



## Evaluating changes in the water level of Zarivar Lake in 30 years (1993-2023)

Mehdi Feyzolahpour<sup>1</sup>  

1. Department of Geography, University of Zanjan, Zanjan, Iran.  
E: [feyzolahpour@znu.ac.ir](mailto:feyzolahpour@znu.ac.ir) (Corresponding Author)

### ARTICLE INFO

### ABSTRACT

#### Keywords

SVM  
MLC  
WRI  
NWI  
Zarivar Lake

This research has evaluated changes in the water level of Zarivar Lake through remote sensing techniques and GIS geographic information systems. Landsat 5 and 8 satellite images were downloaded for the years 1993, 2010, and 2023 to evaluate these changes, and the lake water level was estimated by two methods, SVM and maximum probability of MLC. Near-infrared and short-wave infrared spectral bands can correctly estimate blue areas. New water index (NWI) and water ratio index (WRI) were used for this purpose. The above spectral indices achieved similar results. So the area of the lake for 2023 for NWI and WRI index was estimated as 9.26 and 9.06 square kilometers, respectively. These values were equal to 8.28 and 8.2 km in 1993, respectively, and this shows a slight increase. The estimated values for SVM and MLC algorithms are different and the year 2023 showed values of 12.75 and 6.21 square kilometers, respectively. The Kappa coefficient value for this year for the above models was 0.94 and 0.87, respectively, and showed the high accuracy of the SVM model. Correlation coefficient values between WRI and NWI spectral indices were also equal to 0.97. There is a negative correlation between the NWI index and the 7 bands of Landsat 8, and the highest correlation between this index and the near-infrared band is -0.95. As investigations showed, the water level of Zarivar Lake was decreasing.

#### Article History:

Received:  
17 JA 2024  
Received in revised form:  
133 JU 2024  
Accepted:  
02 JUL 2024  
Available online:  
15 AU 2024

**Citation:** Feyzolahpou, M. (2024). Evaluating changes in the water level of Zarivar Lake in 30 years (1993-2023). *Journal of Geography*, 22 (81), 19-33.

 <http://10.22034/iga.2024.2017970.1280>



© The Author (s).

Publisher: Iranian Geographical Associati

This is an open access article under the CC BY license (<https://creativecommons.org/licenses/by/4.0/>)

## Extended Abstract

### Introduction

The coastline is defined as the contact line between the land and the lake. Any fluctuation in the lake level creates significant changes in the beach. Extreme changes in the status of different wetlands in the world have occurred mainly through the expansion of urbanization and the growth of agriculture. Changes in the coastline are supposedly essential in environmental management. This is important in coastal erosion monitoring, flood forecasting, and water resources assessment. Remote sensing images are the most reliable type of information data in the world. Various satellite sensors have been placed in Earth's orbit since 1960 to monitor the Earth's surface. Regular monitoring of lakes can provide a basis for understanding human impacts and managing the lake more efficiently. Nowadays, remote sensing and geographic information systems have presented new methods for ecosystem management. These systems allow the development of an automated system for extracting specific elements such as coastlines. GIS system is a useful tool in spatial analysis, accurate description of spatial correlations, and providing effective outputs. Remote sensing systems have been widely used to analyze and evaluate images in different intervals and have made it possible to examine beaches by comparing old and new images. Researchers so far have used no learning algorithm to check the changes in the coastline and the level of Zarivar Lake. This research uses the maximum probability model (MLC) and support vector machine (SVM) to evaluate the change in the coastline and water level of Zarivar Lake.

### Methodology

At first, 3 Landsat 5 and 8 satellite images were selected for Zarivar Lake in the periods of May 1993, 2010, and 2023. The amount of rainfall reaches its peak in May. Therefore, the processing is done in the best conditions so that the maximum rate of expansion and retreat of the lake water level can be obtained in 30 years. The specifications of the images should be free of cloud cover to assess shoreline changes over time. Satellite images depict the state of Zarivar Lake from 1993 to 2023. The 1993 TM sensor map of the Landsat 5 satellite was supposedly a base map to obtain and compare the amount of changes in the years under study. This research uses a multivariate spatial analysis tool. At first, the lake water level was obtained for all three images through the maximum probability method. The support vector machine technique was also used to classify the area under study and gain the amount of surface reduction. The extracted vector layers determined the regression of the lake since 1993. This research used the Kappa coefficient to evaluate the accuracy and reliability of each model and calculated its values for each of the desired years. It estimated, as the last step, the correlation between the NWI and WRI spectral indices and the bands used in their preparation and drew a scatter diagram to determine the relationship between the spectral indices.

### Results and Discussion

The water level of the lake in 1993 is supposedly a basis for evaluating the amount of regression. The total area of the lake according to the MLC model in 1993 was equal to 5.4 square kilometers. The surface area of the lake in 2010 was approximately 8.28 square kilometers, which has increased by 52.7% compared to 1993. The area of surface water reached 21.6 square kilometers in 2023, which has decreased by 25% compared to 2010. The maximum retreat occurred in the southern part of the lake, and a significant deformation was observed in the western part of the lake. Both methods have shown similar results. NWI and WRI spectral indices besides MLC and SVM algorithms were also used to investigate changes in the water's broad stretch of Zarivar Lake. The above indices correctly separate the blue broad stretches from other ones, but it is necessary to reclassify the above maps to gain the area of the blue broad stretches. As the classified map shows, it is possible to estimate the area of Zarivar Lake in spectral indices. The area of the lake has increased from 8.28 square kilometers to 9.26

square kilometers and has increased by 11.8 percent according to the NWI spectral index. The area of the lake in the WRI index has increased from 2.8 square kilometers to 9.06 square kilometers, showing an increase of 10.48%. This shows that the lake level has increased in both indices and the resulting values are very close to each other and only differ by 1.32%. A correlation diagram was established between indicators and the spectral bands used in their preparation to investigate their correlation. The results show that the Pearson correlation coefficient between the two spectral indices NWI and WRI is equal to 0.97 percent and the R2 coefficient is equal to 0.95.

## Conclusion

New techniques based on learning algorithms and spectral indices make it possible to investigate the changes of water broad stretches in intervals of two years. Free satellite images such as Landsat 5 and 8 enable long-term observations. Different spectral bands can show the reflective behavior of water and help to identify them. Likewise, the changes in water broad stretches in semi-arid land like Iran are of great importance. Thus, changes in the water area of Zarivar Lake were investigated in the period 1993-2023. The area under study was divided into three water broad stretches, agricultural lands, and barren lands, through the SVM and MLC algorithms. It showed that the water broad stretch in the SVM model for the years 1993, 2010, and 2023 is equivalent to 8.62, and 10.13, respectively and it was 12.75 square kilometers. The above values in the MLC model are equivalent to 5.42, 8.28, and 6.21. Both models showed an increase in the lake level, but the obtained values had significant differences. For example, the changes in 2023 showed different values for both models. The results of the Kappa coefficient for the SVM model were equal to 0.94 in 2023.

## Funding

There is no funding support.

## Authors' Contribution

All of the author approved the content of the manuscript and agreed on all aspects of the work.

## Conflict of Interest

Author declared no conflict of interest.

## Acknowledgments

We are grateful to all the scientific consultants of this paper.

## References

- 1) Abbas, Z. & Jaber, H.S. (2020). Accuracy assessment of supervised classification methods for extraction land use maps using remote sensing and GIS techniques. IOP Conf. Series: Mater. Sci. Eng, 745(1), 121-126. <https://doi.org/10.1088/1757-899X/745/1/012166>
- 2) Abdoli, M. & Haghghi, M. (2021). Comparison of support vector machine and artificial neural network classification methods to produce landuse maps (Case study: Bojagh National Park), Journal of Environmental Research and Technology, 8(5), 47-60. [persian].
- 3) Abedi, M., Norouzi, G. & Bahroudi, A. (2012). Support Vector machine for multi classification of mineral prospectivity areas, computers and Geosciences,46(2), 272-283. <http://doi.org/10.1016/j.cageo.2011.12.014>
- 4) Afifi, M. (2021). Investigation of the Effect of Drought on Vegetation Using Remote Sensing Techniques, Case Study of Dorodzan Dam Catchment, Journal of Geography, 19(70), 153-172. [persian].
- 5) Al-Abudi, B. Q. & Kouder, N. Z. (2016). Change Detection Study for Al Razaza Lake and The Surrounding Area, GIS & Geospatial Technologies Conference, Special Issue, December 2016, 180-191. <http://doi.org/10.1016/j.ejrs.2022.01.013>
- 6) Al-Azzawi, T.M.F. (2019). Integration approach of remote sensing and GIS to detect land use/land cover change dynamics in himreen lake and surrounding area. Al- Adab J,130(3),111-130. <http://doi.org/10.31973/aj.v1i130.646>

