

**КЛАСИФИКАЦИЈА ОЗИМИХ КУЛТУРА КОМБИНАЦИЈОМ ВИШЕВРЕМЕНСКИХ  
ОПТИЧКИХ СЕНТИНЕЛ-2 И РАДАРСКИХ СЕНТИНЕЛ-1 СНИМАКА****Даворин Бајић<sup>\*</sup>, Драгутин Аџић<sup>1</sup> и Лука Сабљић<sup>1</sup>**<sup>1</sup>Универзитет у Бањој Луци, Природно-математички факултет, Бања Лука, Република Српска

**Сажетак:** Израда карте начина коришћења земљишта са фокусом на пољопривредно земљиште и озиме културе идентификован је као примарни циљ овог истраживања. Примјеном метода даљинске детекције, одабиром, обрадом и анализом мулти-временске серије радарских Сентинел-1 и оптичких Сентинел-2 сателитских снимака изведене су варијабле неопходне за покретање надзиране пиксел базиране класификације. Покретањем алгоритама машинског учења класификовани су сателитски снимци са укупном тачношћу од 0.96 и Капа коефицијентом 0.95. Израђена је карта озимих усјева за производну сезону 2019/2020 за подручје истраживања које се налази у оквирима природно-географске цјелине Лијевча поља. Истраживање је показало да су код озимих култура убједљиво највеће површине под озимом пшеницом. Комбинација оптичких и радарских сателитских снимака дала је боље резултате него појединачно оптички или радарски. Коришћење мулти-временске серије сателитских снимака допринијело је већој тачности и поузданости класификације. Мјерење спектралне дистанце показало се корисно у процесу дефинисања оптималног времена агрегације. Читав процес припреме сателитских снимака и сам процес класификације изведен је у Google окружењу под називом Google Earth Engine употребом његових ресурса који су доступни, бесплатни и захваљујући којима је процес мулти-временске и мулти-сензорске класификације подручја истраживања био изводљив.

**Кључне ријечи:** класификација, даљинска детекција, вегетациони индекси, тачност, Лијевче поље.

Original scientific paper

**WINTER CROPS CLASSIFICATION USING COMBINATION OF MULTI-TEMPORAL  
OPTICAL SENTINEL-2 AND RADAR SENTINEL-1 IMAGES****Davorin Bajić<sup>\*</sup>, Dragutin Adžić<sup>1</sup> and Luka Sabljčić<sup>1</sup>**<sup>1</sup>University of Banja Luka, Faculty of Natural Sciences and Mathematics, Banja Luka, Republic of Srpska

**Abstract:** Creating a land use map with a focus on agricultural land and winter crops was identified as the primary goal of this research. Applying remote sensing methods, selecting, processing and analyzing a multi-temporal series of radar Sentinel-1 and optical Sentinel-2 satellite images, the variables necessary for starting the supervised pixel-base classification were performed. Running machine learning algorithms, the satellite images were classified with an overall accuracy of 0.96 and a Kappa coefficient of 0.95. A map of winter crops for the 2019/2020 production season was created for research area located within the natural-geographical unit Lijevo field. Research has shown that of the winter crops, the largest areas are under winter wheat. The combination of optical and radar satellite imagery gave better results than either optical or radar imagery alone. The use of multi-temporal series of satellite images contributed to greater accuracy and reliability of the classification. The measurement of the spectral distance proved to be useful in the process of defining the optimal aggregation time. The entire process of preparing satellite images and the classification process itself was carried out in the Google environment called Google Earth Engine using its resources that are available, free of charge and thanks to which the process of multi-temporal and multi-sensor classification of the research area was feasible.

**Key words:** classification, remote sensing, vegetation indices, accuracy, Lijevo field.

\* Аутор за кореспонденцију: Даворин Бајић, Универзитет у Бањој Луци, Природно-математички факултет, Младена Стојановића 2, 78000 Бања Лука, Република Српска, Босна и Херцеговина, Е-mail: davorin.bajic@pmf.unibl.org

\* Corresponding author: Davorin Bajić, University of Banja Luka, Faculty of Natural Sciences and Mathematics, Mladena Stojanovića 2, 78000 Banja Luka, Republic of Srpska, Bosnia and Herzegovina, E-mail: davorin.bajic@pmf.unibl.org

## УВОД

Информације о начину коришћења земљишта и земљишном покривачу чине базу основу у многим апликацијама намијењеним прије свега планирању, управљању ресурсима, идентификовању промјена у животној средини, идентификовању крчења шума и еколошком предвиђању (Khan et al., 2012). Приступ даљинске детекције представља највећи извор прикупљања информација о земљином покривачу и начину коришћења земљишта (Pu & Gong, 1998). За прикупљање ових информација, односно података могу се користити различите методе даљинске детекције. Метода сателитског осматрања Земљине површине нуди одговарајући приступ с обзиром на покривеност и врсту података коју пружа.

Класификација слике базирана на даљинској детекцији представља прикладан приступ за израду мапа о начину коришћења земљишта и земљишном покривачу, прије свега због предности у погледу трошкова израде, те просторне и временске резолуције (Foody, 2004). Развој даљинске детекције и приступачности производа сателитске технологије, довели су до тога да је даљинска детекција достигла висок ниво примјене у области пољопривреде. Класификација и мапирање усјева важно је са аспекта процјене обима сјетве на некој територији, као и за управљање пољопривредним површинама, те пружа неопходне информације националним агенцијама које доносе и спроводе мјере пољопривредне политике. Мапе врста усјева подразумијевају основу за праћење раста и развоја усјева, те представљају неопходне инпуте за израду модела приноса, нарочито за базне ратарске културе као што су пшеница и кукуруз (Wu, 2014).

Традиционална даљинска детекција и њена примјена у пољопривреди углавном се ослањала на податке изведене из оптичких снимака и то у видљивом и блиско-инфрацрвеном дијелу електромагнетног спектра (Orynbaikyzy et al., 2019). Значајно већи број истраживања заснивао се на оптичким подацима (Belgiu & Csillik, 2018; Vuolo et al., 2018; Conrad et al.,

## INTRODUCTION

Information about land use and land cover form the basis of many applications aimed primarily at planning, resource management, identifying environmental changes, identifying deforestation and environmental forecasting (Khan et al., 2012). The remote sensing approach represents the largest source of information collection on land cover and land use (Pu & Gong, 1998). Various remote sensing methods can be used to collect this information, or data. The method of satellite observation of the Earth's surface offers an appropriate approach considering the coverage and the type of data it provides.

Image classification based on remote sensing represents a suitable approach for creating land use and land cover maps, primarily due to advantages in terms of production costs and spatial and temporal resolution (Foody, 2004). The development of remote sensing and the accessibility of satellite technology products have led to the fact that remote sensing has reached a high level of application in the field of agriculture. Classification and mapping of crops is important from the aspect of assessing the extent of sowing in a territory, as well as for the management of agricultural areas, and provides the necessary information to national agencies that adopt and implement agricultural policy measures. Maps of crop types provide a basis for monitoring crop growth and development, and represent necessary inputs for producing yield models, especially for basic field crops such as wheat and corn (Wu, 2014).

Traditional remote sensing and its application in agriculture mainly relied on data derived from optical images in the visible and near-infrared part of the electromagnetic spectrum (Orynbaikyzy et al., 2019). A significantly larger number of studies were based on optical data (Belgiu & Csillik, 2018; Vuolo et al., 2018; Conrad et al., 2010; Dimitrov et al., 2019; Inglada et al., 2015). Spatial, temporal and spectral resolution has

2010; Dimitrov et al., 2019; Inglada et al., 2015). Просторна, временска и спектрална резолуција временом се увећала, константно побољшавајући резултате класификације (Tricht et al., 2018). Осим класификација на основу оптичких снимака, један број истраживања успјешно је проведен користећи само радарске снимке и информације о фенологији усјева (Bargiel, 2017; Clauss et al., 2018; Kenduiywo et al., 2018; Nasrallah, 2019). Оптички подаци користе видљиви, блиско-инфрацрвени и краткоталасни инфрацрвени дио електромагнетног спектра пружајући драгоцене информације о боји лишћа, садржају воде и укупном здрављу биљака, док радарски подаци зависно од фреквенције и поларизације, пружају сложен приказ структуре и храпавости површине, влажности земљишта и топографије (McNairn & Brisco, 2004). Бројне студије доказале су комплементарност оптичких и радарских података чија комбинација може повећати тачност процеса класификације (McNairn et al., 2009; Qiao et al., 2014; Park & Im, 2016; Mansaray et al., 2017; Kussul et al., 2018).

Покретањем мисије Сентинел-1 (2014 A/2016 B) и Сентинел-2 (2015 A/2017 B) којима управља Европска свемирска агенција (European Space Agency – ESA), повећало се интересовање и број истраживања на тему мапирања усјева базираним на синергији ова два извора података (Sonobe et al., 2017; Tricht et al., 2018; Denize et al., 2019; Sun et al., 2019; Campos-Taberner et al., 2019; Orynbaikyzy et al., 2020; Abubakar et al., 2020).

Вишевременски сателитски снимци утичу на прецизност класификације, али такође представљају специфичан изазов са аспекта претраживања, преузимања, складиштења и комплексности обраде сателитских снимака. Претраживање и преузимање података захтијевно је са аспекта времена потребног за извођење ових радњи. Потребна је адекватна меморија за складиштење велике количине података, затим процесори и радна меморија са високим перформансама који су неопходни за израчунавање и покретање захтијевних алгоритама. Ови проблеми у великој мјери могу

increased over time, constantly improving classification results (Tricht et al., 2018). Apart from classifications based on optical images, a number of studies have been successfully conducted using only radar images and crop phenology information (Bargiel, 2017; Clauss et al., 2018; Kenduiywo et al., 2018; Nasrallah, 2019). Optical data use the visible, near-infrared and short-wave infrared part of the electromagnetic spectrum, providing valuable information about leaf colour, water content and overall plant health, while radar data, depending on frequency and polarization, provide a complex representation of surface structure and roughness, soil moisture and topography (McNairn & Brisco, 2004). Numerous studies have proven the complementarity of optical and radar data, the combination of which can increase the accuracy of the classification process (McNairn et al., 2009; Qiao et al., 2014; Park & Im, 2016; Mansaray et al., 2017; Kussul et al., 2018).

