

Original Article



Land Use and Land Cover Classification by Combining GLCM, SNIC, and Machine Learning Algorithms in Google Earth Engine Environment (Case Study: Part of the Lands of North Mahabad, West Azerbaijan) Mahdi Naderi*

Affiliation

Dep. of Remote Sensing and
GIS, Tarbiat Modares
University, Tehran, Iran

ABSTRACT

Introduction: In recent decades, land use and land cover changes information has been successfully derived from remote sensing data at various levels, from local to global scale. Accurate and frequent monitoring of these changes is required for urban planning, precision agriculture, and sustainable management of land resources. The availability of remote sensing data by providing different levels of spatial details, as well as the development of satellite image classification algorithms, has made object-oriented approaches more useful in land use and land cover (LULC) classification compared to traditional approaches. Therefore, in this study, an object-oriented approach using a combination of GLCM, SNIC, and machine learning algorithms is presented to classify the LULC of a part of the lands of North Mahabad, West Azerbaijan, in 2019 using satellite images in Google Earth Engine.

Data and Methods: For this purpose, after preparing the initial dataset, which contains the bands of Sentinel-1 and Sentinel-2 images, the ALOS digital surface model, and NDVI, BSI, SAVI, and total scattering power (TSP) indices, two pixel-based and object-oriented approaches, as well as the random forest algorithm, were used to classify land use and land cover, and their results were compared to explain the best approach in terms of the accuracy of the various classes. In the object-oriented approach, textural measures were extracted by applying the GLCM matrix to the initial dataset. Due to the increase in the number of bands, the PCA method was used to reduce the dimensions of the image. Finally, by combining the PC1 layer and the segmentation layer obtained from the SNIC algorithm, the random forest algorithm was considered to produce land use and land cover maps of the study area.

Results and Discussion: According to the research findings, the object-oriented approach performed better than the pixel-based approach in classifying various land use classes in the study area, with an overall accuracy and kappa coefficient of 86.40% and 0.8307, respectively, compared to 82.73% and 0.8028. The results of the accuracy evaluation criteria showed that the producer accuracy of most of the classes except for corn, fall irrigated vegetables, wheat, and barley irrigated in the object-oriented approach was higher than the pixel-based method, and their classification accuracy was more than 90%. Additionally, water, build-up, corn, and sugar beet classes have the highest user accuracy in the object-oriented LULC map.

Conclusion: The findings showed that the appropriate determination of the super-pixel size of the SNIC clustering algorithm and the use of GLCM texture criteria effectively improved the performance of the proposed approach in land use and land cover classification.

Keywords: Object-oriented Classification, Random forest, Spectral indices, Radar and optic data, Super-pixel size.

Citation:

Naderi, M., *Land Use and Land Cover Classification by Combining GLCM, SNIC, and Machine Learning Algorithms in Google Earth Engine Environment (Case Study: Part of the Lands of North Mahabad, West Azerbaijan)*, Iran J Remote Sens GIS, 17(1):41-60.

* Corresponding Author: naderimahdi@modares.ac.ir
DOI: <https://doi.org/10.48308/GISJ.2023.233271.1181>

Received: 2023.09.28
Accepted: 2023.11.27



Copyright: © 2025 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license <https://creativecommons.org/licenses/by/4.0/>.



طبقه‌بندی کاربری و پوشش زمین با ترکیب الگوریتم‌های SNIC، GLCM و یادگیری ماشین در سامانه گوگل ارث انجین (مطالعه موردی: بخشی از اراضی شمال مهاباد، آذربایجان غربی)

مهدي نادري

چکیده

سابقه و هدف: در دهه‌های گذشته، داده‌های سنجش از دور با موفقیت برای استخراج اطلاعات و تغییرات کاربری و پوشش زمین (LULC) در سطوح گوناگون، از مقیاس محلی تا جهانی، به کار رفته است. پایش دقیق و منظم این تغییرات در برنامه‌ریزی شهری، کشاورزی دقیق و مدیریت پایدار منابع زمین ضرورت دارد. فراهمی داده‌های سنجش از دور با ارائه سطوح بی‌سابقه‌ای از جزئیات مکانی و همچنین توسعه الگوریتم‌های طبقه‌بندی تصاویر ماهواره‌ای، باعث شده است که رویکردهای شیء‌گرا، در مقایسه با رویکردهای معمول، در طبقه‌بندی کاربری و پوشش زمین کاربرد بیشتری پیدا کنند. بدین‌منظور، در این مطالعه، رویکردی شیء‌گرا با ترکیب الگوریتم‌های SNIC، GLCM و یادگیری ماشین مطرح شده که هدف از آن طبقه‌بندی کاربری و پوشش زمین بخشی از اراضی شمال مهاباد در آذربایجان غربی، با استفاده از تصاویر ماهواره‌ای سنتینل-۲ در سال ۲۰۱۹ در سامانه گوگل ارث انجین بوده است.

مواد و روش‌ها: روش انجام شدن این پژوهش به‌گونه‌ای است که ابتدا مجموعه داده اولیه، شامل باندهای هدف تصاویر سنتینل-۱ و سنتینل-۲، مدل رقومی سطح زمین ALOS و شاخص‌های NDVI، BSI، SAVI و توان بازپراکنش کل (TSP) آماده‌سازی شد. در مرحله دوم، با اتخاذ دو رویکرد پیکسل‌پایه و شیء‌گرا و الگوریتم جنگل تصادفی، کاربری و پوشش زمین طبقه‌بندی شد و نتایج حاصل از آنها، برای تبیین بهترین رویکرد از نظر دقت کلاس‌های گوناگون، مقایسه شد. در رویکرد شیء‌گرا، معیارهای بافتی با اعمال ماتریس وقوع توأم گام‌های خاکستری (GLCM) روی مجموعه داده اولیه استخراج شد و با توجه به افزایش تعداد باندها روش تحلیل مؤلفه‌های اصلی (PCA)، برای کاهش ابعاد تصویر، به کار رفت. در گام آخر، با ترکیب لایه PC1 و لایه قطعه‌بندی حاصل از الگوریتم خوشه‌بندی ساده غیرتکراری (SNIC)، الگوریتم جنگل تصادفی به‌منظور تهیه نقشه‌های کاربری و پوشش زمین محدوده مطالعاتی در نظر گرفته شد.

نتایج و بحث: تحلیل معیارهای ارزیابی صحت نشان داد که رویکرد شیء‌گرا با صحت کلی و ضریب کاپای معادل 0/86/40 و 0/8307، در مقایسه با رویکرد پیکسل‌پایه با صحت کلی و ضریب کاپای 0/82/73 و 0/8028، نتایج بهتری را در طبقه‌بندی کاربری‌های متفاوت اراضی منطقه مورد مطالعه داشته است. نتایج معیارهای ارزیابی صحت نشان داد صحت تولیدکننده اغلب کلاس‌های کاربری، به‌جز ذرت، سبزیجات آبی پاییزه و گندم و جو آبی، در رویکرد شیء‌گرا بیشتر از روش پیکسل‌پایه است و دقت طبقه‌بندی آنها بالاتر از ۹۰٪ بوده است. علاوه‌براین، کاربری‌های پوشش‌های پهنه آبی، ساخته‌شده، ذرت و چغندر قند بیشترین صحت کاربر را در نقشه کاربری و پوشش زمین شیء‌گرا به خود اختصاص داده‌اند.

نتیجه‌گیری: یافته‌های تحقیق نشان دادند که تعیین مناسب اندازه سوپرپیکسل الگوریتم خوشه‌بندی SNIC و به‌کارگیری معیارهای بافتی GLCM به‌طور مؤثری عملکرد رویکرد پیشنهادی را در طبقه‌بندی کاربری و پوشش زمین، بهبود می‌بخشد.

واژه‌های کلیدی: طبقه‌بندی شیء‌گرا، جنگل تصادفی، شاخص‌های طیفی، داده رادار و اپتیک، اندازه سوپرپیکسل.

استناد: نادری، م.، طبقه‌بندی کاربری و پوشش زمین با ترکیب الگوریتم‌های SNIC، GLCM و یادگیری ماشین در سامانه گوگل ارث انجین (مطالعه موردی: بخشی از اراضی شمال مهاباد، آذربایجان غربی)، نشریه سنجش از دور و GIS ایران، سال ۱۷، شماره ۱، بهار ۱۴۰۴، ۴۱-۴۰ ع.



۱- مقدمه

مناطق کشاورزی، در طول مکان و زمان در سراسر جهان، به سرعت در حال تغییرند که این تغییرات نتیجه تغییر پوشش زمین بر اثر فعالیت‌های انسانی و فرایندهای طبیعی (Joshi et al., 2016) و همچنین تغییر اقلیم است. کاربری و پوشش زمین (LULC)^۱ به نحوه استفاده از زمین برای اهداف گوناگون انسانی، مانند کشاورزی و مناطق مسکونی یا ویژگی‌های فیزیکی سطح زمین، مانند پهنه‌های آبی، علفزارها و صخره‌ها اشاره دارد (Tassi & Vizzari, 2020). نقشه‌برداری و به دست آوردن اطلاعات دقیق و مطمئن از تغییرات LULC در مطالعات درباره گرمایش جهانی (Zhou et al., 2021)، مطالعات تغییر اقلیم (Yang et al., 2013)، برنامه‌ریزی شهری و مدیریت پایدار منابع (Khalil & ul-Haque, 2018) و همچنین تنوع زیستی و مطالعات زیست‌محیطی (Dronova et al., 2015) ضرورت دارد.

