

Detekcija i klasifikacija saobraćajnih znakova

Cilj ovog rada je detekcija i klasifikacija saobraćajnih znakova i upoređivanje korišćenih metoda. Za testiranje sistema za detekciju i klasifikaciju korišćenjene su dve baze: German Traffic Sign Recognition Benchmark (GTSRB) i German Traffic Sign Detection Benchmark (GTSDB): GTSRB za klasifikaciju, a GTSDB za detekciju. Pre primena metoda za detekciju znakova, izvršena je predobrada slike: slika je prebačena iz RGB kolor sistema, u sistem koji je pogodniji za manipulaciju sa bojama, HSV kolor sistem, nakon čega je urađena binarizacija po komponentama. Nakon toga je na celu sliku primenjena erozija, odvojeno po komponentama crvene i plave boje. Saobraćajni znakovi detektovani su metodom korelacije i metodom lokalnih minimuma. Za klasifikaciju korišćena su dva metoda: template matching i treniranje neuronske mreže. Tačnost metode korelacije i lokalnih minimuma zavisi od veličine znakova. Za znakove manje od 50 piksela, metodom korelacije dobijena je tačnost od 22%, a metodom lokalnih maksimuma 26%. Za znakove veće od 50 piksela metodom korelacije dobijena je tačnost od 55%, a metodom lokalnih maksimuma 65%. Tačnost klasifikacije primenom template matchinga iznosi 49.6%, dok tačnost neuronske mreže iznosi 84.3%. Veća tačnost neuronske mreže u odnosu na template matching metod je očekivana pošto template matching nije pogodan za detektovanje rotiranih znakova.

Uvod

Detekcija i klasifikacija saobraćajnih znakova su dva problema kojima se trenutno bavi kompjuterska vizija. Pošto neopažanjem nekog saobraćajnog znaka vozač može da ugrozi svoju bezbednost i bezbednost drugih učesnika u saobraćaju, detekcija i klasifikacija saobraćajnih znakova ima primenu u sistemima za pomoć vozačima (ADAS) (Stallkamp *et al.* 2012), takođe imaju i primenu i u samovozećim automobilima (Houben *et al.* 2013). Saobraćajni znaci su dizajnirani da se ističu bojama, oblikom, kao i natpisima i da budu lako vidljivi i prepoznativi od strane ljudi. Samim tim je dosta olakšana njihova pravilna detekcija i klasifikacija.

Ovaj rad se može podeliti na dva dela. To su detekcija saobraćajnih znakova i klasifikacija saobraćajnih znakova. U okviru detekcije je potrebno detektovani saobraćajni znak na slici i odrediti njegov konkretan položaj. Klasifikacija se bavi raspoređivanjem slika saobraćajnih znakova u klase tj. grupe. Jednu grupu čine slike saobraćajnih znakova koji imaju isto značenje.

Pre nego što se pristupi detekciji saobraćajnih znakova potrebno je izvršiti prethodnu obradu (predobradu) slike da bi se u toku same detekcije iskoristilo što više informacija sa slike. Kao što je opisano u radu Vishwanathan *et al.* (2017) trenutno se za detekciju saobraćajnih znakova najčešće koriste konvolucione neuronke mreže (KNN). U radu Zhu *et al.* (2016) je korišćen metod korelacije. Metod lokalnih maksimuma je korišćen u radu Gil-Jiménez *et al.* (2005). U ovom radu će biti upoređena uspešnost metoda korelacije i metoda lokalnih maksimuma.

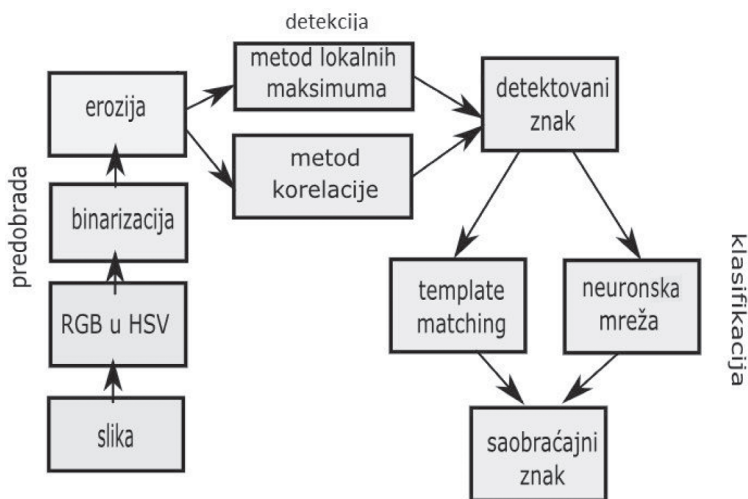
Milica Aleksić (2001), Niš, Zelena 28b, učenica 2. razreda Gimnazija „Svetozar Marković” u Nišu