With the launch of the Sentinel-1 (2014 A/2016 B) and Sentinel-2 (2015 A/2017 B) missions operated by European Space Agency (ESA), the interest and number of research on the topic of crop mapping based on the synergy of these two data sources has increased (Sonobe et al., 2017; Tricht et al., 2018; Denize et al., 2019; Sun et al., 2019; Campos-Taberner et al., 2019; Orynbaikyzy et al., 2020; Abubakar et al., 2020).

Multi-temporal satellite images affect the accuracy of the classification, but they also represent a specific challenge in terms of searching, downloading, storing and processing complexity of satellite images. Searching and downloading data is demanding in terms of the time required to perform these actions. Adequate memory is needed to store a large amount of data, then high-performance processors and working memory are necessary to calculate and run demanding algorithms. These problems can largely be overcome by using platforms such as Google Earth Engine (GEE), which is based on cloud technology. GEE is a platform for processing a large

се превазићи коришћењем платформи као што је Google Earth Engine (GEE), а која је базирана на клауд технологији. GEE је платформа за обраду велике количине геоподатака и развијена је за извођење гепросторних анализа на планетарној скали (Gorelick, 2017). Лак, брз и бесплатан приступ скуповима података, отворио је врата континуираном надгледању Земљине површине кроз разумне и са аспекта надгледања прихватљиве просторне и временске резолуције (Zurqani et al., 2018). Рачунања у GEE изводе се помоћу Google инфраструктуре, гдје су анализе аутоматски паралелизоване тако да паралелно могу бити укључени многи компјутерски процесори приликом одређеног рачунања. Ово је од изузетног значаја нарочито за обимне и захтијевне геопросторне анализе. Подаци из других извора се могу користити у GEE, те се могу репројектовати ако је то неопходно (Bajić et al., 2017). У последњих 2–3 године настају многе апликације и студије засноване на GEE платформи у чијем фокусу је истраживање начина коришћења земљишта, те посебно интересантно за ово истраживање студије о класификацији типова усјева (Teluguntla et al., 2018; Poortinga et al., 2019; Paludo et al., 2020; Tassi & Vizzari, 2020; Xinkai et al., 2020; Marszalek et al., 2020; Amani et al., 2020).

Такође, традиционални приступ класификацији усјева са подацима изведеним из даљинске детекције, заснован је првенствено на техникама надзиране и ненадзиране класификације (Palchowdhuri et al., 2018). Аутори у овом раду изводе надзирну пиксел базирану класификацију, која подразумева класификацију сваког пиксела на вишевременском скупу података. Читав процес класификације биће надзиран, почев од прикупљања тренинг података који ће се користити у учењу алгоритма класификације, па до израде карте начина коришћења земљишта са тежиштем на пољопривредном земљишту, односно усјевима озиме пшенице, уљане репице, зоби и јечма.

## ПОДРУЧЈЕ ИСТРАЖИВАЊА И ПОДАЦИ

### Подручје истраживања

Подручје истраживања (Сл. 1) налази се на сјеверу Републике Српске / Босне и Херцеговине (БиХ) у обухвату геопростора Лијевча поља,

amount of geodata and was developed to perform geospatial analyses on a planetary scale (Gorelick, 2017). Easy, fast and free access to data sets has opened the door to continuous monitoring of the Earth's surface through reasonable and from the point of view of monitoring acceptable spatial and temporal resolution (Zurqani et al., 2018). Calculation in GEE are performed using the Google infrastructure, where analyses are automatically parallelized so that many computer processors can be involved in parallel during a particular calculation. This is of exceptional importance, especially for extensive and demanding geospatial analyses. Data from other sources can be used in GEE, and can be reprojected if necessary (Bajić et al., 2017). In the last 2–3 years, many applications and studies based on the GEE platform have been created, the focus of which is research on land use, and especially interesting for this research is the study on the classification of crop types (Teluguntla et al., 2018; Poortinga et al., 2019; Paludo et al., 2020; Tassi & Vizzari, 2020; Xinkai et al., 2020; Marszalek et al., 2020; Amani et al., 2020).

Also, the traditional approach to crop classification with outputs derived from remote sensing is based primarily on supervised and unsupervised classification techniques (Palchowdhuri et al., 2018). In this paper, the authors perform supervised pixel-based classification, which includes the classification of each pixel on a multi-temporal data set. The entire classification process will be monitored, started with the collection of training data that will be used in learning the classification algorithm, and ending with the creation of a land use map with a focus on agricultural land, i.e. crops of winter wheat, rapeseed, oats and barley.

## AREA OF RESEARCH AND DATA

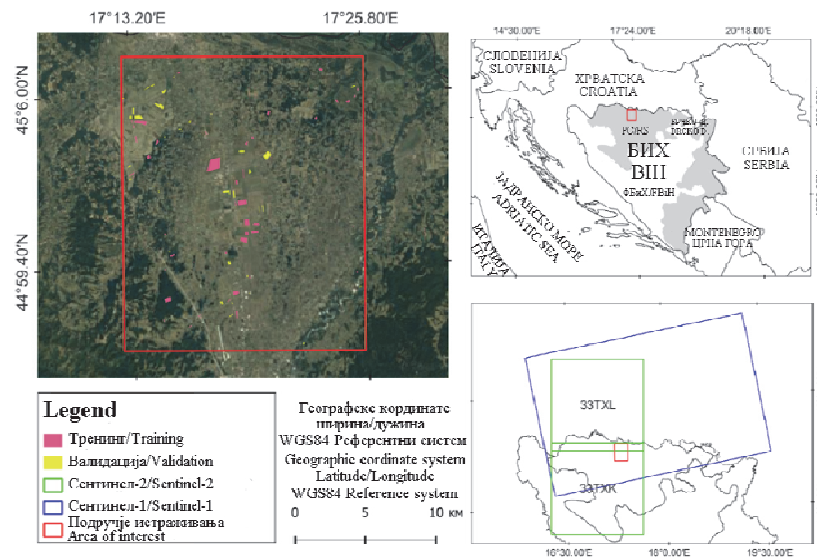
### Area of research

The research area (Fig. 1) is located in the north of Republic of Srpska / Bosnia and Herzegovina (B&H) within the geospace of



које је по физиономском принципу веома јасно издиференцирана физичко-географска структурна јединица.

Lijevče field, which according to the physiognomic principle is a very clearly differentiated physical-geographical structural unit.



Сл. 1. Подручје истраживања  
Fig. 1. Study Area

У физичко-географском смислу Лијевче поље је равница, благо нагнута ка сјеверу, односно сјевероистоку у односу на динарски планински систем и представља један морфогенетски блок. Лијевче поље има облик неправилног, обрнутог троугла, чију основицу представља долина Саве (сјеверна граница дужине од око 24 km), а краке ријека Врбас (источна граница дужине од око 34 km) и морфоструктура изохипса од око 120 m н.в. (западна граница дужина од око 34 km). Површина Лијевча поља износи око 500 km<sup>2</sup> (Трбић, 2004).

Подручје истраживања има умјерено-континенталну климу коју одликује влажна и топла лjeta и хладне зиме са мањом количином падавина. Просјечна годишња температура ваздуха и просјечна годишња количина падавина износи 11.2 °C и 1040 mm, респективно. Просјечна температура најтоплијег мјесеца (јул) износи 24 °C, док просјечна температура најхладнијег мјесеца (јануара) износи 0.3 °C. Истраживани простор одликује континентални плувиометријски режим са највећом количином падавина у сезони лjeta (284 mm) и најмањом у сезони зима (227 mm). Најкишовитији

In the physical-geographical sense, the Lijevče field is a plain, slightly inclined to the north, that is, to the northeast in relation to the Dinaric mountain system, and represents one morphogenetic block. The Lijevče field has the shape of an irregular, inverted triangle, the base of which is the Sava valley (northern border of about 24 km long), and the branches of the Vrbas River (eastern border of about 34 km long) and the isohypse morphostructure of about 120 m above sea level (western border length of about 34 km). The area of Lijevče field is about 500 km<sup>2</sup> (Трбић, 2004).

The research area has a moderate-continental climate characterized by wet and hot summers and cold winters with less precipitation. The average annual air temperature and average annual precipitation amount to 11.2 °C and 1040 mm, respectively. The average temperature of the hottest month (July) is 24 °C, while the average temperature of the coldest month (January) is 0.3 °C. The investigated area is characterized by a continental pluviometric regime with the highest amount of precipitation in the summer season (284 mm) and the lowest in the winter

мјесец је јун у којем се просјечно излучи 109 mm, док је мјесец са најмањом количином падавина фебруар 65 mm (Милосављевић, 1973). Према расположивом природном потенцијалу (пољопривредне површине, употребна вриједност земљишта, повољан положај у односу на саобраћајнице) геопростор Лијевча поља има изнад просјечне природне (плодно земљиште, облик рељефа, клима) и економске услове за развој (Трбић, 2004).

У Таб. 1. приказан је календар сјетве и жетве за ратарске културе на подручју БиХ.

season (227 mm). The rainiest month is June, with an average precipitation of 109 mm, while the month with the least amount of precipitation is February, 65mm (Милосављевић, 1973). According to the available natural potential (agricultural areas, usable value of the land, favorable position in relation to roads), the geospace of Lijevče field has above average natural (fertile soil, landform, climate) and economic conditions for development (Трбић, 2004).

Tab. 1 shows the sowing and harvesting calendar for field crops in B&H.

