

Research Paper

Evaluating the Performance of Different Machine Learning Methods in Classifying Land Cover and Use by Using Remote Sensing Images

Abdolhossein Baghlani^{1*}, Seyyed Majid Hafezi²,

1. Associate Prof. of Civil and Environmental Engineering, Shiraz University of Technology, Shiraz, Iran

2. Former MSc Student of Civil and Environmental Engineering, Shiraz University of Technology, Shiraz, Iran

Received: 2024.12.03

Revised: 2025.01.04

Accepted: 2025.01.19

Use your device to scan and
read the article online



DOI:

[10.71632/wej.2025.1192391](https://doi.org/10.71632/wej.2025.1192391)

Keywords:

Land use/Land cover (LULC) -
Remote sensing - Supervised
classification - Google Earth
Engine

Abstract

Introduction: The issue of land use changes and their detection, as well as the effects they have on cities and their surrounding environments, has become an important and practical topic, and the use and creation of various up-to-date methods and models to study this issue have become an important matter. In this regard, remote sensing data, by providing up-to-date and reliable information on the status of land cover, are a suitable tool for preparing land cover and use maps.

Methods: In this study, the catchment area of the Neyshabur Plain which is a part of the catchment area of the central desert of Iran is considered. Envi 5.6 and ArcMap 10.7 software were used to process, analyze, and retrieve satellite data, and Qgis 3.16 software was used to finalize thematic maps. It should be noted that in this study, the Google Earth Engine, which is known as the most powerful system for processing satellite image time series in remote sensing, was also used.

Findings: According to the results of the error matrix obtained, it was found that the neural network method with an overall accuracy of 83.35 and a kappa coefficient of 0.79 for the year 2013, the maximum likelihood method with an overall accuracy of 81.92 and a kappa coefficient of 0.78 for the year 2019, and a neural network with an overall accuracy of 36.79 and a kappa coefficient of 0.75 for the year 2021, have more favorable performance and accuracy for preparing land use maps than other methods.

Citation: Baghlani A, Hafezi SM, Evaluating the Performance of Different Machine Learning Methods in Classifying Land Cover and Use by Using Remote Sensing Images, Water Resources Engineering Journal. 2025; 18 (67): 1- 18.

***Corresponding author:** Abdolhossein Baghlani

Address: Dept. of Civil and Environmental Engineering, Shiraz University of Technology, Shiraz, Iran

Tell: +989177101923

Email: baghlani@sutech.ac.ir

Extended Abstract

Introduction

In general, the phenomena and features of the Earth's surface are called land cover, all activities that humans perform on Earth are called land use, and maps that represent such activities on Earth's surface are called land use maps.

Land cover and land-use change are important issues that have significant impacts on the environment and its processes. Access to up-to-date and accurate land cover and use data through satellite imagery provides an excellent opportunity to identify, monitor, and model future changes.

Research has shown that changes in land cover and use caused by human interventions, such as deforestation, arable farming, and urbanization, can have irreversible effects on ecosystems and the environment [1]. Detecting these changes is important for monitoring the dynamics of different land cover types and land uses in the future.

By assessing land use changes, it is possible to plan and manage land to reduce destructive effects using remote sensing technology at large scales with high accuracy and low cost.

Geographic Information Systems (GIS) and Remote Sensing (RS) are powerful and cost-effective tools for assessing spatial and temporal changes in land cover and use [2]. Remote sensing data are the most common source for detecting, quantifying, and revealing patterns of land cover and use because they collect data at regular intervals and are suitable for accurate geographic processing and geo-referencing [3].

Materials and Methods

The catchment area of the Neyshabur Plain is part of the catchment area of the central desert of Iran and is located in the northeast. This basin has a total area of approximately 7200 square kilometers, of which approximately 4300 square kilometers are plains and the rest are highlands (Fig 2). Neyshabur Plain is one of the most important plains of Razavi Khorasan Province in terms of agricultural

productivity and population density. In the climatic divisions of the country, Neyshabur is part of the central plateau and semi-desert climate; in terms of rainfall, it is considered a dry area

In this study, to identify the maximum changes that occurred in the land cover of the region, in the period of 9 years from 2013 to 2021, 3 years, wet (2019), dry (2021), and normal (2013) were specified according to the amount of annual precipitation obtained from the weather station, as well as the SPI standardized rainfall index for the 12-month period from 1982 to 2022, using the CHIRPS rainfall satellite data, which was calculated in the GEE.

Three different machine learning approaches, i.e. minimum distance, maximum likelihood, and neural network have been used and the results are compared.

Findings

The performance of all the aforementioned methods was evaluated according to the results of various parameters in the generated error matrix, and it was found that the minimum distance method could not perform well in any of the studied years. In contrast, other algorithms based on their different inputs have been able to produce classification maps with desirable accuracy for each LULC in each year. The performance results of all methods used in this study are shown in Figs 10,11,12 and 13.

Based on the results obtained, it was determined that the minimum distance algorithm was unable to produce classification maps with the desired accuracy and precision in any of the years, while the two other methods perform better and give satisfactory results.

Discussion

Three various machine learning methods were employed in this study for land use classification of the Neyshabur Plain in Iran. In comparison, classification methods showed acceptable but different performance in each year, both in general and in terms of the ability of each method to separate land uses with different spectral behaviors. In 2019, the maximum likelihood

algorithm, and in 2013 and 2021, the neural network algorithm achieved the best results.

It is worth mentioning that according to the numbers and various statistical parameters, the error matrix is expressed as outputs that indicate the accuracy of the classified maps; however, by obtaining good results, one cannot expect to produce a completely accurate and correct classification map, since the matrix of errors is not able to show part of the errors in the classified maps. Sufficient and suitable knowledge of the user in the study area should be considered to ensure the accuracy and correct distribution of different LULC classes

Conclusion

In this study, by taking advantage of the very high processing capabilities of the Earth Engine system in retrieving and processing satellite images, an attempt was made to examine changes in land cover and land use in Neyshabur city using different methods.

In this study, an attempt was made to show the maximum amount of change that occurred in the land cover level in the 3-year study period, wet, dry, and normal, based on annual precipitation information, and the images related to these dates were selected, processed, and analyzed.

Based on the results obtained, it was determined that the minimum distance algorithm was not able to produce classification maps with the desired accuracy and precision in any of the years.

