

## КЛАСИФИКАЦИЈА ОБЛАКА ТАЧАКА ПРИМЕНОМ ДУБОКОГ УЧЕЊА

## CLASSIFICATION OF POINT CLOUD USING DEEP LEARNING

Галина Јанковић, Факултет техничких наука, Нови Сад

## Област – ГЕОДЕЗИЈА И ГЕОИНФОРМАТИКА

**Кратак садржај** – У овом раду описан је поступак креирања модела вештачких неуронских мрежа у циљу класификације облака тачака. Модел је обучаван са различитим улазним параметрима, а затим тестиран различитим метрикама.

**Кључне речи:** облак тачака, ласерско скенирање, дубоко учење, вештачке неуронске мреже, класификација, Python, детекција објеката

**Abstract** – This paper describes the process of creating a model of artificial neural network in order to classify point cloud. The model is trained with different input parameters and then tested with different metrics.

**Keywords:** point cloud, LiDAR, deep learning, ANN, classification, Python, object detection

## 1. УВОД

Облак тачака представља скуп тачака познатих координата у 3D простору, који поред координата може садржати и разне информације, попут интензитета ласерског зрака, вредности боје, броју одбитака, и сл. Повећањем доступности аквизиционих уређаја, као и повећањем примене у разним областима, попут аутономне вожње и роботике, облак тачака је постао један од најзначајнијих формата података за 3D представљање [1].

Један од основних задатака анализе облака тачака чини његова класификација, односно груписање тачака у одговарајућу класу. Ручна класификација облака тачака подразумева додељивање класе свакој тачки унутар облака на мануелан начин. Овај дуготрајан и досадан процес постао је замењив иновацијама у области дубоког учења.

Дубоко учење је област машинског учења заснована на неуронским мрежама, које омогућавају да се алгоритмима изводе закључци какве би и сам човек извео, и као таква, постаје највише преферирана техника за задатке попут класификације, сегментације и детекције.

Обрада структурираних дводимензионалних података постала је лако могућа методама машинског учења, међутим, облак тачака чини неправилан и неструктуриран скуп података.

Предмет овог истраживачког рада састоји се у формирању модела неуронске мреже за класификацију

## НАПОМЕНА:

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

облака тачака у две класе – тачке које припадају и тачке које не припадају објекту. Подаци из облака тачака прикупљени су ласерским снимањем из ваздуха на територији Петроварадина.


Модел је формиран применом Python програмских библиотека за дубоко учење и креирањем конволуционе неуронске мреже (енг. *Convolutional Neural Network – CNN*).

У раду је исти модел трениран над ласерским подацима који садрже или интензитет зрака или вредности боје, или њихову комбинацију. Модел је тестиран помоћу неколико метрика. Експериментом је утврђено који улазни подаци су допринели највећој тачности модела. На крају, модел је примењен на неклассификоване податке, те је резултате предикције могуће и визуелно интерпретирати.


## 2. ОБЛАК ТАЧАКА

Савремене технологије прикупљања просторних података омогућавају добијање масовне количине информација о ентитетима у реалном свету на врло брз начин. Једна од таквих технологија јесте ласерско скенирање или како је још познат термин у литератури - LiDAR (енг. *Light Detection and Range*), активна, оптичко-механичка, безконтактна метода прикупљања просторних података. Ова технологија базирана је на мерењу растојања до објеката помоћу ласера. Резултат скенирања представља облак тачака.

Облак тачака (енг. *point cloud*) чини скуп тачака у простору са познатим координатама. Подаци облака тачака представљају погодан формат за визуализацију 3D света и често се користе у областима мобилног мапирања, архитектури, грађевинарству, роботизи, аутономној вожњи, проширеној и виртуелној стварности [1].



а)



б)

Слика 1. Облак тачака са учитаним подацима о интензитету зрака (а) и вредностима боје (б)

Поред координата тачака, облак може садржати и додатне карактеристике попут нормала површине,

вредности боје или интензитета ласерског зрака. Скуп ових информација помаже кориснику да целокупна структура буде препознатљива.

Постоје различити формати складиштења резултата скенирања, који умногоме утичу на прецизност и количину информација смештених у фајлу. Један од стандарда у области ласерског скенирања чини \*.las формат, бинарна структура за складиштење и размену ласерских података.

