



Journal of Environmental Studies

Vol. 46, No. 2, Summer 2020

Journal Homepage: www.Jes.ut.ac.ir

Print ISSN: 1025-8620 Online ISSN 2345-6922

Monitoring and Modeling of Urmia Lake Area Variations Using Artificial Neural Network

Document Type
Research Paper

Ali Radman, Mehdi Akhoondzadeh*

Received
January 1, 2020

Department of Photogrammetry and Remote Sensing, School of Surveying and Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran

Accepted
April 13, 2020

DOI: [10.22059/JES.2021.304189.1008026](https://doi.org/10.22059/JES.2021.304189.1008026)

Abstract

Urmia Lake is one of the largest hypersaline lakes in the world and the largest inland body of salt water in northwest of Iran, which has been in a critical situation over the last few years. In this paper, Urmia lake and its basin variations were monitored, then the ability of artificial neural network for predicting the lake's area was evaluated. For observing environmental variations, monthly precipitation was computed using TRMM satellite dataset. Terrestrial Water Storage (TWS) and TWS Anomaly (TWSA) were estimated from GLDAS hydrological dataset and GRACE mission respectively. To monitor lake itself Jason-1, Jason-2/OSTM, Jason-3, and MODIS satellite altimetry and MODIS data were used to compute lake's Water Level (WL) and area. These five parameters were estimated over 183 months from April 2002 to June 2017. Moreover, variation of the lake during that period was modeled, using two ANN methods of MLP and LSTM. The LSTM model reached RMSE (for normalized data) of 0.0511 which demonstrates its reliability. To predict Urmia lake's further changes, 4 model were constructed to predict lake area in next 3, 6, 9, and 12 months. Hence, the LSTM network modeled next 3 and 6 month with a suitable RMSE (0.0882) and also with an appropriate ability to predict area fluctuation caused by seasonal changes.

Keywords: ANN, Neural network, Prediction, Urmia Lake, Water level

* Corresponding author

Email: makhonz@ut.ac.ir

Expanded Abstract

Introduction

Due to increase of water exploitation and drought, the need for water resources has been risen in past decades. Numerous regions around the world are under threat of environmental crisis, as a result of climate change. Declination in the amount of precipitation can be led to various subsequences, such as significant reduction in the level of ground and surface water, e.g., lakes. Through the development of satellite imagery systems, it is possible to monitor and evaluate changes in rainfall, groundwater level, surface water area, and level.

Urmia Lake is one of the largest hypersaline lakes in the world and the largest inland body of salt water in northwest of Iran. The lake and its corresponding basin were in a catastrophic situation and under threat of drying up. The lake's area and WL were decreasing from 1995 due to climatic change and anthropogenic activities. Irrigation expansion after 2000 was indicated as the dominant human driver of the Lake Urmia desiccation.

Remote sensing provides certain tools for monitoring lakes and their basin over time and space. Numerous studies have been conducted to observe and evaluate climate change after the launch of Gravity Recovery and Climate Experiment (GRACE) satellite mission. GRACE dataset has been used widely to determine water storage variations over the world as well as Iran. This satellite data has been used for various purposes including ground and surface water monitoring. Employing this dataset beside precipitation and satellite altimetry data have been used for observing changes in watersheds and lakes in numerous studies. Modelling and predicting environmental and climate changes are always an important task. Gathering several remote sensing data and predicting them would be helpful mostly for disaster management and also decision making.

Therefore, it is possible to observe and evaluate variation in rainfall, groundwater level, surface water area, and level. In this study, Urmia Lake and its watershed changes were monitored using various satellite data such as TRMM, GLDAS, GRACE, MODIS. Moreover, machine-learning based methods were developed to predict the lake surface changes.

Materials and Methods

To monitor Urmia Lake changes, several data were used to survey variation in precipitation, ground and surface water storage, lake water level, and area in 183 months from April 2002 to June 2017. Sufficient temporal resolution of the data is an essential factor in monitoring of changes through the time. Accordingly, for monitoring the overall change of the Urmia lake, we prefer a satellite data with at least monthly temporal resolution. Therefore, overall variations of the lake and its corresponding basin were modeled using these data with adequate temporal resolution.

Tropical Rainfall Measuring Mission (TRMM) is an international collaboration which aims to observe rainfall for environmental studies. TRMM data provides precipitation in various temporal and spatial resolutions. In this study, TRMM-3b43 level 3 monthly data, with 0.25 degree spatial resolution estimates rainfall in Urmia lake basin, including 83 pixels in each time step.

The GLDAS hydrological model consists of various variables (e.g., soil temperature, soil moisture, precipitation, etc.). In this study, the GLDAS data with 1 degree spatial resolution provides terrestrial water storage (TWS) by integrating soil moisture (kg m^{-2}), snow water equivalent (kg m^{-2}), and canopy water storage (kg m^{-2}). Three types of monthly GLDAS model data (MOS, VIC, and NOAH) were hired for this purpose.

GRACE is a joint mission between Germany and the USA, giving information about mass changes within Earth. The level 2 (RL05) data was of GRACE used to monitor TWSA, which was computed

from spherical harmonics using methods developed by Wahr and Swanson. In addition, a 300 km Gaussian filter was applied to reduce high frequency noises.

The investigated Global Reservoirs and Lakes Monitor (G-REALM) dataset including Jason-1, Jason-2/OSTM, and Jason-3 altimeters were employed to survey Water Level (WL) variation of Urmia lake. In order to monitor lake extent changes during the 17 years, MODIS atmospheric corrected product MOD09Q1 version 6 data, with 250 m spatial and 8-day temporal resolution was used through Google Earth Engine. The product provides surface spectral reflectance of bands 1 and 2, which is the composite of 8 products with the absence of clouds, cloud shadow, and aerosol loading. Although, the Normalized Difference Water Index (NDWI) is a common method to separate water from land and it also had the best result on Landsat data, Normalized Difference Vegetation Index (NDVI) performs transcendent distinguishing between water and land while using MODIS data and also in the specific case of Urmia Lake. Therefore, in this study, the NDVI index was chosen as an appropriate index to separate water and non-water. To determine lake area, first, water region was detected. Then, area of water extent was computed as lake area.

For modeling the lake's area variation, machine learning based methods were investigated. As a time-series prediction problem, a Multilayer Perceptron (MLP) and a Long Short-Term Memory (LSTM) networks were constructed using TRMM rainfall, GLDAS, GRACE TWS, and altimeter WL as inputs (predictors) of the models, and lake's area as Target. About 80% of data was assigned to training, 10% to validation, and the same portion to test. A feedforward MLP including one hidden layer and 5 neurons and a Recurrent LSTM network with same hidden layer and 10 neurons, were obtained. In order to evaluate network's performance, Root Mean Square Error (RMSE) was used. In addition, the delay parameter of 12 months or one year was chosen for estimating future variations.

Discussion of Results

Except seasonal changes, amount of monthly rainfall during the mentioned period experienced a significant decrease from 2004 to 2008, and then it fluctuates to 2017. The changes in precipitation rate can affect other parameters considerably. As a result, water mass variation obtained from GLDAS data, falls from 2003 to 2008, and after that, similarly to rainfall variation, it fluctuates. However, TWSA computed by GRACE data, after reduction to 2008 and rise to 2010, behaved otherwise, and it went down steadily to 2017. Urmia Lake WL declined during the whole period. This decrement was intensified from 2006 to 2010, after that it halted gradually to 2017 as consequence of increase in rainfall rate. Area of the lake decreased from 2004 to 2015, also it faced an extreme fall in 2008. Next, to 2017, the area increased slightly.

Due to a decade drought of Urmia Lake, it was in critical circumstance. Consequently, estimating future variation of the lake is necessary. Instead of using physical models or assessing the impact of each parameter on the surface of the lake directly and indirectly, which are complicated tasks, a machine-learning based method is hired. Disregarding the exact relation between factors, this learning-based method can determine and model changes. By using two of the most common ANN based methods including MLP and LSTM, variation of the lake during that period was modeled.

MLP and LSTM models reached overall RMSE (for normalized data) of 0.0586 and 0.0511, respectively, which indicates reliability of both models for predicting lake area changes; however, LSTM network performed superior specially over test data (RMSE of 0.0487). In addition, to predict Urmia Lake's further changes and assess LSTM model capabilities comprehensively, four networks were constructed to predict lake area of next 3, 6, 9, and 12 months. Accordingly, result demonstrates LSTM abilities for predicting upcoming year variation of the lake with RMSE of 0.0882 (better than

prediction for 6 and 9 months).

Conclusions

Variation in each part of environment and climate (such as rainfall, TWS, WL and area of lakes) affects others. Therefore, it is possible to monitor and model these relations between the parameters. In this study, two ANN methods of MLP and LSTM were investigated to model Urmia Lake surface area which the LSTM model performed transcendent. Moreover, LSTM method provides a model which is able to predict the lake area of next 12 months with a high accuracy.

In order to improve the network's accuracy, it is suggested to increase the number of data and parameters, which are used as network input. It would help the network to implement the training stage with a higher capability to recognize diverse situations properly.

پایش و مدل‌سازی تغییرات سطحی دریاچه ارومیه با استفاده از شبکه عصبی مصنوعی

علی رادمان، مهدی آخوندزاده هنزایی*

گروه فتوگرامتری و سنجش از دور، دانشکده مهندسی نقشه برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران، تهران، ایران.

تاریخ پذیرش مقاله: ۱۳۹۹/۰۱/۲۵

تاریخ وصول مقاله: ۱۳۹۸/۱۰/۱۱

چکیده

دریاچه ارومیه یکی از بزرگترین پهنه‌های آبی شور در جهان است که در سال‌های اخیر در شرایط بحرانی قرار داشته است. در این مطالعه، تغییرات این دریاچه و حوضه آبخیز آن بررسی شد. سپس قابلیت‌های شبکه عصبی مصنوعی در پیش‌بینی تغییرات سطحی دریاچه ارزیابی شد. بدین ترتیب با استفاده از داده‌های سنجنده TRMM، مدل هیدرولوژیکی GLDAS، سنجنده GRACE، سری ماهواره‌های ارتفاع سنجی Jason و همچنین تصاویر MODIS به ترتیب میزان بارش، تغییرات احجام آبی سطحی و زیر سطحی (TWS)، تغییرات ارتفاعی و سطحی دریاچه ارومیه در بازه ۱۸۳ ماه بین آوریل ۲۰۰۲ تا ژوئن ۲۰۱۷ محاسبه شد. در ادامه با استفاده از دو روش مبتنی بر یادگیری ماشین MLP و LSTM و به‌کارگیری پارامترهای مؤثر بر تغییرات سطحی دریاچه به‌عنوان ورودی شبکه، تغییرات سطحی دریاچه با جذر خطای مربعات مانده‌های ۰/۰۵۱۱ توسط شبکه بهینه LSTM مدل‌سازی شد. همچنین به‌منظور پیش‌بینی تغییرات سطحی دریاچه برای مدت زمان طولانی‌تر، چهار مدل برای تخمین تغییرات ۳، ۶، ۹ و ۱۲ ماه بعد، تشکیل شدند که در نتیجه آن، شبکه LSTM این تغییرات را برای یک سال آینده با دقتی بالا (جذر خطای مربعات مانده‌های ۰/۰۸۸۲) و توانایی مناسب در شناسایی تغییرات فصلی، تخمین زد.