In comparison, other classification methods have shown acceptable but different performance in each year, both in general and in terms of the ability of each method to separate land uses with different spectral behaviors. In 2019, the maximum likelihood algorithm, and in 2013 and 2021, the neural network algorithm achieved the best results.

Ethical Considerations compliance with ethical guidelines

The cooperation of the participants in the present study was voluntary and accompanied by their consent.

Funding

No funding.

Authors' contributions

Design and conceptualization: Abdolhossein Baghlani, Seyyed Majid Hafezi

Methodology and data analysis: Seyyed Majid Hafezi

Supervision and final writing: Abdolhossein Baghlani

مقاله پژوهشی

ارزیابی عملکرد روش های مختلف یادگیری ماشین در طبقه بندی پوشش و کاربری اراضی با استفاده از تصاویر سنجنش از دور

عبدالحسین بغلانی^{۱*}، سید مجید حافظی^۲

۱. دانشیار مهندسی عمران و محیط زیست، دانشکده مهندسی عمران و محیط زیست، دانشگاه صنعتی شیراز، شیراز، ایران

۲. دانش آموخته کارشناسی ارشد رشته مهندسی عمران آب، دانشکده مهندسی عمران و محیط زیست، دانشگاه صنعتی شیراز، شیراز، ایران

چکیده

مقدمه: امروزه موضوع تغییرات کاربری اراضی و آشکار سازی آن ها و نیز اثراتی که بر شهر ها و محیط های پیرامون آن می گذارند، به یکی از مباحث مهم و کاربردی تبدیل شده است و به کارگیری و ایجاد روش ها و مدل های متنوع و به روز، جهت بررسی این موضوع به امری بسیار ضروری و لازم تبدیل گردیده است. در این راستا، داده های سنجنش از دور با ارائه اطلاعات به روز و موثق از وضعیت پوشش زمین، ابزار مناسبی برای تهیه نقشه های پوشش و کاربری اراضی هستند.

روش: در این پژوهش حوضه آبریز دشت نیشابور مورد بررسی قرار گرفته است. جهت پردازش، تحلیل و فراخوانی داده های ماهواره ای از نرم افزار های Envi 5.6، ArcMap 10.7 و نیز برای نهایی سازی نقشه های موضوعی از نرم افزار Qgis 3.16 استفاده شده است. لازم به ذکر هست در این مطالعه از سامانه گوگل ارث انجین نیز که به عنوان قوی ترین سامانه پردازش

سری زمانی تصاویر ماهواره ای در علم سنجنش از دور شناخته می شود هم به کار گرفته شده است. **یافته ها و نتیجه گیری:** طبق نتایج ماتریس خطای به دست آمده مشخص شد که روش شبکه عصبی با صحت کلی ۸۳/۳۵ و ضریب کاپای ۰/۷۹ برای سال ۱۳۹۲، حداکثر احتمال با صحت کلی ۸۱/۹۲ و ضریب کاپای ۰/۷۸ برای سال ۱۳۹۸ و شبکه عصبی با صحت کلی ۷۹/۳۶ و ضریب کاپای ۰/۷۵ برای سال ۱۴۰۰ نسبت به سایر روش ها عملکرد مطلوب تر و دقت بیشتری برای تهیه نقشه های کاربری اراضی دارند.

تاریخ دریافت: ۱۴۰۳/۱۹/۱۳

تاریخ داوری: ۱۴۰۳/۱۰/۱۵

تاریخ پذیرش: ۱۴۰۳/۱۰/۳۰

از دستگاه خود برای اسکن و خواندن مقاله به صورت آنلاین استفاده کنید



DOI:

[10.71632/wej.2025.1192391](https://doi.org/10.71632/wej.2025.1192391)

واژه های کلیدی:

پوشش و کاربری اراضی - سنجنش از دور - طبقه بندی نظارت شده - سامانه گوگل ارث انجین

* نویسنده مسئول: عبدالحسین بغلانی

نشانی: دانشکده مهندسی عمران و محیط زیست، دانشگاه صنعتی شیراز، شیراز، ایران.

تلفن: ۰۹۱۷۷۱۰۱۹۲۳

پست الکترونیکی: baghlani@sutech.ac.ir

مقدمه

در کل پدیده ها و عوارض سطحی زمین را پوشش زمین ، تمام فعالیت هایی که انسان بر روی زمین انجام می دهد را کاربری زمین و نقشه هایی که نشان دهنده چنین فعالیت هایی بر روی سطح زمین می باشند را نقشه های کاربری اراضی می نامند.

تغییر پوشش و کاربری اراضی یکی از موضوعات مهمی است که اثرات قابل توجهی بر محیط زیست و فرایندهای آن دارد. دسترسی به داده های به روز و دقیق پوشش و کاربری اراضی از طریق تصاویر ماهواره ای فرصتی عالی برای شناسایی، نظارت و مدل سازی پیش بینی تغییرات آینده را مهیا می سازد. تحقیقات نشان داده اند که تغییراتی که به واسطه دخالت های انسان در پوشش و کاربری اراضی اتفاق افتاده است نظیر جنگل زدایی ، مزارع قابل کشت و شهر سازی می توانند اثرات غیر قابل برگشتی بر اکوسیستم و محیط زیست وارد کنند (۱). تشخیص این تغییرات برای نظارت بر پویایی پوشش ها و کاربری های مختلف در آینده بسیار مهم است. با ارزیابی تغییرات کاربری ها ، امکان برنامه ریزی و مدیریت اراضی ، برای کاستن از اثرات تخریبی با استفاده از فن آوری سنجش از دور در سطوح وسیع ، با دقت بالا و هزینه کم امکان پذیر می باشد. سیستم های اطلاعات جغرافیایی^۱ (GIS) و سنجش از دور^۲ (RS) ابزارهای قدرتمند و مقرون به صرفه برای ارزیابی تغییرات مکانی و زمانی پوشش و کاربری اراضی هستند (۲). داده های سنجش از دور رایج ترین منبع برای تشخیص، کمی سازی و آشکار سازی الگوهای پوشش و کاربری اراضی به دلیل جمع آوری داده های با دوره زمانی متناوب ، مناسب برای پردازش و زمین مبنا کردن جغرافیایی دقیق هستند (۳).