Анализа облака тачака означава додељивање низа карактеристика снимљеним тачакама, које ће се даље примењивати у одређене сврхе. Екстракција особина, сегментација и филтрирање, препознавање облика само су неки од задатака обраде 3D облака. Један од основних задатака анализе чини и његова класификација, односно груписање тачака са сличним карактеристикама у исту класу – класу вегетације, зграда, тла, водених површина, итд..

### 3. ДУБОКО УЧЕЊЕ

Дубоко учење (енг. *deep learning*) је техника машинског учења заснована на неуронским мрежама, дизајнирана да опонаша људски мозак [2]. Минимална људска интервенција потребна у изради неког задатка чини алгоритме дубоког учења пожељним у различитим сферама живота. С друге стране, захтевање масовних количина података и значајних рачунарских ресурса, ограничавају њихову употребу.

#### 3.1. Формирање модела неуронских мрежа

Креирање модела неуронских мрежа подразумева дефинисање улазних, излазних и скривених слојева, које чине огромни скупови података, неопходни да би их рачунар разумео и дао тачне резултате. Вештачке неуронске мреже (енг. *Artificial Neural Network – ANN*) постављају низ бинарних питања тачно/нетачно на основу улазних података, укључујући сложене математичке прорачуне, те класификују те податке на основу добијених одговора [3].

У литератури постоје различите препоруке за дефинисање броја улазних и излазних слојева, као и неурона у њима. Број неурона у улазном слоју треба да одговара димензионалности улазних података. У овом раду исти модел неуронске мреже биће испробан над различитим улазним подацима, који садрже интензитет или вредности боје зрака и на самом крају њихову комбинацију. У зависности од циља неког проблема, разликоваће се број излазних слојева. Број скривених слојева специфичан је за сваки проблем и захтева експериментисање са различитим бројевима, док се не дође до оптималног решења. Приликом формирања модела, води се рачуна и о избору техника регуларизације, које спречавају прекомерно тренирање мреже и губљење моћи генерализације. Осим тога, бира се и одговарајући оптимизатор, кључна компонента чија је сврха да прилагоди параметре модела током процеса обуке како би се минимизирала специфична функција губитка. Функција губитка мери разлику између предвиђеног излаза и стварних циљних вредности.

Што је мањи губитак, то су предвиђања модела боље усклађена са истинитим подацима.

#### 3.2. Обука и евалуација модела

Дефинисањем архитектуре жељеног модела, приступа се обуци модела над тренинг подацима. Дефинише се број узорака, параметар који показује колико се узорака користи у једној итерацији, и број епоха, параметар којим се дефинише колико пута ће мрежа проћи кроз читав скуп података.

#### 3.3. Оцена тачности модела


Процена тачности и перформанси модела следи након обуке и евалуације. Важна метрика евалуације за многе ANN моделе, посебно у задацима класификације, јесте тачност. Тачност модела мери колико добро предвиђања модела одговарају стварним циљним вредностима у неком скупу података. Међутим, тачност није једина метрика за процену перформанси, већ у комбинацији са другим методама попут прецизности и одзива, омогућава добијање потпуне процене квалитета модела и подобности за дати задатак.

### 4. ИЗАЗОВИ ДУБОКОГ УЧЕЊА У РАДУ СА ОБЛАКОМ ТАЧАКА

Технике дубоког учења данас чине најмоћније средство за обраду података у рачунарској визији и као такве, постале су очекиван избор за обраду структурираних података, попут слика. Насупрот сликама, облак тачака чини неструктуриран сет података. Управо неструктурираност чини примену метода дубоког учења веома изазовном. Осим што је неструктуриран, облак тачака карактеришу и неправилност и неуређеност. Неправилност означава неравномерно узорковање различитих региона у облаку, тако да неке регионе карактеришу сувише густе, док други садрже веома ретке тачке. Неуређеност означава то да се скуп тачака у облаку не складишти истим редоследом којим те тачке представљају сцену у 3D простору.