کلیدواژه‌ها: ارتفاع سنجی، دریاچه ارومیه، شبکه عصبی، مدل‌سازی، GRACE

سراغاز

برداشت بیش از حد آب‌های سطحی و زیر سطحی، در معرض خطرات بسیاری قرار دارد (Zarghami, 2011); (Delju et al., 2013). خشک شدن این دریاچه خسارات و پیامدهای جبران‌ناپذیری خواهد داشت. با توسعه سیستم‌های ماهواره‌ای، پایش و بررسی محیط زیست با استفاده از روش‌های دور سنجی ممکن شده که با توجه به هزینه و زمان‌بر بودن پایش‌های زیست‌محیطی، سنجش از دور بسیار کارا و مفید به نظر می‌رسد. کاهش بارندگی پیامدهای بسیاری دارد که مهم‌ترین آن‌ها کاهش سطح آب‌های

در سال‌های اخیر با توسعه شهرها، کارخانه‌ها و گسترش کشاورزی نیاز به منابع آبی رو به افزایش است. مناطق بسیاری در سراسر جهان تحت تأثیر بحران‌های زیست‌محیطی و همچنین خشک‌سالی قرار گرفته‌اند. دریاچه ارومیه یکی از زیست‌بوم‌های مهم و از مناطق حیاتی است که در سال‌های اخیر با مشکلات بسیاری مواجه بوده و در معرض خشک شدن قرار دارد. این دریاچه بزرگترین سطح آبی داخلی ایران است که با توجه به بحران خشک‌سالی و

Email: makhonz@ut.ac.ir

* نویسنده مسئول:

DOI: [10.22059/JES.2021.304189.1008026](https://doi.org/10.22059/JES.2021.304189.1008026)

DOR [20.1001.1.10258620.1399.46.2.4.5](https://doi.org/20.1001.1.10258620.1399.46.2.4.5)

ارتباط آن با بارندگی‌ها صورت گرفته است. Yang Zhou و همکارانش (۲۰۱۶) تغییرات ذخایر آب حوضه آبخیز دریاچه Poyang را با استفاده از داده‌های ماهواره‌ای مختلف بررسی کردند. در این مطالعه از سال ۲۰۰۳ تا ۲۰۱۴ با استفاده از داده‌های ثقل سنجی GRACE تغییرات آب‌های منطقه تخمین زده شد و با استفاده از داده‌های مدل جهانی GLDAS و سنجنده TRMM^۱، تأثیرات رطوبت خاک و بارندگی به ترتیب بر تغییرات آب‌های زمینی و داده‌های ارتفاع سنجی ماهواره‌ای بررسی شد و نشان داد در بازه زمانی مورد بررسی با یکدیگر ارتباط بالایی دارند و داده‌های ذخایر آب زمینی به دست آمده به شدت تحت تأثیر تغییرات رطوبت خاک و بارندگی منطقه قرار دارد.

از طرفی دریاچه ارومیه با توجه به خشک‌سالی سال‌های اخیر یکی از مناطق مورد توجه است که تحقیقات بسیاری در پایش تغییرات این منطقه انجام شده است (Alesheikh et al., 2007; Dastranj et al., 2018). در تحقیقی که توسط M.J. Tourian و همکارانش (۲۰۱۵) انجام شد با استفاده از داده‌های مختلف وضعیت دریاچه ارومیه از سال ۲۰۰۲ تا ۲۰۱۴ بررسی شد. با استفاده از داده ثقل‌سنجی GRACE، داده‌های ارتفاع‌سنجی ماهواره‌های ENVISAT و CryoSat-2، تصاویر اپتیکی MODIS و از طریق روش طبقه‌بندی بدون نظارت ISODATA و همچنین داده‌های بارندگی، تغییرات حوضه آبخیز دریاچه ارومیه را بررسی کردند. در مطالعه‌ای دیگر بهرام خزائی و همکاران (۲۰۱۹) به بررسی علل خشک‌سالی دریاچه ارومیه پرداختند. در این راستا از ۱۹۸۱ تا ۲۰۱۵ از داده‌های بارندگی و دمایی برای بررسی شرایط جوی، داده‌های رطوبت خاک و ارتفاعی برای تغییرات هیدرولوژیکی و همچنین داده‌های پوشش گیاهی برای پایش تغییرات منطقه استفاده کردند. علاوه بر این از طریق شاخص NDVI^۵ و داده‌های سنجنده MODIS، تغییرات پوشش گیاهی بررسی شد. از طریق محصول GREALM^۶ که از داده‌های سری‌های مختلف سنجنده Jason و Topex استفاده کرده

زیرزمینی و آب‌های سطحی از جمله دریاچه‌ها است. با استفاده از داده‌های ماهواره‌ای امکان پایش ویژگی‌های مختلف فراهم آمده است. بدین ترتیب امکان بررسی میزان بارندگی در طول زمان، تغییرات آب‌های زیرزمینی با استفاده از ماهواره‌های ثقل‌سنجی، تغییرات آب‌های سطحی مانند دریاچه‌ها با استفاده از تصاویر نوری و تغییرات ارتفاعی دریاها و دریاچه‌ها از طریق داده‌های ارتفاع سنجی میسر است.

به‌منظور پایش تغییرات زیست‌محیطی تحقیقات بسیاری با ترکیب داده‌های ماهواره‌ای انجام گرفته، از جمله مطالعاتی در مناطق مختلف ایران برای محاسبه تغییرات آب‌های زمینی و زیرزمینی صورت گرفته است. در این راستا زهره فرجی و همکارانش (۲۰۱۷) در تحقیقی به بررسی قابلیت داده‌های سنجنده GRACE^۱ در برآورد تغییرات آب‌های زیرزمینی منطقه دشت قزوین از سال ۲۰۰۳ تا ۲۰۱۰ پرداختند و از داده‌های مشاهدات زمینی و مدل GLDAS^۲ برای مقایسه و ارزیابی بهره بردند. همچنین فروتن و همکارانش (۲۰۱۴) در پژوهشی الگوی تغییرات ذخایر آبی ایران از طریق داده‌های GRACE، ارتفاع سنجی و هیدرولوژیکی از سال ۲۰۰۲ تا ۲۰۱۱ را محاسبه کردند. بدین ترتیب با استفاده از داده‌های ثقل سنجی GRACE تغییرات سطحی و زیر سطحی آب‌ها را اندازه‌گیری کردند و با کمک داده‌های ارتفاع سنجی و همچنین GLDAS آن را به اجزایش تقسیم کرده و با حذف اجزای دیگر تغییرات آب‌های زیرزمینی را برای کل منطقه ایران برآورد کردند. علی اشرف‌زاده و همکارانش (۲۰۱۶) با استفاده از داده‌های ثقل سنجی GRACE و مدل‌های هیدرولوژی GLDAS و CLM4^۳ تغییرات ذخایر آب‌های زمینی و زیرزمینی ایران از سال ۲۰۰۲ تا ۲۰۱۰ را تخمین زدند که منابع غیر طبیعی از جمله عوامل انسانی به‌عنوان علت کاهش آب‌های زیرزمینی شناسایی شدند.

برای انجام پایش‌های زیست‌محیطی دریاچه‌ها، علاوه بر پایش آب‌های سطحی و زیر سطحی، پژوهش‌هایی به‌منظور محاسبه تغییرات ارتفاعی سطح آب دریاچه‌ها و

۱۹۸۲ تا ۲۰۰۲ را تخمین زدند و به بررسی تغییرات ماهیانه بلند مدت در منطقه پرداختند.

بدین ترتیب تحقیقات بسیاری در زمینه تغییرات هیدرولوژیکی مناطق مختلف به‌ویژه پهنه‌های آبی و حوضه‌های آبخیز صورت گرفته است که در آن‌ها عمدتاً به روند تغییرات یا تأثیر یکی از عوامل بر دیگری اعتنا شده اما کمتر به مدل کردن تمامی عوامل به صورت یکجا و بررسی تأثیر آن‌ها بر بروز یک بحران زیست‌محیطی پرداخته شده است. با توجه به قابلیت داده‌های مختلف ماهواره‌ای، تأثیر آن‌ها بر یکدیگر و همچنین مدل‌های مختلف، در پژوهش پیش‌رو پارامترهای مختلف مؤثر بر خشک شدن دریاچه ارومیه نظیر تغییرات میزان بارندگی، تغییرات آب‌های زمینی و زیرزمینی، روند تغییرات ارتفاعی و سطحی دریاچه ارومیه بررسی شده و سپس با استفاده از روش‌های مختلف مدل‌سازی، روند تغییرات سطحی دریاچه ارومیه مدل‌سازی و پیش‌بینی می‌شود.

منطقه مورد مطالعه

منطقه مورد مطالعه حوضه آبریز دریاچه ارومیه در شمال غرب ایران است (عرض جغرافیایی بین ۳۵/۵ و ۳۸/۸ شمالی و طول جغرافیایی بین ۴۴ و ۴۸ شرقی) که با بخش شمالی کوه‌های زاگرس و دامنه غربی البرز احاطه شده است (شکل ۱).



شکل ۱. موقعیت حوضه آبخیز دریاچه ارومیه، واقع در شمال غربی ایران

است، تغییرات ارتفاعی دریاچه ارومیه به دست آمده و بدین ترتیب به آنالیز ارتباط میان پارامترهای مختلف و روند خشک‌سالی پرداختند.

در تحقیقاتی نیز به‌منظور پیش‌بینی و تخمین تغییرات زیست‌محیطی از داده‌های مختلف ماهواره‌ای بهره گرفته شده است (Long et al., 2014; Sun, 2013). از جمله این مطالعات Gonca Okay Ahi و همکاران (۲۰۱۹) به بررسی تغییرات ذخایر آب‌های زیرزمینی و پارامترهای مؤثر بر آن نظیر بارش، رطوبت خاک و تغییرات شرایط آب و هوایی در ترکیه پرداختند. بدین منظور از داده‌های ثقلسنجی GRACE، مدل GLDAS، داده‌های بارندگی TRMM و شاخص‌های مختلف خشک‌سالی استفاده کردند. در نتیجه این مطالعات دریافتند خروجی GRACE به تخمین زودتر خشک‌سالی کمک می‌کند. همچنین داده‌های بارندگی تأثیرات بسزایی بر تغییرات احجام آبی دارند. در پژوهشی که در همان سال صورت گرفت Hao Chen و همکاران (۲۰۱۹) تغییرات بلند مدت آب‌های زیرزمینی در حوضه آبخیز رودخانه Songhua را با استفاده از داده‌های GRACE و داده‌های مدل سطح زمین GLDAS بررسی کردند. با توجه به اینکه داده‌های GRACE از سال ۲۰۰۲ در دسترس هستند، با استفاده از این داده از سال ۲۰۰۳ تا ۲۰۱۳ و همچنین داده‌های مدل سطح زمین GLDAS، با روش‌های مبتنی بر شبکه عصبی تغییرات آب زیرزمینی منطقه از

مواد و روش‌ها

در این تحقیق از داده‌های مختلفی برای پایش حوضه آبخیز دریاچه ارومیه بهره گرفته شده که به اختصار در جدول ۱ آمده‌اند. با توجه به اینکه هدف پایش تغییرات کلی دریاچه ارومیه و عوامل مؤثر بر آن با استفاده از داده‌های دور سنجی و ماهواره‌ای است، استفاده از داده‌هایی با پیوستگی زمانی کافی به گونه‌ای که در هر ماه حداقل یک مقدار برای هر پارامتر مورد محاسبه در دسترس باشد بر توان تفکیک مکانی ارجحیت دارد. از این طریق تغییرات کلی محاسبه شده و سپس این تغییرات مدل‌سازی می‌شوند. در ادامه هر یک از این داده‌ها و روش مورد استفاده با جزئیات بیشتر تشریح می‌شوند.

