

АУТОМАТИЗАЦИЈА ПРОИЗВОДЊЕ ТОПОГРАФСКИХ КАРТА ПРИМЕНОМ МЕТОДА ДУБОКОГ УЧЕЊА**TOPOGRAPHIC MAP PRODUCTION AUTOMATION USING DEEP LEARNING METHODS**

Милош Басарић, Факултет техничких наука, Нови Сад и Војногеографски институт „Генерал Стеван Бошковић”, Београд

Област – ГЕОДЕЗИЈА И ГЕОИНФОРМАТИКА**1. УВОД**

Кратак садржај – Израда дигиталних топографских карата захтева коришћење података из различитих извора, у оквиру строгих картографских правила. Оправдана је потреба за развојем напредне методологије за аутоматско генерисање података о зградама. Применом U-net конволуцијске неуронске мреже имплементирани у Python-у, на сателитском ортофото снимку резолуције 30 cm, добијена је маска за предикције објеката. Извршена је векторска обрада маске, креирајући полигоне са задатим подацима о ротацији, из којих су добијени одговарајући вектори тачака који репрезентују зграде. Добијени су подаци који захтевају минималну манипулацију и корекцију. Алат је развијен за топографску карту размере 1:25.000. Лист карте приближно покрива површину од око 120 km². Уз мање модификације, овај алат се може користити на читавом низу топографских карата.

Кључне речи: Дубоко учење, Сегментација слике, Топографска карта, Екстракција топографских података, Екстракција отисака зграда

Abstract – The production of digital topographic maps requires the use of data from various sources, within the framework of strict cartographic rules. The need to develop an advanced methodology for the automatic extraction of building data is justified. Using the U-net convolutional neural network implemented in Python, a building prediction mask was obtained on a 30 cm resolution satellite orthophoto. Vector processing of the mask was performed, creating polygons with given rotation data, from which corresponding point vectors representing buildings were obtained. Generated data require minimal manipulation and correction. The tool was developed for a 1:25,000 scale topographic mapsheet. The mapsheet covers an area of approximately 120 km². With minor modifications, this tool can be used on a wide range of topographic maps.

Keywords: Deep learning, Image segmentation, Topographic map, Topographic data extraction, Building footprint extraction

НАПОМЕНА:

Овај рад је проистекао из мастер рада чији ментор је био др Мирко Говедарица, ред. проф.

Војна топографска карта у размери 1:25.000 у издању Војногеографског института представља врло важан картографски производ на националном нивоу. Негујући картографско наслеђе које је ова институција градила у свом дугом постојању, и за ову карту се може рећи да је изврстан пример квалитетног картографског продукта чија израда захтева софистицирано технолошко окружење и пажљив приступ раду, а како је читљивост, прегледност и верност ове карте нешто о чему се нарочито води рачуна, велики број људи учествује у процесу производње једног листа карте.

Међутим, значајно време у односу на укупно се утроши на фотограметријску обраду па је постојање напредних система за аутоматско генерисање топографских података оправдано и потребно.

Овај рад има за циљ да представи радни процес аутоматског креирања и картографског позиционирања векторских тачкастих објеката које се односе на зграда које се приказују ван размере на дигиталној топографској карти 1:25.000. Такав векторски податак је врло доминантан по питању учесталости појављивања симбола, поготово када су у питању урбана градска подручја. Класичан реституциони фотограметријски приступ за креирање поменутих објеката временски је веома захтеван и заузима значајно време у односу на целокупно време за примарну фотограметријску обраду.

Типична пракса је да извршилац фотограметријске обраде креира сваки објекат појединачно. Подаци добијени аутоматским путем, на начин како је представљено у овом раду захтевају минималну манипулацију и корекцију што значајно штеди временске и остале ресурсе, а притом поједностављује израду топографске карте уопште.