Таб. 1. Календар сјетве и жетве главних ратарских култура на простору БиХ  
 Tab. 1. Crop calendar for main crops in the B&H

Усјеви / Crops	Сјетва (мјесец) / Sowing (month)	Жетва (мјесец) / Harvest (month)
Пшеница озима / Winter wheat	X, XI	VI, VII
Пшеница јара / Spring wheat	III	VII
Раж / Rye	IX, X	VI, VII
Јечам озими / Winter barley	X	VI, VII
Јечам јари / Spring barley	III	VII
Зоб озима / Winter oats	IX, X	VI, VII
Зоб јара / Spring oats	III	VII, VIII
Кукуруз / Maize	IV, V	IX, X
Просо обично / Millet	IV, V	VIII
Сирак / Sorghum vulgare	IV, V	VIII, IX
Рижа / Rice	IV, V	VIII
Сунцокрет / Sunflower	IV	VIII, IX
Соја / Soybean	IV	VIII, IX
Уљана репица / Rapeseed	IX	VI, VII

Према процјењеним подацима Министарства пољопривреде, шумарства и водопривреде Републике Српске под озимим културама у сезони 2019/2020 у Лијевчу пољу засијано је око 15000 ha. Од засијане површине на пшеницу отпада око 70 %, затим на јечам 15 %, уљану репицу 8.5 %, озиму зоб 6 % и тритикале 0.5 %.

#### Референтни подаци

За истраживање прикупљени су референтни подаци за производну сезону 2019/2020, и то за озиме културе: пшеницу, јечам, уљану репи-

According to the estimated data of the Ministry of Agriculture, Forestry and Water Management of the Republic of Srpska, about 15000 ha were sown under winter crops in the 2019/2020 season in Lijevče field. About 70 % of the sown area is wheat, followed by barley 15 %, oilseed rape 8.5 %, winter oats 6 % and triticale 0.5 %.

#### Reference data

Reference data for the 2019/2020 production season were collected for the research, for winter crops: wheat, barley, oilseed rape,

цу, зоб, затим за оранице и травнате површине, те за водене површине (језера и ријеке), шуме и изграђене површине (урбане површине). За озиме културе, травнате површине и оранице подаци су прикупљени директно на терену уз помоћ GPS-а и дигиталне камере и то на 150 локација, док су за водене површине, шуме и изграђене површине коришћени Google сателитски снимци високе резолуције. На подручју истраживања у једном незнатном удјелу у укупној производњи житарица заступљени су тритикале и јаре културе (јара пшеница, јари јечам и јара зоб), међутим на терену није прикупљен довољан број репрезентативних узорака тако да су свјесно игнорисани у класификацији. С обзиром на њихов незнатан удио у укупној производњи житарица на подручју Лијевча поља (по процјени аутора рада не више од 2–3 %), оне неће значајно утицати на резултат надзиране класификације. На Сл. 2. приказано је шест површина под различитим културама, травом и ораницом са прецизно дефинисаним геопросторним положајем (x, y координатама).

oats, then for arable land and grassy areas, and for water areas (lakes and rivers), forests and built-up areas (urban areas). For winter crops, grasslands and arable land, data was collected directly on the ground with the help of GPS and digital cameras at 150 locations, while for water bodies, forests and built-up areas, high-resolution Google satellite images were used. In the research area, triticale and spring crops (spring wheat, spring barley and spring oats) are represented in an insignificant share of the total grain production, however, a sufficient number of representative samples were not collected in the field, so they were deliberately ignored in the classification. Considering their insignificant share in the total grain production in the area of Lijevo field (according to the author's estimation, no more than 2–3 %), they will not significantly affect the result of the supervised classification. Fig. 2. shows six areas under different crops, grass and arable land with a precisely defined geospatial position (x, y coordinates).



Сл. 2. Озиме културе: I – озима пшеница, II – озими јечам, III – уљана репица, IV – озима зоб, V – травната површина, VI – ораница

Fig. 2. Winter crops: I – winter wheat, II – winter barley, III – rapeseed, IV – winter oats, V – grassland, VI – ploughland

У QGIS (<https://www.qgis.org/en/site/>) апликацији извршена је ручна делинација тренинг парцела на основу Сентинел-2 сателитског снимка, Google сателитских снимака високе

In the QGIS (<https://www.qgis.org/en/site/>) application, manual delineation of the training plots was performed based on the Sentinel-2 satellite image, high-resolution Google Satellite

резулације и уз помоћ фотографија и GPS података (x, y координата) прикупљених на терену.

images and with the help of photos and GPS data (x, y coordinates) collected in the field.

Таб. 2. Број тренинг и валидационих пиксела по класама  
 Tab. 2. Number of training and validation pixels per class

Класа / Class	Kod / Code	Тренинг / Training	Валидација / Validation
Зоб / Oats	1	67	71
Уљана репица / Rapeseed	2	120	100
Трава / Grassland	3	257	245
Шума / Forest	4	165	116
Вода / Water	5	137	119
Пшеница / Wheat	6	208	285
Изграђене површине / Built-up	7	101	139
Ораница / Ploughland	8	208	333
Јечам / Barley	9	130	89

Број тренинг и валидационих пиксела приказан је у Таб. 2. Свакој од 9 класа додјељен је број класе, те су полигони случајним одабиром подијељени у односу тренинг (48 %) / валидација (52 %). За узорковање случајним одабиром издвојено је максимално 20 тачака (пиксела) по полигону, минималног међусобног растојања од 20 m. Овакав приступ се у великој мјери користи у литератури (Tassi & Vizzari, 2020). Овим начином издвојено је укупно 2890 тачака/пиксела, 1393 за тренирање и 1497 тачака за валидацију.

The number of training and validation pixels is shown in Tab. 2. Each of the 9 classes was assigned a class number, and the polygons were randomly selected in the ratio of training (48 %) / validation (52 %). A maximum of 20 points (pixels) per polygon, with a minimum distance of 20 m, were selected for random sampling. This approach is widely used in the literature (Tassi & Vizzari, 2020). In this way, a total of 2890 points/pixels were extracted, 1393 for training and 1497 points for validation.

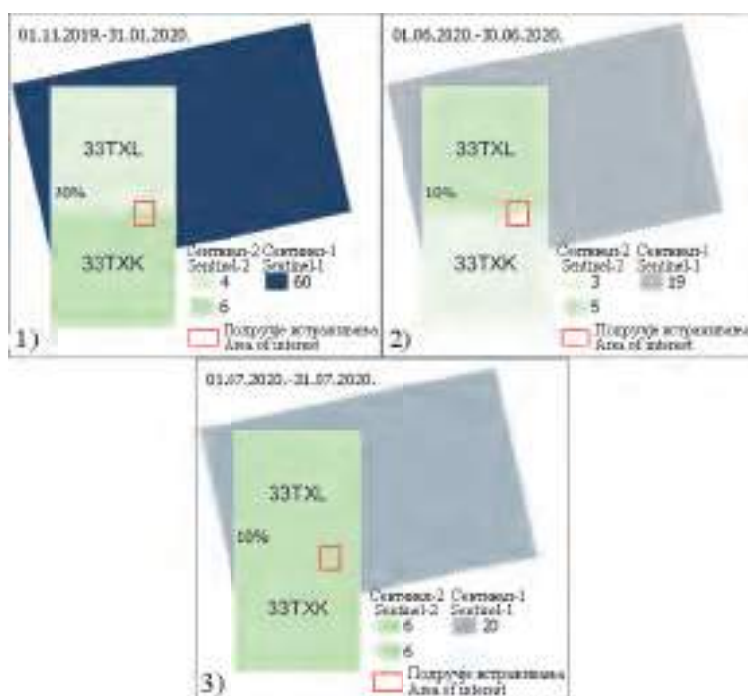
#### Satellite data

##### Сателитски подаци

У раду су коришћене комбинације више-временских радарских Сентинел-1 (С-1) и оптичких Сентинел-2 (С-2) сателитских снимака за 2019. и 2020. годину. Тачан положај подручја истраживања у односу на захвате С-1 и С-2 снимака приказан је на Сл. 3, на којој је дат и број С-1 и С-2 снимака од којих су израђени композитни скупови података као и проценат облачности (С-2) за сваки период.

Combinations of multi-temporal radar Sentinel-1 (S-1) and optical Sentinel-2 (S-2) satellite images for 2019 and 2020 were used in the paper. The exact location of the research area in relation to the captures of S-1 and S-2 images is shown in Fig. 3, which also shows the number of S-1 and S-2 images from which the composite data sets were made, as well as the percentage of cloudiness (S-2) for each period.





Сл. 3. Положај подручја истраживања у односу на захват (плочице) Сентинел-2 и Сентинел-1 сателита са бројем снимака за сваки период и процентом облачности

Fig. 3. Position of the study area in relation to the coverage (tiles) of Sentinel-2 and Sentinel-1 satellites with the number of images for each period and the percentage of cloud cover

Од спектралних канала у првој фази истраживања коришћени су сви канали сем канала В1 (обалне аеросоли), В9 (водена пара) и В10 (цируси). Касније ће се у даљем истраживању извршити селекција најоптималнијих спектралних канала за сваки временски период. Осим тога, за потребе класификације изведени су и вегетациони индекси из спектралних канала. Сентинел-2 снимак покрива видљиви дио спектра (канал В2, В3 и В4), ивично црвени (канал В5, В6, В7, В8А), блиско инфра-црвени (канал В8) и краткоталасни инфра-црвени спектар (канал В11 и В12). За израду 3 композита од оптичких С-2 снимака нивоа 2А, облачности < 10 % и < 20 %, коришћене су функције маскирања облака и сјенки које су генерисане у Java Script програмском језику и које су израдили програмери GEE заједнице. За потребе истраживања коришћена је Сентинел-1 GRD снимка (Ground Range Detected) која је задржана у линеарној скали (S1\_GRD\_FLOAT), пошто сви кораци припреме захтијевају да подаци буду у линеарној скали. Након припреме С-1 снимака

In the first phase of the research, all channels were used except channels B1 (coastal aerosols), B9 (water vapor) and B10 (cirrus). Later, in further research, the selection of the most optimal spectral channels for each time period will be carried out. In addition, vegetation indices from spectral channels were derived for classification purposes. The Sentinel-2 image covers the visible part of the spectrum (channels B2, B3 and B4), edge-red (channels B5, B6, B7, B8A), near-infrared (channel B8) and short-wave infrared (channels B11 and B12). Cloud and shadow masking functions generated in the Java Script programming language and developed by GEE community developers were used to create 3 composites of level 2A optical S-2 imagery, with cloud cover between < 10 % and < 20 %. For the purposes of the research, Sentinel-1 GRD (Ground Range Detected) footage was used, which was kept in a linear scale (S1\_GRD\_FLOAT), since all preparation steps require the data to be in a linear scale. After

овај сет података је калибрисан на коефицијент повратног распршења изражен у децибелима (dB). Укупно три корака обраде за овај сет података изведени су од стране GEE програмера и ти кораци подразумевају: уклањање топлотне буке, радиометријску калибрацију и корекцију терена.