دریاچه ارومیه دومین دریاچه شور جهان است (Hassanzadeh et al., 2012)، که بین آذربایجان غربی و شرقی در منطقه‌ای نیمه‌خشک و سرد قرار دارد. (Rohli et al., 2015). دریاچه ارومیه و حوضه آبخیز مربوطه در سال‌های اخیر در موقعیت بحرانی و در معرض خطر خشک شدن قرار داشته‌اند (Alborzi et al., 2018). سطح و ارتفاع دریاچه از سال ۱۹۹۵ به دلیل تغییرات اقلیمی و فعالیت‌های انسانی در حال کاهش بوده‌اند (Karbassi et al., 2010; Delju et al., 2013). آبیاری بیش از حد زمین‌های کشاورزی بعد از سال ۲۰۰۰ به‌عنوان علت اصلی انسانی بحران‌های به وجود آمده برای این منطقه شناخته شده است (Khazaei et al., 2019). با توجه به بحران خشک‌سالی که گریبان‌گیر این ناحیه شده، در این مقاله به بررسی تغییرات این منطقه پرداخته می‌شود.

جدول ۱. خلاصه‌ای از داده‌ها و سنجنده‌های مورد استفاده در این تحقیق

متغیر مورد بررسی	سنجنده	مدل / نسخه مورد استفاده	بازه زمانی
بارندگی	TRMM	Level 3 (TRMM-3b43)	آوریل ۲۰۰۲ - ژوئن ۲۰۱۷
احجام آبی	GRACE GLDAS	Level 2 (RL05) NOAH	
ارتفاع سطح دریاچه	Jason-1 Jason-2/OSTM Jason-3	-	
مساحت سطح دریاچه	Terra MODIS	MOD09Q1	

سطح طبقه‌بندی می‌شود و سطح ۳ را محصولات اقلیمی می‌نامند. داده‌های این محصول منطقه بین ۵۰ درجه جنوبی تا ۵۰ درجه شمالی را پوشش می‌دهند. در این مطالعه از داده ماهیانه Level 3 (TRMM-3b43) با توان تفکیک مکانی ۰/۲۵ درجه بهره گرفته شده. این محصول ترکیبی از برآوردهای ماهواره‌ای 3B42 و داده‌های زمینی است (Feidas, 2010; Huffman et al., 2007). بدین ترتیب در ۱۸۳ ماه از ماه آوریل سال ۲۰۰۲ تا ژوئن ۲۰۱۷ بارندگی در حوضه آبریز دریاچه ارومیه دریافت و مجموع بارش ماهیانه اندازه‌گیری شد.

داده‌های بارش TRMM

سنجنده Tropical Rainfall Measuring Mission در سال ۱۹۹۷ با همکاری VNASA و سازمان فضایی ژاپن (JAXA) به منظور مطالعه بارندگی و بررسی دقیق وضعیت آب و هوا کار خود را آغاز کرد. از طریق این داده میزان بارندگی در مقیاس‌های مختلف زمانی و مکانی ثبت می‌شود. بدین ترتیب امکان انجام پایش‌ها با بررسی پیوستگی مکانی و در فواصل کوتاه زمانی، فراهم می‌شود. سنجنده‌های بررسی میزان بارش در ماهواره TRMM شامل رادار بارش، تصویرگر میکروویو TRMM و اسکترهای مرئی و فرسرخ است. محصولات این ماهواره در سه

سطوح مختلف منتشر می کنند. اگرچه هر سه مرکز از داده خام یکسانی استفاده می کنند اما به دلیل بهره گیری از روش های مختلف پردازشی و تصحیحات اعمال شده مدل ها با یکدیگر تفاوت جزئی دارند.

ماهواره GRACE قادر است تغییرات میدان ثقل زمین که نشان دهنده تغییرات احجام آبی است را نمایش دهد. در این راستا از داده های سطح ۲ (RL05) هر سه مرکز تحقیقاتی استفاده شد و در انتها از نتایج به دست آمده سه مرکز، که بسیار به هم نزدیک هستند، میانگین گرفته شد. بدین ترتیب ۱۶۳ داده ماهیانه از آوریل ۲۰۰۲ تا ژوئن ۲۰۱۷ با توان تفکیک مکانی یک درجه دریافت شد، برای ۲۰ ماه به صورت پراکنده داده ای ثبت نشده که در انتها به صورت خطی درونیابی شدند. با استفاده از روش معرفی شده توسط سونسن و همکاران ضرایب هارمونیک درجه یک محاسبه شد (Swenson et al., 2008). از آنجایی که ضرایب زونال درجه دو C20 چندان دقیقی نیستند با داده های SLR^{۱۵} جایگزین شود (Cheng et al., 2011). داده های ماهیانه به دست آمده از طریق رابطه زیر به تغییرات ارتفاع آب معادل تبدیل می شوند (Wahr et al., 1998).

$$\Delta\eta = \frac{a\rho_{ava}}{3\rho_w} \sum_{l=0}^{\infty} \sum_{m=0}^l \frac{2l+1}{1+k_l} \tilde{P}_{lm}(\cos\theta) [\Delta C_{lm} \cos(m\phi) + \Delta S_{lm} \sin(m\phi)] \quad (1)$$

در رابطه ۱، a شعاع کره زمین است. θ و ϕ به ترتیب متمم عرض جغرافیایی و طول جغرافیایی اند. $\rho_{ava} = 1000 \text{ kg/m}^3$ میانگین دانسیته زمین، $\rho_w = 1000 \text{ kg/m}^3$ دانسیته آب، k_l عدد لاو از درجه l و ΔC_{lm} و ΔS_{lm} تغییرات ماهیانه ضرایب هارمونیک کروی و \tilde{P}_{lm} توابع نرمالیزه لژاندر هستند. همچنین برای کاهش نویزهای با فرکانس بالا از یک فیلتر گاوسی ۳۰۰ کیلومتری استفاده می شود.

داده های ارتفاع سنجی

از دو دهه گذشته ماهواره های ارتفاع سنجی بسیاری پرتاب شده است. این فناوری پتانسیل بالایی به عنوان ابزاری کمکی در مقابل روش های سنتی مثل تایدگیج در

مدل های هیدرولوژی GLDAS

مدل GLDAS پروژه ای گروهی با همکاری NASA، NOAA^۹ و NCEP^{۱۰} است که از داده های ماهواره ای و تحقیقات هیدرولوژیکی بهره می برد. مدل GLDAS یک مدل عددی است که داده های سطح آب معادل را با توان تفکیک زمانی و مکانی یک ماه و یک درجه تأمین می کند. یکی آر ویژگی های این مدل، نداشتن داده در مناطق پوشیده شده از آب است. با توجه به اینکه مدل های هیدرولوژی مانند مدل هیدرولوژی GLDAS فقط در مناطق خشکی مقدار دارند، این مدل شامل دمای خاک، رطوبت خاک، آب معادل برف، روان آب های سطحی و زیر سطحی و بسیاری داده های دیگر است (Rodell et al., 2004). در این تحقیق از مدل NOAH با توان تفکیک مکانی یک درجه و به صورت ماهیانه استفاده شده است. بدین ترتیب که آب های سطحی و زیر سطحی (TWS^{۱۱}) به دست آمده از این مدل مجموعی از رطوبت خاک تا عمق ۲۰۰ سانتی متر، آب معادل برف و آب ذخیره شده در گیاهان (بر حسب km/m^2) است، از این طریق میزان آب زمینی برای حوضه آبخیز دریاچه ارومیه و در ۱۸۳ ماه مذکور، استخراج و محاسبه شد.

داده های ثقل سنجی GRACE

از سال ۲۰۰۲ با پرتاب ماهواره های ثقل سنجی GRACE، نسل جدیدی از داده های ماهواره ای فراهم آورده شد که امکان مطالعه تغییرات میدان ثقل زمین را میسر کرده اند. این داده ها کاربردهای متنوعی در علوم زمینی دارند. از آن جایی که علت اصلی تغییرات در میدان ثقل مربوط به تغییرات ذخایر آبی است، GRACE ابزار مناسبی برای این مطالعات است (Wahr et al., 1998).

مأموریت GRACE با همکاری بین سازمان های فضایی آلمان و آمریکا، اطلاعات تغییرات میدان ثقل زمین را ثبت می کند. این دو ماهواره از طریق سه مرکز تحقیقات فضایی دانشگاه تگزاس CSR^{۱۲}، مرکز تحقیقات علوم زمین آلمان GFZ^{۱۳} و آزمایشگاه JPL^{۱۴}، اطلاعات و داده ها را در

صورت عملی بهره گرفته. محصولات ارتفاعی سطح از طریق یک فرایند نیمه خودکار تولید می‌شوند و تغییرات ارتفاعی آب‌های سراسر جهان را در دسترس قرار می‌دهد. بدین ترتیب از طریق این مجموعه، داده‌های پردازش و تصحیح شده سنجنده‌های ارتفاع سنجی Jason-1 و Jason-2 و Jason-3 از سال ۲۰۰۲ تا ۲۰۱۷ دریافت شده و بررسی می‌شوند.



شکل ۲. مسیر عبور سری ماهواره Jason روی دریاچه ارومیه (Track 133)

محاسبه تغییرات سطحی دریاچه از طریق تصاویر نوری

به منظور بررسی تغییرات سطحی پهنه‌های آبی از جمله دریاچه‌ها، از داده‌های مختلف ماهواره‌ای نوری می‌توان بهره برد. تصاویر سری ماهواره‌های Landsat و MODIS از رایج‌ترین داده‌ها برای این مقصود هستند. در انتخاب سنجنده مناسب برای بررسی تغییرات، دو پارامتر توان تفکیک مکانی و توان تفکیک زمانی، بسیار حائز اهمیت هستند.

