

Research Paper



The effectiveness of Random Tree Algorithm (RTC), Maximum Likelihood (MLC), and Support Vector Machine (SVM) models in detecting changes in the water area of Lake Neor and the effects of these changes on the surface temperature using the LST model in the 2002-2022 period



Mehdi Feyzolahpour^{1*}



This paper is an open access and licenced under the CC BY NC licence.



DOI:10.22034/hyd.2023.58342.1706

Reference to this article: Feyzolahpour, Mehdi. (2023). Paper Title Investigating the effectiveness of Random Tree Algorithm (RTC), Maximum Likelihood (MLC) and Support Vector Machine (SVM) models in detecting the changes in the water area of Lake Neor and the effect of these changes on the surface temperature using the LST model in the period from 2002 to 2022. *Hydrogeomorphology*, 11(40): 1–21.

Keywords

Random Tree, Maximum likelihood, Support vector Machine, LST, Neor Lake, Northwest of Iran

Receive Date: 2023/09/08

Accept Date: 2023/12/25

Available: 2024/10/21

ABSTRACT

Changes in land cover and land use due to human activities have left adverse effects on the environment. The eastern regions of Ardabil province are a clear example of this phenomenon. The purpose of this research is to analyze spatial and temporal changes in land cover and land use and its effects on the temperature of the surface of the earth in Lake Neor. To estimate land use and land cover, random forest models (RTC), maximum likelihood model (MLC) and support vector machine (SVM) were used and the efficiency of each was estimated by the Kappa coefficient and it was observed that the SVM model has the highest Kappa coefficient (0.87). Bands 6, 5 and 10 of Landsat 8 were also used to extract the LST index, and it was observed that the western part of the lake faced an increase in the temperature of the earth's surface. During the time period of 2002, 2013 and 2022, significant changes were observed in the water area of Neor Lake and its nearby vegetation. Barren lands had the largest extent in all studied periods. Vegetation has increased by 1.04 square kilometers based on SVM model. The surface area of the lake was estimated as 3.19 square kilometers based on the MLC model in 2002. The area of the water zone in the MLC model has decreased by 1.56 square kilometers between 2002 and 2022, and this decrease is 0.67 and 0.69 square kilometers for the RTC and SVM models, respectively.

* Corresponding Author: Mehdi Feyzolahpour

E-mail: feyzolahpour@znu.ac.ir

1. Assistant Professor, Department of Geography, Zanjan University

Extended Abstract

Introduction

The use of classification methods is one of the widely used cases of using remote sensing data. Each classification method achieves different results. The maximum likelihood method and minimum distance are among the most common classification methods. A major weakness of these methods is that it is difficult to distinguish a complication that has a small spectral effect difference compared to other complications. These problems have led to the creation of newer methods. The artificial neural network, support vector machine algorithm, random forest, and maximum likelihood are some of the methods presented nowadays.. One of the most widely used methods in the separation of satellite images is the Support Vector Machine (SVM) method presented by Vapnik (1992). In this method, the classification of data is linear, and the line with the largest margin is used to divide the data. Accordingly, this research investigates the changes that occurred in the surrounding environment of Lake Neor using three methods, namely the SVM algorithm, maximum likelihood classification, and random tree, and the efficiency of each was evaluated using the Kappa coefficient. Moreover, temperature changes were identified using the LST index in the 2002-2022 period.

Methodology

In this research, the Maximum Likelihood (MLC), Random Tree (RTC), and SVM methods were used to investigate changes in both the water area of Neor Lake and in the cover and use of its surrounding environment. To investigate the use of the LST index, the Landsat 5 satellite images on July 14, 2002, and Landsat 8 on July 28, 2013, and July 13, 2022, were downloaded from the US Geological Survey website. Seven bands of each image were combined and trained in the calculations of learning algorithms. Through the trained values, the area was divided into three uses: water area, vegetation, and wasteland, and analyzed in the relevant algorithms to obtain the output map.

Results and Discussion

In the RTC random forest model, the area of the water zone in 2002 was equal to 3.53 km², which was reduced to 2.86 km² in 2022. The area of vegetation increased from 2.29 km² in 2002 to 3.85 km² in 2022. The area of barren lands was accompanied by a slight decrease and reached from 12.61 km² in 2002 to 11.71 km² in 2022. This type of land use occupies the largest area in the study area. Using SVM as the last learning algorithm in this research, the area of the blue zone in 2002 was estimated to be about 3.5 km², which is very similar to the values obtained by the random forest model in the same year. In 2022, this type of land use has an area equal to 2.81 km², which is only 0.05 km² different from the value obtained with the random forest model. The vegetation of this area was equal to 2.42 and 3.46 km² in 2002 and 2022, respectively. Finally, the last type of land use, which is devoted to barren land, has the largest area and shows the least change from 12.5 km² in 2002 to 12.15 km², which shows a very slight decrease. Based on each index, the estimated surface temperature values indicated that the minimum and maximum temperature values were 14.24 and 39.92 °C, respectively, on July 14, 2002, which was the lowest temperature recorded on the surface of the lake. On July 28, 2013, the minimum and maximum temperatures were 17.42 and 40.9 °C, and the minimum temperature showed an increase of 3.18 °C compared to 2002. It can be seen that the western part of Neor Lake has faced an increase in temperature.

Conclusions

Various methods have been proposed to investigate land use and land cover changes, including SVM, random forest, and maximum likelihood models. Therefore, the above methods were used in this research to estimate the trend of land use changes in the area of Lake Neor for the years 2002, 2013, and 2022. The results showed significantly similar values estimated by the SVM and random forest models. For example, the amount of water area in 2002 in the SVM model was equal to 3.5 km², which was estimated to be equal to 3.53 km² in the random forest model, with a difference of only 0.03 km², while the model estimated the maximum probability of this amount to be about 3.19 km². The water area decreased and the vegetation increased in all models, and the largest increase was observed on the southern shore of the lake. Barren lands with the largest area have seen the least changes. The results show that the surface of the Neor Lake is decreasing in the southwest and northeast parts.



بررسی کارایی مدل های الگوریتم جنگل تصادفی (RTC)، حداکثر احتمال (MLC) و ماشین بردار پشتیبانی (SVM) در تشخیص تغییرات پهنه آبی دریاچه نئور و تاثیر این تغییرات در دمای سطح زمین با استفاده از مدل LST در بازه زمانی ۲۰۰۲ تا ۲۰۲۲



مهدی فیض اله پور *



این مقاله به صورت دسترسی باز و با لایسنس CC BY NC کپی‌رایتو کامانز قابل استفاده است.



ارجاع به این مقاله: مهدی فیض اله پور، (۱۴۰۲). بررسی کارایی مدل های الگوریتم جنگل تصادفی (RTC)، حداکثر احتمال (MLC) و ماشین بردار پشتیبانی (SVM) در تشخیص تغییرات پهنه آبی دریاچه نئور و تاثیر این تغییرات در دمای سطح زمین با استفاده از مدل LST در بازه زمانی ۲۰۰۲ تا ۲۰۲۲. هیدروژئومورفولوژی، ۱۱ (۴۰): ۱- 21.

DOI:10.22034/hyd.2023.58342.1706



چکیده

تغییرات پوشش و کاربری زمین در اثر فعالیت های انسانی تأثیرات نامطلوبی بر محیط زیست بر جای گذاشته است. مناطق شرقی استان اردبیل نمونه بارز این پدیده به شمار می آید. هدف از این تحقیق تجزیه و تحلیل تغییرات مکانی و زمانی در پوشش و کاربری زمین و اثرات آن بر دمای سطح زمین در دریاچه نئور می باشد. برای برآورد کاربری و پوشش زمین از مدل های جنگل تصادفی (RTC)، مدل حداکثر احتمال (MLC) و ماشین بردار پشتیبانی (SVM) استفاده شده و کارایی هر کدام توسط ضریب کاپا برآورد گردیده و مشاهده شد که مدل SVM از بیشترین میزان ضریب کاپا (۰/۸۷) برخوردار است. برای استخراج شاخص LST نیز از باندهای ۶ لندست ۵ و ۱۰ لندست ۸ بهره گرفته شده و مشاهده شد که بخش غربی دریاچه با افزایش دمای سطح زمین مواجه گردیده است. در طول دوره زمانی ۲۰۰۲، ۲۰۱۳ و ۲۰۲۲ تغییرات قابل توجهی در پهنه آبی دریاچه نئور و پوشش های گیاهی مجاور آن مشاهده شد. زمین های بایر بیشترین وسعت را در تمام دوره های مورد مطالعه داشته است. پوشش گیاهی بر اساس مدل SVM حدود ۱/۰۴ کیلومتر مربع افزایش یافته است. مساحت سطح دریاچه بر اساس مدل MLC در سال ۲۰۰۲ معادل ۳/۱۹ کیلومتر مربع برآورد گردید. مساحت پهنه آبی در مدل MLC در بازه زمانی ۲۰۰۲ تا ۲۰۲۲ حدود ۱/۵۶ کیلومتر مربع کاهش یافته و این میزان کاهش برای مدل های RTC و SVM به ترتیب معادل ۰/۶۷ و ۰/۶۹ کیلومتر مربع می باشد.

