48(1):25–36
- LAILIA NL, Arafah F, Jaelani A, and PAMUNGKAS AD (2015) Development of water quality parameter retrieval algorithms for estimating total suspended solids and chlorophyll-A concentration using Landsat-8 imagery at Poteran island water. *Remote Sensing and Spatial Information Sciences* 2(2)
- Lin J-L, Karangan A, Huang YM, and Kang S-F (2022) Eutrophication factor analysis using Carlson trophic state index (CTSI) towards non-algal impact reservoirs in Taiwan. *Sustainable Environment Research*, Springer 32(1):1–12
- Lins RC, Martinez J-M, Motta Marques D Da, Cirilo JA and Fragoso CR (2017) Assessment of chlorophyll-a remote sensing algorithms in a productive tropical estuarine-lagoon system. *Remote Sensing* 9:516
- Morel A and Prieur L (1977) Analysis of variations in ocean color 1. *Limnology and Oceanography*, Wiley Online Library 22(4):709–722
- Ouma YO, Noor K, and Herbert K (2020) Modelling reservoir chlorophyll-a, TSS, and turbidity using Sentinel-2A MSI and Landsat-8 OLI satellite sensors with empirical multivariate regression. *Journal of Sensors*, Hindawi: 1-21

- Parsinejad M, Rosenberg DE, Govarchin Ghale YA, Khazaei B, Null S, Raja O, Safaie A, Sima S, Sorooshian A, and Wurtsbaugh WA (2021) 40-Years of Lake Urmia restoration research: Synthesis and Next Steps. *Science of the Total Environment*, Elsevier (832), 1 August 2022, 155055
- Prasad S, Saluja R, and Garg JK (2020) Assessing the efficacy of Landsat-8 OLI imagery derived models for remotely estimating chlorophyll-a concentration in the Upper Ganga River, India. *International Journal of Remote Sensing*, Taylor & Francis 41(7):2439–2456
- Ramaswamy S, Rastogi R, and Shim K (2000) Efficient algorithms for mining outliers from large data sets. *Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data*, 427–438
- Saberioon M, Brom J, Nedbal V, Souček P, and Císar P (2020) Chlorophyll-a and total suspended solids retrieval and mapping using Sentinel-2A and machine learning for inland waters. *Ecological Indicators*, Elsevier 113:106236
- Safavi S, Saghafian B, and Hosseini SA (2020) Characterizing flow pattern and salinity using the 3D MIKE 3 model: Urmia Lake case study. *Arabian Journal of Geosciences*, Springer 13(3):1–12
- Sharma MP, Kumar A, and Rajvanshi S (2010) Assessment of trophic state of lakes: A case of Mansi Ganga Lake in India. *Hydro Nepal: Journal of Water, Energy and Environment* 6:65–72
- Sima S, Rosenberg DE, Wurtsbaugh WA, Null SE and Kettenring KM (2021) Managing Lake Urmia, Iran for diverse restoration objectives: Moving beyond a uniform target lake level. *Journal of Hydrology: Regional Studies*, Elsevier 35:100812
- Smith VH and Schindler DW (2009) Eutrophication science: Where do we go from here? *Trends in Ecology & Evolution*, Elsevier 24(4):201–207
- Strömbeck N, Candiani G, Giardino C, and Zilioli E (2003) Water quality monitoring of Lake Garda using multi-temporal MERIS data. *Proceedings of MERIS User Workshop*
- Sudheer KP, Chaubey I, and Garg V (2006) Lake water quality assessment from landsat thematic mapper data using neural network: an approach to optimal band combination selection. *JAWRA, Journal of the American Water Resources Association*, Wiley Online Library 42(6):1683–1695
- Sváb E, Tyler AN, Preston T, Présing M, and Balogh K V (2005) Characterizing the spectral reflectance of algae in lake waters with high suspended sediment concentrations. *International Journal of Remote Sensing*, Taylor & Francis 26(5):919–928
- Swanson ER (1998) Trophic state index revisited. *LakeLine* 18(4):18–20
- Tarh-e-Noandishan (2020) Hydrodynamic investigation of adding extra openings along the causeway of Lake Urmia. Tarh-e-Noandishan Consulting Company, Tehran, Iran (In Persian)
- Toming K, Kutser T, Laas A, Sepp M, Paavel B, and Nõges T (2016) First experiences in mapping lake water quality parameters with Sentinel-2 MSI imagery. *Remote Sensing* 8:640
- Torbick N, Hu F, Zhang J, Qi J, Zhang H, and Becker B (2008) Mapping chlorophyll-a concentrations in West Lake, China using Landsat 7 ETM+. *Journal of Great Lakes Research*, Elsevier 34(3):559–565
- Vanhellemont Q and Ruddick K (2014) Turbid wakes associated with offshore wind turbines observed with Landsat 8. *Remote Sensing of Environment*, Elsevier 145:105–115
- Wang F, Han L, Kung H and Van Arsdale RB (2006) Applications of Landsat-5 TM imagery in assessing and mapping water quality in Reelfoot Lake, Tennessee. *International Journal of Remote Sensing*, Taylor & Francis 27(23):5269–5283
- Watanabe F, Alcántara E, Rodrigues T, Rotta L, Bernardo N, and Imai N (2017) Remote sensing of the chlorophyll-a based on OLI/Landsat-8 and MSI/Sentinel-2A (Barra Bonita reservoir, Brazil). *Anais da Academia Brasileira de Ciências. SciELO Brasil* 90:1987–2000
- Watanabe FS, Alcântara E, Rodrigues TW, Imai NN, Barbosa CC, and Rotta LH (2015) Estimation of chlorophyll-a concentration and the trophic state of the Barra Bonita Hydroelectric Reservoir using OLI/Landsat-8 Images. *International Journal of Environmental Research and Public Health* 12:10391-10417
- Wong T-T (2015) Performance evaluation of classification algorithms by k-fold and leave-one-out cross validation. *Pattern Recognition*, Elsevier 48(9):2839–2846
- Wu M, Zhang W, Wang X, and Luo D (2009) Application of MODIS satellite data in monitoring water quality parameters of Chaohu Lake in China. *Environmental monitoring and assessment*, Springer 148(1):255–264

- Yadav S, Yamashiki Y, Susaki J, Yamashita Y, and Ishikawa K (2019) Chlorophyll estimation of lake water and coastal water using Landsat-8 and Sentinel-2a Satellite. *International Archives of the Photogrammetry, Remote Sensing, & Spatial Information Sciences*
- Zeinoddini M, Tofighi MA, and Vafae F (2009) Evaluation of dike-type causeway impacts on the flow and salinity regimes in Urmia Lake, Iran. *Journal of Great Lakes Research, Elsevier* 35(1):13–22
- Zhang T, Huang M, and Wang Z (2020) Estimation of chlorophyll-a Concentration of lakes based on SVM algorithm and Landsat 8 OLI images. *Environmental Science and Pollution Research, Springer* 27(13):14977–14990