



ZAJEM NEPOZIDANIH STAVBNIH ZEMLJIŠČ Z OBJEKTKO KLASIFIKACIJO PODATKOV ORTOFOTA IN AEROLASERSKEGA SKENIRANJA

DELINERATION OF VACANT BUILDING LAND USING ORTHOPHOTO AND LIDAR DATA OBJECT CLASSIFICATION

Dejan Jenko, Mojca Foški, Krištof Oštir, Žiga Kokalj

UDK: 528.7/.8+349.414:(497.4)

Klasifikacija prispevka po COBISS.SI: 1.01

Prispelo: 6. 2. 2018

Sprejeto: 29. 8. 2019

DOI: 10.15292/geodetski-vestnik.2019.03.344-378

SCIENTIFIC ARTICLE

Received: 6. 2. 2018

Accepted: 29. 8. 2019

SI | EN

IZVLEČEK

S težavami določitve lokacije in površine nepozidanih stavbnih zemljišč se srečujejo v številnih slovenskih občinah. V prispevku je obravnavana možnost določitve nepozidanih stavbnih zemljišč s samodejnim posodabljanjem podatkov. Obravnavane metode določitve nepozidanih stavbnih zemljišč temeljijo na sloju pokrovnosti zemljišč, ki ga pridobivamo z objektno klasifikacijo podatkov aerolaserskega skeniranja (ALS) in ortofota. Nepozidana stavbna zemljišča ugotavljamo z obdelavo in čiščenjem podatkov v okolju geografskih informacijskih sistemov. Metodo smo preizkusili na izbranih območjih v občini Trebnje. Sloj nepozidanih stavbnih zemljišč, pridobljen s samodejnimi zajemom, smo primerjali s podatki, pridobljenimi z vizualno interpretacijo (ročnim zajemom). Ugotovili smo, da lahko s predstavljenim metodologijo samodejnega zajema nepozidanih stavbnih zemljišč pospešimo in pocenimo ročni zajem podatkov ter predvsem posodabljanje podatkov, ne moremo pa ga še popolnoma nadomestiti.

ABSTRACT

Exact data about the location and area of vacant building land have been a major issue in several Slovene municipalities. This article deals with automatic vacant building land delineation. The presented methodology is based on the object-based classification that derives the land cover layer from orthophoto and laser scanning data. With post-processing and data cleaning in GIS, we create the vacant building land layer. The methodology was tested in study areas in the Municipality of Trebnje. The results were compared to the vacant building land layer generated by visual interpretation (manual vectorisation). We found that the presented methodology of automatic delineation of vacant buildings can speed up the processing and lower the cost of manual vectorisation and, in particular, data updating but we cannot completely replace manual work.

KLJUČNE BESEDE

objektna klasifikacija, prostorsko načrtovanje, nepozidana stavbna zemljišča, ortofoto, lidar, aerolasersko skeniranje

KEY WORDS

object based classification, spatial planning, vacant building land, orthophoto, airborne lidar

1 INTRODUCTION

Sustainable spatial development is a commitment stemming from European (CEMAT, 2000) and international documents (Agenda for Sustainable Development until 2030, 2016), the Spatial Development Strategy of Slovenia (SPRS, 2004), and the Spatial Planning Act 2 (ZUreP-2, 2017). In the latter, sustainable spatial development is defined as development providing for the needs of current and future generations, taking into account the objectives of spatial planning in a way to allow for rational and efficient land use and the use of buildings, and coordinated arrangement of activities in space (Article 6 of ZUreP-2, 2017). Following the strategic spatial guidelines, spatial planning is embodied in implementing planning acts, i.e. on building plots intended for construction (Article 3 of ZUreP-2, 2017). Building land can be built-up (ground occupied by buildings) or vacant (Article 142 of ZUreP-2, 2017). Vacant building land, i.e. land where construction may take place, is relevant for spatial development. The act provides for built-up and vacant land to be entered in the Building Land Registry, meaning that this information should be acquired and serve as a basis for spatial analyses, spatial documents, and the planning of fitting-out of space and land policy measures. Currently there is no appropriate record of built-up and vacant land in Slovenia (Medved and Berk, 2019), while the municipalities that need this information the most have addressed this issue in various ways. This is being tackled through mass collection of data on inhabited land and the actual use of inhabited land (Masovni zajem ..., 2017), which was started in 2017. Now, 24% of all built-up plots in Slovenia has been recorded (Medved and Berk, 2019) and according to the work programme all land across Slovenia should be logged by the end of 2020. The website http://storitve.pis.gov.si/pis-jv/evidenca_stavbnih_zemljisc.html provides access to all recorded data for Prekmurje, south-east Slovenia, and the municipalities of Piran and Izola.

Data are acquired (Masovni zajem ..., 2017) by photointerpretation, which is supported by other data sources. The acquisition and maintenance (updating) of spatial data using the visual photointerpretation method is a demanding task, financially unfavourable, and time-consuming (Kos and Šumrada, 2013; Mesner, 2016).

Remote sensing procedures are used to ensure that the data are being updated. Object-oriented analysis is often used to identify the changes in the Earth's surface, land management, and planning (Kanjir, 2009; Mesner, 2016). The breakthrough of object-oriented analysis is attributed to the development of satellite systems reaching a spatial resolution better than 1 m (Veljanovski et al., 2011). The data acquired are useful in geographic information systems (GIS), in general and, also for the needs of spatial planning.

Object-based classification is a procedure where pixels with similar characteristics are combined into segments. In the semantic classification procedure, the segments are, based on their attributes, classified into semantic classes (Liu and Xia, 2010; Veljanovski et al., 2011). As underlined by Liu and Xia (2010), Blaschke (2010), and Yanjing (2015), segmentation should be given special attention during object-based classification. A well-designed segmentation maintains the right relationship between the size of the segments and the size of the structures on the ground, so that the segments are neither too fragmented nor too big (Kanjir, 2009; Blaschke, 2010). The segmentation and semantic classification phases are followed by post-classification, which corrects obvious errors and allows for generalisation of the results (Kokalj and Oštir, 2006; Veljanovski et al., 2011).

Many authors, from Slovenia as well, have addressed the collection of data on the land cover using object-based classification procedures. Kanjir (2009) obtained land cover based on orthophoto imagery, Grigillo (2009) and Grigillo et al. (2011) detected changes in buildings, automatically captured data on new buildings, and thus updated the topographic layer of buildings based on the digital terrain model and the orthophoto data. Švab Lenarčič (2009) and Švab Lenarčič and Oštir (2015) classified land cover based on orthophoto imagery and an airborne laser scanning (ALS) point cloud. By introducing the standard deviation of height, calculated based on laser scanning points, they qualitatively differentiated between buildings and trees, and compared the building mask with the mask created using manual delineation. Land cover delineation based on object-based classification, using orthophotos and ALS data, has also been used by Yanjing (2015) and Yongmin et al. (2011), who found that simultaneous use of orthophotos and airborne laser scanning allows for better results than the use of orthophotos or point clouds of laser scanning only. Triglav Čekada et al. (2018) used the method of automatic identification of changes to identify changes in land cover of agricultural land to speed up the procedures for the needs of recording the actual use of agricultural and forest land. Veljanovski and Kokalj (2016) successfully determined land cover from historical aerial images for the case of Breginj. Mesner (2016) studied the possibility of automatic updating of the building cadastre layer, actual land use, and land cover based on orthophotos and drew up the conclusion that automatic recognition procedures reached a level allowing for detection of changes and updating of layers, paired with the supervision of the operator.

This paper examines the problems related to determining vacant building land. Up-to-date information on vacant building land is the basic condition for implementing development activities of local communities, thus providing support to spatial planning (Article 252, ZUreP-2, 2017). The described methods of determining built-up and vacant building plots are based on the procedure of object-based classification of remote sensing data and the processing in a geographic information system. Land cover is determined in the first stage of using the orthophoto imagery and the ALS cloud point. Along with the municipal spatial plan, the land cover layer is used to determine vacant building land, which is then refined using selected criteria. The automatically obtained layer of vacant building land was compared to the layer obtained using visual interpretation, where we found that automatic delineation, along with the operator's visual checking (and any possible corrections) can significantly speed up, and lower the costs of, data acquisition and maintenance, rather than completely replace the manual delineation.

2 WORKING METHODS

2.1 Data and study area

Land cover determination is based on orthophoto and infrared orthophoto data, both in a spatial resolution of 0.5 m. The photos covering the study area were captured in May 2014 (GURS, 2016). We also used an ALS point cloud with a density of five points per square kilometre (ARSO, 2016). These layers are the source data for object-based classification. For the needs of analysis in a GIS environment and vacant building land delineation, we used the land cadastre depiction (GURS, 2016) and the layer of the Municipality of Trebnje's Municipal Spatial Plan (OPN občine Trebnje, 2013).

We analysed three study areas in the Municipality of Trebnje, which differ as to the type of settlement.

The first area (Figure 1) includes part of the built-up area of Trebnje with the old town centre with central and service activities, old apartment buildings, and railway. On the northern outskirts of the town, there are mostly single-dwelling family houses, and in the north-eastern part there is a business zone. The second area is the aggregated rural settlement Veliki Gaber (Figure 2), with residential, agricultural, and simple structures, clustered along the main thoroughfare, surrounded by agricultural land. The third area includes the settlement of Liseč, which is a typical winegrowing area with a distinctly dispersed settlement typology and a diverse relief (Figure 3).



Figure 1: Study area Trebnje
(GURS, 2016).



Figure 2: Study area Veliki Gaber
(GURS, 2016).



Figure 3: Study area Liseč
(GURS, 2016).

Data analysis and object-based classification were done using ENVI 5.3, ENVI LiDAR 5.3, and LAStools 2017 software. Further processing and determination of vacant building land were done in ArcGIS 10.3 (ESRI). Geometric analyses of land cover in individual plots were done using a Python script, while the results are recorded in the SQLite database.

2.2 Determination of land cover and vacant building land

The first step is to generate a land cover layer. Before the object-based classification, the source data (described in chapter 2.1 Data and research area) were used to produce the digital terrain model (DTM) and digital surface model (DSM) of a resolution of 0.5 m. In the 0.5-m resolution raster grid we calculated the standard deviation in height, which was used to distinguish between buildings and trees. By subtraction of DSM and DTM layers, we calculated the normalised digital surface model (nDMS), which gives the heights of structures above the ground and allows for recognition of bridges, which are, based solely on the standard deviation in height, incorrectly classified in the class of buildings.

Based on the rules, land cover for six classes was determined in ENVI using object-based classification: grassland, cropland, urban and built-up land, buildings, forest, and water. The first step of the classification is segmentation, where an iterative approach for parameter optimisation was used. We used an edge-based segmentation algorithm, yielding the best results according to the visual analysis. The segmentation was done in all three colour channels in the visible spectrum and the IR channel of the orthophotos. The classification rules were then developed. We mostly analysed spectral and textural attributes, and by using the selected statistics of attributes we determined the limit values of the classification classes. The object-based classification was done for each area with the predefined set of rules. As a result, we

obtained a land cover layer in the raster format which we converted into the vector format and then joined the adjacent polygons of the same classification class.

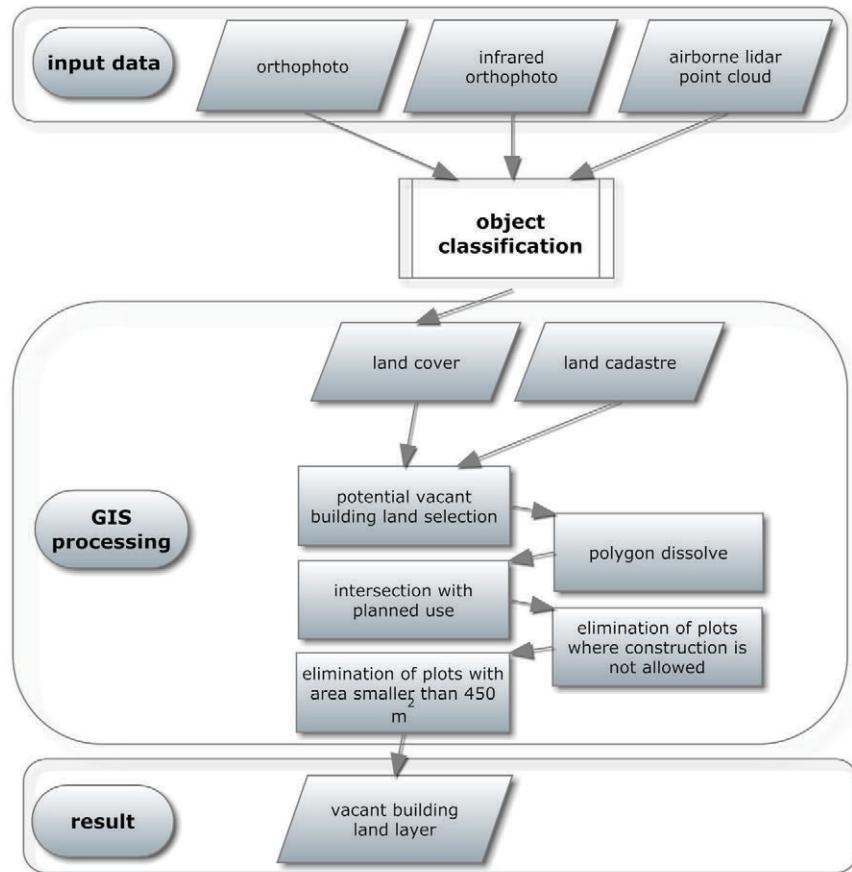


Figure 4: Working method chart

Land cover was assigned to the land plots based on the intersection of the land cover layer and the land cadastre depiction layer. We exported the data table of the intersection layer, which provides input to the Python script used to analyse each plot. Based on the land cover classes we determined the shares of built-up land (class of buildings), paved surfaces (share of urban and built-up land) and vacant land (classes: grassland, cropland, and forest). After reviewing the results, we determined that a potentially vacant building plot makes up an area whose land cover is comprised of buildings or built-up land to less than 10%. By considering this criterion we selected the potentially vacant plots, combined the adjacent polygons, and intersected them with the municipal spatial plan. We excluded the plots where construction, in line with the Municipal Spatial Plan, is not permitted (other zoned land use: residential areas, areas of central activities, production activities, and special areas). In the last step we excluded vacant building plots with a surface less than 450 m², which equals the smallest surface of a building plot for residential construction (OPN občine Trebnje, 2013). This exclusion criterion was used in all types of zoned land use. The data processing procedure is shown in the diagram (Figure 4).