کلیدواژه‌ها

جنگل تصادفی، حداکثر احتمال، ماشین بردار پشتیبانی، LST، دریاچه نئور، شمال غرب ایران

تاریخ دریافت: ۱۴۰۲/۰۶/۱۷

تاریخ پذیرش: ۱۴۰۲/۰۹/۰۴

تاریخ انتشار: ۱۴۰۳/۰۷/۳۰

* نویسنده مسئول: مهدی فیض اله پور
رایانامه: feyzolahpour@znu.ac.ir

۱- استادیار گروه جغرافیا، دانشگاه زنجان

مقدمه

تغییر کاربری اراضی به معنای تغییر یک بخش از زمین برای اهداف مشخص بوده و ناشی از فعالیت های انسانی می باشد در حالیکه تغییر پوشش زمین، ویژگی های سطح زمین را توصیف می کند (پاتل^۱ و همکاران، ۲۰۱۹: ۶). تغییرات مداوم محیطی و اثرات نامطلوب مرتبط با آن، در حال تبدیل شدن به بحرانی مهم در سطح جهانی می باشد (لی^۲ و همکاران، ۲۰۲۰: ۱۳۴). تغییر LULC توسط ترکیبی از علل مختلف ایجاد می شود. عامل اول مربوط به فعالیت های انسانی بوده و عامل دوم در ارتباط با مسائل اجتماعی، اقتصادی و سیاسی می باشد. فعالیت های انسانی، نیروهای محرک اصلی تغییرات فضایی در مقیاس های مختلف به شمار می آیند (دامتیا^۳ و همکاران، ۲۰۲۰: ۶۸، هاسن^۴ و همکاران، ۲۰۱۷: ۱۲۲، بوکایی^۵ و همکاران، ۲۰۱۶: ۹۹، هگازی^۶ و همکاران، ۲۰۱۵: ۱۲۲). تغییرات کاربری و پوشش زمین اثرات منفی را در مقیاس محلی تا جهانی به همراه داشته است. لی^۷ و همکاران (۲۰۲۰) تاثیرات آن را بر محیط زیست جهانی، تغییر اقلیم و توسعه پایدار گزارش کرده اند. هاسن^۸ و اسان (۲۰۱۷) در تحقیقات خود چنین عنوان کردند که مشکلات مرتبط با فرسایش خاک، وخامت کیفی خاک و کمبود آب با تغییرات LULC در ارتباط هستند. تاثیرات این عامل بر اکوسیستم ها و تنوع زیستی و تخریب سکونتگاه ها توسط دینکا^۹ و چاکا (۲۰۱۹) و پاتل^{۱۰} و همکاران (۲۰۱۹) گزارش شده است. تغییر پوشش و کاربری زمین باعث تخریب زمین و شبکه های آبراهه ای شده و بر دمای سطح زمین تاثیر می گذارد (دامتیا و همکاران، ۲۰۲۰: ۶۶، بلای^{۱۱} و همکاران، ۲۰۱۹: ۳۳، کیکان^{۱۲} و همکاران، ۲۰۱۶: ۲۴، پال و زیال^{۱۳}، ۲۰۱۷: ۱۳۰). از این رو، تشخیص تغییر کاربری و پوشش زمین و نیروهای محرک آن برای حفاظت از محیط زیست، مدیریت منابع، برنامه ریزی کاربری زمین، توسعه اجتماعی و اقتصادی و توسعه پایدار حائز اهمیت می باشد (آلمو^{۱۴} و همکاران، ۲۰۱۹: ۸۲). دمای سطح زمین (LST) اشاره به دمای تابشی پوسته سطح زمین دارد. این شاخص، یک پارامتر مهم در توصیف ریز اقلیم و انتقال تشعشع اتمسفر به شمار می آید (راجندریان و مانی^{۱۵}، ۲۰۱۵: ۲۱). شاخص LST ارتباط قابل توجهی نیز با عوامل هیدرولوژیکی، تغییرات آب و هوایی، تنوع زیستی، ارزیابی رطوبت خاک و اراضی زراعی، ارزیابی بلایای طبیعی و تغییرات کاربری اراضی دارا می باشد (راجانی و وارا داراجان^{۱۶}، ۲۰۲۱: ۶۱۲). نظارت بر تغییرات مکانی و زمانی پوشش و کاربری زمین و دمای سطح زمین با استفاده از فناوریهای سنجش از دور در حال تبدیل شدن به یک موضوع تحقیقاتی مهم در سطح جهانی است (آلمو^{۱۷} و همکاران، ۲۰۱۹: ۸۱).

استفاده از روش های طبقه بندی یکی از موارد پر کاربرد استفاده از داده های سنجش از دور می باشد. هر روش طبقه بندی به نتایج متفاوتی دست می یابد (گایو^{۱۸} و همکاران، ۲۰۱۲: ۵۳۶). روش حداکثر احتمال و کمترین فاصله از متداول ترین روش های طبقه بندی به شمار می روند. بزرگترین ضعف این روش ها در این است که اگر یک عارضه از اختلاف اثر طیفی کمی نسبت به سایر عوارض برخوردار باشد تفکیک آن با مشکل همراه است (هاردو ۱۹۸۲: ۳۴). این مشکلات باعث ایجاد روش های جدیدتری شده است. امروزه روش هایی مانند روش شبکه عصبی مصنوعی، الگوریتم ماشین بردار پشتیبانی، جنگل تصادفی و حداکثر احتمال ارائه شده اند. هر الگوریتم طبقه بندی روش های مخصوص خود را داشته و به نتایج متفاوتی دست می یابد. یکی از پر کاربردترین روش ها در تفکیک تصاویر ماهواره ای روش ماشین بردار پشتیبانی یا SVM می باشد. این روش در سال ۱۹۹۲ به وسیله واپنیک ارائه گردید (واپنیک^{۱۹}، ۱۹۹۵: ۲۳). در این روش طبقه بندی داده ها به صورت خطی بوده و در تقسیم داده ها از خطی استفاده می شود که دارای بیشترین حاشیه می باشد. در صورتی که داده ها را نتوان به صورت خطی از یکدیگر جدا نمود از توابع کرنل بهره گرفته می شود. این روش در مواردی مانند زمین شناسی، کشاورزی و تعیین کاربری اراضی به کار گرفته شده است (مونتراکیس^{۲۰} و همکاران، ۲۰۱۱: ۸۲، عابدی و همکاران، ۲۰۱۲).

1 Patel et al
2 Li et al
3 Damtea et al
4 Hassen et al
5 Bokaie et al

6 Hegazy
7 Li et al,
8 Hassen et al
9 Dinka et al
10 Patel et al

11 Belay
12 Kikon
13 Pal and Ziaul
14 Alemu
15 Rajendran and Mani

16 Rajani and
Varadarajan
17 Alemu
18 Geo
19 Vapnik
20 Mountrakis

گرانیان^۱ و همکاران، ۲۰۱۶: ۳۳). استفاده از این روش در تحلیل تصاویر ماهواره ای به سرعت در حال افزایش است (جیانگ^۲ و همکاران، ۲۰۱۱: ۳۱۷، هوانگ^۳ و همکاران، ۲۰۰۲: ۷۳۰، کمپول^۴ و همکاران، ۲۰۱۰: ۵۹۲، اوومن^۵ و همکاران، ۲۰۰۸: ۴۱۳). در ایران تحقیقات مختلفی در زمینه استفاده از روش های الگوریتم یادگیری انجام شده است. اسلمی و همکاران (۱۳۹۴) برای بررسی پوشش و کاربری زمین از روش های ماشین بردار پشتیبانی و شبکه عصبی مصنوعی استفاده کردند. بررسی ها نشان داد که هر دو روش از میزان صحت قابل قبولی برخوردار هستند. شنایی و زارعی (۱۳۹۵) از روش حداکثر احتمال، ماشین بردار پشتیبانی و شبکه عصبی مصنوعی برای تهیه نقشه کاربری اراضی استفاده نمودند. نتایج نشان داد که مدل های فوق به نحوی از درصد صحت قابل قبول برخوردار هستند. جهانبخشی و همکاران (۱۳۹۷) قابلیت های مدل حداکثر احتمال، جنگل تصادفی و ماشین بردار پشتیبانی را در زمینه کاربری اراضی مورد بررسی قرار دادند. نتایج نشان داد که مدل ماشین بردار پشتیبانی نسبت به سایر مدل ها به نتایج بهتری دست یافته است. عبدلی و همکاران (۱۳۹۹) روش ماشین بردار پشتیبانی را با مدل شبکه عصبی مصنوعی مقایسه کرده و مشاهده کردند که مدل ماشین بردار پشتیبانی با برخورداری از ضریب کاپای بالاتر به نتایج بهتری دست یافته است.

با توجه به موارد اشاره شده، در این تحقیق برای بررسی تغییرات رخ داده در محیط پیرامونی دریاچه نور از سه روش الگوریتم ماشین بردار پشتیبانی، طبقه بندی حداکثر احتمال و درخت تصادفی استفاده شده و کارایی هر کدام با استفاده از ضریب کاپا مورد بررسی قرار گرفته و با بهره گیری از شاخص LST تغییرات دمایی در بازه زمانی ۲۰۰۲ تا ۲۰۲۲ مورد شناسایی قرار گرفت.

مواد و روش ها

دریاچه نور در عرض شمالی ۳۷ درجه و ۵۵ دقیقه و ۳۰ ثانیه تا ۳۸ درجه و یک دقیقه و طول شرقی ۴۸ درجه و ۳۲ دقیقه تا ۴۸ درجه و ۳۶ دقیقه و ۳۰ ثانیه در فاصله ۴۸ کیلومتری جنوب شرقی شهر اردبیل واقع شده است. ارتفاع این دریاچه از سطح دریا معادل ۲۴۸۰ متر بوده و در ارتفاعات باغوداغ قرار گرفته است. مساحت این دریاچه بین ۲۱۰ تا ۲۴۰ هکتار در نوسان بوده است. آب این دریاچه شیرین بوده و عمق متوسط آن ۳ متر می باشد.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی


1 Granian

3 Huange

5 Oommen

2 Jiange


4 Campvalls




شکل (۱): موقعیت منطقه مورد مطالعه در محدوده دریاچه نئور

Figure (1): Location of the studied area in the Neor Lake area

در این تحقیق برای بررسی تغییرات پهنه آبی دریاچه نئور و تغییر پوشش و کاربری محیط پیرامونی آن از سه روش حداکثر احتمال (MLC)، درخت تصادفی (RTC) و ماشین بردار پشتیبانی (SVM) استفاده شده و تاثیر این تغییرات بر دمای سطح زمین با استفاده از شاخص LST مورد بررسی قرار گرفت. به این منظور تصاویر روزهای ۱۴ جولای ۲۰۰۲ ماهواره لندست ۵ و روزهای ۲۸ جولای ۲۰۱۳ و ۱۳ جولای ۲۰۲۲ ماهواره لندست ۸ از سایت سازمان زمین شناسی آمریکا دانلود گردید. در محاسبات مربوط به الگوریتم های یادگیری، ۷ باند هر تصویر با یکدیگر ترکیب شده و آموزش داده شدند.





