



Journal of Environmental Studies

Vol. 46, No. 4, Winter 2021

Journal Homepage: www.Jes.ut.ac.ir
Print ISSN: 1025-8620 Online ISSN 2345-6922

Generation of Karun River Water Salinity Map from Landsat- 8 Satellite Images Using Support Vector Regression, Multilayer Perceptron and Genetic Algorithm

Document Type
Research Paper

Received
October 11, 2020

Accepted
January 6, 2021

Mohsen Ansari , Mehdi Akhoondzadeh*

School of Surveying and Geospatial Engineering, College of Engineering,
University of Tehran, Tehran, Iran

DOI: [10.22059/JES.2021.317955.1008130](https://doi.org/10.22059/JES.2021.317955.1008130)

Abstract

Salinity intrusion is a complex issue in coastal and hot and dry areas. Currently, remote sensing techniques have been widely used to monitor water salinity changes, ranging from inland river networks to deep oceans. The Karun River basin, with a basin area of 67,000 km², is located in the southern part of Iran. The salinity of Karun River has been increasing due to some critical factors, e.g. severe climate condition and regional physiography, industrial sources, domestic and urban sewerage, irrigation of agricultural land, fish hatchery, hospital sewage, and high tide level of Persian Gulf. This study aimed at building Support Vector Regression (SVR) and Multilayer Perceptron (MLP) models to realize the salinity intrusion through the relationship between reflectance from the Landsat-8 Operational Land Imager images and salinity levels measured in situ. A total of 102 observed samples were divided into 75% training and 25% test. Besides, the Genetic Algorithm (GA) was applied to determine the best performer bands combination. Furthermore, we employ GA to optimize SVR parameters and number of layers and neurons of MLP neural network in order to maximize model accuracy. The result showed that the MLP approach was the better model to estimate water salinity along the Karun River network in the study area, which coefficient of determination (R^2) and RMSE of test data is obtained as 0.73 and 390 μ scm⁻¹.

Keywords: Water salinity, Genetic Algorithm (GA), Landsat-8 satellite image, Support Vector Regression (SVR), Multilayer Perceptron (MLP), Karun River

* Corresponding author

Email: makhonz@ut.ac.ir

Extended abstract

Introduction

The Karun River is the biggest river basin in Iran, which supplies water demands of about 16 cities, several villages, thousands of hectares of agricultural. This river polluted because of domestic and urban sewerage, industrial sources, and irrigation of agricultural land, Hospital sewage and high tide level of Persian Gulf.

Therefore, because of the importance of this river, the water salinity of this river is determined in this study. The traditional methods of determining water salinity are costly in comparison with remote sensing methods.

In the present study, Landsat 8 (OLI) data was used to calculate the water salinity map for Karun River since not only it is free, but it also has an acceptable resolution.

Materials and Methods

Landsat 8 (OLI) images were used to calculate reflectance for a pixel and were attained from (US Geological Survey (USGS) 2019). First, radiometric correction was applied to normalize satellite images. This process convert Digital Number into radiance. Second, in order to attain the surface reflectance values, the process of atmospheric correction was applied using the Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes (FLAASH).

Water salinity was calculate by Iran Water and Power Recourses Development Company. Eight stations are located in the crucial point for EC measuring ALIKALE, GOTVAND, SHOOSHTAR, SHOTEYT, GARGAR, DEZ, AHVAZ, and ABADAN.

Iran Water and Power Recourses Development Company obtained 102 observed EC samples from June 2013 to July 2018 along the Karun River.

The Support Vector Machine was classically used for classification, Support Vector Classification, but extended for using along with regression issue, namely Support Vector Regression.

The results related to the quality of the SVR depend on some factors: the loss function \mathcal{E} , the error penalty factor C and the kernel function parameters.

Usually, radial basis kernel function (RBF), $k(x, x') = k(x, x') = \exp(-||x - x' / \sigma^2)$, has been used in remote sensing studies, so, it is implemented in this study. Finally, the Genetic Algorithm (GA) is employed to optimize some parameters including C , \mathcal{E} and σ .

GA is an optimization technique create by Holland (1975) and discussed the mechanism of GA in solving nonlinear optimization problems.

Besides, the Genetic Algorithm (GA) was applied to determine the best performer bands combination. Furthermore, we employ GA to optimize SVR parameters and number of layers and neurons of MLP neural network in order to maximize model accuracy.

Results and Discussion

Salinity intrusion is a complex issue in coastal, hot, and dry areas. Currently, remote sensing techniques have

been widely used to monitor water salinity changes, ranging from inland river networks to deep oceans. The Karun River basin, with a basin area of $67,000 \text{ km}^2$, is located in the southern part of Iran. The salinity of Karun River has been increasing due to some critical factors, e.g. severe climate condition and regional physiography, industrial sources, domestic and urban sewerage, irrigation of agricultural land, fish hatchery, hospital sewage, and high tide level of Persian Gulf .

This study aimed at building Support Vector Regression (SVR) and Multilayer Perceptron (MLP) models to realize the salinity intrusion through the relationship between reflectance from the Landsat-8 Operational Land Imager images and salinity levels measured *in situ*. 102 observed samples were divided into 75% training and 25% test.

Besides, the Genetic Algorithm (GA) was applied to determine the best performer bands combination. Furthermore, we employ GA to optimize SVR parameters and number of layers and neurons of MLP neural network in order to maximize model accuracy.

The result showed that the MLP approach was the better model to estimate water salinity along the Karun River network in the study area, which coefficient of determination (R^2) and RMSE of test data is obtained as 0.73 and $390\mu\text{s cm}^{-1}$.

GA analysis proved that bands 1, 2 and 3 are the best for modeling water salinity. In this study, the GA is used to determine the SVR meta-parameters including the loss function \mathcal{E} , the error penalty factor C and σ parameters, which are obtained to be 1×10^{-9} , 1099 and 0.96, respectively, and number of layers and neurons of MLP neural network, which are obtained to be 5 and 35, respectively.

The result showed that the MLP approach was the better model to estimate water salinity along the Karun River network in the study area, which coefficient of determination (R^2) and RMSE of test data is obtained as 0.73 and $390\mu\text{s cm}^{-1}$.

Conclusion

The present study calculated the relationship between reflectance retrieved from Landsat-8 OLI and water salinity in the Karun River. SVR and MLP models had acceptable operation by considering the large size, geographic complexity of the study domain and the wide range of field data that change between 385 and $4310\mu\text{s cm}^{-1}$. Augmentation field data is the critical priority work for future study to probe the relationship between water salinity and satellite images. In addition, the contribution of thermal bands can help to increase accuracy of models.

تهیه نقشه شوری رود کارون از تصاویر ماهواره ای لندست-۸ با استفاده از رگرسیون بردار پشتیبان، شبکه عصبی پرسپترون چندلایه و الگوریتم ژنتیک

محسن انصاری، مهدی آخوندزاده هنزایی*

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

۱۳۹۹/۱۰/۱۷ تاریخ پذیرش مقاله

۱۳۹۹/۷/۲۰ تاریخ وصول مقاله

چکیده

شوری آب یک مؤلفه‌ی فیزیکی کلیدی است که در کیفیت آب، رشد و بهبود زندگی گیاهان و حیوانات آبی تأثیر می‌گذارد. شوری آب رود کارون به دلیل شرایط اقلیمی در حال افزایش است. در این مطالعه تلاش شده است تا با برقراری ارتباط میان باندهای سنجنده لندست-۸ و داده‌های میدانی تهیه‌شده از شوری آب رود کارون، مدلی برای شوری آب ارائه گردد. برای این منظور ۱۰۲ داده‌ی میدانی که شامل مقادیر هدایت الکتریکی هستند از تاریخ ژوئن ۲۰۱۳ تا جولای ۲۰۱۸ از رود کارون برداشت شده است؛ و از ۳۶ تصویر ماهواره‌ای سنجنده لندست-۸ بدون ابر برای استخراج انعکاس سطح استفاده شده است. لازم به ذکر است که تفاوت زمانی بین داده‌های میدانی و تصاویر ماهواره‌ای حداکثر دو روز است. در نهایت ۱۰۲ داده‌ی میدانی و انعکاس سطح هفت باند غیرحرارتی سنجنده لندست ۸ به نسبت ۷۵ به ۲۵ برای آموزش الگوریتم‌ها و ارزیابی آن‌ها تقسیم شده‌اند. در این مطالعه از الگوریتم ژنتیک استفاده شده است تا علاوه بر پیدا کردن مناسب‌ترین باندهای سنجنده لندست-۸، پارامترهای الگوریتم بردار پشتیبان و تعداد لایه‌ها و نورون‌های شبکه عصبی پرسپترون چندلایه را نیز تخمین بزنند. در این مطالعه باندهای ۱، ۲ و ۳ سنجنده لندست-۸ به‌عنوان حساس‌ترین باندها به شوری انتخاب شده است و سپس با بهینه کردن پارامترهای الگوریتم بردار پشتیبان و تعداد لایه‌ها و نورون‌های شبکه عصبی چندلایه توسط الگوریتم ژنتیک به ترتیب ضریب تعیین ۰/۷ و ۰/۷۳ حاصل گردیده است.