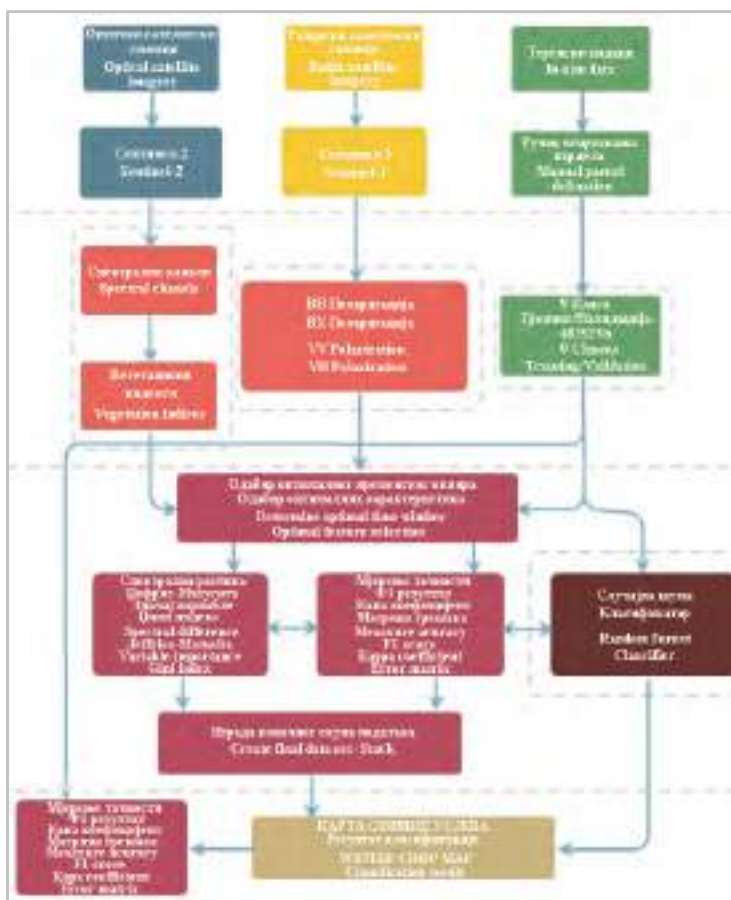
preparation of S-1 recordings, this data set was calibrated to the backscatter coefficient expressed in decibels (dB). A total of three processing steps for this data set were performed by GEE programmers and these steps include: removal of thermal noise, radiometric calibration and terrain correction.

МЕТОДЕ

METHODS

Да би израдили неки скуп података потребно је учинити неколико основних корака, почев од прикупљања референтних података, ручне делинације парцела, дефинисање временских оквира осматрања, филтрирање и оптимизација количине информација неопходних за извођење надзиране класификације, те избор класификатора и покретање алгоритма класификације. Овим корацима, кроз неколико фаза, текао је процес надзирне класификације (Сл. 4).

In order to create a data set, it is necessary to do several basic steps, starting with the collection of reference data, manual delineation of parcels, definition of time frames of observation, filtering and optimization of the amount of information necessary to perform a supervised classification, as well as the selection of a classifier and the start of the classification algorithm. With these steps, through several stages, the supervisory classification process is underway (Fig. 4).



Сл. 4. Радни процес класификације  
 Fig. 4. Workflow of classification

Неопходност константног мјерења тачности класификације захтијева извођење узастопних итерација на истом или различитом скупу података. Цијели процес захтијева огромне инфраструктурне ресурсе, те из тог разлога није погодан за извођење на локалним машинама. Као адекватно и квалитетно алтернативно рјешење у овом случају намеће се GEE окружење. Ово окружење даје могућност лаког извођења изузетно захтијевних процеса. Осим постизања високе прецизности и поузданости резултата класификације, тежило се и оптималној потрошњи ресурса и већој брзини извођења операција. Зато су у ту сврху након што су израђени скупови података по периодима, исти изведени у GEE складиште (Google Earth Engine Assets), те су касније позивани у радни простор GEE. Даље, агрегацијом 3 композита у један сложени скуп података (енгл. Stack) изведен је финални скуп података.

Селекција оптималног временског оквира мјерењем Jeffries-Matusita дистанце

Вријеме агрегације података у мултивременским класификацијама, у значајној мјери одређује исход класификације. Како би се период по период измјерила сепарација између класа, у оквиру GEE израчунате су спектралне дистанце Jeffries-Matusita (JM) и Bhattacharyya (BH). Осим добијања информација о оптималним временским периодима, корисна је информација и у којем је спектралном каналу или вегетационом индексу већа сепарација између класа. У свом раду Hao et al. (2014) примјењују мјерења JM и BH дистанце да би разумјели како се сепарација различитих усјева мијења током сезоне, са циљем избора оптималних временских периода у којима се изводе и рачунају варијабле неопходне за класификацију.

Дистанца JM је мјера просјечне удаљености између двије класе и дефинисана је као:

$$J_{ij} = 2(1 - e^{-B_{ij}}) \quad (1)$$

гдје је  $B_{ij}$  BH удаљеност:

The necessity of constant measurement of classification accuracy requires the performance of successive iterations on the same or different data set. The entire process requires huge infrastructure resources, and for this reason it is not suitable for execution on local machines. As an adequate and high-quality alternative solution in this case, the GEE environment is imposed. This environment gives the possibility of easily performing extremely demanding processes. In addition to achieving high precision and reliability of the classification results, the aim was also to optimize the consumption of resources and speed up the execution of operations. Therefore, for this purpose, after the data sets by period were created, they were exported to the GEE storage-asset (Google Earth Engine Assets), and were later called into the GEE workspace. Further, by aggregating 3 composited into one complex data set (Stack), the final data set was derived.

Selection of the optimal time frame by measuring the Jeffries-Matusita distance

The time of data aggregation in multi-temporal classifications largely determines the outcome of the classification. To achieve this, the spectral distance was calculated within the Jeffries-Matusita (JM) and Bhattacharyya (BH) GEEs, in order to measure the separation between classes period by period. In addition to obtaining information about optimal time periods, information is also useful in which spectral channel or vegetation index has a greater separation between classes. In their paper, Hao et al. (2014) apply JM and BH distance measurements to understand how to separation of different crops changes during the season, with the aim of choosing the optimal time periods in which the variables necessary for the classification are derived and calculated.

The JM distance is a measure of the average distance between two classes and is defined as:

$$J_{ij} = 2(1 - e^{-B_{ij}}) \quad (1)$$

where is  $B_{ij}$  Bhattacharyya is the distance:

$$B_{ij} = \frac{1}{8}(\mu_i - \mu_j)^t \left( \frac{\Sigma_i + \Sigma_j}{2} \right) (\mu_i - \mu_j) + \frac{1}{2} \ln \left( \frac{|(\Sigma_i + \Sigma_j)/2|}{\sqrt{|\Sigma_i||\Sigma_j|}} \right) \quad (2)$$

а гдје су  $\mu_i$  и  $\mu_j$  средњи вектори две разматране класе,  $\Sigma_i$  и  $\Sigma_j$  су одговарајуће матрице коваријанце. JM дистанца се креће у вриједности од 0 до 2 повећавајући сепарацију између класа, док већа вриједност  $B_{ij}$  одговара већем просјечном растојању између класа. У случају нормално дистрибуираних класа,  $J_{ij}$  постаје  $B_{ij}$  (Richards & Jia, 2006). Вриједност 0 значи никакву, док вриједност 2 значи потпуну сепарацију између парова класа (Sousa et al., 2003). Резултат мјерења JM спектралне дистанце су 3 временска периода чије су временске серије података преточене у 3 композитна скупа.

#### Израда скупова података даљинске детекције

За потребе класификације осим спектралних канала оптичких снимака, израђено је неколико вегетационих индекса који су коришћени у изради укупно 3 композита. Спектрални индекси изведени из сателитских снимака даљинске детекције нашироко су коришћени за класификацију усјева (Orynbaikyzy et al., 2020). Из С–2 за потребе истраживања израђена су 4 спектрална индекса и то: вегетациони индекс нормализоване разлике (Normalised Difference Vegetation Index – NDVI), водени индекс нормализоване разлике (Normalised Difference Water Index – NDWI), затим вегетациони индекс прилагођен рефлексiji земљишта (Soil Adjust Vegetation Index – SAVI) и индекс израђености (Index-Based Built-up Index – IBI). NDVI први је у свом истраживању предложио Роуз са групом аутора (Rouse et al., 1973). Овај вегетациони индекс најчешће је коришћен и експлоатисан од стране заједнице истраживача у даљинској детекцији. Многа истраживања базирана на овом вегетационом индексу показала су изузетне резултате, између осталих и велики број класификација усјева изведен је захваљујући NDVI индексу (Qiao et al., 2014; Palchowdhuri et al., 2018; Amani et al., 2020). NDWI садржи информације о количини воде у биљкама и у великој мјери се користи за класификацију (Gao, 1996; Sun et al., 2020). Избор вегетационог индекса базирао се на

$$B_{ij} = \frac{1}{8}(\mu_i - \mu_j)^t \left( \frac{\Sigma_i + \Sigma_j}{2} \right) (\mu_i - \mu_j) + \frac{1}{2} \ln \left( \frac{|(\Sigma_i + \Sigma_j)/2|}{\sqrt{|\Sigma_i||\Sigma_j|}} \right) \quad (2)$$

and where  $\mu_i$  and  $\mu_j$  are the mean vectors of the two considered classes,  $\Sigma_i$  and  $\Sigma_j$  are the corresponding covariance matrices. The JM distance ranges from 0 to 2, increasing the separation between classes, while a larger value of  $B_{ij}$  corresponds to a larger average distance between classes. In the case of normally distributed classes,  $J_{ij}$  becomes  $B_{ij}$  (Richards & Jia, 2006). A value of 0 means none, while a value of 2 means complete separation between pairs of classes (Sousa et al., 2003). The result of the JM spectral distance measurement in 3 time periods whose time series of data have been transformed into 3 composite sets.