شکل (۲): تصاویر رنگی کاذب حاصل از ترکیب باندهای ۷ گانه در سالهای ۲۰۰۲، ۲۰۱۳ و ۲۰۲۲

Figure (2): False color images resulting from the combination of 7 bands in the years 2002, 2013 and 2022

از طریق مقادیر آموزش داده شده منطقه به سه کاربری پهنه آبی، پوشش گیاهی و زمین بایر تقسیم شده و در الگوریتم های مربوطه مورد تحلیل قرار گرفته و نقشه خروجی به دست آمد. باندهای مورد استفاده در جدول زیر نمایش داده شده است. مدل های مورد استفاده در این تحقیق در ادامه مورد تشریح قرار گرفتند.

جدول (۱): خصوصیات باندهای استفاده شده از ماهواره های لندست ۵ و ۸

Table (1): Characteristics of the bands used by Landsat 5 and 8 satellites

سنجنده	تاریخ تصویربرداری	باند	توان تفکیک	طول موج
TM لندست ۵	۲۰۰۲/۰۷/۱۴	باند ۱	۳۰ متر	آبی
		باند ۲	۳۰ متر	سبز
		باند ۳	۳۰ متر	قرمز
		باند ۴	۳۰ متر	مادون قرمز نزدیک
		باند ۵	۳۰ متر	مادون قرمز موج کوتاه
		باند ۶	۱۲۰ متر	حرارتی
		باند ۷	۳۰ متر	مادون قرمز موج کوتاه
OLI لندست ۸	۲۰۱۳/۰۷/۲۸	باند ۱	۳۰ متر	گرد و غبار، ساحل
		باند ۲	۳۰ متر	آبی
	۲۰۲۲/۰۷/۱۳	باند ۳	۳۰ متر	سبز
		باند ۴	۳۰ متر	قرمز
		باند ۵	۳۰ متر	مادون قرمز نزدیک
		باند ۶	۳۰ متر	مادون قرمز موج کوتاه
		باند ۷	۳۰ متر	مادون قرمز موج کوتاه
		باند	۱۰۰ متر	حرارتی

مدل SVM یک سیستم یادگیری تحت نظارت بوده و بر اساس پیشرفت های اخیر در نظریه یادگیری آماری استوار است (کریستیان و شاو، ۲۰۰۰: ۷۱). کورتز او واپینک (۱۹۹۵) مدل SVM را برای طبقه بندی های باینری توسعه دادند. برخی از تحقیقات بر روی توابع ریاضی مدل SVM متمرکز شده اند. این مدل طبقات را به سطوح تصمیم گیری تقسیم کرده و مرز بین طبقات را به حداکثر می رساند. بردارهای پشتیبانی از عناصر مهم مجموعه آموزشی به شمار می آیند (بوسر و همکاران، ۱۹۹۲: ۱۴۹، فودی و همکاران، ۲۰۰۷: ۱۷۳۸). برای اجرای SVM، داده های آموزشی مورد نیاز است. این داده ها فرایند جداسازی طبقات را بهینه سازی می کنند (فودی و ماتر، ۲۰۰۶: ۱۸۴). با استفاده از یک تابع پایه شعاعی (RBF)، پراکنش طبقات با محدوده های غیرخطی را می توان در یک محدوده جدا شده خطی ترسیم نمود (هوانگ و همکاران، ۲۰۰۲: ۷۳۲). آموزش SVM با RBF مستلزم تنظیم دو پارامتر است. یکی از این پارامترها، پارامتر منظم سازی است که تعادل بین به حداکثر رسانی حساسیت حواشی و به حداقل رساندن خطای آموزشی را برقرار کرده و کنترل می کند.

پارامتر تنظیم کننده کوچک تمایل به تاکید بر حواشی و نادیده گرفتن نقاط پرت در داده های آموزشی دارد. پارامتر منظم سازی بزرگ ممکن است با داده های آموزشی بیشتری مطابقت داشته باشد. شرح جامع پارامترهای SVM را می توان در نوشته های کریستیان و شاو (۲۰۰۰) و بورگز (۱۹۹۸) مشاهده نمود. طبقه بندی SVM شامل چهار نوع خطی، چند جمله ای، RBF و سیگموئید می باشد. نوع RBF در بیشتر موارد به خوبی عمل می کند. ساختار ریاضی این چهار نوع در معادلات زیر نشان داده شده است.

$$\begin{aligned} k(x_i, x_j) &= x_i^t x_j & \text{خطی (۱)} & (۱) \\ k(x_i, x_j) &= (\gamma x_i^t x_j + r)^d, \gamma > 0 & \text{چند جمله ای (۲)} & (۲) \\ k(x_i, x_j) &= \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0 & \text{نوع RBF (۳)} & (۳) \\ k(x_i, x_j) &= \tan h(\gamma x_i^t x_j + r) & \text{نوع سیگموئید (۴)} & (۴) \end{aligned}$$

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

روش حداکثر احتمال MLC یک روش مبتنی بر طبقه بندی نظارت شده است که از تئوری بایاس ریشه گرفته و احتمال وابستگی یک پیکسل را به یک طبقه معین نشان می دهد. به این منظور از معادله زیر بهره گرفته می شود:

$$P(i|W) = \frac{P(Wi)P(i)}{P(W)} \quad (۵)$$

در این معادله $P(Wi)$ و $P(i)$ تابع احتمالاتی و احتمال وقوع i در منطقه مورد مطالعه بوده و $P(W)$ احتمال مشاهده W می باشد. برای محاسبه $P(W)$ از معادله زیر استفاده می شود.

$$P(W) = \sum_{i=1}^M P(Wi)P(i) \quad (۶)$$

در این معادله M ، تعداد طبقات را نشان داده و فاکتور $P(W)$ ضریب ثابتی است که برای نرمال سازی مورد استفاده قرار می گیرد. بر اساس رابطه زیر، پیکسل x در طبقه i واقع می شود.

$$x \in i \text{ if } P(i|W) > P(j|W) \text{ for all } j \neq i \quad (۷)$$

1 Cortes et al

3 Foody

5 Cristianini, N & Shawe-Taylor

6 Burges

2 Boser

4 Foody and Mathur

در این مدل چنین فرض می شود که توزیع داده ها در طبقات از توزیع گوسی چند متغیره پیروی می کند. هر پیکسل به طبقاتی با بیشترین احتمال اختصاص یافته و اگر مقادیر احتمالی در زیر آستانه تعیین شده توسط کاربر قرار گیرد به عنوان پیکسل فاقد طبقه در نظر گرفته می شود. روند کلی مدل حداکثر احتمال به این شکل است که در ابتدا تعداد انواع کاربری ها و پوشش ها در منطقه مورد مطالعه تعیین شده و سپس برای هر یک از طبقات مورد نظر، پیکسل های آموزشی در نظر گرفته می شود. از این پیکسل ها برای تخمین میانگین و ماتریس کوواریانس هر طبقه استفاده می شود. در نهایت هر پیکسل در انواع مختلف کاربری ها جای می گیرد. مدل درخت تصمیم به آسانی قابل اجرا می باشد لیکن مقادیر واریانس به دست آمده بالا بوده و لذا از صحت قابل قبولی برخوردار نیستند. برای غلبه بر این مشکل انواع مختلفی از درخت تصمیم تولید می شود که در آن زیرمجموعه های مختلفی در همان مجموعه آموزشی با روش های مختلفی آموزش داده می شوند (بریمان^۱؛ ۲۰۰۱: ۱۲۶). مدل جنگل تصادفی یک نوع الگوریتم یادگیری مبتنی بر ماشین است که بر اساس روش درختان تصمیم گیری استوار است. این روش به نوعی از الگوریتم های ماشین تعلق دارد که در آن طبقه بندی ها به صورت مجموعه ای انجام می گیرند. در این حالت از پیش بینی های چندین مدل پایه مستقل، میانگین گرفته شده و پیش بینی انجام می گیرد. ساختار این مدل به عنوان یک روش طبقه بندی و رگرسیون چند متغیره به شکل کاملاً موفقی به اجرا در آمده است (دنیل^۲ و همکاران، ۲۰۱۴: ۱۴). روش جنگل تصادفی، اغتشاشات تصادفی را در فرایند یادگیری مورد استفاده قرار می دهد تا بدین وسیله مدل های مختلفی تولید شده و از فرایند پیش بینی ها برای پیش بینی مجموعه ها استفاده نماید (لویپه^۳؛ ۲۰۱۴: ۷۶). مدل درخت تصادفی بر خلاف مدل ماشین بردار پشتیبانی SVM، ترکیبی از متغیرها را مدیریت می کند. در مدل SVM قبل از فرایند آموزش و طبقه بندی، اقدام به نرمال سازی داده ها می شود در حالی که مدل درخت تصادفی نسبت به محدوده داده ها از حساسیت کمتری برخوردار است. با این وجود، در مجموعه های آموزشی کوچکتر، مدل ماشین بردار پشتیبانی عملکرد بهتری داشته است. بررسی دمای سطح زمین برای درک چرخه انرژی و تبادل آب با محیط امری حیاتی می باشد. تجزیه و تحلیل LST با استفاده از داده های حرارتی ماهواره ای مستلزم روش های مختلفی از جمله تراز رادیومتری سنجنده، تصحیح بازتاب سطح و هوا و تغییرات LULC می باشد. برای محاسبه LST از باند ۱۰ ماهواره لندست ۸ استفاده می شود. مراحل محاسبه LST بر اساس روش تاکور و همکاران (۲۰۲۰) و کافی و همکاران (۲۰۲۱) در زیر شرح داده شده است. به این منظور در ابتدا مقادیر تابش طیفی در بالای اتمسفر محاسبه می گردد. معادله زیر برای این منظور در نظر گرفته شده است.