کلیدواژه

شوری آب رود کارون، تصاویر ماهواره‌ای لندست-۸، رگرسیون بردار پشتیبان (SVR)، شبکه عصبی پرسپترون چندلایه (MLP)، الگوریتم ژنتیک (GA)

سرآغاز

کشور، در این مطالعه سعی شده است تا مدلی مناسب برای تهیه نقشه شوری این رودخانه به‌منظور کمک به حل مشکل شوری و مدیریت این بحران ارائه گردد. علاوه بر آن، مطالعه‌ای در زمینه برآورد شوری رود کارون توسط علم نوین سنجش‌ازدور و به کمک تصاویر ماهواره‌ای صورت نگرفته است. روش‌های سنتی برای تخمین شوری آب از نظر مالی و زمانی در مقایسه با روش‌های سنجش‌ازدوری بسیار هزینه‌بر هستند.

پیدا کردن باندهای حساس به شوری آب به‌اندازه‌ی پیدا

رود کارون بزرگ‌ترین رود ایران است که آب موردنیاز برای ۱۶ شهر و هزاران هکتار زمین کشاورزی و تعداد زیادی تأسیسات صنعتی را در مسیر خود فراهم می‌کند و در نهایت به خلیج فارس می‌ریزد (Naddafi et al., 2007). این رودخانه به دلیل شرایط اقلیمی، تأسیسات صنعتی، فاضلاب‌های شهری، آبیاری زمین‌های کشاورزی، فاضلاب‌های بیمارستان‌های موجود در بستر رودخانه و جزر و مد شدید خلیج فارس شور شده است (Karamouz et al., 2004). بنابراین، به دلیل اهمیت این رودخانه در

Email: makhonz@ut.ac.ir

DOI: [10.22059/JES.2021.317955.1008130](https://doi.org/10.22059/JES.2021.317955.1008130)

DOR: [20.1001.1.10258620.1399.46.4.1.6](https://doi.org/20.1001.1.10258620.1399.46.4.1.6)

* نویسنده مسئول:

تعیین ۰/۴۹ و به خطای جذر میانگین مربعات ۵ (RMSE) ppt ۳/۵۳ رسیده‌اند (Xie et al., 2013). مدل بهینه‌ساز وزن‌دار مخصوص^۶ نیز برای تخمین شوری آب استفاده شده است و به ضریب تعیین ۰/۹۲ و به خطای جذر میانگین مربعات ۱/۸ ppt رسیده است (Khadim et al., 2017). همچنین مدل‌های رگرسیونی چندخطی، درخت تصمیم و جنگل تصادفی نیز در یک مطالعه پیاده شده است و به ضریب تعیین‌های بین ۰/۱۳ تا ۰/۲۲ و به خطای جذر میانگین مربعات بین ppt ۲/۱۳ تا ppt ۴/۱۷ رسیده است (Nguyen et al., 2018).

هدف از انجام این مطالعه آن است تا با استفاده از الگوریتم ژنتیک (GA)^۷ توأم با باندهای انعکاسی مناسب لندست-۸ و پارامترهای بهینه ماشین بردار پشتیبان^۸ (SVR) و همچنین تعداد بهینه لایه‌ها و نورون‌های شبکه عصبی پرسپترون چندلایه^۹ (MLP) برای به دست آوردن نقشه شوری آب تخمین زده شوند.

در این مطالعه از تصاویر سنجنده لندست-۸ استفاده شده است زیرا نه تنها رایگان هستند بلکه از توان تفکیک مکانی و زمانی لازم برای پیاده‌سازی روش‌ها نیز برخوردار هستند. برای انجام مدل‌سازی از ۱۰۲ داده میدانی جمع آوری شده توسط هشت ایستگاه بر روی رود کارون از ماه ژوئن ۲۰۱۳ تا جولای ۲۰۱۸ استفاده شده است. در نهایت از الگوریتم‌های ژنتیک، ماشین بردار پشتیبان و شبکه عصبی پرسپترون چندلایه برای تهیه نقشه شوری آب استفاده شده است.

مواد و روش بررسی

منطقه مورد مطالعه

رود کارون بزرگ‌ترین رود ایران با مساحتی تقریباً برابر ۶۷۵۰۰ کیلومترمربع در جنوب غربی ایران بین طول جغرافیایی ۴۸°۱۵' و ۵۲°۱۵' شرقی و عرض جغرافیایی ۳۰°۱۷' و ۳۳°۴۹' شمالی قرار دارد. این رودخانه از جنوب اصفهان و از رشته‌کوه‌های زاگرس سرچشمه می‌گیرد

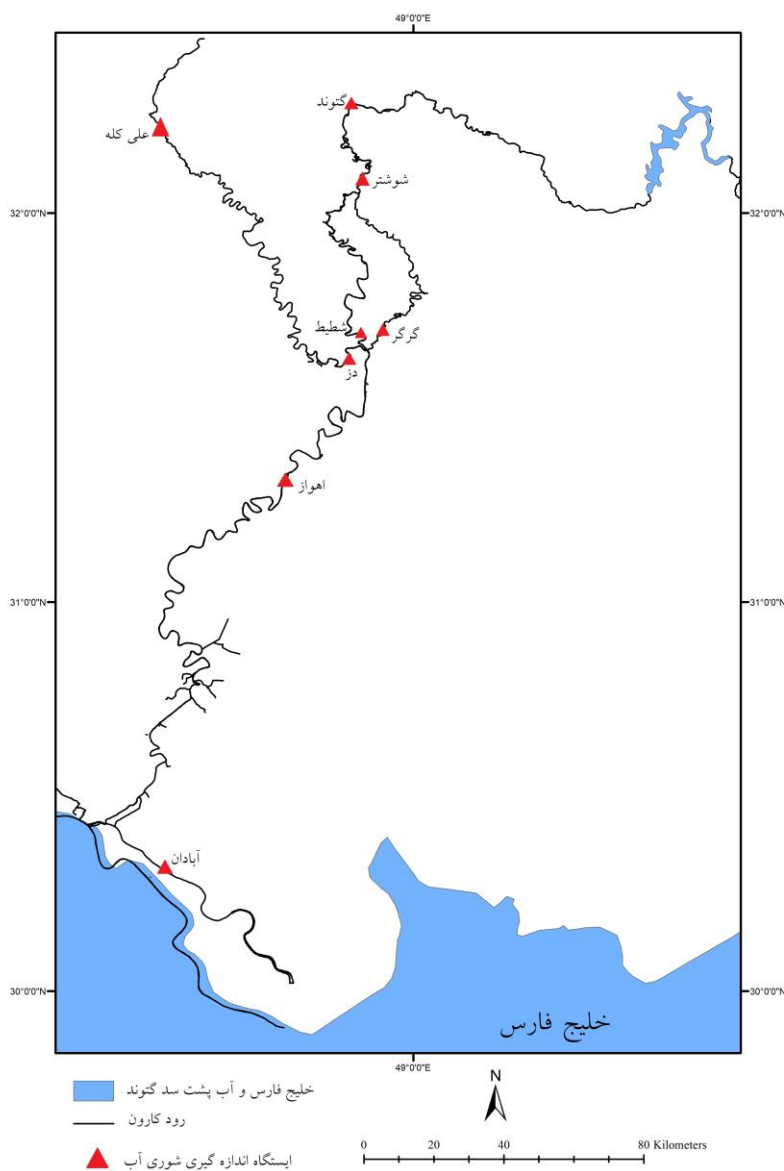
کردن یک روش مدل‌سازی بهینه مهم است (Nguyen et al., 2018). علاوه بر آن، استفاده از متغیرهای زیاد در مدل‌سازی باعث می‌شود که مدل سریع به داده‌های آموزشی برازش داده شود ولی در پیاده‌سازی مدل به‌دقت مطلوبی نرسد (Messner et al., 2017). بنابراین پیدا کردن بهترین ترکیب باندها برای مدل‌سازی نقش مهمی را ایفا می‌کند.

در مطالعات قبلی از سنجنده‌های لندست-۵۱، مادیس^۱ (MODIS) و لندست-۸۳ برای مدل‌سازی شوری آب استفاده شده است. در مطالعات قبلی برای مدل‌سازی شوری آب از ترکیب باندهای متفاوتی از لندست-۵ استفاده شده است برای مثال، باندهای ۵ و ۶ (Khorram, 1985)، باندهای ۴ و ۷ (Lavery et al., 1993)، باندهای ۱، ۴ و ۷ (Vuille & Baumgartner, 1993)، باندهای ۱، ۳ و ۴ (Zhang et al., 2012)، باندهای ۱، ۲، ۳، ۴، ۵ و ۷ (Xie et al., 2013) و باندهای ۱، ۳ و ۴ (Nazeer & Bilal, 2018). Urquhart و همکاران (۲۰۱۲) گزارش دادند که انعکاس‌های سنجنده مادیس در طول موج‌های ۴۸۸، ۴۴۳ و ۶۶۷ نانومتر با شوری آب ارتباط دارند. علاوه بر آن Zhao و همکاران (۲۰۱۷) گزارش دادند که باندهای ۱، ۲، ۳ و ۴ سنجنده لندست-۸ با شوری در ارتباط هستند. Ansari و Akhoondzadeh (۲۰۱۹ و ۲۰۲۰) گزارش دادند که باندهای ۱ و ۲ و ۳ سنجنده لندست-۸ با شوری در ارتباط هستند. در ارتباط با سنجنده لندست-۸ مطالعات دیگری توسط Nguyen و همکاران (۲۰۱۸) صورت گرفته است که بیان می‌کند ترکیب باندهای ۲، ۳، ۴ و ۷ سنجنده لندست-۸، بهترین ترکیب برای تخمین شوری آب است.