پرکاربردترین روش رایج طبقه‌بندی LULC تفسیر بصری است که نیازمند کارشناسی آموزش دیده و بیان گزارش‌های دقیق درباره کاربری‌های گوناگون زمین در منطقه مورد نظر است. چنین تفسیر بصری‌ای به ارائه درکی دقیق درباره منطقه‌ای معین کمک می‌کند اما درعین حال ممکن است، برای تحلیل‌های LULC در مقیاس بزرگ، نامطمئن و نامناسب باشد (Darem et al., 2023). علاوه بر این تهیه اطلاعات LULC با استفاده از رویکردهای معمول، مانند پیمایش میدانی یا عکس‌های هوایی، پرهزینه و زمان‌بر است (Ali et al., 2018). در یک تقسیم‌بندی کلی، طبقه‌بندی تصاویر ماهواره‌ای در سطح پیکسل و شیء انجام می‌شود. طبقه‌بندی پیکسل پایه براساس اطلاعات موجود در هر پیکسل عمل می‌کند و در مناطقی با ناهمگونی طیفی بالا، اغلب به اثر فلفل نمکی^۲ منجر می‌شود. این نوع طبقه‌بندی معمولاً برای ارزیابی تصاویر ماهواره‌ای دارای وضوح اندک (مانند ارزیابی پوشش جنگلی یا منطقه زراعی) مناسب است (Shendryk et al., 2019). تحلیل تصویر مبتنی بر

شیء (OBIA)^۳ شامل قطعه‌بندی تصویر به اشیای متمایز، براساس ویژگی‌های فیزیکی آنها، مانند شکل و بافت و اختصاص یک کلاس LULC به هر شیء می‌شود (Darem et al., 2023). با توجه به پیشرفت‌های اخیر در زمینه الگوریتم‌های قطعه‌بندی تصویر، رویکردهای شیء‌گرا به دلیل توانایی در ترسیم و طبقه‌بندی چشم‌انداز با مقیاس‌های گوناگون، در مقایسه با رویکردهای معمول، کاربرد بیشتری پیدا کرده‌اند (Blaschke, 2010).

رویکردهای شیء‌گرا، به رغم هزینه‌های محاسباتی بیشتر قطعه‌بندی و استفاده از چندین ویژگی در طبقه‌بندی، به طور کلی نتایج بهتری را هنگام استفاده از داده‌هایی با وضوح مکانی بالاتر به دست می‌دهند (Solano et al., 2019؛ Messina et al., 2020). با وجود کارآمدی داده‌های سنجش از دور به علت قرار دادن سطوح بی سابقه جزئیات مکانی در دسترس عموم و همچنین رویکردهای شیء‌گرا در طبقه‌بندی LULC، استفاده از این اطلاعات برای نقشه برداری مناطق بزرگ سبب ایجاد چالش‌هایی، مانند پیچیدگی محاسباتی بالا می‌شود (Shaharum et al., 2019). با این حال پلتفرم‌های مبتنی بر فضای ابری، مانند سامانه گوگل ارث انجین (GEE)^۴، به طور مؤثری اشکالات مربوط را برطرف می‌کنند. قابلیت‌های GEE، مانند کتابخانه‌ای تلفیقی از تصاویر ماهواره‌ای رایگان با قدرت تفکیک‌های مکانی و زمانی مناسب، امکان پایش مستمر سطح زمین را فراهم آورده است (Zurqani et al., 2018). در راستای تحقیق حاضر، با به کارگیری فناوری سنجش از دور و تکنیک‌های پردازش تصاویر ماهواره‌ای، مطالعات متعددی در سطوح داخلی و بین‌المللی انجام شده است. استفاده از رویکردهای یادگیری ماشین در طبقه‌بندی LULC در مقایسه با طبقه‌بندی‌کننده‌های آماری، مانند

1. Land Use Land Cover
2. Salt-and-Pepper Effect
3. Object-Based Image Analysis
4. Google Earth Engine

حداکثر شباهت^۱ و فاصله ماخالانوبیس^۲ که مبتنی بر نظریه آماری اند، معمولاً به دلیل این واقعیت است که طبقه‌بندی کننده‌های آماری به ویژگی‌های آماری داده‌ها وابسته‌اند. حداکثر احتمال فرض می‌کند که داده‌ها توزیعی نرمال داشته‌اند و فاصله ماخالانوبیس فرض می‌کند کوواریانس همه کلاس‌ها برابر است. این مفروضات، درباره داده‌ها، محدودیت‌هایی ایجاد می‌کند که دقت نسبی طبقه‌بندی کننده‌ها را کاهش می‌دهد (Olson, 2009).

دلفان^۳ و همکاران (۲۰۲۰) قابلیت تصاویر ماهواره‌ای سنتینل-۲ و لندست-۸ در تهیه نقشه کاربری و پوشش زمین با استفاده از رویکردهای پیکسل پایه و شیء‌گرا را ارزیابی کردند. طبق نتایج پژوهش آنها، به کارگیری تصاویر سنتینل-۲ و رویکرد شیء‌گرا باعث بهبود نتایج طبقه‌بندی کاربری و پوشش زمین می‌شود. حاجی^۴ و همکاران (۲۰۲۲)، برای ارزیابی تغییرات پوشش/کاربری اراضی در حوضه آبخیز روضه‌چای ارومیه، از تصاویر ماهواره‌ای لندست و رویکرد شیء‌گرا در بازه زمانی ۱۹۸۵-۲۰۱۵ بهره بردند. نتایج این تحقیق صحت بالای روش شیء‌گرا در طبقه‌بندی LULC را نشان داد. محمدی و خدابنده‌لو^۵ (۲۰۲۰)، با استفاده از تصاویر ماهواره‌ای لندست و تحلیل‌های شیء‌گرا، تغییرات کاربری اراضی شهر زنجان را مطالعه کردند. برپایه صحت کلی و ضریب کاپا، الگوریتم‌های طبقه‌بندی شیء‌گرا در سال ۲۰۱۹ و طبقه‌بندی ماشین بردار پشتیبان در سال‌های ۱۹۹۹ و ۲۰۰۹، بهترین نتایج را دربرداشتند. قربانیان^۶ و همکاران (۲۰۲۰)، با استفاده از هم‌افزایی چندزمانه مجموعه داده‌های ماهواره‌ای سنتینل-۱ و سنتینل-۲ و الگوریتم‌های جنگل تصادفی و SNIC، نقشه کاربری و پوشش زمین بهبودیافته‌ای مبتنی بر شیء را با سیزده کلاس کاربری و وضوح مکانی ده متر ارائه دادند. صحت کلی و ضریب کاپای نقشه نهایی، برای سال ۲۰۱۷، به ترتیب ۹۵/۶٪ و ۹۵/۰٪ برآورد شد که نشان‌دهنده پتانسیل درخور توجه روش پیشنهادی، در طبقه‌بندی

کاربری و پوشش اراضی است. هدایتی^۷ و همکاران (۲۰۲۲) به منظور آشکارسازی اراضی شالیزاری شهر رشت، شاخص‌های طیفی، مدل رقومی ارتفاعی ALOS و رویکرد شیء‌گرا را به کار بردند. صحت کلی و ضریب کاپای رویکرد طبقه‌بندی شیء‌گرا، در این پژوهش، به ترتیب ۹۴٪ و ۹۲/۰٪ برآورد شد. شونگ^۸ و همکاران (۲۰۱۷) با استفاده از الگوریتم‌های RF و SVM و همچنین قطعه‌بندی با روش سلسله‌مراتبی بازگشتی، نقشه کاربری اراضی قاره آفریقا را تهیه کردند. یافته‌های تحقیق گویای صحت کلی ۹۴٪، صحت تولیدکننده ۸۵/۹٪ و صحت کاربر ۶۸/۵٪ درمورد کلاس اراضی زراعی بود. در برخی مطالعات مبتنی بر گوگل ارث انجین، فرایند قطعه‌بندی تصویر در خارج از محیط GEE توسعه یافته و از ماتریس GLCM برای بهبود فرایند طبقه‌بندی استفاده شده است. استرامن^۹ و همکاران (۲۰۱۹) رویکردی پیشنهادی، مبتنی بر الگوریتم ماشین بردار پشتیبان، شاخص‌های طیفی، ماتریس GLCM و قطعه‌بندی در نرم‌افزار تجاری را به منظور طبقه‌بندی شیء‌گرای پوشش زمین، در دو منطقه شهری متفاوت استکهلم و پکن، مطرح کردند. نتایج این تحقیق نشان داد که ادغام ویژگی‌های یادشده تفکیک‌پذیری بین کلاس‌های پوشش زمین شهری و کاربری زمین را بهبود می‌بخشد. چریری^{۱۰} و همکاران (۲۰۲۰) رویکردی شیء‌گرا را براساس طبقه‌بندی تصاویر سنتینل-۲، با استفاده از الگوریتم خوشه‌بندی SNIC و طبقه‌بندی کننده جنگل تصادفی، پیشنهاد کردند. نتایج تجربی نشان داد که نقشه حاصل از طبقه‌بندی

1. Maximum Likelihood

2. Mahalanobis Distance

3. Delfan

4. Haji

5. Mohammadi & Khodabandehlou

6. Ghorbanian

7. Hedayati

8. Xiong

9. Stromann

10. Djerriri

2018; Hedayati et al., 2022; Mohammadi & Khodabandehlou, 2020)، ویژگی‌های متعددی به همراه لایه قطعه‌بندی مستخرج از نرم‌افزارهای تجاری، در بستر گوگل ارث انجین، به‌منظور طبقه‌بندی LULC استفاده شده است. بنابراین مجموع موارد بیان‌شده از نوآوری‌های این تحقیق محسوب می‌شود.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه


منطقه‌ای که نقشه کاربری و پوشش اراضی آن تهیه شد بخشی از اراضی شمال شهرستان مهاباد، واقع در استان آذربایجان غربی است. این شهر، با مساحت حدود ۲۵۹۱ کیلومترمربع، در دامنه کوه لند شیخان قرار گرفته است. براساس سرشماری عمومی نفوس و مسکن کشور در سال ۱۳۹۵، جمعیت این شهر ۱۶۸۳۹۳ نفر بوده است. حداکثر و حداقل ارتفاع محدوده، به ترتیب، حدود ۲۵۰۰ و ۱۲۷۰ متر از سطح دریاست. از نظر شرایط آب‌وهوایی، باتوجه به قرار گرفتن این شهر در شمال باختری ایران، آب‌وهوای معتدل کوهستانی با تابستان‌های خنک و زمستان‌های بسیار سرد دارد. متوسط بارش این شهر ۳۵۰ میلی‌متر در سال گزارش شده است. از لحاظ موقعیت جغرافیایی، محدوده مطالعاتی تحقیق حاضر در ۳۶ درجه و ۴۵ دقیقه تا ۳۶ درجه و ۵۸ دقیقه عرض شمالی و ۴۵ درجه و ۳۹ دقیقه تا ۴۵ درجه و ۵۰ دقیقه طول شرقی واقع شده است؛ به گونه‌ای که از شمال و شرق به میاندوآب، از غرب به نقده و از جنوب به سردشت محدود می‌شود. کشاورزی این منطقه، اعم از زراعی و باغی، معمولاً زیرکشت محصولاتی مانند یونجه، سیب و گلابی، ذرت، چغندر قند و گندم و جو آبی و دیم است. موقعیت جغرافیایی محدوده مطالعاتی در شکل ۱ نشان داده شده است.

شی‌گرا، در مقایسه با رویکرد پیکسل‌پایه، دقت و کیفیت بصری مطلوبی ایجاد می‌کند. مانانزه^۱ و همکاران (۲۰۲۰) از باندهای طیفی لندست-۷ و لندست-۸، شاخص‌های پوشش گیاهی و ویژگی‌های بافتی مستخرج از GLCM برای تولید نقشه کاربری محدوده مطالعاتی در سال‌های ۲۰۱۲، ۲۰۱۵ و ۲۰۱۸ استفاده کردند. نتایج هر سه دوره نشان داد که سه بانده طیفی منتخب و ویژگی‌های بافتی مستخرج، با اندازه کرنل ۲۵، بهترین عملکرد را در فرایند طبقه‌بندی داشته‌اند. سارزینسکی^۲ و همکاران (۲۰۲۰)، با ادغام داده‌های رادار و اپتیک، با استفاده از تصاویر ماهواره‌ای لندست و ویژگی‌های بافتی GLCM، از مزارع نخل روغنی نقشه‌برداری کردند. یافته‌های تحقیق آنها صحت کلی ۸۴٪، صحت تولیدکننده ۸۴٪ و صحت کاربر ۹۰٪ را درمورد کاربری نخل روغنی نشان داد.

بررسی پیشینه تحقیق، در سطوح داخلی و بین‌المللی، نشان می‌دهد به کارگیری لایه‌های اطلاعاتی متعدد برای طبقه‌بندی LULC با استفاده از الگوریتم‌های طبقه‌بندی و خوشه‌بندی و مقایسه نتایج رویکردهای پیکسل‌پایه و شی‌گرا در تحقیقات بسیاری مورد توجه بوده است. با این حال بهتر است به قابلیت مجموعه داده‌های کاربردی مؤثر در فرایند طبقه‌بندی، به همراه الگوریتم خوشه‌بندی SNIC در قالب مطالعه‌ای جامع و یکپارچه، در سامانه گوگل ارث انجین پرداخته شود؛ به‌ویژه اینکه، در محدوده مطالعاتی تحقیق حاضر، چنین پژوهشی انجام نشده است. تأثیر پارامترهای الگوریتم خوشه‌بندی SNIC، به‌ویژه اندازه سوپریکسل و همچنین عملکرد الگوریتم خوشه‌بندی با/ بدون اعمال ماتریس GLCM نیز در نتایج طبقه‌بندی بررسی می‌شود؛ در مطالعاتی که تا کنون انجام شده، به این موارد پرداخته نشده است. علاوه بر این به کارگیری رویکرد شی‌گرای مبتنی بر الگوریتم خوشه‌بندی SNIC در تحقیقات محدودی در داخل ایران مورد توجه بوده است (Ghorbanian et al., 2020) و در بیشتر مطالعات (Aslami & Ghorbani,

1. Mananze

2. Sarzynski



شکل ۱. موقعیت جغرافیایی منطقه مورد مطالعه

۲-۲- روش تحقیق

بهتر روش‌های یادگیری ماشین در طبقه‌بندی LULC، نرمال‌سازی مجموعه داده به روش نمره استاندارد Z انجام شد تا مقادیر تغییرات تمامی باندهای مجموعه در یک محدوده قرار گیرد. در مرحله طبقه‌بندی LULC، از دو رویکرد پیکسل‌پایه و شیء‌گرا استفاده شد (Ghorbanian et al., 2020). داده‌های پیمایش میدانی به دو گروه داده آموزشی، به‌منظور آموزش مدل طبقه‌بندی‌کننده، و داده آزمایشی به‌منظور اعتبارسنجی مدل با نسبت ۸۰٪ به ۲۰٪ تقسیم شدند. در انتها، از الگوریتم جنگل تصادفی برای طبقه‌بندی پیکسل‌پایه استفاده شد. در رویکرد شیء‌گرا، روند طبقه‌بندی به‌گونه‌ای است که در مرحله اول، ماتریس GLCM برای استخراج ویژگی‌های بافتی روی همان مجموعه داده اولیه اعمال شد. با توجه به افزایش تعداد ویژگی‌ها و کاهش خطای محاسباتی، صرفاً از شش معیار بافتی بهره گرفته شد که شامل میانگین، واریانس، همگنی، کنتراست، نداشتن تشابه و آنتروپی می‌شود. در مرحله

روش تحقیق شامل سه مرحله اصلی می‌شود: (۱) آماده‌سازی مجموعه داده اولیه؛ (۲) طبقه‌بندی LULC با استفاده از رویکردهای پیکسل‌پایه و شیء‌گرا؛ (۳) ارزیابی صحت. در مرحله آماده‌سازی مجموعه داده اولیه، پس از فراخوانی تصاویر بازتاب سطحی سنتینل-۲ و اعمال فیلترهای مکانی، زمانی و ماسک ابر، تصویری میانه با باندهای هدف ایجاد شد. در مرحله بعد، شاخص‌های طیفی NDVI، BSI و SAVI از تصاویر سنتینل-۲ (Hedayati et al., 2022)، قطبش‌های VV، VH و شاخص توان بازپراکنش کل نیز از تصاویر سنتینل-۱ استخراج و هریک، به‌منزله یک باند، به مجموعه داده اولیه اضافه شد (Mahdianpari et al., 2018). در نهایت، داده‌های ارتفاعی مدل رقومی سطح زمین ALOS نیز، به‌منزله ویژگی نهایی، به مجموعه داده اولیه افزوده شد. در گام نهایی آماده‌سازی مجموعه داده اولیه، با توجه به وجود لایه‌های اطلاعاتی متعدد و همچنین عملکرد

شناخته می‌شود، پدید آید (Thi et al., 2018).

۲-۲-۱-۲- قطعه‌بندی براساس خوشه‌بندی

ساده غیر تکراری (SNIC)^۶

SNIC پیشرفته‌ترین الگوریتم قطعه‌بندی سوپرپیکسلی براساس SLIC^۷ است (Mi & Chen, 2020). این روش حالتی غیر تکراری را اتخاذ می‌کند و موفقیت آن، در جایگاه الگوریتم پیش‌پردازش، مدیون سادگی و کارایی محاسباتی و توانایی آن در تولید سوپرپیکسل‌هایی است که الزامات پایبندی مطلوب به مرز خوشه و همسایگی محدود را فراهم می‌کند (Achanta & Susstrunk, 2017). هر عنصر در SNIC شامل موقعیت مکانی، مقدار رنگ، برجسب سوپرپیکسل و فاصله مرکز سوپرپیکسل تا پیکسل منتخب است. سپس K عنصر در صف اولویت (Q) قرار می‌گیرند. مادامی که Q خالی نیست، همیشه عنصری خارج می‌شود که کمترین فاصله را دارد. برای هر پیکسل همسایه متصل به عنصر خارج شده، اگر پیکسل هنوز برجسب گذاری نشده باشد، عنصر جدیدی ایجاد می‌شود و فاصله از مرکز اتصال و برجسب مرکز اتصال به آن اختصاص می‌یابد. هنگامی که تمامی پیکسل‌های تصویر برجسب گذاری شدند و Q خالی شد، الگوریتم SNIC پایان می‌یابد (Achanta & Susstrunk, 2017). تعداد مراکز اولیه (K) پارامتر اصلی تعریف شده از سوی کاربر SNIC است. اندازه یک سوپرپیکسل (S) با استفاده از رابطه (۱) محاسبه می‌شود.

$$S = \left(\frac{N}{K}\right)^{1/2} \quad \text{رابطه (۱)}$$

N تعداد پیکسل‌های تصویر و K تعداد مراکز اولیه است.