### 5. МЕТОДОЛОГИЈА РАДА

Класификација облака тачака применом дубоког учења чини низ процеса неопходних за формирање модела, који би се могао применити и за нека слична подручја. На дијаграму 1 приказан је читав поступак, а њихово објашњење дато је у наставку.



Дијаграм 1. Фазе истраживања у раду

#### 1) Прикупљање података


Облак тачака најчешће проистиче као резултат ласерског скенирања или из различитих софтвера за

фотограметријску обраду. Подаци у овом раду прикупљени су ласерским скенирањем из ваздуха за подручје Петроварадина. Осим ласерских података, прикупљене су и фотографије, које омогућавају да се поред координата тачака у облаку, издвоје и вредности R, G, B компоненте ласерског зрака, те да се свакој тачки и придруже. Сет података садржи 22800705 тачака, а формат у ком су подаци ускладиштени је \*.las.

## 2) Припрема података

Претпроцесинг података подразумева грубу елиминацију тачака, које би представљале одређен шум, попут птица или ниских тачака. Примена аутоматизованог начина класификације захтева и одређен део ручне класификације, који је неопходан за формирање података за обуку модела. Као софтверско решење за ручну класификацију изабран је *Microstation*, у коме су тачке класификоване у две класе – класу *Building* (објекти) и класу *Default* (остало).

Припрема података подразумева и поделу улазних података на део за тренинг и део за предикцију. На слици су приказани подаци за тренинг који чине 70% тачака у облаку.



Слика 3. Ручно класификовани подаци за тренинг

## 3) Манипулација над подацима

Након формирања скупа података за тренинг и предикцију, неопходно је извршити и конверзију података формата \*.las у \*.txt, ради даљег рада у *Python* програмском језику.

Издвајање колона на основу којих ће се вршити тренирање, подела тренинг података на део за обуку, валидацију и тест, као и скалирање ових података ради бржег учења, омогућена је *Python* програмским библиотекама попут *Sklearn*, *Pandas*, *Numpy*, а за креирање самог модела изабрана је библиотека *Keras*. Скуп података за тренинг чини 80% података за обуку, а преосталих 20% подељено је на део за валидацију и део за евалуацију модела.

## 4) Креирање модела

Креирање модела дубоког учења за класификацију описан је у претходном поглављу, која се односи на општи модел за креирање модела. Предмет ове студије представља креирање модела за бинарну класификацију, стога се за излазни слој бира један неурон са сигмоидном функцијом активације, док број улаза чини један слој са 1, 3 или 4 неурона у

зависности од тога који се подаци из облака узимају. Као техника регуларизације изабрана је *Dropout* метода, а за функцију губитка бинарна функција (енг. *Binary crossentropy*). За оптимизатора изабран је *Adadelta*, који је показао нешто боље резултате од најчешће примењиваног *Adam* оптимизатора.

У овој студији, за модел бинарне класификације изабран је модел *Sequential* из *Keras* библиотеке, модел који се користи за истраживање различитих типова неуронских мрежа где се на улазу добија један слој, а како повратну информаџију очекује излаз по жељи. Експеримент се огледа у томе да је овај линеарни модел тестиран над различитим улазним подацима, да би се утврдило да ли се може примењивати за класификацију облака тачака, неправилне структуре.

## 5) Обука модела и оцена тачности

У раду је праћење обуке омогућено функцијом која исписује вредности грешке и тачности приликом сваког корака у обуци, те је на тај начин омогућено спречавање прекомерног тренирања мреже. У складу са рачунарским ресурсима, 60 епоха и 80 узорака је изабрано као оптимално решење за обуку модела.

*Sklearn* програмска библиотека нуди мноштво метода за оцену тачности креираног модела. Поред се предвиђени подаци који представљају класификовани облак тачака са подацима који су ручно класификовани и који су коришћени за обуку модела.

У овој студији, коришћено је неколико метода евалуације. То су тачност, прецизност, осетљивост, *F1-score* и *ROC-AUC score*.