توان تفکیک Landsat در حدود ۳۰ متر است، در حالی که برای MODIS، ۲۵۰ متر است. هر چند Landsat در این مورد توانایی بسیار بهتری دارد اما با توجه به اینکه منطقه مطالعه شده بسیار بزرگ است، این اختلاف در محاسبه مساحت دریاچه ارومیه که در بازه مورد بررسی

پایش تغییرات سطح دریا دارد. ارتفاع سنجی ماهواره‌ای، روشی بر پایه مشاهدات فضایی برای دریاها و اقیانوس‌ها است. این روش در افزایش توان تفکیک مکانی نسبت به تایدگیج‌ها بسیار موفق بوده (Ducet et al., 2000). سری‌های مختلف ماهواره‌های ارتفاع سنج تاکنون به فضا پرتاب شده‌اند که با توجه به اینکه بازه زمانی مورد بررسی در این تحقیق از سال ۲۰۰۲ تا ۲۰۱۷ است و از طرفی با در نظر گرفتن بازه زمانی برداشت داده، از سری سنجنده‌های Jason استفاده شد.

سری ماهواره‌های Jason پروژه مشترکی بین NASA و آژانس فضایی فرانسه (CNES)^{۱۶} است. این سری ماهواره برای اندازه‌گیری تغییرات جهانی سطح دریا با دقت چند سانتی‌متر در سال طراحی شده و با دوره زمانی ۱۰ روزه از سال ۲۰۰۲ ارتفاع آب‌های سطحی زمین را ثبت می‌کند. همچنین این ماهواره برای اندازه‌گیری ارتفاع سطح دریا بهینه شده است (Fatolahzadeh et al., 2016). بدین ترتیب این داده‌ها از نظر آثار ژئوفیزیکی و محیطی از قبیل تأثیر وضعیت سطح دریا، تأخیر یونوسفری، تصحیحات تروپوسفر خشک و تر، آثار جزرومدی مثل جزر و مد اقیانوسی یا قطب، بار جزر و مد اقیانوس، بایاس الکترومغناطیس و تصحیحات بارومتری تصحیح شده‌اند. به طور کلی این ماهواره قادر به جمع‌آوری داده‌هایی است که در نهایت از آن‌ها برای محاسبه ارتفاع سطح دریا (SSH)^{۱۷} و آنامولی سطح دریا (SLA)^{۱۸} استفاده می‌شود. بر خلاف داده‌های نوری، ماهواره‌های ارتفاع سنج تنها بر مسیر مشخص داده ثبت می‌کنند. هر سه سنجنده Jason از یک مسیر مشخص (Track 133) بر روی دریاچه ارومیه عبور می‌کنند (شکل ۲). در این تحقیق برای بررسی تغییرات ارتفاعی دریاچه از مجموعه داده G-REALM استفاده شد. سازمان USDA-FAS^{۱۹} با همکاری NASA و دانشگاه مریلند، به طور مرتب دریاچه‌ها و تغییرات ارتفاعی آن‌ها را در سراسر جهان رصد می‌کنند. این پروژه از داده‌های ارتفاع سنجی راداری NASA، CNES، ESA^{۲۰} و ISRO^{۲۱} روی پهنه‌های آبی به

شاخص‌ها بسیار کارآمدتر است. مرسوم‌ترین شاخص‌ها در تشخیص آب NDVI و NDWI^{۲۳} هستند. شاخص NDWI برای شناسایی و جداسازی آب طراحی شده است (McFeeters, 1996). در پژوهش‌های پیشین رکنی و همکارانش (۲۰۱۴)، شاخص NDWI را به‌عنوان مناسب‌ترین شاخص برای استخراج دریاچه ارومیه با استفاده از داده‌های سنجنده لندست معرفی کردند اما با توجه به پژوهش‌های پیشین صورت گرفته روی داده‌های MODIS و برای دریاچه‌ها با عمق کم، مانند دریاچه ارومیه، شاخص NDVI به نتیجه بهتری منتج می‌شود (Mohebzadeh, 2018; Feng et al., 2012). با توجه به جذب مادون قرمز نزدیک توسط آب مقادیر NDVI برای این مناطق کمتر از خشکی است. این شاخص از طریق رابطه زیر محاسبه می‌شود.

$$NDVI = \frac{NIR-Red}{NIR+Red} \quad (2)$$

در این رابطه NIR^{۲۴} و Red به ترتیب نشان دهنده میزان رفلکتانس^{۲۵} (بازتاب) باندهای ۱ و ۲ سنجنده MODIS هستند. با استفاده از حد‌آستانه گذاری مقادیر آب و غیر آب از هم تفکیک شده و مقادیر کمتر از صفر به‌عنوان آب شناسایی می‌شوند. در نهایت با جمع تعداد پیکسل‌های آب و اعمال ضریب مساحت سطح هر پیکسل، مساحت سطح دریاچه ارومیه در هر زمان به دست می‌آید.

مدل‌سازی

به‌منظور بررسی و تحلیل جامع و دقیق داده‌ها و همچنین با بهره‌گیری از روش‌های مختلف مبتنی بر یادگیری ماشین می‌توان تغییرات منطقه را مدل‌سازی کرده و تأثیر آن‌ها بر دریاچه را سنجد. برای این مدل‌سازی نخست سری زمانی از داده‌های مختلف تشکیل می‌شود، سپس این سری زمانی وارد مدل شده و تغییرات پیش روی آن پیش‌بینی می‌شود. در این راستا روش‌های شبکه عصبی پیش‌خور^{۲۶} multi-layer perceptron (MLP) و بازگشتی^{۲۷} Long-short-term-memory (LSTM) به

حدود ۲,۰۰۰,۰۰۰,۰۰۰ متر مربع مساحت داشته قابل اغماض است. با توجه به اینکه در بازه مورد نظر و برای تشکیل سری زمانی برای هر ماه حداقل باید یک تصویر در دسترس باشد، توان تفکیک زمانی از این منظر حائز اهمیت است که بتوان در هر ماه حداقل یک تصویر مناسب و با حداقل پوشش ابری یافت. فاصله برداشت تصویر Landsat، ۱۶ روز و برای MODIS، ۱-۲ روز است، بدین ترتیب ماهواره Landsat در هر ماه در بهترین حالت می‌تواند دو تصویر برداشت کند که با توجه به اینکه دریاچه در منطقه‌ای قرار دارد که معمولاً در زمستان‌ها قسمتی یا تمامی آن توسط ابر پوشانیده، چندان مناسب نیست. در مقابل MODIS با فواصل ۱-۲ روزه می‌تواند در اکثر مواقع تصویر مناسب ثبت کند. بدین ترتیب علی‌رغم توان تفکیک مکانی مناسب‌تر سری ماهواره‌های Landsat، داده‌های MODIS برای پایش تغییرات سطحی دریاچه ارومیه استفاده شده‌اند.

به‌منظور بررسی تغییرات سطحی دریاچه ارومیه از تصاویر نوری ماهواره MODIS استفاده شد. بدین‌صورت که در بازه ۱۸۳ ماهه مذکور و با کمک موتور پردازش ابری Google Earth Engine این تغییرات محاسبه شدند (Gorelick et al., 2017). در این راستا محصول نسخه ۶، MOD09Q1 انتخاب شد. این محصول تصاویر با توان تفکیک مکانی ۲۵۰ متری را در فواصل زمانی ۸ روزه فراهم می‌آورد که مقدار هر پیکسل در این تصاویر ترکیبی از تمامی تصاویر در بازه هشت روزه است، به گونه‌ای که بیشترین پوشش مشاهداتی، کمترین زاویه دید، نبود ابر یا سایه و آثر^{۲۲} حاصل شود. همچنین تصحیحات آثار اتمسفری نیز روی این محصول اعمال شده‌است. برای بررسی تغییرات سطحی پهنه آبی نخست لازم است این پهنه از سایر مناطق متمایز شود. بدین منظور روش‌های مختلفی نظیر طبقه‌بندی و استفاده از شاخص‌ها وجود دارد (Feyisa et al., 2014; Xu, 2006)، که با توجه به بازه زمانی مورد بررسی و تعداد بالای تصاویر استفاده از

$$y_j = \sum_{k=1}^K w_{jk}^{(2)} z_k + w_{j0}^{(2)} \quad (۶)$$

y در رابطه ۶ نورون خروجی یا به عبارت دیگر خروجی نهایی شبکه است. $w_{jk}^{(2)}$ و $w_{j0}^{(2)}$ نشان‌دهنده وزن‌ها و مقدار بایاس مربوط به لایه خروجی هستند. لایه نهایی از تابع فعال‌ساز خطی بهره می‌گیرد. در مرحله آموزش مقادیر وزن و بایاس از روش backpropagation، که پروسه انتشار خطا بازگشتی است، محاسبه می‌شوند (Demuth and Beale, 2000).

شبکه عصبی حافظه طولانی کوتاه-مدت (LSTM)

برای درک بهتر شبکه عصبی حافظه طولانی کوتاه-مدت (LSTM) نخست به شبکه عصبی بازگشتی کلاسیک (RNN) پرداخته می‌شود (Williams and Zipser, 1989). بر خلاف شبکه‌های پیش‌خور، شبکه‌های بازگشتی شامل یک حلقه هستند که هر ورودی را به خروجی قبلی شبکه متصل می‌کند. بدین ترتیب برخلاف شبکه‌های پیش‌خور، شبکه‌های بازگشتی می‌توانند داده‌های متوالی، مانند سری زمانی، را پردازش کنند.

در رابطه ۳، b مقدار انحراف یا بایاس است. شبکه MLP نوعی از شبکه feedforward است که شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است. هر لایه می‌تواند شامل یک یا چند نورون باشد. بدین ترتیب M پیش‌بینی‌کننده x وارد شبکه می‌شوند. لایه پنهان، K نورون پنهان را شامل می‌شود که از مجموع وزن‌دار پیش‌بینی‌کننده‌ها متشکل است (Bishop, 2006).

$$h_t = H(W_{hh}h_{t-1} + W_{hx}x_t + b_h); \quad t > 0 \quad (۷)$$

در این رابطه، W ماتریس وزن را نشان می‌دهد. W_{hh} ماتریس وزنی است که وضعیت پنهان گام قبل را به گام کنونی متصل می‌کند و W_{hx} ماتریس وزنی است که داده ورودی گام کنونی را به وضعیت پنهان متصل می‌کند. همچنین، b_h نشان‌دهنده بایاس است و H تابع فعال‌سازی غیرخطی وضعیت پنهان است. Tanh و ReLU رایج‌ترین انتخاب‌ها برای تابع فعال‌سازی H در شبکه‌های بازگشتی هستند. هر بلوک بازگشتی همچنین می‌تواند خروجی پیش‌بینی شده \hat{y}_t را از طریق رابطه ۸ محاسبه کند.

اجمال بررسی می‌شوند.