#### Creation of remote sensing datasets

For the purposes of classification, in addition to the spectral channels of the optical images, several vegetation indices were created that were used in the creation of 3 composites. Spectral indices derived from remote sensing satellite imagery have been widely used for crop classification (Orynbaikyzy et al., 2020). From S–2, 4 spectral indices were created for the purposes of research, namely: Normalised Difference Vegetation Index (NDVI), Normalised Difference Water Index (NDWI), the Soil Adjust Vegetation Index (SAVI) and Index-Based Built-up Index (IBI). NDVI was first proposed in research by Rouse with group of authors (Rouse et al., 1973). This vegetation index is most often used and exploited by the remote sensing research community. Many studies based on this vegetation index have shown exceptional results, among others, a large number of crop classifications have been performed thanks to the NDVI index (Qiao et al., 2014; Palchowdhuri et al., 2018; Amani et al., 2020). NDWI contains information about the amount of water in plants and is widely used for classification (Gao, 1996; Sun et al., 2020). The selection of the vegetation index was based on the spectral response of different crops, so eg. SAVI veg-



спектралном одговору различитих усјева, те је тако нпр. SAVI вегетациони индекс прилагођен утицају рефлексije земљишта на основу које се релативно лако могу одвојити прољећне од зимских култура (Palchowdhuri et al., 2018). IBI је изведен из других индекса и користан је за издвајање изграђених површина као и голог земљишта (Xu, 2008).

Осим 3 корака корекције Сентинел-1 сцене изведене од стране GEE програмера, извршена је корекција буке на ивици – граници (енгл. Additional Border Noise Correction), радиометријска корекција терена (енгл. Radiometric terrain normalization), затим примјењен је Гама мап-филтер (енгл. Speckle filtering) према упутствима како је детаљно објашњено и у коду израђено у раду Мулиса и других (Mullissa et al., 2021). За потребе класификације, од С-1 коришћен је интезитет повратног сигнала (dB) вертикално-вертикалне (VV) и вертикално-хоризонталне (VH) поларизације. Након одабира временских периода за које ће се урадити агрегација података у композите, изабране су варијабле од којих ће се израдити 3 композита.

#### Класификацијски алгоритам и мјерење тачности

За потребе израде надзиране пиксел базиране класификације, коришћена је “случајна шума”, алгоритам машинског учења (Random Forest – RF). Класификатор RF користи вишеструко стабло одлуке како би додјелио класификацијске ознаке, те како би смањено пренаученост модела (енгл. Overfitting). Из сваког тренинг податка насумично се узимају узорци, те из добијених насумичних узорака алгоритам израђује „шуму стабала“. У раду је за потребе класификације обучен класификатор RF са параметром од 50 стабала који је примјењен на скуп података за тренинг и валидацију.

Тачност изведене класификације директно је мјерена у GEE, користећи тачке (пикселе) за валидацију. Мјерена је укупна тачност (Overall Accuracy – OA), корисничка тачност (User Accuracy – UA), производна тачност (Producer Accuracy – PA), Капа коефицијент и F–1 резултат (F–1 score). За провјеру тачности кориштена је матрица конфузије (Confusion Matrix), унутар

etation index adopted to the influence of soil reflection, on the basis of which spring crops can be separated from winter crops relatively easily (Palchowdhuri et al., 2018). The IBI built-up index is derived from other indices and is useful for distinguishing built-up areas as well as bare land (Xu, 2008).

In addition to the 3-step correction of the Sentinel-1 scene performed by the GEE programmers, additional border noise correction, radiometric terrain normalization, then Speckle filtering was applied according to instructions as explained in detail and coded in the work of Mullissa and other other authors (Mullissa et al., 2021). For purposes of classification, from S–1, the return signal intensity (dB) of vertical-vertical (VV) and vertical-horizontal (VH) polarization was used. After selecting the time periods for which data aggregation will be done into composites, the variables from which 3 composites will be created were selected.

#### Classification algorithm and fluid measurement

For the purposes of creating a supervised pixel-based classification, a Random Forest (RF) machine learning algorithm was used. RF classifier uses a multiple decision tree to assign classification labels and to reduce overfitting of the model. Samples are taken randomly from each training data, and the algorithm builds a “forest” of trees from the obtained random samples. In this work, a RF classifier with a parameter of 50 trees was trained for the purposes of classification and applied to the data set for training and validation.

The accuracy of the derived classification was directly measured in GEE, using points (pixels) for validation. Overall Accuracy (OA), User Accuracy (UA), Producer Accuracy (PA), Kappa coefficient and F–1 score were measured. To check the accuracy, a Confusion Matrix was used, in which the data on the diagonals represent correctly classified pixels, while the pixels

које подаци на дијагоналама представљају исправно класификоване пикселе, док су пиксели изван дијагонале погрешно класификовани у другу класу. OA класификације дефинисана је као омјер исправно класификованих пиксела насупрот укупног броја пиксела. UA добија се дијелењем броја исправно класификованих пиксела који припадају некој класи са сумом вриједности у редовима те исте класе, док се вриједност PA добија дијелењем броја исправно класификованих пиксела који припадају некој класи са сумом вриједности у колони те исте класе (Dobrinić et al., 2019). Рачунањем Капа коефицијента може се додатно провјерити резултат класификације. Његова вриједност креће се од 0 до 1. Вриједност Капа коефицијента 0 значи да се класификацијом није дошло до бољих резултата који би се остварили случајном класификацијом, док вриједност 1 значи да је класификација без грешке (Landis & Koch, 1977). Ф-1 мјера означава мјеру тачности модела. Користи се када мјере прецизности и одзива не дају довољно јасне резултате. Зависна је од прецизности и одзива и вриједности варирају од 0 до 1, гдје 0 означава лош резултат док 1 значи најбољу могућу тачност модела (Zerrouki & Bouchaffra, 2014).

## РЕЗУЛТАТИ И ДИСКУСИЈА

Резултат мјерења JM спектралне сепарације између озимих култура

У мјерењу JM дистанце коришћене су варијабле изведене из С-2 оптичког сателитског снимка (спектрални канали и вегетациони индекси). Осим тога, фокус је на озимим културама, пошто је дистанца у односу на остале класе (трава, шума, вода, изграђено, оранице) изнад 1.4 и релативно добро се одвајају од озимих култура. Раздвајање класа у оквиру озимих култура представљало је изазов за ауторе рада. У Таб. 3 приказан је резултат мјерења JM спектралне дистанце на основу којих су издвојена 3 временска периода чије су временске серије података преточене у 3 композитна скупа и то за периоде: 1) од 01.11.2019. до 31.01.2020., 2)

outside the diagonal are incorrectly classified into another class. OA of the classification is defined as the ratio of correctly classified pixels against the total number of pixels. UA value is obtained by dividing the number of correctly classified pixels belonging to a class by the sum of the values in the rows of the same class, while the PA is obtained by dividing the number of correctly classified pixels belonging to a class by the sum of the values in the column and of the same class (Dobrinić et al., 2019). The classification result can be additionally checked by calculating the Kappa coefficient. Its value ranges from 0 to 1. The value of the Kappa coefficient 0 means that the classification did not lead to better results than would be achieved by random classification, while the value 1 means that the classification is error-free (Landis & Koch, 1977). F-1 result is a measure of model accuracy. The F-1 measure is a measure of model accuracy. It is used when the precision and responsiveness measures do not give sufficiently clear results. It depends on the accuracy and response and the values vary from 0 to 1, where 0 indicates a poor result while 1 means the best possible accuracy of the model (Zerrouki & Bouchaffra, 2014).

## RESULTS AND DISCUSSION

The result of measuring the JM spectral separation between winter crops

Variables derived from the S-2 optical satellite image (spectral channels and vegetation indices) were used to measure the JM distance. In addition, the focus is on winter crops, since the distance in relation to the other classes (grass, forest, water, built-up, arable land) is above 1.4 and they are relatively well separated from winter crops. The separation of classes within winter crops was a challenge for the authors of the paper. Tab. 3 shows the result of the JM spectral distance measurement, on the basis of which 3 time periods were selected, the time series of which were converted into 3 composite sets for the periods: 1) from 01.11.2019. until 31.03.2020,

од 01.06.2020. до 30.06.2020., 3) од 01.07.2020. до 31.07.2020. 2) from 01.06.2020. until 30.06.2020, 3) from 01.07.2020. until 31.07.2020.

Таб. 3. JM Спектрална дистанца између класа озимих култура  
Tab. 3. JM Spectral distance between classes of winter crops

01.11.2019.–31.01.2020.		Зоб / Oats	Уљана Репица / Rapeseed	Пшеница / Wheat	Јечам / Barley
	Зоб / Oats		1.2619	1.0334	1.174
C–2	Уљана Репица / Rapeseed	1.2619		1.2416	1.2168
S–2	Пшеница / Wheat	1.033	1.1375		1.0095
	Јечам / Barley	1.1745	1.17089	1.0095	
01.06.2020.–30.06.2020.		Зоб / Oats	Уљана Репица / Rapeseed	Пшеница / Wheat	Јечам / Barley
	Зоб / Oats		1.3779	1.348	1.4063
C–2	Уљана Репица / Rapeseed	1.3779		1.2859	1.3862
S–2	Пшеница / Wheat	1.348	1.2859		1.3764
	Јечам / Barley	1.4063	1.3862	1.3764	
01.07.2020.–31.07.2020.		Зоб / Oats	Уљана Репица / Rapeseed	Пшеница / Wheat	Јечам / Barley
	Зоб / Oats		1.3502	1.4006	1.335
C–2	Уљана Репица / Rapeseed	1.3502		1.2796	1.3027
S–2	Пшеница / Wheat	1.335	1.2796		1.3556
	Јечам / Barley	1.3672	1.3027	1.3556	

Са аспекта спектралне сепарације нарочито је занимљив други период, а који се односи на мјесец јун. У првој половини мјесеца јуна јечам углавном сазријева. Процес сазријевања се одражава на резултат сепарације јечма. Ово је изузетно повољан период за одвајање прије свега јечма од пшенице, али и зоби.