سنجش از دور و کاربرد آن در طبقه بندی

سنجش از دور ، علم به دست آوردن اطلاعات در مورد سطح زمین بدون تماس واقعی با آن است. این کار با سنجش و ثبت انرژی منعکس شده یا ساطع شده و پردازش، تجزیه و تحلیل و به کارگیری آن اطلاعات انجام می شود (۴). تکنیک و روش مورد استفاده در این مطالعه برای طبقه بندی تصاویر ماهواره ای از نوع طبقه بندی تحت نظارت^۳ می باشد. در این پژوهش برای فراخوانی و انجام پردازش های مختلف بر روی تصاویر ماهواره ای از بستری تحت عنوان سامانه گوگل ارث انجین استفاده شده است. گوگل ارث انجین^۴ (GEE) یک پلتفرم ابری (تحت وب) سنجش از دور است که برای پردازش و ذخیره سازی حجم زیادی از تصاویر ماهواره ای در مقیاس پتابایت طراحی شده است (۵). کاربرد ها و قابلیت های سامانه ارث انجین از زمان پیدایش آن باعث شده اند که این پلتفرم ابری ، فرصت های پیشرفته ای را برای انجام مطالعات رصد زمین در اختیار پژوهش گران قرار بدهد (۶). در مطالعه (۷) مجموعه داده های سری زمانی Sentinel-1 و Sentinel-2 در بستر GEE برای تولید یک نقشه پوشش اراضی

بهبود یافته ایران با وضوح مکانی ۱۰ متر و سطح بالایی از دقت ، ترکیب شدند. خروجی این مطالعه نقشه طبقه بندی ۱۳ کلاسه مبتنی بر روش شی گرا برای کل ایران در سال ۲۰۱۷ می باشد.

یادگیری ماشین و کاربرد آن در سنجش از دور

مکس ول و همکاران (۲۰۱۸) در پژوهش خود بیان داشته اند که یادگیری ماشین پتانسیل طبقه بندی موثر و کارآمد تصاویر سنجش از دور را ارائه می دهد (۸). نقاط قوت یادگیری ماشینی شامل بالا بردن پتانسیل طبقه بندی موثر و کارآمد تصاویر سنجش از دور، ظرفیت پردازش داده های با ابعاد بالا و جداسازی و تفکیک کاربری های با ویژگی های طیفی مشابه می باشد. متخصصان سنجش از دور به طور فزاینده ای از طبقه بندی کننده های یادگیری ماشین برای نقشه برداری پوشش و کاربری زمین^۵ (LULC) استفاده می کنند (۹). مراحل طبقه بندی یادگیری ماشین به روش نظارت شده به ترتیب شامل برداشت نمونه های آموزشی ، انتخاب الگوریتم یادگیری ، آموزش مدل و در انتها ارزیابی دقت می باشد. الگوریتم های طبقه بندی نظارت شده به کار برده شده در این مطالعه عبارتند از: (۱) حداقل فاصله (۲) حداکثر احتمال یا بیشترین شباهت (۳) شبکه عصبی



شکل ۱. ساختار مفهومی الگوریتم های مختلف یادگیری ماشین به کار برده شده در این مطالعه. الف) حداقل فاصله ب) حداکثر احتمال ج) شبکه عصبی.

⁴ Google Earth Engine

⁵ Land Use and Land Cover

¹ Geographic Information System

² Remote sensing

³ Supervised image classification

روش حداقل فاصله^۶

ایبنا و پونکوثران (۲۰۱۹) در بیان نتایج پژوهش خود که به صورت اختصاصی به بررسی الگوریتم حداقل فاصله پرداخته اند، بیان داشته اند که روش حداقل فاصله زمان کمی را برای آموزش احتیاج دارد، و تمام پیکسل ها نیز طبقه بندی می شوند (۱۰). در عین حال در مطالعه دیگری که توسط (۱۱) در یکی از استان های کشور هندوستان برای ۳ سال، مقایسه ای بر عملکرد روش های مختلف طبقه بندی از جمله حداکثر احتمال و حداقل فاصله و روش های دیگری انجام شده بود، نشان دادند که روش طبقه بندی حداقل فاصله برای یکی از این سه سال مورد بررسی با ضریب کاپای به دست آمده ۷۸/۰۱ از سایر روش ها نتیجه بهتری را به ثبت رسانده و در دو سال دیگر هم با اینکه بهترین روش نبوده اما نتایج بسیار خوبی را از خود به ثبت رسانده و در جداسازی کلاس های مختلف به شکل مطلوبی عمل کرده است.

روش حداکثر احتمال^۷

سونار اربک و ازکان (۲۰۰۴) نیز در مطالعات خود بیان داشتند که روش حداکثر احتمال (بیشترین شباهت) از معروف ترین و پرکاربردترین روش های طبقه بندی اطلاعات در زمره روش های طبقه بندی نظارت شده است (۱۲). در این روش، احتمال اینکه یک پیکسل به تمامی کلاس ها تعلق داشته باشد محاسبه شده و به کلاس با بیشترین احتمال تعلق می گیرد. (۱۳) نیز در پژوهش خود بیان داشتند که طبقه بندی حداکثر احتمال دارای یک نظریه پایه ای دقیق است که در آن می توان به سادگی یک تابع تفکیک کننده کلاس با توزیع نرمال ایجاد کرد.

روش شبکه عصبی^۸

میلر و همکاران (۱۹۹۵) در مطالعه ای که به صورت اختصاصی در رابطه با کارایی الگوریتم شبکه عصبی در سنجش از دور انجام داده بودند بیان داشتند که شبکه های عصبی، نوعی هوش مصنوعی، به ابزارهای عملی برای استفاده در بسیاری از کاربردهای طبقه بندی، تشخیص الگو، بهینه سازی و پیش بینی تبدیل شده اند (۱۴). بیشتر شبکه های عصبی دارای سه لایه و یا بیشتر می باشند. یک لایه ورودی که برای ارائه اطلاعات به شبکه مورد استفاده قرار می گیرد. یک لایه خروجی که برای تولید پاسخ مناسب به ورودی های داده شده استفاده می شود و یک یا چند لایه پنهان که به عنوان آشکار ساز های ویژگی عمل می کنند. تمام گره ها در لایه های مختلف با وزن های مربوطه به یکدیگر متصل شده اند. (۸) در پژوهش کاربردی که بر روی الگوریتم های یادگیری ماشین مختلفی از جمله شبکه های عصبی انجام داده بودند، بیان داشتند که عناصر یک شبکه عصبی مصنوعی نورون ها هستند که در لایه هایی سازماندهی شده اند.