شبکه عصبی مصنوعی شامل چند ورودی و خروجی است که به‌عنوان نورون^{۲۸}های شبکه شناخته می‌شوند و از طریق وزن‌های قابل یادگیری به یکدیگر متصل می‌شوند. در مدل‌های پیش‌خور، سیگنال‌ها مستقیماً از ورودی به سمت خروجی هدایت می‌شوند اما در روش‌های بازگشتی، سیگنال‌ها از طریق حلقه‌ها در شبکه به عقب نیز حرکت می‌کنند. سیگنال‌های به دست آمده از هر حلقه می‌توانند از گام قبلی به ورودی بعدی به‌عنوان دنباله‌ای از داده یا حافظه، اطلاعات بیافزایند. بنابراین بر خلاف مدل‌های پیش‌خور، شبکه‌های بازگشتی وابستگی داده‌های ورودی با ورودی‌های قبلی را در نظر می‌گیرند.

شبکه عصبی مصنوعی پرسپترون چندلایه (MLP^{۲۹})

در مسائل پیش‌بینی سری زمانی مقصود دستیابی به تابع فعال‌سازی (f) بهینه است، به نحوی که مجموعه پیش‌بینی‌کننده x را به هدف y برساند.

$$y=f(x)+b \quad (۳)$$

در رابطه ۴، a_k نورون پنهان؛ $w_{ki}^{(1)}$ وزن‌های مربوط به ورودی هر نورون و $w_{k0}^{(1)}$ مقدار بایاس است. در مرحله بعد خروجی رابطه ۴ وارد تابع فعال‌سازی ψ می‌شود.

$$a_k = \sum_{i=1}^M w_{ki}^{(1)} x_i + w_{k0}^{(1)}, k = 1, \dots, K \quad (۴)$$

در رابطه ۵، z_k خروجی لایه پنهان است. از تابع logistic sigmoid که مقادیر بین صفر و یک دارد برای تابع فعال‌ساز استفاده می‌شود. در نهایت لایه‌های پنهان از طریق یک تابع فعال‌سازی و رابطه‌ای به صورت زیر به خروجی نهایی می‌رسند.

$$z_k = \psi(a_k), k = 1, \dots, K \quad (۵)$$

در رابطه ۵، z_k خروجی لایه پنهان است. از تابع logistic sigmoid که مقادیر بین صفر و یک دارد برای تابع فعال‌ساز استفاده می‌شود. در نهایت لایه‌های پنهان از طریق یک تابع فعال‌سازی و رابطه‌ای به صورت زیر به خروجی نهایی می‌رسند.

\hat{C}_t و C_{t-1} به ترتیب مقادیر کاندیدهای ورودی، جدید و خروجی هستند که برای تعیین اینکه چه بخشی از آنها نگهداری شود از دروازه‌ها عبور داده می‌شوند.

ارزیابی شبکه

به‌منظور ارزیابی نتایج حاصل پارامترهای متنوعی در دسترس هستند که با توجه به اینکه مقصود ارزیابی میزان سازگاری سراسری مدل است، RMSE^{۳۳} به منظور بهینه‌سازی و ارزیابی شبکه استفاده می‌شود.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - t_i)^2} \quad (15)$$

در رابطه ۱۵، y_i و t_i نشان‌دهنده مقادیر پیش‌بینی شده و مشاهداتی و همچنین N ، بیانگر تعداد داده‌های مورد استفاده برای ارزیابی است.

ساختار شبکه

همانگونه که در شکل ۳ مشاهده می‌شود، ورودی‌های شبکه شامل میزان بارندگی به دست آمده از داده‌های TRMM، تغییرات احجام آبی به دست آمده از GRACE، تغییرات مدل هیدرولوژیکی GLDAS و تغییرات ارتفاعی سطح دریاچه هستند، همچنین خروجی یا هدف شبکه، تغییرات سطحی دریاچه است.

نتایج و بحث

تغییرات بارندگی

داده TRMM، ۸۴ پیکسل در هر گام زمانی در حوضه آبخیز دریاچه ارومیه شامل می‌شود. در نظر گرفتن میزان بارندگی در سراسر حوضه از این نظر حائز اهمیت است که هدف نهایی، مدل‌سازی تغییرات دریاچه است که به نوعی تحت تأثیر میزان بارندگی در سراسر حوضه است. میزان بارش محاسبه شده از داده‌های سنجنده TRMM در ۱۸۳ ماه مورد مطالعه در حوضه آبخیز دریاچه ارومیه در شکل ۴ نمایش داده شده‌اند.

همانگونه که مشاهده می‌شود تغییرات فصلی بارش در

$$\hat{y}_t = g(W_{yh}h_t + b_y); \quad t > 0 \quad (8)$$

در رابطه ۸، g یک تابع فعال‌سازی غیرخطی است که می‌تواند متناسب با ساختار خروجی sigmoid logistic یا softmax باشد (Graves, 2013). استفاده از گام‌های زمانی زیاد در یک شبکه بازگشتی ممکن است موجب بیش از حد کوچک یا بزرگ شدن مقادیر گرادین وزن‌ها در طول مراحل یادگیری شود. این مشکل محو شدگی گرادین نامیده می‌شود که باعث از دست رفتن وابستگی‌های طولانی در داده‌های متوالی می‌شود (Bengio et al., 2017; Gamboa, 2017).

شبکه عصبی LSTM برای غلبه بر مشکل محو شدگی گرادین شبکه‌های بازگشتی سنتی توسط Hochreiter and Schmidhuber (۱۹۹۷) توسعه داده شد. به‌منظور استخراج وابستگی‌های طولانی مدت، یک واحد حافظه از شبکه LSTM شامل سه دروازه فراموشی، ورودی و خروجی است. دروازه فراموشی به‌منظور تصمیم‌گیری برای حفظ داده‌های مهم در شبکه است، دروازه ورودی تعیین می‌کند کدام داده‌های جدید وارد شبکه شوند و در نهایت دروازه خروجی، خروجی شبکه را تعیین می‌کند. هر یک از این دروازه‌ها شامل یک تابع سیگموئید^{۳۳} هستند، جایی که تصمیم می‌گیرند اطلاعات را به نرمی به مقداری بین ۰ و ۱ منتقل کنند. روابط مربوط به این سه دروازه و خروجی‌های شبکه LSTM در روابط ۹ تا ۱۴ آمده است.

$$f_t = \sigma(W_{f1}x_t + W_{f2}h_{t-1} + b_f); \quad t > 0 \quad (9)$$

$$i_t = \sigma(W_{i1}x_t + W_{i2}h_{t-1} + b_i); \quad t > 0 \quad (10)$$

$$\tilde{C}_t = H(W_{c1}x_t + W_{c2}h_{t-1} + b_c); \quad t > 0 \quad (11)$$

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t; \quad t > 0 \quad (12)$$

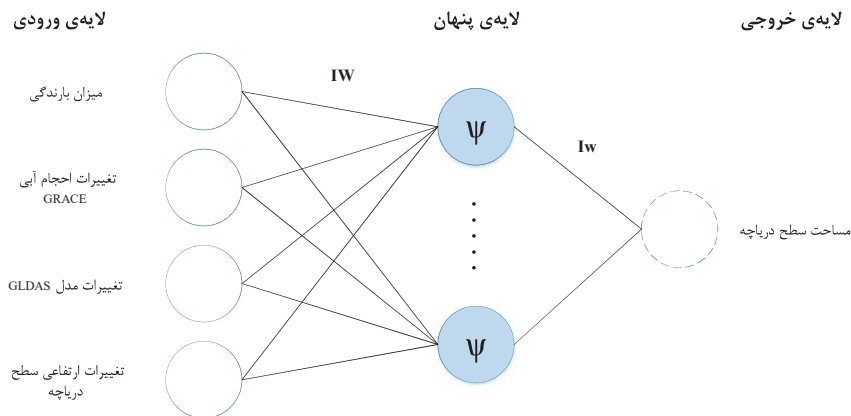
$$o_t = \sigma(W_{o1}x_t + W_{o2}h_{t-1} + b_o); \quad t > 0 \quad (13)$$

$$h_t = o_t \times \tanh(C_t) \quad (14)$$


در این روابط f_t ، i_t و o_t به ترتیب نشان دهنده دروازه‌های فراموشی، ورودی و خروجی هستند. σ نشان گر تابع سیگموئید برای هر یک از دروازه‌ها است. وزن و بایاس‌ها نیز با نمادهای W و b نمایش داده شده‌اند. C_{t-1} ،

سال مورد مطالعه اتفاق افتاده است. پس از آن میزان بارندگی‌ها تا انتهای بازه مورد مطالعه افزایش داشته است. تغییرات در میزان این بارش‌ها می‌تواند تأثیر بسزایی بر سایر پارامترهای مورد بررسی داشته باشد.

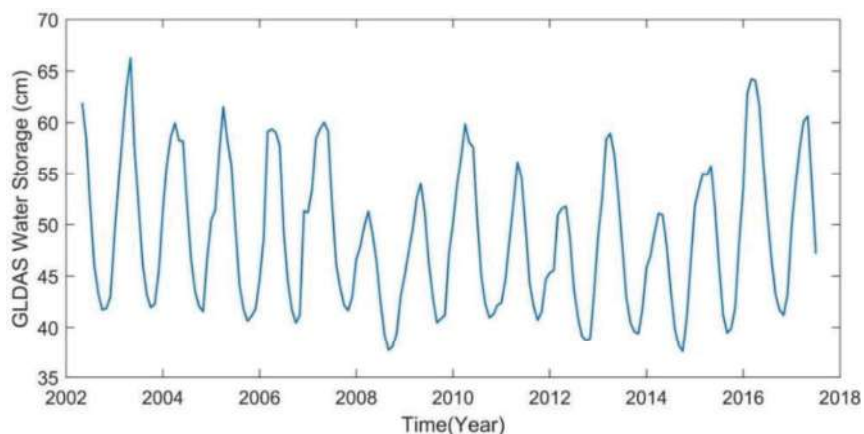
این شکل مشهود است. صرف نظر از تغییرات فصلی بارش‌ها، از سال ۲۰۰۲ تا ۲۰۰۴ بارش سالیانه بیشینه بوده اما پس از آن کاهش چشمگیری داشته، به گونه‌ای که بین سال‌های ۲۰۰۶ الی ۲۰۰۸ کمترین میزان بارندگی در ۱۶



شکل ۳. ساختار شبکه عصبی مورد استفاده در این تحقیق، IW و Iw وزن‌های مربوط به لایه پنهان و خروجی و ψ تابع فعال‌سازی است.



شکل ۴. بارندگی ماهیانه در حوضه آبخیز دریاچه ارومیه (بر حسب میلی‌متر)



شکل ۵. تغییرات احجام آبی حاصل از مدل هیدرولوژیکی GLDAS در حوضه آبخیز دریاچه ارومیه (بر حسب سانتی‌متر)

تغییرات تا حد بسیار زیادی تحت تأثیر تغییرات در میزان بارش هستند.


تغییرات احجام آبی سنجنده GRACE

نتایج داده‌های سنجنده GRACE بسیار شبیه به مدل GLDAS عمل می‌کند. تغییرات احجام آبی به دست آمده از داده‌های این سنجنده به صورت ماهیانه محاسبه و در شکل ۶ نمایش داده شده‌اند که نوسانات آن به مقدار احجام آبی اندازه‌گیری شده از طریق مدل هیدرولوژیکی GLDAS نزدیک است. سنجنده GRACE علاوه بر موارد محاسبه شده توسط مدل هیدرولوژیکی GLDAS مقادیر آب‌های زیرزمینی با عمق بیشتر از ۲۰۰ سانتی‌متر را نیز برآورد می‌کند (Joodaki, 2014).