#### Резултат селекције варијабли и класификације

Након што је резултат мјерења JM дистанце између класа одредио 3 оптимална временска периода, приступило се одабиру и селекцији варијабли од којих ће се изградити 3 композитна скупа података. Процес избора се одвијао тако што су један по један придруживани спектрални канали (изузев спектралних канала B1 – обалне аеросоли, B9 – водена пара и B10 – цируси),

From the aspect of spectral separation, the second period, which refers to the month of June, is particularly interesting. In the first half of June, barley mostly ripens. The ripening process is reflected in the result of barley separation. This is an extremely favorable period for separating barley from wheat, but also oats.

#### Result of variable selection and classification

After the result of measuring the JM distance between classes determined 3 optimal time periods, the selection of variables was made from which 3 composite data sets that will be built. The selection process took place by joining spectral channels one by one (except for spectral channels B1 – coastal aerosols, B9 – water vapor and B10 – cirrus), vegetation indices and the intensity

вегетациони индекси и интезитет повратног сигнала VV и VH поларизације. Комбинација варијабли која даје најбољи резултат мјерења (ОА и Капа коефицијент) је узета као референтна за период мјерења. Тако да за први период композитни скуп података чине варијабле које су приказане у Таб. 4. Приказан је резултат мјерења појединачно за спектралне канале, затим за придружене вегетационе индексе и интезитет повратног сигнала VV и VH поларизације.

of the return signal of VV and VH polarization. The combination of variables that gives the best measurement result (OA and Kappa Coefficient) was taken as reference for the measurement period. So, for the first period, the composite data set consists of the variables shown in Tab. 4. The result of the measurement is presented individually for the spectral channels, then for the associated vegetation indices and the intensity of the return signal of VV and VH polarization.

Таб. 4. С–1 и С–2 варијабле које чине композит првог временског периода и резултати мјерења тачности  
 Tab. 4. S–1 and S–2 variables that make up the composite of the first time period and accuracy measurement results

Спектрални канали / Spectral channels	B2	B3	B4	B5	B11	B12	NDVI	NDWI	SAVI	IBI	VV	VH
Укупна тачност / Overall accuracy	0.80						0.82				0.83	
Капа коефицијент / Kappa Coefficient	0.77						0.79				0.80	

За први период највећа тачност за спектралне канале измјерена је у комбинацији канала видљивог спектра са каналима ивично-црвеног и краткоталасног блиско-инфрацрвеног канала (Таб. 4).

For the first period, the highest accuracy for spectral channels was measured in the combination of visible spectrum channels with edge-red and short-wave near-infrared channels (Tab. 4).

Таб. 5. С–1 и С–2 варијабле које чине композит другог временског периода и резултати мјерења тачности  
 Tab. 5. S–1 and S–2 variables that make up the composite of the second time period and the results of accuracy measurements

Спектрални канали / Spectral channels	B2	B3	B5	B6	B8	B11	NDVI	NDWI	VV	VH
Укупна тачност / Overall accuracy	0.80						0.85		0.91	
Капа коефицијент / Kappa Coefficient	0.77						0.82		0.90	

У композиту другог временског периода (Таб. 5) за разлику од првог временског периода, елиминисан је црвени канал из видљивог спектра (B4), затим краткоталасни инфрацрвени канал (B12), вегетациони индекси SAVI и IBI, интезитет повратног сигнала VV поларизације. То је резултирало порастом ОА и Капа коефицијента у односу на први период.

In the composite of the second time period (Tab. 5), unlike the first time period, the red channel from the visible spectrum (B4), then the short-wave infrared channel (B12), the vegetation indices SAVI and IBI, the intensity of the return signal of VV polarization were eliminated. This resulted in an increase in OA and Kappa Coefficient compared to the first period.



Таб. 6. С–1 и С–2 варијабле које чине композит за трећи временски период и резултати мјерења тачности

Tab. 6. S–1 and S–2 variables that make up the composite for the third time period and the results of accuracy measurements

Спектрални канали / Spectral channels	B2	B4	B5	B8	B12	NDVI	NDWI	IBI	VV	VH
Укупна тачност / Overall accuracy	0.81					0.85			0.89	
Капа коефицијент / Kappa Coefficient	0.78					0.82			0.87	

У трећем временском периоду (Таб. 6) елиминисан је ивично-црвени спектрални канал (B6) који је заступљен у првом и другом временском периоду, али је враћен IBI индекс изграђености који није чинио композит другог временског периода. Пад ОА и Капа статистике у трећем временском периоду у односу на други је очекиван. Наиме, у овом периоду (мјесец јул) све озиме културе достижу пуну зрелост и мијењају боју од зелене у вегетативној фази до фазе зрења која се одликује златном бојом. Зато је у овом периоду класификатору знатно теже да раздвоји класе озимих култура. Након што су израђена три скупа података придружена су у један заједнички мултивременски скуп података (енгл. Stack). Наредни корак је подумијевао класификацију овог скупа података примјењујући класификатор RF са параметром од 50 стабала. ОА класификације је 0.96, док Капа коефицијент износи 0.95. Резултат класификације рефлектује се на приличан пораст тачности у односу на појединачне композите. Резултат коначне класификације представљен је у Таб. 7.

In the third time period (Tab. 6), the edge-red spectral channel (B6), which is represented in the first and second time periods, was eliminated, but the IBI built-up index was returned, which did not make up the composite of the second time period. The drop in OA and Kappa statistics in the third time period compared to the second is expected. Namely, in this period (the month of July) all winter crops reach full maturity and change color from green in the vegetative phase to the ripening phase, which is characterized by a golden color. That is why in this period it is much more difficult for the classifier to separate the classes of winter crops. After the three data sets were created, they were joined into one common multi-temporal data set (Stack). The next step included the classification of this data set using the RF classifier with a parameter of 50 trees. The OA of the classification is 0.96, while the Kappa Coefficient is 0.95. The result of the classification is reflected in a considerable increase in accuracy compared to individual composites. The result of the final classification is presented in Tab. 7.

Таб. 7. Резултати мјерења тачности класификације финалног скупа података, класе: зоб – 1, уљана репица – 2, трава – 3, шума – 4, вода – 5, пшеница – 6, изграђено – 7, ораница – 8, јечам – 9

Tab. 7. Results measuring the accuracy of classification for the final data, classes: oats – 1, rapeseed – 2, grassland – 3, forest – 4, water – 5, wheat – 6, built-up – 7, ploughland – 8, barley – 9

Класа / Class	1	2	3	4	5	6	7	8	9	Сума / Sum	UA (%)
1	47	0	0	0	0	0	0	0	0	47	1
2	0	100	0	0	0	0	0	0	1	101	0.99
3	2	0	245	0	0	1	4	4	12	268	0.91
4	0	0	0	115	0	0	0	0	0	115	1
5	0	0	0	0	119	0	0	0	0	119	1


6	21	0	0	0	0	<b>284</b>	0	0	7	312	0.91
7	0	0	0	0	0	0	<b>131</b>	0	0	131	1
8	0	0	0	1	0	0	2	<b>329</b>	0	332	0.99
9	1	0	0	0	0	0	2	0	<b>69</b>	72	0.96
Сума / Sum	71	100	245	116	119	285	139	333	89		
РА (%)	0.66	1	1	0.99	1	0.99	0.94	0.99	0.77		
F-1 (%)	0.80	0.99	0.95	0.99	1	0.95	0.97	0.99	0.86		

Према резултатима приказаним у матрици конфузије (грешака), класификатор је пикселе уљане репице у потпуности раздвојио од осталих класа. Пшеница је са изузетно високом тачношћу издвојена, док је јечам у границама апсолутно прихватљиве тачности (0.86 F-1). Највећа конфузија је између класе зоби и пшенице, што се рефлектује на крајњи резултат тачности класификације зоби који износи 0.66 (РА) и 0.80 (F-1).

Карта класификације подручја истраживања представљена је на Сл. 5. На њој је видљива између осталих класа, просторна дистрибуција озимих култура на подручју истраживања. Јасно се види да у укупној сјетвеној површини у сезони 2019/2020 доминира озима пшеница.

According to the results shown in the confusion (error) matrix, the classifier completely separated the rapeseed pixels from the other classes. Wheat was separated with extremely high accuracy, while barley was within the limits of absolutely acceptable accuracy (0.86 F-1). The biggest confusion is between the oat and wheat class, which is reflected in the final result of the oat classification accuracy, which is 0.66 (PA) and 0.80 (F-1).

The classification map of the research area is presented in Fig. 5. It shows, among other classes, the spatial distribution of winter crops in the research area. It is clear that winter wheat dominates the total sown area in the 2019/2020 season.



Сл. 5. Карта класификације: зоб – 1, уљана репица – 2, трава – 3, шума – 4, вода – 5, пшеница – 6, изграђено – 7, оранице – 8, јечам – 9

Fig. 5. Classification map: oats – 1, rapeseed – 2, grassland – 3, forest – 4, water – 5, wheat – 6, built-up – 7, ploughland – 8, barley – 9

Упечатљиве су велике појединачне површине под пшеницом (више дестина ха па и стотину ха), али и површине под уљаном репицом које се простиру на мањем броју локалитета али углавном на већим површинама (од неколико десетина хектара). Јечам је такође заступљен на читавом подручју истраживања на знатно мањем броју локалитета у односу на пшеницу и углавном на површинама од неколико ха.

## ДИСКУСИЈА

Огромна количина података, изузетни прије свега меморијски капацитети и различити алгоритми машинског учења доступни на GEE платформи кључни су за ово истраживање. Ако се узме у обзир чињеница да се у традиционалним процесима класификација сателитски снимци прво морају преузети, затим обрадити како би се уопште снимци могли употребити даље, јасно је да би на локалним машинама овај процес класификације био тешко изводљив или знатно отежан и успорен. У истраживању за израду 3 композитна скупа података кориштено је 30 С–2 снимака нивоа 2А и 99 снимака С–1 GRD нивоа. Израђени композити извезени су у GEE складиште што је трајало нешто више од једног сата (68 минута), док је покретање RF класификатора и мјерење тачности трајало око 40 секунди. Осим тога предност GEE у односу на традиционалне класификације јесте што пружа могућност извођења различитих шема класификација у неком разумном времену које подразумијевају велики број итерација, а све са циљем добијања најбољег могућег резултата оптималном потрошњом GEE ресурса.

