

Modeling oil spring exploration based on their spectral characteristics

Shirin Chazani Shrahi¹, Parviz Zeaieanfrouzabadi^{2*}, Seyed Mohammad Tavakkoli Sabour

1. Department of Remote Sensing and GIS, Kharazmi University, Iran
chazani@khu.ac.ir
2. Department of Remote Sensing and GIS, Kharazmi University, Iran
zeaiean@aut.ac.ir
3. Department of Remote Sensing and GIS, Kharazmi University, Iran
tavako_m@yahoo.com

Received: 2023//11/07 - Accepted: 2024/07/06

Abstract

This research presents a method for extracting the spectral characteristics of oil springs (oil seepages) and their exploration by applying artificial neural networks and maximum likelihood algorithms on Landsat 8 OLI images. The study area covers three provinces: Khuzestan, Fars, Kohgiluyeh, and Boyer-Ahmad. Vegetation, water, soil spectral indices, and tasseled cap transformation outputs along surface reflectance images generated the feature space required to explore oil springs. Samples were manually collected from all the features of oil springs to identify and explore oil springs, including different land uses and the existing oil springs already recorded by the Ministry of Petroleum. The separability of oil spring samples was examined with the help of spectral values and signs of sample features. Then, using the statistical data of a part of the samples, the feedforward neural network training with 8 hidden layers was carried out and evaluated. Also, the model parameters for the maximum likelihood algorithm were estimated using the extracted samples. Finally, the trained neural network and maximum likelihood algorithm were applied to the spectral characteristics of the entire study area to extract the probable locations of the oil springs. The results based on the test data showed that the neural network with a kappa coefficient of 92.07% and an overall accuracy of 99.53% separated the oil springs from other land uses. However, the maximum likelihood algorithm showed poor performance in separating the oil springs from other land uses. The kappa coefficient and its overall accuracy were equal to 22.93% and 73.35%, respectively. By examining the classified image obtained from the neural network, 15 new points were extracted as promising locations for oil springs. These points were verified and confirmed by Google Earth images.

Keywords

Oil Spring Reflectance, Oil Polluted Soils, Level 2 Landsat Images, Maximum Likelihood Algorithm, Artificial Neural Networks.

* Corresponding Author



1- Introduction

During recent years, the application of remote sensing technology as one of the most important sources of data gathering towards the study and monitoring of natural resources and their optimized usage has attracted the attention of many experts and specialists in various sciences, including geology, mining, environment, agricultural meteorology, and hydrology, etc. (Sayedain et al., 2013). Using satellite data and implementing different imaging methods is a suitable tool in the exploration and extraction of minerals on the earth's surface. Due to the costly nature of each exploration activity, achieving high certainty about the presence of minerals in an area is one of the essential goals of exploration activities. In this regard, using satellite images and remote sensing methods can reduce this risk and increase certainty (Sayedain et al., 2013). In this regard, the use of satellite images and remote sensing methods and techniques can greatly help the exploration of oil springs and reduce exploration costs (Van Der Meer et al., 2002). So far, much research has been conducted to identify and explore oil springs and hydrocarbon materials, some of which have been investigated below.

In 1985, Segal et al. identified hydrocarbons in Lipson Valley, Utah, using band ratios in Landsat 5 (TM) images. They could detect changes in the mineral content of clay soils caused by hydrocarbon leaks (Segal et al., 1985). In 2002, Meer et al. stated that radar images, aerial imagery, and multispectral sensor images are among the most widely used remote sensing sources for detecting and exploring hydrocarbons (Van Der Meer et al., 2002). In 2001, Ellis et al. described the application of airborne hyperspectral imaging and its capabilities to detect oil spills in remote lands. Using the image classification, they identified the pixels that could contain hydrocarbons or petroleum materials [4]. In 2007, Xu et al. used a combined method for oil and gas exploration (Xu et al., 2007). They stated that there is a cause-and-effect relationship between oil and gas reservoirs and surface anomalies and that these surface anomalies mainly involve changes in surface and related mineral hydrocarbons. They used images from the Hyperion sensor to detect oil and gas leak sites in China's Qinghai province. By providing the appropriate feature space, they finally use the maximum likelihood classification method to classify the area and identify oil and gas in the region. In 2007, Khan and Jacobson used remote sensing images and geochemistry data to identify oil micro spills in the Patrick Drew area of Wyoming. Their research was based on the hypothesis that geochemistry and mineralogical changes have occurred on top of large oil fields. They used Hyperion images and field data to detect oil microleaks (Khan & Jacobson 2008). In 2008, Lammogliaa and Filhoa identified and explored hydrocarbon microspills in the Tucano basin of Brazil using ultra-spectral image classification and neural network analysis of ASTER data. Overall, their study showed the great potential of ASTER data and spectral-spatial methods for the low-cost exploration of hydrocarbons in Brazil (Lammogliaa & Filhoa, 2008).

Other researchers used remote sensing data and a variety of image processing algorithms to detect, identify, and explore oil springs at different locations on the surface of the earth (Perry et al., 2011; Hamzeh, 2011; Shi et al., 2012; Sayedain, 2013; Dehban Varmazani, 2015; Roberto De la Rosa, 2021).

Although hyperspectral images have very high spectral resolution and low signal-to-noise ratio compared to multispectral images, which are the main advantages of these images compared to multispectral images such as Landsat 8, the main problem of hyperspectral images is the low width of the obtained images, for example, the standard dimensions of the images obtained by this sensor are equal to 7.7 km. The length is equal to 42 km. Of course, the size of the images can also increase up to 185 kilometers. Meanwhile, the Landsat 8 images cover an area of 185 km x 185 km. In other words, each image of the Landsat 8 satellite covers an area equal to 24 Hyperion images. On the other hand, It should be noted that Hyperion images are not available for all regions, and this

makes the problem more pronounced. As a result, if the goal is to monitor and explore oil springs in a large area, using Landsat 8 images, apart from their spectral resolution, will be much more appropriate and convenient than hyperspectral images. In this regard, if we could provide the desired spectral feature space for the identification and exploration of oil springs, the use of Landsat 8 images would also be compelling in the exploration of oil springs, which is one of the goals of the present study.

According to the previous studies mentioned above and the lack of research in this applied field and effective use of algorithms in the pursuit and exploration of promising areas of oil springs in Iran, an attempt has been made to investigate and explore oil springs over three provinces of Iran. The data of the OLI sensor from the Landsat 8 satellite, the ground data collected from the existing oil springs, and different analytical methods were used to create a spectral feature space database and perform a proposed method for selecting features. Then, two classifiers, maximum likelihood (MLC) and feedforward neural networks (NN), were implemented to locate unreported locations of the oil springs.

The proposed model does not mention using various indices extracted from satellite images in mineral resources exploration, which can be considered the main innovation of this research. This method can be used by different researchers and mining sectors to explore other mineral resources.

2- Methods

2-1- Study area

The study area is part of three provinces: Khuzestan, Kohgiluyeh, Boyer-Ahmad, and Fars. It includes twelve cities of Izeh, Masjed Soleiman, Bagh-e-Malek, Haftkal, Ramhormoz, Omidiyeh, Aghajari, Behbahan, Hendijan, Gachsaran, Deylam, and Mamasani. It should be noted that the reason for choosing this area is the density of oil springs already identified in these cities. Figure 1 shows the location of the study area in Iran and the provinces of Khuzestan, Kohgiluyeh Boyer-Ahmad, and Fars.

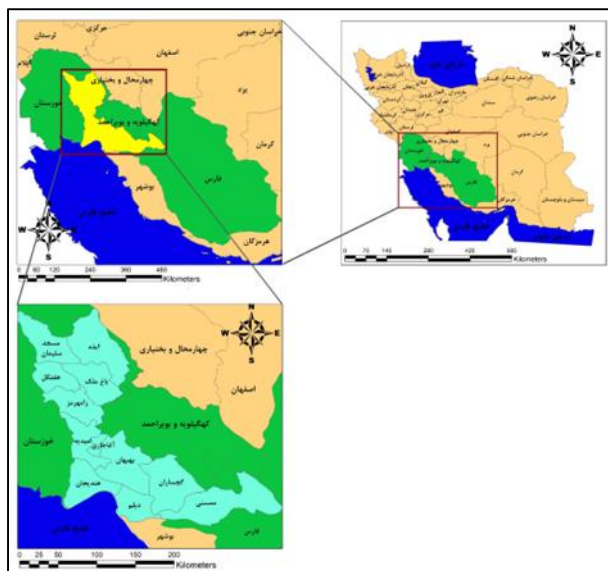


Figure 1. The study area is in Iran, and three provinces cover it.

2-2- Data used

The data used here are as follows:

Landsat 8 Satellite Images (OLI): A level 2 image of collection 2 (land surface reflectance) has

been used. The level 2 Landsat 8 satellite images listed in Table 1 have a spatial resolution of 30 meters and include reflective bands of the features of the earth's surface (Figure 2). Existing oil springs point data identified by the Ministry of Petroleum are shown in Figure 3.

Table 1. Specification of Landsat OLI satellite images.

NO.	PATH	ROW	Acquisition Date
1.	163	39	01-10-2021
2.	164	39	22-09-2021
3.	165	38	29-09-2021

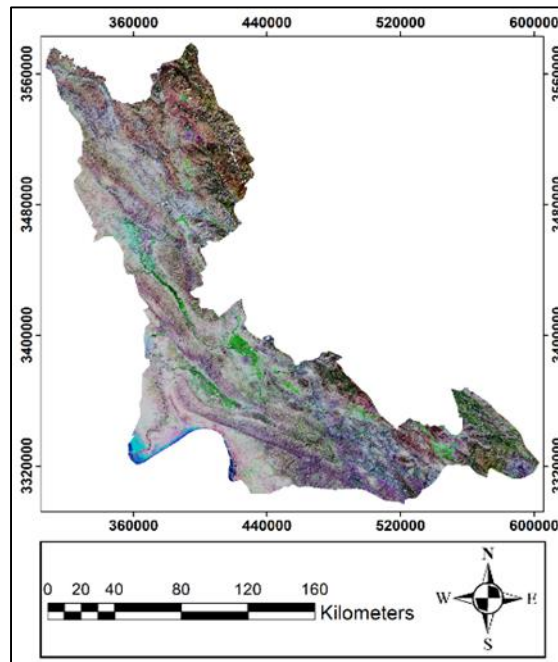


Figure 2. False color composite (RGB) Mosaic Image of the Area.

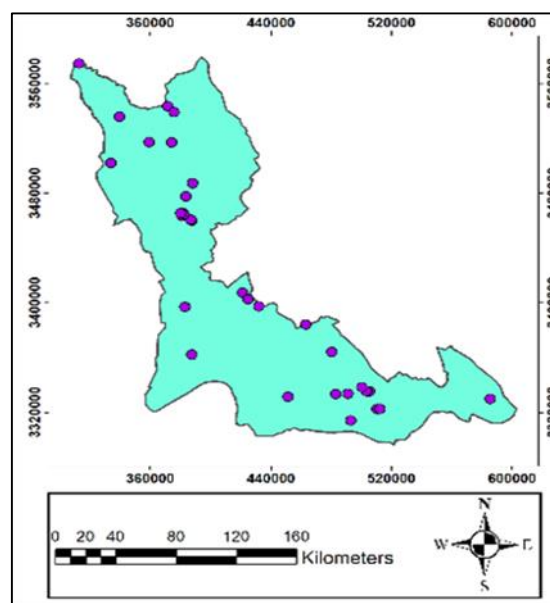


Figure 3. Existing oil springs point data identified by the Ministry of Petroleum.

The flowchart of the proposed method for the identification and exploration of oil springs from the Landsat 8 images is presented in Figure 4 and is described in three general stages:

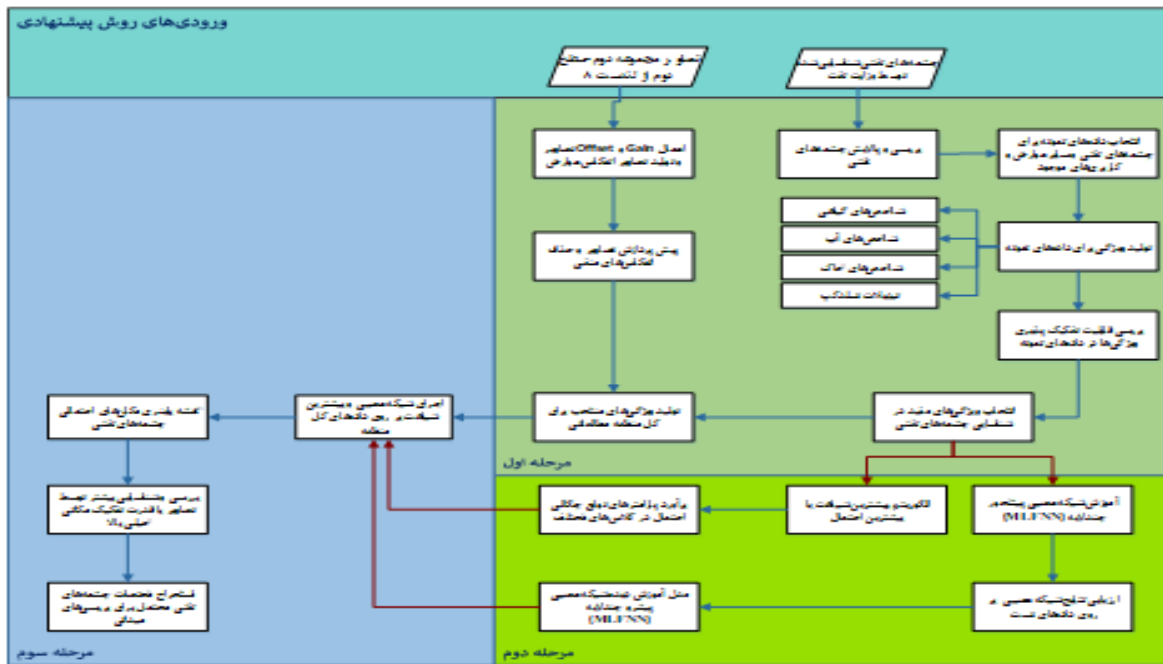


Figure 4. Flowchart of the proposed method for identifying and exploring oil springs from the Landsat 8 images.

2-3- Spectral Reflectance Extraction

In the first step, the reflectance images of the earth's surface features are produced using the Landsat 8 OLI second-level images. Since the second-level images are rescaled to 16-bit images, applying only the Gain factor and the Offset factor is necessary to obtain the true reflection values in the visible and infrared ranges.

At this stage, the existing oil springs identified by the Ministry of Petroleum were examined, and the oil springs that are not visible in Google Earth's Worldview2 images were removed. Because of their tiny size, they could not have an acceptable effect on the reflection values of the desired pixel of Landsat 8. After selecting suitable oil springs, their reflection values and other land uses were sampled.

2-4- Generating Spectral Indices and Properties from Surface Reflectance Images

After converting the images' numerical values to the ground surface's reflection values, satellite spectral indices were produced. 30 selected indices were used, including vegetation, water, soil, and tasseled cap and reflectance of land surface features in bands 2 to 7 of Landsat 8. Scientific formulas to calculate spectral indices are provided on the IDB – Index DataBase website. Some of the outputs of these indices are given in Figure 5.