انتخاب مدل مناسب می‌تواند به اندازه‌ی انتخاب مؤلفه‌ها و متغیرهای مناسب در دقت تخمین یک مؤلفه تأثیر گزار باشد (Fassnacht et al., 2014). اخیراً تعدادی از نویسندگان مدل‌هایی را برای تخمین شوری آب پیشنهاد کرده‌اند، به‌عنوان مثال: روش رگرسیون وزن‌دار جغرافیایی که برای شوری آب پیاده‌سازی شده است و به ضریب

سرچشمه می‌گیرد ترکیب می‌شوند و تشکیل رود کارون بزرگ را می‌دهند. شکل ۱ موقعیت منطقه مورد مطالعه را نشان می‌دهد. منطقه خوزستان از تعداد قابل توجهی تأسیسات صنعتی و مناطق کشاورزی تشکیل شده است که پساب‌های خود را داخل رود کارون می‌ریزند؛ علاوه بر آن افزایش تقاضا برای آب بیشتر به دلیل افزایش جمعیت، شبکه‌های کشاورزی، حوضچه‌های پرورش ماهی و انتقال پساب‌ها به داخل بستر رود کارون بر کیفیت این رودخانه تأثیر می‌گذارد (Naddafi et al., 2007).

(Karamouz et al., 2004). بالادست این رودخانه بزرگ‌ترین سد ایران به نام گتوند قرار دارد؛ که در سال ۲۰۰۳ احداث شده است و در موقعیتی با طول و عرض جغرافیایی به ترتیب $32^{\circ}15'$ و $48^{\circ}49'$ و ارتفاع ۱۰۰ متر قرار دارد؛ ارتفاع ۱۸۰ متری سد این امکان را فراهم می‌آورد تا حجم آبی برابر با ۲۸۰۳ میلیون مکعب پشت سد انباشته شود (Yousefi et al., 2016). رود کارون بعد از گذر از سد گتوند به دو زیرشاخه گرگر و شطیط تقسیم می‌شود و در نهایت در بند قیر با رود دز که از دزفول



شکل ۱. تصویر منطقه مورد مطالعه و موقعیت برداشت داده‌های میدانی

تصاویر ماهواره‌ای

به آب است؛ در این مطالعه از این ویژگی شاخص گیاهی برای استخراج رود کارون از تصاویر ماهواره‌ای لندست-۸ استفاده شده است.

داده‌های واقعیت زمینی

شکل ۱ ایستگاه‌های برداشت داده‌های میدانی در طول رود کارون که شامل هدایت الکتریکی^{۱۴} (EC) می‌باشند را نشان می‌دهد. ۱۰۲ داده میدانی توسط شرکت توسعه منابع آب و نیروی ایران در بازه زمانی ژوئن ۲۰۱۳ و جولای ۲۰۱۸ در ایستگاه‌های علی کله، گتوند، شوشتر، شطیپ، گرگر، دز، اهواز و آبادان برداشت شده است. بیشترین کمترین و میانگین مقادیر هدایت الکتریکی در بازه زمانی ژوئن ۲۰۱۳ و جولای ۲۰۱۸ برای هر ایستگاه در جدول ۱ آورده شده است. در این مطالعه بیشترین اختلاف زمانی بین داده‌های میدانی و تصاویر لندست-۸ استفاده شده، دو روز است؛ که در جدول ۲ تاریخ اخذ داده‌های میدانی و تصاویر لندست ۸ آورده شده است. لازم به ذکر است که با توجه به عدم دسترسی به داده‌هایی با اختلاف زمانی کمتر، این اختلاف زمانی قابل قبول به نظر می‌رسد و در سایر مطالعات مانند Nguyen و همکاران (۲۰۱۸)، این اختلاف زمانی مشاهده می‌گردد.

روش‌های پیشنهادی

سنجده ی لندست-۸ از ۱۱ باند تشکیل شده است که در این مطالعه فقط از هفت باند غیرحرارتی آن استفاده شده است که عبارت‌اند از: باند ۱- (۰/۴۵۳- ۰/۴۳۳ نانومتر)، باند ۲- (۰/۵۱۵- ۰/۴۵ نانومتر)، باند ۳- (۰/۶- ۰/۵۲۵ نانومتر)، باند ۴- (۰/۶۸- ۰/۶۳ نانومتر)، باند ۵- (۰/۸۸۵- ۰/۸۴۵ نانومتر)، باند ۶- (۱/۴۶- ۱/۵۶ نانومتر) و باند ۷- (۲/۳۵- ۲/۰۸ نانومتر)؛ بنابراین، بسیار مهم است تا مشخص گردد که کدام ترکیب از باندها بیشترین حساسیت را نسبت به شوری آب دارند. برای حل این مسئله در مطالعه‌ی اخیر از الگوریتم ژنتیک استفاده شده است.

در این مطالعه از تصاویر ماهواره لندست-۸ برای تخمین شوری آب رود کارون استفاده شده است. تصاویر لندست-۸ سطح ۱ زمین مرجع شده در سیستم مختصات UTM با توان تفکیک مکانی ۳۰ متر در سایت زمین‌شناسی آمریکا^{۱۰} در دسترس می‌باشند. تصاویر استفاده شده در مسیر/ ردیف‌های به ترتیب ۳۸/۱۶۶ و ۳۹/۱۶۵ و ۳۸/۱۶۵ قرار دارند؛ که ۳۶ تصویر بدون ابر از ژوئن ۲۰۱۳ تا جولای ۲۰۱۸ تهیه شده است (جدول ۲). ابتدا برای حذف خطاهای اتمسفری که توسط مولکول‌ها و ذرات معلق در فضا هنگام تصویربرداری ایجاد می‌شود از تصحیحات رادیومتریکی استفاده می‌شود و مقادیر اعداد رقومی (DN)^{۱۱} به تابش تبدیل می‌شوند (Nguyen et al., 2018). در مرحله‌ی بعد برای رسیدن به بازتاب‌های سطح زمین از تصحیحات اتمسفری استفاده می‌شود که در این مطالعه از مدل تصحیح اتمسفری فلش^{۱۲} (FLAASH) استفاده شده است. در این مدل از داده‌هایی مثل زمان عبور ماهواره، ارتفاع سنجنده، موقعیت جغرافیایی، مدل اتمسفری منطقه و زاویه تابش خورشید برای تصحیح خطاهای اتمسفری استفاده می‌شود (Abdelmalik, 2018). با توجه به اینکه استخراج رودخانه از تصاویر ماهواره‌ای یکی از اهداف سنجش‌ازدور است، روش‌های متفاوتی برای محقق کردن این مهم ارائه گردیده است (Shareef et al., 2014). شاخص پوشش گیاهی^{۱۳} (NDVI) یک شاخص آماری است که از باندهای قرمز و مادون‌قرمز نزدیک در طیف الکترومغناطیس استفاده می‌کند که از رابطه‌ی ۱ به دست می‌آید (Chen et al., 2006):

$$NDVI = \frac{(P_{nir} - P_{red})}{(P_{nir} + P_{red})} \quad \text{رابطه (۱)}$$

که P_{nir} و P_{red} به ترتیب مقادیر انعکاس از سطح برای باندهای قرمز و مادون قرمز نزدیک می‌باشند. مقادیر NDVI بین -۱ و ۱ می‌باشند که مقادیر بین ۰ و ۱- مربوط

جدول ۱. بیشترین، کمترین و میانگین مقادیر هدایت الکتریکی که در بازه زمانی ژوئن ۲۰۱۳ و جولای ۲۰۱۸ تهیه شده‌اند. مقادیر هدایت الکتریکی بین مقادیر ۳۸۵ و ۴۶۷۰ تغییر می‌کنند. تقریباً، میانگین مقادیر هدایت الکتریکی از بالادست رودخانه به سمت پایین دست آن در حال افزایش است.

ایستگاه‌های برداشت EC	میانگین EC μscm^{-1}	کمترین مقدار-EC μscm^{-1}	بیشترین مقدار EC μscm^{-1}
علی کله	۴۷۰	۳۸۵	۵۹۵
گتوند	۱۱۱۵	۷۷۰	۱۶۷۰
شوشتر	۱۲۶۹	۸۷۰	۱۸۳۵
شطیط	۱۶۵۶	۱۲۸۰	۲۰۴۵
گرگر	۳۳۴۹	۲۳۷۰	۴۶۷۰
دز	۲۵۵۴	۹۹۵	۳۵۱۰
اهواز	۲۲۶۵	۱۵۸۰	۲۸۸۰
آبادان	۳۶۸۰	۲۱۳۵	۴۳۱۰

الگوریتم ژنتیک یکی از الگوریتم‌های تکاملی است که یک روش جستجوی کلی هست. این الگوریتم بر روی یکسری از جواب‌های مسئله برای نزدیک شدن به بهترین جواب، قانون بقای بهترین را اعمال می‌کند.