2.3 Quality control

Quality control was done in both layers – the land cover layer and the vacant building land layer.

2.3.1 Land cover layer control

The land cover layer quality was estimated using the method of visual interpretation of random segments. The segments were selected using stratified sampling, where in each class we selected 50 random segments. The exception is the class water, where all segments were classified. We assessed the following accuracy measures: the confusion matrix, total accuracy, kappa coefficient, manufacturer's accuracy, and user's accuracy.

The confusion matrix is a cross-tabulation of the benchmark data against the classification results. The confusion matrix is used to calculate various statistics for estimating accuracy. The total accuracy means the relationship between correctly classified segments and all control segments and expresses the percentage of classification accuracy. The kappa coefficient is the statistical measure of a classification's precision. It is based on the comparison of the studied and random classification and can capture the values at an interval [0,1]. The value of coefficient 0.5 means that the classification used allowed for 50% better results than a random classification (Kanjir, 2009; Veljanovski et al., 2011). The kappa coefficient is calculated as (Lillesand in sod., 2004):

$$\kappa = \frac{N \sum_{n=1}^r x_{nn} - \sum_{n=1}^r (x_{n+} \cdot x_{+n})}{N^2 - \sum_{n=1}^r (x_{n+} \cdot x_{+n})} \quad (1)$$

where r is the number of rows in the confusion matrix, N is the number of all pixels in the matrix, x_{nn} is the sum of the diagonal of the confusion matrix, x_{n+} is the sum of the values of the n -th row, x_{+n} is the sum of the values of the n -th column.

The relationship between correctly classified segments related to the benchmarks expresses the manufacturer's accuracy:

$$NP = \frac{n_{prav.}}{n_{ref.}} \quad (2)$$

The reliability of the results is assessed given of their accuracy for the user, i.e. the relationship of correctly classified segments as regards the total number of segments in a class (Oštir, 2006):

$$NU = \frac{n_{prav.}}{n_{seg.}} \quad (3)$$

These are statistical estimations, where the first one describes the percentage of correctly classified segments of a class relative to the benchmark data, while the other is a measure of reliability and expresses the percentage of correctly classified segments that match the actual situation.

2.3.2 Quality control of the vacant building land layer

The layer of vacant building land acquired using automatic delineation was visually checked, and we tried to detect obvious errors. This layer was then intersected with the layer of vacant building land acquired using the photointerpretation method.

The vacant building land layer, acquired using the photointerpretation method, was based on the data of orthophoto imagery captured in 2014, the land cadastre, and the real-estate registry. Because of this we can assume the semantic conformity of both layers of vacant building land. The criteria for delineating vacant building land using photointerpretation were the plot's surface area, shape, and vacancy (i.e. the lack of a building). The congruence of both layers of vacant building land was compared using an intersection of the layers and the calculation of the balance of vacant land.

3 RESULTS AND ANALYSIS

Figures 5–10 show the results of determining land cover and the vacant building land layer for all three selected study areas (Trebnje, Veliki Gaber, and Liseč). The visual checking of the land cover in Trebnje (Figure 5) does not reveal any obvious errors, except for an elongated plot at the north-eastern brink of the settlement, which is classified as a built-up area, while according to its shape we conclude that it is cropland. This is confirmed by Figure 6 where it is evident that the parcel is in fact cropland.

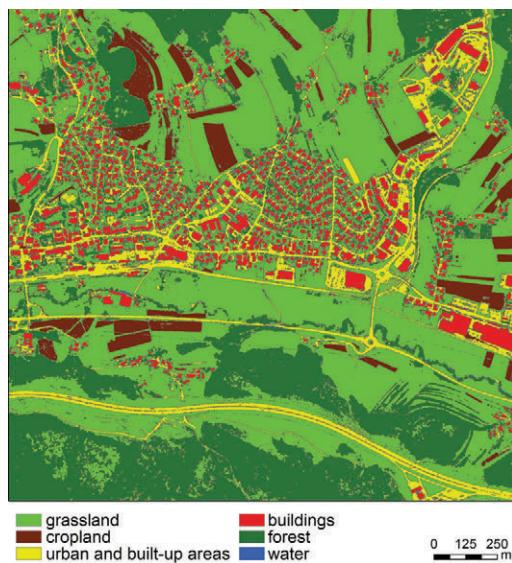


Figure 5: Land cover – study area Trebnje.

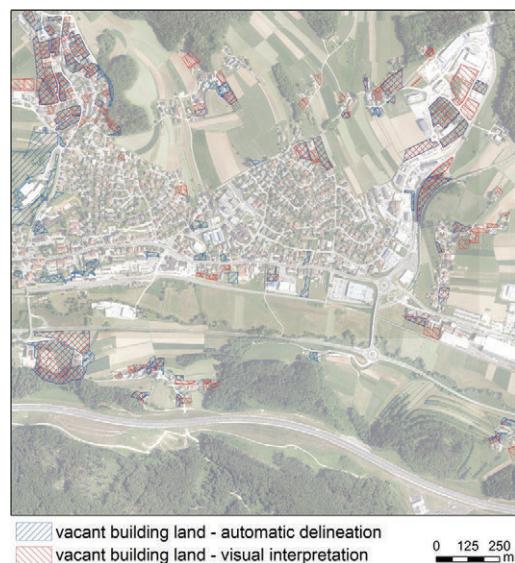


Figure 6: Vacant building land – study area Trebnje.

There are some potential errors in Figure 7, which shows the results of land cover identification in study area Veliki Gaber. These are mainly incorrect classifications of cropland, classified instead as urban and built-up land (several plots in western and north-western parts of the settlement).

Land cover of study area Liseč (Figure 9) is mostly represented by forest, while no major or obvious errors were detected during the review.

The land cover layer quality control is shown in Table 1. The land cover layer shows high overall accuracy of the first study area (Trebnje), which is 90.8% and can be characterised according to Oštrir (2006) as good. The quality assessment of the classification was done using the kappa coefficient, i.e. 88.8%, which means that the given classification reached 88.8% better results than if a random classification had been

used. A comparable accuracy was also reached in study area Lisec (with a total accuracy of 88.4%, and the kappa index of 85.6%). The lowest accuracy was achieved in study area Veliki Gaber, which with a total accuracy of 82.0% managed to get a satisfactory grade (Oštir, 2006).

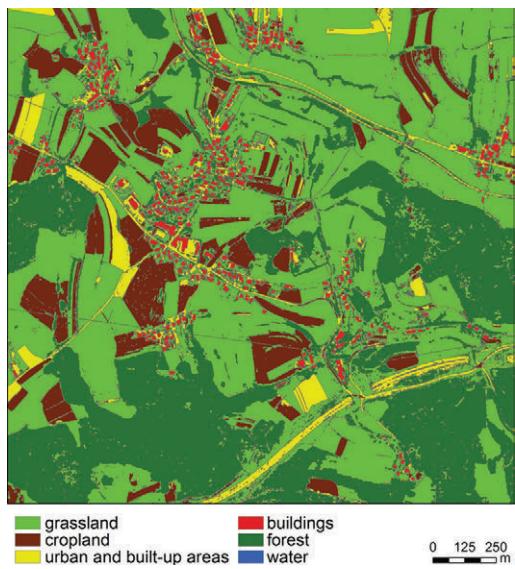


Figure 7: Land cover – study area Veliki Gaber.

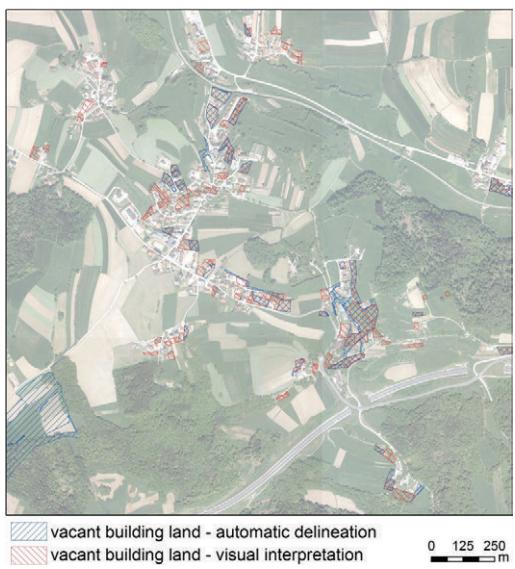


Figure 8: Vacant building land – study area Veliki Gaber.

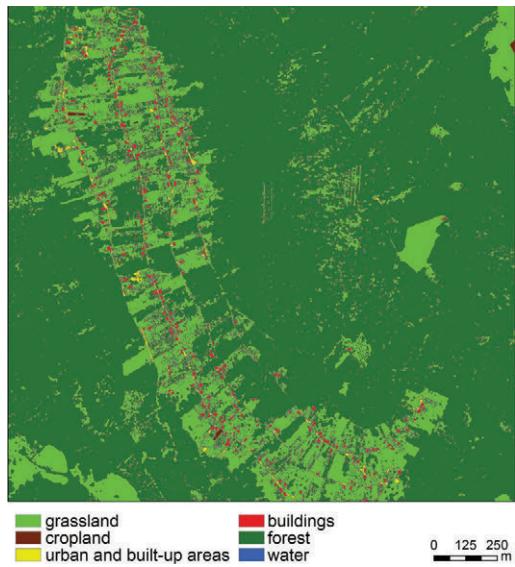


Figure 9: Land cover – study area Lisec.

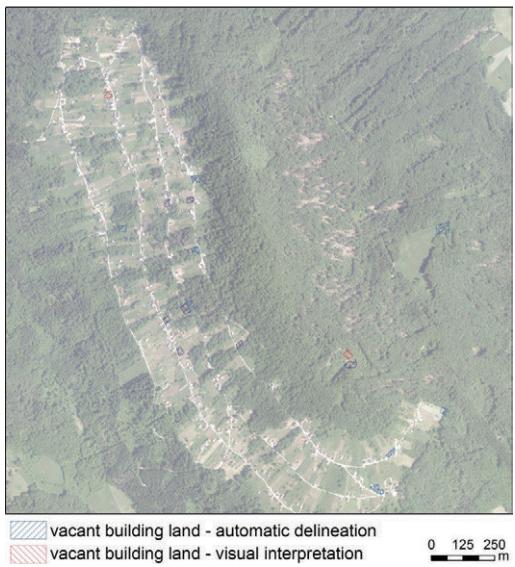


Figure 10 Vacant building land – study area Lisec.

Table 1: Quality control of the classification results

	Study area		
	Trebnje	Veliki Gaber	Lisec
Benchmark points	272	250	250
Correctly classified points	247	205	221
Overall accuracy (%)	90.8	82.0	88.4
Kappa	0.888	0.761	0.856

Tables 2, 3, and 4 show the confusion matrix of all three study areas by land cover classes. The classification of buildings and trees is of high quality, which is the consequence of classification using airborne laser scanning. The standard deviation in height proved to be a reliable parameter, based on which we could distinguish, with a high degree of fidelity, between the classes of buildings and trees. There are practically no errors in these classes. In the study area of Trebnje we identified two cases of incorrect classification of buildings and three cases of incorrect classification of forests (i.e. 20% of all incorrect classifications). Four cases of the described incorrect classifications (two classifications of buildings in the class of forests and two classifications of forests in the class of buildings) showed that the distinction based on the standard deviation is not completely reliable. Such cases occur particularly at the edges of roofs. There some laser beams are reflected off the ground and some off the roof, which is expressed in a higher standard deviation in height and, as a consequence, an incorrect classification. Similar results of classification quality of these two classes were achieved also in study areas Veliki Gaber and Lisec. The most errors in classifications of the class of buildings are detected in study area Lisec with six cases (21% of total incorrect classifications).

In terms of the distribution of incorrect classifications of the rest of the land cover classes, the closest are study areas Trebnje and Lisec, where in each classification class there are on average five incorrect classifications. The class of roads in study area Lisec also exhibits negative results, where there are as many as 12 incorrect classifications as well as several incorrect classifications in the class of buildings (five classifications as forest).

The worst accuracy in classification was found in study area Veliki Gaber, which in terms of classification into classes of forest and buildings does not stand out from the other two study areas, but there are significantly more errors in the classification into grassland, cropland, and roads. Some of the incorrect classifications of cropland into the class of grassland, and vice versa, (a total of six cases) are the result of overgrown cropland. In such cases even two independent operators would visually interpret the information differently and assign different classifications, which is also recognised in the delineation of actual land use in agricultural and forest land; data are therefore checked using the four-eyes principles (i.e. by two operators) (Mesner et al., 2018).

Based on the confusion matrix, the manufacturer's and user's accuracy is estimated (Tables 5, 6 and 7). In the study area of Trebnje the worst reliability was achieved in the classes of grassland (87.3%) and roads (78.2%). The class of buildings reached high reliability, i.e. 98%, while the reliability of the class forest was only by 0.1% lower. The classes of buildings and forest in study area Veliki Gaber achieved comparable results to those in study area Trebnje. Considerably lower results were achieved in the classes

of grassland and cropland (the former only 67.8% and the latter 75.5%), while the reliability of the class of roads is comparable to the reliability of this class in study area Trebnje.