2-4-1- Extracted vegetation spectral indices

The vegetation indices used in this study to form feature space include the following index (Jinru & Su, 2017; Rasul et al., 2018; Sukmono et al., 2019; Yan et al., 2020). In vegetation indices, areas related to vegetation and trees, gardens, and forests have positive and high values. Some areas, such as water or snow, have negative values, and some land uses, such as barren land, have values close to zero.

- Normalized Differential Vegetation Index (NDVI)
- Simple Ratio Index (SRI)
- Improved Vegetation Index (EVI)

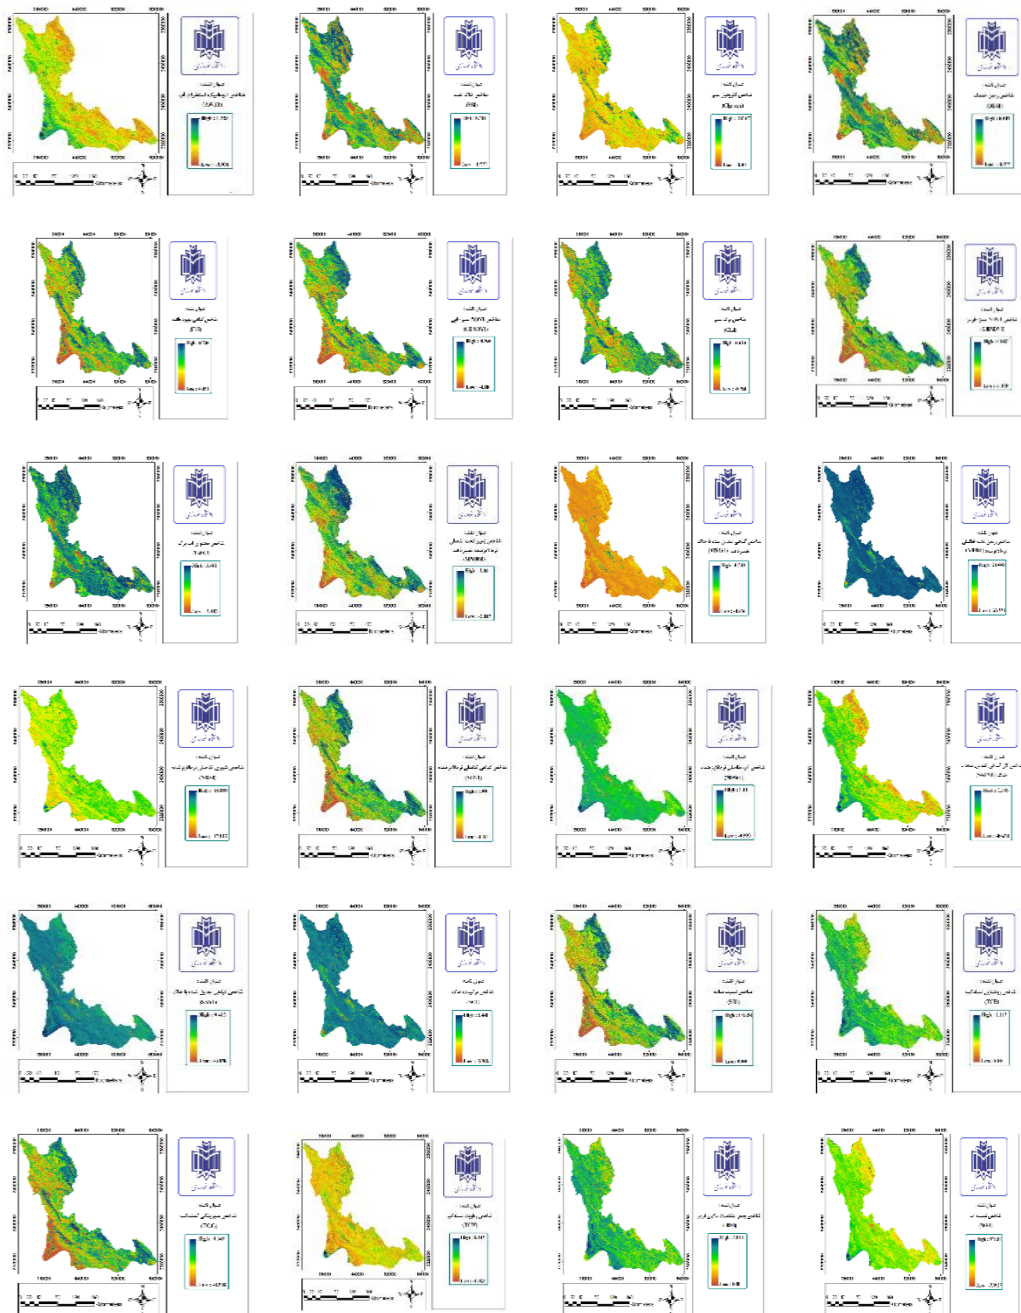


Figure 5. Some of the outputs of spectral indices.

- Soil-Adjusted Vegetation Index (SAVI)
- Soil-Adjusted Total Vegetation Index (SATVI)
- Modified Soil-adjusted Vegetation Index (MSAVI)
- Green Chlorophyll Index (CIgreen)
- Green Leaf Index (GLI)
- Green-Blue NDVI Index (GBNDVI)
- Green-Red NDVI Index (GRNDVI)

- Leaf Water Content Index (LWCI)

2-4-2- Water Spectral Indices

The water indices used in this study to form the feature space include six indices that are produced according to the equations found in IDB – Index DataBase (Jinru & Su, 2017; Rasul et al., 2018; Sukmono et al., 2019; Yan et al., 2020).

- Normalized Differential Water Index (NDWI)
- Automatic Water Extraction Indicator (AWEI)
- Water Ratio Index (WRI)

2-4-3- Soil or Land Spectral Indices

The soil or vacant land indices used in this study for the formation of feature space include the following indices in the equations found in IDB – Index DataBase and include the following (Jinru & Su, 2017; Rasul et al., 2018; Sukmono et al., 2019; Yan et al., 2020).

- Dry Bareness Index (DBSI)
- Normalized Differential Bare-land Index (NDBaI)
- Modified Differential Normalized Bare-land Index (MNDBI)
- Normalized Differential Salinity Index (NDSI)
- Soil Composition Index (SCI)

2-4-4- Tasseled cap indices

In addition to the indices mentioned above, this study has also used 3 indicators related to the tasseled cap transformation. These indicators are generated according to the existing coefficients in the IDB Index Database ([Jackson, 1984; Crist & Kauth; 1986; Ali & Salman]).

- Tasseled Brightness Index (TCB)
- Tasseled Greenness Index (TCG)
- Tasseled Cap Wetness (TCW)

2-5- Feature selection and feature space database generation

In the previous section, all the features that could be useful in exploring oil springs were produced. However, some features cannot isolate and identify oil springs from other uses. In this regard, it is necessary to choose the feature from among the features produced in the previous stage. For this purpose, a simple method for feature selection has been used, which is based on comparing the sign or the average value of the pixels in oil springs with other land uses. In this method, you have some features. In this method, features that meet at least one of the following conditions are selected:

- The average pixel values in the existing oil springs should differ from those in other land uses.

In this study, using the mentioned method, out of 43 initial features, 30 features have been selected (i.e., 6 Landsat 8 bands plus 37 spectral indices), and a feature space dataset with 30 bands has been produced (Table 2).

Based on the spectral behavior of oil springs and oil-contaminated soils, the symbol of the produced oil springs indices for the points are shown in Table 3.

According to Table 3, the symbols of AWEI, NDWI, TCW, GBNDVI, and GRNDVI are negative for oil springs points, and the rest of the indices or bands have positive values in these points.

Table 2. Feature space dataset including Landsat 8 bands and vegetation, water, soil, and tasseled cap indices.

Input Feature NO.	Feature Name	Input Feature NO.	Feature Name
1	LC08-Ref-Blue	16	MNDBI
2	LC08- Ref-Green	17	MSAVI
3	LC08- Ref-Red	18	NDBaI
4	LC08- Ref-NIR	19	NDSI1
5	LC08- Ref-SWIR1	20	NDVI
6	LC08- Ref-SWIR2	21	NDWI
7	AWEI	22	SATVI
8	BII	23	SAVE
9	CIgreen	24	SCI
10	DBSI	25	SRI
11	EVI2	26	TCB
12	GBNDVI	29	TCG
13	GLI	28	TCW
14	GRNDVI	29	With
15	LWCI	30	WRI

Table 3. The signs of indices of oil springs, agricultural land, urban area, soil, water, and trees of the study area

Feature or Index Name	Sign of Water, Agricultural Lands, Soil, Trees & Urban Ares Indices	Oil Spring Sign
AWEI	Positive (Water & Urban)	Negative
BII	Negative (Water & Tree)	Positive
CIgreen	Negative (Water)	Positive
DBSI	Negative (Water & Tree)	Positive
EVI2	Negative (Water)	Positive
GBNDVI	Positive (Soil, tree & Agriculture)	Negative
GLI	Negative (soil & Agriculture)	Positive
GRNDVI	Positive (Tree)	Negative
LWCI	Negative (Water & Tree)	Positive
MNDBI	Negative (Water)	Positive
MSAVI	Negative (Water)	Positive
NDBaI	Negative (Water & tree)	Positive
NDSI1	Negative (Water)	Positive
NDVI	Negative (Water)	Positive
NDWI	Positive (Water)	Negative
SATVI	Negative (Water, Soil & Urban)	Positive
SAVI	Positive (Water)	Positive
SCI	Negative (Water & tree)	Positive
SRI	All Positive	Positive
TCB	All Positive	Positive
TCG	Negative (Water & Urban)	Positive
TCW	Positive (Water & Tree)	Negative
WITH	All Positive	Positive
WRI	All Positive	Positive

2-6- Selection of training samples

To identify and explore oil springs through the maximum likelihood classification method, it is

necessary to sample all the land uses. For this purpose, agricultural lands (seven types), water (seven types), four types of vacant land, one kind of orchard and tree, urban area, and shadow were identified and sampled manually. Samples were also taken from the existing oil springs identified by the Ministry of Oil. In this regard, it should be noted that some of the oil springs were not identifiable in Google Earth images due to their tiny areas and did not affect the reflectance values of Landsat 8 images. They were left out of the sampling process.

2-7- Implementation of the neural network and maximum likelihood algorithm

In the second step, the selected and generated features for the sample data were used to train the feedforward neural networks and MLC to estimate the parameters of the probability density function in each class. The nature of the problem in this study is considered to be two classes. For this purpose, oil spring samples were labeled 1 for the neural network algorithm, and samples of other land uses were labeled zero. However, for MLC, seven land use classes have been assigned. Merging the non-oil classes in the MLC method would cause the variation of the properties of the non-oil class to be high, and as a result, the probability density function will be extensive, and this will cause all the pixels of the image to be classified as non-oil classes. For this reason, in this study, the two-class method was used for the neural network, but for the MLC method, 7 different classes were defined, and after the ML classification, the non-oil classes were combined. Ultimately, output will have two classes of oil-contaminated soils (oil springs) and other land uses. Also, in this step, it is necessary to introduce the parameters of the neural network, such as the type of training function, the number of hidden layers, and the maximum number of iterations or epochs to the neural network. It should be noted that the evaluation of the results of the accuracy of the neural network is also done in this step. Still, for the MLC algorithm, the evaluation is done after the production of the classification map and after the aggregation of non-oil classes is done in the third stage. Among the total available samples, 70% of the samples from each class were used to train the neural network or estimate the parameters of the probability density function of the MLC algorithm, and the remaining 30% were used to test and evaluate the trained neural network and the MLC algorithm. In this study, to identify and explore oil springs by neural networks (ANNs), the *Trainlm* as training function and 8 hidden layers have been used.

2-8- Implementation of Neural Network and MLC Algorithm on the Whole Region and Exploration of Oil Springs

In this step, the trained neural network or the MLC algorithm, whose parameters were set in the previous step, was applied to the features of the entire study area to obtain the classification results. As mentioned in the last step, a binary image showing the possible locations of the oil springs in the study area using the trained neural network for the whole study area is obtained. However, the output of the MLC algorithm is a map showing different land uses.

To evaluate the accuracy of the outputs obtained from the above analysis, the overall accuracy of the Kappa Coefficient of Agreement, the following equations were used, which is based on the construction of a confusion matrix (Jensen, 2015):

$$kappa = \frac{N \sum_{n=1}^k x_{ii} - \sum_{n=1}^k (x_{i+} \times x_{+j})}{N^2 - \sum_{n=1}^k (x_{i+} \times x_{+j})} \quad \text{equation 1}$$

$$overall\ accuracy = \sum_{i=1}^k \frac{x_{ii}}{N} \quad \text{equation 2}$$

N is the total number of samples in the confusion matrix, K is the number of land use, x_{ii} is the number of observations in row I and column I, and x_{i+} and x_{+j} are the number of non-diagonal observations in the confusion matrix.

3- Findings

The final output of both the neural network and MLC algorithm methods are shown in Figures 6 and 7, respectively, and the values of 1 represent the probable locations of the oil springs in the study area. In Figures 6 and 7, the values of one or the oil springs resulting from the classification are dark brown, and the other uses are light gray. It should be noted that the pixels identified as oil springs in the neural network method were not visible in the figure because they covered a small area and were magnified in Figure 6 for better viewing.

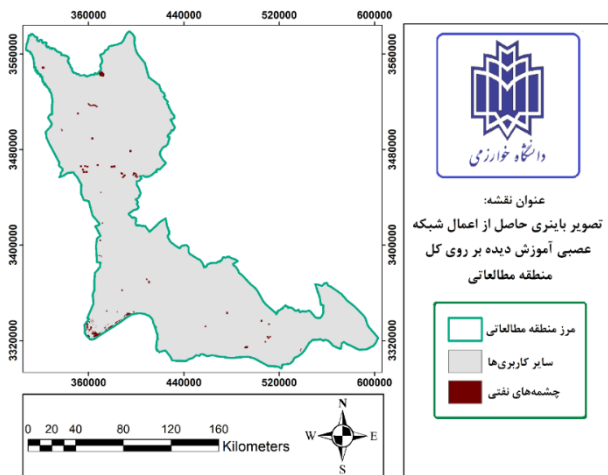


Figure 6. Classified output of Neural Networks

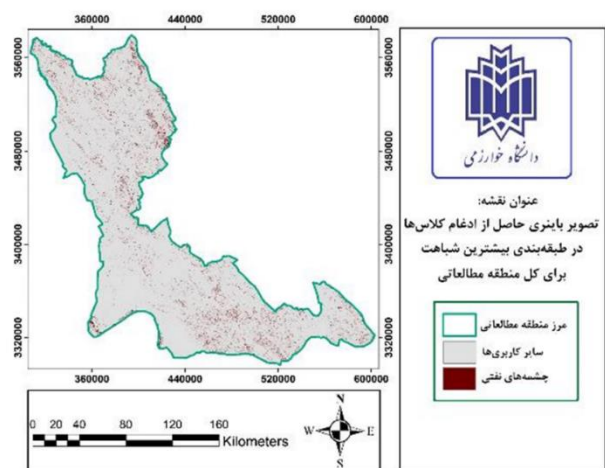


Figure 7: Classified output of MLC

As can be observed in Figure 7, many pixels are classified as oil springs or oil-contaminated soils. In contrast, fewer pixels have been identified as oil springs or oil-contaminated soils in the output neural network method. This makes it very easy to investigate these points with high spatial resolution images, such as Google Earth images. These locations were verified with Google Earth images, and finally, 15 new points in the area were identified as oil springs (Figure 8). To be sure, it is recommended to have a ground-based for these newly found oil springs.