پیشینه تحقیق ها در رابطه با عملکرد الگوریتم های

یادگیری ماشین مختلف

مکس ول و همکاران (۲۰۱۸) در پژوهش خود بیان داشتند که انتخاب یک طبقه بندی کننده یادگیری ماشینی برای یک کار خاص، چالش برانگیز است، نه تنها به دلیل طیف گسترده ای از روش های یادگیری ماشینی موجود، بلکه به این دلیل که تحقیقات مختلف، نتایج متناقضی را بیان داشته اند، و تعمیم در مورد دقت طبقه بندی نسبی الگوریتم های یادگیری ماشینی را دشوار می کند (۸). به طور مثال، (۱۵) دریافتند که شبکه های عصبی ها از درخت تصمیم های منفرد دقیق تر هستند، اما (۱۶) به نتیجه معکوس رسیدند و دریافتند که درخت های تصمیم عملکرد بهتری نسبت به روش شبکه عصبی دارند. یکی از دلایل احتمالی بسیاری از نتایج متناقض در مطالعات مقایسه طبقه بندی، مانند موارد ذکر شده در بالا، این است که رویه های مورد استفاده در مطالعات مختلف ممکن است قابل مقایسه نباشند. بنابراین، یک مطالعه آموزنده خاص، مطالعه (۱۷) است که به طور سیستماتیک عملکرد طیف گسترده ای از الگوریتم های طبقه بندی یادگیری ماشینی را با استفاده از رویه های سازگار و ۳۰ مجموعه داده مختلف مقایسه کردند. (۱۸) در این مطالعه با ابعاد بزرگ، ۱۶۵۱ مقاله که روش های طبقه بندی سنجش از دور را مقایسه کرده و نشان داده که طبقه بندی کننده پارامتریک حداکثر احتمال متداول ترین روش مورد استفاده است که در ۳۲ درصد از مقالات به کار رفته است، اگرچه روش های یادگیری ماشینی دیگر معمولاً دقت بیشتری نسبت به روش حداکثر احتمال دارند. در این مطالعه، تسلط این روش را به در دسترس بودن گسترده آن در بسته های نرم افزاری مرسوم پردازش تصویر سنجش از راه دور نسبت داده است و خواستار توسعه نرم افزار بیشتر و آموزش های مرتبط با یادگیری ماشینی شده است. نکته مهم بعدی در مورد انتخاب طبقه بندی کننده بهینه این می باشد که از آنجایی که توافق روشی در بین نتایج مطالعات مختلف در ادبیات مربوط به بهترین الگوریتم یادگیری ماشینی وجود ندارد، الگوریتم بهینه بسته به کلاس های ترسیم شده، ماهیت داده های آموزشی و متغیرهای پیش بینی کننده به احتمال زیاد در مورد های خاص متفاوت می باشد. بنابراین، مانند (۱۷)، توصیه می شود که در صورت امکان، تحلیلگر باید با چندین طبقه بندی و روش، آزمایش کند تا مشخص کند کدام الگوریتم بهینه را برای یک کار طبقه بندی خاص به کار ببرد.

انگیزه و اهداف

علیرغم در دسترس بودن مجموعه داده های مختلف سنجش از دور از سنسورهای مختلف، هنوز نیاز شدیدی برای بهبود دقت در نقشه های طبقه بندی موضوعی وجود دارد (۱۹). ظهور ماهواره های نسل جدید به عنوان یک مبادله بین مزایای ارائه شده توسط تصاویر چند طیفی و ابرطیفی دیده می شود (۲۰). داده های سنجش از راه دور اولیه دارای

⁶ Minimum Distance

⁷ Maximum likelihood

⁸ Neural network

در این مطالعه به منظور شناسایی حداکثر تغییرات رخ داده در پوشش های اراضی منطقه، در بازه زمانی ۹ ساله از سال ۲۰۱۳ تا ۲۰۲۱، ۳ سال، تر (۲۰۱۹) با ۳۲۱/۲۸ میلی متر، خشک (۲۰۲۱) با ۷۱/۹۲ میلی متر و نرمال (۲۰۱۳) با ۲۴۲/۴۷ میلی متر را بر اساس میزان بارش سالانه به دست آمده از ایستگاه هواشناسی مشخص کردیم. تغییرات بارندگی در محدوده مطالعاتی نیشابور در ۲۱ سال گذشته در شکل ۳ نشان داده شده است.



شکل ۳- تغییرات بارندگی محدوده نیشابور در ۲۱ سال گذشته

روش تحقیق

در این پژوهش جهت پردازش، تحلیل و فراخوانی داده های ماهواره ای از نرم افزار های Envi 5.6، ArcMap 10.7 و نیز برای نهایی سازی نقشه های موضوعی از نرم افزار Qgis 3.16 استفاده شده است. لازم به ذکر هست در این مطالعه از سامانه گوگل ارث انجین نیز که به عنوان قوی ترین سامانه پردازش سری زمانی تصاویر ماهواره ای در علم سنجنش از دور شناخته می شود هم به کار گرفته شده است.

ماهواره ها و باند های طیفی مورد استفاده

برای سال ۲۰۱۳ تصاویر ماهواره Landsat 8 فراخوانی و باند های ۲ تا ۷ و نیز باند حرارتی این ماهواره مورد استفاده قرار گرفته شده است. بر اساس این باند های فراخوانی شده، شاخص های طیفی مختلفی نظیر NDVI، NDBI و نیز MNDWI محاسبه و مورد استفاده قرار گرفته شده است. در کنار این موارد از ماهواره Sentinel 1 که جزوه ماهواره هایی به حساب می آید که از امواج با طول موج بلند مایکروویو برای تشخیص عوارض فیزیکی روی سطح زمین کاربرد زیادی دارد استفاده شده است. برای دو سال ۲۰۱۹ و ۲۰۲۱ علاوه بر استفاده از تصاویر ماهواره های لندست ۸ و سنتینل ۱ و محصولات به دست آمده از طریق آن ها به علت در دسترس بودن تصاویر ماهواره Sentinel 2، این ماهواره نیز مورد استفاده قرار گرفته شده است. برای این دو سال از باند های ۲ تا ۴ و باند های ۸ و ۱۱ برای تولید شاخص های NDVI، NDBI و MNDWI استفاده شده است. در جدول ۵ تمام تصاویر و محصولات آماده ثانویه که با استفاده از ماهواره های مختلف تولید شده و با کمک سامانه ارث انجین برای منطقه مورد مطالعه فراخوانی شده است با ذکر جزئیات بیان شده است در این مطالعه از شاخص های طیفی مختلفی نظیر NDVI، NDBI