- 7) Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS J. Photogramm. Remote Sens.*, 65(1), 2-16. <http://doi.org/10.1016/j.isprsjprs.2009.06.004>
- 8) Boser, B., Guyon, I. & Vapnik, V. (1992). A training algorithm fotoptimal margin classifier, in: *Proceedings of the Fifth Annual ACM Conference on Computational Learning Theory*, Pittsburgh, 8(2), 144–152. <http://doi.org/10.1145/130385.130401>
- 9) Campvalls, G., Mooij, J. & Scholkopf, B. (2010). Remote sensing feature selection by Kernel dependence measures. *IEEE Geoscience and remote sensing Letters*, 7(4), 587- 591. <http://doi.org/10.1109/LGRS.2010.2041896>
- 10) Chen, J., Chen, J., Liao, A., Cao, X., Chen, L., Chen, X., He, C., Han, G., Peng, S., Lu, M., Zhang, W., Tong, X. & Mills, J. (2015). Global land cover mapping at 30 m resolution: a POK-based operational approach. *ISPRS J. Photogramm. Remote Sens.*, 103(2), 7–27. <http://doi.org/10.1016/j.isprsjprs.2014.09.002>
- 11) Cristianini, N. & Shawe-Taylor, J. (2000). *An Introduction to SupportVector Machines and Other Kernelbased Learning Methods*, Cambridge University Press, 2000, Dellepiane, S., De Laurentiis, R. & Giordano, F. (2004). Coastline extraction from SAR images and a method for the evaluation of the coastline precision. *Pattern Recogn. Lett.*, 25(13), 1461–1470. <https://doi.org/10.1017/CBO9780511801389>
- 12) Ding, J., Cuo, L., Zhang, Y. & Zhu, F. (2018). Monthly and annual temperature extremes and their changes on the Tibetan Plateau and its surroundings during 1963– 2015. *Sci. Rep.*,24(5), 1–23. <https://doi.org/10.1038/s41598-018-30320-0>
- 13) El-Asmar, H.M., Hereher, M.E. & El Kafrawy, S.B. (2013). Surface area change detection of the Burullus Lagoon, North of the Nile Delta, Egypt, using water indices: a remote sensing approach. *Egypt. J. Remote Sensing Space Sci.*, 16(1), 119–123. <http://doi.org/10.1016/j.ejrs.2013.04.004>
- 14) Elshahi, M., Negmb, A. & Ali, K. (2016). Performances evaluation of water body extraction techniques using Landsat ETM+ data: case-study of Lake Nubia, Sudan. *Egypt. J. Eng. Sci. Technol.*, 19 (EIJEST, 19(2), 275–281. <http://doi.org/10.21608/EIJEST.2016.97140>
- 15) Foody, G. & Mathur, A. (2006). The use of small training sets containing mixed pixels for accurate hard image classification: training onmixed spectral responses for classification by a SVM, *RemoteSens. Environ.*, 103(4), 179–189. <http://doi.org/10.1080/01431160600962566>
- 16) Foody, G., Boyd, D. & Sanchez-Hernandez, C. (2007). Mapping a specific class with an ensemble of classifiers, *Int. J. Remote Sens.*, 28(2), 1733–1746. <http://doi.org/10.1016/j.rse.2006.04.001>
- 17) Geo, Y., De Jong, K., Liu, F. & Wang, X., Li, C. (2012). A comparison of Artificial neural networks and support vector machines on landcover classification, *Springer verlag Berlin Heidelberg, ISICA, CCIS*, 316(6), 531- 539. <http://doi.org/10.1080/01431161.2011.568531>
- 18) Granian, H., Tabatabaei, S., Asadi, H. & Carranza, E. (2016). Application of Discriminant Analysis support vector machine Gold Potential areas for further Drilling in the Sari Gunay Gold Deposit, NW Iran, *natural Resource Research*,25(2), 145-159. <http://doi.org/10.1007/11053-015-9271-2>
- 19) Hejazizadeh, Z., Pajooh, F. & Shakiba, H. (2021). Analyzing the accuracy of drought indicators and determining the best climatic indicators in southeastern Iran, *Journal of Geography*, 19(68), 5-21. [persian].
- 20) Huang, C., Davis, L.S. & Townshend, J. (2002). An assessment of support vector machines for land cover classification. *International Journal of Remote sensing*, 23(4), 725- 749.
- 21) Jahanbakhshi, F. & Ekhtesasi, M. (2019). Performance Evaluation of Three Image Classification Methods (Random Forest, Support Vector Machine and the Maximum Likelihood) in Land Use Mapping, *Journal of Water and Soil Science*, 22(4), 235-247. [persian].
- 22) Jensen, J.R. (2005). *Introductory Digital image processing a Remote sensing Perspective*, 3rd Edition, Upper saddle River, Prentice Hall. 526. <http://doi.org/10.1080/10106048709354084>
- 23) Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G. & Johnson, B.A. (2019). Deep learning in remote sensing applications: a meta-analysis and review. *ISPRS J. Photogramm. Remote Sens.*, 152(7), 166–177. <http://doi.org/10.1016/j.isprsjprs.2019.04.015>
- 24) Mountrakis, G., Im, J. & Ogole, C. (2011). Support vector machine in remote sensing a review. *ISPRS Journal of photogrammetry and remote sensing*, 13(2), 247- 259. <https://doi.org/10.1016/j.isprsjprs.2010.11.001>
- 25) Muhsin, I.J., Kaittan, M.Q. & Ali, H.I. (1985). Monitoring of the changes in water rate for Al-razaza lake using remote sensing techniques. *Methods*, 24(4), 120-134. <http://doi.org/10.1016/j.ejrs.2022.01.013>

- 26) Najafi, A., Azizi, S. & Mokhtari, M. (2017). Assessment Kernel Support Vector Machines in Classification of Landuses (Case Study: Basin of Cheshmeh kileh-Chalkrod), Journal of Watershed Management Research, 8(15), 92-101. [persian]
- 27) Rasuly, A., Naghdifar, R. & Rasoli, M. (2010). Monitoring of Caspian Sea coastline changes using object-oriented techniques. Procedia Environ. Sci, 2(5), 416-426. <http://doi.org/10.1016/j.proenv.2010.10.046>
- 28) Shanani Hoveyze, M. & Zarei, H. (2016). Comparison of Three Classification Algorithms (ANN, SVM and Maximum Likelihood) for Preparing Land Use Map (Case Study: Abolabbas Basin), Journal of Watershed Management Science, 10(33), 73-84. [persian].
- 29) Shen, L. & Li, C. (2010). Water body extraction from Landsat ETM+ imagery using adaboost algorithm. In: 18th International Conference on Geoinformatics. IEEE, 1-4. <https://doi.org/10.1109/GEOINFORMATICS.2010.5567762>
- 30) Yousefi, H., Torabi Poteh, H., Haghizadeh, A., Samadi, A., Arshiya, A. & Yarahmadi, Y. (2022). Monitoring the Changes of Zaribar Lake in Kurdistan Using Spectral Indicators and Landsat Images in Google Earth Engine System, Hydrogeology, 6(2), 30-41. [persian]
- 31) Yousefiroshan, M. (2022). Estimation of lake Urmia water area using Landsat 8 satellite imagery using MNDWI Index, Journal of Geography, 20(74), 165-186. [persian].
- 32) Zhang, X., Pan, D., Chen, J., Zhao, J., Zhu, Q. & Huang, H. (2014). Evaluation of coastline changes under human intervention using multi-temporal high-resolution images: a case study of the Zhoushan Islands, China. Remote Sensing, 6(10), 9930-9950. <http://doi.org/10.3390/rs6109930>





## ارزیابی تغییرات سطح آب دریاچه زریوار در بازه زمانی ۳۰ سال (۱۹۹۳ تا ۲۰۲۳)

مهدی فیض اله پور<sup>۱</sup>

۱. گروه جغرافیا، دانشکده علوم انسانی و اجتماعی، دانشگاه زنجان، زنجان، ایران، (نویسنده مسئول). E: [feyzolahpour@znu.ac.ir](mailto:feyzolahpour@znu.ac.ir)

### چکیده

### اطلاعات مقاله

نهادها و مکان‌های زیستی مختلف به اقتضای ماهیت و کارکردشان استراتژی‌های مختلفی را برای رسیدن به هدف در نظر می‌گیرند؛ هدف نهایی تمام این استراتژی‌ها رسیدن به توسعه پایدار می‌باشد. هدف اصلی توسعه حذف نابرابری‌هاست. بهترین مفهوم توسعه، رشد همراه با عدالت اجتماعی است. مفهوم توسعه تداوم رشد اقتصادی، رشد ممتد سرانه واقعی همگام با صیانت از محیط زیست و ارتقای ظرفیت‌های حل مساله است. هدف این تحقیق تحلیل عوامل کلیدی مؤثر بر توسعه پایدار منطقه‌ای مکران است، پژوهش حاضر با بهره‌گیری از روش توصیفی - تحلیلی و بر اساس روش‌های آینده‌پژوهی با ترکیبی از روش‌های اسنادی و پیمایشی صورت گرفته است. در این تحقیق برای شناسایی متغیرهای کلیدی مؤثر بر توسعه پایدار منطقه‌ای مکران پس از مطالعه اسناد بالادستی، از روش دلفی دومرحله‌ای استفاده شده است و داده‌های مورد تحلیل شامل ۳۶ متغیر در قالب ۸ حوزه به‌عنوان متغیرهای اولیه مؤثر بر توسعه پایدار می‌باشد. یافته‌ها نشان می‌دهد، که درجه پرشدگی ماتریس ۶۱٪ است که بیانگر پراکندگی متغیرهای مؤثر بر توسعه‌یافتگی مکران می‌باشد. و بنابراین وضعیت توسعه این منطقه پیچیده، چندبعدی و تا حد زیادی مستلزم نقش‌آفرینی مولفه‌های مختلف مدیریتی، سیاست‌گذاری، اجتماعی و اقتصادی در سطوح مختلف کلان، میانه و خرد می‌باشد. در واقع تا زمانی که تحولات اساسی در ساختار اقتصادی و مدیریتی منطقه مکران به وجود نیاید و قدرت اقتصادی لازم و تحولات مدیریتی - نهادی مؤثر صورت نگیرد امکان بهبود در وضعیت توسعه منطقه‌ای مکران ناممکن می‌باشد.