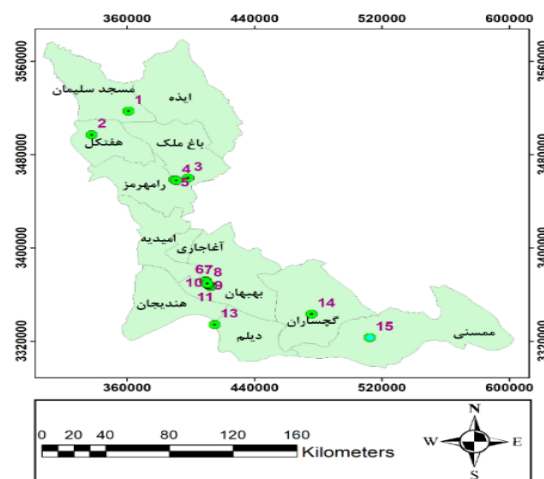


Figure 8. Location map of oil springs (green dots) based on neural networks algorithm.

Google Earth images of these 15 oil springs identified by the neural network are shown in Figure 9. Figure 10 shows the distribution and location of the springs about the region's faults.




Figure 9. Google Earth images of detected oil springs (yellow dots).

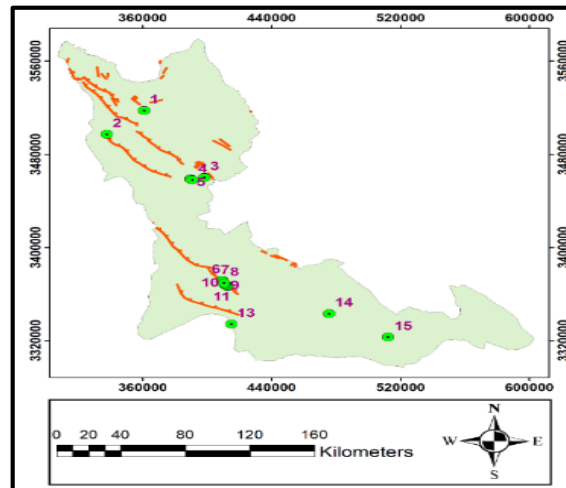


Figure 10. Location map of oil springs (green dots) concerning faults (red lines).

3-1- Spectral characteristics of oil springs

Figure 11 presents the spectral reflectance of oil springs and oil-contaminated soils in Landsat 8 images (wavelengths of 0.4 to 2.3 μ m). The curve presented in Figure 11 is based on the average values of pixels sampled from oil sources identified by the Ministry of Oil.

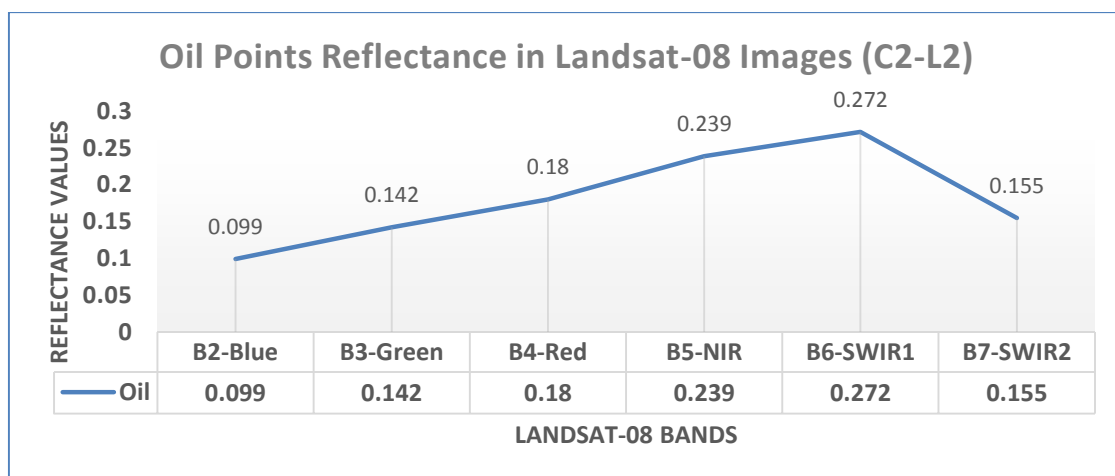


Figure 11. spectral reflectance curve of registered oil springs in different bands of OLI images

The reflectance of oil springs in Landsat 8 images, except band 7, the reflection of oil springs and oil contaminated soils and hydrocarbons increases with an increase in wavelength. The blue band (Landsat 8-second band) has the lowest reflectance, and the shortwave infrared (band 6 with wavelengths of 1560 to 1660 nm) has the highest reflectivity value. After that, the reflectance amount suddenly drops in band 7 of Landsat 8 (shortwave infrared with wavelengths of 2100 to 2300 nm). The reduction of reflectance in the 7th band of Landsat 8 images was not unexpected at all because in the spectral curve of the hyperspectral images, in the equivalent range of the 7 bands of Landsat 8 (2100 to 2300 nm), the reflection has decreased as compared to the range of 1600 nm. This reduction could be due to the proximity of this band to the thermal infrared range. Soil contamination with oil can cause a decrease in soil reflectivity (lowering soil temperature) in this range of the spectrum. This could lead to the definition of a new index using data from this region of the electromagnetic spectrum to identify the oil resources that appear on the surface.

Figure 12 shows the reflectance values of bands 2 to 7 of Landsat 8 images in oil springs and other land uses. According to Figure 12, in the seven types of water identified in the area, the

reflectance values of all bands, especially bands 5 to 7, are low, and this characteristic can be used to separate oil and oil-contaminated soils from water. Comparison of the reflectance values of oil springs with the other land uses leads to find useful bands and generate valuable indices. For example, in orchards and trees, reflectance values in band 5 are higher than band 6, while this is the opposite case in oil and oil-contaminated soils.

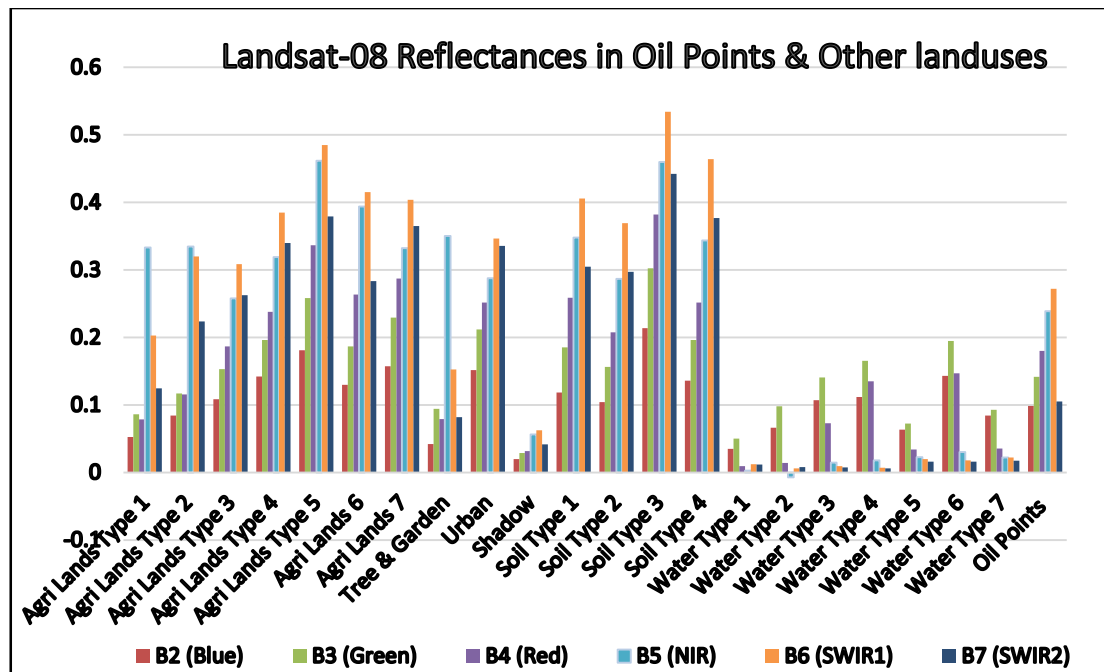


Figure 12. Spectral reflectance curve of other land use in different bands of OLI images

4- Conclusions

The following are the conclusions and remarks about the extraction of spectral characteristics of oil springs and the identification and exploration of THIS FEATU:

- In Landsat 8 images, except band 7, the reflectance of oil springs and oil-contaminated soils and hydrocarbon materials increases with increasing wavelength, and the blue band (I.E. Landsat 8 second band) has the lowest reflectance. Also, the FIRST short-wave infrared range (band 6 with wavelengths of 1560 to 1660 nm) has the highest reflectance. After that, the amount of reflectance is suddenly reduced in band 7 of Landsat 8 (second shortwave infrared with wavelengths of 2100 to 2300 nm).
- In oil springs and oil-contaminated soils, a relatively sharp reduction in the amount of reflectance in the SWIR2 band compared to the SWIR1 band can be used as a characteristic in the identification of oil springs. In this regard, features such as the normalized differential salinity index (NDSI) based on the normalized difference of the SWIR1 and SWIR2 bands are helpful.
- In the exploration of oil springs by neural network method, the user's accuracy is equal to 100%, but the producer's accuracy is 85.71%; this accuracy indicates that in 85.71% of the test data, the oil springs have been correctly labeled as the class of oil springs and 14.29% of the oil springs in the test data have been labeled as the other land uses. In other words, oil springs have not been completely identified, but the comprehensiveness of the identification of oil springs is acceptable.
- Exploring oil springs by the Maximum Likelihood Classification (MLC) method, the producer accuracy for the oil-contaminated soils is 99.52%. Still, the user accuracy for the oil sources is

very low, at 18.11%. This has caused many other uses to be classified as oil springs, and it is practically impossible to identify oil springs by the classification method with the MLC algorithm.

- The distribution of oil springs deduced here showed that 12 out of the 15 oil springs are located near the faults, which alarms us that faults might be considered an indicator of the existence of oil springs.
- Because of the global coverage of the Landsat series, images can be used to study areas that are not covered by other sensors, such as hyperspectral data. Also, each scene of Landsat images covers a much larger area than hyperspectral sensors, which can be helpful in rapid area monitoring.
- Finally, different researchers and mining sectors can use the method presented here to explore other mineral resources.

References

- Ali, S. M. & Salman, S. S. (2016). Landsat-8 (OLI) classification method based on tasseled cap transformation features, 2016 Al-Sadeq International Conference on Multidisciplinary in IT and Communication Science and Applications (AIC-MITCSA), Baghdad.
- Crist, E. P. & Kauth, R. J. (1986). The Tasseled Cap de-mystified, *Photogrammetric Engineering and Remote Sensing*, 52: 81-86.
- Dehban Varmazani, M. (2016). Identification of oil pollution area in Khuzestan using multispectral and thermal Landsat image and Fieldspec3 Spectroradiometer, M.Sc, Shahid Chamran University of Ahvaz.
- Ellis, J. M., H. H. Davis & Zamudio, J.A. (2001). Exploring for onshore oil seep, *Oil and Gas Journal*, 99(37): 49-58.
- Hamzeh, M. (2011). Identification of Oil Seepages Using Hyperspectral Images, Case Study: Khuzestan Province. M.Sc., University of Tehran.
- Jackson, R. D. (1983). Spectral indices in N-Space., *Remote Sensing of Environment*, 13(5): 409-421.
- Jensen, R. *Introductory Digital Image Processing: A Remote Sensing Perspective*, 4th edition. 2015; Pearson series in geographic information science.
- Jinru, X. & Su, B. (2017). Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications, *Journal of Sensors*, 2017: 1-17.
- Khan, S. and Jacobson, S. (2008). Remote sensing and geochemistry for detecting hydrocarbon micro-seepages. *Geological Society of America Bulletin* 120: 95-105.
- Lammogliaa, T. & Filhoa, C. R. S. (2008). Characterization of Hydrocarbon Micro seepages in the Tucano Basin (Brazil) through Hyperspectral Classification and Neural Network Analysis of Advanced Space-borne Thermal Emission and Reflection Radiometer (ASTER) Data, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*.
- Perry, S. L., F. A. Kruse & Carlston, C. (2011). Evidence of Hydrocarbon Seepage Using Multispectral Satellite Imagery, Kurdistan, Iraq, 73rd EAGE Conference and Exhibition-Workshops 2011, European Association of Geoscientists & Engineers.
- Rasul, A., H. Balzter, G. R. F. Ibrahim, H. M. Hameed, J. Wheeler, B. Adamu, S. A. Ibrahim &

- Najmaddin, P. M. (2018). Applying built-up and bare-soil indices from Landsat 8 to cities in dry climates, *Land* 7(3): 81.
- Roberto De la Rosa, Milagrosa Aldana, Vincenzo Costanzo-Alvarez, Santiago Yepez, & Cristina Amon. (2021). The surface expression of hydrocarbon seeps characterized by satellite image spectral analysis and rock magnetic data (Falcon basin, western Venezuela), *Journal of South American Earth Sciences*, Volume 106, 103036.
- Sayedain, S. A. (2013). Exploration of Oil Seepages (Hydrocarbon) Using Target Detection Algorithms in Hyperspectral Images, M.Sc, K.N. Toosi University of Technology.
- Segal, D. B., M. D. Ruth, I. S. Merin, H. Watanabe, K. Soda, O. Takano & Sano, M. (1985). Remote Detection of Anomalous Mineralogy Associated with Hydrocarbon Production, Lisbon Valley, Utah: ABSTRACT, *Mountain Geology*, 23(2): 51-62.
- Shi, P., B. Fu, Y. Ninomiya, J. Sun & Li Y. (2012). Multispectral remote sensing mapping for hydrocarbon seepage-induced lithologic anomalies in the Kuqa foreland basin, south Tian Shan, *Journal of Asian Earth Sciences*, 46: 70-77.
- Sukmono, A., A. Nugraha & Firdaus, H. (2019). Integration of Leaf Water Content Index (LWCI) and Enhanced Vegetation Index (EVI) for Stress Detection of Rice Plant Using Landsat 8 Satellite Imagery, *The 1st International Conference on Geodesy, Geomatics, and Land Administration 2019*, KnE Engineering, pages 398--408. DOI 10.18502/keg.v4i3.5891.
- Van Der Meer, F., P. Van Dijk, H. Van Der Werff & Yang, H. (2002). Remote sensing and petroleum seepage: a review and case study, *Terra Nova*, 14(1): 1-17.
- Xu, D., G. Ni, T. Jiang, L. Jiang & Chi M. (2007). Integration of fieldwork and hyperspectral data for oil and gas exploration, *IEEE International Geoscience and Remote Sensing Symposium*.
- Yan, D., C. Huang & Zhang Y. (2020). Improved Landsat-Based Water and Snow Indices for Extracting Lake and Snow Cover/Glacier in the Tibetan Plateau, *Water* 2020, 12, 1339. <https://doi.org/10.3390/w12051339>.