$$L\lambda = AL + ML * Qcal \quad (8)$$

در این معادله $L\lambda$ تابش طیفی در بالای اتمسفر، ML فاکتور درجه بندی شده ترکیبی تابشی برای باند ۱۰ و $Qcal$ تعداد دیجیتالی باند ۱۰ می باشد. سپس مقادیر تابش طیفی $L\lambda$ به مقادیر درجه روشنایی ماهواره (TB) تبدیل می گردد.

$$TB = \frac{\sum(K2)}{\ln\left(\frac{K1}{L\lambda+1}\right)} \quad (9)$$

در این معادله TB درجه روشنایی بوده و $K1$ و $K2$ ضریب حرارتی ثابت برای باند ۱۰ می باشد. نسبت پوشش گیاهی (PV) و انتشار سطحی (E) نیز بر اساس معادلات زیر محاسبه می شود.

$$PV = \left[\frac{(NDVI - NDVI_{min})}{(NDVI_{max} - NDVI_{min})} \right]^2 \quad (10)$$

¹ Breiman
² Denil

³ Louppe
⁴ Thakur et al

⁵ Kafy

$$E = (0.004.PV) + 0.986 \quad (11)$$

در نهایت، مقادیر درجه روشنایی به مقادیر LST تبدیل می گردد:

$$LST = \left[\frac{TB}{1 + \left(\frac{\lambda.TB}{a}\right) \ln E} \right] \quad (12)$$

در این معادله λ طول موج تابش ساطع شده، a ضریب ثابت ۱۴۳۸۸ برای ماهواره لندست ۸، h ضریب ثابت پلانک، c سرعت نور و k ضریب بولتزمن می باشد.

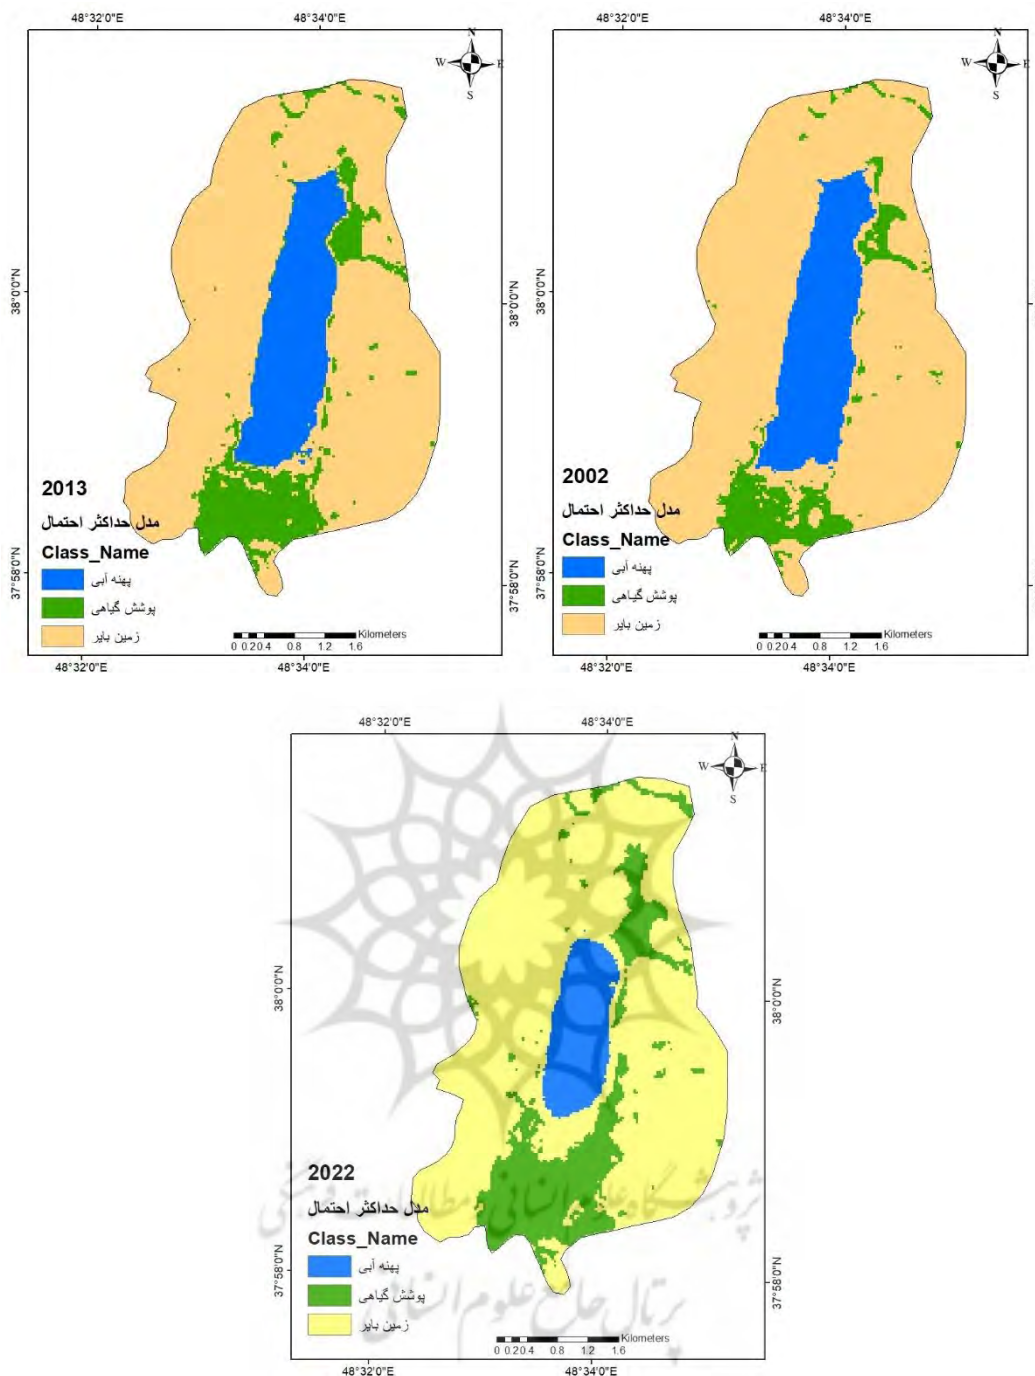
دقت طبقه بندی برای سه تکنیک RTC، MLC و SVM با استفاده از ضریب کاپا مورد ارزیابی قرار گرفت. این ضریب با گنجاندن تمام مقادیر خارج از حد مورب در محاسبات، تمایل شاخص دقت کلی را به تخمین بیش از حد مقادیر، کنترل می کند. در این ضریب تفاوت های آماری در ماتریس خطاهای مختلف مورد آزمایش قرار می گیرد. ضریب کاپا در بین صفر تا ۱ قرار دارد. برای محاسبه ضریب کاپا از معادله زیر استفاده می شود.

$$k = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} + x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} + x_{+i})} \quad (13)$$

در این معادله، N ، x_{ii} ، x_{i+} ، x_{+i} ، به ترتیب تعداد کل نمونه ها، مقادیر دارای چولگی، دقت کاربر و دقت تولید کننده هستند.