بعدی، به منظور کاهش ابعاد مجموعه داده با ۷۸ باند و افزایش تفکیک‌پذیری طیفی، تحلیل مؤلفه اصلی (PCA)^۱ روی مجموعه داده اعمال شد تا از اطلاعات PC1، در مراحل بعدی پردازش، استفاده شود (Stromann et al., 2019). سپس لایه قطعه‌بندی، به کمک الگوریتم SNIC و تنظیم پارامترهای آن، استخراج شد (Paludo et al., 2020). در مرحله نهایی و پس از ترکیب و مرتبط ساختن ویژگی‌های حاصل از PC1 با قطعه‌های مستخرج از الگوریتم SNIC، الگوریتم جنگل تصادفی برای طبقه‌بندی نهایی و تهیه نقشه کاربری و پوشش زمین محدوده مطالعاتی در نظر گرفته شد (Sarzynski et al., 2020). در مرحله اعتبارسنجی نیز با استفاده از نمونه‌های آزمایشی، ارزیابی دقت و مقایسه جامع نقشه‌های کاربری و پوشش زمین مستخرج از رویکردهای پیکسل پایه و شیء‌گرا انجام شد. نمودار جریانی تحقیق در شکل ۲ نشان داده شده است.

۲-۲-۱- طبقه‌بندی کاربری و پوشش زمین

۲-۲-۱-۱- الگوریتم جنگل تصادفی

الگوریتم طبقه‌بندی جنگل تصادفی (RF) که برایمن^۲ در سال ۲۰۰۱ پیشنهاد کرد، الگوریتم نظارت‌شده‌ای مبتنی بر درخت‌های تصمیم‌گیری و تکنیک‌های بهبود یافته تجمیع^۳ و نمونه‌برداری^۴ است. هر درخت در جنگل از پیکسل‌های آموزشی رشد می‌یابد که به‌طور تصادفی برای آموزش طبقه‌بندی RF انتخاب می‌شود. نمونه‌های باقی‌مانده به منزله نمونه‌های خارج از کیسه^۵ در نظر گرفته می‌شوند و برای تخمین خطای طبقه‌بندی، هنگام افزوده شدن درختان به جنگل، به کار می‌روند. سه پارامتری که کاربر باید در الگوریتم RF تعریف کند عبارت‌اند از: (۱) تعداد متغیرهای برآوردکننده در هر گره؛ (۲) تعداد درختان در جنگل تصادفی؛ (۳) حداقل تعداد گره‌های انتهایی (Peters et al., 2008). در نهایت، نتایج به‌دست‌آمده از همه درخت‌ها با یکدیگر مقایسه و برای ساخت درخت بهینه، به رأی گذاشته می‌شوند تا مدل نهایی RF که دسته نهایی نیز

1. Principle Component Analysis
2. Breiman
3. Bagging
4. Bootstrap
5. Out of Bag
6. Simple Non Iterative Clustering
7. Simple Linear Iterative Clustering

۲-۲-۲- ماتریس وقوع توأم گام‌های خاکستری

بافت یک ویژگی متمایز از تمامی سطوح است که شامل اطلاعات مهمی درمورد توزیع فضایی، آرایش ساختاری سطوح و رابطه آنها با محیط اطراف می‌شود (Mananze et al., 2020). یکی از متداول‌ترین رویکردهای استخراج اطلاعات بافتی، الگوریتم GLCM است که درک اساسی از تحلیل بافت و استخراج ویژگی را فراهم می‌کند (Wang et al., 2019). هرالیک^۱ و همکاران (۱۹۷۳) پیشگام این روش پرکاربردند؛ آنها الگوریتم تحلیل بافت را با اختصاص رابطه بافتی بین پیکسل‌های تصویر، ایجاد کردند. ایده اصلی این روش یافتن نقاطی است که سطوح خاکستری یکسان دارند و با فاصله d و جهت θ از یکدیگر قرار گرفته‌اند. بنابراین به جای یک ماتریس، چند ماتریس خواهیم داشت که هریک جهات متفاوتی را که ممکن است دو نقطه نسبت به یکدیگر داشته باشند، مشخص می‌کند. این روش به تصویری سطح خاکستری به‌منزله ورودی نیاز دارد که از طریق ترکیب خطی باندهای NIR، قرمز و سبز تصویر اصلی طبق رابطه (۲) در GEE استخراج شد.

$$Gray = (0.3 * NIR) + (0.59 * Red) + (0.11 * Green)$$

رابطه (۲)

در این معادله، NIR باند فرورسرخ نزدیک، Red باند

قرمز و Green باند سبز است. در جدول ۱، ویژگی‌های بافتی مستخرج از ماتریس GLCM آمده که در تحقیق پیش رو استفاده شده است.

۳-۲- داده‌های مورد استفاده


۱-۳-۲- تصاویر ماهواره‌ای سنتینل-۲

سنتینل-۲ ماهواره‌ای چندطیفی است که تصاویر سنجش از دور را در سیزده باند، در محدوده‌های طیف مرئی، فرورسرخ نزدیک (NIR)^۲، لبه قرمز^۳ و فرورسرخ موج کوتاه (SWIR)^۴، با وضوح مکانی متغیر ۱۰، ۲۰ و ۶۰ متر، تهیه می‌کند (Bagherian Marzouani et al., 2014). با توجه به ماهیت تحقیق، تصویر میانه این سنجنده در سال ۲۰۱۹، با شش باند طیفی شامل باندهای آبی، سبز، قرمز، فرورسرخ نزدیک، لبه قرمز و فرورسرخ موج کوتاه، متناسب با تقویم زراعی منطقه مورد مطالعه در نظر گرفته شد. همچنین با استفاده از باندهای تصویر سنتینل-۲، شاخص‌های طیفی همچون شاخص پوشش گیاهی تفاضلی نرمال‌شده (NDVI)^۵، شاخص خاک لخت (BSI)^۶ و شاخص پوشش گیاهی تعدیل‌شده خاک (SAVI)^۷ استخراج شد (Singh et al., 2016; Polykretis et al., 2020) تا در نهایت، مجموعه موارد فوق به‌منزله ویژگی، در فرایند طبقه‌بندی کاربری و پوشش زمین، به کار روند.

جدول ۱. ویژگی‌های بافتی مستخرج از ماتریس GLCM که در تحقیق حاضر به کار رفته است

ردیف	ویژگی بافتی	توضیحات
۱	میانگین	میانگین مقادیر پیکسل در پنجره
۲	کنتراست	تعداد تغییرات بافت محلی در تصویر
۳	آنتروپی	تصادفی بودن توزیع پیکسل‌ها در تصویر
۴	همگنی	یکنواختی پیکسل‌ها در تصویر
۵	واریانس	پراکندگی حول میانگین مقادیر پیکسل در پنجره
۶	نداشتن تشابه	معیار خطی از تغییرات محلی در یک تصویر

1. Haralick
2. Near-Infrared
3. Red edge
4. Short Wave Infrared
5. Normalized Difference Vegetation Index
6. Bare Soil Index
7. Soil Adjusted Ve



شکل ۲. نمودار جریان، تحقیق

۳-۳-۲- مدل رقومی سطح زمین ALOS

از سری برنامه‌های سازمان فضایی اروپا (ESA)^۱ است که انقلاب بزرگی در فناوری پایش زمین ایجاد کرد (Lanari et al., 2020). سنتینل- ۱ شامل دو ماهواره به نام‌های سنتینل- 1A و سنتینل- 1B است که در زاویه^{۱۸۰} درجه نسبت به یکدیگر قرار گرفته‌اند و از جمله ماهواره‌های باند C (طول موج معادل ۵/۵۴ سانتی‌متر) محسوب می‌شود که مدار قطبی خورشیدآهنگ و وضوح مکانی متغیر، از پنج متر با عرض برداشت بیست کیلومتر تا چهل متر با عرض برداشت چهارصد کیلومتر، دارد (Li et al., 2021). در پژوهش حاضر، از دو پلاریزاسیون VV و VH تصویر میانه^۱ سنتینل- ۱، با فرمت GRD^۲ و همچنین شاخص توان بازپراکنش کل^۳ مستخرج از تصویر میانه SAR، به‌منزله و بژگه^۴، در فرایند طبقه‌بندی^۵ استفاده شد.

1. European Space Agency
2. Ground Range Detection
3. Total Scattering Power
4. Digital Surface Model
5. Japan Aerospace Exploration Agency

نسخه ۲/۲ این مدل رقومی سطح زمین که حداقل و حداکثر تغییرات ارتفاعی را به ترتیب ۱۰۵۴- و ۱۵۳۵۵ متر نشان می‌دهد، به منزله ویژگی، در فرایند طبقه‌بندی LULC به کار رفت. در جدول ۲، ویژگی‌های استخراج شده از تصاویر رادار و اپتیک و سایر لایه‌های اطلاعاتی مورد استفاده در پژوهش حاضر بیان شده است.

۴-۳-۲- داده‌های پیمایش میدانی

مجموعه داده پیمایش میدانی که برای طبقه‌بندی

LULC محدوده مطالعاتی تحقیق حاضر به کار رفته است، یازده کلاس با کاربری‌های پهنه آبی، سیب و گلابی، ساخته شده، ذرت، سبزیجات آبی پاییزه، خاک لخت، مرتع، چغندرقد، گندم و جو دیم، گندم و جو آبی و یونجه را دربرمی‌گیرد. تعداد کل نمونه‌های برداشت شده، برای آموزش و اعتبارسنجی مدل طبقه‌بندی کننده، ۵۰۴ نمونه بوده که تعداد آنها، برای هر کلاس کاربری، در جدول ۳ آمده است.