تغییرات احجام آبی از مدل GLDAS

مدل GLDAS تغییرات رطوبت خاک تا عمق ۲۰۰ سانتی‌متر، آب معادل برف و آب ذخیره شده در گیاهان (برحسب km/m^2) را شامل می‌شود. تغییرات این احجام در بازه زمانی ۲۰۰۲-۲۰۱۷ در حوضه آبخیز دریاچه ارومیه محاسبه و در شکل ۵ نمایش داده شده است.

در این شکل تغییرات فصلی به وضوح مشهود است و در طول بازه زمانی مورد مطالعه، نوسانات به دست آمده از مدل GLDAS تقریباً در یک محدوده ثابت قرار دارند. علاوه بر تغییرات فصلی، در سال ۲۰۰۸ شاهد افت در مقدار احجام آبی هستیم که پس از آن تا سال ۲۰۱۰ افزایش یافته و سپس تا سال ۲۰۱۴ مجدداً کاهش می‌یابد. در نهایت این روند کاهشی متوقف شده و در انتها تا حدودی افزایش می‌یابد. همانگونه که مشاهده می‌شود این



شکل ۶. تغییرات ماهیانه احجام آبی به دست آمده از سنجنده GRACE در حوضه آبخیز دریاچه ارومیه (بر حسب سانتی‌متر)



شکل ۷. ارتفاع ماهیانه دریاچه ارومیه با استفاده از داده‌های آلتیتمتری به دست آمده از مدل G-REALM (بر حسب متر)

پس از آن روند افت دریاچه کند شده است. به عبارت دیگر تغییرات ارتفاعی سطح دریاچه مستقیماً تحت تأثیر تغییرات بارندگی نبوده و علیرغم افزایش‌های مقطعی بارش‌ها، به صورت مداوم کاهش یافته است.

تغییرات سطح دریاچه ارومیه

تغییرات سطحی دریاچه ارومیه در بازه زمانی مورد نظر از طریق تصاویر MODIS و با استفاده از شاخص NDVI محاسبه شد که در شکل ۸ نمایش داده شده است.


همانگونه که در سایر داده‌های مورد بررسی مشهود بود تغییرات فصلی بر سطح دریاچه نیز اثرگذارند. به‌طور کلی سطح دریاچه از سال ۲۰۰۵ تا ۲۰۱۴ روند کاهشی داشته است که این مسئله در سال ۲۰۰۸ شدت یافته، بعد از سال ۲۰۱۴ این روند متوقف شده و از سال ۲۰۱۵ تا ۲۰۱۷ مقداری افزایش یافته است. روند کاهشی بعد از سال ۲۰۰۵ در سایر پارامترهای مورد محاسبه نیز مشهود بود اما در تغییرات سطحی و ارتفاعی دریاچه ارومیه این کاهش با شدت بسیار بیشتری نمایان است که می‌تواند به دلیل عوامل مختلف از جمله جمعیتی از عوامل مؤثر بر تمامی پارامترها باشد. همچنین تأثیر افزایش میزان بارندگی در سال ۲۰۱۵، افزایش آب‌های سطحی و زیر سطحی به دست آمده از مدل هیدرولوژیکی GLDAS، به صورت صعودی در سطح دریاچه نمایان است.

به عبارت دیگر داده‌های سنجنده GRACE علاوه بر تغییرات فصلی از عواملی دیگر نیز تأثیر می‌پذیرند که بر تغییرات آب‌های زیرزمینی اثر گذارند. از جمله عوامل عمده مؤثر بر تغییرات احجام آبی محاسبه شده می‌توان به تغییرات بارندگی و برداشت آب‌های سطحی و زیر سطحی اشاره کرد. شکل ۶ نشان می‌دهد از سال ۲۰۰۲ تا ۲۰۰۵ احجام آبی در بالاترین سطح خود قرار داشتند اما پس از آن تا سال ۲۰۱۴ این سطح کاهش یافته و سپس این روند کاهشی تا حدودی متوقف شده و پس از آن، اندکی افزایش یافته است. با توجه به کاهش میزان بارندگی‌ها از سال ۲۰۰۶ تا ۲۰۰۸، کاهش احجام آبی قابل پیش‌بینی بود و در انتها با افزایش نامحسوس بارندگی و ادامه داشتن این روند افزایشی، توقف روند کاهش در احجام آبی صورت گرفت و بعد از سال ۲۰۱۴ سطح احجام آبی افزایش یافت.

تغییرات ارتفاعی سطح دریاچه

برای بررسی تغییرات ارتفاعی دریاچه ارومیه، از داده‌های سنجنده‌های Jason-1، Jason-2/OSTM، Jason-3 و استفاده شد که از طریق مدل G-REALM فراهم شدند، این مقادیر در شکل ۷ نمایش داده شده‌اند.

همانگونه که در شکل ۷ مشاهده می‌شود، صرف نظر از تغییرات فصلی و نوسانات مقطعی، سطح دریاچه ارومیه به طور کلی در بازه زمانی مورد بررسی در حال پایین آمدن بوده است. این کاهش از سال ۲۰۰۶ تا ۲۰۱۰ شدت یافته و



شکل ۸. مساحت سطح ماهیانه دریاچه ارومیه (بر حسب کیلومتر مربع)

بهینه در نظر گرفته شد. به طریق مشابه و با بررسی تجربی، با ۵ نرون در لایه پنهان شبکه MLP و ۱۰ نرون در لایه پنهان شبکه LSTM، نتیجه بهینه حاصل شد. شبکه MLP برای رسیدن به بهترین جواب ۱۸۶ بار تکرار شد که این مقدار برای شبکه LSTM ۲۶۰ مرتبه بود.

در این مسیر نخست شبکه برای تخمین تغییرات یک گام (ماه) آینده تشکیل داده شد. در این راستا ۱۰ درصد داده‌ها برای تست (۱۷ ماه آخر)، ۱۰ درصد برای ارزیابی (۱۷ ماه، قبل از داده تست) و ۸۰ درصد باقی مانده برای آموزش انتخاب شدند (۱۳۷ ماه). بدین ترتیب، مقادیر پیش‌بینی شده توسط هر یک از شبکه‌ها برای ۱۷۱ ماه محاسبه شدند، که در شکل ۹ نمایش داده شده است.

همانگونه که در شکل ۹ مشاهده می‌شود هر دو شبکه در داده‌های آموزش و ارزیابی مقادیری بسیار نزدیک به واقعیت تخمین زده‌اند اما در داده‌های تست عملکرد شبکه LSTM تا حدودی مناسب‌تر است. با توجه به پارامتر تأخیر، برای ۱۲ ماه ابتدایی مقدار پیش‌بینی شده وجود ندارد اما در ادامه این مقادیر نمایش داده شده‌اند. در شکل ۹ مشاهده می‌شود تغییرات کلی به‌خوبی تخمین زده شده‌اند. همچنین در این دو مدل تغییرات فصلی نیز تا حدودی نمایش داده شده است که نشان دهنده عملکرد مناسب شبکه‌های مورد استفاده است. برای بررسی دقیق‌تر و مقایسه دقت شبکه‌های مورد استفاده، مقدار جذر میانگین مربعات خطاها (RMSE) محاسبه شد. این مقادیر در جدول ۲ نمایش داده شده‌اند.

به صورت کلی شبکه‌های MLP و LSTM تغییرات سطحی دریاچه ارومیه را به ترتیب با مقادیر RMSE روی داده‌های نرمال شده ۰/۰۵۸۶ و ۰/۰۵۱۱ محاسبه کردند که نشان دهنده درجه اطمینان این شبکه‌ها به‌منظور پیش‌بینی تغییرات یک ماه بعد است. از طرفی با بررسی دقیق‌تر مشاهده می‌شود که شبکه MLP روی داده‌های آموزشی عملکرد بسیار خوبی دارد اما در داده‌های تست، شبکه LSTM به مراتب عملکرد مناسب‌تری دارد که می‌تواند به

مدل‌سازی

عوامل مختلفی بر تغییرات سطحی دریاچه ارومیه مؤثرند. بخشی از این عوامل بر تغییرات احجام آبی زمینی و زیرزمینی نیز تأثیر گذارند. همچنین بارندگی عامل مستقیمی است که می‌تواند موجب کاهش یا افزایش سطح دریاچه شود. عوامل مختلفی نظیر عوامل انسانی نیز بر تغییرات مساحت سطح دریاچه تأثیر گذارند که از طریق بررسی نظری امکان‌پذیر نیست. لذا به‌منظور مدل‌سازی این عوامل می‌توان از روش‌های مبتنی بر یادگیری ماشین و شبکه‌های عصبی بهره برد.



مدل‌سازی و پیش‌بینی تغییرات سطحی

در این مطالعه به‌منظور دستیابی به نتیجه بهینه از دو روش مبتنی بر یادگیری ماشین MLP و LSTM بهره گرفته شد. برای تشکیل هر شبکه از داده‌های کمکی شامل تغییرات بارندگی، تغییرات سطح آب‌های سطحی و زیر سطحی به دست آمده از داده‌های ثقل سنجی GRACE و مدل هیدرولوژیکی GLDAS و همچنین تغییرات ارتفاع دریاچه ارومیه، به‌عنوان ورودی و سری زمانی تغییرات مساحت سطح دریاچه به‌عنوان هدف شبکه استفاده شد.

در این مطالعه به‌منظور دستیابی به نتیجه بهینه، در هر دو مدل از شبکه‌ای با یک لایه پنهان و پارامتر تأخیر ۱۲ ماه استفاده شد. بدین صورت که از دوازده داده نخست در سری زمان برای پیش‌بینی داده سیزدهم، بهره گرفته شد و به همین ترتیب پیش‌بینی و تخمین سایر مقادیر انجام شد. در واقع این پارامتر نشان دهنده تعداد ماه‌هایی است که با استفاده از آن، ماه بعدی تخمین زده می‌شود که به‌صورت تجربی و با در نظر گرفتن این نکته که تغییرات عوامل مختلف از جمله بارندگی، تغییرات آب‌های سطحی و زیر سطحی تا مدتی حدود یک سال بر تغییرات سطحی دریاچه می‌توانند مؤثر باشند، تأخیر بهینه ۱۲ ماه انتخاب شد. همچنین تعداد یک لایه پنهان پس از بررسی به صورت تجربی و وقوع پدیده بیش‌برازش (Overfitting) در داده‌های آموزشی با افزایش تعداد لایه‌ها، به‌عنوان مقدار

تغییرات را با دقت ۰/۰۵۱۱ برآورد می‌کند. از این رو در ادامه از این شبکه برای پیش‌بینی تغییرات سطحی دریاچه ارومیه در بازه زمانی طولانی‌تر بهره گرفته شده‌است.