Ervin Seke (1998), Zrenjanin, Dimitrija Tucovića 1, učenik 4. razreda Zrenjaninske gimnazije

MENTORI:

Sofija Petrović, student Elektrotehničkog fakulteta Univerziteta u Beogradu

Ratko Amanović, student Elektrotehničkog fakulteta Univerziteta u Beogradu



Slika 1. Blok šema predobrade slike i detekcije i klasifikacije saobraćajnog znaka

Figure 1. Block diagram of image preprocessing and traffic sign detection and classification

Klasifikacija se može raditi treniranjem neuronske mreže (Srećković i Graovac 2010), a može i korišćenjem template matchinga (www.automatika.rs). U ovom radu će se uporediti uspešnost ova dva metoda u klasifikaciji saobraćajnih znakova.

Korišćeni algoritam sastoji se iz tri dela: predobrada slike, detekcija saobraćajnog znaka i klasifikacija saobraćajnog znaka. Blok šema algoritma prikazana je na slici 1. Predobrada slike se sastoji iz prebacivanja slike iz RGB sistema boja u HSV sistem boja, binarizacije slike i erozije slike. U okviru detekcije upoređivani su metod korelacije i metod lokalnih maksimuma. Dalje na klasifikaciju se prosleđuju samo oni delovi slike za koje se pretpostavlja da se na njima nalazi saobraćajni znak. U okviru klasifikacije upoređivani su metodi neuronskih mreža i template matching-a. Kao izlaz klasifikacije se dobija ime znaka koji se nalazi na slici.

Pošto se kod metoda korelacije izgled potencijalnih znakova upoređuje sa izgledom pravih znakova, a kod metoda lokalnih maksimuma samo broji koliko svaki potencijalni znak ima uglova, očekuje se da metod korelacije ima dosta manje false positive detekcija. Ovo je prva hipoteza. Kod metoda korelacije potencijalni znakovi upoređivani su sa znakovima koji nisu rotirani. Kao druga hipoteza se pretpostavlja da će metod lokalnih maksimuma imati više true positive detekcija nego metod korelacije. Cilj rada je poređenje dva metoda za detekciju saobraćajnih znakova i dva metoda za klasifikaciju saobraćajnih znakova.

Metod

U ovom poglavlju će biti detaljno razmatrani svi metodi korišćeni za predobradu slike, detekciju i klasifikaciju saobraćajnih znakova. Predobrada slike priprema sliku da se što tačnije i preciznije detektuju delovi slike u kojima se potencijalno nalazi saobraćajni znak. Svaki deo slike koji se detektuje kao potencijalno saobraćajni znak se prosleđuje klasifikatoru. U okviru klasifikacije se potom određuje da li je neki potencijalni znak uopšte znak i ako jesto određuje se koji je to znak.

Predobrada slike

Da bi se na slici što lakše detektovao saobraćajni znak potrebno je izvršiti predobradu slike. Predobrada slike se sastoji iz 3 dela: pretvaranje slike iz RGB sistema boja u HSV sistem boja, binarizacije slike i erozije slike.

Prvi deo predobrade slike čini pretvaranje slike iz RGB u HSV sistem boja. HSV sistem boja je intuitivniji ljudima i zato omogućava lakše baratanje sa informacijama o svakom pikselu. RGB sistem boja nam daje informaciju o tome koliko se crvene, zelene i plave boje nalazi u svakom pikselu, dok nam HSV sistem boja daje informacije o tome koja boje je neki piksel, koliko je zasićenje te boje i kolika je količina te boje na tom pikselu.