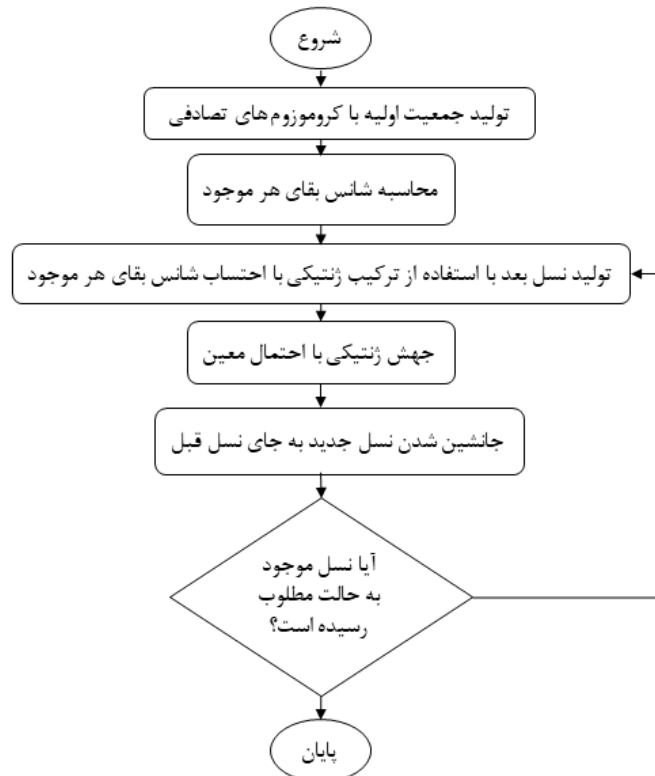
این الگوریتم در هر نسل به کمک یک فرآیند انتخابی متناسب با ارزش جواب‌ها و تولیدمثل^{۱۵} جواب‌های انتخاب شده حاصل از عملگرهای ژنتیکی، تقریب‌های بهتری از جواب‌های نهایی به دست می‌آورد (Sivanandam & Deepa, 2008). الگوریتم ژنتیک از سه جزء اصلی تشکیل شده است که عبارت‌اند از کروموزوم، جمعیت و تابع هدف. در این الگوریتم، هر کروموزوم معرف یک نقطه در فضای جستجو یا به عبارت دیگر یک راه حل ممکن برای مسئله است که از تعدادی ژن ثابت تشکیل شده است (Shan et al., 2008). برای نمایش کروموزوم‌ها از کدگذاری^{۱۶} دودویی یا رشته‌های بیتی استفاده می‌شود. بعد از ایجاد یک جمعیت اولیه از کروموزوم‌ها، جمعیت جدید بر اساس ترکیبی از جمعیت اصلی، جمعیت فرزندان و جمعیت جهش‌یافتگان از روی جمعیت اصلی ایجاد شده‌اند، تولید می‌گردد. برای استفاده از الگوریتم ژنتیک ابتدا باید یک تابع هدف تعریف شود. هدف از استفاده الگوریتم ژنتیک بهینه کردن تابع هدف به صورت بیشینه کردن تابع برازندگی^{۱۷} است (Shan et al., 2008). به‌طور کلی بهینه‌سازی توسط الگوریتم ژنتیک از مراحل زیر تشکیل

جدول ۲. تاریخ اخذ تصاویر ماهواره‌ای و اخذ داده داده‌های میدانی در این جدول آورده شده است تا اختلاف زمانی بین این دو داده نشان داده شود. بیشترین اختلاف زمانی بین این دو تاریخ دو روز می‌باشد. در بعضی از تاریخ‌های ذکر شده برای اخذ تصاویر، چند تصویر با مسیر/ ردیف‌های مختلف تهیه شده است که در نهایت تعداد آن‌ها به ۳۶ تصویر می‌رسد.

تاریخ اخذ تصاویر ماهواره‌ای	تاریخ اخذ داده‌های میدانی
۲۰۱۳/۶/۱۹	۲۰۱۳/۶/۱۹
۲۰۱۳/۶/۲۶	۲۰۱۳/۶/۲۵
۲۰۱۳/۷/۱۲	۲۰۱۳/۷/۱۴
۲۰۱۳/۸/۱۳	۲۰۱۳/۸/۱۳
۲۰۱۳/۸/۲۲	۲۰۱۳/۸/۲۴
۲۰۱۳/۹/۲۳	۲۰۱۳/۹/۲۵
۲۰۱۳/۱۰/۲۵	۲۰۱۳/۱۰/۲۶
۲۰۱۳/۱۲/۲۸	۲۰۱۳/۱۲/۲۹
۲۰۱۴/۳/۲	۲۰۱۴/۳/۱
۲۰۱۴/۴/۳	۲۰۱۴/۴/۵
۲۰۱۴/۴/۲۶	۲۰۱۴/۴/۲۸
۲۰۱۴/۹/۱۰	۲۰۱۴/۹/۸
۲۰۱۴/۱۰/۳	۲۰۱۴/۱۰/۴
۲۰۱۴/۱۲/۱۵	۲۰۱۴/۱۲/۱۴
۲۰۱۵/۲/۱	۲۰۱۵/۲/۱
۲۰۱۵/۷/۱۸	۲۰۱۵/۷/۱۶
۲۰۱۵/۹/۴	۲۰۱۵/۹/۳
۲۰۱۶/۴/۲۴	۲۰۱۶/۴/۲۶
۲۰۱۶/۷/۲۹	۲۰۱۶/۷/۲۸
۲۰۱۶/۱۰/۱	۲۰۱۶/۹/۲۹
۲۰۱۷/۱/۲۱	۲۰۱۷/۱/۲۳
۲۰۱۷/۵/۱۳	۲۰۱۷/۵/۱۴
۲۰۱۷/۱۲/۷	۲۰۱۷/۱۲/۵

اصلی جدید (۵) اگر شرط توقف محقق نشده است، از مرحله ۲ تکرار صورت می‌گیرد (۶) خاتمه. شکل ۲ فلوجارت روش GA را نشان می‌دهد. تابع برازندگی استفاده‌شده در این مطالعه، شبکه عصبی پرسپترون چندلایه و الگوریتم رگرسیونی ماشین بردار پشتیبان است.

شده است (Sivanandam & Deepa, 2008): (۱) انتخاب جمعیت تصادفی و ارزیابی آن‌ها توسط تابع برازندگی (۲) انتخاب والدین و ترکیب آن‌ها برای تولید فرزندان (۳) انتخاب اعضای جمعیت برای اعمال جهش (۳) ترکیب جمعیت اصلی، فرزندان، جهش‌یافتگان برای تولید جمعیت



شکل ۲. فلوجارت الگوریتم ژنتیک

ی لندست-۸) در یک ضریبی در شبکه عصبی مصنوعی ضرب می‌شوند که این ضریب پارامتر وزن^{۱۹} (w) نام دارد و در نهایت با مقادیر بایاس^{۲۰} (b) جمع می‌شوند. در یک شبکه عصبی مصنوعی بعد از معرفی بردار ورودی، شبکه با اندازه‌گیری خروجی و با انتخاب پارامترهای وزن و بایاس به صورتی که خروجی قابل قبول به دست آید، آموزش می‌بیند که فرآیند یادگیری نام دارد (Mary & Yegnanarayana, 2004). شبکه‌های عصبی برای انتقال بین لایه‌های ورودی میانی و میانی خروجی از یک تابع فعال‌سازی^{۲۱} استفاده می‌کنند. در این مطالعه از شبکه عصبی مصنوعی پرسپترون چندلایه و از روش پس انتشار^{۲۲} برای

شبکه عصبی مصنوعی

شبکه عصبی مصنوعی^{۱۸} (ANN) شامل تعدادی واحدهای پردازش به صورت موازی است که به آن‌ها نورون گفته می‌شود. نورون‌ها دانش‌های تجربی به دست آمده را حفظ می‌کنند و برای کاربردهای مختلف از آن‌ها استفاده می‌کنند (Pappu and Gummadi, 2017). شبکه‌های عصبی از گذشته، تجربه و محیط می‌آموزند و رفتار خود را هنگام یادگیری بهبود می‌دهند. خاصیت یادگیری، غیرخطی بودن و تطابق‌پذیری از ویژگی‌های مهم شبکه عصبی مصنوعی است (Da Silva et al., 2017). بردارهای ورودی به شبکه داده‌های زمینی و انعکاس سطح آن‌ها برای ۷ باند سنجنده

$$f(x) = \sum_{i=1}^{n_{sv}} (a_i - a_i^*) k(x_i, x) \quad \text{رابطه (۳)}$$

$$s. t. 0 \leq a_i^* \leq c, 0 \leq a_i \leq c$$

n_{sv} تعداد بردارهای حامی هست و k همان تابع هسته است (رابطه ۴).

$$k(x, x_i) = \sum_{j=1}^{\infty} g_j(x) g_j(x_i) \quad \text{رابطه (۴)}$$

عملکرد مناسب تابع رگرسیون وابسته به انتخاب بهینه‌ی پارامترهای گاما، اپسیلون و هزینه^{۲۴} (C, ϵ, γ) و تابع هسته است. با استفاده از رابطه ۵ مقدار c محاسبه می‌شود (Wang et al., 2016).

$$c = \max(|\bar{y} + 3\sigma_y|, |\bar{y} - 3\sigma_y|) \quad \text{رابطه (۵)}$$

\bar{y} میانگین پاسخ‌های آموزشی و σ_y انحراف استاندارد پاسخ‌های آموزشی می‌باشند.