### واژگان کلیدی:

توسعه‌یافتگی  
برنامه‌ریزی  
آمایش سرزمین  
مکران  
میک‌مک

### تاریخ دریافت:

۱۴۰۲/۱۰/۲۶

### تاریخ بازنگری:

۱۴۰۲/۰۳/۰۲

### تاریخ پذیرش:

۱۴۰۳/۰۴/۱۲

### تاریخ چاپ:

۱۴۰۳/۰۶/۰۱

**استاد:** فیض اله پور، مهدی. (۱۴۰۳). ارزیابی تغییرات سطح آب دریاچه زریوار در بازه زمانی ۳۰ سال (۱۹۹۳ تا ۲۰۲۳)، فصلنامه جغرافیا، (۸۱) ۲۲، ۳۳-۱۹.

doi: <http://10.22034/iga.2024.2017970.1280>



## مقدمه و پیشینه

استفاده از روش های طبقه بندی یکی از موارد پر کاربرد استفاده از داده های سنجش از دور می باشد. هر روش طبقه بندی به نتایج متفاوتی دست می یابد (Geo et al, 2012:536). روش حداکثر احتمال و کمترین فاصله از متداول ترین روش های طبقه بندی به شمار می روند. امروزه روش هایی مانند روش شبکه عصبی مصنوعی، الگوریتم ماشین بردار پشتیبانی، جنگل تصادفی و حداکثر احتمال ارائه شده اند. هر الگوریتم طبقه بندی روش های مخصوص خود را داشته و به نتایج متفاوتی دست می یابد. یکی از پر کاربردترین روش ها در تفکیک تصاویر ماهواره ای روش ماشین بردار پشتیبانی یا SVM می باشد. این روش در سال ۱۹۹۲ به وسیله واپنیک ارائه گردید (Boser et al, 1992: 37). در این روش طبقه بندی داده ها به صورت خطی بوده و در تقسیم داده ها از خطی استفاده می شود که دارای بیشترین حاشیه می باشد. در صورتی که داده ها را نتوان به صورت خطی از یکدیگر جدا نمود از توابع کرنل بهره گرفته می شود. این روش در مواردی مانند زمین شناسی، کشاورزی و تعیین کاربری اراضی به کار گرفته شده است (Abedi et al, 2012: 252; Mountrakis et al, 2011: 252; Granian et al, 2016: 150; 212). استفاده از این روش در تحلیل تصاویر ماهواره ای به سرعت در حال افزایش است (Huange et al, 2002: 731; Campvalls et al, 2010: 592).

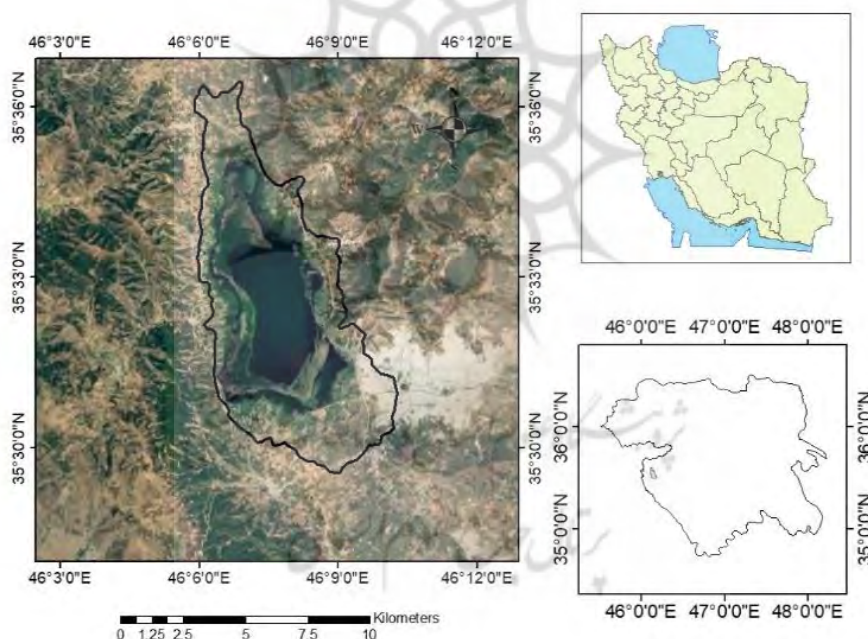
تحقیقات مختلفی در زمینه استفاده از الگوریتم های یادگیری انجام شده است. شنائی و زارعی (۱۳۹۵) در تهیه نقشه های کاربری اراضی از روش های حداکثر احتمال، ماشین بردار پشتیبانی و شبکه عصبی مصنوعی استفاده کرده و نتایج حاصله را با یکدیگر مقایسه کردند. نتایج نشان داد که هر دو مدل از توانایی بالایی در تشخیص کاربری اراضی برخوردار می باشند. نجفی و همکاران (۱۳۹۶) برای بررسی کاربری زمین در حوضه چشمه کیله از روش ماشین بردار پشتیبانی استفاده کردند. نتایج نشان داد که این مدل در تفکیک مناطقی که از نظر طیفی مشابه بوده اند بهتر عمل کرده است. جهانبخشی و اختصاصی (۱۳۹۷) عملکرد روش های بیشترین شباهت، ماشین بردار پشتیبانی و جنگل تصادفی را در بررسی پوشش اراضی مورد ارزیابی قرار دادند. نتایج نشان داد که مدل ماشین بردار پشتیبانی نسبت به مدل های دیگر به نتایج قابل قبولی دست یافته است. عبدلی و حقیقی (۱۳۹۹) روش شبکه عصبی مصنوعی را با روش ماشین بردار پشتیبانی مقایسه کرده و مشاهده کردند که مدل ماشین بردار پشتیبانی نسبت به مدل شبکه عصبی مصنوعی به نتایج بهتری دست می یابد. دریاچه زریوار کردستان از جنبه های مختلفی مورد بررسی قرار گرفته است لیکن تاکنون در موارد معدودی به تغییرات سطح این دریاچه پرداخته شده است. عادبدینی و ستوده پور (۱۳۹۶) با استفاده از سیستم اطلاعات جغرافیایی و سنجش از دور اقدام به آشکارسازی روند تغییرات دریاچه نموده اند. به این منظور دوره زمانی ۵۷ ساله از ۱۳۳۵ تا ۱۳۹۲ مورد بررسی قرار گرفته و مشاهده شد که سطح دریاچه از ۱۲۹۷ هکتار در سال ۱۳۳۵ به ۸۸۲ هکتار در سال ۱۳۹۲ کاهش یافته است. یوسفی و همکاران (۱۴۰۰) با استفاده از شاخص های طیفی تفاضل نرمال و تصاویر لندست به بررسی تغییرات دریاچه زریوار پرداختند. به این منظور از شاخص های NDWI و MNDWI استفاده شد. نتایج نشان داد که شاخص MNDWI از قابلیت خوبی در تشخیص پهنه دریاچه زریوار برخوردار است. عفیفی (۱۴۰۰) با استفاده از تکنیک های سنجش از دور به بررسی اثر خشکسالی در حوضه آبریز سد درودزن پرداختند. نتایج نشان داد که شاخص NDVI بیشترین همبستگی را نسبت به تغییرات خشکسالی داشته است. حجازی زاده و همکاران (۱۴۰۰) به منظور تعیین بهترین شاخص در جنوب شرق ایران اقدام به مقایسه چند شاخص خشکسالی نمودند. نتایج نشان داد که شاخص دینامیک بارش استاندارد عملکرد بهتری در برآورد خشکسالی داشته است. یوسفی روشن (۱۴۰۱) با استفاده از

تصاویر ماهواره ای لندست ۸ و با استفاده از شاخص MNDWI، پهنه آبی دریاچه ارومیه را بررسی کردند. نتایج نشان داد که این شاخص از قابلیت بالایی در بررسی پهنه های آبی برخوردار بوده است.

بر اساس تحقیقات صورت گرفته مشاهده می شود که تاکنون برای بررسی تغییرات خط ساحلی و سطح دریاچه زریوار از هیچ الگوریتم یادگیری استفاده نشده است لذا در این تحقیق برای ارزیابی تغییر خط ساحلی و سطح آب دریاچه زریوار از مدل حداکثر احتمال (MLC) و ماشین بردار پشتیبانی (SVM) استفاده شده است.

### روش تحقیق

دریاچه زریوار در مختصات جغرافیایی ۴۶ درجه و ۵ دقیقه تا ۴۶ درجه و ۱۱ دقیقه طول شرقی و ۳۵ درجه و ۲۸ دقیقه تا ۳۵ درجه و ۳۷ دقیقه عرض شمالی قرار دارد. ارتفاعا دریاچه از سطح دریا ۱۲۷۵ متر بوده و در ارتفاعات زاگرس واقع شده و دریاچه ای طبیعی می باشد. بخشی از جنگل های زاگرس در این منطقه قرار گرفته است. عمق این دریاچه بین ۲ تا ۷ متر متغیر است. در فصل سرد این منطقه متاثر از اقلیم مدیترانه ای می باشد. میانگین درجه حرارت معادل ۱۳ درجه سانتیگراد بوده است.