Table 2: Confusion matrix – study area Trebnje

Class	1	2	3	4	5	6	Total classified
1 Travniki	48	3	3		1	1	56
2 Grassland		43	3				46
3 Cropland	2	3	43			3	51
4 Urban and built-up areas			1	48	2		51
5 Buildings		1		2	47		50
6 Forest						18	18
Total – benchmark	Water	50	50	50	50	22	272

Table 3: Confusion matrix – study area Veliki Gaber

Class	1	2	3	4	5	6	Total classified
1 Grassland	40	10	9				59
2 Cropland	5	37	7				49
3 Urban and built-up areas	5	3	34		1		43
4 Buildings				48	3		51
5 Forest				2	46		48
6 Water						0	0
Total – benchmark	50	50	50	50	50	0	250

Table 4: Confusion matrix – study area Liseč

Class	1	2	3	4	5	6	Total classified
1 Grassland	45	3	2				50
2 Cropland	1	42	7		1		51
3 Urban and built-up areas	3	2	41				46
4 Buildings				45	1		46
5 Forest	1	3		5	48		57
6 Water						0	0
Total – benchmark	50	50	50	50	50	0	0

The results of the study area Liseč are, according to the overall accuracy, i.e. 88.4%, comparable to the results in study area Trebnje. In Table 5 we can observe three incorrect classifications, where cropland is classified as forest. This mostly involves cases of vineyards where because of the vines the standard deviation in height is higher, and the area is classified in the class of forests.

Regarding the reliability of the result obtained, the class of buildings stands out, as it achieved the worst reliability in the Veliki Gaber study area (94.1%). Similar results were achieved in the class of forests, while considerable differences are noticed in study area Liseč, where the reliability of the class is 84.2%. This was mostly the consequence of five cases of incorrect classification of buildings and three cases of incorrect classification of cropland segments. The class of roads in all three study areas reached comparable reliability with a range of only 2.7% (the highest and lowest values are 78.2% and 75.5%, respectively).

Table 5: Manufacturer's and user's accuracy – study area Trebnje

Class	Benchmark points	Classified points	Correctly classified points	Manufacturer's accuracy (%)	User's accuracy (%)
Grassland	50	56	48	96.0	87.3
Cropland	50	46	43	86.0	91.5
Urban and built-up areas	50	51	43	86.0	78.2
Buildings	50	51	48	96.0	98.0
Forest	50	50	47	94.0	97.9
Water	22	18	18	81.8	100.0
Total	272	272	247		

Table 6: Manufacturer's and user's accuracy – study area Veliki Gaber

Class	Benchmark points	Classified points	Correctly classified points	Manufacturer's accuracy (%)	User's accuracy (%)
Grassland	50	59	40	80.0	67.8
Cropland	50	49	37	74.0	75.5
Urban and built-up areas	50	43	34	68.0	79.1
Buildings	50	51	48	96.0	94.1
Forest	50	48	46	92.0	95.8
Water	0	0	0	N/A	N/A
Total	250	250	205		

Table 7: Manufacturer's and user's accuracy – study area Liseč

Class	Benchmark points	Classified points	Correctly classified points	Manufacturer's accuracy (%)	User's accuracy (%)
Grassland	50	50	45	90	90
Cropland	50	51	42	84	77.8
Urban and built-up areas	50	46	41	82	89.1
Buildings	50	46	45	90	97.8
Forest	50	57	48	96	84.2
Water	0	0	0	N/A	N/A
Total	250	250	221		

Comparison of automatic delineation of vacant building land and the delineation using the photointerpretation method is shown in Figures 6, 8, and 10. We observe that in study area Trebnje (Figure 6) the polygons of vacant building land agree well; we also draw attention to a large area of vacant building land in NW part of Trebnje, which is specified in Figure 11 (left section above). The figure shows in more detail the area south of the Ljubljana–Zagreb regional road (section right above) and part of vacant building land in an industrial zone (section left below). In this section, we notice an obvious divergence in the layers of automatic and manual capture of vacant building land – this case is analysed in detail below.

Some coinciding cases of vacant building land were identified in the study area Veliki Gaber (Figure 8). A more detailed illustration of the selected sections of both layers of vacant building land is shown in Figure 12. The section left above shows the overlapping of the layers in the NW part of the study area,

while the right section above shows the area in the central part of Veliki Gaber and the right section below the area in the SE part of Veliki Gaber. We did not prepare more detailed sections for study area Liseč, as there are not many vacant building plots; the comparison of both layers of vacant building land is shown in Figure 10.

Table 8: Comparison of vacant building land using visual interpretation and automatic delineation, respectively.

	Visual interpretation [ha]	Automatic delineation [ha]	Share (%)
Study area Trebnje	181.3	123.2	68.0
Study area Veliki Gaber	95.1	50.3	52.9
Study area Liseč	5.3	3.6	68.0

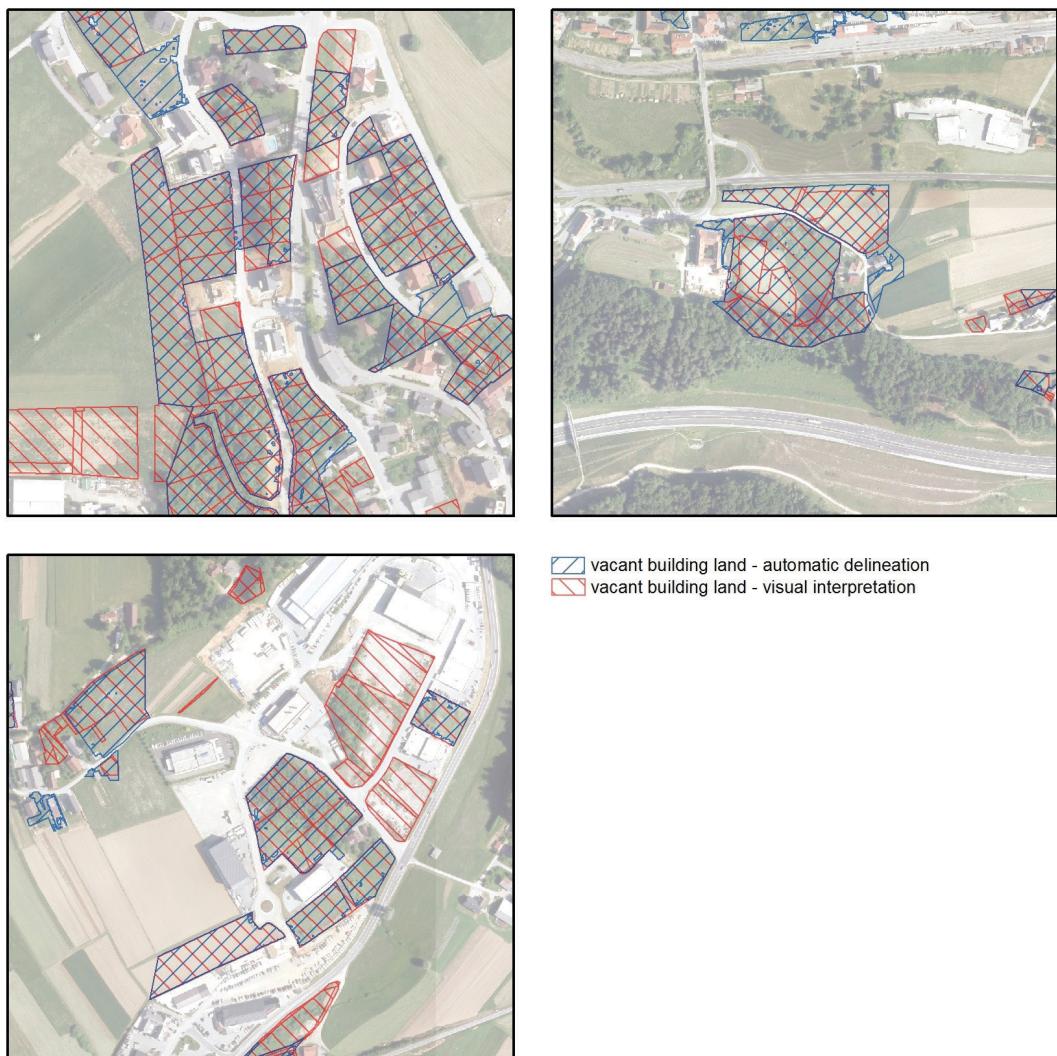


Figure 11: Detailed sections of vacant building land with the results of automatic delineation and photointerpretation – study area Trebnje.



Figure 12: Detailed sections of vacant building land with the results of automatic delineation and photointerpretation – study area Veliki Gaber.

Using the photointerpretation method, in study area Trebnje 181.2 ha of vacant building land was identified, of which 123.2 ha was successfully identified using automatic delineation (Table 8). An identical result was obtained in the study area Lisec, where there are very few vacant building plots. The worst result was achieved in the Veliki Gaber study area.

Table 9 contains data on the balance of vacant building land, broken down into classes of detailed zoned land use from the Municipal Spatial Plan of Trebnje (OPN občine Trebnje, 2013). We see that in study areas Trebnje and Veliki Gaber most vacant building land is in residential areas, while major surfaces of vacant building land are also in areas of production activities. By taking into account the shares of identified vacant building land in relation to detailed zoned land use, we see that there are no significant

deviations in the quality of identification. In most cases, an identification accuracy over 50% was achieved. The actual share of correctly identified vacant building land in study areas of Trebnje and Lisec was 68% and in the study area Veliki Gaber a 52.9% accuracy was achieved (Table 9).

These shares of correctly identified vacant building land are not surprising. In study areas of Trebnje and Lisec, where land cover was determined with high accuracy (i.e. 90%), in 68% of cases the vacant building land layer was congruent with the manual delineation. In study area Veliki Gaber, where the correctness of the land cover layer was lower, this is indirectly reflected in the lower share of correctly recognised vacant building land.

Table 9: The balance of areas of vacant building land related to detailed zone land use from the Municipality of Trebnje's Municipal Spatial Plan (2013)

		Dispersed settlement areas (A)	Special areas (B)	Areas of central activities (C)	Areas of production activities (I)	Residential areas (S)
Study area Trebnje	visual interpretation [ha]	N/A	32,1	N/A	48,1	101,0
	automatic delineation [ha]	N/A	31,9	N/A	27,0	64,3
	share (%)	N/A	99	N/A	56	64
Study area Veliki Gaber	visual interpretation [ha]	1,1	N/A	2,8	N/A	91,3
	automatic delineation [ha]	0,5	N/A	1,4	N/A	48,5
	share (%)	45	N/A	50	N/A	53
Study area Lisec	visual interpretation [ha]	3,9	N/A	N/A	N/A	1,4
	automatic delineation [ha]	3,1	N/A	N/A	N/A	0,5
	share (%)	80	N/A	N/A	N/A	36

4 DISCUSSION

The presented methodology for identifying vacant building land has provided, despite some irregularities, some promising and useful results.

The discrepancies between both methods of delineating vacant building plots occur particularly where vacant building plots are of a conditionally suitable shape (e.g. narrow and elongated plots), which however in terms of their surface satisfy the criterion for their classification under vacant building land (450 m² for the Municipality of Trebnje). An operator who would delineate vacant building land, based on photointerpretation would not classify plots of inadequate shape as land suitable for construction. In automatic delineation of vacant building land the algorithm did not check the shape of building plots, but only their surface area, which caused discrepancies between the two delineations. Error elimination in such cases is in the next step left to the operator; nevertheless the algorithm could be upgraded to identify the appropriate plot shape.

Another kind of incongruence is the result of limitations of the algorithm of automatic recognition of vacant building plots due to their classification in the wrong land cover class. Land cover of the central part of the industrial zone in the NE part of the Trebnje study area (left section above on Figure 13) is a paved surface (macadam parking area or a handling area). Using the object-based classification, the

area was (mostly) correctly classified in the class of built-up land (section left below in Figure 13), which directly caused that the area was not identified during the automatic delineation of vacant building land. In the manual delineation, the area was identified as vacant building land (Figure 6 – plots in the NE part of the figure).

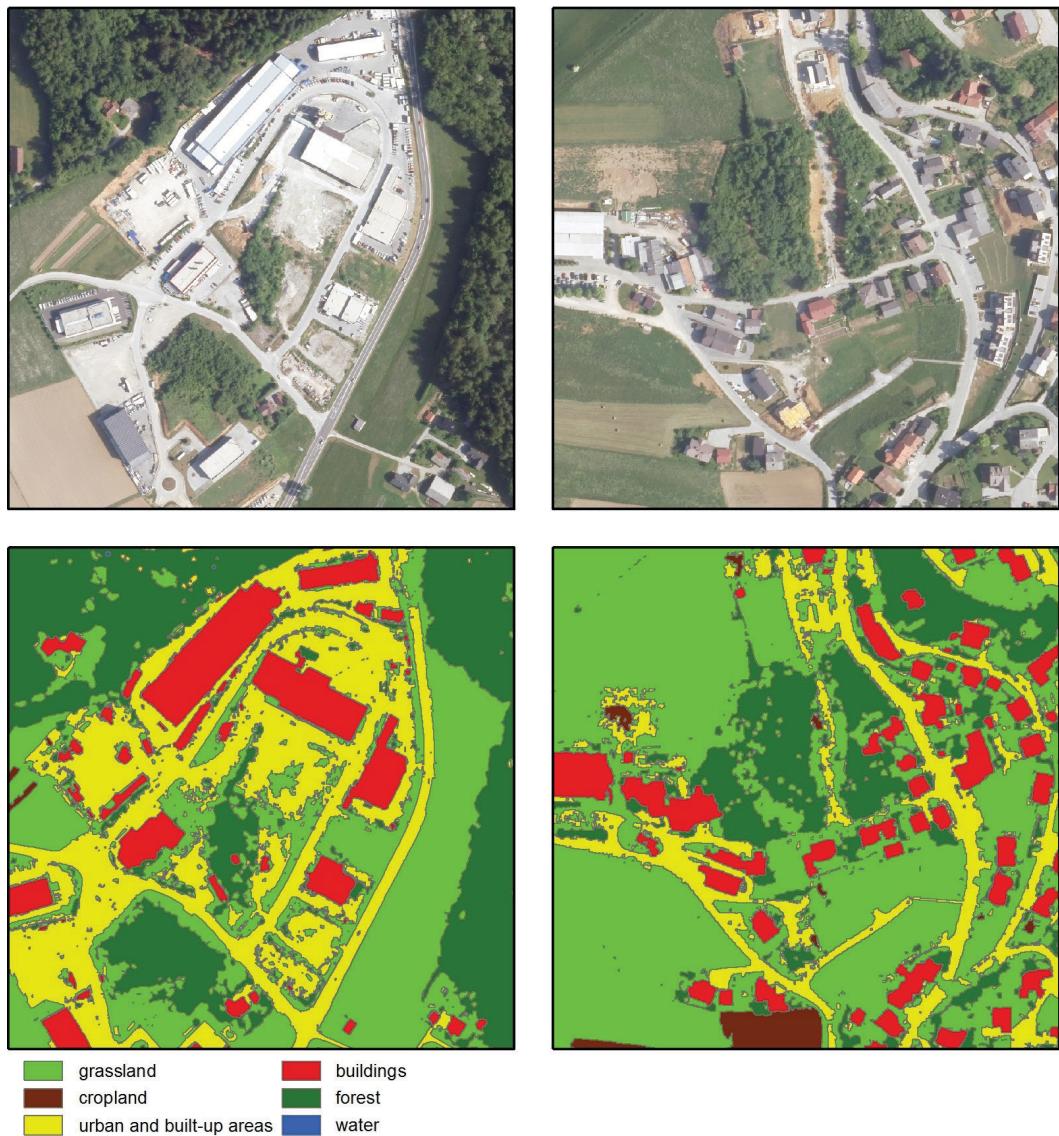


Figure 13: Detailed orthophoto and land cover sections – study area Trebnje.