دلیل وقوع پدیده بیش‌برازش (Overfitting) داده‌های آموزشی در شبکه MLP باشد. بدین ترتیب، به صورت کلی شبکه LSTM که از روش بازگشتی استفاده می‌کند برای پیش‌بینی تغییرات سطحی مناسب‌تر است و این



شکل ۹. تغییرات تخمینی مساحت دریاچه ارومیه با استفاده از مدل‌های MLP و LSTM از ماه جولای ۲۰۰۵ تا ژوئن ۲۰۱۷

جدول ۲. مقادیر جذر میانگین مربعات خطاهای مدل‌ها برای تخمین تغییرات سطحی دریاچه ارومیه

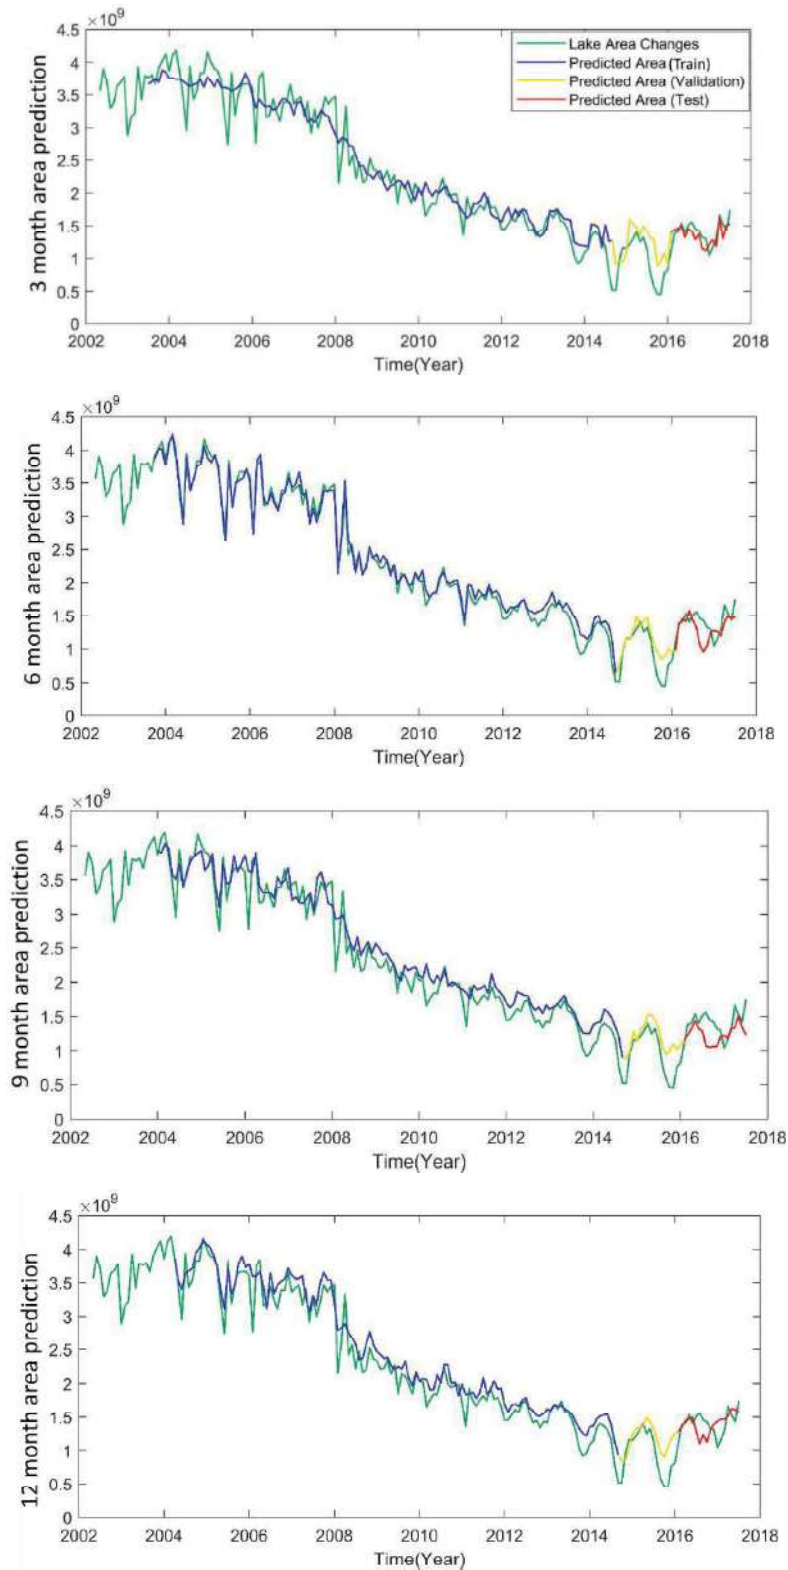
مدل	آموزش	ارزیابی	تست	کل
MLP	۰/۰۴۹۴	۰/۰۴۸۵	۰/۱۱۲۱	۰/۰۵۸۶
LSTM	۰/۰۴۸۷	۰/۰۶۰۲	۰/۰۴۴۰	۰/۰۵۱۱

مدل جدیدی تشکیل می‌شود. در تمامی این چهار مدل نیز ۱۷ داده تست، ۱۷ داده ارزیابی و سایر داده‌ها به‌عنوان آموزش انتخاب شده، همچنین پارامتر تأخیر و سایر پارامترها همانند شبکه پیش‌بینی یک ماه آینده انتخاب شد. در ادامه در شکل ۱۰ تغییرات تخمین زده شده، نمایش داده

پیش‌بینی تغییرات برای بازه زمانی طولانی‌تر

به‌منظور ارزیابی قابلیت روش‌های مبتنی بر یادگیری ماشین برای پیش‌بینی تعداد ماه‌های بیشتر، شبکه‌های بازگشتی LSTM برای تخمین تغییرات در ۳، ۶، ۹ و ۱۲ ماه آینده تشکیل شد. برای انجام هر یک از این پیش‌بینی‌ها

شده است.



شکل ۱۰. مدل و پیش‌بینی تغییرات سطح آب دریاچه ارومیه با استفاده از مدل LSTM به ترتیب به صورت ۳، ۶، ۹ و ۱۲ ماه، بر حسب مترمربع

طرفی مشاهده می‌شود مدل ۱۲ ماهه در تخمین داده‌های تست و افزایش انتهای دوره مورد مطالعه، نسبت به مدل ۹ ماهه عملکرد بهتری داشته است. به منظور ارزیابی و بررسی آماری هر یک از مدل‌های تشکیل شده، پارامتر جذر میانگین مربعات مانده‌ها برای هر یک از این مدل‌ها روی داده‌های نرمال شده، محاسبه شد و به تفکیک برای داده‌های آموزش، ارزیابی و تست در جدول ۳ آمده است.

با استفاده از مدل LSTM، شبکه‌هایی برای تخمین تغییرات تا ۳، ۶، ۹ و ۱۲ ماه بعد آموزش داده شدند. تغییرات پیش‌بینی شده در شکل ۱۰ به تصویر درآمده‌اند. در تمامی شکل‌ها مشاهده می‌شود تغییرات کلی در بازه زمانی مورد مطالعه، شناسایی و مدل‌سازی شده‌اند اما در تشخیص تغییرات دوره‌ای و فصلی کمی دچار مشکل شده است. همچنین مقادیر کمینه، میان سال‌های ۲۰۱۴ تا ۲۰۱۶ تا حدود مناسبی (به‌ویژه در مدل ۶ ماه) برآورد شده، از

جدول ۳. مقادیر جذر میانگین مربعات خطاهای شبکه‌های LSTM برای تخمین تغییرات سطحی دریاچه ارومیه برای زمان مختلف (۳، ۶، ۹ و ۱۲ ماه)

آموزش	ارزیابی	تست	کل	ماه
۰/۰۷۰۷	۰/۰۹۸۱	۰/۰۵۸۷	۰/۰۷۵۱	۳ ماه
۰/۱۱	۰/۱۴۴۳	۰/۰۹۲۸	۰/۱۱۵۸	۶ ماه
۰/۰۹۵۴	۰/۱۲۹۴	۰/۰۶۷۲	۰/۱	۹ ماه
۰/۰۸۶۳	۰/۱۰۶۳	۰/۰۴۸۷	۰/۰۸۸۲	۱۲ ماه

مدل‌سازی بهره برد. با توجه به اهمیت دریاچه ارومیه و بحران‌های اخیر خشک‌سالی که با آن روبه‌رو بود، در این تحقیق قابلیت داده‌های مختلف و روش‌های مبتنی بر یادگیری ماشین برای مدل‌سازی و پیش‌بینی تغییرات سطحی این دریاچه بررسی شده است.

در این راستا نخست به بررسی تغییرات هیدرولوژیکی منطقه و با استفاده از داده‌ها و روش‌های دورسنجی پرداخته شد. تغییرات سطحی دریاچه ارومیه با استفاده از داده‌های نوری سنجنده MODIS محاسبه شد. به منظور بررسی عوامل مؤثر بر تغییرات سطحی دریاچه پارامترهای مختلف شامل تغییرات ماهانه بارندگی، آب‌های سطحی و زیر سطحی و تغییرات ارتفاعی سطح دریاچه به‌عنوان داده‌های کمکی و به ترتیب با بهره‌گیری از داده‌های TRMM، ثقل سنجی GRACE، هیدرولوژیکی GLDAS و ارتفاع‌سنجی سری ماهواره Jason استفاده شدند. هر یک از این عوامل بر تغییرات سطحی دریاچه ارومیه به صورت مستقیم یا غیرمستقیم تأثیر گذارند که می‌توانند در تخمین و پیش‌بینی تغییرات سطحی دریاچه مؤثر باشند. بدین

با توجه به جدول ۳ و همانگونه که در شکل ۱۰ نیز مشهود بود، عملکرد کلی مدل ۱۲ ماهه از ۹ و ۶ ماهه مناسب‌تر است. بدین ترتیب، تغییرات سالیانه پارامترهای مختلف (ورودی‌های شبکه)، بر تغییرات سطحی دریاچه تأثیر بیشتری دارند. از طرفی، مدل ۳ ماهه به صورت کلی با توجه به نزدیک بودن مقادیر پیش‌بینی شده عملکرد مطلوب‌تری را نشان می‌دهد اما در برآورد داده‌های تست، شبکه ۱۲ ماه، با RMSE ۰/۰۴۸۷، توانسته تغییرات یک سال بعد را به خوبی پیش‌بینی کند. بدین صورت با استفاده از روش مبتنی بر یادگیری ماشین LSTM، امکان پیش‌بینی تغییرات سطحی دریاچه ارومیه تا یک سال بعد، با خطای RMSE ۰/۰۸۸۲، فراهم شده است.