شکل ۱. موقعیت محدوده مورد مطالعه در دریاچه زریوار  
منبع: (ترسیم از نویسندگان)

در ابتدا، ۳ تصویر ماهواره ای لندست ۵ و ۸ برای دریاچه زریوار در دوره های زمانی ماه می ۱۹۹۳، ۲۰۱۰ و ۲۰۲۳ انتخاب شد. میزان بارندگی در ماه می به اوج خود می رسد بنابراین پردازش در بهترین شرایط انجام می شود تا بتوان نرخ بیشترین گسترش و عقب نشینی سطح آب دریاچه را در بازه زمانی ۳۰ سال به دست آورد. برای ارزیابی تغییرات خط ساحلی در طول زمان، مشخصات تصاویر استفاده شده ایجاب می کند که عاری از پوشش ابر باشند (Zhang et al, 2014:9933). تصاویر ماهواره ای وضعیت دریاچه زریوار را از سال ۱۹۹۳ تا ۲۰۲۳ به تصویر می کشد. نقشه ۱۹۹۳



سنجنده TM ماهواره لندست ۵ به عنوان نقشه پایه در نظر گرفته شد تا میزان تغییرات در سال های مورد مطالعه به دست آمده و مقایسه گردد.


جدول ۱. خصوصیات باندهای استفاده شده از ماهواره های لندست ۵ و ۸

سنجنده	تاریخ تصویربرداری	باند	توان تفکیک	طول موج
TM لندست ۵	۱۹۹۳/۰۵/۱۶	باند ۱	۳۰ متر	آبی
		باند ۲	۳۰ متر	سبز
		باند ۳	۳۰ متر	قرمز
		باند ۴	۳۰ متر	مادون قرمز نزدیک
		باند ۵	۳۰ متر	مادون قرمز موج کوتاه
		باند ۶	۱۲۰ متر	حرارتی
		باند ۷	۳۰ متر	مادون قرمز موج کوتاه
OLI لندست ۸	۲۰۲۳/۰۵/۱۹	باند ۱	۳۰ متر	گرد و غبار، ساحل
		باند ۲	۳۰ متر	آبی
		باند ۳	۳۰ متر	سبز
		باند ۴	۳۰ متر	قرمز
		باند ۵	۳۰ متر	مادون قرمز نزدیک
		باند ۶	۳۰ متر	مادون قرمز موج کوتاه
		باند ۷	۳۰ متر	مادون قرمز موج کوتاه

در این تحقیق از ابزار تحلیل مکانی چند متغیره استفاده شده است. در ابتدا سطح آب دریاچه برای هر سه تصویر با استفاده از روش حداکثر احتمال به دست آمد. علاوه بر این از تکنیک ماشین بردار پشتیبانی برای طبقه بندی منطقه مورد مطالعه و به دست آوردن میزان کاهش سطح استفاده شد. لایه های برداری استخراج شده برای تعیین پسرفت دریاچه از سال ۱۹۹۳ به کار گرفته شد.

برای آموزش تصاویر در مدل ماشین بردار پشتیبانی (SVM) و حداکثر احتمال (MLC) نیاز به ترکیب ۷ باند ماهواره لندست ۵ و ۸ می باشد. تصاویر رنگی کاذب برای سالهای مورد مطالعه در زیر نمایش داده شد.

پروژه گاه علوم انسانی و مطالعات فرهنگی  
پرتال جامع علوم انسانی



شکل ۲. تصاویر رنگی کاذب سال های ۱۹۹۳، ۲۰۱۰ و ۲۰۲۳ برای ترسیم نقشه SVM و MLC  
منبع: (ترسیم از نویسندگان)

مدل SVM یک سیستم یادگیری تحت نظارت بوده و بر اساس پیشرفت های اخیر در نظریه یادگیری آماری استوار است (Cristianini et al, 2000:36). برخی از تحقیقات بر روی توابع ریاضی مدل SVM متمرکز شده اند. این مدل طبقات را به سطوح تصمیم گیری تقسیم کرده و مرز بین طبقات را به حداکثر می رساند. بردارهای پشتیبانی از عناصر مهم مجموعه آموزشی به شمار می آیند (Foody et al, 1978; Boser et al, 1992: 149). برای اجرای SVM، داده های آموزشی مورد نیاز است. این داده ها فرایند جداسازی طبقات را بهینه سازی می کنند (Foody et al, 2006: 184). با استفاده از یک تابع پایه شعاعی (RBF)، پراکنش طبقات با محدوده های غیرخطی را می توان در یک محدوده جدا شده خطی ترسیم نمود (Huange et al, 2002:731). آموزش SVM با RBF مستلزم تنظیم دو پارامتر است. یکی از این پارامترها، پارامتر منظم سازی است که تعادل بین به حداکثر رسانی حساسیت حواشی و به حداقل رساندن خطای آموزشی را برقرار کرده و کنترل می کند.

پارامتر تنظیم کننده کوچک تمایل به تاکید بر حواشی و نادیده گرفتن نقاط پرت در داده های آموزشی دارد. پارامتر منظم سازی بزرگ ممکن است با داده های آموزشی بیشتری مطابقت داشته باشد. شرح جامع پارامترهای SVM را می توان در نوشته های کریستیانینی<sup>۱</sup> و همکاران (۲۰۰۰) مشاهده نمود. طبقه بندی SVM شامل چهار نوع خطی، چند جمله ای، RBF و سیگموئید می باشد. نوع RBF در بیشتر موارد به خوبی عمل می کند. ساختار ریاضی این چهار نوع در معادلات زیر نشان داده شده است.

رابطه (۱)	خطی (۱)	$k(x_i, x_j) = x_i^t x_j$
رابطه (۲)	چند جمله ای (۲)	$k(x_i, x_j) = (\gamma x_i^t x_j + r)^d, \gamma > 0$
رابطه (۳)	نوع RBF (۳)	$k(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2), \gamma > 0$
رابطه (۴)	نوع سیگموئید (۴)	$k(x_i, x_j) = \tan h(\gamma x_i^t x_j + r)$

در این معادلات،  $x_i$  بردار پشتیبانی  $i$  ها،  $x_j$  نقاط آموزش داده شده برای  $j$  ها،  $t$  پارامتر هموارسازی،  $k$  تابع مرکزی،  $\gamma$  پهنای هسته در توابع هسته مدل ها به جز مدل خطی،  $d$  نسبت درجه چند جمله ای در توابع هسته،  $r$  نسبت بایاس در توابع هسته ای مدل های چند جمله ای و سیگموئید بوده و  $\gamma$ ،  $d$  و  $r$  پارامترهای کنترل شده توسط کاربر می باشد زیرا تعریف صحیح آنها بطور قابل توجهی باعث افزایش دقت SVM می شود.

روش حداکثر احتمال (MLC) یکی از رایجترین روش های طبقه بندی به شمار می آید. در ابتدا احتمال تعلق هر پیکسل به طبقات موجود محاسبه شده و سپس پیکسل ها به طبقاتی که بیشترین احتمال را در بر گرفته تعلق می گیرد برای محاسبه میزان احتمال از قانون بیز استفاده شده و به صورت زیر برآورد می گردد (Jensen, 2005: 311).

$$D = \ln(ac) - [0.5 \ln(|cov|)] - [0.5(x - mt)^T (cov^{-1})(x - mt)] \quad (۵)$$

در این رابطه  $D$  نشان دهنده فواصل وزنی،  $C$  درصد احتمال تعلق پیکسل ها به طبقات،  $x$  بردار اثر طیفی پیکسل ها،  $mt$  میانگین داده های تعلیمی در طبقات  $ac$  و  $cov$  ماتریس کواریانس پیکسل های آموزش داده شده در رده طبقات  $c$  می باشد. در صورتی که نمونه مورد نظر از بیشترین مقدار  $D$  برخوردار باشد بر اساس رابطه زیر به طبقه  $J$  تعلق می گیرد.

$$J = \arg \max_{i=1 \dots M} D_i \quad (۶)$$

طبقه بندی در این روش بر اساس واریانس و کواریانس انجام گرفته و چنین فرض می شود که پیکسل ها در تمام ناحیه آموزش داده شده دارای توزیع نرمال هستند (Jensen, 2005: 311).

برای ارزیابی صحت و درجه اعتبار هر یک از مدل های استفاده شده در این تحقیق از ضریب کاپا استفاده شده و مقادیر آن برای هر یک از سال های مورد نظر برآورد گردید. در آخرین مرحله همبستگی بین شاخص طیفی NWI، WRI و باندهای استفاده شده در تهیه آنها برآورد شده و نمودار پراکنش ترسیم شد تا بدین وسیله رابطه بین شاخص های طیفی مشخص گردد.