Let us also underline the case at the westernmost border of the Trebnje study area (Figure 5), which is shown in more detail in the right section above in Figure 13. This is not due to an error in the procedure of identifying vacant building land, but rather due to an error in the object-based classification procedure. In the object-based classification procedure, abandoned cropland was classified either as built-up

land, cropland, or grassland (right section below in Figure 13). In the further processing we found that the share of built-up land makes up more than 10% of the total surface of the plot and falls under the exclusion criterion, i.e. the reason why the plot was not identified as vacant building land. The deviation of both layers of vacant building land, in this case, is shown in Figure 6 (see the plots along the western edge of the image).

5 CONCLUSIONS

The setting-up and maintenance of vacant building land layers in municipalities is still manual, based on photointerpretation and using orthophoto imagery, the real-estate registry, the land cadastre, current spatial documents, and other auxiliary layers. Such a procedure is used also in the mass collection of data on inhabited areas and the actual use of inhabited land (Masovni zajem..., 2017), which is time and financially consuming.

This paper deals with the development of a methodological approach to automatic identification of vacant building land, which is based on the object-based classification procedure using the ALS point cloud, orthophoto and infrared orthophoto images, and the later processing in GIS. In the first step we obtain the vector layer of land cover, which is used through the combined application of the municipal spatial plan and the land cadastre depiction to determine vacant building plots. This approach made it possible to identify as much as 68% vacant building land in study areas Trebnje and Liseč delineated manually, while there were 52% of such plots in study area Veliki Gaber.

The object-based classification procedures per se do not cause problems and are developed enough for such an application, as evidenced by the quality of the classification. The highest reliability of the classification is obtained by the classes of buildings and forest, while grassland was classified with somewhat lower reliability. Most problems occur in the classification into the classes of roads and cropland. This does not come as a surprise, as both roads and cropland have very diverse spectral signatures and are frequently shaded or partially covered by tree canopies, which makes the identification more difficult.

The quality of determining vacant building land directly depends on the quality of land cover determination. In the study area Trebnje, the land cover layer with 90.8% of correctly classified segments was certainly of better quality for further use. Something similar can be said for study area Liseč, while in study area Veliki Gaber most errors in identifying vacant building plots are attributed to the lower quality of determining the land cover layer. The procedure of determining vacant building land based on the intersection of the layers of land cover and the municipal spatial plan is plot-oriented – for each plot the shares of built-up or vacant land are calculated. The criterion for distinguishing between built-up and vacant plots was determined experientially and should be determined in more detail in the future. According to the diversity of settlement in Slovenia, the criteria would probably vary among the municipalities and also depend of the individual settlements.

With narrow and elongated vacant building plots and other irregular shapes, the automatic procedure has been found to be unreliable. In such cases the assessment by an expert classifier is necessary, and further research should be directed toward developing reliable classification rules, which are the basic condition for good results. In this study we did not address the development of criteria and geometric rules for plot shapes, which could be used to exclude plots of inadequate shapes, such as narrow or elongated

vacant building plots; nevertheless attempts have been made to define the shapes of plots in agricultural land (Foški, 2017; Foški, 2019).

The presented methodology does not attain reliability high enough to be able to exclude the critical review of an operator. The visual checking of the results is not intended to eliminate errors of the automatic procedure but rather to allow for critical professional assessment of various cases. Similar conclusions were drawn by Čekada et al. (2018) who find that with automatic delineation in a two-stage procedure, where in the first stage the data of automatic acquisition are prepared and in the second stage the operator checks and critically assesses the data, the visual photointerpretation procedures are considerably accelerated along with achieving a comparable level of data quality.

The described method was used both in the first vacant building land delineation and during the later updating of the layer. The upgrading of the layer is possible with new input data (orthophotos, infrared orthophotos, airborne laser scanning point clouds, and spatial planning documents), coupled with the visual inspection of the results and error corrections. The advantages of automatic over manual delineation are related to time and financial savings and, conditionally, in the objectiveness of the acquisition.

It would therefore, be reasonable to test the methodology in a greater test area and in an area where mass collection of data on inhabited areas and the actual use of inhabited land had already been done. Based on the findings, it would be necessary to think about how to include automatic identification of changes in building land into the maintenance of the emerging data layer. We believe that in the future the shares of manual delineation and visual interpretation of remote sensing images will reduce and will be complemented with automatic classification.

Acknowledgements

This research work was done as part of basic research projects J2-9251: M3Sat – Methodology of Multitemporal Multisensor Satellite Image Analysis and J6-9395: High-resolution drought monitoring based on satellite and ground data, and research programme P2-0406: Earth Observation and Geoinformatics, funded by the Slovenian Research Agency (ARRS) from the national budget.

Literature and references:

- Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65, 2–16. DOI: <https://doi.org/10.1016/j.isprsjprs.2009.06.004>
- Agenda za trajnostni razvoj do leta 2030 (2016). Združeni narodi. http://www.srvk.gov.si/si/delovna_področja/razvojno_nacrtovanje/slovenija_in_agenda_2030, accessed 10.June 019.
- ARSO (2016). Podatkovna zbirka laserskega skeniranja. Ljubljana: Ministrstvo za okolje in prostor, Agencija Republike Slovenije za okolje.
- CEMAT (2000). Vodilna načela za trajnostni prostorski razvoj evropske celine. Evropska svet. Ljubljana: Ministrstvo za okolje in prostor.
- Foški, M. (2017). Določanje parcelnih vzorcev in analiza njihovega spremenjanja v slovenskem podeželskem prostoru. Doktorska disertacija. Ljubljana: Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo.
- Foški, M. (2019). Using the parcel shape index to determine arable land division types. *Acta Geographica Slovenica*, 59 (1), 83–101. DOI: <https://doi.org/10.3986/AGS.4574>
- Grigillo, D. (2009). Samodejno odkrivanje stavb na visokoločljivostnih slikovnih virih za potrebe vzdrževanja topografskih podatkov. Doktorska disertacija. Ljubljana: Univerza v Ljubljana, Fakulteta za gradbeništvo in geodezijo.
- Grigillo, D., Kosmatin Fras, M., Petrovič, D. (2011). Samodejen zajem in iskanje sprememb v topografskem sloju stavb iz digitalnega modela površja in multispektralnega ortofota. *Geodetski vestnik*, 55 (1), 11–27. DOI: <http://dx.doi.org/10.15292/geodetski-vestnik.2011.01.011-027>
- GURS (2016). Podatkovna zbirka zemljiškokastrskega prikaza. Ljubljana: Ministrstvo za okolje in prostor, Geodetska uprava Republike Slovenije.
- Kanjir, U. (2009). Objektna klasifikacija rabe tal iz podatkov daljinskega zaznavanja.

- Diplomska naloga. Ljubljana: Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo.
- Kokalj, Ž., Oščir, K. (2006). Ugotavljanje pokrovnosti Slovenije iz satelitskih posnetkov Landsat. Geografski vestnik, 78 (2), 85–95.
- Kos, M., Šumrada, R. (2013). Primera izvajanja direktive INSPIRE in izvedbe sistema metapodatkov v Sloveniji in Švici. Geodetski vestnik, 57 (1), 25–45. DOI: <http://www.geodetski-vestnik.com/en/11-clanki-doi/142-gv57-1-kos>, accessed 10 June 2019.
- Lillesand, T. M., Kiefer, R. W., Chipman, J. W. (2004). Remote Sensing and Image Interpretation. 5. izdaja. New York: John Wiley and Sons, Inc.
- Liu, D., in Xia, F. (2010). Assessing object-based classification: advantages and limitations. *Remote Sensing Letters*, 1 (4), 187–194. DOI: <http://dx.doi.org/10.1080/01431161003743173>
- Masovni zajem poseljenih zemljišč in dejanske rabe poseljenih zemljišč (2017). Tehnična dokumentacija. Ljubljana: Ministrstvo za okolje in prostor, Geodetska uprava Republike Slovenije.
- Medved, K., Berk, S. (2019). Množični zajem podatkov in vzpostavitev evidence stavbnih zemljišč. Geodetski vestnik, 63 (2), 287.
- Mesner, N. (2016). Analiza možnosti uporabe samodejne klasifikacije podobe za vzdrževanje prostorskih podatkovnih zbirk. Magistrska naloga. Ljubljana: Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo.
- Mesner, N., Mangačić, A., Tič, K., Valjanovski, T., Kanjir, U., Đurić, N., Foški, M., Triglav Čekada, M. (2018). Rezultati projekta: Samodejni postopki identifikacije sprememb dejanske rabe kmetijskih zemljišč. Geodetski vestnik, 62 (3), 501–509. http://www.geodetski-vestnik.com/62/3/gv62-3_mesner.pdf, accessed 10 June 2019.
- OPN Občine Trebnje. (2013). Odlok o občinskem prostorskem načrtu Občine Trebnje, Uradni list RS, št. 50/2013.
- Oščir, K. (2006). Daljinsko zaznavanje. Ljubljana: ZRC SAZU, Inštitut za antropološke in prostorske študije.
- SPRS (2004). Strategija prostorskega razvoja Slovenije. Ljubljana: Ministrstvo za okolje in prostor.
- Švab Lenarčič, A. (2009). Uporaba lidarskih podatkov za klasifikacijo pokrovnosti. Magistrska naloga. Ljubljana: Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo.
- Švab Lenarčič, A., Oščir, K. (2015). Uporaba lidarskih podatkov za klasifikacijo pokrovnosti. Ljubljana: ZRC SAZU, Inštitut za antropološke in prostorske študije.
- Triglav Čekada, M., Mesner, N., Tič, K., Brč, V., Meža, S., Radovan, D., Mangačić, A., Valjanovski, T., Kanjir, U., Pehani, P., Kokalj, Ž., Oščir, K., Foški, M., Zavodnik Lamovšek, A. (2018). CRPV2-1620: Samodejni postopki identifikacije sprememb dejanske rabe kmetijskih zemljišč. Zaključno poročilo. Ljubljana: Geodetski inštitut Slovenije. <http://www.gis.si/en/predstavitev/projektov/v2-1620>, accessed 10 June 2019.
- Veljanovski, T., Kanjir, U., Oščir, K. (2011). Objektno usmerjena analiza podatkov daljinskega zaznavanja. Geodetski vestnik, 55 (4), 641–664. DOI: <https://doi.org/10.15292/geodetski-vestnik.2011.04.641-664>
- Veljanovski, T., Kokalj, Ž. (2016). Slikovna retrospektiva porušenega Breginja in analiza pokrajinskih sprememb. http://www.sdtj.si/wp/wp-content/uploads/2016/09/JTDH-2016_Veljanovski-Kokalj_Slikovna-retrospektiva-porusenega-Breginja.pdf, accessed 1 July 2019.
- Yanjing, J. (2015). Object-based Land Cover Classification with Orthophoto and LIDAR data. Master of Science Thesis in Geoinformatics. Stockholm: School of Architecture and Built Environment. Royal Institute of Technology (KTH).
- Yongmin, K., Youkyung, H., Younggi, B., Jaewan, C., Dongyeob, H., Yongil, K. (2011). Object-based classification of an urban area through a combination of aerial image and airborne lidar data. ASPRS 2011 Annual Conference, Milwaukee, Wisconsin.
- ZUreP-2 (2017). Zakon o urejanju prostora 2. Uradni list RS, št. 61/2017.