جدول ۲. ویژگی‌های مستخرج از تصاویر رادار و اپتیک و سایر لایه‌های اطلاعاتی مورد استفاده در پژوهش حاضر

داده	توضیحات ویژگی	فرمول	منبع
سنتینل-۱	پلاریزاسیون VV	VV	Mahdianpari et al., 2018
	پلاریزاسیون VH	VH	
	توان بازپراکنش کل	$ S_{VV} ^2 + S_{VH} ^2$	
سنتینل-۲	باندهای آبی، سبز، قرمز، فروسرخ نزدیک، لبه قرمز و فروسرخ موج کوتاه	B2, B3, B4, B8, B8A, B11	Sarzynski et al., 2020
	شاخص پوشش گیاهی تفاضلی نرمال شده (NDVI)	$(B8-B4)/(B8+B4)$	
	شاخص خاک لخت (BSI)	$((B11+B4) - (B8+B2))/((B11+B4) + (B8+B2))$	
Takaku et al., 2014	شاخص پوشش گیاهی تعدیل شده خاک (SAVI)	$(1+L)*(B8-B4)/(B8+B4+L)$	Jenerette et al., 2007
	مدل رقومی سطح زمین جهانی ALOS DSM با قدرت تفکیک مکانی سی متر		

جدول ۳. تعداد نمونه‌های پیمایش میدانی کلاس‌های کاربری منطقه مورد مطالعه

کاربری / پوشش	تعداد نمونه‌های پیمایش میدانی
پهنه آبی	۱۳
سیب و گلابی	۱۵۶
ساخته شده	۳۳
ذرت	۴۲
سبزیجات آبی پاییزه	۵۲
خاک لخت	۶
مرتع	۳
چغندرقد	۷۴
گندم و جو دیم	۱۴
گندم و جو آبی	۵۵
یونجه	۵۶
تعداد کل	۵۰۴

۳- ارزیابی صحت


ارزیابی دقت، با استفاده از ماتریس ابهام، اغلب بینش عمیقی درباره نتایج طبقه‌بندی به دست می‌دهد و آن را به ابزاری ارزشمند برای اهداف طبقه‌بندی LULC تبدیل می‌کند. در این پژوهش، از معیارهای صحت کلی، ضریب کاپا، صحت تولیدکننده و صحت کاربر در ارزیابی نقشه‌های کاربری و پوشش زمین مستخرج از فرایند طبقه‌بندی استفاده شد. صحت کلی نسبت تعداد پیکسل‌های به‌درستی طبقه‌بندی‌شده به تعداد کل پیکسل‌های تصویر است (Mahdianpari et al., 2018). ضریب کاپا تمامی پیکسل‌هایی را که درست و غلط طبقه‌بندی شده‌اند، محاسبه می‌کند (Darem et al., 2023). صحت تولیدکننده احتمال نسبت دادن کلاس خاص به یک پیکسل از طریق الگوریتم طبقه‌بندی است؛ در شرایطی که کلاس واقعی آن پیکسل برای تولیدکننده مشخص باشد (Mananze et al., 2020). صحت کاربر نیز معرف احتمال طبقه‌بندی کلاسی خاص، مطابق با همان کلاس در نقشه واقعیته زمینی است (Thenkabail, 2015).

۴- نتایج و بحث


۴-۱- نتایج حاصل از طبقه‌بندی LULC مبتنی بر رویکرد پیکسل پایه
در شکل ۳، نقشه LULC محدوده مطالعاتی مستخرج از فرایند طبقه‌بندی مبتنی بر رویکرد پیکسل پایه در سال ۲۰۱۹ نشان داده شده است که یازده کلاس با کاربری‌های پهنه آبی، سیب و گلابی، ساخته‌شده، ذرت، سبزیجات آبی پاییزه، خاک لخت، مرتع، چغندرقد، گندم و جو دیم، گندم و جو آبی و یونجه را شامل می‌شود. صحت کلی و ضریب کاپای نقشه LULC به ترتیب، ۸۲/۷۳٪ و ۰/۸۰۲۸ برآورد شد. معیارهای صحت کاربر و صحت تولیدکننده ارائه‌شده در شکل ۴ و همچنین تفسیر بصری و آماری نتایج نشان می‌دهد عملکرد الگوریتم جنگل تصادفی، در طبقه‌بندی بیشتر کاربری‌های اراضی، نسبتاً قابل قبول بوده است.

کاربری‌های/ پوشش‌های پهنه آبی، سیب و گلابی، ساخته‌شده، چغندرقد و گندم و جو دیم بیشترین صحت تولیدکننده (بالای ۹۰٪) را به خود اختصاص داده‌اند. همچنین کاربری‌های/ پوشش‌های پهنه آبی، ساخته‌شده، ذرت و چغندرقد بیشترین صحت کاربر را داشته‌اند که ازجمله دلایل شناسایی و طبقه‌بندی مطلوب این کاربری‌ها می‌توان به ویژگی‌های طیفی و بازپراکنش متفاوت آنها، در مقایسه با سایر کاربری‌ها، اشاره داشت. باین حال این الگوریتم، در شناسایی و تفکیک همه کاربری‌ها، عملکرد مطلوبی نداشته است و ملاحظه می‌شود که در اغلب بخش‌های محدوده مطالعاتی، کاربری‌های خاک لخت و مرتع به اشتباه در زمره کاربری/ پوشش ساخته‌شده طبقه‌بندی شده‌اند. با استناد به این نکته که موفقیت هر طبقه‌بندی مبتنی بر یادگیری ماشین اغلب به اندازه و کیفیت مجموعه داده آموزشی بازمی‌گردد (Zou et al., 2015)، یکی از دلایل تفکیک‌پذیری نامناسب این کاربری‌ها نیز همین مورد در نظر گرفته می‌شود؛ به گونه‌ای که تعداد نمونه‌های آموزشی کاربری خاک لخت ۶ و کاربری مرتع ۳ بوده است. همچنین به‌رغم قابلیت‌های روش‌های پیکسل پایه در طبقه‌بندی تصاویر ماهواره‌ای، این رویکردها در شناسایی کلاس‌های مبهم، مانند ابر و سایه، عملکرد ضعیفی دارند زیرا ویژگی‌های بازتابی آنها ممکن است مشابه سایر کاربری‌ها و پوشش‌های زمین باشد. ازاین‌رو در نقشه LULC تحقیق حاضر نیز مشخص است که وجود سایه، در بخش‌های غربی و جنوبی محدوده مطالعاتی، به طبقه‌بندی نادرست کاربری خاک لخت و مرتع منجر شده است و نتایج مشابه در تحقیق هیوز و هایس^۱ (۲۰۱۴) این موضوع را تصدیق می‌کند. علاوه بر موارد بیان‌شده، باید در نظر داشت که اگرچه داده‌های کمکی می‌توانند در بهبود دقت طبقه‌بندی مؤثر باشند، اهمیت نسبی آنها و داده‌های طیفی براساس پیچیدگی اجزا و شکل چشم‌انداز معین می‌شود (Hosseiny et al., 2022).

1. Hughes & Hayes



شکل ۳. نقشه LULC محدوده مطالعاتی با رویکرد پیکسل پایه، در سال ۲۰۱۹




شکل ۴. معیارهای صحت کاربر و صحت تولیدکننده کاربری‌های گوناگون اراضی در نقشه LULC پیکسل پایه (کاربری‌های خاک لخت و مرتع حذف شد)


۲-۴- نتایج طبقه‌بندی LULC مبتنی بر رویکرد شیء‌گرا

در شکل ۵، نقشه LULC محدوده مطالعاتی، مستخرج از فرایند طبقه‌بندی مبتنی بر رویکرد شیء‌گرا در سال ۲۰۱۹، نشان داده شده است که یازده کلاس با کاربری‌های پهنه آبی، سیب و گلابی، ساخته‌شده، ذرت، سبزیجات آبی پاییزه، خاک لخت، مرتع، چغندر قند، گندم و جو دیم، گندم و جو آبی و یونجه را دربرمی‌گیرد. صحت کلی و ضریب کاپا برای نقشه

LULC به ترتیب، ۰/۸۶/۴۰ و ۰/۸۳۰۷ محاسبه شد که در مقایسه با معیارهای ارزیابی صحت نقشه LULC پیکسل پایه، عملکرد مطلوب رویکرد پیشنهادی کاملاً مشهود بوده است. براساس معیارهای صحت کاربر و صحت تولیدکننده ارائه‌شده در شکل ۶ و همچنین تحلیل بصری نتایج، صحت تولیدکننده اغلب کاربری‌ها، به‌غیر از کاربری‌های خاک لخت، مرتع، ذرت، سبزیجات آبی پاییزه و گندم و جو آبی، بیش از ۹۰٪ بوده است.



شکل ۵. نقشه LULC محدوده مطالعاتی با رویکرد شیء‌گرا، در سال ۲۰۱۹: (الف)؛ تصویر میانه سنتینل-۲ (ب)؛ نقشه LULC با رویکرد پیکسل پایه (پ)؛ نقشه LULC با رویکرد شیء‌گرا



شکل ۶. معیارهای صحت کاربر و صحت تولیدکننده کاربری‌های متفاوت اراضی، در نقشه LULC شی‌گرا (کاربری‌های خاک لخت و مرتع حذف شد)

GLCM در دقت طبقه‌بندی شی‌گرا آمده است. اندازه سوپریکسل در الگوریتم SNIC تأثیر بسیاری در دقت طبقه‌بندی دارد. اگر این اندازه خیلی بزرگ باشد، ممکن است یک خوشه بیش از یک کلاس را در خود جای دهد و در نتیجه، دقت طبقه‌بندی کاهش یابد. از سویی، اگر اندازه سوپریکسل خیلی کوچک باشد، کارایی قطعه‌بندی آن کاهش می‌یابد و ممکن است هر خوشه صرفاً حاوی چند پیکسل از یک تصویر ماهواره‌ای باشد. براساس جدول ۴، ملاحظه می‌شود که افزایش اندازه سوپریکسل به کاهش دقت طبقه‌بندی منجر می‌شود؛ به گونه‌ای که با تعیین مقادیر ۵، ۱۰، ۱۵ و ۲۰ برای اندازه سوپریکسل، صحت کلی و ضریب کاپا به ترتیب، برابر با ۰/۸۵/۰۴ و ۰/۸۳/۸۳، ۰/۸۱۹۶ و ۰/۸۳/۸۳ و ۰/۷۸/۰۲ و ۰/۷۵۶۴ و ۰/۷۲/۴۷ و ۰/۶۸۸۷ می‌شود. از این رو تأثیر این پارامتر در عملکرد الگوریتم شی‌گرا مشهود است و یافته‌های حاصل از این بخش نیز با برخی تحقیقات (Achanta & Susstrunk, 2017؛ Yang et al., 2021) مطابقت دارد. همچنین نتایج بررسی عملکرد الگوریتم SNIC، با اعمال/ بدون اعمال ماتریس GLCM (جدول ۴)، نشان می‌دهد به کارگیری معیارهای بافتی در دست‌یابی به صحت و دقت قابل قبول نقشه LULC شی‌گرا مؤثر بوده است.