بنابراین، ماشین بردار پشتیبان داده‌ها را با توجه به دسته‌های از پیش مشخص شده آن‌ها به یک فضای جدید می‌برد و به گونه‌ای که داده‌ها به صورت خطی (ابر صفحه) قابل تفکیک و دسته‌بندی باشند و سپس با پیدا کردن خطوط پشتیبان (صفحات پشتیبان در فضای چندبعدی)، تلاش می‌کند که معادله خطی را پیدا کند که بیشترین فاصله را بین دودسته مطابق شکل ۳ ایجاد کند (Yu & Kim, 2012).


تعیین و تصحیح وزن‌ها و بایاس‌های بین نوروهای مختلف و از تابع تانزانت هایپربولیک سیگموئید به عنوان تابع فعال‌سازی استفاده شده است.

رگرسیون ماشین بردار پشتیبان (SVR)

ماشین بردار پشتیبان^{۲۳} (SVM) یک روش ماشینی یادگیری به منظور طبقه‌بندی، رگرسیون و دیگر کاربردهای آموزشی است. یکی از کاربردهای ماشین بردار پشتیبان، رگرسیون ماشین بردار پشتیبان (SVR) است که به طور کلی از دودسته از داده‌ها استفاده می‌کند؛ از داده‌های آموزشی برای به دست آوردن مدل و استفاده‌ی از مدل برای تخمین داده‌های آزمونه. کیفیت مدل‌های ماشین بردار پشتیبان به تنظیم پارامترهای مدل‌سازی ماشین بردار پشتیبان به شدت وابسته است (Chang and Lin, 2011). در روش SVR هدف تخمین یک تابع نامعلوم بر مبنای تعداد محدودی از داده‌های آموزشی هست. به صورتی که تابع خروجی به صورت مدل آماری رابطه ۲ هست (Chang & Lin, 2011):

$$s. t = \begin{cases} y_i - f(x_i, w) \leq \epsilon + \xi_i \\ f(x_i, w) - y_i \leq \epsilon + \xi_i \\ \epsilon_i, \xi_i \geq 0, i = 1, 2, \dots, n \end{cases} \quad \text{رابطه (۲)}$$

این مسئله‌ی بهینه می‌تواند تبدیل به مسئله دوگانه و انتخاب بردار حامل و تابع هسته شود (رابطه ۳) (Chang & Lin, 2011):



شکل ۳: ابر صفحه‌ی جداکننده خطی در فضای خطی (Yu & Kim, 2012)

بردار پشتیبان (c, ϵ, γ) بهینه شود. هدف از تکرارهای الگوریتم ژنتیک کمینه کردن مقدار تابع برازندگی یا R^2 - است. برای بهینه کردن پارامترهای روش SVR و بهترین ترکیب باندی ابتدا یک مقدار ثابت را به سه پارامتر (c, ϵ, γ) اختصاص داده و سعی می‌شود با استفاده از الگوریتم GA سه باند از باندهای طیفی سنجنده‌ی لندست-۸ طوری انتخاب گردند که بیشترین دقت حاصل شود. پس از آن که بهترین ترکیب باندی حاصل گردید، مقدار ثابت تخصیص داده شده برای سه پارامتر مذکور را به دو پارامتر γ و ϵ دوباره تخصیص داده و سعی می‌شود مقدار c با استفاده از الگوریتم GA بهینه گردد. در مرحله بعد مشابه روش قبل کار برای بهینه کردن پارامتر γ با ثابت نگه داشتن دو پارامتر c و ϵ ادامه می‌یابد. در مرحله آخر، مقادیر بهینه دو پارامتر c و γ به دست آمده است، در نتیجه اقدام به بهینه کردن پارامتر ϵ می‌شود. این مراحل تا جایی ادامه می‌یابد که بهترین عملکرد و دقت حاصل شود. پس از به دست آمدن بهترین ترکیب باندها و بهینه کردن پارامترهای الگوریتم رگرسیون بردار پشتیبان، مدل به دست آمده برای یک تصویر لندست-۸ به تاریخ ۵ سپتامبر ۲۰۱۸ پیاده شده است. شکل ۴ فلوجارت این روش را نشان می‌دهد.

در ادامه تلاش شده است تا با ترکیب الگوریتم ژنتیک و شبکه عصبی پرسپترون چندلایه؛ ابتدا دوباره بهترین ترکیب باندهای سنجنده لندست-۸ تخمین زده شود و سپس با استفاده از الگوریتم ژنتیک تعداد لایه‌های بهینه برای شبکه عصبی پرسپترون چندلایه تخمین زده شود. در ادامه با ثابت در نظر گرفتن تعداد لایه‌ها که در حلقه‌ی الگوریتم ژنتیک قبلی مشخص شده بود؛ مجدداً از یک الگوریتم ژنتیک استفاده شده است تا تعداد نورون‌های هر لایه مشخص شود. با قرار دادن تابع هدف R^2 -ادر الگوریتم ژنتیک، تلاش برای کمینه کردن آن صورت گرفته است. برای بهینه کردن تعداد لایه‌ها و نورون‌های هر لایه در روش MLP و بهترین ترکیب باندی ابتدا یک مقدار ثابت را به تعداد لایه‌ها و نورون‌های هر لایه تخصیص داده

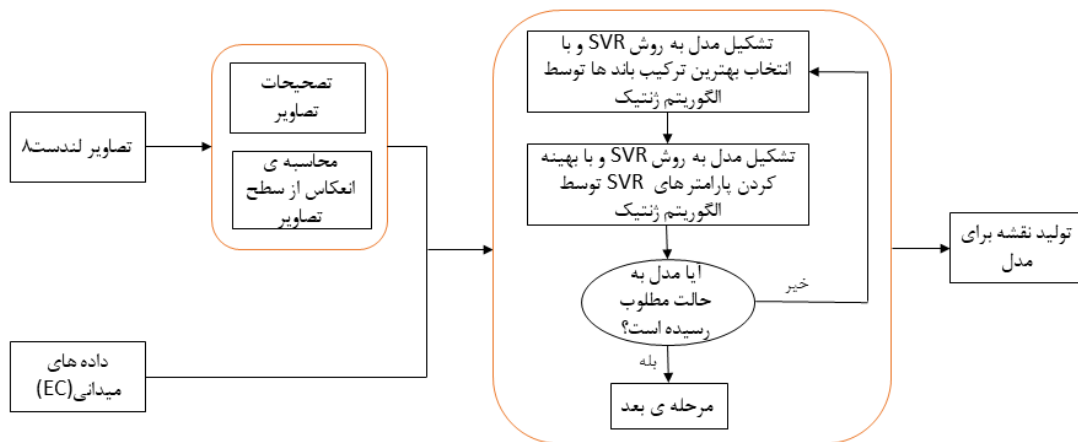
لازم به ذکر است که در این مطالعه از کرنل تابع پایه‌ی شعاعی^{۲۵} (RBF) که بیشترین کاربرد را در بین دیگر توابع کرنل دارد استفاده شده است. دلیل نام‌گذاری این تابع کرنل آن است که ابر صفحه‌های جداساز در آن به صورت شعاعی تعریف می‌شوند و به شکل منحنی‌های بسته به طبقه‌بندی داده‌ها در فضای ویژگی می‌پردازند (Vapnik, 1995). معادله‌ای این تابع کرنل به شکل زیر است (رابطه ۶):

$$k(x, x') = \exp(-\|x - x'\|^2 / \sigma^2) \quad \text{رابطه (۶)}$$

ترکیب الگوریتم ژنتیک با رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی

همان‌طور که گفته شد، الگوریتم ژنتیک به عنوان یک الگوریتم بهینه‌سازی با در نظر گرفتن مجموعه‌ای از نقاط فضای جواب در هر تکرار به نحو کارایی مناطق مختلف فضای جواب را جستجو می‌کند. این الگوریتم با یک گروه از کروموزوم‌ها به نام جمعیت کار خود را شروع می‌کند و سپس با عملگرهای انتخاب، تقاطع^{۲۶} و جهش^{۲۷} جمعیت جدید تولید می‌کند تا به بهترین جواب برسد. لازم به ذکر است که در این مطالعه، پارامترهای الگوریتم ژنتیک استفاده شده از عملگرهای ژنتیکی تقاطع، جهش استفاده شده است. نرخ عملگر جهش برابر ۰/۰۵، نرخ عملگر تقاطع ۰/۷ در نظر گرفته شده است؛ همچنین سائز جمعیت ۲۸۲۰ و حداکثر تکرار ۲۹۷۰ در نظر گرفته شده است. با قرار دادن تابع هدف R^2 -۱ در الگوریتم ژنتیک، تلاش برای کمینه کردن آن صورت گرفته است.