Jenko D., Foški M., Oščir K., Kokalj Ž. (2019). Delineation of vacant building land using orthophoto and LIDAR data object classification. Geodetski vestnik, 63 (3), 344–378.
DOI: <https://doi.org/10.15292/geodetski-vestnik.2019.03.344-378>

ZAJEM NEPOZIDANIH STAVBNIH ZEMLJIŠČ Z OBJEKTNOM KLASIFIKACIJO PODATKOV ORTOFOTA IN AEROLASERSKEGA SKENIRANJA

OSNOVNE INFORMACIJE O ČLANKU:

GLEJ STRAN 344

1 UVOD

Trajnostni prostorski razvoj je zaveza, ki izhaja iz evropskih (CEMAT, 2000) in svetovnih dokumentov (Agenda za trajnostni razvoj do leta 2030, 2016), pa tudi iz Strategije prostorskega razvoja Slovenije (SPRS, 2004) in Zakona o urejanju prostora 2 (ZUreP-2, 2017). Slednji ga opredeljuje kot razvoj, ki ob upoštevanju ciljev urejanja prostora omogoča zadovoljevanje potreb sedanjih in prihodnjih generacij, in to tako, da zagotavljamo racionalno in učinkovito rabo zemljišč in objektov in usklajeno razmestitev dejavnosti v prostoru (6. člen ZUreP-2, 2017). Prostorski razvoj se na podlagi strateških prostorskih usmeritev udejanja v izvedbenih planskih aktih, in to na stavbnih zemljiščih, ki so namenjena graditvi objektov (3. člen ZUreP-2, 2017). Stavbna zemljišča so lahko pozidana zemljišča (na katerih so že objekti) in nepozidana zemljišča (142. člen ZUreP-2, 2017). Za razvoj prostora so pomembna nepozidana stavbna zemljišča, na katerih se lahko izvaja gradnja. Z zakonom je predvideno, da se pozidana in nepozidana zemljišča vodijo v evidenci stavbnih zemljišč, kar pomeni, da je treba tovrstne podatke pridobiti in na njihovi podlagi pripraviti analize stanja prostora, prostorske akte ter tudi načrtovanje opremljanja prostora in ukrepe zemljiške politike. V Sloveniji zdaj ni ustrezne evidence pozidanih in nepozidanih zemljišč (Medved in Berk, 2019), občine, ki bi te podatke najbolj potrebovale, pa so težavo reševali na različne načine. To se poskuša odpraviti v okviru množičnega (masovnega) zajema poseljenih zemljišč in dejanske rabe poseljenih zemljišč (Masovni zajem ..., 2017), ki se je začel v letu 2017. Tako je zajetih 24 % vseh pozidanih zemljišč v Sloveniji (Medved in Berk, 2019), v skladu s programom dela pa bi bila zajeta vsa zemljišča za celotno Slovenijo do konca leta 2020. Na spletni strani http://storitve.pis.gov.si/pis-jv/evidencia_stavbnih_zemljisc.html so dostopni zajeti podatki za Prekmurje, jugovzhodno Slovenijo ter občini Piran in Izolo.

Zajem podatkov (Masovni zajem ..., 2017) se izvaja z metodo fotointerpretacije ob podpori drugih virov podatkov. Zajem in vzdrževanje (posodabljanje) prostorskih podatkov z metodo vizualne fotointerpretacije je zahtevno opravilo, finančno neugodno in časovno potratno (Kos in Šumrada, 2013; Mesner, 2016).

S postopki daljinskega zaznavanja lahko izboljšamo predvsem ažurnost prostorskih podatkov. Objektno usmerjeno analizo pogosto uporabimo za ugotavljanje sprememb površja Zemlje, upravljanje zemljišč in načrtovanje (Kanjir, 2009; Mesner, 2016). Preboj postopkov objektno usmerjene analize gre pripisati

tudi razvoju satelitskih sistemov, ki dosegajo prostorsko ločljivost, boljšo od enega metra (Veljanovski in sod., 2011). Pridobljeni podatki so uporabni v geografskih informacijskih sistemih (GIS) tudi za potrebe prostorskega načrtovanja.

Objektna klasifikacija je postopek, pri katerem so piksi s podobnimi lastnostmi združeni v segmente. Segmenti so v postopku semantične klasifikacije na podlagi atributov razvrščeni v pomenske razrede (Liu in Xia, 2010; Veljanovski in sod., 2011). Kot izpostavljajo Liu in Xia (2010), Blaschke (2010) in Yanjing (2015), je posebno pozornost pri izvajanju objektne klasifikacije treba nameniti segmentaciji. Z dobro segmentacijo se ohrani pravo razmerje med velikostjo segmentov in velikostjo objektov v naravi, torej segmenti niso ne preveč razdrobljeni ne preveliki (Kanjir, 2009; Blaschke, 2010). Fazama segmentacije in semantične klasifikacije sledi še poklasifikacija, s katero odpravljamo očitnejše napake in posplošimo rezultate (Kokalj in Oštir, 2006; Veljanovski in sod., 2011).

Z zajemom pokrovnosti tal s postopki objektne klasifikacije so se, tudi v Sloveniji, ukvarjali številni avtorji. Kanjur (2009) je zajela pokrovnost tal na podlagi ortofota, Grigillo (2009) ter Grigillo in sod. (2011) so odkrivali spremembe stavb in samodejno zajeli nove stavbe ter tako posodobili topografski sloj stavb na podlagi podatkov digitalnega modela reliefsa in ortofota. Švab Lenarčič (2009) ter Švab Lenarčič in Oštir (2015) sta na podlagi ortofota in oblaka točk aerolaserskega skeniranja (ALS) klasificirala pokrovnost tal. Z uvedbo standardnega odklona višine, izračunanega na podlagi točk laserskega skeniranja, sta kakovostno ločila stavbe in drevesa, masko stavb pa primerjala z masko, ustvarjeno z ročnim zajemom. Z zajemom pokrovnosti tal na podlagi objektne klasifikacije ob uporabi ortofota in podatkov ALS so se ukvarjali tudi Yanjing (2015) ter Yongmin in sod. (2011), ki so ugotovili, da souporaba ortofota in podatkov aerolaserskega skeniranja zagotovi boljše rezultate kot uporaba zgolj ortofota ali oblaka točk laserskega skeniranja. Triglav Čekada s sod. (2018) je z metodo samodejne identifikacije sprememb ugotavljal spremembe pokrovnosti na kmetijskih zemljišč z namenom pospešitve postopkov za potrebe evidence dejanske rabe kmetijskih in gozdnih zemljišč. Veljanovski in Kokalj (2016) sta uspešno določila pokrovnost tal iz zgodovinskih letalskih posnetkov na primeru Breginja. Mesner (2016) je preučila možnosti samodejnega posodabljanja sloja katastra stavb, dejanske rabe in pokrovnosti tal na podlagi ortofota ter prišla do ugotovitve, da so postopki samodejnega prepoznavanja dosegli raven, ki omogoča zaznavanje sprememb in posodabljanje slojev ob nadzoru operaterja.

V prispevku je obravnavana problematika določitve nepozidanih stavbnih zemljišč. Ažurni podatki o nepozidanih stavbnih zemljiščih so osnovni pogoj za izvajanje razvojnih dejavnosti lokalnih skupnosti in so podpora prostorskemu načrtovanju (252. člen ZUreP-2, 2017). Opisane metode določitve pozidanih in nepozidanih stavbnih zemljišč temeljijo na postopku objektne klasifikacije podatkov daljinskega zaznavanja in obdelavi v geografskem informacijskem sistemu. V prvi fazi ob uporabi ortofota in oblaka točk ALS določimo pokrovnost tal. Sloj pokrovnosti skupaj z občinskim prostorskim načrtom uporabimo za določitev nepozidanih stavbnih zemljišč, ki jih v nadaljevanju prečistimo z izbranimi kriteriji. Samodejno pridobljen sloj nepozidanih stavbnih zemljišč smo primerjali s slojem, pridobljenim z vizualno interpretacijo, in ugotovili, da je mogoče s samodejnim zajemom ob vizualni kontroli operaterja (in njegovih morebitnih popravkih) bistveno pospešiti in poceniti zajem in vzdrževanje podatkov, ne more pa še v celoti nadomestiti ročnega zajema.

2 METODE DELA

2.1 Podatki in območje raziskave

Določitev pokrovnosti temelji na podatkih ortofota in infrardečega ortofota, obeh v prostorski ločljivosti 0,5 metra. Listi, ki pokrivajo območje raziskave, so bili zajeti v maju 2014 (GURS, 2016). Uporabili smo tudi oblak točk ALS z gostoto pet točk na kvadratni meter (ARSO, 2016). Našteti sloji so izvorni podatki za objektno klasifikacijo. Za potrebe analize v okolju GIS in določitve nepozidanih stavbnih zemljišč smo v nadaljevanju uporabili tudi zemljiškokatastrski prikaz (GURS, 2016) in sloj občinskega prostorskoga načrta občine Trebnje (OPN občine Trebnje, 2013).

Analizirali smo tri testna območja v občini Trebnje, ki se medsebojno razlikujejo po načinu poselitve. Prvo območje (slika 1) vključuje del strnjenega naselja Trebnje s starim mestnim jedrom, kjer so centralne in storitvene dejavnosti, starejši večstanovanjski objekti ter železnica. Na severnem obrobju naselja stojijo v večini enostanovanske družinske hiše, na severovzhodnem delu pa je gospodarska cona. Drugo območje vključuje strnjeno podeželsko naselje Veliki Gaber (slika 2), s stanovanjskimi, kmetijskimi in enostavnimi objekti, zgoščenimi ob glavni prometnici, in kmetijskimi zemljišči v okolini. Tretje območje vključuje naselje Liseč, ki je tipično vinogradniško območje z izrazito razpršeno tipologijo poselitve ter razgibanim reliefom (slika 3).



Slika 1: Testno območje Trebnje (GURS, 2016).



Slika 2: Tesno območje Veliki Gaber (GURS, 2016).

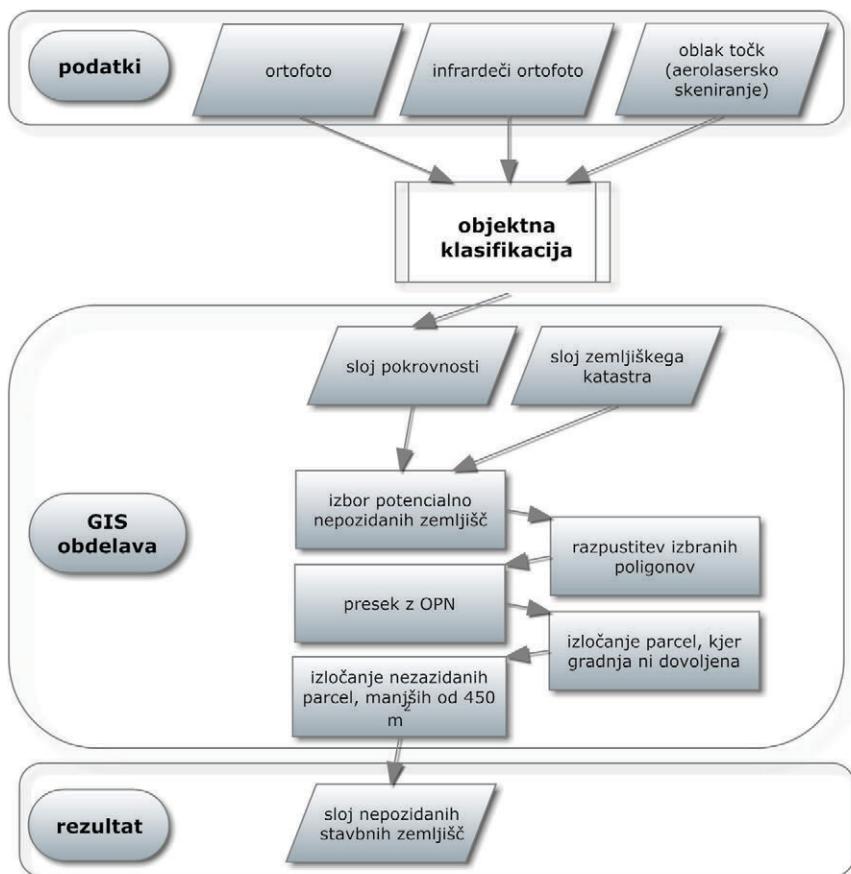


Slika 3: Testno območje Liseč (GURS, 2016).

Analiza podatkov in objektna klasifikacija sta bili izvedeni v programih ENVI 5.3, ENVI LiDAR 5.3 in LAStools 2017. Nadaljnja obdelava in določitev nepozidanih stavbnih zemljišč je bila izvedena v ArcGISu 10.3 (ESRI). Geometrične analize pokrovnosti posameznih parcel so bile izvedene s skripto Python, rezultati pa zapisani v podatkovno zbirkovo SQLite.

2.2 Določitev pokrovnosti tal in nepozidanih stavbnih zemljišč

Prvi korak obdelave je generiranje sloja pokrovnosti tal. Pred objektno klasifikacijo smo iz izvornih podatkov (opisani v poglavju *2.1 Podatki in območje raziskave*) izdelali sloja digitalnega modela reljefa (DMR) in digitalnega modela površja (DMP) ločljivosti 0,5 metra. V rastrski mreži ločljivosti pol metra smo izračunali standardni odklon višine, ki je bil uporabljen za ločevanje stavb in dreves. Z matematičnim odstevanjem sloja DMP in DMR smo izračunali normirani digitalni model površja (nDMP), v katerem



Slika 4: Diagram metode dela.

V ENVIju smo z objektno klasifikacijo na podlagi pravil določili pokrovnost tal za šest razredov: travniki, obdelovalna zemljišča, utrjene površine, stavbe, gozd in vode. Prvi korak klasifikacije je segmentacija, ki je bila izvedena iterativno, da smo določili optimalne parametre. Uporabljen je bil segmentacijski algoritem na podlagi robov (angl. *edge based*), s katerim so bili glede na vizualno analizo doseženi najboljši rezultati. Segmentacija je bila izvedena na vseh treh vidnih barvnih kanalih in IR-kanalu ortofota. Sledilo je oblikovanje klasifikacijskih pravil. Analizirali smo predvsem spektralne in teksturne atribute ter z uporabo izbranih statistik atributov določili mejne vrednosti razredov klasifikacije. Za vsako območje smo z nastavljenimi pravili izvedli postopek objektne klasifikacije. Kot rezultat smo dobili sloj pokrovnosti tal v rastrskem formatu, ki smo ga pretvorili v vektorski zapis in združili stične poligone istega klasifikacijskega razreda.