Резултатима мјерења JM дистанце успјешно су одређена 3 оптимална временска периода за агрегацију варијабли у композит. Успјешно је повезано вријеме највеће сепарације пшенице и јечма са фазом зријења јечма која је кључна за сепарацију ове двије културе. Добијени резултати у истраживању показују да се комбинацијом С–2 и С–1 сателитских снимака могу извести тачније, прецизније класификације у односу на класификације изведене на основу само једног извора података. Укључивање С–1

Impressive are the large individual areas under wheat (more than a hundred hectares), but also the areas under oilseed rape, which are spread over a smaller number of locations, but mostly over larger areas (of several tens of hectares). Barley is also represented in the entire research area in a significantly smaller number of localities compared to wheat and mostly on areas of several ha.

## DISCUSSION

The huge amount of data, exceptional above all memory capacities and various machine learning algorithms available on the GEE platform are key to this research. If taken into account the fact that in traditional classification process satellite images must first be downloaded, then process, in order to be able to use the images further, it is clear that on local machines this classification process would be difficult or significantly more difficult and slowed down. 30 S–2 satellite images of level 2A and 99 satellite images of S–1 GRD level were used in the research to create 3 composite data sets. The created composites were exported to the GEE assets which took a little more than one hour (68 minutes), while starting the RF classifier and measuring the accuracy took about 40 seconds. In addition, the advantage of GEE compared to traditional classifications is that GEE provides the possibility of performing different classification schemes in a reasonable amount of time, which involve a large number of iterations, all with the aim of obtaining the best possible result with the optimal consumption of GEE resources.

The results of the JM distance measurement successfully determined 3 optimal time periods for the aggregation of variables into a composite. The time of the greatest separation of wheat and barley was successfully linked with the ripening phase of barley, which is crucial for the separation of these cultures. The results obtained in the research show that with the combination of S–2 and S–1 satellite images, more accurate and precise classifications can be performed compared to classifications based on only one data source. The inclusion of the S–1 variable did not significantly increase the accuracy,

варијабли није у знатној мјери повећало тачност, али је у моменту достизања максимума С–2 варијабли, утицала на повећање процента тачности (нпр. у трећем периоду максимално повећање ОА са 0.85 на 0.88, Капа повећање са 0.83 на 0.87). Начином селекције и избором варијабли постигнут је висок ниво тачности. Агрегацијом 3 композита у један скуп података и класификацијом финалног скупа података, достигнут је знатно виши ниво тачности у односу на резултат класификације појединачних композита. Мултивременска серија података у знатној мјери утицала је на повећање тачности класификације (од највеће ОА трећег композита 0.87, Капа 0.85 до ОА 0.96 и Капа 0.95).

### ЗАКЉУЧАК

У истраживању је кориштен GEE за генерисање 3 композита који су придружени у један скуп података и класификовани алгоритмом RF. Општи закључак је да се класификацијом вишевременских С–1 и С–2 снимака са алгоритмом RF могу прецизно класификовати озиме културе на локалном нивоу. GEE окружење омогућава редовно годишње или сезонско ажурирање карте усјева изузетно брзо, ефикасно и прецизно. Осим тога, GEE захваљујући сложеним функцијама које су развили GEE програмери за обраду сателитских снимака, допушта истраживачима да више енергије и времена утроше за усавршавање алгоритма класификације, а мање на процес обраде сателитских снимака.

Резултат истраживања потврдио је претходно изнесене процјене да је озима пшеница доминантна озима култура која се узгаја на подручју Лијевча поља. Аутори рада сматрају да је резултат истраживања примјењив у изради инвентара озимих усјева или неким намјенским апликацијама у којима је процјена засијаних површина под озимим културама јако битан извор информација.

Недостатак у истраживању чини релативно ограничен број тренинг података који је у одређеној мјери неуравнотежен. Ово се нарочито односи на озиме културе, тако да је у

but at the moment of reaching the maximum of the S–2 variable, it influenced the increase in the percentage of accuracy (e.g. in the third period, the maximum increase in OA from 0.85 to 0.88, Kappa increase from 0.83 to 0.87). A high level of accuracy was achieved by the method of selection and the choice of variables. By aggregating 3 composites into one data set and classifying the final data set, a significantly higher level of accuracy was achieved compared to the result of the classification of individual composites. The multi-temporal series of data significantly influenced the increase in classification accuracy (from the highest OA of the third composite 0.87, Kappa 0.85 to the OA 0.96 and Kappa 0.95).

### CONCLUSION

In the research, GEE was used to generate 3 composites that were joined in one data set and classified by the RF algorithm. The general conclusion is that by classifying multi-temporal S–1 and S–2 recordings with the RF algorithm, it is possible to accurately classify winter crops at the local level. The GEE environment enables regular annual or seasonal crop map updates extremely quickly, efficiently and accurately. In addition, GEE, thanks to the complex features developed by GEE programmers for processing satellite images, allows researchers to spend more energy and time on refining the classification algorithm, and less on the processing of satellite images.

The result of the research confirmed the previously stated estimates that winter wheat is the dominant winter crop grown in the area of Lijevče field. The authors of the paper believe that the results of the research are applicable in the creation of an inventory of winter crops or some dedicated applications in which the assessment of areas sown under winter crops is a very important source of information.

A shortcoming in the research is the relatively limited number of training data, which is somewhat unbalanced. This especially ap-



неком наредном истраживању за поузданији резултат класификације неопходно прикупити далеко већи број тренинг података што би пружило могућност већег и квалитетнијег избора адекватних тренинг података, као и података валидације. Осим тога, класификација је извођена на површински мањем (око 350 km<sup>2</sup>) и хомогеном подручју које се одликује интензивном пољопривредном производњом. Аутори сматрају да је то један од разлога који је утицао на прилично високе резултате тачности класификације.

plies to winter crops, so in some future research, for a more reliable classification result, it is necessary to collect a much larger number of training data, which would provide the possibility of a larger and better selection of adequate training data, as well as validation data. In addition, the classification was performed on a smaller (about 350 km<sup>2</sup>) and homogeneous area characterized by intensive agricultural production. The authors believe that this is one of the reasons that influenced the rather high classification accuracy results.

## ЛИТЕРАТУРА / REFERENCES

- Abubakar, G. A., Wang, K., Shahtahamssebi, A., Xue, X., Belete, M., Gudo, A. J. A., Shuka, K. A. M., & Gan, M. (2020). Mapping Maize Fields by Using Multi-Temporal Sentinel-1A and Sentinel-2A Images in Makarfi, Northern Nigeria, Africa. *Sustainability*, 12(6), 2539. <https://doi.org/10.3390/su12062539>
- Amani, M., Kakooei, M., Moghimi, A., Ghorbani, A., Ranjgar, B., Mahdavi, S., Davidson, A., Fiset, T., Rollin, P., Brisco, B., & Mohammadzadeh, A. (2020). Application of Google Earth Engine Cloud Computing Platform, Sentinel Imagery, and Neural Networks for Crop Mapping in Canada. *Remote Sensing*, 12(21), 3561. <https://doi.org/10.3390/rs12213561>
- Bajić, D., Adžić, D., & Dekić, R. (2017). GIS-Based spatial-temporal analysis of the biomass production in the Republic of Srpska territory. *Гласник/Herald*, 21, 53–69. <https://doi.org/10.7251/HER2117053B>
- Bargiel, D. (2017). A new method for crop classification combining time series of radar images and crop phenology information. *Remote Sensing of Environment*, 198, 369–383. <https://doi.org/10.1016/j.rse.2017.06.022>
- Belgiu, M., & Csillik, O. (2018). Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. *Remote Sensing of Environment*, 204, 509–523. <https://doi.org/10.1016/j.rse.2017.10.005>
- Campos-Taberner, M., Garcia-Haro, F. J., Martinez, B., Sánchez-Ruiz, S., & Gilabert, M. A. (2019). A Copernicus Sentinel-1 and Sentinel-2 Classification Framework for the 2020+ European Common Agricultural Policy: A Case Study in València (Spain). *Agronomy*, 9(9), 556. <https://doi.org/10.3390/agronomy9090556>
- Clauss, K., Ottinger, M., & Kuenzer, C. (2018). Mapping rice areas with Sentinel-1 time series and superpixel segmentation. *International Journal of Remote Sensing*, 39(5), 1399–1420. <https://doi.org/10.1080/01431161.2017.1404162>
- Conrad, C., Fritsch, S., Zeidler, J., Rücker, G., & Desch, S. (2010). Per-Field Irrigated Crop Classification in Arid Central Asisa Using SPOT and ASTER Data. *Remote Sensing*, 2(4), 1035–1056. <https://doi.org/10.3390/rs2041035>
- Denize, J., Hubert-Moy, L., Betbeder, J., Corgne, S., Baudry, J., & Pottier, E. (2019). Evaluation of Using Sentinel-1 and -2 Time-Series to Identify Winter Land Use in Agricultural Landscapes. *Remote Sensing*, 11(1), 37. <https://doi.org/10.3390/rs11010037>
- Dimitrov, P., Dong, Q., Eerens, H., Gikov, A., Filchev, L., Roumenina, E., & Jeleu, G. (2019). Sub-Pixel Crop Type Classification Using PROBA-V 100m NDVI Time Series and Reference Data from Sentinel-2 Classifications. *Remote Sensing*, 11(11), 1370. <https://doi.org/10.3390/rs11111370>
- Dobrinić, D., Medak, D., & Katanec, A. (2019). Klasifikacija zemljišnog pokrova iz podataka