مقاله پژوهشی

مدل سازی اکتشاف چشمه های نفتی بر مبنای استخراج خصوصیات طیفی آن ها

شیرین چزانی شراهی^۱، پرویز ضیائیان فیروز آبادی^{۲*}، سیدمحمدتوکل صبور^۳

۱. کارشناس مسئول آزمایشگاه، دانشکده علوم زمین، دانشگاه خوارزمی، تهران، ایران، chazani@khu.ac.ir

۲. دانشیار گروه سنجش از دور و GIS، دانشگاه خوارزمی، p.zeaiean@gmail.com

۳. استادیار گروه سنجش از دور و GIS، دانشگاه خوارزمی، tavako_m@yahoo.com

دریافت: ۱۴۰۲/۰۹/۰۶ - پذیرش: ۱۴۰۳/۰۴/۱۶

چکیده

در این پژوهش روشی برای استخراج خصوصیات طیفی چشمه های نفتی و اکتشاف آنها با بهره گیری از تصاویر سنجنده OLI ماهواره لندست ۸ و اعمال الگوریتم های شبکه عصبی مصنوعی و بیشترین شباهت ارائه شده است. منطقه مطالعاتی محدوده ای از سه استان خوزستان، فارس و کهگیلویه و بویر احمد را در برمی گیرد. از شاخص های طیفی گیاهی، آب، خاک و شاخص های تبدیل تسلدکپ در کنار باندهای بازتاب تصاویر بازتابی استفاده شد تا فضای ویژگی مورد نیاز برای اکتشاف چشمه های نفتی تولید گردند. برای شناسایی و اکتشاف چشمه های نفتی، از تمام عوارض و کاربری های موجود در منطقه در کنار چشمه های نفتی موجود و شناسایی شده توسط وزارت نفت، بصورت دستی نمونه برداری گردید. با استفاده از مقادیر و علامت ویژگی ها در نمونه های برداشت شده، قابلیت تفکیک پذیری چشمه های نفتی از سایر کاربری ها مورد بررسی قرار گرفت. در ادامه با استفاده از داده های آماری بخشی از نمونه ها، آموزش شبکه عصبی پیشخور با ۸ لایه پنهان انجام و مورد ارزیابی قرار گرفت. همچنین برآورد پارامترهای مدل برای الگوریتم بیشترین شباهت توسط نمونه های استخراج شده انجام گرفت و در نهایت شبکه عصبی آموزش دیده و مدل بیشترین شباهت بر روی ویژگی های کل منطقه مطالعاتی اعمال گردید تا مکان های احتمالی چشمه های نفتی استخراج شوند. نتایج صحت سنجی بر اساس داده های آزمون نشان داد که شبکه عصبی با ضریب کاپای ۰.۹۲/۰۷ و صحت کلی ۰.۹۹/۵۳٪، چشمه های نفتی را از سایر کاربری ها تفکیک کرده است اما الگوریتم بیشترین شباهت در جداسازی چشمه های نفتی را از سایر کاربری ها بسیار ضعیف عمل کرده است بطوریکه ضریب کاپای و صحت کلی آن به ترتیب برابر با ۰.۲۲/۹۳٪ و ۰.۷۳/۳۵٪ می باشد. در این پژوهش با بررسی تصویر طبقه بندی به دست آمده از شبکه عصبی، ۱۵ نقطه جدید به عنوان مکان های احتمالی چشمه های نفتی استخراج گردید و بررسی این نقاط توسط تصاویر گوگل، وجود چشمه های نفتی در نقاط مشخص شده را تایید کرد.

کلمات کلیدی

بازتاب چشمه های نفتی، خاک های آلوده به نفت، تصاویر سطح دوم لندست ۸، تصاویر بازتاب، شبکه عصبی مصنوعی (ANNs).



۱- مقدمه

تصویربرداری فراطیفی هوابرد و قابلیت‌های آن برای تشخیص نشت نفت در زمین‌های دورافتاده را توصیف کردند [4]. آنان با استفاده از طبقه‌بندی، پیکسل‌هایی که می‌توانستند حاوی مواد هیدروکربنی یا نفتی باشند را مشخص کردند.

در پژوهش انجام گرفته توسط ژو^۴ و همکاران در سال ۲۰۰۷، از یک روش ترکیبی برای شناسایی و اکتشاف نفت و گاز استفاده کردند [5]. آن‌ها بیان کردند که یک رابطه علت و معلولی بین مخازن نفت و گاز و ناهنجاری‌های سطحی وجود دارد و این ناهنجاری‌های سطحی عمده‌تاً شامل تغییرات هیدروکربن‌های سطحی و معدنی مرتبط می‌باشد. آن‌ها از تصاویر سنجنده هایپریون (Hyperion) جهت کشف محل‌های نشت نفت و گاز در استان کینگ‌های^۵ چین استفاده کردند. با فراهم‌سازی فضای ویژگی مناسب، در نهایت آن‌ها از روش طبقه‌بندی ماکزیمم شباهت^۶ برای طبقه‌بندی منطقه و شناسایی نفت و گاز در منطقه استفاده کردند.

خان^۷ و جاکوبسون^۸ نیز در سال ۲۰۰۷، از ترکیب تصاویر سنجنش از دوری و داده‌های ژئوشیمیایی استفاده کردند تا ریزتراوشات نفتی را در منطقه پاتریک در او^۹ از ایالت ویومینگ^{۱۰} شناسایی کنند [6]. پژوهش آنان بر پایه این فرضیه بود که تغییرات ژئوشیمیایی و کانی‌شناختی در بالای میدانی نفتی بزرگ اتفاق افتاده است. آنان از تصاویر هایپریون و داده‌های میدانی برای اکتشاف ریزتراوشات نفتی استفاده کردند.

لاموگلیا و فیل هوآ نیز در سال ۲۰۰۸، با استفاده از طبقه‌بندی تصاویر فراطیفی و تحلیل شبکه عصبی داده‌های رادیومتر ASTER، اقدام به شناسایی و اکتشاف ریزنشست‌های هیدروکربنی در حوضه توکانو از برزیل کردند [7]. بطور کلی آن پژوهش، پتانسیل عالی داده‌های ASTER و روش‌های طیفی- مکانی برای اکتشاف کم‌هزینه هیدروکربن‌ها در برزیل را نشان داد.

در پژوهشی که در سال ۲۰۱۰، توسط پری و همکاران

بهره‌گیری از فناوری سنجنش از دور و انواع تصاویر ماهواره‌ای در طی سال‌های اخیر به عنوان یکی از مهم‌ترین منابع جمع‌آوری اطلاعات به منظور مطالعه و پایش منابع زمینی و بهره‌برداری بهینه از آنها، توجه بسیاری از کارشناسان و متخصصان علوم مختلف از جمله زمین‌شناسی، معدن، محیط زیست، هواشناسی کشاورزی و هیدرولوژی و غیره را به خود جلب نموده است [1].

استفاده از داده‌های ماهواره‌ای و به کارگیری روش‌های مختلف تصویربرداری، ابزاری مناسب در اکتشاف و استخراج مواد معدنی موجود در سطح زمین می‌باشد. با توجه به هزینه بر بودن هر فعالیت اکتشافی رسیدن به قطعیت بالا در خصوص حضور مواد معدنی در یک منطقه از اهداف مهم فعالیت‌های اکتشافی می‌باشد. در این خصوص استفاده از تصاویر ماهواره‌ای و به کار بردن روش‌های دورسنجی می‌تواند این ریسک را کاهش داده و قطعیت را بالا برد [1]. در این خصوص استفاده از تصاویر ماهواره‌ای و به کار بردن روش‌ها و تکنیک‌های سنجنش از دوری می‌تواند کمک شایانی در اکتشاف چشمه‌های نفتی و کاهش هزینه‌ها داشته باشد [2].

تاکنون برای شناسایی و اکتشاف چشمه‌های نفتی و مواد هیدروکربوری پژوهش‌های بسیاری انجام گرفته که در ادامه برخی از این پژوهش‌ها مورد بررسی قرار گرفته است.

در سال ۱۹۸۵، سگال و همکاران، با به کار گرفتن نسبت‌های بانندی در تصاویر لندست ۵ (TM) اقدام به شناسایی هیدروکربن‌ها در دره لیبسون^۱ از ایالت یوتا کردند [3]. آن‌ها توانستند تغییراتی را که در محتویات معدنی خاک‌های رس، به سبب نشت هیدروکربن‌ها بوجود آمده بود را شناسایی کنند.

میر^۲ و همکاران با پژوهشی که در سال ۲۰۰۲ داشتند، بیان کردند که تصاویر راداری، تصاویر هوایی و تصاویر سنجنده‌های چندطیفی از منابع سنجنش از دوری می‌باشند که بیشترین استفاده را در شناسایی و اکتشاف هیدروکربن‌ها دارند [2].

در سال ۲۰۰۱، الیس^۳ و همکاران در پژوهشی کاربرد

^۴ Xu

^۵ Qinghai

^۶ Maximum Likelihood

^۷ Khan

^۸ Jacobson

^۹ Patrick Draw

^{۱۰} Wyoming

^۱ Lisbon Valley

^۲ Meer

^۳ Ellis

مخلوط^۹ (MTMF) و برآوردگر انسجام تطبیقی^{۱۰} (ACE) استفاده کرد تا تصاویر امتیاز تطابق مربوط به هر الگوریتم در قالب تصویر درجه خاکستری تولید گردد. در نهایت با اعمال حدآستانه بر روی هر تصویر امتیاز تطابق اهداف شناسایی شده توسط الگوریتمها استخراج شدند.

در پژوهشی دیگر در سال ۲۰۱۶، دهبان ورمزانی برای شناسایی آلودگیهای نفتی از تصاویر ماهوارههای لندست ۸ و هایپریون استفاده کرد [11]. پژوهش آنان نشان داد که نتایج به دست آمده از تصاویر هایپریون دارای همبستگی قابل قبولی با نتایج حاصل از تصاویر لندست ۸ بود.

روبرتو د لا روسا و همکاران با هدف به نقشه درآوردن تغییرات تجمعی مینرالهای آلترا شده توسط هیدروکربن در خاکها و رسوبات از تحلیل خوشه ای دو مرحله ای در منطقه فاکن ونزولا بهره بردند. آنها تصاویر ماهواره ای استر را با داده های مغناطیس سنجی سنگها ترکیب کرده و به این نتیجه دست یافتند که این روش میتواند ابزار مناسبی برای اکتشاف نفت و بررسی آلودگیهای محیط زیستی تراوشات هیدروکربنی باشد [12].

هرچند تصاویر هایپراسپکترال نسبت به تصاویر چندطیفی قدرت تفکیک طیفی بسیار بالا و نسبت سیگنال به نویز پایین دارند که مزیت‌های اصلی این تصاویر نسبت به تصاویر چندطیفی مثل لندست ۸ می‌باشد اما مشکل اصلی تصاویر هایپراسپکترال عرض کم تصاویر اخذ شده می‌باشد بعنوان مثال ابعاد استاندارد تصاویر اخذ شده توسط سنجنده برابر با ۷/۷ کیلومتر و طولی برابر با ۴۲ کیلومتر را دارا می‌باشند. البته طول تصاویر تا ۱۸۵ کیلومتر نیز می‌تواند افزایش داشته باشد. در حالیکه تصاویر لندست ۸ وسعتی برابر با ۱۸۵ کیلومتر در ۱۸۵ کیلومتر را پوشش می‌دهند. به عبارت دیگر هر یک تصویر از ماهواره لندست ۸، وسعتی برابر با ۲۴ تصاویر هایپریون را پوشش می‌دهد. لازم به ذکر می‌باشد که از طرفی داده‌های تصاویر هایپریون برای تمام مناطق در دسترس نیستند و این مسئله مشکل را پررنگ تر می‌کند. در نتیجه در صورتی که هدف پایش و اکتشاف چشمه‌های نفتی در منطقه وسیعی باشد استفاده از تصاویر لندست ۸ سوای قدرت تفکیک طیفی آن به

انجام گرفت رخنمون‌های دگرگون شده شامل ترکیبات جداشونده و کربناته، به وسیله باندهای تصاویر سنجنده‌های چند طیفی ASTER و Landsat ETM+ مدل شدند [8]. روشی که در آن پژوهش مورد استفاده قرار گرفته است به مدلسازی معدنی مشهور هست و زمانی مورد استفاده قرار می‌گیرد که داده‌های مرجع یا داده‌هایی از واقعیت^۱ وجود نداشته باشد.

در پژوهش انجام گرفته توسط حمزه در سال ۲۰۱۱، برای اکتشاف تراوشات نفتی از تصاویر سنجنده هایپریون از پلتفرم EO-1 استفاده کرد [9]. وی یک مدل ترکیبی از تکنیک‌های میانگین طیفی فاصله متغیر^۲ (VISA) و تطبیق منحنی طیفی^۳ (SCM) را برای اکتشاف غیرمستقیم تراوشات هیدروکربوری استفاده کرد. همچنین در آن پژوهش، برای شناسایی و اکتشاف مستقیم تراوشات نفتی، دو شاخص هیدروکربنی با بهره گیری از عوارض جذبی در محدوده ۱۷۳۰ و ۳۱۲۰ نانومتر توسعه داده شد و نتایج دو روش مستقیم و غیرمستقیم مورد بررسی قرار گرفت که هر دو روش قابل قبول بودند.

در پژوهشی که در سال ۲۰۱۲، توسط شی^۴ و همکاران انجام گرفت از تصاویر ASTER برای شناسایی چشمه‌های هیدروکربنی استفاده شد [10]. آن‌ها نشان دادند که استفاده از دو نسبت باندهای B4/B9 و B2/B1 می‌تواند تغییراتی از جمله سفیدشدگی سطوح قرمز که ناشی از وجود چشمه‌های هیدروکربنی است، را آشکار کنند. در آن پژوهش، وجود یا ذخیره‌سازی نفت و گاز منوط به شرایط زمین‌شناسی مناسب از جمله وجود تاق‌دیس ملایم و نسبتاً کوتاه و گسل‌های سطحی اعلام شده است.