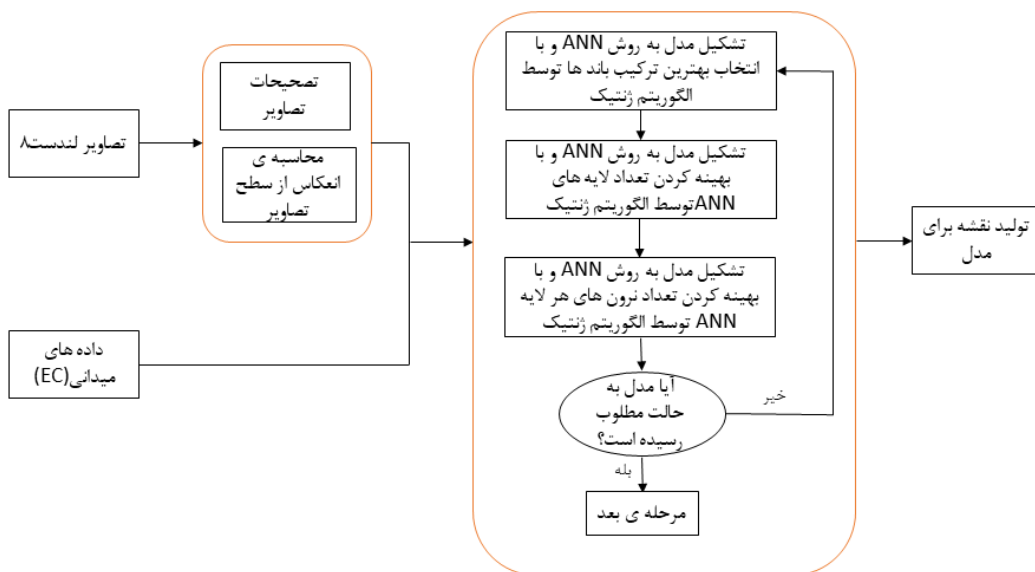
در این مطالعه تلاش شده است تا با ترکیب الگوریتم ژنتیک و رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی پرسپترون چندلایه شوری آب کارون مدل‌سازی شود. ابتدا با ترکیب الگوریتم ژنتیک با رگرسیون بردار پشتیبان و با قرار دادن تابع هدف R^2 -۱ در الگوریتم ژنتیک به دنبال بهترین ترکیب باندهای سنجنده لندست-۸ هستیم؛ سپس در داخل الگوریتم رگرسیون بردار پشتیبان دوباره از الگوریتم ژنتیک استفاده شده است تا پارامترهای الگوریتم رگرسیون



شکل ۴. فلوجارت الگوریتم SVR و ژنتیک.

بهینه کردن تعداد نورون‌ها با ثابت نگه‌داشتن تعداد لایه‌ها ادامه می‌یابد. این مراحل تا جایی ادامه می‌یابد که بهترین عملکرد و دقت حاصل شود. پس از به دست آمدن بهترین ترکیب باندها و بهینه کردن تعداد لایه‌ها و نورون‌های هر لایه در شبکه عصبی پرسپترون چند لایه، مدل به دست آمده در یک تصویر لندست-۸ به تاریخ ۵ سپتامبر ۲۰۱۸ پیاده‌سازی گردیده است. شکل ۵ فلوجارت این روش را نشان می‌دهد.

و سعی می‌شود تا با استفاده از الگوریتم GA سه باند از باندهای طیفی سنجنده ی لندست-۸ طوری انتخاب گردند که بیشترین دقت حاصل شود. پس از آن که بهترین ترکیب باندها حاصل گردید؛ مقدار ثابت تخصیص داده شده برای تعداد لایه‌ها و نورون‌های هر لایه را به تعداد نورون‌های هر لایه دوباره تخصیص داده و سعی می‌شود تعداد لایه‌های شبکه با استفاده از الگوریتم GA بهینه گردند. در مرحله بعد مشابه روش قبل کار برای




شکل ۵. فلوجارت الگوریتم MLP و ژنتیک

نتایج

پیااده‌سازی مدل ترکیبی رگرسیون بردار پشتیبان و الگوریتم ژنتیک

در این مقاله، پارامترهای الگوریتم ژنتیک استفاده‌شده از عملگرهای ژنتیکی متقاطع، جهش استفاده‌شده است. نرخ عملگر جهش برابر ۰/۰۵، نرخ عملگر متقاطع ۰/۷ در نظر گرفته شده است؛ همچنین سائز جمعیت ۲۰ و حداکثر تکرار ۷۰ در نظر گرفته‌شده است. با قرار دادن تابع هدف R^2-1 در الگوریتم ژنتیک، تلاش برای کمینه کردن آن


صورت گرفته است. در این الگوریتم ترکیب باندهای ۱، ۲ و ۳ به‌عنوان بهترین باند و پارامترهای مدل رگرسیون بردار پشتیبان (C, ϵ, γ) به ترتیب برابر $(0/86)$ و $(0/00000012)$ و $(1079/83)$ به دست آمده است. شکل ۶ نحوه‌ی همگرا شدن الگوریتم ژنتیک و SVR را برای پیدا کردن بهترین ترکیب باندها و بهینه کردن پارامترهای SVR نشان می‌دهد. در این مقاله با استفاده از الگوریتم پیشنهاد شده در نهایت ضریب تعیین ۰/۷ و خطای جذر میانگین مربعات μscm^{-1} ۳۹۵ حاصل گردیده است (شکل ۷).



شکل ۶. نحوه‌ی همگرا شدن الگوریتم ژنتیک و SVR


پیااده‌سازی مدل ترکیبی شبکه عصبی پرسپترون چندلایه و الگوریتم ژنتیک

در این مقاله، پارامترهای الگوریتم ژنتیک استفاده شده از عملگرهای ژنتیکی متقاطع، جهش استفاده شده است. نرخ عملگر جهش برابر ۰/۰۵، نرخ عملگر متقاطع ۰/۷ در نظر گرفته‌شده است؛ همچنین سائز جمعیت ۲۰ و حداکثر تکرار ۷۰ در نظر گرفته شده است. با قرار دادن تابع هدف R^2-1 در الگوریتم ژنتیک، تلاش برای کمینه کردن آن صورت گرفته است. در نتیجه این الگوریتم ترکیب باندهای ۱، ۲ و ۳ به‌عنوان بهترین باند و تعداد لایه‌های شبکه برابر ۵ و تعداد نورون‌های هر لایه برابر ۳۵ در نظر گرفته‌شده

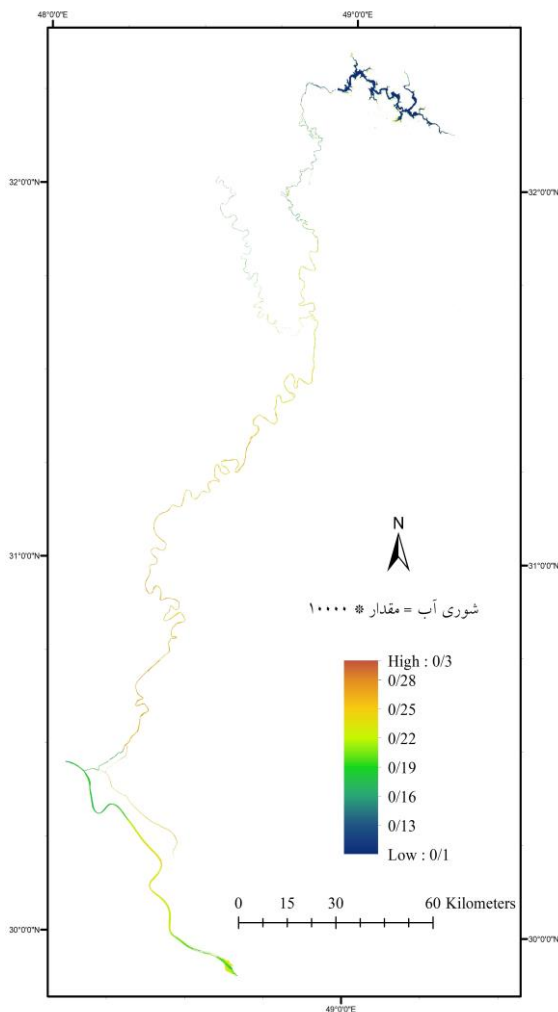
شکل ۷. ضریب تعیین ۰/۷ و خطای جذر میانگین مربعات μscm^{-1} ۳۹۵ برای داده‌های آزمون برای روش SVR

نشان می‌دهد. در این مقاله با استفاده از الگوریتم پیشنهاد شده ضریب تعیین 0.73 و خطای جذر میانگین مربعات $363 \mu\text{scm}^{-1}$ حاصل گردیده است (شکل ۹).

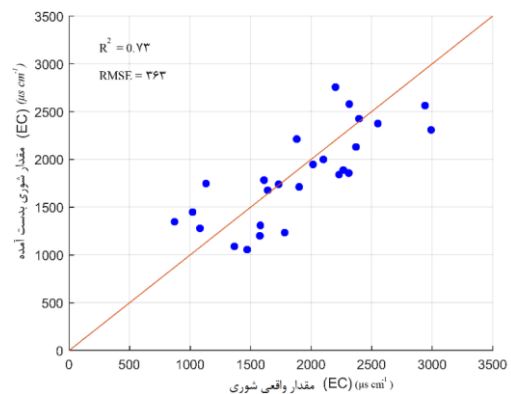
است. شکل ۸ نحوه‌ی همگرا شدن الگوریتم ژنتیک و شبکه عصبی MLP را برای پیدا کردن بهترین ترکیب باندها و بهینه کردن تعداد لایه‌ها و نورون‌های شبکه عصبی MLP



شکل ۸. نحوه‌ی همگرا شدن الگوریتم ژنتیک و شبکه عصبی MLP



شکل ۱۰. نقشه شوری آب رود کارون در تاریخ ۵ سپتامبر ۲۰۱۸ توسط مدل رگرسیون بردار پشتیبان



شکل ۹. ضریب تعیین 0.73 و خطای جذر میانگین مربعات $363 \mu\text{scm}^{-1}$ برای داده‌های آزمون برای روش شبکه عصبی MLP