نتیجه‌گیری

عوامل مختلف زیست‌محیطی نظیر بارندگی، روان آب‌های سطحی و زیر سطحی، سطح و ارتفاع دریاچه‌ها بر یکدیگر تأثیر گذارند. از این رو می‌توان برای پیش و پیش‌بینی تغییرات یک پارامتر از عوامل مؤثر بر آن در

3. Common Land Model
4. Tropical Rainfall Measuring Mission
5. Normalized Difference Vegetation Index
6. Global Reservoirs and Lakes Monitor
7. National Aeronautics and Space Administration
8. Japan Aerospace Exploration Agency
9. National Oceanic and Atmospheric Administration
10. National Centers for Environmental Prediction
11. Total Water Storage
12. Center for Space Research at University of Texas, Austin
13. Geo Forschungs Zentrum
14. Jet Propulsion Laboratory
15. Satellite Laser Ranging
16. Centre national d'études spatiales
17. Sea Surface Height
18. Sea Level Anomalies
19. United States Department of Agriculture – Foreign Agricultural Service
20. European Space Agency
21. Indian Space Research Organisation
22. aerosol
23. Normalized Difference Water Index
24. Near-InfraRed
25. reflectance
26. feed forward
27. recurrent
28. neuron
29. Multi-layer Perceptron
30. Recurrent Neural Network
31. Rectified Linear Unit
32. Sigmoid
33. Root Mean Square Error

ترتیب، روش مبتنی بر شبکه عصبی MLP و یادگیری عمیق LSTM استفاده شدند. در این راستا از داده‌های مختلف مؤثر بر تغییرات سطحی دریاچه به‌عنوان ورودی شبکه در مدل‌سازی بهره گرفته شد و با تعیین پارامترهای بهینه برای هر مدل، شبکه‌ها تشکیل شدند. این دو مدل با جذر خطای کمترین مربعات مانده‌های به ترتیب ۰/۰۵۸۶ و ۰/۰۵۱۱ تغییرات سطحی دریاچه ارومیه را برای یک ماه آینده برآورد کردند.

با توجه به قابلیت این روش‌ها، توانایی آن‌ها به‌منظور پیش‌بینی تغییرات برای بازه‌های زمانی طولانی‌تر نیز بررسی شد. نتایج به دست‌آمده امکان پیش‌بینی این تغییرات با دقت مناسب تا دوازده ماه بعد با دقت ۰/۰۸۸۲ را نشان می‌دهند. از این رو با استفاده از داده کمکی مناسب و بهره‌گیری از روش‌های مبتنی بر یادگیری ماشین، مدل‌سازی تغییرات سطحی دریاچه‌ها امکان‌پذیر است. به‌منظور بهبود این مدل‌سازی می‌توان پارامترهای ورودی مدل را افزایش داد یا بازه زمانی طولانی‌تری برای آموزش شبکه استفاده کرد.

یادداشت‌ها

1. Gravity Recovery and Climate Experiment
2. Global Land Data Assimilation System

منابع

- Alborzi, A., A. Mirchi, H. Moftakhari, I. Mallakpour, S. Alian, A. Nazemi, E. Hassanzadeh, O. Mazdiyasi, S. Ashraf and K. Madani (2018). Climate-informed environmental inflows to revive a drying lake facing meteorological and anthropogenic droughts. *Environmental Research Letters* 13(8): 084010.
- Alesheikh, A. A., A. Ghorbanali and N. Nouri (2007). Coastline change detection using remote sensing. *International Journal of Environmental Science & Technology* 4(1): 61-66.
- Ashrafzadeh Afshar, A., G. R. Joodaki and M. A. Sharifi (2016). Evaluation of Groundwater Resources in Iran Using GRACE Gravity Satellite Data. *Journal of Geomatics Science and Technology* 5(4): 73-84.
- Bengio, Y., P. Simard and P. Frasconi (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE transactions on neural networks* 5(2): 157-166.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*, springer.
- Chen, H., W. Zhang, N. Nie and Y. Guo (2019). Long-term groundwater storage variations estimated in the Songhua River Basin by using GRACE products, land surface models, and in-situ observations. *Science of the Total Environment* 649: 372-387.
- Cheng, M., J. C. Ries and B. D. Tapley (2011). Variations of the Earth's figure axis from satellite laser ranging and GRACE. *Journal of Geophysical Research: Solid Earth* 116(B1).

- Dastranj, H., F. Tavakoli and A. Soltanpour (2018). Investigating the water level and volume variations of Lake Urmia using satellite images and satellite altimetry. *Journal of Geographical Data (SEPEHR)* 27(107): 149-163.
- Delju, A., A. Ceylan, E. Piguet and M. Rebetez (2013). Observed climate variability and change in Urmia Lake Basin, Iran. *Theoretical and applied climatology* 111(1-2): 285-296.
- Demuth, H. and M. Beale (2000). *Neural network toolbox user's guide*.
- Ducet, N., P.-Y. Le Traon and G. Reverdin (2000). Global high-resolution mapping of ocean circulation from TOPEX/Poseidon and ERS-1 and-2. *Journal of Geophysical Research: Oceans* 105(C8): 19477-19498.
- Faraji, Z., A. Kaviani and A. Ashrafzadeh (2017). Assessment of GRACE satellite data for estimating the groundwater level changes in Qazvin province. *Ecohydrology* 4(2): 463-476.
- Fatolahzadeh, F., B. Voosoghi, m. Raoofian-Naeeni, M. Mohebi and R. Javadi Azar (2016). Determination of the correction due to hydrological and oceanic effects in study of the gravity variations. *Journal of Geospatial Information Technology* 4(2): 13-28.
- Feidas, H. (2010). Validation of satellite rainfall products over Greece. *Theoretical and Applied climatology* 99(1-2): 193-216.
- Feng, L., C. Hu, X. Chen, X. Cai, L. Tian and W. Gan (2012). Assessment of inundation changes of Poyang Lake using MODIS observations between 2000 and 2010. *Remote Sensing of Environment* 121: 80-92.
- Feyisa, G. L., H. Meilby, R. Fensholt and S. R. Proud (2014). Automated Water Extraction Index: A new technique for surface water mapping using Landsat imagery. *Remote Sensing of Environment* 140: 23-35.
- Forootan, E., R. Rietbroek, J. Kusche, M. Sharifi, J. Awange, M. Schmidt, P. Omondi and J. Famiglietti (2014). Separation of large scale water storage patterns over Iran using GRACE, altimetry and hydrological data. *Remote Sensing of Environment* 140: 580-595.
- Gamboa, J. C. B. (2017). Deep learning for time-series analysis. *arXiv preprint arXiv:1701.01887*.
- Gorelick, N., M. Hancher, M. Dixon, S. Ilyushchenko, D. Thau and R. Moore (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment* 202: 18-27.
- Graves, A. (2013). Generating sequences with recurrent neural networks. *arXiv preprint arXiv:1308.0850*.
- Hassanzadeh, E., M. Zarghami and Y. Hassanzadeh (2012). Determining the main factors in declining the Urmia Lake level by using system dynamics modeling. *Water Resources Management* 26(1): 129-145.
- Hochreiter, S. and J. Schmidhuber (1997). Long short-term memory. *Neural computation* 9(8): 1735-1780.
- Huffman, G. J., D. T. Bolvin, E. J. Nelkin, D. B. Wolff, R. F. Adler, G. Gu, Y. Hong, K. P. Bowman and E. F. Stocker (2007). The TRMM multisatellite precipitation analysis (TMPA): Quasi-global, multiyear, combined-sensor precipitation estimates at fine scales. *Journal of hydrometeorology* 8(1): 38-55.
- Joodaki, G. (2014). *Earth mass change tracking using GRACE satellite gravity data* (PhD thesis), NTNU Trondheim.
- Karbassi, A., G. N. Bidhendi, A. Pejman and M. E. Bidhendi (2010). Environmental impacts of desalination on the ecology of Lake Urmia. *Journal of Great Lakes Research* 36(3): 419-424.
- Khazaei, B., S. Khatami, S. H. Alemohammad, L. Rashidi, C. Wu, K. Madani, Z. Kalantari, G. Destouni and A. Aghakouchak (2019). Climatic or regionally induced by humans? Tracing hydro-climatic and land-use changes to better understand the Lake Urmia tragedy. *Journal of hydrology* 569: 203-217.
- Long, D., Y. Shen, A. Sun, Y. Hong, L. Longuevergne, Y. Yang, B. Li and L. Chen (2014). Drought and flood monitoring for a large karst plateau in Southwest China using extended GRACE data. *Remote Sensing of Environment* 155: 145-160.
- McFeeters, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International journal of remote sensing* 17(7): 1425-1432.
- Mohebzadeh, H. (2018). Extracting AL Relationship for Urmia Lake, Iran Using MODIS NDVI/NDWI Indices. *Journal of Hydrogeology & Hydrologic Engineering* 7: 2.

- Okay Ahi, G. and S. Jin (2019). Hydrologic Mass Changes and Their Implications in Mediterranean-Climate Turkey from GRACE Measurements. *Remote Sensing* 11(2): 120.
- Rodell, M., P. Houser, U. Jambor, J. Gottschalck, K. Mitchell, C.-J. Meng, K. Arsenault, B. Cosgrove, J. Radakovich and M. Bosilovich (2004). The global land data assimilation system. *Bulletin of the American Meteorological Society* 85(3): 381-394.
- Rohli, R. V., T. Andrew Joyner, S. J. Reynolds, C. Shaw and J. R. Vázquez (2015). Globally Extended Köppen-Geiger climate classification and temporal shifts in terrestrial climatic types. *Physical Geography* 36(2): 142-157.
- Rokni, K., A. Ahmad, A. Selamat and S. Hazini (2014). Water feature extraction and change detection using multitemporal Landsat imagery. *Remote sensing* 6(5): 4173-4189.
- Sun, A. Y. (2013). Predicting groundwater level changes using GRACE data. *Water Resources Research* 49(9): 5900-5912.
- Swenson, S., D. Chambers and J. Wahr (2008). Estimating geocenter variations from a combination of GRACE and ocean model output. *Journal of Geophysical Research: Solid Earth* 113(B8).
- Tourian, M., O. Elmi, Q. Chen, B. Devaraju, S. Roohi and N. Sneeuw (2015). A spaceborne multisensor approach to monitor the desiccation of Lake Urmia in Iran. *Remote Sensing of Environment* 156: 349-360.
- Wahr, J., M. Molenaar and F. Bryan (1998). Time variability of the Earth's gravity field: Hydrological and oceanic effects and their possible detection using GRACE. *Journal of Geophysical Research: Solid Earth* 103(B12): 30205-30229.
- Williams, R. J. and D. Zipser (1989). A learning algorithm for continually running fully recurrent neural networks. *Neural computation* 1(2): 270-280.
- Xu, H. (2006). Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International journal of remote sensing* 27(14): 3025-3033.
- Zarghami, M. (2011). Effective watershed management; case study of Urmia Lake, Iran. *Lake and Reservoir Management* 27(1): 87-94.
- Zhou, Y., S. Jin, R. Tenzer and J. Feng (2016). Water storage variations in the Poyang Lake Basin estimated from GRACE and satellite altimetry. *Geodesy and Geodynamics* 7(2): 108-116.