تکنیک NWI به وسیله دینگ<sup>۱</sup> و همکاران (۲۰۱۸) پیشنهاد شده و از چهار باند طیفی آبی، مادون قرمز نزدیک، مادون قرمز موج کوتاه ۱ و ۲ برای استخراج پهنه های آبی استفاده کرده است. این شاخص باند سبز را با باند آبی جایگزین کرده و باند NIR با مجموع بازتابی ۳ باند مادون قرمز جایگزین شده است.

$$NWI = \frac{(P_{blue} - (PNIR + PSWIR_1 + PSWIR_2))}{(P_{blue} + (PNIR + PSWIR_1 + PSWIR_2))} \quad (۷)$$

شاخص دیگری که در برآورد تغییرات سطح آب استفاده شد شاخص نسبت آب (WRI) می باشد. شین<sup>۲</sup> و همکاران (۲۰۱۰) شاخص نسبت آب را در سال ۲۰۱۰ ارائه کردند. در این تکنیک چهار باند طیفی به کار گرفته شد. این شاخص از

1. Ding

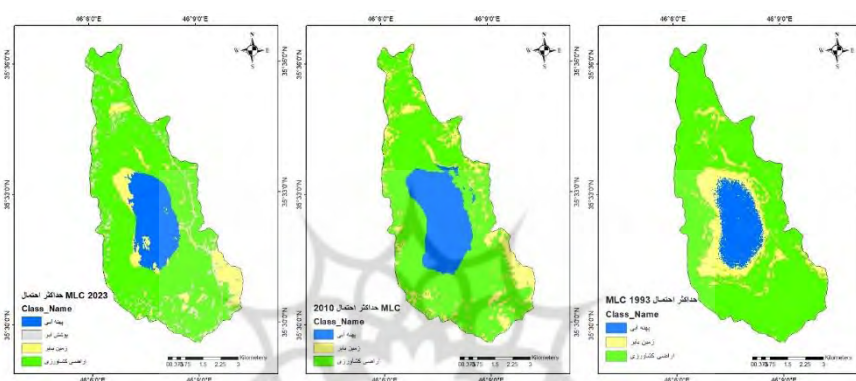
2. Shen

نسبت بین مجموع بازتاب طیفی دو باند مرئی سبز و قرمز به مجموع بازتاب طیفی مادون قرمز نزدیک و مادون قرمز موج کوتاه (SWIR1) به دست می آید.

$$WRI = \frac{(P_{green} + P_{red})}{(P_{NIR} + P_{SWIR1})} \quad \text{رابطه (۸)}$$

### بحث و یافته‌ها

سطح آب دریاچه در سال ۱۹۹۳ به عنوان پایه ای برای ارزیابی میزان پسرفت در نظر گرفته شده است. شکل ۵ میزان عقب نشینی سطح دریاچه را تا سال ۲۰۲۳ بر اساس روش حداکثر احتمال نشان می دهد.



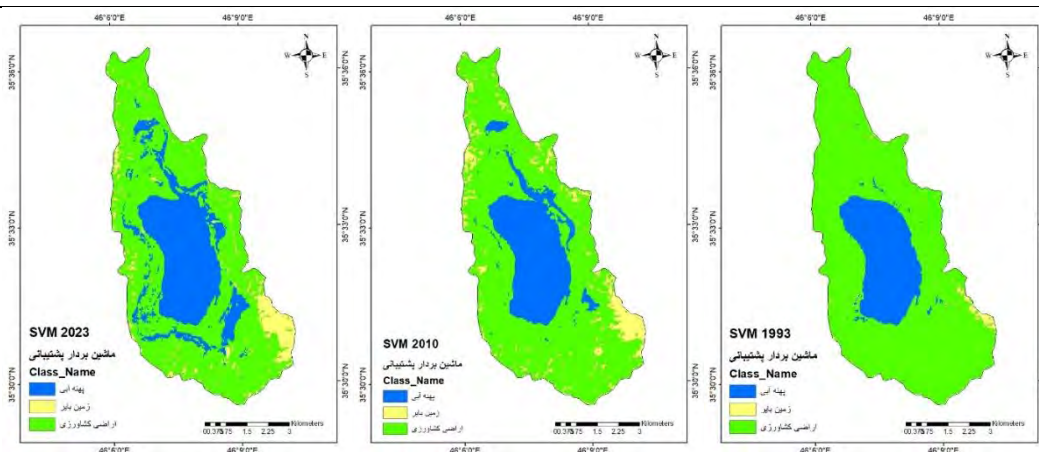
شکل ۳. تغییرات سطح دریاچه زیروار بر اساس مدل حداکثر احتمال MLC از سال ۱۹۹۳ تا ۲۰۲۳  
منبع: (ترسیم از نویسندگان)

کل مساحت دریاچه بر اساس مدل MLC در سال ۱۹۹۳ معادل ۵/۴۲ کیلومتر مربع بوده است. در سال ۲۰۱۰ مساحت سطح دریاچه تقریباً ۸/۲۸ کیلومتر مربع بوده که نسبت به سال ۱۹۹۳ با افزایشی معادل ۵۲/۷ درصدی مواجه شده است. در سال ۲۰۲۳ مساحت آب های سطحی به ۶/۲۱ کیلومتر مربع رسید که نسبت به سال ۲۰۱۰ با ۲۵ درصد کاهش روبرو شده است. حداکثر عقب نشینی در قسمت جنوبی دریاچه اتفاق افتاده و علاوه بر آن تغییر شکل قابل توجهی به وضوح در قسمت غربی دریاچه مشاهده می شود. علاوه بر این، نتایج طبقه بندی SVM در شکل ۶ نمایش داده شده و نشان می دهد که سطح دریاچه تا سال ۲۰۲۳ افزایش یافته است. مقادیر برآورد شده برای تغییرات پهنه آبی دریاچه زیروار در جدول زیر نمایش داده شده است.

جدول ۲. مساحت پهنه های برآورد شده توسط کدل های MLC و SVM

کاربری	MLC			SVM		
	۱۹۹۳	۲۰۱۰	۲۰۲۳	۱۹۹۳	۲۰۱۰	۲۰۲۳
پهنه آبی	۵/۴۲	۸/۲۸	۶/۲۱	۸/۶۲	۱۰/۱۳	۱۲/۷۵
اراضی زراعی	۳۲/۰۴	۳۰/۲۷	۳۰/۰۷	۳۵/۵۸	۳۱/۱۱	۲۸/۰۷
زمین بایر	۷/۳	۶/۲	۳/۰۲	۰/۵۶	۳/۵۱	۳/۲۶

منبع: (ترسیم از نویسندگان)



شکل ۴. تغییرات سطح دریاچه زریوار بر اساس مدل ماشین بردار پشتیبانی SVM از سال ۱۹۹۳ تا ۲۰۲۳  
منبع: (ترسیم از نویسندگان)

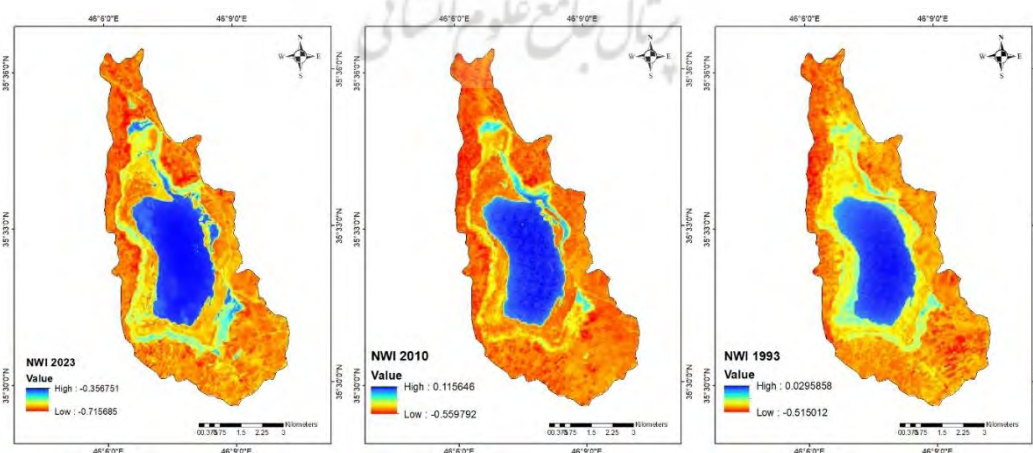
در هر دو روش نتایج مشابهی حاصل شده است. از نظر بصری، نقشه های (شکل ۶) را می توان با شکل ۵ مقایسه کرد و مشاهده می شود که مقادیر تغییرات از شباهت قابل توجهی برخوردار هستند. با این وجود، مدل SVM دقت بالایی را در فرایندهای طبقه بندی نشان داد. مقادیر ضریب کاپا برای هر دو مدل در زیر نشان داده شد.

جدول ۳. مقادیر ضریب کاپا برای مدل های SVM و MLC در بازه زمانی ۱۹۹۳ تا ۲۰۲۳

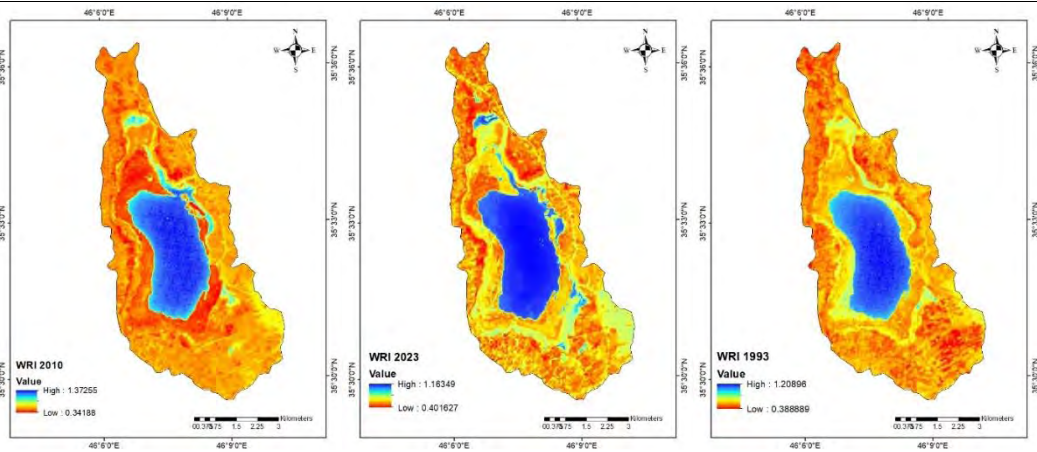
سال	ضریب کاپا مدل SVM	ضریب کاپا مدل MLC
۱۹۹۳	۰/۹۲	۰/۸۵
۲۰۱۰	۰/۹۶	۰/۸۹
۲۰۲۳	۰/۹۴	۰/۸۷

منبع: (ترسیم از نویسندگان)

علاوه بر الگوریتم های SVM و MLC از شاخص های طیفی NWI و WRI نیز برای بررسی تغییرات پهنه آبی دریاچه زریوار استفاده شد. باندهای طیفی مادون قرمز نزدیک و مادون قرمز موج کوتاه از قابلیت برآورد صحیح پهنه های آبی برخوردار می باشند. به این منظور از شاخص جدید آب (NWI) و شاخص نسبت آب (WRI) استفاده شد. تصاویر حاصل از این شاخص ها در زیر نشان داده شده است.