تفکیک پذیری های مکانی، طیفی و زمانی محدود بودند که تشخیص تغییرات مبتنی بر سنجنش از دور را به طور قابل توجهی محدود کرده بودند (۲۱). در نتیجه، محققان فهرست رو به رشدی از تکنیک ها، الگوریتم ها و روش های تشخیص تغییرات را بررسی کرده اند (۲۲). علیرغم مزایای استفاده از داده های سنجنش از دور چند زمانه و چند منبع، استفاده از این اطلاعات برای نقشه برداری از مناطق بزرگ، چالش هایی مانند پیچیدگی محاسباتی بالا را به همراه دارد (۲۳). با این حال، پلتفرم های مبتنی بر محاسبات ابری، مانند Google Earth Engine، به طور موثری اشکالات مربوطه را برطرف می کنند (۲۴). گوگل ارث انجین یک پلتفرم بزرگ پردازش داده های جغرافیایی است که برای تجزیه و تحلیل جغرافیایی در مقیاس های بزرگ توسعه یافته است. قابلیت های موجود در گوگل ارث انجین، مانند یک کتابخانه تلفیقی از تصاویر ماهواره ای رایگان، دری را برای نظارت مستمر سطح زمین از طریق وضوح های مکانی و زمانی معقول باز کرده است (۲۴).


مواد و روش ها

منطقه مورد مطالعه

حوزه آبریز دشت نیشابور جزئی از حوضه آبریز کویر مرکزی ایران بوده و در شمال شرق آن قرار می گیرد. این حوضه با وسعت تقریبی کل ۷۲۰۰ کیلومتر مربع که حدود ۴۳۰۰ کیلومتر مربع آن را دشت و بقیه را ارتفاعات تشکیل می دهد. این شهر در دامنه های بلندی های بینالود در شمال شرق ایران جای گرفته است. همچنین در تقسیمات اقلیمی کشور، نیشابور جزو اقلیم فلات مرکزی و نیمه بیابانی است و از نظر میزان بارندگی جزء نواحی خشک محسوب می شود.

توپوگرافی

متوسط ارتفاع منطقه در دشت نیشابور ۱۰۵۰ متر و در کل منطقه ۱۷۴۰ متر است. از نظر وسعت، بخش اعظمی از وسعت شهرستان در نواحی دشت و با محدوده ارتفاعی ۱۰۵۰ متر تا ۱۴۰۰ متر، نواحی کوهپایه ای با ارتفاع ۱۴۰۰ تا ۲۴۰۰ متر و درصد کمی از وسعت منطقه را نواحی مرتفع کوهستانی با محدوده ارتفاعی ۲۴۰۰ متر به بالاتر پوشش داده است.



شکل ۲- موقعیت منطقه مورد مطالعه

های های مورد نیاز در هر ماهواره بیان شده است. در این مطالعه با توجه به شناخت از منطقه مورد پژوهش و نیز تکنیک ها و روش های مختلف استفاده شده ، قادر به شناسایی و تفکیک ۶ کلاس کاربری مختلف در این منطقه خواهیم بود. که نوع و توصیف هر کدام از این کلاس ها در جدول ۷ آورده شده است.

و MNDWI که به ترتیب از راست به چپ شاخص گیاهی تفاوت نرمال شده^۹ ، شاخص شهری تفاوت نرمال شده^{۱۰} و نیز شاخص آب تفاوت نرمال شده بهینه^{۱۱} به منظور جداسازی هر چه بهتر پوشش های گیاهی ، شهری و آب استفاده شده اند. در جدول ۶ مشخصات هر کدام از این شاخص ها به همراه فرمول های محاسبه آن ها بر اساس باند

جدول ۱- ماهواره های مورد استفاده

شماره ردیف	اسم ماهواره	بازه زمانی مورد استفاده	منبع تصاویر	UTM Zone	توان تفکیک مکانی (متر)	توان تفکیک زمانی (روز)	تعداد تصاویر فراخوانی شده
۱۰	Landsat 8 OLI/TIRS	۲۰۱۳/۰۴/۰۱_۲۰۲۱/۱۰/۰۱	United States Geological Survey (USGS)	۴۰N	۳۰_۱۰۰	۱۶	۱۱۱
۲۰	Sentinel-2_Level-2A	۲۰۱۹/۰۱/۰۱_۲۰۲۱/۱۲/۳۰	European Union/ESA/Copernicus	۴۰N	۱۰_۶۰	۵	۱۳۰۰
۳۰	Sentinel-1 SAR GRD	۲۰۱۴/۱۰/۰۳_۲۰۲۱/۱۲/۳۰	European Union/ESA/Copernicus	۴۰N	۱۰	۶	۵۵۷

جدول ۲- باند های طیفی مورد استفاده در Landsat 8 OLI/TIRS

شماره باند	اسم باند	طول موج (μm)	توان تفکیک مکانی (متر)	کاربرد
SR_B2	Blue	۰.۴۵-۰.۵۱	۳۰	نقشه برداری آبی، تبخیر خاک/گیاه
SR_B3	Green	۰.۵۳-۰.۵۹	۳۰	پوشش گیاهی، ارزیابی سلامت گیاهان
SR_B4	Red	۰.۶۴-۰.۶۷	۳۰	شناسایی نوع گیاه، خاک و ویژگی های شهری
SR_B5	Near infrared (NIR)	۰.۸۵-۰.۸۸	۳۰	تشخیص و تجزیه و تحلیل گیاهان
SR_B6	Short-wave infrared 1 (SWIR_1)	۱.۵۷-۱.۶۵	۳۰	تجزیه و تحلیل رطوبت نسبی/خشکسالی
SR_B7	Short-wave infrared 2 (SWIR_2)	۲.۱۱-۲.۲۹	۳۰	تشخیص بهتر آتش سوزی های فعال
ST_B10	Thermal infrared (surface temperature)	۱۰.۶۰-۱۱.۱۹	۱۰۰	نقشه برداری دمای زمین و برآورد رطوبت خاک

جدول ۳- باند های طیفی مورد استفاده در Sentinel 2_Level-2A

شماره باند	اسم باند	طول موج (μm)	توان تفکیک مکانی (متر)
B2	Blue	۰.۴۹	۱۰
B3	Green	۰.۵۶	۱۰
B4	Red	۰.۶۶	۱۰
B8	Near infrared (NIR)	۰.۸۴	۱۰
B11	Short-wave infrared 1 (SWIR_1)	۱.۶۱	۲۰