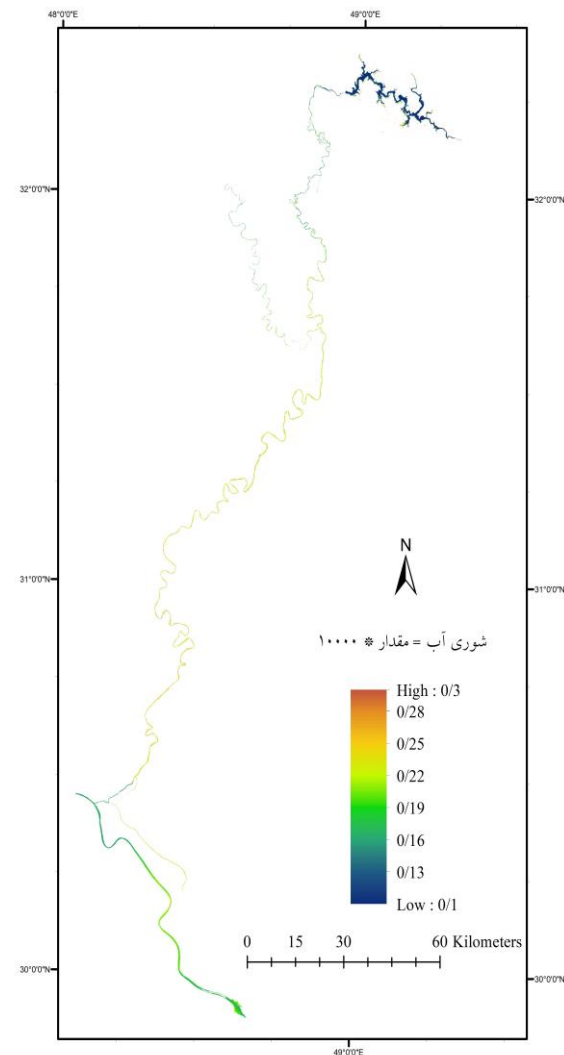
در این مقاله، پس از مشخص شدن ترکیب باندهای مناسب از سنجنده لندست-۸ و نهایتاً با بهینه کردن پارامترهای مدل SVR و تعداد لایه‌ها و نورون‌های شبکه عصبی پرسپترون چندلایه، دو مدل به‌دست‌آمده برای تصویر لندست-۸ به تاریخ ۵ سپتامبر ۲۰۱۸ پیاده‌سازی گردیده است. نقشه‌های به‌دست‌آمده از هر دو روش در شکل‌های ۱۰ و ۱۱ قابل مشاهده هستند.

ارزیابی

هدف از این پژوهش ارائه‌ی مدل‌های SVR و MLP برای به دست آوردن شوری آب کارون بوده است که

بیان کرده‌اند که باند ۳ سنجنده لندست ۵ (TM) یا به عبارتی باند قرمز بیشترین همبستگی را با شوری آب دارد که برخلاف نتایج به‌دست‌آمده در این مقاله است.

با ترکیب الگوریتم ژنتیک و SVR برای مدل‌سازی شوری آب ضریب تعیین ۰/۷ و خطای جذر میانگین مربعات $395 \mu\text{scm}^{-1}$ حاصل گردید (شکل ۷) که با توجه به وسیع بودن منطقه مورد مطالعه و تعداد داده‌های میدانی، دقت قابل‌قبولی به نظر می‌رسد. همچنین با ترکیب الگوریتم ژنتیک و شبکه عصبی MLP برای مدل‌سازی شوری آب ضریب تعیین ۰/۷۳ و خطای جذر میانگین مربعات $363 \mu\text{scm}^{-1}$ بدست آمده است (شکل ۹) که نسبت به روش SVR دارای دقت مناسبتری بوده و با توجه به دامنه وسیع داده‌های میدانی که از $385 \mu\text{scm}^{-1}$ تا $4310 \mu\text{scm}^{-1}$ مطابق جدول ۱ متغیر است، دقت‌های به‌دست‌آمده در هر دو روش قابل‌قبول به نظر می‌رسند. شبکه عصبی MLP این قابلیت را دارد تا با معرفی داده‌های جدید به شبکه، بتوان عملیات آموزش شبکه را با داده‌های جدید دوباره انجام داد و با توجه به ضریب تعیین قابل‌قبول آن می‌توان با داده‌های میدانی بیشتر مدل بهتری را توسط شبکه به‌دست‌آمده تهیه کرد. همان‌طور که از شکل ۷ و شکل ۹ مشخص است، MLP دقت بهتری را نسبت به SVR ارائه داده است و داده‌های شوری واقعی و محاسبه‌شده مقادیر نزدیک‌تری را نسبت به هم دارا می‌باشند و بیشتر به سمت نیمساز میل کرده‌اند. مقادیر RMSE برای SVR و MLP به ترتیب $395 \mu\text{scm}^{-1}$ و $363 \mu\text{scm}^{-1}$ بدست‌آمده است که با توجه به نوسانات شدید شوری در این رود که از مقادیر $385 \mu\text{scm}^{-1}$ تا $4310 \mu\text{scm}^{-1}$ از پشت سد گتوند تا ورودی رود کارون به خلیج فارس در حال تغییر هستند، مقادیر قابل‌قبولی به نظر می‌رسند. Nguyen و همکاران (۲۰۱۸) با واردکردن اطلاعات مکانی و مختصات نقاط به مدل کمترین مربعات معمولی (OLS) توانسته‌اند به ضریب تعیین ۰/۷۴ برسند که نسبت به روش پیاده شده در این مقاله به‌دقت بهتری دست پیدا کرده‌اند.



شکل ۱۱. نقشه شوری آب رود کارون در تاریخ ۵ سپتامبر ۲۰۱۸ توسط شبکه عصبی مصنوعی پرسپترون چندلایه

نقشه‌های به‌دست‌آمده برای شوری آب کارون می‌تواند برای مدیریت بحران شوری این رود و کمک به حل این مشکل مفید واقع شود. به دلیل اهمیت و موقعیت استراتژیک این رود برای کشور ایران، شوری آب این رودخانه مورد مطالعه قرار گرفت. با استفاده از الگوریتم ژنتیک در دو مدل SVR و MLP در این مقاله، ترکیب باندهای ۱، ۲ و ۳ به‌عنوان بهترین و حساس‌ترین ترکیب باندهای سنجنده لندست ۸ برای تشخیص شوری آب انتخاب گردید. اگرچه ترکیب باند به‌دست‌آمده با بسیاری از مطالعات قبلی سازگار است ولی در بعضی از مطالعات قبلی مانند Baban (۱۹۹۷) و مقاله Wang و Xu (۲۰۰۸)

به کارگیری الگوریتم SVR و شبکه عصبی MLP تلاش بر آن شده است که مدلی برای شوری آب رود کارون به دست آید. شبکه عصبی MLP توانست با ضریب تعیین بهتری نسبت به SVR به مقدار ۰/۷۳ برسد و ۰/۰۳ ضریب تعیین را بهبود بخشد. با توجه به نقشه‌های تهیه شده می‌توان نشان داد که شوری آب رود کارون از بالادست به سمت پایین دست در حال افزایش است. در نتیجه رود کارون در مسیر خود مرتباً در حال شور شدن است. این مقاله نشان می‌دهد که وجود سازند گچساران دلیل اصلی شوری آب رود کارون نیست؛ و دلایل دیگری مانند ورود فاضلاب‌های شهری و کشت نیشکر موجب شوری آب رود کارون شده است. در مطالعات بعدی می‌توان با داشتن داده‌های میدانی بیشتر دقت مدل‌ها را افزایش داد و همچنین می‌توان با بررسی عوامل اصلی شوری مثل زمین‌های کشاورزی کشت نیشکر و منابع اصلی ورود فاضلاب شهری با کندوکاو بهتری، راه‌حل مناسب برای حل این بحران زیست‌محیطی ارائه داد. همچنین استفاده‌ی از سنجنده‌هایی با توان تفکیک مکانی بالاتر می‌تواند در بهبود دقت موثر باشد.

تقدیر و تشکر

نویسندگان این مقاله از شرکت توسعه منابع آب و نیروی ایران بابت فراهم نمودن داده‌های میدانی نهایت تشکر را دارند. این پژوهش توسط صندوق حمایت از پژوهشگران و فناوران کشور تحت تفاهم‌نامه شماره ۹۸۰۰۹۴۰۸ حمایت مالی شده است.