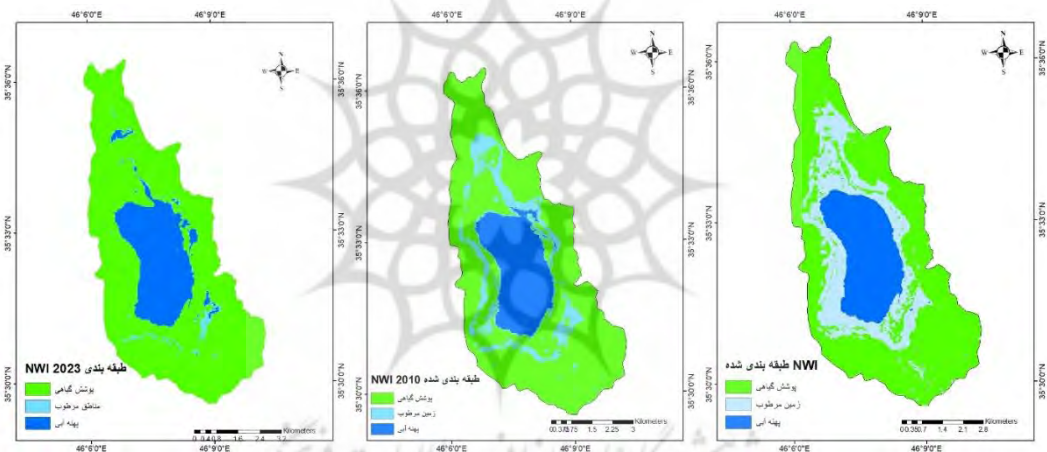


شکل ۵. تغییرات سطح دریاچه زریوار بر اساس شاخص طیفی NWI از سال ۱۹۹۳ تا ۲۰۲۳  
منبع: (ترسیم از نویسندگان)

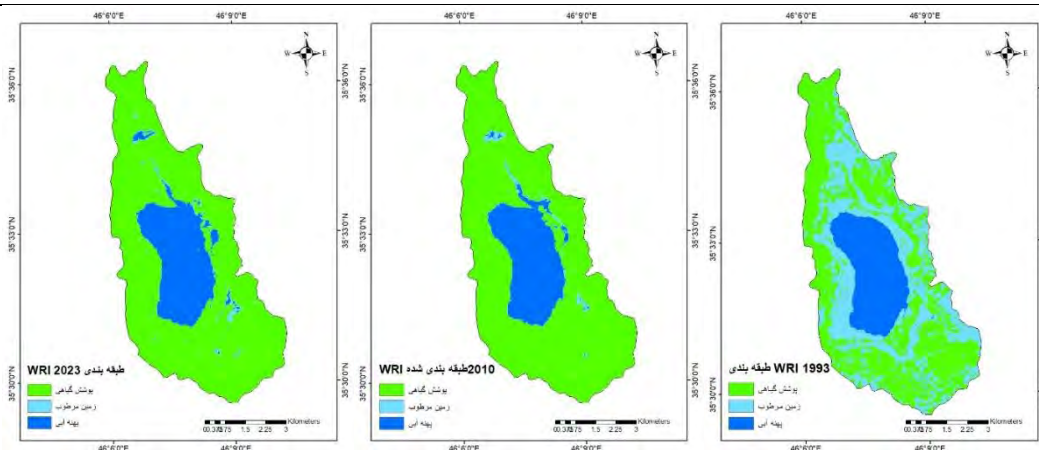


شکل ۶. تغییرات سطح دریاچه زریوار بر اساس شاخص طیفی WRI از سال ۱۹۹۳ تا ۲۰۲۳  
منبع: (ترسیم از نویسنده)

شاخص های فوق به درستی پهنه های آبی را از سایر پهنه ها جدا می سازد لیکن برای به دست آوردن مساحت پهنه های آبی لازم است که نقشه های فوق Reclassify گردند. پس از اجرای فرایند فوق نقشه های زیر به دست آمد.



شکل ۷. نقشه طبقه بندی شده شاخص NWI در بازه زمانی ۱۹۹۳ تا ۲۰۲۳  
منبع: (ترسیم از نویسنده)



شکل ۸. نقشه طبقه بندی شده شاخص WRI در بازه زمانی ۱۹۹۳ تا ۲۰۲۳  
منبع: (ترسیم از نویسنده)

بر اساس نقشه طبقه بندی شده امکان برآورد مساحت پهنه دریاچه زریوار در شاخص های طیفی میسر می گردد. فرایندهای ماشین بردار پشتیبانی و حداکثر احتمال نیازی به این امر نبوده و بر اساس نقشه خروجی می توان مساحت پهنه ها را به دست آورد لیکن در شاخص های طیفی این امر میسر نبوده و نیاز به Reclassify می باشد. بر این اساس مساحت پهنه دریاچه به صورت زیر به دست آمد.

جدول ۴. مساحت پهنه دریاچه زریوار در شاخص های طیفی NWI و WRI از سال ۱۹۹۳ تا ۲۰۲۳

کاربری	WRI بر حسب کیلومتر مربع			NWI بر حسب کیلومتر مربع		
	۲۰۲۳	۲۰۱۰	۱۹۹۳	۲۰۲۳	۲۰۱۰	۱۹۹۳
پوشش گیاهی	۳۵/۴	۳۶/۱۴	۳۶/۵	۳۶/۴۶	۳۶/۴۷	۳۶/۴۷
سطح دریاچه	۹/۰۶	۸/۶	۸/۲	۸/۲۹	۸/۲۸	۸/۲۸

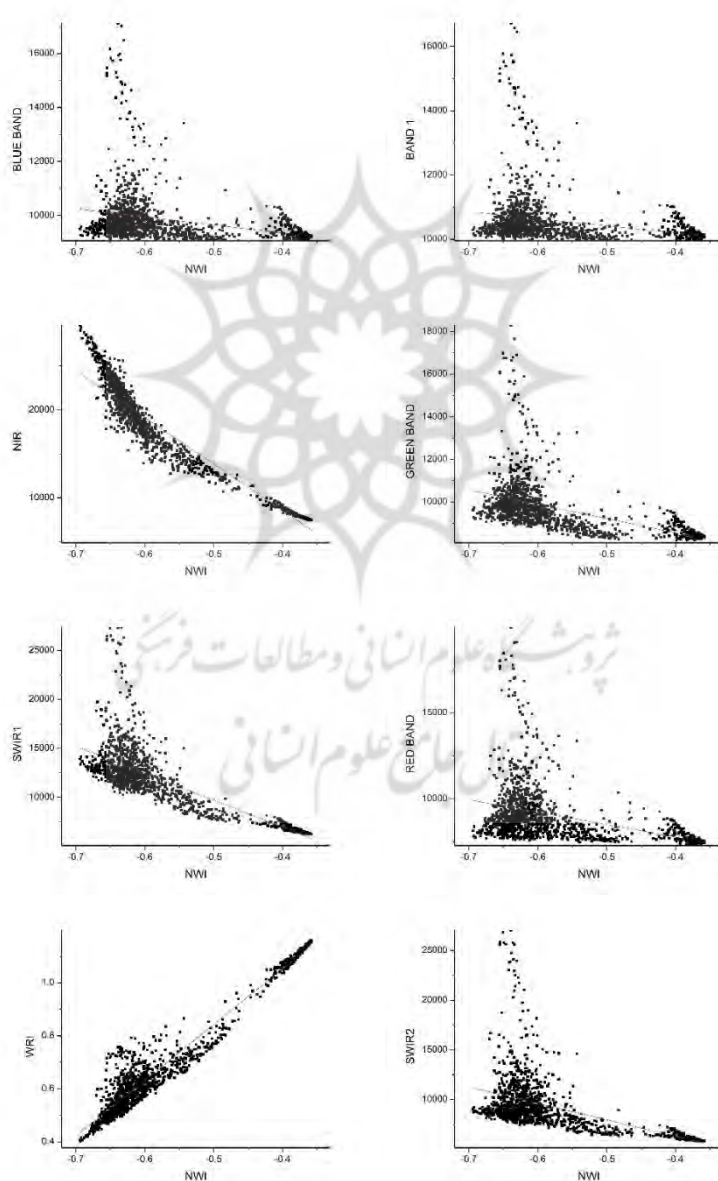
منبع: (ترسیم از نویسندگان)