### I. Тачност

Тачност (енг. *Accuracy*) пружа увид у то колико добро функционише модел, тј. говори нам колико често модел тачно предвиђа исход. Чини основну метрику за задатке класификације.

$$Accuracy = \frac{Correct\ predictions}{All\ predictions} \quad (1)$$

### II. Прецизност и осетљивост

Прецизност (енг. *precision*) представља однос тачно предвиђених позитивних запажања и укупних предвиђених позитивних запажања.

$$Precision = \frac{TN}{TP + FP} \quad (2)$$

При чему *TN* означава број узорака тачно предвиђених као негативна класа, *TP* број узорака тачно предвиђених као позитивна класа, односно *FP* погрешно предвиђених.

Осетљивост (енг. *recall*) је мера способности модела да исправно идентификује све релевантне случајеве међу стварним позитивним инстанцама.

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

### III. F1-score

Средину између прецизности и осетљивости чини *F1-score*. Често се користи за проблеме бинарне класификације, при чему висок означава добар баланс између прецизности и осетљивости.

$$F1 = \frac{2 * Precision * Recall}{Precision + Recall} \quad (4)$$

### IV. ROC-AUC score

Метода процене тачности модела *ROC-AUC* мери способност модела да разликује позитивне и негативне узорке у различитим граничним вредностима.

Пратећи само тачност као меру квалитета модела, показано је да не постоји значајна разлика уколико се користе различити улазни параметри. Међутим, пратећи и остале метрике, утврђено је да су вредности о боји ласерског зрака допринеле побољшању модела, а да у комбинацији са интензитетом зрака доприносе највећој прецизности (Табела 1).


ТАБЕЛА 1 РЕЗУЛТАТИ ОЦЕНЕ ТАЧНОСТИ МОДЕЛА

Улазни подаци	Accuracy	Precision	Recall	F1	ROC_AUC
Интензитет	87	24	10	16	50
RGB	91	80	35	49	67
Интензитет +RGB	92	91	38	51	68

### б) Предикција класа

Поред квантитативних параметара оцене тачности, често је један од најбољих показатеља за процену резултата визуелна интерпретација. У овој студији ће се модел који је показао највећу тачност применити и за евалуацију над неклаификованим подацима, па ће се и резултат класификације приказати у *Microstation* софтверу.

Обука модела над подацима који су ручно класификовани у складу са оценом тачности, омогућава да се креирани модел користи за предикцију класа над неклаификованим подацима (Слика 4). Модел који је показао највећу тачност је комбиновани модел, те је он примењен над неклаификованим делом облака, а њихова визуализација се може видети на слици.



Слика 4. Примена модела над неклаификованим подацима облака и његова визуализација

### 7. ЗАКЉУЧАК

Облак тачака, као важан тип геометријске структуре, захтева брзе и ефикасне алгоритме за његову обраду, а методе дубоког учења могу одговорити на овај изазов.

Ова студија је показала да је модел *Sequential* способан за класификацију облака тачака. Такође, показано је и да је додавање информација о боји ласерског зрака значајно допринело побољшању перформанси креираног модела.

Иако је применом комбинованог модела, постигнута тачност од преко 90%, модел је направио и одређене грешке при класификацији. Најчешћи проблем представља мешање високе вегетације и објеката. Улазне податке чине подаци снимљени из ваздуха, те је врло честа појава била преклапање делова кровова дрвећем, па је питање да ли би се и ручном класификацијом постигло добра екстракција ових делова.

### 8. ЛИТЕРАТУРА

- [1] Saifullahi A. B., Shangshu Y., Cheng W., Jibril M.A., Jonathan L., "Review: Deep Learning on 3D Point Clouds"
- [2] Bayu A., Wibisono A., Wisesa H. A., Intizhami N. S., Jatmiko W., Gamal A., "Semantic Segmentation of Lidar Point Cloud in Rural Area", 2019 *IEEE International Conference on Communication, Networks and Satellite*
- [3] <https://www.simplilearn.com/data-preprocessing-in-machine-learning-article> (приступљено у октобру 2023.)

### Кратка биографија:



**Галина Јанковић** рођена је у Новом Саду 2000. године. Основне академске студије на Факултету техничких наука, смер Геодезија и геоинформатика, уписала је први пут 2018. године, а дипломирала 2022. године. Исте године уписује и мастер студије на истом смеру.

контакт:

[galina.jankovic369@gmail.com](mailto:galina.jankovic369@gmail.com)