Како је идеја имплементација методологије рада у затворен технолошки процес Војногеографског института, целокупни процес је базиран на софтверима и технолошким могућностима институције. То значи да су коришћени софтвери ArcGIS 10.3, Global Mapper 18 и програмски језик Python 3.7 са адекватним библиотекама. Алгоритми за позиционирање објеката су креирани у оквиру ArcGIS-овог Model Builder алата. Самим тим, остварени су технолошки услови за имплементацију у систем рада Војногеографског института.

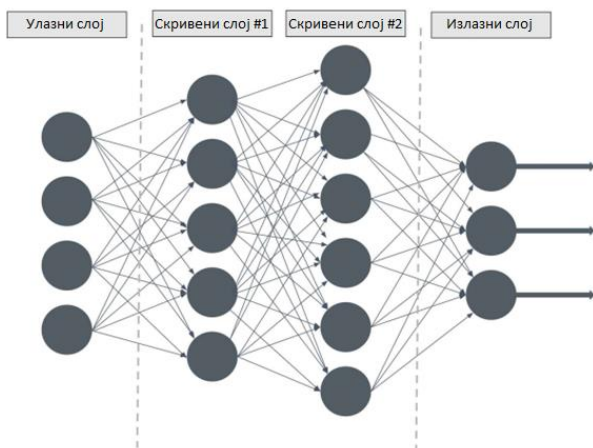
2. ДУБОКО УЧЕЊЕ И ОБРАДА САТЕЛИТСКИХ СНИМАКА

У сваком историјском раздобљу људско тело је упоређивано са модерним машинама тог времена [1], док је у последњих неколико деценија заступљено упоређивање мозга са рачунаром. Поставке о мозгу као рачунару довеле су до конструкције вештачких неуронских мрежа, које узимају значајну употребу у вештачкој интелигенцији [1].

Машинско учење подразумева рачунарско учење из података коришћењем алгоритма ради обављања задатака без експлицитног програмирања, док дубоко учење користи комплексне структуре алгоритма моделованих по узору на људски мозак. То омогућава процесирање неструктурираних података као што су документи, слике и текст [2]. Дубоко учење описује алгоритме који анализирају податке на сличан начин као што би и људи доносили закључке. Да би се ово постигло, за примену дубоког учења користи се слојевита структура алгоритма која се зове вештачка неуронска мрежа (*Artificial neural network – ANN*). Дизајн такве структуре инспирисан је биолошком неуронском мрежом, што је довело до процеса учења са већим потенцијалом него што су стандардни модели машинског учења.

2.1. Вештачке неуронске мреже

У складу са сликом примера једне вештачке неуронске мреже, биће дата објашњења о структури исте. На слици 1 је дат приказ вештачких неурона односно чворова повезаних по слојевима. Примећујемо да је сваки чвор повезан са свим чворовима у претходном и наредном слоју. Леви слој је улазни, док је десни слој излазни слој. Средишњи слојеви се називају скривени слојеви јер њихова вредност није оперативна за процес учења. Најједноставније речено, скривени слојеви су прорачунате вредности које се користе да се изврши за дати циљ. Што више има скривених слојева између улазног и излазног слоја мреже, мрежа је „дубља“. Генерално, свака вештачка неуронска мрежа са два или више скривених слојева представља дубоку неуронску мрежу (*Deep neural network*) [2].



Слика 1. Приказ структуре неуронске мреже
Врста вештачких неуронских мрежа су конволуцијске неуронске мреже. Конволуцијске неуронске мреже су

алгоритми креирани за рад са сликама. Конволуција је процес где се користи филтер базиран на тежинама над сваким елементом слике, на основу чега рачунар разуме и реагује са тим елементима. То може бити корисно када треба да претражимо велики број фотографија ради проналажења неког детаља [2].

Алгоритам примењен за овај пројекат јесте конволуцијска неуронска мрежа *U-Net*. *U-Net* је алгоритам објављен 2015. године у [3], креиран за потребе сегментације биомедицинских односно микроскопских слика.