^{۱۱} Modified Normalized Difference Water Index

^۹ Normalized Difference Vegetation Index

^{۱۰} Normalized Difference Built-up Index

جدول ۴ - باند های طیفی مورد استفاده در Sentinel 1-SAR GRD

مشخصات	سایز پیکسل (متر)	اسم باند
تک قطبی شدن، ارسال عمودی/دریافت عمودی	۱۰	VV
قطبش متقابل دو باند، انتقال عمودی/دریافت افقی	۱۰	VH

جدول ۵- تصاویر و محصولات ثانویه مورد استفاده در این مطالعه

توان تفکیک مکانی (متر)	مرجع	منبع تصاویر	بازه زمانی مورد استفاده	ماهواره مورد استفاده	نوع تصویر	شماره ردیف
۳۰	(۲۵)	JAXA Earth Observation Research Center	۲۰۱۱	Advanced Land Observing Satellite (ALOS)	digital surface model (DSM)	۱.
۳۸	(۲۶)	EC JRC	۲۰۰۰_۲۰۱۳	Landsat7_Landsat8	Global Human Settlement Layers(GHSL)	۲.
۳۰	(۲۷)	EC JRC / Google	۲۰۱۳_۲۰۲۰	Landsat8	JRC Yearly Water Classification History	۳.
۱۰	(۲۸)	Esri Inc.	۲۰۱۹_۲۰۲۱	Sentinel-2	Land use/land cover(LULC)	۴.

جدول ۶- شاخص های طیفی مورد استفاده در این مطالعه

مرجع	فرمول بر اساس باند های مورد استفاده		فرمول	شاخص طیفی
	Sentinel2	Landsat8		
(۲۹)	$\frac{B8 - B4}{B8 + B4}$	$\frac{B5 - B4}{B5 + B4}$	$\frac{NIR - RED}{NIR + RED}$	NDVI
(۳۰)	$\frac{B11 - B8}{B11 + B8}$	$\frac{B6 - B5}{B6 + B5}$	$\frac{SWIR1 - NIR}{SWIR1 + NIR}$	NDBI
(۳۱)	$\frac{B3 - B11}{B3 + B11}$	$\frac{B3 - B6}{B3 + B6}$	$\frac{GREEN - SWIR1}{GREEN + SWIR1}$	MNDWI

جدول ۷- کلاس های کاربری شناسایی شده در منطقه مورد مطالعه

کلاس کاربری اراضی	توصیف	کد مربوطه
اراضی شهری	این دسته شامل سکونتگاه های شهری و خانه های پراکنده روستایی، ارتباطات حمل و نقل و تاسیسات می شود.	۱
اراضی کشاورزی	این دسته شامل مناطق تحت پوشش محصولات چند ماهه و یکساله شامل گندم و جو و پسته و..... می شود.	۲
پوشش درختی	این دسته شامل باغات و درختچه های متراکم و پوشش های درختی متفاوتی که در تمام طول سال وضعیت رشد ثابتی رو دارند.	۳
پهنه آبی	این دسته شامل آب های آزاد دائمی شهر، رودخانه ها، نهرها، دریاچه ها، برکه ها و مخازن مختلف را پوشش می دهند.	۴

۵	اراضی بایر	این دسته شامل زمین ها بدون پوشش گیاهی یا دارای پوشش گیاهی خیلی ضعیف ، زمین های زراعی رها شده ، زمین های فرسوده شده به دلیل تخریب زمین ، مکان های دفن زباله و زمین های حفاری فعال میشود.
۶	مراتع	این دسته شامل مناطق پوشیده شده از درختان تنک با علف های متراکم و اراضی مرتعی با پوشش گیاهان بوته ای و بخش های محصور از زمین های کشاورزی است که توسط دام های اهلی مانند اسب، گاو، گوسفند چرا می شوند.

فرایند ها و مرحله های مختلف طی شده در این پژوهش به صورت خلاصه آورده شده است.

تعداد و نحوه توزیع نمونه های تعلیمی و کنترل برداشت شده برای هر کاربری در هر سال


در ادامه نمونه های تعلیمی برای تولید نقشه های طبقه بندی برای هر کاربری و نیز برای هر سال در سامانه ارث انجین بر روی این تصاویر چند بانده برداشت و جمع آوری می گردد همچنین برای ارزیابی نتایج طبقه بندی بر اساس هر الگوریتم نیز نمونه های کنترل با استفاده از تصاویر گوگل ارث برای کاربری های مربوطه در هر سال برداشت شده اند. که نحوه توزیع و پراکنش و تعداد این نمونه های تعلیمی و کنترل در جدول ۸ و شکل های ۴ و ۵ آورده شده است. در شکل ۶ ، تمام

جدول ۸- نحوه پراکنش و تعداد نمونه های تعلیمی و کنترل در کاربری های مختلف برای هر سال						
۱۴۰۰		۱۳۹۸		۱۳۹۲		
نمونه های کنترل	نمونه های تعلیمی	نمونه های کنترل	نمونه های تعلیمی	نمونه های کنترل	نمونه های تعلیمی	کلاس کاربری اراضی
۱۰۱	۲۳۰	۱۰۵	۲۱۲	۲۰۰	۳۳۹	اراضی شهری
۱۰۰	۳۹۳	۱۰۵	۵۱۳	۱۰۰	۳۴۳	اراضی کشاورزی
۱۰۰	۳۴۴	۱۰۴	۳۲۰	۱۰۰	۳۳۸	پوشش درختی
۷۰	۱۵۴	۹۱	۲۳۱	۷۰	۲۲۵	پهنه آبی
۱۰۰	۲۶۰	۱۰۵	۲۷۰	۹۹	۳۲۲	اراضی بایر
۱۰۰	۳۶۳	۱۰۴	۴۶۰	۹۸	۳۹۹	مراتع
۵۷۱	۱۷۴۴	۶۱۴	۲۰۰۶	۶۶۷	۱۹۶۶	تعداد کل

نمونه های تعلیمی ۱۳۹۲

نمونه های تعلیمی ۱۳۹۸

نمونه های تعلیمی ۱۴۰۰




شکل ۴- نحوه توزیع نمونه های تعلیمی برداشت شده در سامانه ارت انجین برای منطقه نیشابور برای سال های ۱۳۹۲، ۱۳۹۸ و ۱۴۰۰


نمونه های کنترل ۱۳۹۲

نمونه های کنترل ۱۳۹۸

نمونه های کنترل ۱۴۰۰



شکل ۵- نحوه توزیع نمونه های کنترل برداشت شده با استفاده از تصاویر گوگل ارت برای منطقه نیشابور برای سال های ۱۳۹۲، ۱۳۹۸ و ۱۴۰۰




شکل ۶- مراحل و روند اجرایی تحقیق


نتایج

طبقه بندی تصاویر و استخراج کلاس های کاربری مختلف

در ادامه نقشه های طبقه بندی شده برای سال های ۱۳۹۲، ۱۳۹۸ و ۱۴۰۰ بر اساس تمام الگوریتم های ذکر شده آورده شده است.