یافته ها و بحث

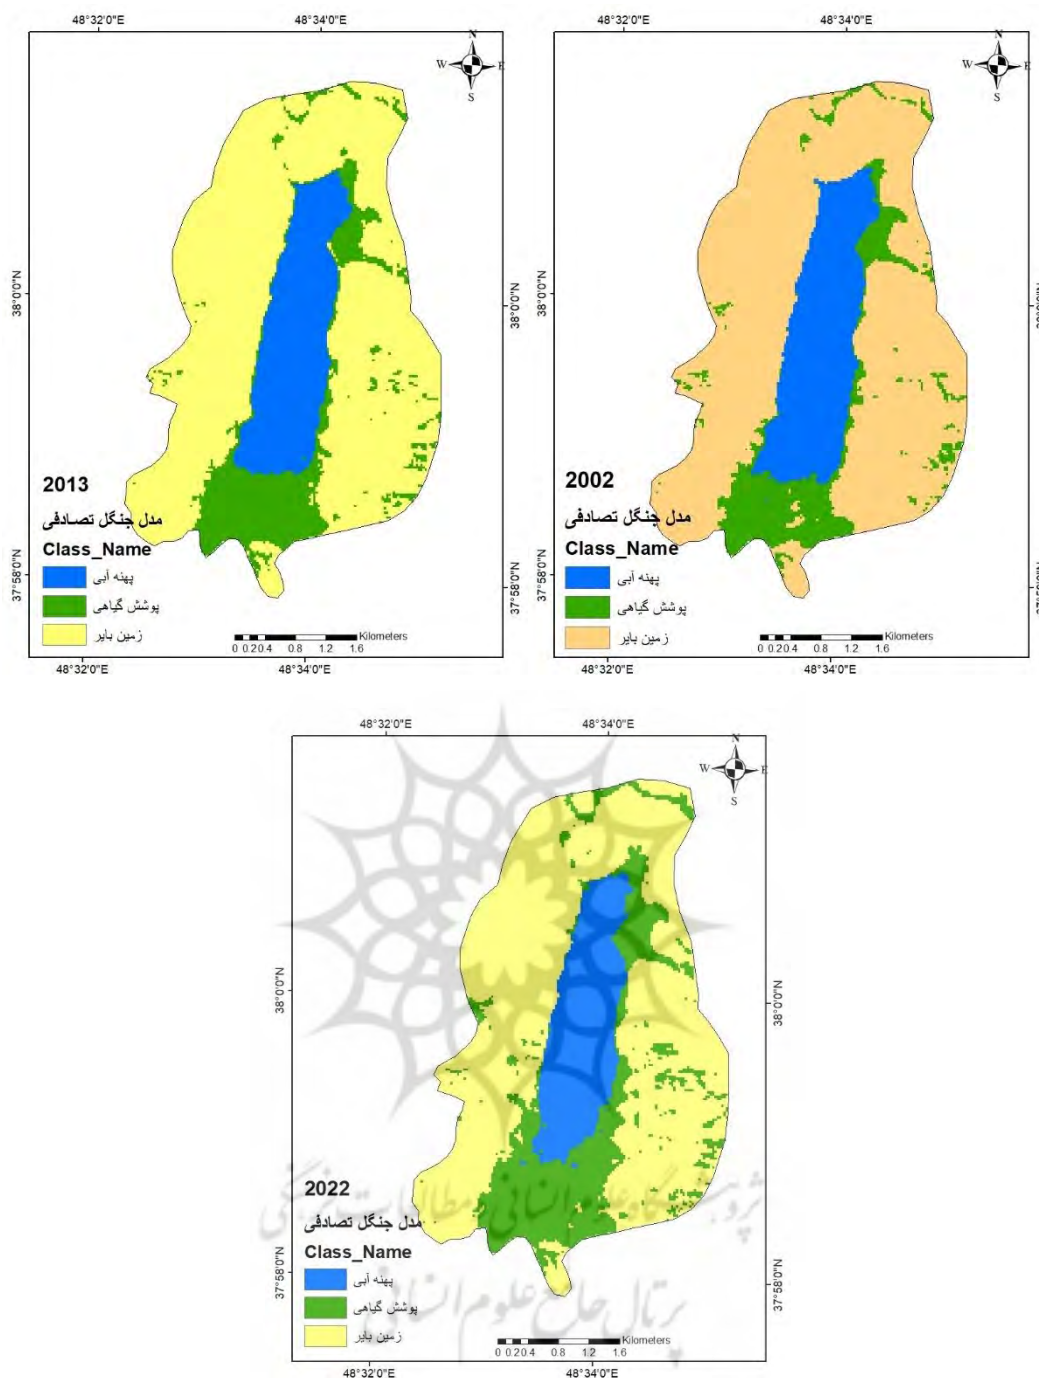
دریاچه ها و تالاب ها در شرایط کنونی از فعالیت های انسانی و تغییر اقلیم تاثیر پذیرفته اند. حتی نواحی که از تنش آبی کمتری برخوردارند نیز از این پدیده ها متاثر شده اند. دریاچه نغور واقع در شرق استان اردبیل نیز از این تغییرات در امان نمانده است به منظور بررسی این تغییرات و تاثیر آن در پهنه آبی دریاچه و در کنار آن تاثیرپذیری دمای سطح زمین از این فرایندها از مدل های ماشین بردار پشتیبانی، جنگل تصادفی و حداکثر احتمال استفاده شده و کارایی هر کدام در شناسایی ماربری و پوشش زمین مورد بررسی قرار گرفته است. این فرایند برای سالهای ۲۰۱۳، ۲۰۲۲ و ۲۰۲۲ اعمال گردیده است. در مدل MLC مساحت پهنه آبی برای سال ۲۰۰۲ معادل ۳/۱۹ کیلومتر مربع بوده و این میزان در سال ۲۰۲۲ به ۱/۶۳ کیلومتر مربع رسیده است. به عبارتی مساحت این پهنه از ۱۷/۳ درصد در سال ۲۰۰۲ به ۸/۸۴ درصد در سال ۲۰۲۲ کاهش یافته است. مساحت پوشش گیاهی در این مدل از ۱/۵۸ کیلومتر مربع در سال ۲۰۰۲ به ۳/۲۵ کیلومتر مربع افزایش یافته است. به عبارتی مساحت این نوع کاربری از ۸/۵۷ درصد در سال ۲۰۰۲ به ۱۷/۶۳ درصد در سال ۲۰۲۲ رسیده و افزایش قابل توجهی را نشان می دهد. این افزایش در نواحی جنوبی و شمال شرقی دریاچه نغور رخ داده و در زمین های خشک شده این دریاچه به وقوع پیوسته است. در این بین زمین های بایر با کمترین تغییرات مواجه شده اند. با این وجود بیشترین مساحت در محدوده مورد مطالعه اختصاص به این نوع کاربری داشته است. به طوری که از ۱۳/۶۵ کیلومتر مربع در سال ۲۰۰۲ به ۱۳/۵۵ کیلومتر در سال ۲۰۲۲ رسیده است.



شکل (۳): مقادیر برآورد شده توسط مدل حداکثر احتمال در بازه زمانی ۲۰۰۲ تا ۲۰۲۲

Figure (3): Values estimated by the maximum likelihood model in the period from 2002 to 2022

در مدل جنگل تصادفی RTC مساحت پهنه آبی در سال ۲۰۰۲ معادل ۳/۵۳ کیلومتر مربع بوده که در سال ۲۰۲۲ این میزان به ۲/۸۶ کیلومتر مربع کاهش یافته بود. مساحت پوشش گیاهی با افزایش همراه بوده و از ۲/۲۹ کیلومتر مربع در سال ۲۰۰۲ به ۳/۸۵ کیلومتر مربع در سال ۲۰۲۲ رسیده است. مساحت زمین های بایر از کاهش جزئی همراه بوده و از ۱۲/۶۱ کیلومتر مربع در سال ۲۰۰۲ به ۱۱/۷۱ کیلومتر مربع در سال ۲۰۲۲ رسیده است. این نوع کاربری بیشترین پهنه را در منطقه مورد مطالعه به خود اختصاص داده است.

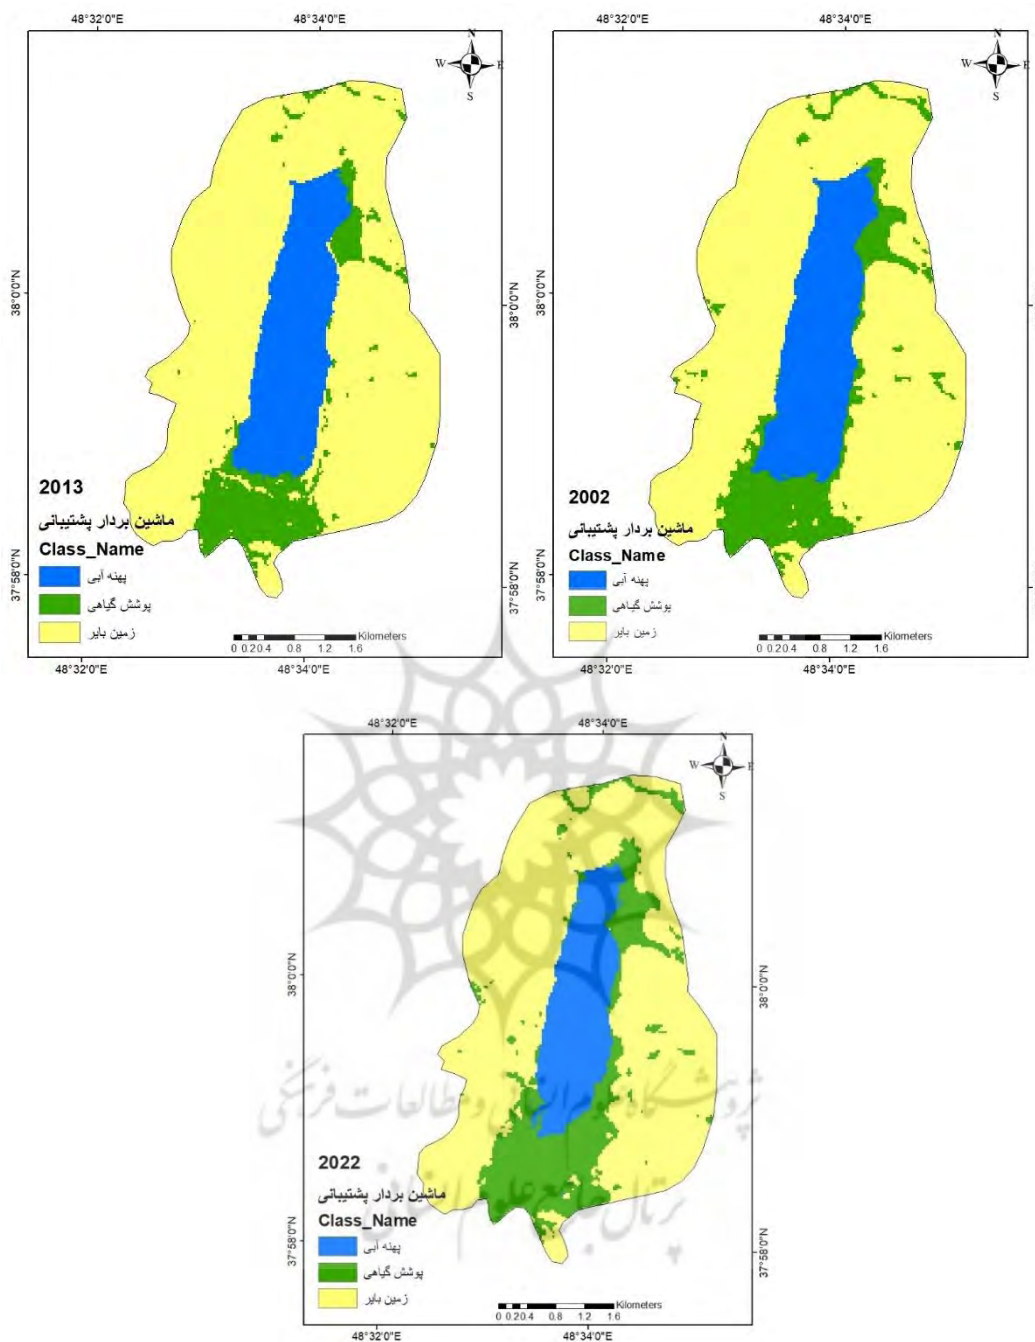


شکل (۴): مقادیر برآورد شده توسط مدل جنگل تصادفی در بازه زمانی ۲۰۰۲ تا ۲۰۲۲

Figure (4): Values estimated by the random forest model in the period from 2002 to 2022

آخرین الگوریتم یادگیری که در این تحقیق مورد استفاده قرار گرفته است الگوریتم ماشین بردار پشتیبانی SVM می باشد. در این الگوریتم مساحت پهنه آبی در سال ۲۰۰۲ حدود ۳/۵ کیلومتر مربع برآورد گردید که به مقادیر به دست آمده توسط مدل جنگل تصادفی در این سال بسیار شبیه می باشد. در سال ۲۰۲۲ این نوع کاربری از مساحتی معادل ۲/۸۱ کیلومتر مربع برخوردار است که با مقدار به دست آمده با مدل جنگل تصادفی تنها ۰/۰۵ کیلومتر مربع اختلاف دارد. پوشش گیاهی این منطقه در سال ۲۰۰۲ معادل ۲/۴۲ کیلومتر مربع بوده و در سال ۲۰۲۲ معادل ۳/۴۶ کیلومتر مربع برآورد گردید. در نهایت، آخرین نوع کاربری که اختصاص به زمین بایر دارد از

بیشترین مساحت برخوردار بوده و کمترین تغییر را نشان می دهد به صورتی که از ۱۲/۵ کیلومتر مربع در سال ۲۰۰۲ به ۱۲/۱۵ کیلومتر مربع رسیده که کاهش بسیار جزئی را نشان می دهد.