Binarizacija je proces u kome se određuje koji su sve pikseli određene boje na nekoj slici. U ovom radu se traže pikseli crvene, plave i bele

Tabela 1. Parametri binarizacije

	Hue	Saturation	Value
Crvena	$0 < H < 20, 300 < H < 360$	$0.2 < S < 1$	$0.2 < V < 1$
Plava	$190 < H < 270$	$0.2 < S < 1$	$0.1 < V < 1$
Bela	$0' < H < 360$	$0 < S < 0.1$	$0.85 < V < 1$

boje. Za svaku boju se pravi matrica veličine početne slike. Ukoliko je određeni piksel na početnoj slici crvene, plave ili bele boje tada se u odgovarajućoj matrici na odgovarajućem mestu upisuje 1. Na svim ostalim mestima je upisano 0. Parametri na osnovu kojih se određuje da li je na slici neki piksel crvene, plave ili bele boje dati su u tabeli 1.


Različite vrednosti ovih parametara su testirane na uzorku od 10 slika iz baze. Odabrane su vrednosti za koje se pretpostavlja da će omogućiti da se izdvoje samo pikseli željene boje. Kao parametri binarizacije su odabrani parametri za koje je najveći odnos broja tačno detektovanih znakova i broja oblika koji su detektovani kao znaci, a nisu znaci. Pod tačno detektovan znak se smatra svaki detektovani oblik kod kog se površina kvadrata opisanog oko njega poklapa sa više od 50% sa površinom kvadrata opisanog oko stvarnog znaka na slici. Ova vrednost odabrana je na osnovu rada Zitnick i Dollar (2014). Informacije o tačnim položajima znakova na slici su sastavni deo korišćene baze.

Na kraju predobrade vršena je erozija slike da bi se razdvojili svi znakovi koji su na početnoj slici iste boje i veoma blizu jedan drugon, a posle

binarizacije su ostali spojeni na binarizovanim slikama. Takođe erozijom je smanjem i šum na slici. To je rađeno tako što je svaki piksel koji ima vrednost 1 i u čijoj okolini svi pikseli imaju vrednost 1 zadrži vrednost 1, dok svi ostali pikseli koji ne ispunjavaju ova dva uslova dobijaju vrednost 0.


Detekcija

Cilj detekcije je da se na fotografiji saobraćaja pronađe oblast fotografije na kojoj se potencijalno nalazi saobraćajni znak. U ovom radu su korišćena dva metoda za detekciju saobraćajnih znakova, i to: metod lokalnih maksimuma (Gil-Jiménez *et al.* 2005) i metod korelacije (Zhu *et al.* 2016). U okviru oba metoda se za svaki potencijalni saobraćajni znak analizira udaljenost ivičnih piksela od geometrijskog centra znaka u zavisnosti od ugla pod kojim se oni nalaze u odnosu na horizontalu koja prolazi kroz centar znaka. Udaljenost je izražena u pikselima. Na slici 2 nalazi se primer ove zavisnosti kod nasumično odabranog pravougaonog znaka iz GTSDDB baze. U okviru detekcije analizirani su znaci trougaonog i četvorougaoonog oblika.



Slika 2. Zavisnost udaljenosti ivičnih piksela oblika od ugla pod kojim se oni nalaze u odnosu na horizontalu koja prolazi kroz geometrijski centar

Figure 2. Dependence of the distance of edge shape pixels from the angle of their position in relation to the horizontal line that goes through the geometric center



Slika 3. Templejt za znak trougaonog oblika. Relativna udaljenost predstavlja udaljenost ivice od centra u odnosu na najudaljeniji piksel.

Figure 3. Template for the triangular shape sign. The relative distance is the distance between the edge and the center in relation to the most distant pixel.

Metod lokalnih maksimuma. U okviru ovog metoda je analiziran broj ekstremuma u okviru opisane zavisnosti. Primećuje se da za svaki oblik postoji tačno određen broj maksimuma i minimuma. U okviru ovog metoda brojeni su lokalni maksimumi kojih trougaoni znakovi imaju 3, a pravougaoni 4. Pod maksimumom se smatra svaka tačka iz ove zavisnosti koja je veća od oba svoja suseda.