S presekom sloja pokrovnosti tal in sloja zemljiškokatastrskega prikaza smo zemljiškim parcelam pripisali pokrovnost. Izvozili smo podatkovno tabelo presečnega sloja, ki je vhodni podatek skripte v Pythonu, s katero smo analizirali vsako parcelo. Na podlagi razredov pokrovnosti smo določili delež pozidane

površine (razred stavb), delež utrjene površine (razred utrjenih površin) in delež nepozidane površine (razredi: travniki, obdelovalna zemljišča in gozd). S pregledom rezultatov smo določili, da je potencialno nepozidano stavbno zemljišče tisto, katerega pokrovnost v manj kot 10 % predstavljajo stavbe ali utrjene površine. Z upoštevanjem tega merila smo izbrali potencialno nepozidana zemljišča, združili stične poligone in jih presekali z občinskim prostorskim načrtom (OPN). Izločili smo parcele, na katerih v skladu z OPN ni dovoljena gradnja. Ostala so območja z namensko rabo stanovanj, območja centralnih dejavnosti, območja proizvodnih dejavnosti in posebna območja. V zadnjem koraku smo izločili nepozidana zemljišča s površino, manjšo od 450 m², kar ustreza najmanjši površini gradbene parcele za stanovanjsko stavbo (OPN občine Trebnje, 2013). Izločitveni kriterij je bil uporabljen pri vseh tipih namenske rabe. Postopek obdelave podatkov je prikazan na diagramu (slika 4).

2.3 Kontrola kakovosti

Kontrolo kakovosti smo opravili na obeh izdelanih slojih – na sloju pokrovnosti tal in sloju nepozidanih stavbnih zemljišč.

2.3.1 Kontrola kakovosti sloja pokrovnosti tal

Kakovost sloja pokrovnosti tal smo ocenili z metodo vizualne interpretacije naključnih segmentov. Segmente smo izbrali s stratificiranim vzorčenjem, pri čemer smo v vsakem razredu izbrali 50 naključnih segmentov. Izbema je le razred vode, kjer smo klasificirali vse segmente. Ocenjevali smo naslednje mere natančnosti: matriko napak, skupno natančnost, koeficient Kappa, natančnost proizvajalca in natančnost uporabnika.

Matrika napak je navzkrižna tabela, ki odraža razmerja med referenčnimi podatki in rezultati klasifikacije. Z matriko napak izračunamo različne statistike, s katerimi ocenjujemo natančnost. Skupna natančnost pomeni razmerje pravilno razvrščenih segmentov v primerjavi z vsemi kontrolnimi segmenti in odraža odstotek pravilnosti klasifikacije. Koeficient Kappa je statistični kazalnik natančnosti klasifikacije. Temelji na primerjavi preučevane in naključne klasifikacije in lahko zajame vrednosti na intervalu [0,1]. Vrednost koeficiente 0,5 odraža, da je uporabljeni klasifikacija zagotovila za 50 % boljše rezultate kot naključna klasifikacija (Kanjir, 2009; Veljanovski in sod., 2011). Koeficient Kappa izračunamo (Lillesand in sod., 2004):

$$\kappa = \frac{N \sum_{n=1}^r x_{nn} - \sum_{n=1}^r (x_{n+} \cdot x_{+n})}{N^2 - \sum_{n=1}^r (x_{n+} \cdot x_{+n})} \quad (1)$$

kjer je r število vrstic v matriki napak, N število vseh piksov v matriki, x_{nn} vsota diagonale matrike napak, x_{n+} vsota vrednosti n-te vrstice, x_{+n} vsota vrednosti n-tega stolpca.

Razmerje med pravilno razvrščenimi segmenti glede na referenčne pove natančnost proizvajalca:

$$NP = \frac{n_{prav.}}{n_{ref.}} \quad (2)$$

Oceno zanesljivosti dobljenega rezultata ocenjujemo z natančnostjo za uporabnika, ki pomeni razmerje pravilno razvrščenih segmentov glede na skupno število segmentov v razredu (Oštir, 2006):

$$NU = \frac{n_{prav.}}{n_{seg.}} \quad (3)$$

To sta statistični oceni, pri čemer prva opisuje odstotek pravilno razvrščenih segmentov posameznega razreda glede na referenčne podatke, druga pa je merilo zanesljivosti in izkazuje odstotek pravilno razvrščenih segmentov, ki sovpadajo z dejanskim stanjem.

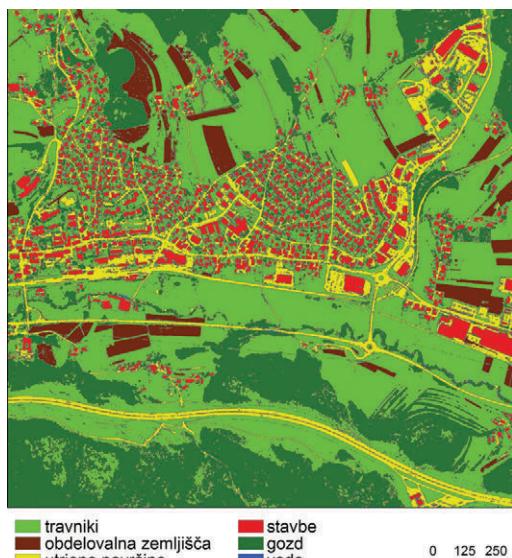
2.3.2 Kontrola kakovosti sloja nepozidanih stavbnih zemljišč

Sloj nepozidanih stavbnih zemljišč, pridobljen s samodejnim zajemom, smo vizualno pregledali in poskušali odkriti očitnejše napake. Sledil je presek sloja s slojem nepozidanih stavbnih zemljišč, pridobljenim z metodo fotointerpretacije.

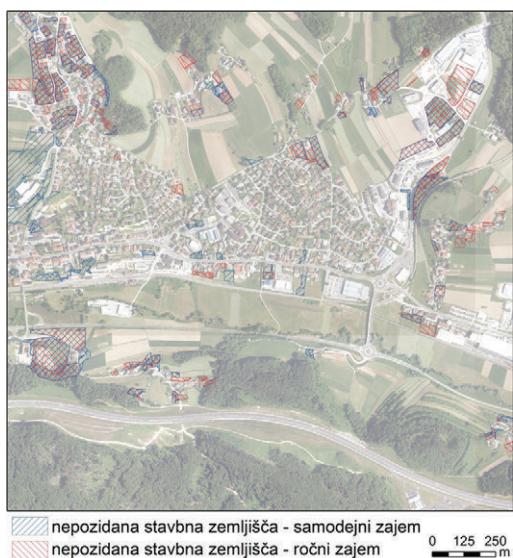
Sloj nepozidanih stavbnih zemljišč, pridobljen z metodo fotointerpretacije, je temeljil na podatkih ortofoto posnetkov, zajetih v letu 2014, zemljiškega katastra in registra nepremičnin. Zaradi našteteve lahko predpostavljamo pomensko skladnost obeh slojev nepozidanih stavbnih zemljišč. Kriteriji za zajem nepozidanih stavbnih zemljišč z metodo fotointerpretacije so bili površina parcele, oblika parcele in nepozidanost (torej da objekt tam še ne stoji). Skladnost obeh slojev nepozidanih stavbnih zemljišč smo preverjali s presekom slojev ter izračunom bilance nepozidanih površin.

3 REZULTATI IN ANALIZA

Slike 5–10 prikazujejo rezultate določitve pokrovnosti tal in sloja nepozidanih stavbnih zemljišč za vsa tri izbrana testna območja (Trebnje, Veliki Gaber in Liseč). Vizualni pregled pokrovnosti tal Trebnjega (slika 5) ne razkrije očitnih napak, izstopa podolgovata parcela na severovzhodnem robu naselja, ki je razvrščena v razred utrjenih površin, glede na njeno obliko pa lahko sklepamo, da gre za obdelovalno površino. Navedeno potrdimo s sliko 6, kjer opazimo, da je parcela v naravi obdelovalna površina.



Slika 5: Pokrovnost tal – testno območje Trebnje.



Slika 6: Nepozidana stavbna zemljišča – testno območje Trebnje.



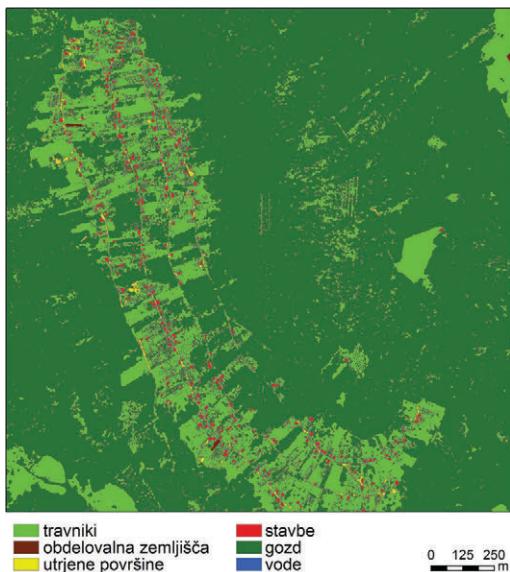
Slika 7: Pokrovnost tal zemljišča – testno območje Veliki Gaber.



Slika 8: Nepozidana stavbna zemljišča – testno območje Veliki Gaber.

Na sliki 7, ki prikazuje rezultate določitve pokrovnosti tal testnega območja Veliki Gaber, opazimo kar nekaj potencialnih napak. Praviloma gre za napačne klasifikacije obdelovalnih površin, ki so klasificirane kot utrjene površine (več parcel na zahodnem in severozahodnem delu naselja).

Pokrovnost tal testnega območja Liseč (slika 9) v večini predstavlja gozd, večjih oziroma očitnejših napak ob pregledu ne opazimo.



Slika 9: Pokrovnost tal zemljišča – testno območje Liseč.



Slika 10: Nepozidana stavbna zemljišča – testno območje Liseč.

Kontrola kakovosti sloja pokrovnosti tal je prikazana v preglednici 1. Sloj pokrovnosti izkazuje visoko skupno natančnost prvega testnega območja (Trebnje), ki znaša 90,8 % in jo lahko po Oštirju (2006) označimo za dobro. Oceno kakovosti klasifikacije smo izvedli tudi s koeficientom Kappa, ki znaša 88,8 %, kar pomeni, da je obravnavana klasifikacija dosegla 88,8 % boljše rezultate, kot bi jih dosegli z naključno klasifikacijo. Primerljivo natančnost smo dosegli tudi na testnem območju Liseč (skupna natančnost znaša 88,4 %, indeks Kappa pa 85,6 %). Najnižja natančnost je bila dosežena na testnem območju Veliki Gaber, ki je s skupno natančnostjo 82,0 % še ujela oceno zadovoljivo (Oštir, 2006).

Preglednica 1: Kontrola kakovosti rezultatov klasifikacije

	Testno območje		
	Trebnje	Veliki Gaber	Liseč
Referenčne točke	272	250	250
Pravilno klasificirane točke	247	205	221
Skupna natančnost (%)	90,8	82,0	88,4
Kappa	0,888	0,761	0,856

Preglednice 2, 3 in 4 prikazujejo matrike napak vseh treh testnih območij po razredih pokrovnosti. Klasifikacija stavb in dreves doseže visoko kakovost, kar je posledica razvrščanja s podatki aerolaserskega skeniranja. Standardni odklon višine se je izkazal za zanesljiv parameter, na podlagi katerega smo z visoko kakovostjo ločili med klasifikacijskima razredoma stavb in dreves. Pri navedenih razredih napak tako rekoč ni. Na testnem območju Trebnjega opazimo dva primera napačne klasifikacije stavb in tri primere napačne klasifikacije gozda (kar pomeni 20 % vseh napačnih klasifikacij). Štirje primeri opisanih napačnih klasifikacij (dve klasifikaciji stavb v razred gozda in dve klasifikaciji gozda v razred stavb) so pokazali, da tudi ločevanje na podlagi standardnega odklona ni popolnoma zanesljivo. Tovrstni primeri se pojavljajo predvsem na robovih streh. Tam se pogosto nekaj laserskih žarkov odbije od tal in nekaj od strehe, kar se odraži na višjem standardnem odklonu višine in posledično napačni klasifikaciji. Podobni rezultati kakovosti klasifikacije navedenih dveh razredov so bili doseženi tudi na testnih območjih Veliki Gaber in Liseč. Največ napačnih klasifikacij razreda stavb opazimo na testnem območju Liseč, kjer je takšnih primerov šest (21 % vseh napačnih klasifikacij).

Po razporeditvi napačnih klasifikacij preostalih razredov pokrovnosti sta si najbližje testni območji Trebnje in Liseč, kjer je v vsakem klasifikacijskem razredu povprečno po pet napačnih klasifikacij. V negativni smeri odstopa razred cest v testnem območju Liseč, kjer je napačnih klasifikacij kar dvanaest, več pa je tudi napačnih klasifikacij razreda stavb (najdemo pet primerov napačne klasifikacije v razred gozda).

Najslabša natančnost klasifikacije je bila dosežena na testnem območju Veliki Gaber, ki sicer pri klasifikaciji v razreda gozd in stavba ne odstopa od preostalih dveh testnih območij, opazimo pa občutno več napak pri klasifikaciji v razrede travnikov, obdelovalnih površin in cest. Nekaj napačnih klasifikacij obdelovalnih površin v razred travnik in nasprotno (takšnih primerov je skupno šest) je posledica zaraščanja obdelovalne površine. V tovrstnih primerih bi pogosto tudi dva neodvisna operaterja različno vizualno interpretirala podatke in območeje različno klasificirala, kar zaznavajo tudi pri zajemu dejanske rabe kmetijskih in gozdnih zemljišč, zato se kontrola podatkov izvaja po konceptu štirih oči (dva operaterja) (Mesner s sod., 2018).