یادداشت‌ها

1. Landsat 5
2. Moderate Resolution Imaging Spectroradiometer
3. Landsat 8
4. coefficient of determination
5. Root Mean Square Error
6. Spatially Weighted Optimization Model
7. Genetic Algorithm
8. Support Vector Regression
9. Multilayer Perceptron
10. Earth explorer.usgs.gov
11. Digital Number

مدل‌هایی مانند SVR و MLP که از یادگیری ماشین استفاده می‌کنند دقتشان به شدت به داده‌های ورودی برای آموزش الگوریتم وابسته هستند. در صورتی که برداشت داده‌های میدانی از منطقه وسیع مورد مطالعه در این مقاله و با توزیع زمانی مناسب و منظم، از نظر اقتصادی با محدودیت‌هایی مواجه است، در هر صورت ۱۰۲ داده‌ی میدانی با توزیع زمانی مناسب برای این پژوهش تهیه شده است. محدودیت بعدی در تهیه‌ی داده‌های میدانی هم‌زمانی آن‌ها با زمان تصویربرداری ماهواره لندست-۸ است؛ که در این مقاله با حداکثر فاصله زمانی ۲ روز تلاش شده است تا از ۱۰۲ داده میدانی استفاده گردد (جدول ۲). همان‌طور در نقشه‌های نشان داده شده در شکل‌های ۱۰ و ۱۱ قابل مشاهده است، شوری آب رود کارون از بالا به سمت پایین در حال افزایش بوده که نشان از آن دارد که آب رود کارون در مسیر خود شور می‌شود که می‌تواند دلایلی مثل کشت نیشکر، ورود فاضلاب‌های شهری، ورود پساب‌های حوضچه‌های پرورش ماهی و جزر و مد شدید خلیج فارس باشد. با توجه به گزارش‌های نهاد جهاد کشاورزی خوزستان^{۳۰} در سال‌های ۲۰۱۴ و ۲۰۱۶ به ترتیب ۸۲۰۰ و ۳۷۲۲ هکتار از زمین‌های کشاورزی حوضه‌ی رود کارون به کشت نیشکر تخصیص داده شده است که این روند کاهش در کشت نیشکر می‌تواند به کاهش شوری آب رود کارون کمک کند. مدل‌های به دست آمده در این مقاله می‌توانند برای مدیریت هرچه بهتر این مشکل محیط‌زیستی مفید باشند.

بحث و نتیجه‌گیری

این مطالعه رابطه‌ی بین بازتاب‌های از سطح دریافت شده توسط سنجنده لندست ۸ و شوری آب را مورد بررسی قرار داده است. در ابتدا با استفاده از الگوریتم ژنتیک بهترین ترکیب باندها که نسب به شوری آب بیشترین حساسیت را دارند شناسایی شده‌اند که در نتیجه باندهای ۱، ۲ و ۳ سنجنده‌ی لندست-۸ انتخاب گردیدند. در نهایت با

- | | |
|--|----------------------------|
| 12. Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes | 21. Transfer Function |
| 13. Normalized Difference Vegetation Index | 22. Back Propagation |
| 14. Electrical Conductivity | 23. Support Vector Machine |
| 15. Reproduction | 24. Cost |
| 16. Coding | 25. Radial Basis Function |
| 17. Fitness function | 26. Crossover |
| 18. Artificial Neural Network | 27. Mutation |
| 19. Weight | 28. Population size |
| 20. Bias | 29. Max Iterations |
| | 30. www.ajkhz.ir |

فهرست منابع

- Abdelmalik, K. (2018). Role of statistical remote sensing for Inland water quality parameters prediction. *The Egyptian Journal of Remote Sensing and Space Science*, 21(2), 193-200.
- Ansari, M., and Akhoondzadeh, M. (2019). Water Salinity Mapping of Karun Basin Located in Iran Using the Svr Method. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 97-101. <https://doi.org/10.5194/isprs-archives-XLII-4-W18-97-2019>.
- Ansari, M., and Akhoondzadeh, M. (2020). Mapping water salinity using Landsat-8 OLI satellite images (Case study: Karun basin located in Iran). *Advances in Space Research*, 65(5), 1490-1502. <https://doi.org/10.1016/j.asr.2019.12.007>.
- Baban, S. M. (1997). Environmental monitoring of estuaries; estimating and mapping various environmental indicators in Breydon Water Estuary, UK, using Landsat TM imagery. *Estuarine, coastal and shelf science*, 44(5), 589-598.
- Chang, C.-C., and Lin, C.-J. (2011). LIBSVM: A library for support vector machines. *ACM transactions on intelligent systems and technology (TIST)*, 2(3), 27.
- Chen, X.-L., Zhao, H.-M., Li, P.-X., and Yin, Z.-Y. (2006). Remote sensing image-based analysis of the relationship between urban heat island and land use/cover changes. *Remote sensing of environment*, 104(2), 133-146.
- Da Silva, I. N., Spatti, D. H., Flauzino, R. A., Liboni, L. H. B., and dos Reis Alves, S. F. (2017). Artificial neural networks. *Cham: Springer International Publishing*.
- Fassnacht, F., Hartig, F., Latifi, H., Berger, C., Hernández, J., Corvalán, P., and Koch, B. (2014). Importance of sample size, data type and prediction method for remote sensing-based estimations of aboveground forest biomass. *Remote Sensing of Environment*, 154, 102-114.
- Holland, J. H. (1975). Adaptation in natural and artificial systems Ann Arbor. *The University of Michigan Press*, 1, 975.
- Karamouz, M., Mahjouri, N., and Kerachian, R. (2004). River water quality zoning: a case study of Karoon and Dez River system. *Iran J Environ Healt*, 1, 16-27.
- Khadim, F. K., Su, H., and Xu, L. (2017). A spatially weighted optimization model (SWOM) for salinity mapping in Florida Bay using Landsat images and in situ observations. *Physics and Chemistry of the Earth, Parts A/B/C*, 101, 86-101.
- Khorram, S. (1985). Development of water quality models applicable throughout the entire San Francisco Bay and delta. *Photogrammetric Engineering and Remote Sensing*, 51, 53-62.

- Lavery, P., Pattiaratchi, C., Wyllie, A., and Hick, P. (1993). Water quality monitoring in estuarine waters using the Landsat Thematic Mapper. *Remote Sensing of Environment*, 46(3), 268-280.
- Mary, L., and Yegnanarayana, B. (2004). *Autoassociative neural network models for language identification*. Paper presented at the International Conference on Intelligent Sensing and Information Processing, 2004. Proceedings of.
- Messner, J. W., Mayr, G. J., and Zeileis, A. (2017). Nonhomogeneous boosting for predictor selection in ensemble postprocessing. *Monthly Weather Review*, 145(1), 137-147.
- Naddafi, K., Honari, H., and Ahmadi, M. (2007). Water quality trend analysis for the Karoon River in Iran. *Environmental monitoring and assessment*, 134(1-3), 305-312.
- Nazeer, M., and Bilal, M. (2018). Evaluation of ordinary least square (OLS) and geographically weighted regression (GWR) for water quality monitoring: A case study for the estimation of salinity. *Journal of Ocean University of China*, 17(2), 305-310.
- Nguyen, P. T., Koedsin, W., McNeil, D., and Van, T. P. (2018). Remote sensing techniques to predict salinity intrusion: application for a data-poor area of the coastal Mekong Delta, Vietnam. *International journal of remote sensing*, 39(20), 6676-6691.
- Pappu, S. M. J., and Gummadi, S. N. (2017). Artificial neural network and regression coupled genetic algorithm to optimize parameters for enhanced xylitol production by *Debaryomyces nepalensis* in bioreactor. *Biochemical engineering journal*, 120, 136-145.
- Shan, J., Alkheder, S., and Wang, J. (2008). Genetic algorithms for the calibration of cellular automata urban growth modeling. *Photogrammetric Engineering and Remote Sensing*, 74(10), 1267-1277.
- Shareef, M. A., Toumi, A., and Khenchaf, A. (2014). *Prediction of water quality parameters from SAR images by using multivariate and texture analysis models*. Paper presented at the SAR Image Analysis, Modeling, and Techniques XIV.
- Sivanandam, S., and Deepa, S. (2008). Genetic algorithms. In *Introduction to genetic algorithms* (pp. 15-37): Springer.
- Urquhart, E. A., Zaitchik, B. F., Hoffman, M. J., Guikema, S. D., and Geiger, E. F. (2012). Remotely sensed estimates of surface salinity in the Chesapeake Bay: A statistical approach. *Remote Sensing of Environment*, 123, 522-531.
- US Geological Survey (USGS) (2019). Science for a changing world. Retrieved from <https://earthexplorer.usgs.gov/>
- Vapnik, V. N. (1995). The nature of statistical learning. *Theory*.
- Vuille, M., and Baumgartner, M. F. (1993). Hydrologic investigations in the north Chilean Altiplano using landsat-MSS and-TM data. *Geocarto International*, 8(3), 35-45.
- Wang, F., and Xu, Y. J. (2008). Development and application of a remote sensing-based salinity prediction model for a large estuarine lake in the US Gulf of Mexico coast. *Journal of Hydrology*, 360(1-4), 184-194.
- Wang, L. a., Zhou, X., Zhu, X., Dong, Z., and Guo, W. (2016). Estimation of biomass in wheat using random forest regression algorithm and remote sensing data. *The Crop Journal*, 4(3), 212-219.
- Xie, Z., Zhang, C., and Berry, L. (2013). Geographically weighted modelling of surface salinity in Florida Bay using Landsat TM data. *Remote sensing letters*, 4(1), 75-83.
- Yousefi, S., Pourghasemi, H. R., Hooke, J., Navratil, O., and Kidová, A. (2016). Changes in morphometric meander parameters identified on the Karoon River, Iran, using remote sensing data. *Geomorphology*, 271, 55-64.

- Yu, H., and Kim, S. (2012). SVM tutorial—classification, regression and ranking. *Handbook of Natural computing*, 479-506.
- Zhang, C., Xie, Z., Roberts, C., Berry, L., and Chen, G. (2012). Salinity assessment in Northeast Florida bay using Landsat TM data. *southeastern geographer*, 52(3), 267-281.
- Zhao, J., Temimi, M., and Ghedira, H. (2017). Remotely sensed sea surface salinity in the hyper-saline Arabian Gulf: Application to landsat 8 OLI data. *Estuarine, Coastal and Shelf Science*, 187, 168-177.