کاربری‌های/ پوشش‌های پهنه آبی، ساخته شده، ذرت و چغندر قند بیشترین صحت کاربر را به خود اختصاص داده‌اند؛ دلیل آن را می‌توان ویژگی‌های طیفی و بازپراکنش متفاوت آنها دانست که در مقایسه با سایر کاربری‌ها، با استفاده از الگوریتم جنگل تصادفی، امکان تشخیص و طبقه‌بندی آنها به راحتی وجود داشته است. درباره کاربری‌های یونجه و سبزیجات آبی پاییزه، بیان می‌شود که دقت طبقه‌بندی آنها کمتر از رویکرد پیکسل پایه بوده است. برخلاف رویکرد پیکسل پایه، رویکرد شی‌گرا در طبقه‌بندی و تفکیک کاربری ساخته شده در مقایسه با کاربری‌های خاک لخت و مرتع، به رغم تعداد کم نمونه‌های آموزشی این دو کلاس، عملکردی درخور توجه داشته است و تفکیک‌پذیری مناسب این کاربری‌ها را می‌توان، در نقشه طبقه‌بندی محدوده مطالعاتی، مشاهده کرد.

۳-۴- نتایج حاصل از تأثیر پارامتر اندازه سوپریکسل الگوریتم SNIC و معیارهای بافتی GLCM در دقت طبقه‌بندی شی‌گرا

در جدول ۴، نتایج حاصل از تأثیر اندازه پارامتر سوپریکسل الگوریتم SNIC و معیارهای بافتی

جدول ۴. نتایج حاصل از تأثیر پارامتر اندازه سوپریکسل و ماتریس GLCM در دقت طبقه‌بندی شیء‌گرا

اندازه سوپریکسل		ماتریس GLCM		بدون ماتریس GLCM	
		صحت کلی (%)	ضریب کاپا	صحت کلی (%)	ضریب کاپا
۵		۸۶/۴۰	۰/۸۳۰۷	۸۳/۰۴	۰/۷۹۹۶
۱۰		۸۳/۸۳	۰/۸۰۳۸	۷۴/۷۴	۰/۶۹۳۱
۱۵		۷۸/۰۲	۰/۷۵۶۴	۷۲/۸۹	۰/۶۶۸۳
۲۰		۷۲/۴۷	۰/۶۸۸۷	۶۰/۷۴	۰/۵۱۸۸

ملاحظه می‌شود که با اندازه سوپریکسل ۵ و اعمال ماتریس GLCM، بالاترین صحت کلی و ضریب کاپای (۸۶/۴۰٪ و ۰/۸۳۰۷) نقشه کاربری و پوشش زمین حاصل شده است. از دیگر سو، با اندازه سوپریکسل ۵ و بدون اعمال ماتریس GLCM، صحت کلی و ضریب کاپا به ترتیب ۸۳/۰۴٪ و ۰/۷۹۹۶ محاسبه شده است و ملاحظه می‌شود که در شرایطی با اندازه سوپریکسل یکسان، صحت و دقت نقشه LULC کاهش می‌یابد اما در عین حال و بدون در نظر گرفتن معیارهای بافتی، نتایج ارزیابی صحت از رویکرد پیکسل پایه بهتر است که به برتری رویکرد شیء‌گرا در طبقه‌بندی LULC اشاره می‌کند. کمترین صحت کلی و ضریب کاپا نیز با اندازه سوپریکسل ۲۰ و بدون اعمال ماتریس GLCM برآورده شد (صحت کلی برابر با ۶۰/۷۴٪ و ضریب کاپای ۰/۵۱۸۸). یافته‌های تحقیق نشان می‌دهد به کارگیری معیارهای بافتی مستخرج از GLCM، با در نظر گرفتن شکل و اندازه کاربری‌های/ پوشش‌های اراضی و همچنین ویژگی‌های منطقه مورد مطالعه، در تفکیک پذیری بین کلاس‌های متفاوت کاربری و پوشش زمین نقش پررنگی داشته است؛ به گونه‌ای که اطلاعات بافتی در طبقه‌بندی مطلوب کاربری‌های بسیار ناهمگن و پیچیده، مانند مناطق ساخته شده با آنتروپی داخلی بالا (Choudhury et al., 2019) و همچنین طبقه‌بندی کاربری‌هایی با بافت منظم، مانند محصولات زراعی،

مؤثر بوده است. نتایج این مطالعه با تحقیقات سو^۱ و همکاران (۲۰۰۸) و دکر^۲ (۲۰۰۳) مطابقت دارد. علاوه بر این، اعمال PCA روی مجموعه داده اولیه، به منزله یکی از روش‌های کاهش ابعاد ویژگی و افزایش تفکیک پذیری کلاس‌های گوناگون و استخراج چند باند معرف که شامل اطلاعات طیفی و بافتی مهم باشد، نیز در افزایش صحت و دقت نقشه LULC مبتنی بر رویکرد شیء‌گرا مؤثر بوده است؛ نتایج مطلوب به کارگیری این روش‌ها، مانند مطالعه استرامن و همکاران (۲۰۱۹) نیز، آن را تصدیق می‌کند.

با توجه به عملکرد بهتر رویکرد شیء‌گرا در مقایسه با رویکرد پیکسل پایه در طبقه‌بندی کاربری و پوشش زمین، مساحت کاربری‌های گوناگون اراضی برآورد شد که نتایج آن در جدول ۵ آمده است. طبق این جدول، کاربری سیب و گلابی با مساحت معادل ۷۶/۴۳۴ کیلومتر مربع به منزله کاربری اصلی منطقه مورد مطالعه شناسایی شد و از سوی دیگر کمترین مساحت کاربری نیز به کاربری ذرت، با ۱/۷۵۲ کیلومتر مربع، متعلق بوده است.

1. Su

1. Dekker

متر و همچنین شاخص BSI با وضوح مکانی بیست متر (به دلیل استفاده از باند SWIR) از مهم‌ترین عوامل محدودکننده حصول دقت و صحت بهینه در این تحقیق بیان می‌شود. از دیگر یافته‌های این پژوهش، می‌توان به اهمیت تنظیم بهینه پارامترهای الگوریتم خوشه‌بندی SNIC و همچنین الگوریتم طبقه‌بندی کننده جنگل تصادفی اشاره کرد. تحلیل نتایج این بخش نشان داد که تعیین مناسب آنها، در عملکرد رویکرد پیشنهادی در طبقه‌بندی کاربری و پوشش زمین، تأثیر شایان توجهی می‌گذارد. در انتها، بیان این نکته حائز اهمیت است که دقت نهایی هر رویکرد طبقه‌بندی مشروط به مناسب بودن داده‌های ورودی، کیفیت داده‌های آموزشی و ویژگی‌های منطقه مورد مطالعه است و صرف‌نظر از نحوه عملکرد الگوریتم جنگل تصادفی در طبقه‌بندی LULC، یکی از دلایل بالقوه طبقه‌بندی نادرست کاربری‌های خاک لخت و مرتع، در دو رویکرد پیکسل‌پایه و شیء‌گرا، می‌تواند همین نکته باشد زیرا کیفیت و تعداد نمونه‌های آموزشی این دو کلاس کاربری مناسب نبوده است. با توجه به نتایج تحقیق حاضر، پیشنهاد می‌شود که در مطالعات آتی، روش‌های یادگیری عمیق با تنظیم بهینه پارامترهای آن به کار رود و همچنین حساسیت ویژگی‌های مؤثر در بهبود فرایند طبقه‌بندی تحلیل شود.

۶- منابع

- Achanta, R. & Susstrunk, S., 2017, **Superpixels and Polygons Using Simple Non-Iterative Clustering**, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, USA, PP. 4651-4660, DOI: 10.1109/CVPR.2017.520.
- Ali, M.Z., Qazi, W. & Aslam, N., 2018, **A Comprehensive Study of ALOS-2 PALSAR and Landsat-8 Imagery for Land Cover Classification Using Maximum Likelihood Classifier**, The Egyptian Journal of Remote Sensing and Space Science, 21(1), PP. 29-35, DOI: 10.1016/j.ejrs.2018.03.003.