Preglednica 2: Matrika napak – testno območje Trebnje

Razred	1	2	3	4	5	6	Skupaj razvrščene
1 Travniki	48	3	3		1	1	56
2 Obdelovalna zemljišča		43	3				46
3 Utrjene površine	2	3	43			3	51
4 Stavbe			1	48	2		51
5 Gozd		1		2	47		50
6 Vode						18	18
Skupaj referenčne	50	50	50	50	50	22	272

Preglednica 3: Matrika napak – testno območje Veliki Gaber

Razred	1	2	3	4	5	6	Skupaj razvrščene
1 Travniki	40	10	9				59
2 Obdelovalna zemljišča	5	37	7				49
3 Utrjene površine	5	3	34		1		43
4 Stavbe				48	3		51
5 Gozd				2	46		48
6 Vode						0	0
Skupaj referenčne	50	50	50	50	50	0	250

Preglednica 4: Matrika napak – testno območje Lisec

Razred	1	2	3	4	5	6	Skupaj razvrščene
1 Travniki	45	3	2				50
2 Obdelovalna zemljišča	1	42	7		1		51
3 Utrjene površine	3	2	41				46
4 Stavbe				45	1		46
5 Gozd	1	3		5	48		57
6 Vode						0	0
Skupaj referenčne	50	50	50	50	50	0	0

Na podlagi matrike napak lahko ocenimo tudi proizvajalčev in uporabnikovo natančnost (preglednice 5, 6 in 7). Pri testnem območju Trebnje sta najslabšo zanesljivost dosegla razred travnikov (87,3 %) in cest (78,2 %). Razred stavb je dosegel visoko zanesljivost, ki znaša kar 98 %, zanesljivost razreda gozd pa le desetinko odstotka manj. Razreda stavb in gozda v testnem območju Veliki Gaber sta dosegla primerljive rezultate kot razreda v testnem območju Trebnje. Občutno nižji rezultat sta dosegla razreda travnikov in obdelovalnih zemljišč (prvi le 67,8 % in drugi 75,5 %), medtem ko je zanesljivost razreda cest primerljiva z zanesljivostjo tega razreda na testnem območju Trebnje.

Rezultati testnega območja Lisec so glede na skupno natančnost, ki znaša 88,4 %, primerljivi z rezultati testnega območja Trebnje. V preglednici 5 opazimo tri napačne klasifikacije razreda obdelovalnih zemljišč v razred gozda. Gre za primere vinogradov, kjer je zaradi vinske trte standardni odklon višine večji in je območje klasificirano v razred gozda.

Glede zanesljivosti dobljenega rezultata izstopa razred stavb, ki je najslabšo zanesljivost dosegel v testnem območju Veliki Gaber (94,1 %). Podobne rezultate je dosegel razred gozd, bistveno razliko pa lahko opazimo v testnem območju Liseč, kjer zanesljivost navedenega razreda znaša 84,2 %. Navedeno je večinoma posledica petih primerov napačne klasifikacije stavb in treh primerov napačne klasifikacije segmentov obdelovalnih zemljišč. Razred cest je v vseh treh testnih območjih dosegel primerljivo zanesljivost z razponom le 2,7 % (najvišja vrednost znaša 78,2 %, najnižja 75,5 %).

Preglednica 5: Proizvajalčeva in uporabnikova natančnost – testno območje Trebnje

Razred	Referenčne točke	Klasificirane točke	Pravilno klasificirane točke	Proizvajalčeva natančnost (%)	Uporabnikova natančnost (%)
Travniki	50	56	48	96,0	87,3
Obdelovalna zemljišča	50	46	43	86,0	91,5
Utrjene površine	50	51	43	86,0	78,2
Stavbe	50	51	48	96,0	98,0
Gozd	50	50	47	94,0	97,9
Vode	22	18	18	81,8	100,0
Skupaj	272	272	247		

Preglednica 6: Proizvajalčeva in uporabnikova natančnost – testno območje Veliki Gaber

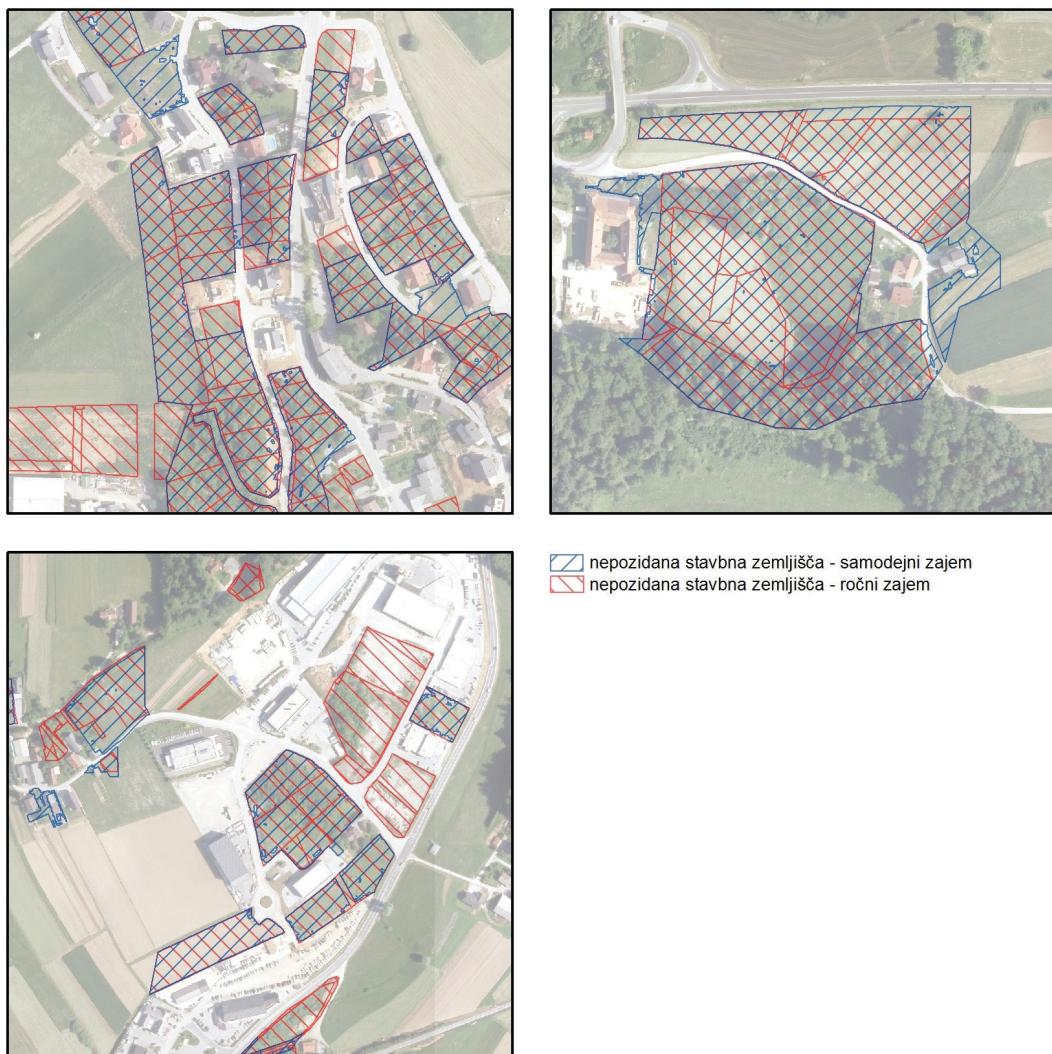
Razred	Referenčne točke	Klasificirane točke	Pravilno klasificirane točke	Proizvajalčeva natančnost (%)	Uporabnikova natančnost (%)
Travniki	50	59	40	80,0	67,8
Obdelovalna zemljišča	50	49	37	74,0	75,5
Utrjene površine	50	43	34	68,0	79,1
Stavbe	50	51	48	96,0	94,1
Gozd	50	48	46	92,0	95,8
Vode	0	0	0	N/A	N/A
Skupaj	250	250	205		

Preglednica 7: Proizvajalčeva in uporabnikova natančnost – testno območje Liseč

Razred	Referenčne točke	Klasificirane točke	Pravilno klasificirane točke	Proizvajalčeva natančnost (%)	Uporabnikova natančnost (%)
Travniki	50	50	45	90	90
Obdelovalna zemljišča	50	51	42	84	77,8
Utrjene površine	50	46	41	82	89,1
Stavbe	50	46	45	90	97,8
Gozd	50	57	48	96	84,2
Vode	0	0	0	N/A	N/A
Skupaj	250	250	221		

Primerjavo samodejnega zajema nepozidanih stavbnih zemljišč in zajema z metodo fotointerpretacije

prikazujejo slike 6, 8 in 10. Opazimo, da se na testnem območju Trebnje (slika 6) poligoni nepozidanih stavbnih zemljišč dobro ujemajo, izpostavimo večje območje nepozidanih stavbnih zemljišč na severozahodnem delu naselja Trebnje, ki ga podrobnejše prikazuje slika 11 (zgornji levi izsek). Navedena slika podrobnejše prikazuje tudi območje južno od regionalne ceste Ljubljana–Zagreb (zgornji desni izsek) in del nepozidanih stavbnih zemljišč na območju industrijske cone (spodnji levi izsek). Na navedenem izseku opazimo očitno razhajanje slojev samodejnega in ročnega zajema nepozidanih stavbnih zemljišč – primer je podrobnejše analiziran v nadaljevanju.



Slika 11: Detajlni izsledki nepozidanih stavbnih zemljišč na testnem območju Trebnje.

Nekaj sovpadajočih primerov nepozidanih stavbnih zemljišč opazimo tudi na testnem območju Veliki Gaber (slika 8). Podrobnejši prikaz izbranih izsekov obeh slojev nepozidanih stavbnih zemljišč prikazuje slika 12. Zgornji levi izsek prikazuje prekrivanje slojev na severozahodnem delu testnega območja, zgornji

desni izsek prikazuje območje v osrednjem delu naselja Veliki Gaber, spodnji desni izsek pa območje na jugovzhodnem delu naselja Veliki Gaber. Podrobnejših izsekov za testno območje Lisec nismo pripravili, saj je nepozidanih stavbnih zemljišč tam malo, primerjavo obeh slojev nepozidanih stavbnih zemljišč pa prikazuje slika 10.

Z metodo fotointerpretacije je bilo v testnem območju Trebnje prepoznanih 181,2 hektarja nepozidanih stavbnih zemljišč, od katerih smo s samodejnim zajemom uspešno prepoznali 123,2 hektarja površin (preglednica 8). Identičen rezultat je bil dosežen v testnem območju Lisec, kjer je nepozidanih stavbnih zemljišč zelo malo. Najslabši rezultat pa je bil dosežen v testnem območju Veliki Gaber.

Preglednica 8: Primerjava nepozidanih površin stavbnih zemljišč z ročnim in samodejnim zajemom

	Ročni zajem [ha]	Samodejni zajem [ha]	Delež (%)
Testno območje Trebnje	181,3	123,2	68,0
Testno območje Veliki Gaber	95,1	50,3	52,9
Testno območje Lisec	5,3	3,6	68,0

Preglednica 9 vsebuje podatke o bilanci površin nepozidanih stavbnih zemljišč, členjeno po razredih podrobne namenske rabe iz občinskega prostorskega načrta občine Trebnje (OPN občine Trebnje, 2013). Opazimo, da se v testnem območju Trebnje in Veliki Gaber večina nepozidanih stavbnih zemljišč nahaja na območjih stanovanj, večje površine nepozidanih stavbnih zemljišč pa so tudi na območjih proizvodnih dejavnosti. Upoštevaje deleže pravilno prepoznanih nepozidanih stavbnih zemljišč glede na podrobno namensko rabo, ugotavljamo, da bistvenih odstopanj v kakovosti prepozname ni. V večini primerov je bila dosežena več kot 50-odstotna zanesljivost prepozname. Dejanski delež pravilno prepoznanih nepozidanih stavbnih zemljišč je v testnem območju Trebnje in Lisec dosegel 68-odstotno, v testnem območju Veliki Gaber pa 52,9-odstotno pravilnost (preglednica 9).

Preglednica 9: Bilanca površin nepozidanih stavbnih zemljišč glede na podrobno namensko rabo iz OPN občine Trebnje (2013)

	Površine razprtene poselitve (A)	Posebna območja (B)	Območja centralnih dejavnosti (C)	Območja proizvodnih dejavnosti (I)	Območja stanovanj (S)
Testno območje Trebnje	ročni zajem [ha]	N/A	32,1	N/A	48,1
	samodejni zajem [ha]	N/A	31,9	N/A	27,0
	delež [%]	N/A	99	N/A	56
Testno območje Veliki Gaber	ročni zajem [ha]	1,1	N/A	2,8	N/A
	samodejni zajem [ha]	0,5	N/A	1,4	N/A
	delež [%]	45	N/A	50	N/A
Testno območje Lisec	ročni zajem [ha]	3,9	N/A	N/A	N/A
	samodejni zajem [ha]	3,1	N/A	N/A	N/A
	delež [%]	80	N/A	N/A	N/A

Deleži pravilno prepoznanih nepozidanih stavbnih zemljišč ne presenečajo. V testnem območju Trebnje in Lisec, kjer je bila z visoko kakovostjo določena že pokrovnost tal (znašala je 90 %), je tudi sloj nepozidanih stavbnih zemljišč v 68 % skladen z ročnim zajemom. V testnem območju Veliki Gaber, kjer je

sloj pokrovnosti tal dosegel slabšo pravilnost, pa se to neposredno odraža tudi na nižjem deležu pravilno prepoznanih nepozidanih stavbnih zemljišč.