در پژوهشی که توسط سیدین در سال ۲۰۱۳ انجام گردید از تصاویر سنجنده هایپریون و دستگاه طیف‌سنج اسپکترورادایومتر^۵ فیلداسپیک^۶ استفاده گردید تا چشمه‌های نفتی شناسایی نشده در منطقه کمرون از شهرستان ایزه را استخراج کنند [1]. وی از چهار الگوریتم حداقل سازی انرژی مقید^۷ (CEM)، فیلتر تطابقی^۸، فیلتر همسان تنظیم شده

^۱ Ground Truth

^۲ Variable Interval Spectral Average (VISA)

^۳ Spectral Curve Matching (SCM)

^۴ Shi

^۵ Spectroradiometer

^۶ FieldScape3

^۷ Constrained energy minimization (CEM)

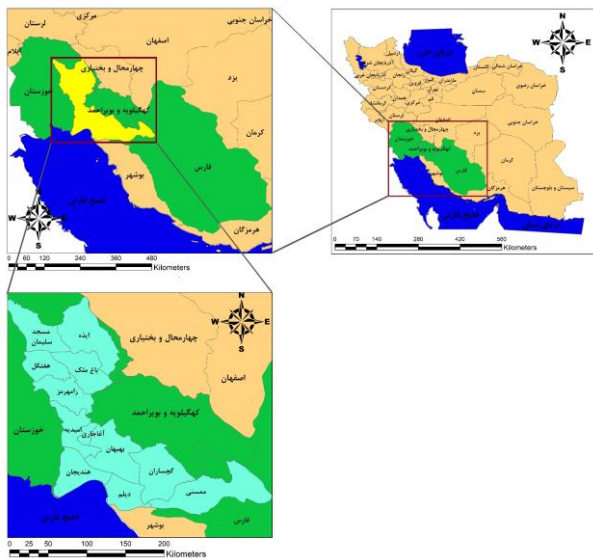
^۸ Matched Filter (MF)

^۹ Mixture Tuned Matched Filtering (MTMF)

^{۱۰} Adaptive Coherence Estimator (ACE)

۲۲ درجه و ۲۲ دقیقه شمالی تا ۲۹ درجه و ۴۸ دقیقه شمالی قرار دارد. منطقه مطالعاتی انتخاب شده وسیع می‌باشد و مساحت آن بطور تقریبی ۲۶۶۸۱/۸ کیلومتر مربع می‌باشد.

در این منطقه، حداقل ارتفاع ۴ متر می‌باشد یعنی پست‌ترین نقطه ۴ متر بالاتر از سطح دریا قرار گرفته است و حداکثر ارتفاع آن ۳۳۰۷ متر بالاتر از سطح دریا می‌باشد. متوسط ارتفاع منطقه نیز ۱۶۵۶ متر بالاتر از سطح دریا می‌باشد.



شکل ۱. موقعیت منطقه مطالعاتی پژوهش نسبت به استان کشور ایران

داده‌هایی که در این پژوهش مورد استفاده قرار گرفته‌اند به شرح ذیل است.

- تصاویر ماهواره‌ی لندست ۸ سنجنده OLI: در این پژوهش از تصویر سطح دو از مجموعه دو (بازتاب عوارض سطح زمین) استفاده شده است. تصویر سطح دو ماهواره‌ی لندست ۸ دارای قدرت تفکیک مکانی ۳۰ متر و شامل باندهای بازتاب عوارض سطح زمین می‌باشد. در این پژوهش به دلیل وسعت منطقه از سه تصویر لندست ۸ استفاده شده است. مشخصات تصاویر استفاده شده در این پژوهش در جدول ۱ ارائه شده است. تصویر سطح دو ماهواره‌ی لندست ۸ برای منطقه مطالعاتی با ترکیب رنگی کاذب SWIR2-NIR-Green در شکل ۲ نشان داده شده است.
- داده‌های نقطه‌ای چشمه‌های شناسایی شده توسط وزارت نفت در منطقه مطالعاتی که در شکل ۳ نشان داده شده است.

مراتب مناسبتر و راحت تر از تصاویر هایپراسپکترال خواهد بود. در این خصوص اگر به توانیم با بررسی و تولید ویژگی‌هایی همانند شاخص‌های طیفی، فضای ویژگی موردنظر برای شناسایی و اکتشاف چشمه‌های نفتی را تامین کنیم، استفاده از تصاویر لندست ۸ نیز در اکتشاف چشمه‌های نفتی کارساز خواهد بود که یکی از اهداف پژوهش حاضر می‌باشد.

با توجه به مطالعات پیشین ذکر شده در این بخش و نبود مطالعه در زمینه کارکردی داده‌های ماهواره‌ای و الگوریتم‌های موثر در پی‌جویی و اکتشاف مناطق امید بخش چشمه‌های نفتی در ایران در این پژوهش برای اولین بار از داده‌های سنجنده OLI از ماهواره لندست ۸، داده‌های زمینی برداشت شده از چشمه‌های نفتی موجود و روش‌های متفاوت تحلیلی، با ایجاد فضای ویژگی و انجام یک روش پیشنهادی در انتخاب ویژگی‌ها، از دو طبقه بندی کننده حداکثر شباهت (MLC) و شبکه عصبی پیش‌خور (NN)، سعی بر آن شد تا با توجه به خصوصیات طیفی چشمه‌های نفتی موجود، مکان آن دسته از چشمه‌های نفتی که گزارش نشده است را بیابیم.

فقدان به کارگیری اندیسه‌های متنوع مستخرج از تصاویر ماهواره‌ای در اکتشاف منابع معدنی به گونه‌ای که در مدل پیشنهادی در این مقاله آمده است می‌تواند بعنوان نوع آوری اصلی این پژوهش مطرح گردد. این روش می‌تواند در اکتشاف منابع معدنی دیگر توسط سایر محققین و بخش‌های معدنی به کار گرفته شود.

۲- داده‌ها و روش تحقیق

۲-۱- منطقه مطالعاتی

منطقه مطالعاتی در این پژوهش مربوط به بخشی از سه استان خوزستان، کهگیلویه و بویر احمد و فارس می‌باشد و شامل دوازده شهرستان ایذه، مسجد سلیمان، باغ‌ملک، هفتکل، رامهرمز، امیدیه، آغاچاری، بهبهان، هندیجان، گچساران، دیلم و ممسنی می‌باشد. لازم به ذکر هست که علت انتخاب این محدوده تراکم چشمه‌های نفتی شناسایی شده در این شهرستان‌ها می‌باشد. در شکل ۱، موقعیت منطقه مطالعاتی این پژوهش نسبت به کشور ایران و استان‌های خوزستان، کهگیلویه و بویر احمد و فارس نشان داده شده است.

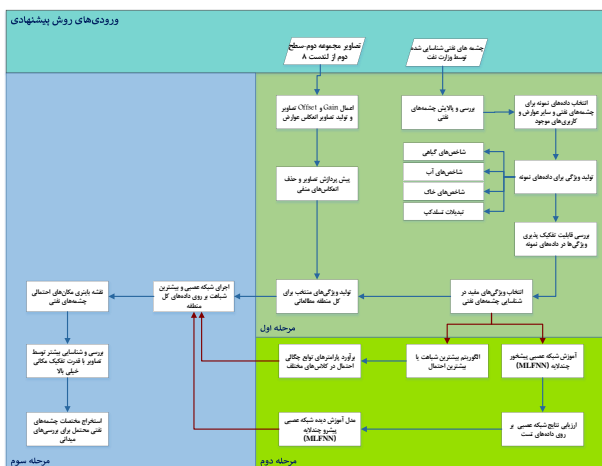
منطقه مطالعاتی منتخب از نظر طول جغرافیایی در محدوده ۴۸ درجه و ۵۸ دقیقه شرقی تا ۵۲ درجه و ۴ دقیقه شرقی قرار گرفته است و از نظر عرض جغرافیایی در محدوده

جدول مشخصات تصاویر استفاده شده در پژوهش حاضر

شماره	مسیر (Path)	ردیف (Row)	تاریخ تصویر
۱	۱۶۳	۳۹	۲۰۲۱/۱۰/۰۱
۲	۱۶۴	۳۹	۲۰۲۱/۰۹/۲۲
۳	۱۶۵	۳۸	۲۰۲۱/۰۹/۲۹

۲-۲- روش انجام پژوهش

روند کلی روش پیشنهادی برای شناسایی و اکتشاف چشمه های نفتی از تصاویر لندست ۸ در شکل ۴ ارائه شده است و در ادامه در سه مرحله کلی تشریح شده است.

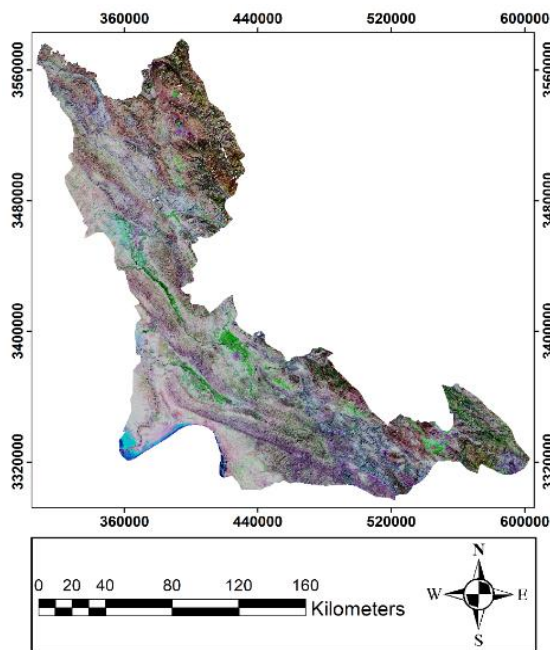


شکل ۴. روش پیشنهادی برای شناسایی و اکتشاف چشمه های نفتی

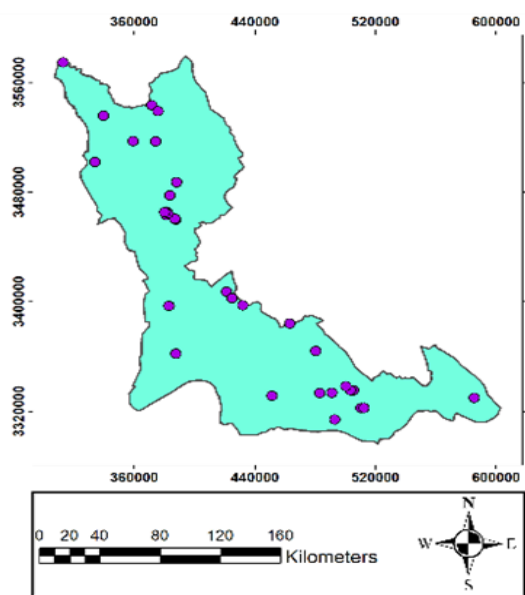
۲-۳- استخراج بازتاب طیفی

در مرحله اول با استفاده از تصاویر سطح دوم لندست ۸ سنجنده OLI، تصاویر بازتاب عوارض سطح زمین تولید می گردند. تصاویر سطح دوم در حقیقت همان تصاویر بازتاب عوارض سطح زمین می باشند که مقیاس آن تغییر یافته است. برای این منظور کفایت فقط فاکتور ضرب (Gain) و فاکتور جمع (Offset) بر روی باندهای ۲ تا ۷ از تصاویر سطح دوم اعمال گردد تا مقادیر واقعی بازتاب در محدوده مرئی و مادون قرمز به دست آیند. با تولید تصاویر بازتاب عوارض سطح زمین، ممکن است برخی پیکسل ها به دلیل بازتاب بسیار ضعیف و همچنین منفی بودن مقدار Offset دارای مقادیر منفی باشند که نیاز است مقادیر بازتاب این پیکسل ها از منفی به مقدار صفر تغییر یابد. برای این منظور در این مرحله، تصاویر بازتاب پیش پردازش می گردند و مقادیر منفی آن حذف می شوند.

همچنین در این مرحله، چشمه های نفتی موجود و شناسایی شده توسط وزارت نفت بررسی شده و چشمه های نفتی که قابلیت رویت در تصاویر Worldview2 گوگل ارث را ندارند حذف شدند. چون به دلیل وسعت بسیار کوچک نمی توانستند در مقادیر بازتاب پیکسل مورد نظر لندست ۸، تاثیر قابل قبولی به گذارند. بعد از انتخاب چشمه های نفتی مناسب، از مقادیر بازتاب آن ها در کنار سایر کاربری ها نمونه



شکل ۲. تصویر سطح دو ماهواره لندست ۸ از منطقه مطالعاتی با ترکیب رنگی کاذب (SWIR2-NIR-Green) (موزاییک شده از سه تصویر یاد شده در جدول ۱).



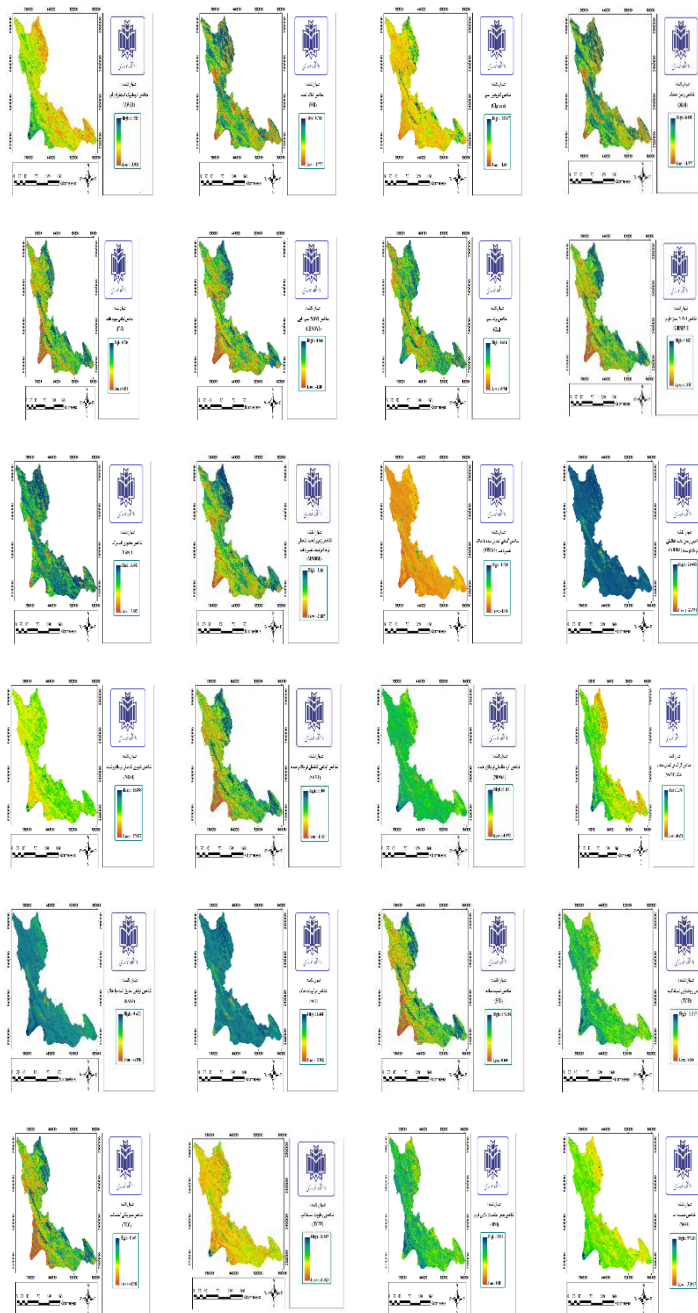
شکل ۳. پراکندگی داده های نقطه ای چشمه های شناسایی شده توسط وزارت نفت در منطقه مطالعاتی

برداری انجام شد.