شکل (۵): مقادیر برآورد شده توسط مدل جنگل تصادفی در بازه زمانی ۲۰۰۲ تا ۲۰۲۲

Figure (5): Values estimated by the random Tree model in the period from 2002 to 2022

مقادیر مربوط به مساحت پهنه های آبی، پوشش گیاهی و زمین های بایر برای هر یک از کاربری بر حسب کیلومتر مربع و درصد در جدول زیر نمایش داده شده و میزان تغییرات اعم از افزایش و کاهش هر نوع کاربری به تفکیک ذکر گردیده است.

جدول (۲): مقادیر هر یک از کاربری ها و پوشش های زمین برای مدل های SVM و MLC .RTC در سال ۲۰۰۲

Table (2): Values of each land use and land cover for RTC, MLC and SVM models in 2002

SVM		RTC		MLC		نوع کاربری
درصد	مساحت km2	درصد	مساحت km2	درصد	مساحت km2	
۱۹	۳/۵	۱۹/۱۵	۳/۵۳	۱۷/۳	۳/۱۹	پهنه آبی
۱۳/۱۳	۲/۴۲	۱۲/۴۲	۲/۲۹	۸/۵۷	۱/۵۸	پوشش گیاهی
۶۷/۸۲	۱۲/۵	۶۸/۴۲	۱۲/۶۱	۷۴/۰۶	۱۳/۶۵	زمین بایر

جدول (۳): مقادیر هر یک از کاربری ها و پوشش های زمین برای مدل های SVM و MLC .RTC در سال ۲۰۱۳

Table (3): Values of each land use and land cover for RTC, MLC and SVM models in 2013

SVM		RTC		MLC		نوع کاربری
درصد	مساحت km2	درصد	مساحت km2	درصد	مساحت km2	
۱۸/۴	۳/۳۹	۱۷/۶۳	۳/۲۵	۱۶/۵	۳/۰۴	پهنه آبی
۱۰/۸۵	۲	۱۴/۲۷	۲/۶۳	۱۲/۲	۲/۲۶	پوشش گیاهی
۷۰/۷	۱۳/۰۳	۶۸/۰۴	۱۲/۵۴	۷۱/۱۸	۱۳/۱۲	زمین بایر

جدول (۴): مقادیر هر یک از کاربری ها و پوشش های زمین برای مدل های SVM و MLC .RTC در سال ۲۰۲۲

Table (4): Values of each land use and land cover for RTC, MLC and SVM models in 2022

SVM		RTC		MLC		نوع کاربری
درصد	مساحت km2	درصد	مساحت km2	درصد	مساحت km2	
۱۵/۲۴	۲/۸۱	۱۵/۵۱	۲/۸۶	۸/۸۴	۱/۶۳	پهنه آبی
۱۸/۷۷	۳/۴۶	۲۰/۸۸	۳/۸۵	۱۷/۶۳	۳/۲۵	پوشش گیاهی
۶۵/۹۲	۱۲/۱۵	۶۳/۵۳	۱۱/۷۱	۷۳/۵۲	۱۳/۵۵	زمین بایر

جدول (۵): میزان تغییرات کاربری ها و پوشش زمین در مدل MLC در بازه زمانی ۲۰۰۲ تا ۲۰۲۲

Table (5): The amount of land use and land cover changes in the MLC model in the period from 2002 to 2022

نوع کاربری	۲۰۰۲-۲۰۱۳	۲۰۱۳-۲۰۲۲	۲۰۰۲-۲۰۲۲
پهنه آبی	-۰/۱۵	-۱/۴۱	-۱/۵۶
پوشش گیاهی	+۰/۶۸	+۰/۹۹	+۱/۶۷
زمین بایر	-۰/۵۳	+۰/۴۳	-۰/۱

جدول (۶): میزان تغییرات کاربری ها و پوشش زمین در مدل RTC در بازه زمانی ۲۰۰۲ تا ۲۰۲۲

Table (6): The amount of land use and land cover changes in the RTC model in the period from 2002 to 2022

نوع کاربری	۲۰۰۲-۲۰۱۳	۲۰۱۳-۲۰۲۲	۲۰۰۲-۲۰۲۲
پهنه آبی	-۰/۲۸	-۰/۳۹	-۰/۶۷
پوشش گیاهی	+۰/۳۴	+۱/۲۲	+۱/۵۶
زمین بایر	-۰/۰۷	-۰/۸۳	-۰/۹

جدول (۷): میزان تغییرات کاربری ها و پوشش زمین در مدل SVM در بازه زمانی ۲۰۰۲ تا ۲۰۲۲

Table (7): The amount of land use and land cover changes in the SVM model in the period from 2002 to 2022

نوع کاربری	۲۰۰۲-۲۰۱۳	۲۰۱۳-۲۰۲۲	۲۰۰۲-۲۰۲۲
پهنه آبی	-۰/۱۱	-۰/۵۸	-۰/۶۹
پوشش گیاهی	-۰/۴۲	+۱/۴۶	+۱/۰۴
زمین بایر	+۰/۵۳	-۰/۸۸	-۰/۳۵

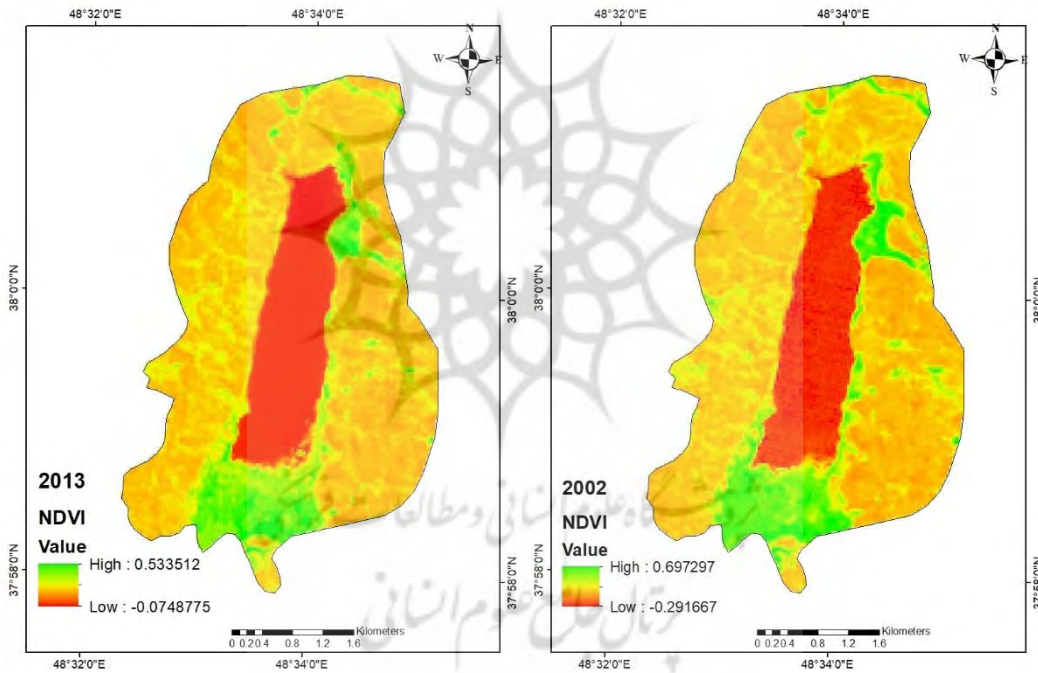
برای بررسی کارایی هر یک از مدل ها در برآورد پوشش و کاربری زمین از ضریب کاپا استفاده می شود. مقادیر نزدیک به عدد یک نشان دهنده بیشترین دقت در مدل می باشند. مدل های یادگیری از تشخیص پهنه های آبی با کمترین اختلال مواجه هستند که علت این امر در بازتاب پایین این پهنه ها بوده که تشخیص آنها را به راحتی میسر می ساد. تنها در مواقعی که عمق دریاچه کاهش داشته باشد این الگوریتم ها دچار مشکل شده و به اشتباه ان بخش ها را زمین بایر یا پوشش گیاهی در نظر می گیرند. بعضا نیزآرها و گیاهان مردابی نیز باعث این اختلال می گردند. الگوریتم های ماشین بردار پشتیبانی ، جنگل تصادفی و حداکثر احتمال از درجات متفاوتی از دقت برخوردار هستند. بررسی ها نشان داد که مدل SVM از بیشترین دقت برخوردار بوده و مدل MLC از کمترین میزان ضریب کاپا برخوردار می باشد. در سال ۲۰۲۲ میزان ضریب کاپا با بیشترین کاهش برای هر سه مدل همراه بوده که علت آن کاهش عمق دریاچه و ایجاد تداخل بین پوشش گیاهی و پهنه های آبی می باشد.