شکل ۸- نقشه های طبقه بندی شده پوشش و کاربری اراضی منطقه نیشابور با استفاده از الگوریتم های حداقل فاصله، حداکثر احتمال و شبکه عصبی برای سال ۱۳۹۸



شکل ۷- نقشه های طبقه بندی شده پوشش و کاربری اراضی منطقه نیشابور با استفاده از الگوریتم های حداقل فاصله، حداکثر احتمال و شبکه عصبی برای سال ۱۳۹۲

مورد ماتریس خطا در بر می گیرند (۳۲). استفاده از معیارهای متفاوت بیان کننده دقت ممکن است به تفاسیر و نتایج متفاوت و احتمالاً متناقض منجر شود (۳۳). در این قسمت به پرکاربردترین معیارهای بیان کننده دقت که در اکثر مطالعات و پژوهش های به کار رفته است اشاره می کنیم. معیارهای ارزیابی دقت مورد استفاده در این مطالعه شامل پارامترهای صحت کلی، ضریب کاپا، دقت تولید کننده، دقت کاربر، خطای omission و خطای commission می باشند. تحقیقات سنجش از دور اولیه بر دستیابی به محصولات نقشه موضوعی به دست آمده از سنجش از دور که تقریباً دقت ۸۵٪ را دارا می باشد، تأکید داشتند (۳۴).


ارزیابی عملکرد الگوریتم های مختلف یادگیری ماشین
عملکرد تمامی روش های ذکر شده با توجه به نتایج پارامترهای مختلف موجود در ماتریس خطا های تولید شده برای هر کدام، مورد ارزیابی قرار گرفته که در بین آن ها روش حداقل فاصله در هیچ کدام از سال های مورد مطالعه نتوانست عملکرد مطلوبی را از خود به جای بگذارد در مقایسه با آن، سایر الگوریتم ها در هر سال و با توجه به ورودی های مختلفی که داشتند، قادر به تولید نقشه های طبقه بندی با دقت مطلوبی برای هر کاربری شده اند. نتایج بررسی عملکرد تمامی روش های مورد استفاده در این مطالعه در شکل های ۱۰، ۱۱، ۱۲ و ۱۳ نشان داده شده است.




شکل ۹- نقشه های طبقه بندی شده پوشش و کاربری اراضی منطقه نیشابور با استفاده از الگوریتم های حداقل فاصله، حداکثر احتمال و شبکه عصبی برای سال ۱۴۰۰

ارزیابی دقت


هیچ توافقی در مورد یک رویکرد استاندارد برای ارزیابی دقت نقشه موضوعی بر اساس تجزیه و تحلیل ماتریس های خطا وجود ندارد. هر اندازه گیری دقت ممکن است برای یک هدف خاص از سایر معیارها مرتبط تر باشد زیرا معیارهای دقت مختلف، اطلاعات متفاوتی را در




شکل ۱۰- مقایسه عملکرد الگوریتم های مختلف یادگیری ماشین برای هر سه سال ۱۳۹۲، ۱۳۹۸ و ۱۴۰۰ بر اساس پارامترهای صحت کلی و ضریب کاپا.



شکل ۱۱- مقایسه عملکرد الگوریتم های مختلف یادگیری ماشین در جداسازی کاربری های مختلف برای سال ۱۳۹۲ بر اساس پارامتر های دقت تولید کننده و دقت کاربر.



شکل ۱۲- مقایسه عملکرد الگوریتم های مختلف یادگیری ماشین در جداسازی کاربری های مختلف برای سال ۱۳۹۸ بر اساس پارامتر های دقت تولید کننده و دقت کاربر.



شکل ۱۳- مقایسه عملکرد الگوریتم های مختلف یادگیری ماشین در جداسازی کاربری های مختلف برای سال ۱۴۰۰ بر اساس پارامتر های دقت تولید کننده و دقت کاربر.

بحث و نتیجه گیری

در این تحقیق با بهره جستن از امکانات و توان پردازشی بسیار بالای سامانه ارث انجین در فراخوانی و پردازش تصاویر ماهواره ای ، سعی در بررسی تغییرات پوشش و کاربری اراضی در شهرستان نیشابور به روش های مختلف شده است. در این تحقیق سعی شده که برای نشان دادن حداکثر میزان تغییرات رخ داده در سطح پوشش های اراضی در بازه زمانی مورد مطالعه ۳ سال ، تر ، خشک و نرمال بر اساس اطلاعات بارش سالانه انتخاب و تصاویر مربوط به این تاریخ ها مورد پردازش و تحلیل قرار بگیرند. بر اساس نتایج به دست آمده مشخص گردید که الگوریتم حد اقل فاصله در هیچ کدام از سال ها قادر به تولید نقشه های طبقه بندی با دقت و صحت مطلوب نبوده. در مقایسه ، سایر روش های طبقه بندی کننده هر کدام در هر سال عملکرد قابل قبول و البته متفاوتی را چه به صورت کلی و چه در مورد توانایی و قابلیت هر روش در جداسازی کاربری ها با رفتارهای طیفی متفاوت از خود نشان داده اند در سال ۱۳۹۸ الگوریتم حداکثر احتمال و در سال های ۱۳۹۲ و ۱۴۰۰ نیز الگوریتم شبکه عصبی بهترین نتایج را به دست آورده بودند.

based_cellular_automata_and_weight
s-of-evidence_techniques

- Serra P, Pons X, Saurí D. Land-cover and land-use change in a Mediterranean landscape: A spatial analysis of driving forces integrating

ملاحظات اخلاقی پیروی از اصول اخلاق پژوهش

همکاری مشارکت کنندگان در تحقیق حاضر به صورت داوطلبانه و با رضایت آنان بوده است.