- Sentinel satelitskih. *Zbornik radova – 12. simpozij ovlaštenih inženjera geodezije*, 50–55.
- Foody, G. M., & Mathur, A. (2004). Toward intelligent training of supervised image classifications: directing training data acquisition for SVM classification. *Remote Sensing of Environment*, 93(1), 107–117. <https://doi.org/10.1016/j.rse.2004.06.017>
- Gao, B. (1996). NDWI-A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58(3), 257–266. [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Hao, P., Wang, L., Niu, Z., Aablikim, A., Huang, N., Xu, S., & Chen, F. (2014). The Potential of Time Series Merged from Landsat-5 TM and HJ-1 CCD for Crop Classification: A Case Study for Bole and Manas Countries in Xinjiang, China. *Remote Sensing*, 6(8), 7610–7631. <https://doi.org/10.3390/rs6087610>
- Inglada, J., Arias, M., Tardy, B., Hagolle, O., Valero, S., Morin, D., Dedieu, G., Sepulcre, G., Bontemps, S., Defourny P., & Koetz, B. (2015). Assessment of an Operational System for Crop Type Map Production Using High Temporal and Spatial Resolution Satellite Optical Imagery. *Remote Sensing*, 7(9), 12356–12379. <https://doi.org/10.3390/rs70912356>
- Kenduiwo, B. K., Bargiel, D., & Soergel, U. (2018). Crop-type mapping from a sequence of Sentinel 1 images. *International Journal of Remote Sensing*, 39(19), 6383–6404. <https://doi.org/10.1080/01431161.2018.1460503>
- Khan, G. A., Khan, S., Zafar, N., Islam, S., Ahmad, F., Rehman, F., & Ullah, M. (2012). A Review of different Approaches of Land Cover Mapping. *Life Science Journal*, 9(4), 1023–1032.
- Kussul, N., Mykola, L., Shelestov, A., & Skakun, S. (2018). Crop inventory at regional scale in Ukraine: developing in season and end of season crop maps with multi-temporal optical and SAR satellite imagery. *European Journal of Remote Sensing*, 51(1), 627–636. <https://doi.org/10.1080/22797254.2018.1454265>
- Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33(1), 159–174. <https://doi.org/10.2307/2529310>
- Mansaray, L. R., Huang, W., Zhang, D., Huang, J., & Li, J. (2017). Mapping Rice Fields in Urban Shanghai, Southeast China, Using Sentinel-1A and Landsat 8 Datasets. *Remote Sensing*, 9(3), 257. <https://doi.org/10.3390/rs9030257>
- Marszalek, M., Lösch, M., Körner, M., & Schmidhalter, U. (2020). Multi-temporal Crop Type and Field Boundary Classification with Google Earth Engine. *Preprints*, 2020040316. <https://doi.org/10.20944/preprints202004.0316.v1>
- McNairn, H., & Brisco, B. (2004). The application of C-band polarimetric SAR for agriculture: a review. *Canadian Journal of Remote Sensing*, 30(3), 525–542. <https://doi.org/10.5589/m03-069>
- McNairn, H., Champagne, C., Shang, J., Holmstrom, D., & Reichert, G. (2009). Integration of optical and Synthetic Aperture Radar (SAR) imagery for delivering operational annual crop inventories. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(5), 434–449. <https://doi.org/10.1016/j.isprsjprs.2008.07.006>
- Миросављевић, П. (1973). *Клима Босне и Херцеговине*. Географски факултет Сарајево.
- Mullissa, A., Vollrath, A., Odongo-Braun, C., Slagter, B., Balling, J., Gou, Y., Gorelick, N., & Reiche, J. (2021). Sentinel-1 SAR Backscatter Analysis Ready Data Preparation in Google Earth Engine. *Remote Sensing*, 13(10), 1954. <https://doi.org/10.3390/rs13101954>
- Nasrallah, A., Baghdadi, N., Hajj, M. E., Darwish, T., Belhouchette, H., Faour, G., Darwich, S., & Mhawej, M. (2019). Sentinel-1 Data for Winter Wheat Phenology Monitoring and Mapping. *Remote Sensing*, 11(19), 2228. <https://doi.org/10.3390/rs11192228>

- Orynbaikyzy, A., Gessner, U., & Conrad, C. (2019). Crop type classification using a combination of optical and radar remote sensing data: a review. *International Journal of Remote Sensing*, 40(17), 6553–6595. <https://doi.org/10.1080/01431161.2019.1569791>
- Orynbaikyzy, A., Gessner, U., Mack, B., & Conrad, C. (2020). Crop Type Classification Using Fusion of Sentinel-1 and Sentinel-2 Data: Assessing the Impact of Feature Selection, Optical Data Availability, and Parcel Sizes on the Accuracies. *Remote Sensing*, 12(17), 2779. <https://doi.org/10.3390/rs12172779>
- Park, S., & Im, J. (2016). Classification of croplands through fusion of optical and SAR time series data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XXIII ISPRS Congress, XLI-B7*, 703–704. <https://doi.org/10.5194/isprs-archives-XLI-B7-703-2016>
- Palchowdhuri, Y., Valcarce-Diñeiro, R., King, P., & Sanabria-Soto, M. (2018). Classification of multi-temporal spectral indices for crop type mapping: a case study in Coalville, UK. *The Journal of Agricultural Science*, 156(1), 24–36. <https://doi.org/doi:10.1017/S0021859617000879>
- Paludo, A., Becker, W. R., Richetti, J., Silva, L. C. D. A., & 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), 1624–1636. <https://doi.org/10.1080/17538947.2020.1772893>
- Poortinga, A., Tenneson, K., Shapiro, A., Nquyen, Q., Aung, K. S., Chishtie, F., & Saah, D. (2019). Mapping Plantation in Myanmar by Fusing Landsat-8, Sentinel-2 and Sentinel-1 Data along with Systematic Error Quantification. *Remote Sensing*, 11(7), 831. <https://doi.org/10.3390/rs11070831>
- Pu, R., & Gong, P. (1998). Predicting Land-Cover Changes with Gray Systems Theory and Multitemporal Aerial Photographs. *Geographic Information Sciences*, 4(1–2), 73–79. <https://doi.org/10.1080/10824009809480506>
- Qiao, C., Daneshfar, B., Davidson, A. M., Jarvis, I., Liu, T., & Fiset, T. (2014). Integration of optical and polymetric SAR imagery for locally accurate crop classification. *2014 IEEE Geoscience and Remote Sensing Symposium*, 1485–1488. <https://doi.org/10.1109/IGARSS.2014.6946718>
- Richards, J. A., & Jia, X. (2006). *Remote Sensing Digital Image Analysis: An Introduction*. Springer Berlin, Heidelberg. <https://doi.org/10.1007/3-540-29711-1>
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1973). Monitoring Vegetation Systems in the Great Plains with ERTS. *Third Earth Resources Technology Satellite-1 Symposium*, 1(A).
- Sonobe, R., Yamaya, Y., Tani, H., Wang, X., Kobayashi, N., & Mochizuki, K. (2017). Assessing the suitability of data from Sentinel-1A and 2A for crop classification. *GIScience & Remote Sensing*, 54(6), 918–938. <https://doi.org/10.1080/15481603.2017.1351149>
- Sousa, A. M. O., Pereira, J. M. C., & Silva, J. M. N. (2003). Evaluating the performance of multitemporal image compositing algorithms for burned area analysis. *International Journal of Remote Sensing*, 24(6), 1219–1236. <https://doi.org/10.1080/01431160110114466>
- Sun, C., Bian, Y., Zhou, T., & Pan, J. (2019). Using of Multi-Source and Multi-Temporal Remote Sensing Data Improves Crop-Type Mapping in the Subtropical Agriculture Region. *Sensors*, 19(10), 2401. <https://doi.org/10.3390/s19102401>
- Sun, L., Chen, J., Guo, S., Deng, X., & Han, Y. (2020). Integration of Time Series Sentinel-1 and Sentinel-2 Imagery for Crop Type Mapping over Oasis Agricultural Areas. *Remote Sensing*, 12(1), 158. <https://doi.org/10.3390/rs12010158>
- Tassi, A., & Vizzari, M. (2020). Object-Oriented LULC Classification in Google Earth Engine Combining SNIC, GLCM, and Machine Learning Algorithms. *Remote Sensing*, 12(22), 3776. <https://doi.org/10.3390/rs12223776>
- Teluguntla, P., Thenkabail, P. S., Oliphant, A., Xiong, J., Gumma, M. K., Congalton, R. G., Yadav, K., & Huete, A. (2018). A 30-m land-

- sat-derived cropland extent product of Australia and China using random forest machine learning algorithm on Google Earth Engine cloud computing platform. *ISPRS Journal of Photogrammetry and Remote Sensing*, 144, 325–340. <https://doi.org/10.1016/j.isprsjprs.2018.07.017>
- Трбић, Г. (2004). *Лијевче поље-климатске одлике*. Географско друштво Републике Српске
- Tricht, K. V., Gobin, A., Gilliams, S., & Piccard, I. (2018). Synergistic Use of Radar Sentinel-1 and Optical Sentinel-2 Imagery for Crop Mapping: A Case Study for Belgium. *Remote Sensing*, 10(10), 1642. <https://doi.org/10.3390/rs10101642>
- Vuolo, F., Neuwirth, M., Immitzer, M., Atzberger, C., & Ng, W. T. (2018). How much does multi-temporal Sentinel-2 data improve crop type classification? *International Journal of Applied Earth Observations and Geoinformation*, 72, 122–130. <https://doi.org/10.1016/j.jag.2018.06.007>
- Wu, B., Meng, J., Li, Q., Yan, N., Du, X., & Zhang, M. (2014). Remote sensing-based global crop monitoring: experiences with China's Crop-Watch system. *International Journal of Digital Earth*, 7(2), 113–137. <https://doi.org/10.1080/17538947.2013.821185>
- Xinkai, L., Han, Z., Younglin, S., Benke, L., Changmin, J., Tianqi, L., Sayed, B. H., & Gouling, S. (2020). Large-Scale Crop Mapping From Multisource Remote Sensing Images in Google Earth Engine. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 414–427. <https://doi.org/10.1109/JSTARS.2019.2963539>
- Xu, H. (2008). A new index for delineating built-up land features in satellite imagery. *International Journal of Remote Sensing*, 29(14), 4269–4276. <https://doi.org/10.1080/01431160802039957>
- Zerrouki, N., & Bouchaffra, D. (2014). Pixel-based or Object-based: Which approach is more appropriate for remote sensing image classification? *2014 IEE Internatioanl Conference on Systems, Man, and Cybernetics (SMC)*, 864–869. <https://doi.org/10.1109/SMC.2014.6974020>
- 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, 175–185. <https://doi.org/10.1016/j.jag.2017.12.006>