جدول (۸): مقادیر ضریب کاپا برای مدل های ماشین بردار پشتیبانی، جنگل تصادفی و حداکثر شباهت در بازه زمانی ۲۰۰۲ تا ۲۰۲۲

Table (8): Kappa coefficient values for support vector machine, random forest and maximum similarity models in the period from 2002 to 2022

مدل	۲۰۰۲	۲۰۱۳	۲۰۲۲
SVM	۰/۸۷	۰/۸۳	۰/۸۱
RTC	۰/۷۹	۰/۷۵	۰/۷۲
MLC	۰/۷۳	۰/۷۱	۰/۶۹

تغییرات در کاربری و پوشش زمین و همچنین پهنه های آبی می تواند تغییراتی را در دمای سطح زمین ایجاد نماید. لذا برای پی بردن به این تاثیرات، دمای سطح زمین بر اساس شاخص LST در دو ماهواره لندست ۵ و ۸ برای سال های ۲۰۰۲، ۲۰۱۳ و ۲۰۲۲ برآورد گردید. در ترسیم نقشه LST از شاخص های دمای بالای اتمسفر، نسبت پوشش گیاهی، میزان تشعشع و دمای روشنایی استفاده شده مقادیر NDVI در زیر نمایش داده شده است.



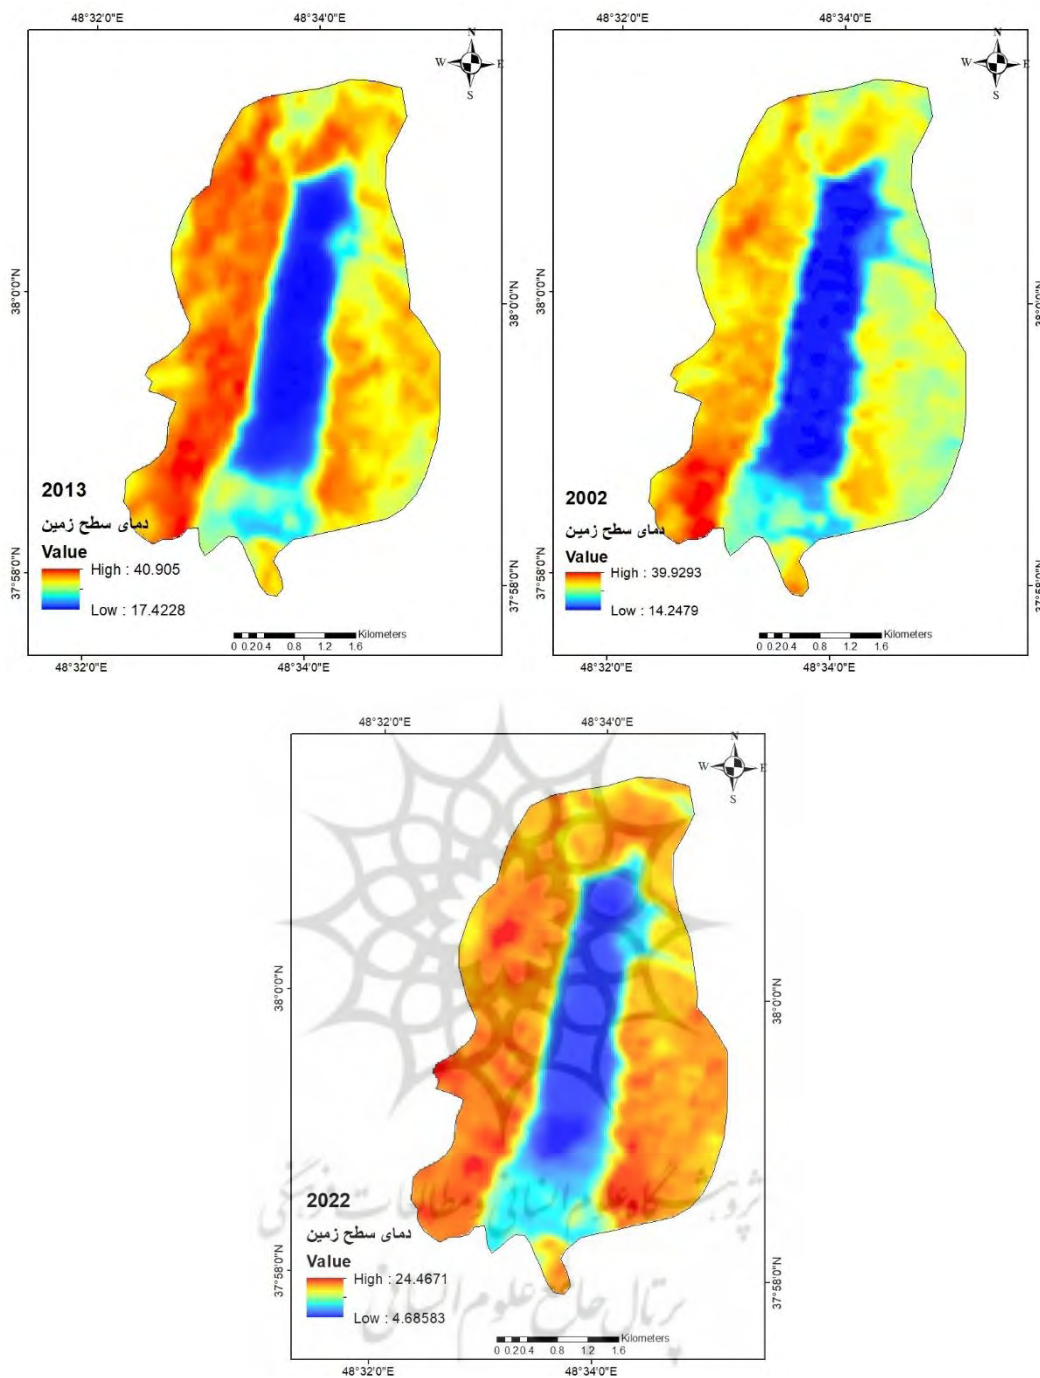


شکل (۶): مقادیر NDVI در منطقه مورد مطالعه در بازه زمانی ۲۰۰۲ تا ۲۰۲۲

Figure (6): NDVI values in the study area in the period from 2002 to 2022

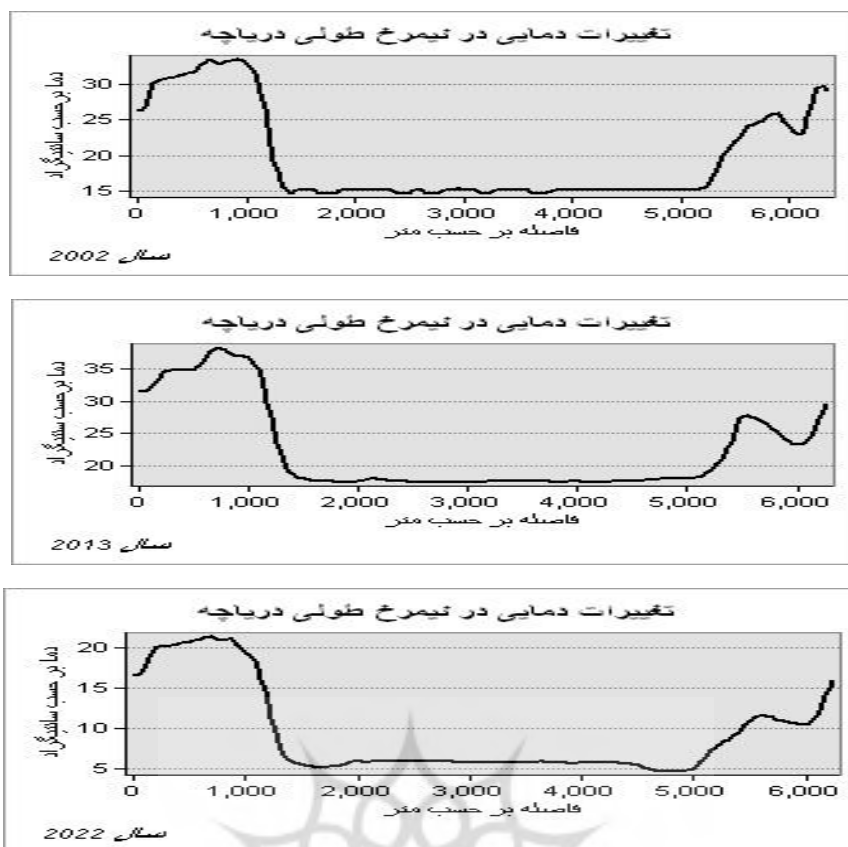
بر اساس هر یک از شاخص‌ها، مقادیر دمای سطح زمین برآورد گردیده و مشاهده شد که در روز ۱۴ جولای ۲۰۰۲ مقادیر حداقل دما و حداکثر دما به ترتیب معادل ۱۴/۲۴ و ۳۹/۹۲ درجه سانتیگراد بوده که کمترین دما در سطح دریاچه به ثبت رسیده است. در روز ۲۸ جولای ۲۰۱۳ کمترین و بیشترین دما معادل ۱۷/۴۲ و ۴۰/۹ درجه سانتیگراد بوده و مشاهده می‌شود که دمای حداقل نسبت به سال ۲۰۰۲ حدود ۳/۱۸ درجه سانتیگراد افزایش را نشان می‌دهد. مشاهده می‌شود که بخش غربی دریاچه نئور با افزایش دما مواجه گردیده است. در تاریخ ۱۳ جولای ۲۰۲۲ مقادیر حداقل و حداکثر به ترتیب معادل ۴/۶۸ و ۲۴/۴۶ درجه سانتیگراد بوده که کاهش قابل توجهی در دمای این سال مشاهده شده که علت آن رخداد اقلیمی لحظه‌ای بوده است. نیم‌رخ از تغییرات دمایی سال‌های ۲۰۰۲، ۲۰۱۳ و ۲۰۲۲ از سطح دریاچه نمایش داده شده است.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی



شکل (۷): مقادیر شاخص LST در بازه زمانی جولای ۲۰۰۲ تا ۲۰۲۲

Figure (7): LST index values in the period from July 2002 to 2022



شکل (۸): نیمرخ طولی از سطح دریاچه بر اساس تغییرات دمایی نقشه LST در سال های ۲۰۲۲، ۲۰۱۳ و ۲۰۰۲

Figure (8): Longitudinal profile of the lake surface based on the temperature changes of the LST map in the years 2002, 2013 and 2022