بر اساس شاخص طیفی NWI مساحت دریاچه از ۸/۲۸ کیلومتر مربع به ۹/۲۶ کیلومتر مربع رسیده و حدود ۱۱/۸ درصد افزایش یافته است. در شاخص WRI مساحت دریاچه از ۸/۲ کیلومتر مربع به ۹/۰۶ کیلومتر مربع رسیده و ۱۰/۴۸ درصد افزایش را نشان می دهد. این امر حاکی از آن است که در هر دو شاخص سطح دریاچه افزایشی را نشان داده و مقادیر حاصله بسیار نزدیک به هم بوده و تنها ۱/۳۲ درصد با یکدیگر تفاوت داشته اند. به منظور بررسی روابط همبستگی بین شاخص ها با باندهای طیفی استفاده شده در تهیه آنها، نمودار همبستگی بین آنها برقرار گردید. نتایج نشان می دهد که ضریب همبستگی پیرسون بین دو شاخص طیفی NWI و WRI معادل ۰/۹۷ درصد بوده و ضریب R2 نیز معادل ۰/۹۵ می باشد لذا می توان چنین استدلال کرد که هر دو شاخص به نتایج بسیار مشابهی دست یافته و شاخص WRI با بهره گیری از باند های سبز، قرمز، مادون قرمز نزدیک و مادون قرمز موج کوتاه به نتایجی مشابه با شاخص NWI دست می یابد. از بین باندهای طیفی بیشترین همبستگی بین NWI و مادون قرمز نزدیک به میزان ۰/۹۵- می باشد. شاخص NWI با تمام باندهای طیفی دارای همبستگی منفی می باشد. کمترین میزان همبستگی نیز بین این شاخص با باند ۱ به میزان ۰/۲۷- می باشد. مقادیر فوق در جدول زیر نمایش داده شده است.

جدول ۵. مقادیر ضریب همبستگی پیرسون بین شاخص NWI و باندهای استفاده شده در تهیه این شاخصها در سال ۲۰۲۳

شاخص ها و باندها	ضریب همبستگی پیرسون	ضریب $R^2$
NWI, SWIR2	-.۵۶	.۳۳
NWI, SWIR1	-.۷۹	.۶۳
NWI, NIR	-.۹۵	.۹۱
NWI, Red	-.۴۳	.۱۸
NWI, GREEN	-.۵۳	.۲۸
NWI, BLUE	-.۳۱	.۰۹
NWI, BAND1	-.۲۷	.۰۷
NWI, WRI	.۹۷	.۹۵

منبع: (ترسیم از نویسندگان)



شکل ۹. نمودار پراکنش بین شاخص NWI، NWI و باندهای طیفی برای سال ۲۰۲۳

منبع: (ترسیم از نویسندگان)



## نتیجه گیری

با بهره گیری از تکنیک های جدید مبتنی بر الگوریتم های یادگیری و شاخص های طیفی می توان به بررسی تغییرات پهنه های آبی در بازه های زمانی چندین ساله پرداخت. تصاویر ماهواره ای رایگان مانند لندست ۵ و ۸ امکان رصدهای طولانی مدت را میسر می سازد.

باندهای مختلف طیفی می توانند رفتار بازتابی آب را نمایش داده و به شناسایی آنها کمک نمایند. در کنار آن، تغییرات پهنه های آبی در سرزمین نیمه خشکی مانند ایران از اهمیت بالایی برخوردار است. با توجه به این امر به بررسی تغییرات پهنه آبی دریاچه زریوار در بازه زمانی ۱۹۹۳ تا ۲۰۲۳ پرداخته شد. با بهره گیری از الگوریتم ماشین بردار پشتیبانی SVM و طبقه بندی حداکثر احتمال MLC منطقه مورد مطالعه به سه پهنه آبی، اراضی زراعی و زمین های بایر تقسیم گردیده و مشاهده شد که پهنه آبی در مدل SVM برای سالهای ۱۹۹۳، ۲۰۱۰ و ۲۰۲۳ به ترتیب معادل ۸/۶۲، ۱۰/۱۳ و ۱۷/۵ کیلومتر مربع بوده است. مقادیر فوق در مدل MLC معادل ۵/۴۲، ۸/۲۸ و ۶/۲۱ می باشد. در هر دو مدل، افزایشی در سطح دریاچه مشاهده شد لیکن مقادیر به دست آمده از تفاوت قابل توجهی برخوردار بوده اند. برای مثال، تغییرات در سال ۲۰۲۳ برای هر دو مدل مقادیر متفاوتی را نشان داد.

نتایج ضریب کاپا برای مدل SVM معادل ۰/۹۴ در سال ۲۰۲۳ به دست آمد. این مقدار در مدل MLC معادل ۰/۸۷ برآورد گردید. لذا مشاهده می شود که مدل SVM از دقت بالاتری برخوردار است. شاخص طیفی NWI، مساحت سطح دریاچه را حدود ۹/۲۶ کیلومتر مربع برآورد نمود. در مدل WRI و در سال ۲۰۲۳ این مقدار معادل ۹/۰۶ کیلومتر مربع برآورد شد. مشاهده می شود که این دو شاخص در پیش بینی پهنه آبی به نتایج مشابهی دست یافتند. در مقایسه بین شاخص های طیفی با باندهای استفاده شده مشاهده شد که همبستگی بین شاخص های NWI و WRI معادل ۰/۹۷ بوده و نشان می دهد که هر دو شاخص به نتایج مشابهی دست یافته اند. در مقایسه بین شاخص NWI و باندهای طیفی نیز مشاهده شد که بین این شاخص و باندها همبستگی منفی برقرار بوده و بیشترین میزان همبستگی معادل ۰/۹۵- بوده و بین شاخص NWI و NIR برقرار می باشد. در کل بررسی ها نشان داد که سطح دریاچه با افزایش مواجه بوده است.

## حامی مالی

این اثر حامی مالی نداشته است.

## سهام نویسندگان

نویسندگان در انجام این پژوهش سهم برابر دارند.

## تضاد منافع

نویسندگان اعلام می دارند، هیچ تضاد منافی در رابطه با نویسندگی و یا انتشار این مقاله ندارند.

## تقدیر و تشکر

بنا به اظهار نویسنده مسئول، این مقاله حامی نداشته است.

## منابع

- ۳۳) جهانبخشی، فرشید و اختصاصی، محمدرضا (۱۳۹۷). ارزیابی عملکرد سه روش طبقه بندی تصویر (جنگل تصادفی، ماشین بردار پشتیبانی و بیشترین شباهت) در تهیه نقشه کاربری اراضی، نشریه علوم آب و خاک، (۴) ۲۲، ۲۳۵-۲۴۷. <http://doi.org/10.29252/jstnar.22.4.235>
- ۳۴) حجازی زاده، زهرا؛ پژوه، فرشاد و شکیبا، هانیه (۱۴۰۰). واکاوی و مقایسه چند شاخص خشکسالی اقلیمی و تعیین بهترین شاخص در جنوب شرق ایران، فصلنامه علمی جغرافیا، (۳) ۶۸، ۲۱-۵. <http://dor.net/dor/20.1001.1.27172996.1400.19.1.1.3>
- ۳۵) شنائی، مائده و زارعی، حیدر (۱۳۹۵). مقایسه الگوریتم های طبقه بندی شبکه عصبی مصنوعی، ماشین بردار پشتیبانی و حداکثر احتمال در استخراج نقشه کاربری اراضی حوزه آبخیز الوالعباس، نشریه علوم و مهندسی آبخیزداری، (۳۳) ۱۰، ۷۳-۸۴. <http://doi.org/20.1001.1.20089554.1395.10.33.3.2>
- ۳۶) عبدلی، مهسا و حقیقی، مریم (۱۳۹۹). مقایسه روش های طبقه بندی ماشین بردار پشتیبانی و شبکه عصبی مصنوعی در تهیه نقشه کاربری اراضی، پژوهش و فناوری محیط زیست، (۸) ۵، ۶۰-۴۷. <http://doi.org/10.29252/5.8.47>
- ۳۷) عقیقی، محمد ابراهیم (۱۴۰۰). بررسی اثر خشکسالی بر روی پوشش گیاهی با استفاده از تکنیک های سنجش از دور، فصلنامه علمی جغرافیا، (۷۰) ۱۹، ۱۷۲-۱۵۳. <http://dor.net/dor/20.1001.1.27172996.1400.19.70.9.9>
- ۳۸) نجفی، احمد؛ عزیزی، سارا و مختاری، محمدحسین (۱۳۹۶). کاربرد ماشین بردار پشتیبانی در طبقه بندی کاربری اراضی حوزه چشمه کیله چالکرو، پژوهشنامه مدیریت حوزه آبخیز، (۱۵) ۸، ۱۰۱-۹۲. <https://doi.org/10.29252/jwmmr.8.15.92>
- ۳۹) یوسفی، حسین؛ ترابی، حسن؛ حقی زاده، علی؛ صمدی، آرمان؛ ارشیا، آزاده و یاراحمدی، یزدان. (۱۴۰۰). پایش تغییرات دریاچه زریوار کردستان با استفاده از شاخص های طیفی تفاضل نرمال و تصاویر لندست، نشریه هیدروژئولوژی، (۲) ۶، ۴۱-۳۰. <https://doi.org/10.22034/HYDRO.2022.12845>
- ۴۰) یوسفی روشن، محمدرضا (۱۴۰۱). برآورد پهنه آبی دریاچه ارومیه با استفاده از تصاویر ماهواره ای لندست ۸ با استفاده از شاخص MNDWI، فصلنامه علمی جغرافیا، (۷۴) ۲۰، ۱۸۶-۱۶۵. <http://dor.net/Dor/20.1001.1.27833739.1401.20.74.9.9>
- 41) Abbas, Z. & Jaber, H.S. (2020). Accuracy assessment of supervised classification methods for extraction land use maps using remote sensing and GIS techniques. IOP Conf. Series: Mater. Sci. Eng, 745(1), 121-126. <https://doi.org/10.1088/1757-899X/745/1/012166>
- 42) Abdoli, M. & Haghghi, M. (2021). Comparison of support vector machine and artificial neural network classification methods to produce landuse maps (Case study: Bojagh National Park), Journal of Environmental Research and Technology, 8(5), 47-60. [persian].
- 43) Abedi, M., Norouzi, G. & Bahroudi, A. (2012). Support Vector machine for multi classification of mineral prospectivity areas, computers and Geosciences, 46(2), 272-283. <http://doi.org/10.1016/j.cageo.2011.12.014>
- 44) Afifi, M. (2021). Investigation of the Effect of Drought on Vegetation Using Remote Sensing Techniques, Case Study of Dorodzan Dam Catchment, Journal of Geography, 19(70), 153-172. [persian].
- 45) Al-Abudi, B. Q. & Kouder, N. Z. (2016). Change Detection Study for Al Razaza Lake and The Surrounding Area, GIS & Geospatial Technologies Conference, Special Issue, December 2016, 180-191. <http://doi.org/10.1016/j.ejrs.2022.01.013>
- 46) Al-Azzawi, T.M.F. (2019). Integration approach of remote sensing and GIS to detect land use/land cover change dynamics in himreen lake and surrounding area. Al- Adab J, 130(3), 111-130. <http://doi.org/10.31973/aj.v1i130.646>
- 47) Blaschke, T. (2010). Object based image analysis for remote sensing. ISPRS J. Photogramm. Remote Sens, 65(1), 2-16. <http://doi.org/10.1016/j.isprsjprs.2009.06.004>
- 48) Boser, B., Guyon, I. & Vapnik, V. (1992). A training algorithm fotoptimal margin classifier, in: Proceedings of the Fifth Annual ACM Conference on Computational Learning Theory, Pittsburgh, 8(2), 144-152. <http://doi.org/10.1145/130385.130401>
- 49) Campvalls, G., Mooij, J. & Scholkopf, B. (2010). Remote sensing feature selection by Kernel dependence measures. IEEE Geoscience and remote sensing Letters, 7(4), 587- 591. <http://doi.org/10.1109/LGRS.2010.2041896>