۴-۲- تولید شاخص های طیفی و ویژگی ها از تصاویر بازتاب سطح

بعد از تبدیل ارزشهای عددی تصاویر به مقادیر بازتاب سطح زمین، از آنها برای تولید شاخص های ماهواره ای دخیل در مدل سازی مکان یابی چشمه ها استفاده گردید. در مجموع

از ۳۰ ویژگی منتخب شامل شاخص های گیاهی، آب، خاک و کلاه زنگوله ای (Tasseled Cap) و بازتاب عوارض سطح زمین در باندهای ۲ تا ۷ لندست ۸، استفاده شد. شاخص های مورد استفاده و نحوه محاسبه آنها دروب سایت به آدرس IDB - Index DataBase ارائه شده است. برخی از خروجی های این اندکسها در شکل ۵ آورده شده است.



شکل ۵. خروجی برخی از شاخص ها و باندهای طیفی مورد استفاده در این تحقیق

۲-۴-۱- شاخص های طیفی گیاهی

شاخص های گیاهی مورد استفاده در این پژوهش برای تشکیل فضای ویژگی شامل شاخص های زیر می باشد ([13],[14],[15],[16]). در شاخص های گیاهی مناطق مربوط به پوشش گیاهی و درختان، باغ و جنگل دارای مقادیر مثبت و بالایی می باشند و برخی مناطق مثل آب یا برف دارای مقادیر منفی هستند و برخی کاربری های نیز مثل زمین بایر دارای مقادیری نزدیک به صفر می باشند.

- شاخص گیاهی تفاضلی بهنجار شده^۱ (NDVI)
- شاخص نسبت ساده^۲ (SRI)
- شاخص گیاهی بهبود یافته^۳ (EVI)
- شاخص گیاهی تعدیل شده با خاک^۴ (SAVI)
- شاخص کل گیاهی تعدیل شده با خاک^۵ (SATVI)
- شاخص گیاهی تعدیل شده با خاک تغییر یافته^۶ (MSAVI)
- شاخص کلروفیل سبز^۷ (CIgreen)
- شاخص برگ سبز^۸ (GLI)
- شاخص NDVI سبز-آبی^۹ (GBNDVI)
- شاخص NDVI سبز-قرمز^{۱۰} (GRNDVI)
- شاخص محتوای آب برگ^{۱۱} (LWCI)

۲-۴-۲- شاخص های طیفی آب

شاخص های آب مورد استفاده در این پژوهش برای تشکیل فضای ویژگی شامل شاخص های آب می باشد که مطابق روابط (۱۳ الی ۱۵) تولید می گردند ([13],[14],[15],[16]).

- شاخص آب تفاضلی بهنجار شده^{۱۲} (NDWI)
- شاخص اتوماتیک استخراج آب^{۱۳} (AWEI)

- شاخص نسبت آب^{۱۴} (WRI)

۲-۴-۳- شاخص های طیفی خاک یا زمین

شاخص های خاک یا زمین خالی مورد استفاده در این پژوهش برای تشکیل فضای ویژگی شامل شاخص های در ادامه در روابط (۱۶ الی ۲۲) ارائه شده هست و شامل موارد ذیل می باشد (می باشد ([13],[14],[15],[16])).

- شاخص زمین خشک^{۱۵} (DBSI)
- شاخص زمین لخت تفاضلی بهنجار شده^{۱۶} (NDBaI)
- شاخص زمین لخت تفاضلی بهنجار شده تغییر یافته^{۱۷} (MNDBI)
- شاخص شوری تفاضلی بهنجار شده^{۱۸} (NDSI)
- شاخص ترکیبات خاک^{۱۹} (SCI)

۲-۴-۴- شاخص های تبدیلات تسلدکپ (کلاه زنگوله ای)

در این پژوهش، در کنار شاخص های یاد شده فوق، از ۳ شاخص مربوط به تبدیل تسلدکپ (کلاه زنگوله ای) نیز استفاده شده است که مطابق روابط (۲۳ الی ۲۵) از باندهای ۲ تا ۷ تصاویر سطح دوم لندست ۸ تولید می گردند ([17],[18],[19]).

- شاخص روشنایی تسلدکپ^{۲۰} (TCB)
- شاخص سبزیگی تسلدکپ^{۲۱} (TCG)
- شاخص رطوبت تسلدکپ^{۲۲} (TCW)

۲-۵- انتخاب ویژگی و تشکیل فضای ویژگی

در بخش قبلی، تمام ویژگی هایی که می توانند در اکتشاف چشمه های نفتی مفید واقع شوند تولید شدند. اما مسلماً برخی از این ویژگی ها، توانایی جداسازی و شناسایی چشمه های نفتی را از دیگر کاربری ها ندارند. در این راستا، نیاز به انتخاب ویژگی از بین ویژگی های تولید شده در مرحله قبلی می باشد. برای این

^{۱۳} Automated Water Extraction Index (AWEI)

^{۱۴} Water Ratio Index (WRI)

^{۱۵} Dry Bareness Index (DBSI)

^{۱۶} Normalized Difference Salinity Index (NDSI)

^{۱۷} Modified Normalized Difference Bare-land Index (MNDBI)

^{۱۸} Normalized Difference Salinity Index (NDSI)

^{۱۹} Soil Composition Index (SCI)

^{۲۰} Tasseled Cap Brightness (TCB)

^{۲۱} Tasseled Cap Greenness (TCG)

^{۲۲} Tasseled Cap Wetness (TCW)

^۱ Normalized Difference Vegetation Index (NDVI)

^۲ Simple Ration Index (SRI)

^۳ Enhanced Vegetation Index (EVI)

^۴ Soil Adjusted Vegetation Index (SAVI)

^۵ Soil-Adjusted Total Vegetation Index (SATVI)-measures both Photosynthesizing and Dead Vegetation

^۶ Modified Soil-Adjusted Vegetation Index (MSAVI)

^۷ Chlorophyll Index Green (CIgreen)

^۸ Green Leaf Index (GLI)

^۹ Green-Blue NDVI (GBNDVI)

^{۱۰} Green-Red NDVI (GRNDVI)

^{۱۱} Leaf Water Content Index (LWCI)

^{۱۲} Normalized Difference Water Index (NDWI)

براساس جدول ۳، علامت شاخص‌های AWEI، NDWI، TCW، GBNDVI و GRNDVI برای نقاط مربوط به چشمه‌های نفتی منفی می‌باشند و مابقی شاخص‌ها یا باندها در نقاط مربوط به چشمه‌های نفتی دارای مقادیر مثبت می‌باشند.

۲-۶- انتخاب نمونه‌های آموزشی

برای شناسایی و اکتشاف چشمه‌های نفتی از طریق روش طبقه بندی حداکثر تشابه، نیاز است از تمام عوارض و کاربری‌های موجود در منطقه نمونه برداری گردد. برای این منظور در منطقه مطالعاتی، زمین کشاورزی (با هفت تنوع)، آب (در هفت تنوع)، چهار نوع زمین خالی و یک نوع باغ و درخت، منطقه شهری و سایه شناسایی شدند و از هر کدام بصورت دستی نمونه برداری انجام شد. همچنین از چشمه‌های نفتی موجود و شناسایی شده توسط وزارت نفت، نمونه برداری انجام شد. در این خصوص لازم به ذکر می‌باشد که برخی از چشمه‌های نفتی به دلیل وسعت خیلی کم در تصاویر گوگل قابل شناسایی نبودند و در مقادیر بازتاب تصاویر لندست ۸ نیز تاثیری نداشتند که در روند نمونه برداری کنار گذاشته شدند.

جدول ۳. علامت شاخص‌های تولید شده برای نقاط مربوط به چشمه‌های نفتی، زمین کشاورزی، منطقه شهری، خاک، آب و درخت منطقه مطالعاتی

نام ویژگی یا شاخص	علامت شاخص چشمه‌های نفتی	علامت شاخص آب، زمین کشاورزی، خاک، درخت و منطقه شهری
AWEI	-	مثبت (آب و شهری)
BI1	+	منفی (آب و درخت)
CIgreen	+	منفی (آب)
DBSI	+	منفی (آب و درخت)
EVI2	+	منفی (آب)
GBNDVI	-	مثبت (خاک و درخت، زمین کشاورزی)
GLI	+	منفی (خاک و زمین کشاورزی)
GRNDVI	-	مثبت (درخت)
LWCI	+	منفی (آب و درخت)
MNDBI	+	منفی (آب)
MSAVI	+	منفی (آب)
NDBaI	+	منفی (آب و درخت)

منظور، در این پژوهش از یک روش ساده برای انتخاب ویژگی استفاده شده است که بر مبنای مقایسه علامت یا مقدار میانگین ویژگی در چشمه‌های نفتی با دیگر کاربری‌هاست. در این روش ویژگی‌هایی انتخاب می‌شوند که حداقل یکی از شرایط ذیل را داشته باشد.

- علامت میانگین ویژگی در چشمه‌های نفتی موجود با علامت میانگین ویژگی در دیگر کاربری‌ها متفاوت باشد
- مقدار میانگین ویژگی در چشمه‌های نفتی موجود با مقدار میانگین ویژگی در دیگر کاربری‌ها متفاوت باشد

در این پژوهش، با استفاده از روش یادشده از ۴۳ ویژگی اولیه (شش باند بازتاب لندست ۸ بعلاوه ۳۷ شاخص تولیدی)، ۳۰ ویژگی انتخاب شده است و یک فضای ویژگی بصورت تصویری با ۳۰ باند مطابق جدول ۲ تولید گردیده است.

جدول ۲. تشکیل فضای ویژگی با شاخص‌های تولید شده گیاهی، آب، خاک و تسلدکپ

شماره ویژگی ورودی	نام شاخص	شماره ویژگی ورودی	نام شاخص
۱	LC08-Ref-Blue	۱۶	MNDBI
۲	LC08- Ref-Green	۱۷	MSAVI
۳	LC08- Ref-Red	۱۸	NDBaI
۴	LC08- Ref-NIR	۱۹	NDSI1
۵	LC08- Ref-SWIR1	۲۰	NDVI
۶	LC08- Ref-SWIR2	۲۱	NDWI
۷	AWEI	۲۲	SATVI
۸	BI1	۲۳	SAVI
۹	CIgreen	۲۴	SCI
۱۰	DBSI	۲۵	SRI
۱۱	EVI2	۲۶	TCB
۱۲	GBNDVI	۲۷	TCG
۱۳	GLI	۲۸	TCW
۱۴	GRNDVI	۲۹	WITh
۱۵	LWCI	۳۰	WRI

با توجه به رفتار طیفی چشمه‌های نفتی و خاک‌های آلوده به نفت، علامت شاخص‌های تولید شده برای نقاط مربوط به چشمه‌های نفتی همانند جدول ۳ می‌باشد.

آموزش، تعداد لایه‌های پنهان و حداکثر تعداد تکرار یا اپک به شبکه عصبی معرفی گردد. لازم به ذکر می‌باشد که ارزیابی نتایج صحت شبکه عصبی نیز در همین مرحله انجام می‌شود اما برای الگوریتم بیشترین شباهت، ارزیابی بعد از تولید نقشه طبقه‌بندی و تجمیع کلاس‌های غیرنفتی در مرحله سوم انجام می‌گردد. از میان کل نمونه‌های موجود، ۷۰ درصد نمونه‌های معرفی شده از هر کلاس برای آموزش شبکه عصبی یا برآورد پارامترهای تابع چگالی احتمال الگوریتم بیشترین شباهت در هر کلاس استفاده شد و ۳۰ درصد باقیمانده نیز برای آزمون و ارزیابی شبکه عصبی آموزش دیده یا الگوریتم بیشترین شباهت استفاده گردید. در این پژوهش برای شناسایی و اکتشاف چشمه‌های نفتی توسط شبکه عصبی (ANNs)، از تابع آموزشی Trainlm و تعداد ۸ لایه پنهان استفاده شده است.

۲-۸- اجرای شبکه عصبی و الگوریتم بیشترین شباهت روی کل منطقه و اکتشاف چشمه‌های نفتی

در این مرحله، شبکه عصبی آموزش دیده یا الگوریتم بیشترین شباهت که پارامترهای آن در مرحله قبلی برآورد شده است، بر روی ویژگی‌های مربوط به کل منطقه مطالعاتی اعمال گردید تا نتیجه طبقه‌بندی برای کل منطقه مطالعاتی به دست آید. همانطور که در مرحله قبلی نیز به آن اشاره شد با اعمال شبکه عصبی آموزش دیده بر روی کل منطقه مطالعاتی، یک تصویر باینری به دست می‌آید که مکان‌های احتمالی چشمه‌های نفتی موجود در منطقه مطالعاتی را نشان می‌دهند. اما خروجی الگوریتم بیشترین شباهت یک تصویر طبقه‌بندی با تعداد کلاس‌های موجود در منطقه می‌باشد و بعد از ادغام کلاس‌های غیرنفتی، ارزیابی نتایج الگوریتم بیشترین شباهت با دو کلاس انجام می‌گردد. در این پژوهش، مکان‌های مشخص شده توسط شبکه عصبی آموزش دیده با تصاویر گوگل که قدرت تفکیک مکانی خیلی بالایی دارند بررسی شده و چشمه‌های نفتی موجود در منطقه شناسایی شدند و در نهایت مختصات چشمه‌های نفتی شناسایی شده استخراج می‌گردند.