Metod korelacije. Metod korelacije, kao što mu i ime kaže, računa korelaciju između dva niza udaljenosti ivicnih piksela od centra. Prvi niz je dobijen iz već poznatog modela (templejta) nekog oblika (trougla ili četvorougla), a drugi od oblika koji je detektovan sa slike. Templejt znak je dobijen od proizvoljnog znaka iz baze. Ukoliko je koeficijent korelacije veći od 0.8, smatra se da detektovan oblik pripada vrsti oblika kojoj pripada templejt. U okviru ovog rada se nismo bavili određivanjem ovog koeficijenta, već je on odabran eksperimentalno. Na slici 3 predstavljen je template za znak trougaonog oblika.

Klasifikacija

Klasifikacija slika vršena je dvema metodama. Prva metoda je klasifikacija primenom template matchinga, a druga je primenom neuronske mreže.

Primena template matchinga. Iz svake klase znakova u trening setu izdvojena je reprezentativna slika. Kao reprezentativna uzeta je ona slika na kojoj se najbolje vidi odgovarajući saobraćajni znak. Iz svake reprezentativne slike izdvojena je sadržina znaka. Dobijena slika predstavlja takozvani template. Svaka slika

upoređivana je sa templejtma znaka istog oblika (trougao, četvorougao) kao znak sa slike. Prikom svakog upoređivanja računato je poklapanje slike i templejta (cross correlation). Slika je svrstana u klasu sa čijim templejtom ima najveće poklapanje.

Primena neuronske mreže. Pomoću Matlab je istrenirana neuronska mreža na bazi slika. Ulaz mreže je slika koja sadrži saobraćajni znak. U okviru ulaznog sloja neuronske mreže jedan čvor predstavlja jednu komponentnu HSV sistema boja jednog piksela slike. U okviru izlaznog sloja neuronske mreže jedan čvor predstavlja jedan tip saobraćajnog znaka. Određeni čvor u okviru izlaznog sloja je aktivan, tj. ima vrednost 1, u slučaju da se na ulaznoj slici nalazi odgovarajući saobraćajni znak. Takođe postoji i jedan čvor koji je aktivan u slučaju da se na ulaznoj slici ne nalazi saobraćajni znak. Neuronska mreža se sastoji od 10 slojeva.

Baze podataka

U okviru ovog rada su korišćene dve baze podataka, a to su baze GTSDB i GTSRB.

GTSDB (Houben *et al.* 2013) je baza sadrži 900 slika saobraćaja. Primer slike iz ove baze se nalazi na slici 4. Takođe ova baza sadrži i informacije o tome gde se sve na slikama nalaze saobraćajni znaci. Za određivanje parametara binarizacije iskorišćeno je 10 nasumičnih slika iz ove baze, dok je za testiranje metoda za detekciju iskorišćeno 30 nasumično odabranih slika.

U okviru klasifikacije za treniranje i testiranje korišćenih metoda je korišćena baza GTSRB (Stallkamp *et al.* 2012). Primeri slika iz ove baze



Slika 4. Primer slike iz GTSDB baze

Figure 4. GTSDB dataset image example



Slika 5. Primeri slika iz GTSRB baze

Figure 5. GTSRB dataset image example

se nalazi na slici 4. GTSRB baza sadrži 39210 slika saobraćajnih znakova koji su podeljeni u 43 klase. Svaka klasa predstavlja određeni saobraćajni znak. U bazi se nalazi slike 30 različitih kvadratnih znakova, slike 31 osmougaoznog znaka, 770 slika znakova kružnog oblika i 576 znakova trougaonog oblika. U bazi se nalazi po 30 slika svakog saobraćajnog znaka. U okviru ove baze se takođe nalaze informacije o tome koji se tačno saobraćajni znak nalazi na svakoj slici iz baze i na kom delu slike se nalazi. Pošto su slike iz baze veličine 15×15 piksela do 250×250 piksela sve slike su skalirane da budu veličine 30×30 piksela.

Ulazni sloj neuronske mreže ima 2700 čvorova. Izlazni sloj neuronske mreže ima 44 čvorova. Baza slika je podeljena u tri grupe: trening, vali-

dation i testing set. Za treniranje neuronske mreže je iskorišćeno 70% slika iz baze, dok je za validaciju i testiranje dobijene neuronske mreže iskorišćeno po 15% slika iz ove baze.