جدول ۵. مساحت کاربری‌های اراضی منطقه مورد مطالعه

براساس نقشه LULC شیء‌گرا

کاربری / پوشش	مساحت (کیلومتر مربع)
پهنه آبی	۱/۵۴۵
سیب و گلابی	۷۶/۴۳۴
ساخته شده	۳۳/۲۵۲
ذرت	۱/۷۵۲
سبزیجات آبی پاییزه	۳۱/۲۶۲
خاک لخت	۹۹/۲۳۲
مرتع	۰/۵۵۷
چغندر قند	۹/۶۴۸
گندم و جو دیم	۵۷/۴۶۳
گندم و جو آبی	۵۸/۹۵
یونجه	۱۷/۰۲۱

۵- نتیجه‌گیری

اطلاعات در زمینه کاربری و پوشش زمین از عناصر مهم شکل‌گیری سیاست‌های حوزه اقتصادی، جمعیتی و زیست‌محیطی در سطوح ملی، منطقه‌ای و جهانی است (Ban et al., 2010). در دهه‌های گذشته، داده‌های مشاهده زمین در استخراج اطلاعات و تغییرات پوشش زمین در سطوح گوناگون، کاربرد موفقیت‌آمیزی داشته است (Feng & Li, 2020). هدف از پژوهش حاضر بیان رویکرد طبقه‌بندی شیء‌گرا، مبتنی بر الگوریتم خوشه‌بندی SNIC، معیارهای بافتی GLCM، لایه‌های اطلاعاتی متعدد و الگوریتم جنگل تصادفی است که در پی تهیه نقشه کاربری و پوشش زمین محدوده مطالعاتی، با استفاده از تصاویر ماهواره‌ای سنتینل-۲ در سامانه گوگل ارث انجامین است. در نهایت، نتایج رویکرد پیشنهادی با روش رایج پیکسل‌پایه مقایسه شد. تحلیل یافته‌های تحقیق نشان داد ویژگی‌های مورد استفاده در رویکرد پیشنهادی شاخص‌های طیفی و معیارهای بافتی GLCM دقت طبقه‌بندی را بهبود بسیار چشمگیری می‌دهد. با این حال، با توجه به اهمیت قدرت تفکیک مکانی تصاویر ماهواره‌ای در نقشه‌برداری کاربری و پوشش زمین، به کارگیری ویژگی‌هایی مانند مدل رقومی سطح زمین ALOS با وضوح مکانی سی

- Aslami, F. & Ghorbani, A., 2018, **Object-Based Land-Use/Land-Cover Change Detection Using Landsat Imagery: A Case Study of Ardabil, Namin, and Nir Counties in North-West Iran**, Environmental Monitoring and Assessment, 190(7): P. 376, Doi: 10.1007/s10661-018-6751-y.
- Bagherian Marzouani, M., Akhoundali, A.M., Moazed, H., Jaafarzadeh, N., Ahadian, J. & Hasoonizadeh, H., 2014, **Evaluation of Karun River Water Quality Scenarios Using Simulation Model Results**, International Journal of Advanced Biological and Biomedical Research, 2(2), PP. 339-358, <https://www.ijabbr.com/>.
- Ban, Y., Hu, H. & Rangel, I.M., 2010, **Fusion of QuickBird MS and RADARSAT SAR Data for Urban Land-Cover Mapping: Object-Based and Knowledge-Based Approach**, International Journal of Remote Sensing, 31(6): PP. 1391-1410, Doi: 10.1080/01431160903475415.
- Blaschke, T., 2010, **Object Based Image Analysis for Remote Sensing**, ISPRS Journal of Photogrammetry and Remote Sensing, 65(1): PP. 2-16, Doi: 10.1016/j.isprsjprs.2009.06.004.
- Choudhury, M.A.M., Costanzini, S., Despini, F., Rossi, P., Galli, A., Marcheggiani, E. & Teggi, S., 2019, **Photogrammetry and Remote Sensing for the Identification and Characterization of Trees in Urban Areas**, Journal of Physics Conference Series, 1249, P. 12008, DOI: 10.1088/1742-6596/1249/1/012008.
- Darem, A.A., Alhashmi, A.A., Almadani, A.M., Alanazi, A.K. & Sutantra, G.A., 2023, **Development of a Map for Land Use and Land Cover Classification of the Northern Border Region Using Remote Sensing and GIS**, The Egyptian Journal of Remote Sensing and Space Science, 26, PP. 341-350, DOI: 10.1016/j.ejrs.2023.04.005.
- Dekker, R.J., 2003, **Texture analysis and classification of ERS SAR images for map updating of urban areas in The Netherlands**, IEEE Transactions on Geoscience and Remote Sensing, 41(9), PP. 1950-1958, DOI: 10.1109/TGRS.2003.814628.
- Delfan, E., Naghavi, H., Maleknia, R. & Nouredini, A., 2020, **Comparing the Capability of Sentinel-2 and Landsat-8 Satellite Imagery in Land Use and Land Cover Mapping Using Pixel-Based and Object-Based Classification Methods**, Desert Ecosystem Engineering Journal, 8(25), PP. 1-12, DOI: 10.22052/DEEJ.2018.7.25.25.
- Diek, S., Fornallaz, F., Schaepman, M.E. & De Jong, R., 2017, **Barest Pixel Composite for Agriculture Areas Using Landsat Time Series**, Remote Sensing, 9(12), P. 1245, DOI: 10.3390/rs9121245.
- Djerriri, K., Safia, A. & Adjoudi, R., 2020, **Object-Based Classification of Sentinel-2 Imagery Using Compact Texture Unit Descriptors through Google Earth Engine**, Mediterranean and Middle-East Geoscience and Remote Sensing Symposium, Tunis, Tunisia, PP. 105-108, DOI: 10.1109/M2GARSS47143.2020.9105181.
- Dronova, I., Gong, P., Wang, L. & Zhong, L., 2015, **Mapping Dynamic Cover Types in a Large Seasonally Flooded Wetland Using Extended Principal Component Analysis and Object-Based Classification**, Remote Sensing of Environment, 158, PP. 193-206, DOI: 10.1016/j.rse.2014.10.027.
- Feng, M. & Li, X., 2020, **Land Cover Mapping toward Finer Scales**, Science Bulletin, 65(19), PP. 1604-1606, DOI: 10.1016/j.scib.2020.06.014.
- Ghorbanian, A., Kakooei, M., Amani, M., Mahdavi, S., Mohammadzadeh, A. & Hasanlou, M., 2020, **Improved Land Cover Map of Iran Using Sentinel Imagery within Google Earth Engine and a Novel Automatic Workflow for Land Cover Classification Using Migrated Training Samples**, ISPRS Journal of Photogrammetry and Remote Sensing, 167, PP. 276-288, DOI: 10.1016/j.isprsjprs.2020.07.013.
- Haji, K., Esmali-Ouri, A., Mostafazadeh, R. & Nazarnejad, H., 2022, **Assessment of Land**

- Cover/Land Use Changes Using Object-Oriented Processing of Satellite Imageries (1985-2015) in the Rozechai Watershed of Urmia**, Journal of Applied Researches in Geographical Sciences, 22(66), PP. 171-189, DOI:10.52547/jgs.22.66.171.
- Haralick, R.M., Shanmugam, K. & Dinstein, I.H., 1973, **Textural Features for Image Classification**, Studies in Media and Communication, 3(6), PP. 610-621, DOI: 10.1109/TSMC.1973.4309314.
- Hedayati, A., Vahidnia, M.H. & Behzadi, S., 2022, **Paddy Lands Detection Using Landsat-8 Satellite Images and Object-Based Classification in Rasht City, Iran**, The Egyptian Journal of Remote Sensing and Space Science, 25(1), PP. 73-84, DOI: 10.1016/j.ejrs.2021.12.008.
- Hosseiny, B., Abdi, A.M. & Jamali, S., 2022, **Urban Land Use and Land Cover Classification with Interpretable Machine Learning- A Case Study Using Sentinel-2 and Auxiliary Data**, Remote Sensing Applications: Society and Environment, 28, P. 100843, DOI: 10.1016/j.rsase.2022.100843.
- Hughes, M.J. & Hayes, D.J., 2014, **Automated Detection of Cloud and Cloud Shadow in Single-Date Landsat Imagery Using Neural Networks and Spatial Post-Processing**, Remote Sensing, 6(6), PP. 4907-4926, DOI: 10.3390/rs6064907.
- Jenerette, G.D., Harlan, S.L., Brazel, A., Jones, N., Larsen, L. & Stefanov, W.L., 2007, **Regional Relationships between Surface Temperature, Vegetation, and Human Settlement in a Rapidly Urbanization Ecosystem**, Landscape Ecology, 22, PP. 353-365, DOI: 10.1007/s10980-006-9032-z.
- Joshi, N., Baumann, M., Ehammer, A., Fensholt, R., Grogan, K., Hostert, P., Jepsen, M.R., Kuemmerle, T., Meyfroidt, P., Mitchard, E.T., Reiche, J., Ryan, C. M. & Waske, B., 2016, **A Review of the Application of Optical and Radar Remote Sensing Data Fusion to Land Use Mapping and Monitoring**, Remote Sensing, 8(1), P. 70, DOI: 10.3390/rs8010070.
- Khalil, R.Z. & ul-Haque, S., 2018, **InSAR Coherence-Based Land Cover Classification of Okara, Pakistan**, The Egyptian Journal of Remote Sensing and Space Science, 21(1), PP. 23-28, DOI: 10.1016/j.ejrs.2017.08.005.
- Lanari, R., Bonano, M., Casu, F., Luca, C.D., Manunta, M., Manzo, M., Onorato, G. & Zinno, I., 2020, **Automatic Generation of Sentinel-1 Continental Scale D-InSAR Deformation Time Series through an Extended P-SBAS Processing Pipeline**, Cloud Computing Environment Remote Sensing, 12, P. 2961, DOI: 10.3390/rs12182961.
- Li, Y., Jiang, W., Zhang, J., Li, B., Yan, R. & Wang, X., 2021, **Sentinel-1 SAR-Based Coseismic Deformation Monitoring Service for Rapid Geodetic Imaging of Global Earthquakes**, Natural Hazards Research, 1(1), PP. 11-19, DOI: 10.1016/j.nhres.2020.12.001.
- Mahdianpari, M., Salehi, B., Mohammadimanesh, F., Homayouni, S. & Gill, E., 2018, **The First Wetland INVENTORY MAP of Newfoundland at a Spatial Resolution of 10 M Using Sentinel-1 and Sentinel-2 Data on the Google Earth Engine Cloud Computing Platform**, Remote Sensing, 11(1), P. 43, DOI: 10.3390/rs11010043.
- Mananze, S., Pôças, I. & Cunha, M., 2020, **Mapping and Assessing the Dynamics of Shifting Agricultural Landscapes Using Google Earth Engine Cloud Computing, a Case Study in Mozambique**, Remote Sensing, 12(8), P. 1279, DOI: 10.3390/rs12081279.
- Martha, T.R., Kerle, N., Jetten, V., Van Westen, C.J. & Kumar, K.V., 2010, **Characterizing Spectral, Spatial and Morphometric Properties of Landslides for Semi-Automatic Detection Using Object-Oriented Methods**, Geomorphology, 116, PP. 24-36, DOI: 10.1016/j.geomorph.2009.10.004.
- Messina, G., Peña, J.M., Vizzari, M. & Modica, G., 2020, **A Comparison of UAV and Satellites Multispectral Imagery in Monitoring Onion Crop. An Application in the 'Cipolla Rossa di Tropea' (Italy)**, Remote Sensing, 12(20), P. 3424, DOI: 10.3390/rs12203424.
- Mi, L. & Chen, Z., 2020, **Superpixel-Enhanced**