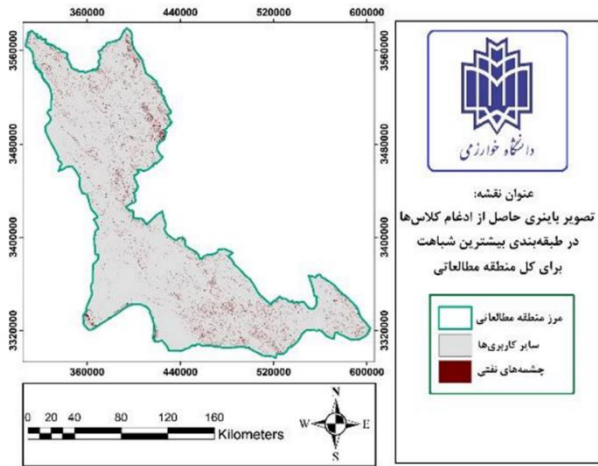
جهت ارزیابی صحت خروجی‌های به دست آمده از تجزیه و تحلیل فوق از صحت کلی (Overall Accuracy) ضریب همخوانی (توافق) کاپا ((Kappa Coefficient of Agreement) از رابطه زیر که بر مبنای بنا نمودن ماتریس درهمی ایجاد می‌گردد بهره گرفته شد [20]:

$$\text{overall accuracy} = \sum_{i=1}^k \frac{x_{ii}}{N}$$

NDSI1	+	منفی (آب)
NDVI	+	منفی (آب)
NDWI	-	مثبت (آب)
SATVI	+	منفی (آب و خاک، شهری)
SAVI	+	مثبت (آب)
SCI	+	منفی (آب و درخت)
SRI	+	مثبت (همه کاربری)
TCB	+	مثبت (همه کاربری)
TCG	+	منفی (آب و شهری)
TCW	-	مثبت (آب و درخت)
WTh	+	مثبت (همه کاربری)
WRI	+	مثبت (همه کاربری)

۲-۷- اجرای شبکه عصبی و الگوریتم بیشترین شباهت

در مرحله دوم، ویژگی‌های انتخاب شده و تولید شده برای داده‌های نمونه برای آموزش شبکه عصبی پیشخور و همچنین برآورد پارامترهای تابع چگالی احتمال الگوریتم بیشترین شباهت در هر کلاس به کار گرفته شدند. ماهیت مسئله در این پژوهش بصورت دو کلاسه در نظر گرفته شده است. برای این منظور برای الگوریتم شبکه عصبی نمونه‌های مربوط به چشمه‌های نفتی با برچسب یک و نمونه‌های مربوط به سایر کاربری‌ها با برچسب صفر به شبکه عصبی پیشخور معرفی شدند. اما در خصوص روش طبقه‌بندی بیشترین شباهت با توجه به ماهیت الگوریتمی که در آن استفاده می‌شود نمی‌توان بدین ترتیب عمل نمود و نیاز هست کلاس‌های غیرنفتی با هم ترکیب نگردند و بعد از انجام طبقه‌بندی بیشترین شباهت، کلاس‌ها با هم ادغام گردند. در صورتی که در روش بیشترین شباهت بخواهیم کلاس‌های غیرنفتی را ادغام کنیم باعث خواهد شد تنوع مقادیر ویژگی‌های کلاس غیرنفتی بالا باشد و در نتیجه آن تابع چگالی احتمال آن بسیار پهن گردد و این امر باعث خواهد شد که تمام پیکسل‌های تصویر بعنوان کلاس غیرنفتی طبقه‌بندی گردند. به همین دلیل، در این پژوهش، برای شبکه عصبی از روش دو کلاسه استفاده شده است اما برای روش بیشترین شباهت به تعداد کلاس‌های موجود در منطقه کلاس تعریف شده است و بعد از انجام طبقه‌بندی بیشترین شباهت، کلاس‌های غیرنفتی با هم ترکیب می‌گردند تا در نهایت تصویر منطقه بصورت دو کلاس خاک‌های الوده به چشمه نفتی و دیگر کاربری‌ها به دست آید. همچنین در این مرحله نیاز هست پارامترهای شبکه عصبی همانند نوع تابع



شکل ۷. پراکندگی چشمه های نفتی در نتیجه اعمال الگوریتم طبقه‌بندی بیشترین شباهت بر روی کل منطقه مطالعاتی

در شکل‌های ۶ و ۷، مقادیر یک یا چشمه‌های نفتی حاصل از طبقه‌بندی با رنگ قهوه‌ای تیره نشان داده شده است و سایر کاربری‌ها با رنگ خاکستری روشن نمایش داده شده است. لازم به ذکر است پیکسل‌هایی که به عنوان چشمه‌های نفتی در روش شبکه عصبی شناسایی شده‌اند به دلیل آنکه وسعت کمی را پوشش می‌دهند در شکل قابل مشاهده نبودند و در شکل ۶، برای مشاهده بهتر بزرگنمایی شدند.

همانطور که از تصویر طبقه‌بندی الگوریتم بیشترین شباهت در شکل ۷ مشخص است، بسیاری از نقاط به عنوان چشمه نفتی یا خاک‌های آلوده به نفت طبقه‌بندی شده است که با رنگ قهوه‌ای نشان داده شده است. در حالیکه در روش شبکه عصبی، تعداد نقاط بسیاری کمی به عنوان چشمه نفتی یا خاک‌های آلوده به نفت شناسایی شده است و کم بودن تعداد نقاط شناسایی شده توسط شبکه عصبی، بررسی این نقاط توسط تصاویر با قدرت تفکیک مکانی خیلی بالا را بسیار آسان می‌کند.

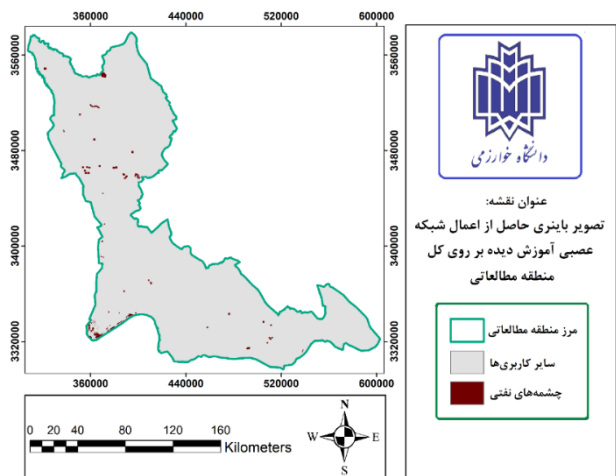
همچنین، مکان‌های مشخص شده توسط شبکه عصبی با تصاویر گوگل که قدرت تفکیک مکانی خیلی بالایی دارند بررسی شدند و ۱۵ نقطه جدید در منطقه به عنوان چشمه‌های نفتی شناسایی شدند که موقعیت آن‌ها در منطقه مطالعاتی با دایره‌های سبز رنگ در شکل ۸ نشان داده شده است. لازم به ذکر است که برای اطمینان از صحت موجودیت چشمه‌های نفتی نیاز هست که بررسی میدانی به عمل آید و صحت کشف چشمه‌های شناسایی شده تایید گردند که در این پژوهش به دلیل محدودیت‌های موجود از بررسی آن صرف‌نظر شده است.

$$kappa = \frac{N \sum_{n=1}^k x_{ii} - \sum_{n=1}^k (x_{i+} \times x_{+j})}{N^2 - \sum_{n=1}^k (x_{i+} \times x_{+j})}$$

که در آن N تعداد کل نمونه‌های موجود در ماتریس درهمی، K تعداد کاربری‌ها و x_{ii} تعداد مشاهدات در ردیف i و ستون i و x_{i+} و x_{+j} تعداد مشاهدات غیر قطری در ماتریس درهمی میباشد.

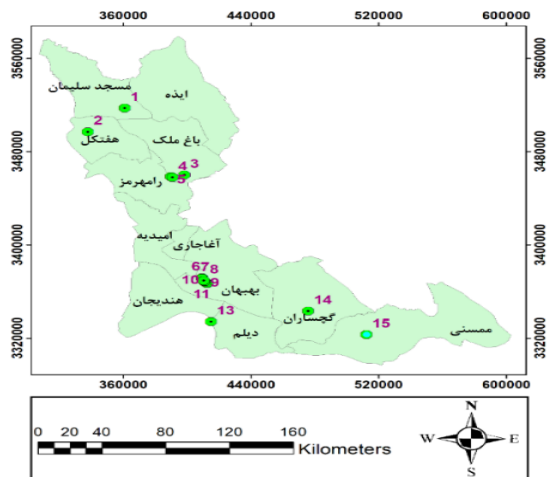
۳- نتایج و بحث

بعد از آموزش شبکه عصبی یا برآورد پارامترهای تابع چگالی احتمال در روش بیشترین شباهت و ارزیابی نتایج آن، مدل آموزش دیده بر روی ویژگی‌های کل منطقه مطالعاتی اعمال می‌گردد تا نتیجه شناسایی یا اکتشاف چشمه‌های نفتی به دست آید. خروجی نهایی هر دو روش شبکه عصبی و الگوریتم بیشترین شباهت یک تصویر طبقه‌بندی دو کلاسه یا یک تصویر باینری می‌باشد که به ترتیب در شکل‌های ۶ و ۷ نشان داده شده است و مقادیر یک در آن نشان دهنده مکان‌های احتمالی چشمه‌های نفتی موجود در منطقه مطالعاتی می‌باشد.



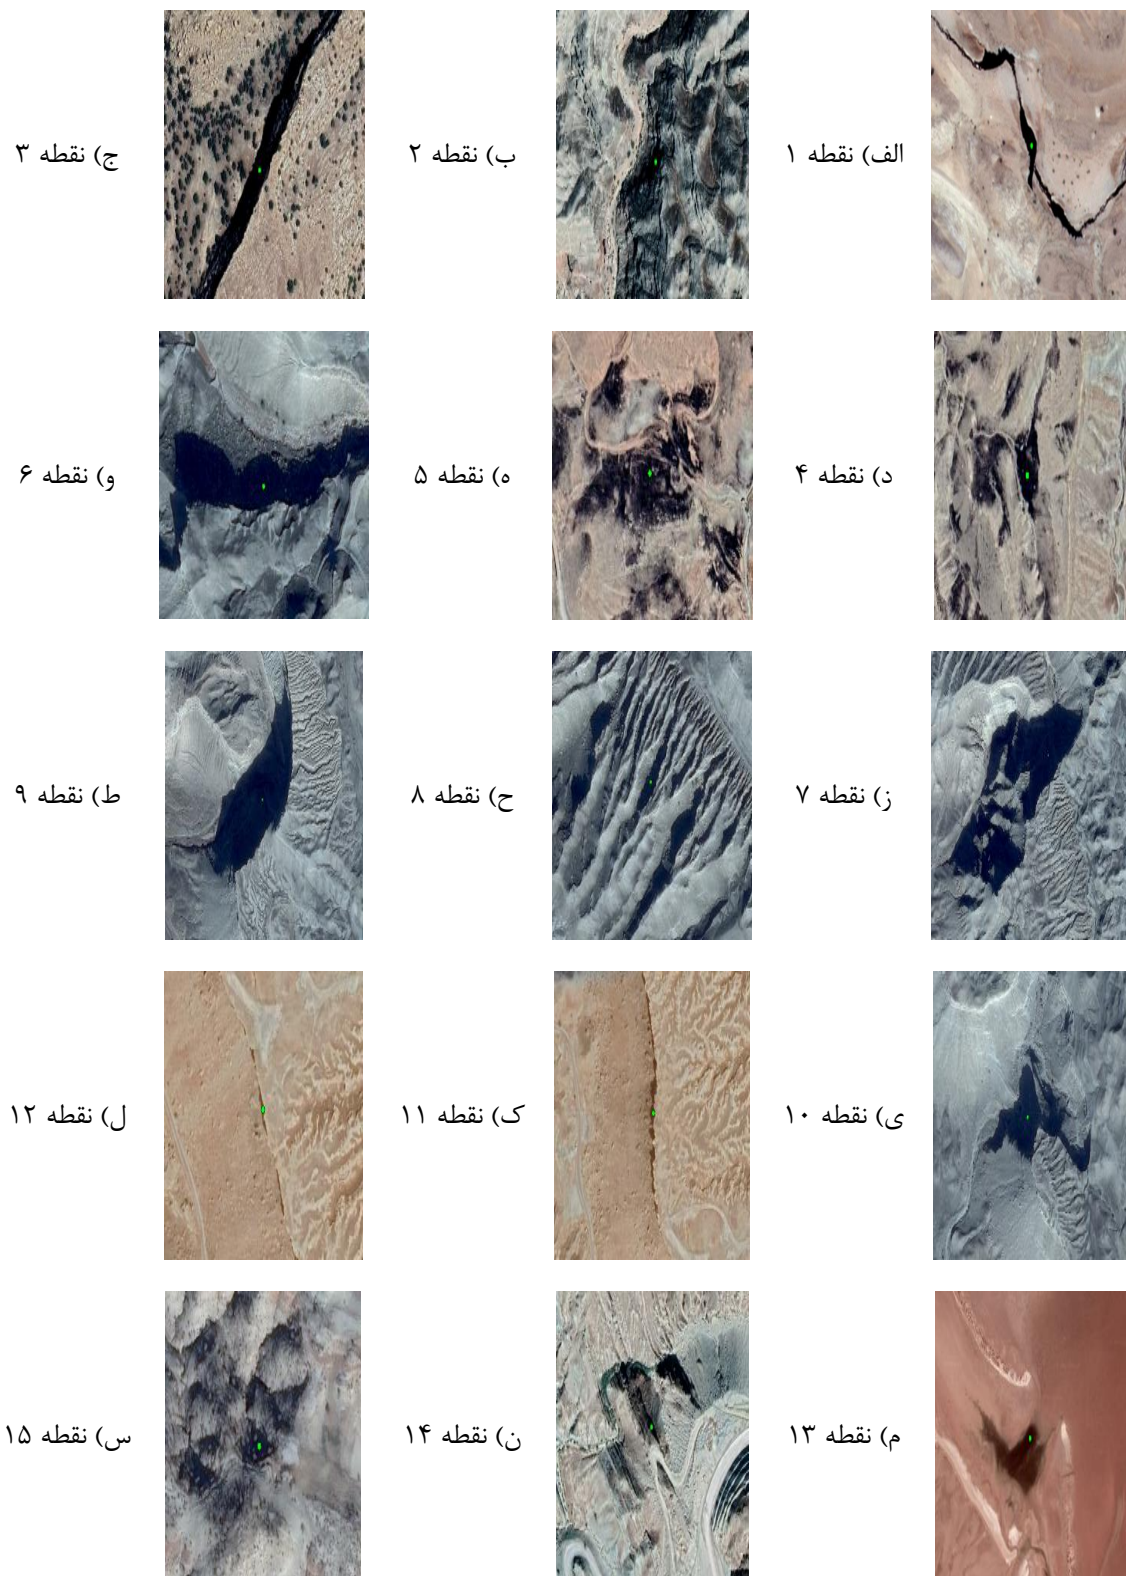
شکل ۶. پراکندگی چشمه های نفتی در نتیجه اعمال شبکه عصبی آموزش دیده بر روی کل منطقه مطالعاتی

شهرستان بهبهان شش چشمه نفتی شناسایی شده است. همچنین در شهرستانهای ایذه، امیدیه، آغاچاری و هندیجان چشمه نفتی شناسایی نشده است. این مطلب به معنای آن نمی باشد که در شهرستانهای ایذه، امیدیه، آغاچاری و هندیجان هیچ چشمه نفتی وجود ندارد بلکه منظور وجود چشمه های نفتی جدید و مازاد بر چشمه های شناسایی شده توسط وزارت نفت می باشد. به عبارت دیگر، در شناسایی چشمه های نفتی از چشمه های نفتی شناسایی شده توسط وزارت نفت صرف نظر شده است. چشمه های نفتی شناسایی شده و فواصل آنها از گسل های موجود در جدول ۴ مشاهده می شود. همچنین تصاویر گوگل ارث این ۱۵ چشمه نفتی شناسایی شده توسط شبکه عصبی در شکل ۹ نشان داده شده است. در شکل ۱۰ پراکندگی و موقعیت مکانی چشمه ها به نمایش در آمده است.