Rezultati i diskusija

Detekcija. U tabelama 2 i 3 predstavljen je broj tačno detektovanih znakova (true positive), broj nedetektovanih znakova (true negative) i broj elemenata koji ne predstavljaju znakove, a detektovani su kao saobraćajni znaci (false positive) za metod lokalnih maksimuma i korelacije. Rezultati u tabelama su podeljeni u tri grupe. Podela na grupe je urađena na osnovu veličine znaka. U tabelama 2 i 3 sa h je označeno koliko su udaljeni najviši i najniži piksel u svakom po-

Tabela 2. Broj true positive, true negative i false positive detekcija za metod lokalnih maksimuma

	$15 < h < 50$	$50 < h < 100$	$100 < h$
True positive	6	12	1
True negative	17	5	2
False positive	332	66	15

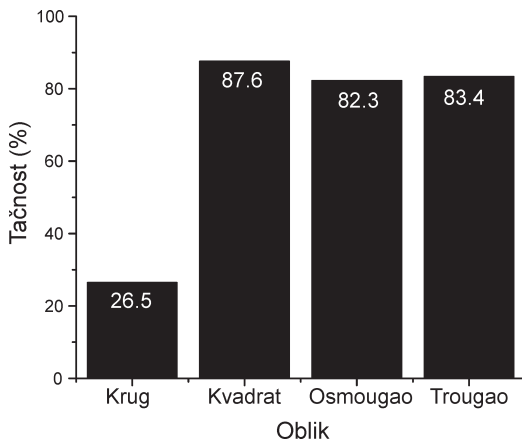
Tabela 3. Broj true positive, true negative i false positive detekcija za metod korelacije

	15 < h < 50	50 < h < 100	100 < h
True positive	5	10	1
True negative	18	7	2
False positive	5	6	2

tencijalnom saobraćajnom znaku izraženo u pikselima. Znakovi su grupisani na one koji su manji od 50 piksela, one koji su između 50 i 100 piksela i one koji su veći od 100 piksela. Iz izloženih rezultata se vidi da su obe hipoteze dokazane, tj. da metod lokalnih maksimuma ima više true positive detekcija dok metod korelacije ima manje false positive detekcija. Takođe se može zaključiti da tačnost detekcije raste sa povećanjem veličine znaka.

Klasifikacija. Tačnost template matching metode iznosi 49.6%. Na slici 6 prikazana je tačnost ove metode za znakove grupisane po obliku.

Najveća tačnost postignuta je pri klasifikaciji znakova kvadratnog oblika i ona iznosi 87.6%, a sledeća po vrednosti je bila tačnost klasifikacije znakova trougaonih oblika koja iznosi 83.4%. Prilikom klasifikacije znakova oblika osmougla postignuta je tačnost od 82.3%. Najmanja tačnost dobijena je klasifikacijom znakova kružnog ob-



Slika 6. Tačnost template matchinga za znakove istog oblika

Figure 6. Accuracy of template matching method for classification of same shaped signs

lika i ona iznosi 26.5%. Različite vrednosti dobijene za tačnost klasifikacije različitih oblika znakova očekivane su zbog nejednakosti broja slika različitih oblika, tj. očekivano je da će tačnost klasifikacije znakova kvadratnog oblika, kojih ima najmanje u bazi biti najveća, dok će znakova okruglog oblika, kojih ima najviše u bazi biti najmanja zato što ima više slika nekog saobraćajnog znaka to se te slike više razlikuju od odabranog templejta.

Tačnost neuronske mreže za trening setu iznosi 86.7%, za validation set 81.2%, a za testing set iznosi 84.3%.

Zaključak

Na osnovu opisanih rezultata zaključuje se da je tačnost detekcije i klasifikacije veća u slučaju kada su znaci većih na slici. Od metoda za detekciju kao tačniji se pokazao metod lokalnih maksimuma. Iako metod korelacije ima nešto manju tačnost on ima dosta manje false positive detekcija što omogućava da se dosta manje potencijalnih znakova dalje prosleđuje na klasifikaciju. Ovo omogućuje da celokupan algoritam radi dosta brže. Za klasifikaciju kao tačniji metod pokazalo se treniranje neuronske mreže.