نتیجه گیری

تغییرات اقلیمی و فعالیت های انسانی باعث تغییرات گسترده ای در پوشش و کاربری زمین شده و به شکل تخریب زمین، وقوع سیلاب، افزایش دمای سطح زمین و مخاطرات زیست محیطی بی شماری می گردد. کشور ایران با قرارگیری در منطقه خشک و نیمه خشک جهان از تغییرات اقلیمی قابل توجهی برخوردار گردیده است. عرض های بالاتر کشور ایران که از اقلیم معتدل تر با بارندگی بیشتر برخوردار هستند نیز از این رخدادها در امان نبوده است. دریاچه نئور در استان اردبیل و در جوار سواحل جنوب غربی دریای خزر نیز از فعالیت های انسانی و تغییرات اقلیمی متاثر شده است. برای بررسی تغییرات کاربری و پوشش زمین روش های مختلفی ارائه گردیده که از آن جمله می توان به روش های ماشین بردار پشتیبانی، جنگل تصادفی و مدل حداکثر احتمال اشاره کرد. لذا در این تحقیق از روش های فوق استفاده شده و روند تغییرات کاربری در محدوده دریاچه نئور برای سال های ۲۰۰۲، ۲۰۱۳ و ۲۰۲۲ برآورد گردید. نتایج نشان داد که مقادیر برآورد شده توسط مدل ماشین بردار پشتیبانی و جنگل تصادفی از شباهت قابل توجهی برخوردار بوده اند. به عنوان مثال مقادیر پهنه آبی در سال ۲۰۰۲ در مدل ماشین بردار پشتیبانی معادل ۳/۵ کیلومتر مربع بوده و در مدل جنگل تصادفی این میزان معادل ۳/۵۳ کیلومتر مربع برآورد گردید یعنی تنها ۰/۰۳ کیلومتر مربع اختلاف مشاهده شده در حالی که مدل حداکثر احتمال این میزان را حدود ۳/۱۹ کیلومتر مربع برآورد نموده است. در تمامی مدل ها پهنه آبی با کاهش مواجه گردیده و پوشش گیاهی افزایش یافته که بیشترین میزان افزایش در ساحل جنوبی دریاچه مشاهده گردید. زمین های بایر با بیشترین مساحت کمترین تغییرات را شاهد بوده اند. نتایج نشان می دهد که سطح دریاچه نئور در بخش های جنوب غربی و شمال شرقی در حال کاهش می باشد.

- Abdoli, M., Haghghi, M. (2020). Comparison of support vector machine and artificial neural network classification methods to produce landuse maps (Case study: Bojagh National Park), *Journal of environmental research and technology*, 8(5): 26-42.
- Abedi, M., Norouzi, G & Bahroudi, A., (2012). Support Vector machine for multi classification of mineral prospectivity areas, *computers and Geosciences*. 46, 272-283.
- Alemu, M.M., (2019). Analysis of Spatio-temporal Land surface temperature and normalized difference vegetation index changes in the Andassa Watershed, Blue Nile Basin, Ethiopia. *J. Resour. Ecol.* 10 (1), 77–85.
- Aslami, F., Ghorbani, A., Sobhani, B., Panahandeh, M. (2015). Comparing artificial neural network, support vector machine and object-based methods in preparation land use/cover maps using landSat-8 images, *Journal of RS and GIS for Natural Resources*, 3(20), 1-14.
- Belay, T & Mengistu, D.A., (2019). Land use and land cover dynamics and drivers in the Muga watershed, Upper Blue Nile basin, Ethiopia. *Remote Sens. Appl.s: Soc. Environ.* 15, 100249
- Bokaie, M., Zarkesh, M.K., Arasteh, P.D & Hosseini, A., (2016). Assessment of urban heat island based on the relationship between land surface temperature and land use/land cover in Tehran. *Sustain. Cities Soc.* 23, 94–104.
- Boser, B., Guyon, I & Vapnik, V., (1992). A training algorithm for optimal margin classifier, in: *Proceedings of the Fifth Annual ACM Conference on Computational Learning Theory*, Pittsburgh, 8, 144–152.
- Breiman, L. (2001). *Random forests* Machine learning. 45, 5- 32.
- Burges, C., (1998). A tutorial on support vector machines for pattern recognition, *Data Mining Know. Discov.* 2, 121–167.
- Campvalls, G., Mooij, J & Scholkopf, B., (2010). Remote sensing feature selection by Kernel dependence measures. *IEEE Geoscience and remote sensing Letters*. 7, 587- 591.
- Cortes, C & Vapnik, V., (1995). Support-vector network, *Mach. Learn.* 20, 273–297.
- Cristianini, N & Shawe-Taylor, J, (2000). *An Introduction to Support Vector Machines and Other Kernelbased Learning Methods*, Cambridge University Press, 2000,
- Damtea, W., Kim, D., & Im, S (2020). Spatiotemporal analysis of land cover changes in the chemoga basin, Ethiopia, using Landsat and google earth images. *Sustainability* 12 (9), 3607
- Denil, M., Matheson, D & Freitas, N. (2014). Narrowing the Gap: random forest in theory and in practice, *Proceeding of the 31st international conference on machine learning Beijing China, JMLR: W and P, Vol 32.* 9 pages.
- Dinka, M.O & Chaka, D.D., (2019). Analysis of land use/land cover change in Adei watershed, Central Highlands of Ethiopia. *J. Water Land Dev.* 41 (IV–VI), 146–153.
- Foody, G., Boyd, D & Sanchez-Hernandez, C., (2007). Mapping a specific class with an ensemble of classifiers, *Int. J. Remote Sens.* 28, 1733–1746.
- Foody, G & Mathur, A., (2006). The use of small training sets containing mixed pixels for accurate hard image classification: training on mixed spectral responses for classification by a SVM, *RemoteSens. Environ.* 103, 179–189.
- Geo, Y., De Jong, K., Liu, F., Wang, X & Li, C., (2012). A comparison of Artificial neural networks and support vector machines on landcover classification, *Springer verlag Berlin Heidelberg, ISICA, CCIS.* 316, 531- 539.
- Granian, H., Tabatabaei, S., Asadi, H & Carranza, E., (2016). Application of Discriminant Analysis support vector machine Gold Potential areas for further Drilling in the Sari Gunay Gold Deposit, NW Iran, *natural Resource Research.* 25(2), 145-159.
- Hassen, E.E., & Assen, M (2017). Land use/cover dynamics and its drivers in Gelda catchment, Lake Tana Hegazy, I.R., & Kaloop, M.R (2015). Monitoring urban growth and land use change detection with GIS and remote sensing techniques in Daqahlia governorate Egypt. *Int. J. Sustain. Built Environ.* 4 (1), 117–124.

- watershed, Ethiopia. *Environ. Syst. Res.* 6 (1), 1–13.
- Hord, R. M., (1982). *Digital imageprocessing of Remotly sensed Data*, Academic press, Newyork, 256.
- Huange, C., Davis, L.S & Townshend, J., (2002). An assessment of support vector machines for land cover classification. *International Journal of Remote sensing.* 23, 725- 749.
- Jahanbakhshi, F., Ekhtesasi, M R. (2019). Performance Evaluation of Three Image Classification Methods (Random Forest, Support Vector Machine and the Maximum Likelihood) in Land Use Mapping. *Journal of water and soil science*, 22 (4) :235-247
- Jiange, X., Lin, M & Zhao, C., (2011). Woodland cover change assessment using decision tree, support vector machines and artificial neural networks classification algorithms, Fourth international conference on intelligent computation Technology and Automation. 312- 315.
- Kafy, A.A. (2021). Impact of Vegetation Cover Loss on Surface Temperature and Carbon Emission in a Fastest-Growing City, Cumilla, Bangladesh, 207. *Building and Environment*.
- Kikon, N., Singh, P., Singh, S.K & Vyas, A., (2016). Assessment of urban heat islands (UHI) of Noida City, India using multi-temporal satellite data. *Sustain. Cities Soc.* 22, 19–28.
- Li, K., Feng, M., Biswas, A., Su, H., Niu, Y & Cao, J., (2020). Driving factors and future prediction of land use and cover change based on satellite remote sensing data by the LCM model: a case study from Gansu province, China. *Sensors* 20 (10), 2757.
- Loupe, G. (2014). *Understanding random forests from theory to practice*, university of Liege. Faculty of applied science. Department of Electrical engineering and computer science. 223 pages.
- Mountrakis, G., Im, J & Ogole, C., (2011). Support vector machine in remote sensing a review. *ISPRS Journal of photogrammetry and remote sensing.* 13, 247- 259.
- Oommen, T., (2008). An objective analysis of support vector machine-based classification for remote sensing. *Mathematical Geosciences.* 40, 409-424.
- Pal, S & Ziaul, S.K., (2017). Detection of land use and land cover change and land surface temperature in English Bazar urban centre. Egypt. *J. Remote Sens. Space Sci.* 20 (1), 125–145.
- Patel, S.K., Verma, P & Singh, G.S., (2019). Agricultural growth and land use land cover change in peri-urban India. *Environ. Monit. Assess.* 191 (9), 1–17.
- Rajani, A & Varadarajan, S., (2021). Estimation and validation of land surface temperature by using remote sensing & GIS for Chittoor District, Andhra Pradesh. *Turk. J. Comput. Math. Educ.* 12 (5), 607–617.
- Rajendran, P & Mani, K., (2015). Estimation of spatial variability of land surface temperature using Landsat 8 imagery. *Int. J. Eng. Sci.* 11 (4), 19–23.
- Shanani Hoveyzeh, M., Zarei, H. (2016). Comparison of Three Classification Algorithms (ANN, SVM and Maximum Likelihood) for Preparing Land Use Map (Case Study: Abolabbas Basin). *Iranian Journal of watershed management science*, 10 (33) :73-84
- Thakur, S., Mondal, I., Bar, S., Nandi, S., Das, P., Ghosh, P.B & De, T.K. (2020). Shoreline changes and its impact on the mangrove ecosystems of some Islands of Indian Sundarbans, North- East coast of India, *J Clean Prod*, 284, 124764. Elsevier.
- Vapnik, V. N., 1995. *The nature of statistical learning Theory*, Springer Verlag, Newyork.