2.2. Сегментација сателитских снимака

Аутоматска екстракција отисака зграда, спољашње површине кровова зграда, на ортофото снимцима високе резолуције је захтеван и значајан задатак [4]. У дигиталној обради слике и рачунарској визији (*CV – computer vision*), сегментација слике је процес поделе делове дигиталне слике у групе тј. по сегментима. Циљ сегментације је да се поједностави и/или промени репрезентација слике у нешто што је смисленије и лакше за анализу [5]. У геоинформатици и генерално у обради ортофото снимака, сегментација је применљивана ради екстракције детаља од интереса у различите намене. Неки од тих приступа за циљ има генерисање топографских података као што су путеви, хидрографија, вегетације или подаци о зградама.

3. ПРИПРЕМА И ПРЕДСТАВЉАЊЕ РАДНОГ ПРОЦЕСА СТУДИЈЕ СЛУЧАЈА

За извођење овог пројекта са аспекта вештачке интелигенције коришћен је програмски језик *python* који је широко распрострањен када је у питању примена машинског и дубоког учења. Поред уобичајених библиотека за обраду и визуелизацију слике као што су *Pillow*, *OpenCV*, *Tiffle* и *Matplotlib*, у овом раду коришћење су и библиотеке од значаја за дубоко учење, тренирање модела односно припрему података као што су *Patchify*, *TensorFlow*, *NumPy* и *Segmentation models*. Главна идеја је била креирати модел за бинарну сегментацију сателитског ортофотоа ради детекције зграда, а у циљу даље векторске обраде ради генерисања векторских тачкастих података о зградама.

3.1. Улазни подаци и припрема података

Као улазни подаци за тренинг *U-Net* модела је коришћен је *Inria* скуп података. *Inria* скуп података су означени аерофото снимци (*The Inria Aerial Image Labeling*) намењени за сегментацију сателитских и аерофото снимака базирану на пикселима као кључној теми у даљинској детекцији.

Скуп података покрива 810 km² (405 km² за тренирање и 405 km² за тестирање) у виду орторектификованих снимака из ваздуха у боји са просторном резолуцијом од 30 cm, као и означене *ground truth* снимке тј. једноканалне кореспондирајуће маске за две семантичке класе (класа зграда приказана вредношћу 255 и класа која се односи на све оно што нису зграде при-

казано вредношћу 0). Снимци покривају насеља различитог степена урбаности и густине насељености [6].

3.1. Радни процес студије случаја

Радни процес студије случаја креиран је тако да се најпре врши одабир података за тренирање. Одабран је само део скупа података који се односи на град Тирол. Припрема података представља креирање сегменте величине 256×256 пиксела од постојећих слика и кореспондирајућих маски. Како би процес тренирања био још ефикаснији, на основу заступљености вредности 255 која се односи на постојање зграда на маскама, узимани су само они парови слика на којима је утврђена постојаност зграда тј. вредности 255 веће од 5 процената. Тренинг модела је извршен у 60 епоха. Резултат крајњег процеса је модел за бинарну сегментацију. Када смо направили модел, следећи корак је припремити податке за употребу моделу односно вршење бинарне сегментације. Један лист топографске карте покрива површину преко 120 km^2 па је потребно поделити снимак на мање делове односно тајлове због процесорских захтева. Снимак је подељен на 16 делова (тајлова) од којих је сваки приликом процеса бинарне сегментације подељен на мале узорке у димензија 256×256 пиксела, који су након бинарне сегментације поновно састављени у првобитну целину која представља маску предикције.

Следећи корак радног процеса јесте векторска обрада. Векторска обрада почиње обрадом маске предикције ради генерисања топографских података. Најпре је потребно добити отиске зграда као полигонских векторских података. Након тог корака се врши селекција података која иде у даљу обраду тј. одабир оних података који су релевантни за даљи рад. После тога, генеришу се тачкасти векторски подаци са адекватном оријентацијом које се односе на зграде. Над њима се употребљавају алгоритми креирани за потребе овог рада који врше позиционирање тачастих вектора у складу са правилима представљања објеката на топографској карти као и њихову примарну генерализацију у складу са размером карте.