شکل ۸. موقعیت چشمه های نفتی احتمالی کشف شده توسط شبکه عصبی در منطقه مطالعاتی

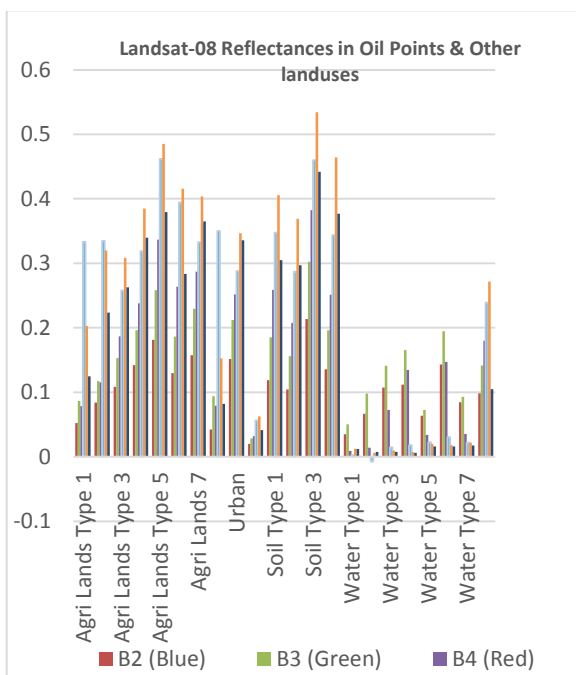
شکل ۸ نشان می دهد که در هر کدام از شهرستان های مسجد سلیمان، هفتکل، رامهرمز، دیلم، گچساران و ممسنی یک چشمه نفتی، در شهرستان باغ ملک دو چشمه نفتی و در



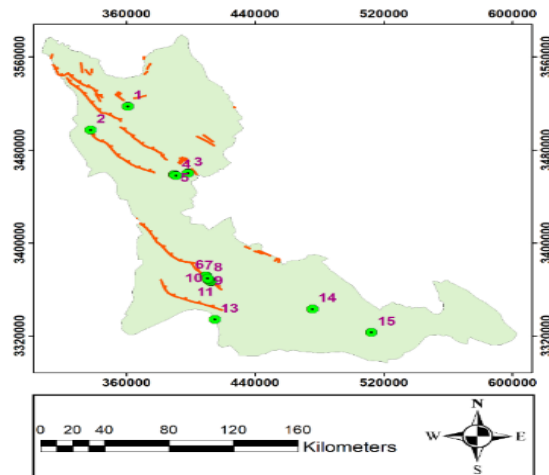
شکل ۹. تصاویر ماهواره‌ای برگرفته گوگل برای ۱۵ چشمه نفتی شناسایی شده توسط شبکه عصبی

(مادون قرمز موج کوتاه ۲ با طول موج های ۲۱۰۰ تا ۲۳۰۰ نانومتر) کاهش پیدا می کند. البته کاهش بازتاب در باند ۷ تصاویر لندست ۸ ابداء دور از انتظار نبود به دلیل آنکه در نمودار طیفی تصاویر هایپراسپکترال نیز در محدوده معادل باند ۷ لندست ۸ (۲۱۰۰ تا ۲۳۰۰ نانومتر)، بازتاب نسبت به محدوده ۱۶۰۰ نانومتر کاهش پیدا کرده است. علت این کاهش میتواند در اثر نزدیک بودن این باند به محدوده مادون قرمز حرارتی باشد. آلوده شدن خاک به نفت میتواند باعث کم شدن بازتاب خاک (پایین آوردن دمای خاک) در این محدوده از طیف شده باشد. این خود میتواند موجب تعریف شاخص جدیدی با استفاده از داده های این ناحیه از طیف الکترومغناطیس برای شناسایی منابع نفتی ظاهر شده در سطح باشد.

در شکل ۱۲، مقادیر بازتاب باندهای ۲ تا ۷ تصاویر لندست ۸ در چشمه های نفتی و دیگر کاربری ها نشان داده شده است. مطابق شکل ۱۲، در هفت نوع آب شناسایی شده در منطقه، مقادیر بازتاب تمامی باندها مخصوصا باندهای ۵ تا ۷ پایین می باشد و از همین مشخصه می توان برای جداسازی نفت و خاک های آلوده به نفت از آب ها استفاده نمود. در دیگر کاربری ها هم مقایسه مقادیر بازتاب چشمه های نفتی با کاربری مورد نظر باندهای مفید و به دنبال آن شاخص های مفید قابل استخراج می باشند. بعنوان مثال در کاربری باغ و درخت مقدار بازتاب باند ۵ بیشتر از باند ۶ می باشد در حالیکه این موضوع در نفت و خاک های آلوده به نفت برعکس می باشد.




شکل ۱۲. بازتاب باندهای ۲ تا ۷ تصاویر لندست ۸ در چشمه های نفتی و دیگر کاربری ها (طول موج های ۰/۴ تا ۲/۳ میکرومتر) (یافته های تحقیق)



شکل ۱۰. موقعیت مکانی چشمه های نفتی احتمالی کشف شده در منطقه مطالعاتی نسبت به گسل های منطقه (خطوط قرمز رنگ)

۳-۱- خصوصیات طیفی چشمه های نفتی

در شکل ۱۱، بازتاب چشمه های نفتی و خاک های آلوده به نفت در باندهای ۲ تا ۷ تصاویر لندست ۸ (طول موج های ۰/۴ تا ۲/۳ میکرومتر) نشان داده شده است. نمودار ارائه شده در شکل ۱۱، براساس میانگین مقادیر پیکسل های نمونه برداری شده از چشمه های نفتی شناسایی شده توسط وزارت نفت می باشد.



شکل ۱۱. بازتاب چشمه های نفتی در باند های ۲ تا ۷ تصاویر لندست ۸ (طول موج های ۰/۴ تا ۲/۳ میکرومتر) (یافته های تحقیق)

بازتاب چشمه های نفتی در تصاویر لندست ۸ به استثنای باند ۷، بازتاب چشمه های نفتی و خاک های آلوده به نفت و مواد هیدروکربوری با افزایش طول موج افزایش پیدا می کند و باند آبی (باند دوم لندست ۸) با کمترین طول موج، کمترین بازتاب را دارا می باشد و محدوده مادون قرمز موج کوتاه ۱ (باند ۶ با طول موج های ۱۵۶۰ تا ۱۶۶۰ نانومتر) بیشترین مقدار بازتاب را دارا می باشد و بعد از آن مقدار بازتاب به یکباره در باند ۷ لندست ۸

۴- بحث و نتیجه گیری

نتیجه گیری‌های مربوط به استخراج خصوصیات طیفی چشمه‌های نفتی و شناسایی و اکتشاف چشمه‌های نفتی در این پژوهش به شرح ذیل می‌باشد.

۸۵/۷۱٪ می‌باشد، این صحت بیانگر این است که در ۸۵/۷۱ درصد از داده‌های تست چشمه‌های نفتی به درستی بعنوان کلاس چشمه‌های نفتی برچسب گذاری شده است و ۱۴/۲۹ درصد از چشمه‌های نفتی در داده‌های تست بعنوان کلاس سایر کاربری‌ها برچسب‌گذاری شدند. به عبارت دیگر چشمه‌های نفتی بصورت کاملاً جامع شناسایی نشده‌اند اما جامعیت شناسایی چشمه‌های نفتی قابل قبول می‌باشد.

- در تصاویر لندست ۸ به استثنای باند ۷، بازتاب چشمه‌های نفتی و خاک‌های آلوده به نفت و مواد هیدروکربوری با افزایش طول موج افزایش پیدا می‌کند و باند آبی (باند دوم لندست ۸) با کمترین طول موج، کمترین بازتاب را دارا می‌باشد و محدوده مادون قرمز موج کوتاه ۱ (باند ۶ با طول موج‌های ۱۵۶۰ تا ۱۶۶۰ نانومتر) بیشترین مقدار بازتاب را دارا می‌باشد و بعد از آن مقدار بازتاب به یکباره در باند ۷ لندست ۸ (مادون قرمز موج کوتاه ۲ با طول موج‌های ۲۱۰۰ تا ۲۳۰۰ نانومتر) کاهش پیدا می‌کند.
- در چشمه‌های نفتی و خاک‌های آلوده به نفت، کاهش نسبتاً شدید مقدار بازتاب در باند SWIR2 نسبت به باند SWIR1 می‌تواند به عنوان یک مشخصه در شناسایی چشمه‌هایی نفتی به کار گرفته شود. در این خصوص ویژگی‌هایی همانند شاخص شوری تفاضلی نرمالایز شده (NDSI) که بر مبنای تفاضل نرمالایز شده باندهای SWIR1 و SWIR2 می‌باشد مفید هستند.
- مقادیر شاخص‌های TCW، NDWI، AWEI، GBNDVI و GRNDVI برای نقاط مربوط به چشمه‌های نفتی منفی می‌باشند و مابقی شاخص‌ها یا باندها در نقاط مربوط به چشمه‌های نفتی دارای مقادیر مثبتی هستند.
- در این پژوهش برای شناسایی و اکتشاف چشمه‌های نفتی توسط شبکه عصبی (ANNs)، از تابع آموزشی Trainlm و تعداد ۸ لایه پنهان استفاده شده است که نتایج آن قابل قبول می‌باشد.
- روش شبکه عصبی مصنوعی (ANNs) در صورتی که با نمونه‌های مناسب و کافی آموزش داده شود می‌تواند بعنوان روشی موفق در شناسایی و اکتشاف چشمه‌های نفتی با صحت بالا به کار گرفته شود. بطوریکه در این پژوهش، مقادیر ضریب کاپا و صحت کلی اکتشاف چشمه‌های نفتی و خاک‌های آلوده به نفت توسط شبکه عصبی به ترتیب برابر با ۹۲/۰۷٪ و ۹۹/۵۱٪ می‌باشند.
- در اکتشاف چشمه‌های نفتی توسط روش شبکه عصبی، صحت کاربر برابر با ۱۰۰٪ می‌باشد اما صحت تولیدکننده

- در اکتشاف چشمه‌های نفتی توسط روش طبقه‌بندی بیشترین شباهت (MLC)، صحت تولیدکننده برای خاک‌های آلوده به چشمه نفتی برابر با ۹۹/۵۲٪ می‌باشد، اما صحت کاربر برای چشمه‌های نفتی بسیار پایین و برابر با ۱۸/۱۱٪ می‌باشد. همین امر باعث شده است بسیاری از نقاط مربوط به سایر کاربری‌ها نیز بعنوان چشمه نفتی طبقه‌بندی شده است و عملاً شناسایی چشمه‌های نفتی توسط روش طبقه‌بندی بیشترین شباهت ممکن نباشد.
- بررسی پراکندگی چشمه‌های نفتی کشف شده در منطقه مطالعاتی نسبت به گسل‌های منطقه نشان داد که ۱۲ مورد از ۱۵ چشمه نفتی کشف شده توسط شبکه عصبی در نزدیکی گسل‌ها قرار دارند.
- تصاویر لندست ۸ به دلیل آنکه تمام سطح کره زمین را پوشش می‌دهند می‌توانند در بررسی مناطقی که توسط داده‌های هایپراسپکترال پوشش داده نمی‌شود به کار گرفته شود. همچنین هر Scene از تصاویر لندست ۸ وسعت بسیار بیشتری را نسبت به سنجنده‌های هایپراسپکترال پوشش می‌دهند در پایش سریع منطقه می‌توانند مفید باشند.

منابع

1. Sayedain, S. A.; 2013; "Exploration of Oil Seepages (Hydrocarbon) Using Target Detection Algorithms in Hyperspectral Images", M.Sc, K.N. Toosi University of Technology.
2. Van Der Meer, F., P. Van Dijk, H. Van Der Werff and H. Yang; 2002; "Remote sensing and petroleum seepage: a review and case study" , Terra Nova, 14(1): 1-17.
3. Segal, D. B., M. D. Ruth, I. S. Merin, H. Watanabe, K. Soda, O. Takano and M. Sano; 1985; "Remote Detection of Anomalous Mineralogy Associated with Hydrocarbon Production", Lisbon Valley, Utah: ABSTRACT, Mountain Geology, 23(2): 51-62
4. Ellis, J. M., H. H. Davis and J. A. Zamudio, 2001; "Exploring for onshore oil seep.", Oil and Gas

- Amon.; 2021; "The surface expression of hydrocarbon seeps characterized by satellite image spectral analysis and rock magnetic data (Falcon basin, western Venezuela)", Journal of South American Earth Sciences, Volume 106, 103036.
13. Jinru, X. and B. Su; 2017; "Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications", Journal of Sensors, 2017: 1-17.
 14. Rasul, A., H. Balzter, G. R. F. Ibrahim, H. M. Hameed, J. Wheeler, B. Adamu, S. a. Ibrahim and P. M. Najmaddin; 2018; "Applying built-up and bare-soil indices from Landsat 8 to cities in dry climates", Land 7(3): 81.
 15. Sukmono, A., A. Nugraha and H. Firdaus; 2019; "Integration of Leaf Water Content Index (LWCI) and Enhanced Vegetation Index (EVI) for Stress Detection of Rice Plant Using Landsat 8 Satellite Imagery", KnE Engineering.
 16. Yan, D., C. Huang and Y. Zhang; 2020; "Improved Landsat-Based Water and Snow Indices for Extracting Lake and Snow Cover/Glacier in the Tibetan Plateau", Water 12.
 17. Jackson, R. D.; 1983; "Spectral indices in N-Space.", Remote Sensing of Environment, 13(5): 409-421.
 18. Crist, E. P. and R. J. Kauth; 1986; "The Tasseled Cap de-mystified", Photogrammetric Engineering and Remote Sensing, 52: 81-86.
 19. Ali, S. M. and S. S. Salman; 2016; " Landsat-8 (OLI) classification method based on tasseled cap transformation features", 2016 Al-Sadeq International Conference on Multidisciplinary in IT and Communication Science and Applications (AIC-MITCSA), Baghdad.
 20. Jensen, "Introductory Digital Image Processing: A Remote Sensing Perspective, 4th edition. 2015; Pearson series in geographic information science. Journal, 99(37): 49-58.
 5. Xu, D., G. Ni, T. Jiang, L. Jiang and M. Chi; 2007; "Integration of field work and hyperspectral data for oil and gas exploration", IEEE International Geoscience and Remote Sensing Symposium.
 6. Khan, S. and S. Jacobson (2008). "Remote sensing and geochemistry for detecting hydrocarbon micro-seepages." Geological Society of America Bulletin 120: 95-105
 7. Lammogliaa, T. and C. R. S. Filhoa; 2008; "Characterization of Hydrocarbon Micro seepages in the Tucano Basin, (Brazil) through Hyperspectral Classification and Neural Network Analysis of Advanced Space-borne Thermal Emission and Reflection Radiometer (ASTER) Data.", The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences.
 8. Perry, S. L., F. A. Kruse and C. Carlston; 2011;" Evidence of Hydrocarbon Seepage Using Multispectral Satellite Imagery, Kurdistan, Iraq., 73rd EAGE Conference and Exhibition-Workshops 2011, European Association of Geoscientists & Engineers.
 9. Hamzeh, M.; 2011; "Identification of Oil Seepages Using Hyperspectral Images", Case Study: Khuzestan Province. M.Sc., University of Tehran.
 10. Shi, P., B. Fu, Y. Ninomiya, J. Sun and Y. Li; 2012; "Multispectral remote sensing mapping for hydrocarbon seepage-induced lithologic anomalies in the Kuqa foreland basin, south Tian Shan", Journal of Asian Earth Sciences, 46: 70-77.
 11. Dehban Varmazani, M.; 2016; "Identification of oil pollution area in Khuzestan using multispectral and thermal landsat image and Fieldspec3 Spectroradiometer", M.Sc, Shahid Chamran University of Ahvaz.
 12. Roberto De la Rosa, Milagrosa Aldana, Vincenzo Costanzo-Alvarez, Santiago Yopez, Cristina