- Deep Neural Forest for Remote Sensing Image Semantic Segmentation**, ISPRS Journal of Photogrammetry and Remote Sensing, 159, PP. 140-152, DOI: 10.1016/j.isprsjprs.2019.11.006.
- Mohammadi, A. & Khodabandehlou, B., 2020, **Classification and Assessment of Land Use Changes in Zanjan City Using Object-Oriented Analysis and Google Earth Engine System**, Journal of Geography and Environmental Planning, 31(2), PP. 25-42, DOI: 10.22108/GEP.2020.120666.1242.
- Olson, C., 2009, **The Fallacy of Normality in Remotely Sensed Data**, ASPRS Annual Conference, American Society for Photogrammetry and Remote Sensing, Baltimore, Maryland, <https://www.asprs.org/a/publications/proceedings/baltimore09/0072.pdf>.
- Paludo, A., Becker, W.R., Richetti, J., De Albuquerque Silva, L.C. & Johann, J.A., 2020, **Mapping Summer Soybean and Corn with Remote Sensing on Google Earth Engine Cloud Computing in Parana State-Brazil**, International Journal of Digital Earth, 13(12), PP. 1624-1636, DOI: 10.1080/17538947.2020.1772893.
- Peters, J., Verhoest, N.E.C., Samson, R., Boeckx, P. & De Baets B., 2008, **Wetland Vegetation Distribution Modelling for the Identification of Constraining Environmental Variables**, Landscape Ecology, 23, PP. 1049-1065, DOI: 10.1007/s10980-008-9261-4.
- Polykretis, C., Grillakis, M.G. & Alexakis, D.D., 2020, **Exploring the Impact of Various Spectral Indices on Land Cover Change Detection Using Change Vector Analysis: A Case Study of Crete Island, Greece**, Remote Sensing, 12(2), P. 319, DOI: 10.3390/rs12020319.
- Sarzynski, T., Giam, X., Carrasco, L. & Lee, J.S.H., 2020, **Combining Radar and Optical Imagery to Map Oil Palm Plantations in Sumatra, Indonesia, Using the Google Earth Engine**, Remote Sensing, 12(7), P. 1220, DOI: 10.3390/rs12071220.
- Shaharum, N.S.N., Shafri, H.Z.M., Ghani, W.A.W.A.K., Samsatli, S., Prince, H.M., Yusuf, B. & Hamud, A.M., 2019, **Mapping the Spatial Distribution and Changes of Oil Palm Land Cover Using an Open Source Cloud-Based Mapping Platform**, International Journal of Remote Sensing, 40(19), PP. 7459-7476, DOI: 10.1080/01431161.2019.1597311.
- Shendryk, Y., Rist, Y., Ticehurst, C. & Thorburn, P., 2019, **Deep Learning for Multi-Modal Classification of Cloud, Shadow and Land Cover Scenes in PlanetScope and Sentinel-2 Imagery**, ISPRS Journal of Photogrammetry and Remote Sensing, 157, PP. 124-136, DOI: 10.1016/j.isprsjprs.2019.08.018.
- Singh, R.P., Singh, N., Singh, S. & Mukherjee, S., 2016, **Normalized Difference Vegetation Index (NDVI) Based Classification to Assess the Change in Land Use/Land Cover (LULC) in Lower Assam, India**, International Journal of Advanced Remote Sensing and GIS, 5, DOI: 10.23953/cloud.ijarsg.74.
- Solano, F., Di Fazio, S. & Modica, G., 2019, **A Methodology Based on GEOBIA and WorldView-3 Imagery to Derive Vegetation Indices at Tree Crown Detail in Olive Orchards**, International Journal of Applied Earth Observation and Geoinformation, 83, P. 101912, DOI: 10.1016/j.jag.2019.101912.
- Stromann, O., Nascetti, A., Yousif, O. & Ban, Y., 2019, **Dimensionality Reduction and Feature Selection for Object-Based Land Cover Classification Based on Sentinel-1 and Sentinel-2 Time Series Using Google Earth Engine**, Remote Sensing, 12(1), P. 76, DOI: 10.3390/rs12010076.
- Su, W., Li, J., Chen, Y., Liu, Z., Zhang, J., Low, T.M., Suppiah, I., & Hashim, S.A.M., 2008, **Textural and local spatial statistics for the object-oriented classification of urban areas using high resolution imagery**, International Journal of Remote Sensing, 29, pp 3105-3117, DOI: 10.1080/01431160701469016.
- Takaku, J., Tadono, T. & Tsutsui, K., 2014, **Generation of High Resolution Global DSM from ALOS PRISM**, The International

- Archives of the Photogrammetry**, Remote Sensing and Spatial Information Science, 4, PP. 25-31, DOI: 10.5194/isprsarchives-XL-4-243-2014.
- Tassi, A. & Vizzari, M., 2020, **Object-Oriented LULC Classification in Google Earth Engine Combining SNIC, GLCM, and Machine Learning Algorithms**, Remote Sensing, 12, P. 3776, DOI: 10.3390/rs12223776.
- Thenkabail, P.S., 2015, **Remotely Sensed Data Characterization, Classification and Accuracies**, CRC Press, Boca Raton, <https://doi.org/10.1201/b19294>.
- Thi, H., Nguyen, T., Doan, T. & Radeloff, V., 2018, **Applying Random Forest Classification to Map Land Use/Land Cover Using Landsat-8 OLI**, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLII-3/W4, Istanbul, Turkey, DOI: 10.5194/isprs-archives-XLII-3-W4-363-2018.
- Wang, C., Li, D., Li, Z., Wang, D., Dey, N., Biswas, A., Moraru, L., Sherratt, R. & Shi, F., 2019, **An Efficient Local Binary Pattern Based Plantar Pressure Optical Sensor Image Classification Using Convolutional Neural Networks**, Optik, 185, PP. 543-557, DOI: 10.1016/j.ijleo.2019.02.109.
- Xiong, J., Thenkabail, P.S., Tilton, J.C., Gumma, M.K., Teluguntla, P., Oliphant, A., Congalton, R.G., Yadav, K. & Gorelick, N., 2017, **Nominal 30-m Cropland Extent Map of Continental Africa by Integrating Pixel-Based and Object-Based Algorithms Using Sentinel-2 and Landsat-8 Data on Google Earth Engine**, Remote Sensing, 9, P. 1065, DOI: 10.3390/rs9101065.
- Yang, J., Gong, P., Fu, R., Zhang, M., Chen, J., Liang, S., Xu, B., Shi, J. & Dickinson, R., 2013, **The Role of Satellite Remote Sensing in Climate Change Studies**, Nature Climate Change, 3(10), PP. 875-883, DOI: 10.1038/nclimate2033.
- Yang, L., Wang, L., Abdullahi Abubakar, G. & Huang, J., 2021, **High-Resolution Rice Mapping Based on SNIC Segmentation and Multi-Source Remote Sensing Images**, Remote Sensing, 13(6), P. 1148, DOI: 10.3390/rs13061148.
- Zhou, D., Xiao, J., Frolking, S., Liu, S., Zhang, L., Cui, Y. & Zhou, G., 2021, **Croplands Intensify Regional and Global Warming According to Satellite Observations**, Remote Sensing of Environment, 264, P. 112585, DOI: 10.1016/j.rse.2021.112585.
- Zou, Q., Ni, L., Zhang, T. & Wang, Q., 2015, **Deep Learning Based Feature Selection for Remote Sensing Scene Classification**, IEEE Geoscience and Remote Sensing Letters, 12(11), PP. 2321-2325, DOI: 10.1109/LGRS.2015.2475299.
- Zurqani, H.A., Post, C.J., Mikhailova, E.A., Schlautman, M.A. & Sharp, J.L., 2018, **Geospatial Analysis of Land Use Change in the Savannah River Basin Using Google Earth Engine**, International Journal of Applied Earth Observation and Geoinformation, 69, PP. 175-185, DOI: 10.1016/j.jag.2017.12.006.