Како би се забележио крајњи резултат и ради адекватне имплементације добијених података у систем Војногеографског института врши се формирање растерског отиска симбола објеката односно тачкастих векторских података.

4. СТУДИЈА СЛУЧАЈА - ВРАЊЕ

Сегментација слике је рађена над сателитским снимком резолуције 30 cm који обухвата територију листа дигиталне топографске карте 1:25.000 са номенклатурним бројем НК34-5/6-2-4 на којој се налази целокупна површина градског подручја Врања са околним местима. Применом конволуцијске неуронске мреже *U-Net* добијена је бинарна маска предикције отисака објеката на основу улазног сателитског снимка. Добитија маска се векторизује путем функције *Raster to Polygon* након чега је потребно обрисати неколицину полигона неадекватне површине, након чега се ради низ функција за

генерализацију облика отисака објекта. Утврђено је да сви полигони испод 5 m^2 површине не задовољавају критеријуме да буду самостални и буду део накнадне обраде података. Такође, детектовани објекти са већом површином који се не приказују симболом тачке за зграду ван размере се елимишу из резултата. На упрошћеном скупу полигона додаје се поље у атрибутивну табелу и у то поље се уписује резултат функције *Calculate Polygon Main Angle* која рачуна углавну ротацију сваког полигона односно дирекциони угао. Након тога се примењује функција *Feature To Point* која генерише тачкасте податке позиционирани у центру постојећих полигона.

Нови тачкасти слој у себи садржи атрибуте полигона па је самим тим задржана и њихова вредност оријентације. Добитије тачке немају посебно дефинисану симбологију и њихови кружни симболи не подржавају никакву врсту ротације. Због тога је потребно додати жељени симбол за тачкасти слој који одговара згради ван размере који како није кружни, подржаваја ротацију. Ротација се читава из кореспондирајућег поља у атрибутивној табели и на тај начин добијамо исправно заротиран објекат. Након тога је потребно конвертовати податке у репрезентације и доделити детаљне димензије симбола који одговара кључу дигиталне топографске карте 1:25.000 Војногеографског института.

Добитије векторских тачкастих података који одговарају местима предикције на излазном растеру модела дубоког учења је примарни задатак, али врло важан аспект јесте позиционирање тих векторских података на такав начин да одговарају картографским правилима за приказивање објеката у насељу. Из тог разлога креирани су алгоритми за мерење објеката у складу картографским правилима. Креирана су четири алгоритма:

1. Алгоритам за равнање података у блиском окружењу путева
2. Алгоритам за прилепљивање података уз комуникације представљених са две линије
3. Алгоритам за одвајање података од комуникација представљених једном линијом
4. Алгоритам за проређивање и примарну генерализацију објеката

Да би се извршило позиционирање објеката потребно је имати податке од којих то позиционирање и зависи. То су векторски подаци који се односе на комуникације (путеви и железничке пруге). Појава железничких пруга у рејону студије случаја је минимална.


Генерализовани подаци о путевима се обрађују функцијом *Split Line At Vertices* чиме се добија посебан векторски објекат пута између сваке две тачке осе пута. То значи да је сваки сегмент пута посебан векторски објекат.

Додаје се нова колона у атрибутивној табели тих података где се извршава код кроз *Field Calculator* ради рачунавања дирекционог угла сваког сегмента пута. То омогућава правилну реализацију првог алгоритма.

5. ПРИКАЗ РЕЗУЛТАТА

Применом конволуцијске неуронске мреже, на сателитском ортофото снимку (слика 2, приказ 1), добијена је маска предикције објеката (приказ 2), као резултат бинарне сегментације засноване на тест скупу података за обуку модела. Векторска обрада маске изведена је креирањем полигона са припадајућим подацима о ротацији (приказ 3), из којих су добијени одговарајући вектори тачака (приказ 4).