- 50) Chen, J., Chen, J., Liao, A., Cao, X., Chen, L., Chen, X., He, C., Han, G., Peng, S., Lu, M., Zhang, W., Tong, X. & Mills, J. (2015). Global land cover mapping at 30 m resolution: a POK-based operational approach. *ISPRS J. Photogramm. Remote Sens*, 103(2), 7–27. <http://doi.org/10.1016/j.isprsjprs.2014.09.002>
- 51) Cristianini, N. & Shawe-Taylor, J. (2000). *An Introduction to Support Vector Machines and Other Kernelbased Learning Methods*, Cambridge University Press, 2000.
- Dellepiane, S., De Laurentiis, R. & Giordano, F. (2004). Coastline extraction from SAR images and a method for the evaluation of the coastline precision. *Pattern Recogn. Lett*, 25(13), 1461–1470. <https://doi.org/10.1017/CBO9780511801389>
- 52) Ding, J., Cuo, L., Zhang, Y. & Zhu, F. (2018). Monthly and annual temperature extremes and their changes on the Tibetan Plateau and its surroundings during 1963– 2015. *Sci. Rep.*, 24(5), 1–23. <https://doi.org/10.1038/s41598-018-30320-0>
- 53) El-Asmar, H.M., Hereher, M.E. & El Kafrawy, S.B. (2013). Surface area change detection of the Burullus Lagoon, North of the Nile Delta, Egypt, using water indices: a remote sensing approach. *Egypt. J. Remote Sensing Space Sci*, 16(1), 119–123. <http://doi.org/10.1016/j.ejrs.2013.04.004>
- 54) Elshahabi, M., Negmb, A. & Ali, K. (2016). Performances evaluation of water body extraction techniques using Landsat ETM+ data: case-study of Lake Nubia, Sudan. *Egypt. J. Eng. Sci. Technol.*, 19 (EIJEST, 19(2), 275–281. <https://doi.org/10.21608/EIJEST.2016.97140>
- 55) Foody, G. & Mathur, A. (2006). The use of small training sets containing mixed pixels for accurate hard image classification: training on mixed spectral responses for classification by a SVM, *Remote Sens. Environ*, 103(4), 179–189. <https://doi.org/10.1080/01431160600962566>
- 56) Foody, G., Boyd, D. & Sanchez-Hernandez, C. (2007). Mapping a specific class with an ensemble of classifiers, *Int. J. Remote Sens*, 28(2), 1733–1746. <http://doi.org/10.1016/j.rse.2006.04.001>
- 57) Geo, Y., De Jong, K., Liu, F. & Wang, X., Li, C. (2012). A comparison of Artificial neural networks and support vector machines on landcover classification, Springer verlag Berlin Heidelberg, ISICA, CCIS, 316(6), 531- 539. <http://doi.org/10.1080/01431161.2011.568531>
- 58) Granian, H., Tabatabaei, S., Asadi, H. & Carranza, E. (2016). Application of Discriminant Analysis support vector machine Gold Potential areas for further Drilling in the Sari Gunay Gold Deposit, NW Iran, *natural Resource Research*, 25(2), 145-159. <http://doi.org/10.1007/11053-015-9271-2>
- 59) Hejazizadeh, Z., Pajoo, F. & Shakiba, H. (2021). Analyzing the accuracy of drought indicators and determining the best climatic indicators in southeastern Iran, *Journal of Geography*, 19(68), 5-21. [persian].
- 60) Huange, C., Davis, L.S. & Townshend, J. (2002). An assessment of support vector machines for land cover classification. *International Journal of Remote sensing*, 23(4), 725- 749.
- 61) Jahanbakhshi, F. & Ekhtesasi, M. (2019). Performance Evaluation of Three Image Classification Methods (Random Forest, Support Vector Machine and the Maximum Likelihood) in Land Use Mapping, *Journal of Water and Soil Science*, 22(4), 235-247. [persian].
- 62) Jensen, J.R. (2005). *Introductory Digital image processing a Remote sensing Perspective*, 3rd Edition, Upper saddle River, Prentice Hall. 526. <http://doi.org/10.1080/10106048709354084>
- 63) Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G. & Johnson, B.A. (2019). Deep learning in remote sensing applications: a meta-analysis and review. *ISPRS J. Photogramm. Remote Sens*, 152(7), 166–177. <https://doi.org/10.1016/j.isprsjprs.2019.04.015>
- 64) Mountrakis, G., Im, J. & Ogole, C. (2011). Support vector machine in remote sensing a review. *ISPRS Journal of photogrammetry and remote sensing*, 13(2), 247- 259. <https://doi.org/10.1016/j.isprsjprs.2010.11.001>
- 65) Muhsin, I.J., Kaittan, M.Q. & Ali, H.I. (1985). Monitoring of the changes in water rate for Al-razaza lake using remote sensing techniques. *Methods*, 24(4), 120-134. <http://doi.org/10.1016/j.ejrs.2022.01.013>
- 66) Najafi, A., Azizi, S. & Mokhtari, M. (2017). Assessment Kernel Support Vector Machines in Classification of Landuses (Case Study: Basin of Cheshmeh kileh-Chalkrod), *Journal of Watershed Management Research*, 8(15), 92-101. [persian]
- 67) Rasuly, A., Naghdifar, R. & Rasoli, M. (2010). Monitoring of Caspian Sea coastline changes using object-oriented techniques. *Procedia Environ. Sci*, 2(5), 416–426. <http://doi.org/10.1016/j.proenv.2010.10.046>
- 68) Shanani Hoveyze, M. & Zarei, H. (2016). Comparison of Three Classification Algorithms (ANN, SVM and Maximum Likelihood) for Preparing Land Use Map (Case Study: Abolabbas Basin), *Journal of Watershed Management Science*, 10(33), 73-84. [persian].

- 69) Shen, L. & Li, C. (2010). Water body extraction from Landsat ETM+ imagery using adaboost algorithm. In: 18th International Conference on Geoinformatics. IEEE, 1-4. <https://doi.org/10.1109/GEOINFORMATICS.2010.5567762>
- 70) Yousefi, H., Torabi Poteh, H., Haghizadeh, A., Samadi, A., Arshiya, A. & Yarahmadi, Y. (2022). Monitoring the Changes of Zaribar Lake in Kurdistan Using Spectral Indicators and Landsat Images in Google Earth Engine System, Hydrogeology, 6(2), 30-41. [persian]
- 71) Yousefiroshan, M. (2022). Estimation of lake Urmia water area using Landsat 8 satellite imagery using MNDWI Index, Journal of Geography, 20(74), 165-186. [persian].
- 72) Zhang, X., Pan, D., Chen, J., Zhao, J., Zhu, Q. & Huang, H. (2014). Evaluation of coastline changes under human intervention using multi-temporal high-resolution images: a case study of the Zhoushan Islands, China. Remote Sensing, 6(10), 9930-9950. <http://doi.org/10.3390/rs6109930>