Zahvalnost. Milošu Stojanoviću na savetima koje nam je pružio tokom izrade projekta.

Literatura

- Gil-Jiménez P., Lafuente-Arroyo S., Gómez-Moreno H., López-Ferreras F., Maldonado-Bascón S. 2005. Traffic Sign Shape Classification Evaluation II: FFT Applied to the Signature of Blobs. *Signal Processing*, **88**: 2943.
- Hechri A., Hmida R., Mtibaa A. 2015. Robust road lanes and traffic signs recognition for driver assistance system. *International Journal of*

Computational Science and Engineering, **10** (1-2): 202.

Houben S., Stallkamp J., Schlipsing M., Salmen J., Igel C. 2013. Detection of Traffic Signs in Real-World Images. *The 2013 International Joint Conference on Neural Networks*.

Srećković U., Graovac S. 2010. Detekcija i osnovna klasifikacija saobraćajnih znakova u slici. U *Telekomunikacioni forum TELFOR*. Beograd, 23-25. novembar 2010, str. 701-704.

Stallkamp J., Schlipsing M., Salmen J., Igel C. 2012. Man vs. computer: Benchmarking machine learning algorithms for traffic sign recognition. *Neural Networks*, **32**: 323.

Vishwanathan H., Peters D., Zhang J. 2017. Traffic sign recognition in autonomous vehicles using edge detection. U *Proceedings of the ASME 2017 Dynamic Systems and Control Conference*. Tysons Virginia, USA, October 11-13, 2017.

www.automatika.rs.
<https://www.automatika.rs/baza-znanja/neuronske-mreze/uvod-u-neuronske-mreze.html>

Zhu Z., Liang D., Zhang S., Huang X., Li B., Hu S. 2016. Traffic-Sign Detection and Classification in the Wild. U *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, str. 2110-2118.

Zitnick C., Dollar P. 2014. Edge boxes: Locating object proposals from edge. *European Conference on Computer Vision 2014*

Milica Aleksić and Ervin Seke

Traffic Sign Detection and Classification

Computer vision is an area of computing which aims to enable computers to observe the world like people do. Methods for detection and classification of traffic signs have been compared in this paper. These methods can be used in the manufacturing of self-driving cars.

The given problem consists of two smaller problems – detecting traffic signs and their cor-

rect classification. Two datasets are used for testing detection and classification algorithms: German Traffic Sign Recognition Benchmark (GTSRB) and German Traffic Sign Detection Benchmark (GTSDB). The second dataset contains images of traffic and it is used for testing the detector of traffic signs, while the first base is used for training and testing classifiers.

Before the picture is let through the detector it must come in for preprocessing, which consists of transferring the picture from RGB to HSV system of color, binarization of the picture within the components of HSV and erosion of the picture.

During detection, every group of pixels is analyzed within the binarized pictures. If that group of pixels has a shape of a traffic sign, then it will be sent to the classifier. Firstly, the circular signs are detected using the standard deviation method. For the detection of the other shapes two other methods are used: local maxima method and correlation method. On the sample of 30 images consisting of signs bigger than 50 pixels, the correlation method detected 55% of signs, while it detected 22% of the signs smaller than 50 pixels. The local maxima method detected 65% signs bigger than 50 pixels and 26% of the signs smaller than 50 pixels. Also, note that 96% of the shapes that the local maxima method classified as signs were not actually signs, while the method of correlation detected 45%. From these results we can conclude that the local maxima method is more successful in detection, but a big issue with this method is that it slows down the execution of the algorithm because it falsely recognizes some shapes as signs and then forwards them to classifiers for processing.

Classification represents grouping images into certain groups named “classes”. Images from the GTSRB were arranged into 44 classes. Every class contained images of the same traffic sign except the 44th, which contained images that are not signs. Classification of the dataset is done using template matching and training neural network, as two separate methods. The accuracy of classification obtained with template matching is 49.6%, while the accuracy of the neural network is 84.3%. A higher accuracy of the neural network is expected. 