Алгоритми креирани коришћењем *ArcGIS Model Builder*-а примењени су на претходно припремљене векторске податке, док је за додатне прорачуне коришћен *python*. Развијени алгоритми 2, 3 и 4 морали су да задовоље картографска ограничења заснована на минималној удаљености између зграда и удаљености од графичког знака на путу. За што адекватнији естетски приказ, објекти у окружењу пута се ротирају у истом правцу што реализује алгоритам 1 (прикази 5 и 6).



Слика 2. Преглед корака екстракције података о зградама

6. ЗАКЉУЧАК

Израда топографске карте, као основног продукта Војногеографског института веома је сложен процес и постоји константна потреба за усавршавањем истог. Убрзавање и аутоматизација било које фазе овог задатка доприноси квалитету крајњег производа. Решење за аутоматизацију једног од сегмената овог процеса реализовано је путем примене вештачке интелигенције односно дубоког учења и алгоритама за векторску обраду добијених података. Опште разматрање резултата овог рада је да је предложени метод подесан и адаптиран за потребе производног процеса топографске карте 1:25.000 у издању Војногеографског института. Важећа картографска правила имплементирана су путем креираних

алгоритама. Применом ове методологије, добијени подаци изискују минималну манипулацију и корекције, што резултује у уштеди времена и осталих ресурса, као и поједностављивањем продукције топографске карте генерално. Примена метода дубоког учења за детекцију топографских података односно сегментацију аерофото снимака је врло заступљена у научној заједници последњих година. Искорак у односу на то, представља векторска обрада картографска правила. Креирани модел дубоког учења, а нарочито алгоритми су предмет сталног унапређивања и усавршавања. Након тестирања предложеног решења у производном систему, јавиће се повратна информација у ком смеру је потребно усавршити предложено решење. Тада ће бити могуће достићи оптимални ниво аутоматског генерисања топографских података о грађевинама и зградама ванразмерним симболима тачкастог вектора.

7. ЛИТЕРАТУРА

- [1] Х. Мориц, „Знаност, ум и свемир“, Загреб, Школска књига, 1998, pp. 7-11.
- [2] „Deep Learning vs. Machine Learning – What’s The Difference?“, Levy, 26 Јул 2022. [На мрежи]. Доступно на: <https://levity.ai/blog/difference-machine-learning-deep-learning#:~:text=Machine%20learning%20means%20computers%20learning,as%20documents%2C%20images%20and%20text.> [Последњи приступ 28 Јул 2022].
- [3] О. Ronneberger, Р. Fischer и Т. Brox, „U-Net: Convolutional Networks for Biomedical Image Segmentation“, *MICCAI 2015 - Medical Image Computing and Computer-Assisted Intervention*, т. Lecture Notes in Computer Science, бр. 9351, pp. 234-241, 2015.
- [4] Z. Kokeza, M. Vujasinovic, M. Govedarica, B. Milojevic and G. Jakovljević, Automatic building footprint extraction from UAV images using neural networks, *Geodetski Vestnik* 64 (2022) 545.
- [5] L. Shapiro и G. Stockman, „Computer Vision“, New Jersey, Prentice-Hall, 2001, pp. 279-325.
- [6] Inria, „Inria Aerial Image Labeling Dataset“, The dataset, [На мрежи]. Доступно на: <https://project.inria.fr/aerialimagelabeling/>. [Последњи приступ 11 Септембар 2022].

Кратка биографија:



Милош Басарић из Бачке Паланке рођен је 1996. године. Завршио Војну гимназију у Београду 2015. године и Војну академију у Београду 2019. године на смеру Војногеодетско инжењерство. Као активан је геодетски официр Војске Србије ради на Војногеографском институту „Генерал Стеван Бошковић“ у Београду. Даље школовање наставио на мастер студијама на Факултету Техничких наука на смеру Геодезија и геоинформатика.

контакт:
m-basarić@protonmail.com