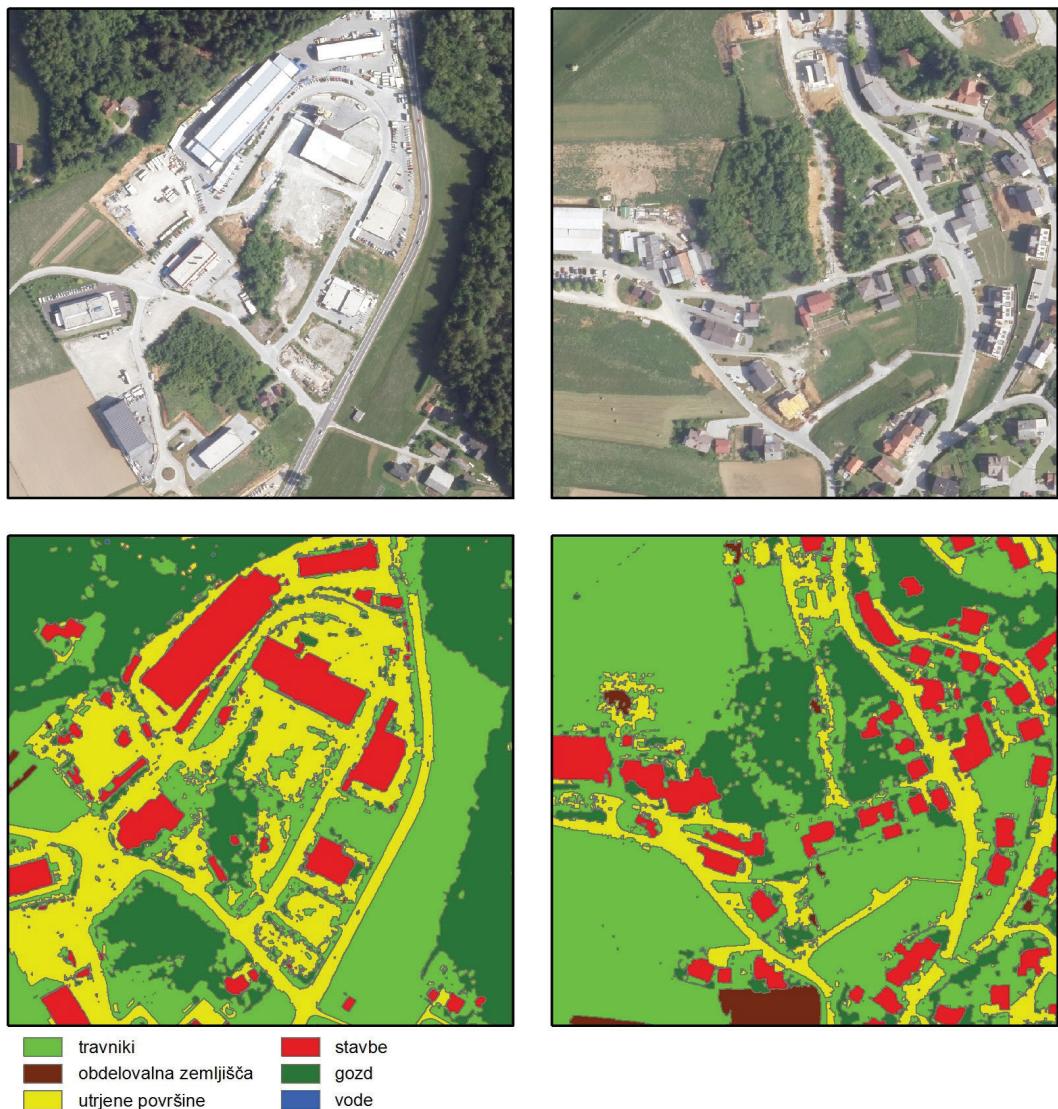
Slika 12: Detajljnejši izseki nepozidanih stavbnih zemljišč z rezultati samodejnega zajema in fotointerpretacije – testno območje Veliki Gaber.

4 RAZPRAVA

Predstavljena metodologija prepoznavanja nepozidanih stavbnih zemljišč je kljub nekaterim nepravilnostim ponudila obetavne in uporabne rezultate.

Razhajanja med obema metodama zajema nepozidanih stavbnih zemljišč se pojavljajo predvsem tam, kjer so nepozidana stavbna zemljišča pogojno primernih oblik za pozidavo (na primer ozke in dolge

parcele), ki pa površinsko zadovoljijo kriterij za uvrstitev v nepozidana stavbna zemljišča (za občino Trebnje je to 450 m^2). Operater, ki bi zajemal nepozidana stavbna zemljišča na podlagi fotointerpretacije, parcel neustreznih oblik ne bi uvrstil med zemljišča, primerna za novogradnjo. Pri samodejnem zajemu nepozidanih stavbnih zemljišč algoritem ni preverjal oblike zemljiške parcele, temveč le njeno površino, zaradi česar se v tovrstnih primerih pojavlja neskladje med obema zajemoma. Odpravljanje napake je v takih primerih v naslednjem koraku prepričljeno operaterju, vsekakor pa je mogoče algoritem nadgraditi tudi s prepoznavanjem ustreznih oblik parcel.



Slika 13: Detailnejša izseka ortofota in pokrovnosti tal – testno območje Trebnje.

Druga vrsta neskladij je posledica omejitve algoritma samodejnega prepoznavanja nepozidanih stavbnih

zemljišč zaradi uvrstitev v napačni razred pokrovnosti. Pokrovnost tal osrednjega dela industrijske cone v severovzhodnem delu testnega območja Trebnje (levi zgornji izsek na sliki 13) predstavlja utrjena površina (makadamsko parkirišče oziroma manipulacijska površina). S postopkom objektne klasifikacije je bilo območje (v večinskem deležu) pravilno razvrščeno v razred utrjenih površin (spodnji lev izsek na sliki 13), kar je neposredni razlog, da območje v postopku samodejnega prepoznavanja nepozidanih stavbnih zemljišč ni bilo prepoznano. Območje je bilo v postopku ročnega zajema prepoznano kot nepozidano stavbno zemljišče (slika 6 – parcele v severovzhodnem delu slike).

Izpostavimo še primer povsem ob zahodni meji testnega območja Trebnje (slika 5), ki ga podrobnejše prikazuje desni zgornji izsek na sliki 13. Tokrat ne gre za napako v postopku prepoznavanja nepozidanih stavbnih zemljišč, temveč se je napaka pojavila že v postopku objektne klasifikacije. Opuščena obdelovalna površina je bila v postopku objektne klasifikacije delno razvrščena v razred utrjenih površin, delno v razred obdelovalnih površin in delno v razred travniki (desni spodnji izsek na sliki 13). V nadaljnji obdelavi je bilo ugotovljeno, da delež utrjene površine predstavlja več kot 10 % celotne površine parcele, kar je izločilni kriterij oziroma razlog, da parcela ni prepoznana kot nepozidano stavbno zemljišče. Odstopanje obeh slojev nepozidanih stavbnih zemljišč v tem primeru prikazuje slika 6 (glej parcele ob zahodnem robu slike).

5 SKLEP

Vzpostavitev in posodabljanje slojev nepozidanih stavbnih zemljišč v občinah še vedno poteka ročno, na podlagi fotointerpretacije in z uporabo podatkov ortofota, registra nepremičnin, zemljiškega katastra, veljavnih prostorskih aktov in drugih pomožnih slojev. Tovrstni postopek se uporablja tudi pri množičnem zajemu poseljenih zemljišč in dejanske rabe poseljenih zemljišč (Masovni zajem..., 2017), kar je časovno in tudi finančno potratno.

Prispevek obravnava razvoj metodološkega pristopa za samodejno prepoznavanje nepozidanih stavbnih zemljišč, ki temelji na postopku objektne klasifikacije ob uporabi oblaka točk ALS, ortofota in infrardečega ortofota ter kasnejše obdelave v GIS. V prvem koraku pridobimo vektorski sloj pokrovnosti tal, ki ga s souporabo občinskega prostorskega načrta in zemljiškokatastrskega prikaza uporabimo za določitev nepozidanih stavbnih zemljišč. S tovrstnim pristopom smo na testnih območjih Trebnje in Lisec uspešno prepoznali kar 68 % nepozidanih stavbnih zemljišč, ki so bila zajeta z ročnim zajemom, na testnem območju Veliki Gaber pa je bilo takšnih zemljišč 52 %.

Postopki objektne klasifikacije sami po sebi ne povzročajo težav in so dovolj razviti za tovrstno uporabo, o čemer priča tudi kakovost klasifikacije. Najvišjo zanesljivost klasifikacije dosegata razreda stavb in gozd, z malo manjšo zanesljivostjo pa nam je uspelo klasificirati travnike. Največ težav se pojavlja pri razvrščanju v razreda cest in obdelovalnih površin. Ugotovitev ni presenetljiva, saj imajo tako ceste kot tudi obdelovalne površine zelo raznolike spektralne podpise ter so pogosto osenčene ali delno prekrite z drevesnimi krošnjami, kar otežuje prepoznavo.

Kakovost določitve nepozidanih stavbnih zemljišč je neposredno odvisna od kakovosti določitve pokrovnosti tal. Na testnem območju Trebnje je bil sloj pokrovnosti z 90,8 % pravilno razvrščenih segmentov zagotovo dovolj kakovosten za nadaljnjo uporabo. Podobno lahko trdimo za testno območje Lisec, v testnem območju Veliki Gaber pa lahko dobrošen del napak pri prepoznavanju nepozidanih stavbnih ze-

mljišč pripisemo nižji kakovosti določitvi sloja pokrovnosti tal. Postopek določitve nepozidanih stavbnih zemljišč na podlagi preseka slojev pokrovnosti in občinskega prostorskega načrta je parcelno orientiran – za vsako posamezno parcelo izračunamo delež pozidane in nepozidane površine. Kriterij razmejevanja med pozidanimi in nepozidanimi parcelami smo določili izkustveno in bi ga bilo v prihodnje treba natančneje določiti. Glede na raznolikost poselitve v Sloveniji bi se kriteriji verjetno razlikovali med občinami pa tudi v odvisnosti od posameznih naselij.

Pri ozkih in dolgih nepozidanih stavbnih zemljiščih ter drugih nepravilnih oblikah se samodejni postopek pokaže kot nezanesljiv. V takšnih primerih je nujna presoja strokovnjaka oziroma je nadaljnje raziskave smiselnos usmeriti v razvoj zanesljivih klasifikacijskih pravil, ki so osnovni pogoj za kakovostne nadaljnje rezultate. V študiji se nismo ukvarjali z oblikovanjem kriterijev in določitvijo geometrijskih pravil za oblike parcel, s katerimi bi iz zajema izločili parcele neustreznih oblik, kot so ozka in dolga nepozidana stavbna zemljišča, so pa bili poskusi narejeni za oblike parcel na kmetijskih zemljiščih (Foški, 2017; Foški, 2019).

Predstavljena metodologija še ne dosega tako visoke zanesljivosti, da bi lahko izključili kritičen pregled operaterja. Vizualni pregled rezultatov ni namenjen le odpravi napak samodejnega postopka, temveč omogoča tudi kritično strokovno presojo posameznih primerov. Do podobnih ugotovitev so prišli Čekada in sod. (2018), ki ugotavljajo, da se lahko s samodejnim zajemom v dvostopenjskem postopku, kjer se v prvi fazi pripravijo podatki samodejnega zajema, v drugi fazi pa operater izvede kontrolo in kritično presojo podatkov, bistveno pospešijo postopki vizualne fotointerpretacije ob doseganju primerljive stopnje kakovosti podatkov.

Opisana metoda je uporabna tako pri prvem zajemu nepozidanih stavbnih zemljišč kot pri kasnejšem posodabljanju sloja. Posodobitev sloja je mogoča ob novih vhodnih podatkih (ortofoto, infrardeči ortofoto, oblak točk aerolaserskega skeniranja in prostorski akti), potreben pa je vizualni pregled rezultatov in odprava vseh napak. Prednosti samodejnega zajema pred ročnim so predvsem v časovnem in finančnem prihranku ter pogojno tudi v objektivnosti zajema.

Metodologijo bi bilo smiselnoprveriti na večjem testnem območju in na območju, kjer je že bil izveden množični zajem poseljenih zemljišč in dejanske rabe poseljenih zemljišč. Na podlagi ugotovitev pa bi bilo nujno razmislati, kako samodejno identifikacijo sprememb stavbnih zemljišč vključiti v vzdrževanje nastajajočega podatkovnega sloja. Vsekakor pa menimo, da se bo v prihodnosti delež ročnega zajema in vizualne interpretacije daljinskih posnetkov zmanjševal in se dopolnjeval s samodejno klasifikacijo.

Zahvala

Raziskovalno delo je bilo delno opravljeno v okviru temeljnih raziskovalnih projektov J2-9251: M3Sat – Metodologija analize časovnih vrst satelitskih posnetkov različnih senzorjev in J6-9395: Opazovanje suše v visoki ločljivosti z modeliranjem talnih in satelitskih ter raziskovalnega programa P2-0406: Opazovanje Zemlje in Geoinformatika, ki jih sofinancira Javna agencija za raziskovalno dejavnost Republike Slovenije iz državnega proračuna.



Jenko D., Foški M., Oštir K., Kokalj Ž. (2019). Zajem nepozidanih stavbnih zemljišč z objektno klasifikacijo podatkov ortofota in aerolaserskega skeniranja. Delineation of vacant building land using orthophoto and LIDAR data object classification.

Geodetski vestnik, 63 (3), 344-378.

DOI: <https://doi.org/10.15292/geodetski-vestnik.2019.03.344-378>

Dejan Jenko, mag. inž. geod. in geoinf.

Bolkova ulica 5b, SI-1235 Radomlje
e-naslov: dejan.jenko1@gmail.com

prof. dr. Krištof Oštir, univ. dipl. fiz.

Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo
Jamova 2, SI-1000 Ljubljana
e-naslov: kristof.ostir@fgg.uni-lj.si

viš. pred. dr. Mojca Foški, univ. dipl. inž. geod.

Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo

Jamova 2, SI-1000 Ljubljana
e-naslov: mojca.foski@fgg.uni-lj.si

doc. dr. Žiga Kokalj, univ. dipl. geog.

Znanstvenoraziskovalni center Slovenske akademije znanosti in umetnosti, Inštitut za antropološke in prostorske študije
Center odličnosti Vesolje, znanost in tehnologije
Novi trg 2, SI-1000 Ljubljana
e-naslov: ziga.kokalj@zrc-sazu.si