حامی مالی

هزینه تحقیق حاضر توسط نویسندگان مقاله تامین شده است.

مشارکت نویسندگان

تعارض منافع

بنابر اظهار نویسندگان، مقاله حاضر فاقد هرگونه تعارض منافع بوده است.

References

- https://www.researchgate.net/publication/323960416_Land_use_change_modeling_and_the_effect_of_compact_city_paradigms_integration_of_GIS-

- biophysical and human factors. Appl Geogr. 2008;28(3):189-209.
3. Chen X, Vierling L, Deering D. A simple and effective radiometric correction method to improve landscape change detection across sensors and across time. Remote Sens Environ. 2005;98(1):63-79.
4. <https://ate.community/index.php?P=FullRecord&ID=38494elevation-data-and-air-photos/tutorial-fundamentals-remote-sensing/9309>
5. Kumar L, Mutanga O. Google Earth Engine Applications. Google Earth Engine Applications. 2019.
6. Kumar L, Mutanga O. Google Earth Engine Applications Since Inception : 2018;1-15.
7. <https://ui.adsabs.harvard.edu/abs/2020JPRS..167..276G/abstract>
8. <https://www.tandfonline.com/doi/full/10.1080/01431161.2018.1433343>
9. https://www.researchgate.net/publication/328226839_Guidance_on_and_comparison_of_machine_learning_classifiers_for_Landsat-based_land_cover_and_land_use_mapping
10. Abinaya V, Poonkuntran S. Classification of Satellite Image using Minimum Distance Classification Algorithm. 2019;(1):15-8.
11. Sisodia PS, Tiwari V, Kumar A. A comparative analysis of remote sensing image classification techniques. Proc 2014 Int Conf Adv Comput Commun Informatics, ICACCI 2014. 2014;1418-21.
12. Sunar Erbek F, Özkan C. Comparison of maximum likelihood classification method with supervised artificial neural network algorithms for land use activities. Int J Remote Sens. 2004;27(10):1973-91.
13. Liang S, Cheng J, Zhang J. Maximum likelihood classification of soil remote sensing image based on deep learning. 2020;24(3):357-65.
14. Miller DM, Kaminsky EJ, Rana S. Neural network classification of remote-sensing data. Comput Geosci. 1995;21(3):377-86.
15. Rogan J, Franklin J, Stow D, Miller J, Woodcock C, Roberts D. Mapping land-cover modifications over large areas: A comparison of machine learning algorithms. Remote Sens Environ. 2008;112:2272-83.
16. Lippitt CD, Rogan J, Li Z, Eastman JR, Jones TG. Mapping Selective Logging in Mixed Deciduous Forest: A Comparison of Machine Learning Algorithms. Photogramm Eng Remote Sens. 2008;74(10):1201-11.
17. Lawrence RL, Moran CJ. Remote Sensing of Environment The AmericaView classification methods accuracy comparison project: A rigorous approach for model selection. Remote Sens Environ [Internet]. 2015;170:115-20. Available from: https://www.researchgate.net/publication/282329051_The_AmericaView_classification_methods_accuracy_comparison_project_A_rigorous_approach_for_model_selection
18. Le Yu LL. International Journal of Remote Meta-discoveries from a synthesis of satellite-based land-cover mapping. 2014;(September):37-41.
19. Schuster C, Förster M, Kleinschmit B. Testing the red edge channel for improving land-use classifications

- based on high-resolution multi-spectral satellite data. *Int J Remote Sens.* 2012;(September 2013):37-41.
20. https://www.researchgate.net/publication/257128805_High_density_biomass_estimation_for_wetland_vegetation_using_WorldView-2_imagery_and_random_forest_regression_algorithm *International Journal of Applied Earth Observation and Geoinformation* 18_399-406
21. <https://www.semanticscholar.org/paper/An-overview-of-recent-remote-sensing-and-GIS-based-Boyd-Foody/9ad794a701633a6b902daac3a3d7d90c19050cb6>
22. Si Salah H, Goldin SE, Rezgui A, Nour El Islam B, Ait-Aoudia S. What is a remote sensing change detection technique? Towards a conceptual framework. *Int J Remote Sens* [Internet]. 2020;41(5):1788-812. Available from: https://www.researchgate.net/publication/352546314_What_is_a_remote_sensing_change_detection_technique_Towards_a_conceptual_framework
23. <https://www.tandfonline.com/doi/full/10.1080/22797254.2020.1850179>
24. https://www.researchgate.net/publication/322939072_Geospatial_analysis_of_land_use_change_in_the_Savannah_River_Basin_using_Google_Earth_Engine
25. Tadono T, Ishida H, Oda F, Naito S, Minakawa K, Iwamoto H. Precise Global DEM Generation by ALOS PRISM. *ISPRS Ann Photogramm* Remote Sens Spat Inf Sci. 2014;II-4(May):71-6.
26. Pesaresi M, Ehrlich D, Ferri S, Florczyk AJ, Freire S, Halkia M, et al. Operating procedure for the production of the Global Human Settlement Layer from Landsat data of the epochs 1975, 1990, 2000, and 2014; JRC Technical Reports EUR 27741 EN [Internet]. Publications Office of the European Union. 2016. 62 p. Available from: doi:10.2788/253582 (online)
27. https://www.researchgate.net/publication/311467513_High-resolution_mapping_of_global_surface_water_and_its_long-term_changes
28. Brown CF, Brumby SP, Guzder-williams B, Birch T, Hyde SB, Mazzariello J, et al. Dynamic World , Near real-time global 10 m land use land cover mapping. *Nature.* 2022;1-17.
29. Huang S, Tang L, Hupy JP, Wang Y, Shao G. A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular <https://link.springer.com/article/10.1007/s11676-020-01155-1>
30. Zha Y, Gao J, Ni S. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *Int J Remote Sens.* 2003;(November 2012):37-41.
31. Xu H. Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *Int J*

- Remote Sens. 2006;(November 2012):37-41.
32. Jensen JR. Introductory Digital Image Processing A Remote Sensing Perspective.
33. Foody GM. Status of land cover classification accuracy assessment. Remote Sens Environ. 2002;80:185-201.
34. Anderson JR, Hardy EE, Roach JT, Witmer RE. A Land Use and Land Cover Classification System for Use with Remote Sensor Data. 1976.