

RASPOZNAVANJE PROMETNIH ZNAKOVA

Ivan Filković


Mentor: Prof. dr. sc. Zoran Kalafatić

Sadržaj

- Motivacija, uvod
- Sustav za raspoznavanje prometnih znakova
- Skupovi podataka
- Rezultati testiranja
- Zaključak, budući ciljevi

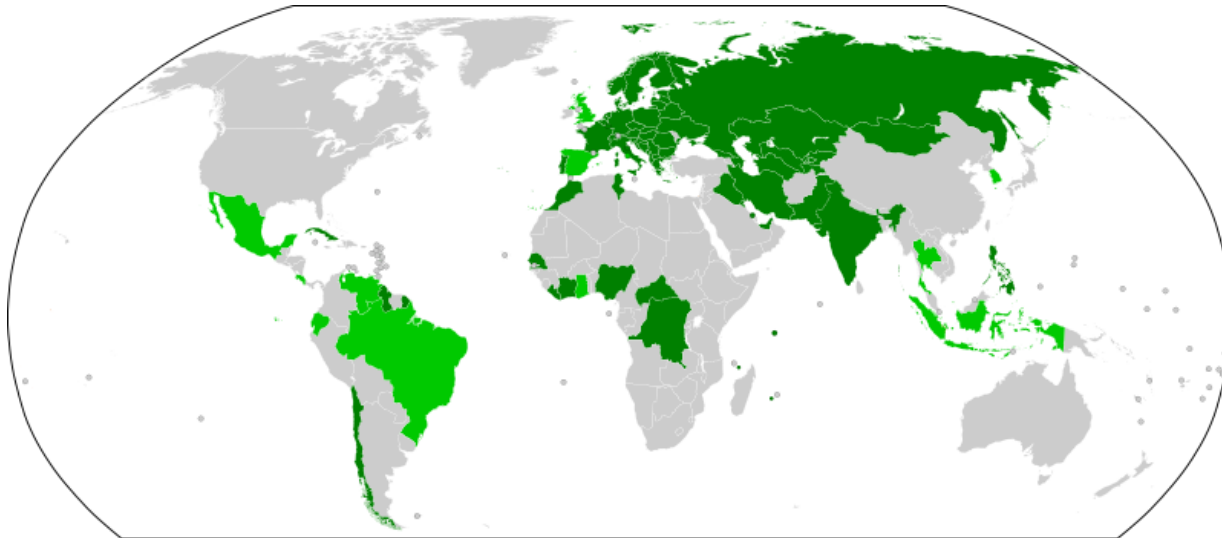
Motivacija

- Moderni sustavi za potporu vozaču (engl. ***Advanced Driver Assistance Systems*** - ADAS)
 - Sustavi održavanja cestovne infrastrukture
 - Autonomna vozila
-
- Primjena u projektu VISTA u okviru sustava za otkrivanje, raspoznavanje i praćenje prometnih znakova



Uvod

- Bečki sporazum o prometnim znakovima i signalizaciji (1968)
 - Standardizacija prometnih znakova (manje razlike između država)
 - 62 države potpisnice (Hrvatska; većina europskih država)






- **Problem:** nemogućnost izrade jedinstvenog sustava za otkrivanje i raspoznavanje prometnih znakova

Uvod – Prometni znakovi

- Osam osnovnih vrsta prometnih znakova (Bečki sporazum):

1. Znakovi upozorenja od opasnosti
2. Znakovi prednosti
3. Znakovi zabrane ili ograničenja
4. Znakovi obveze
5. Znakovi posebne regulacije prometa
6. Znakovi informacija, objekata ili usluga
7. Znakovi smjera, položaja ili naznake
8. Dopunske ploče



- Primjeri osnovnih vrsta prometnih znakova u Hrvatskoj

Uvod – Prometni znakovi (Hrvatska)

- A. Znakovi opasnosti
 - A01 – A50 → 50 znakova
- B. Znakovi izričitih zabrana
 - B01 – B62 → 62 znaka
- C. Znakovi obavijesti
 - C01 – C133 → 133 znaka
- D. Znakovi obavijesti za vođenje prometa
 - D01 – D17 → 17 znakova
- E. Dopunske ploče
 - E01 – E50 → 50 znakova

322 različita prometna znaka!!!

Uvod

- Prometni znakovi su jednostavni objekti strogo ograničeni svojim oblikom i bojom
- Osmišljeni da budu što uočljiviji čovjeku (intenzivne boje, pravilni oblici i reflektivna površina)
- **Problem:** reprezentacija koja odgovara čovjeku je nepogodna za računalo

- **Problem:**

- Promjena osvjetljenja
- Djelomična prekrivenost prometnih znakova
- Vremenski uvjeti
- Perspektiva prometnih znakova



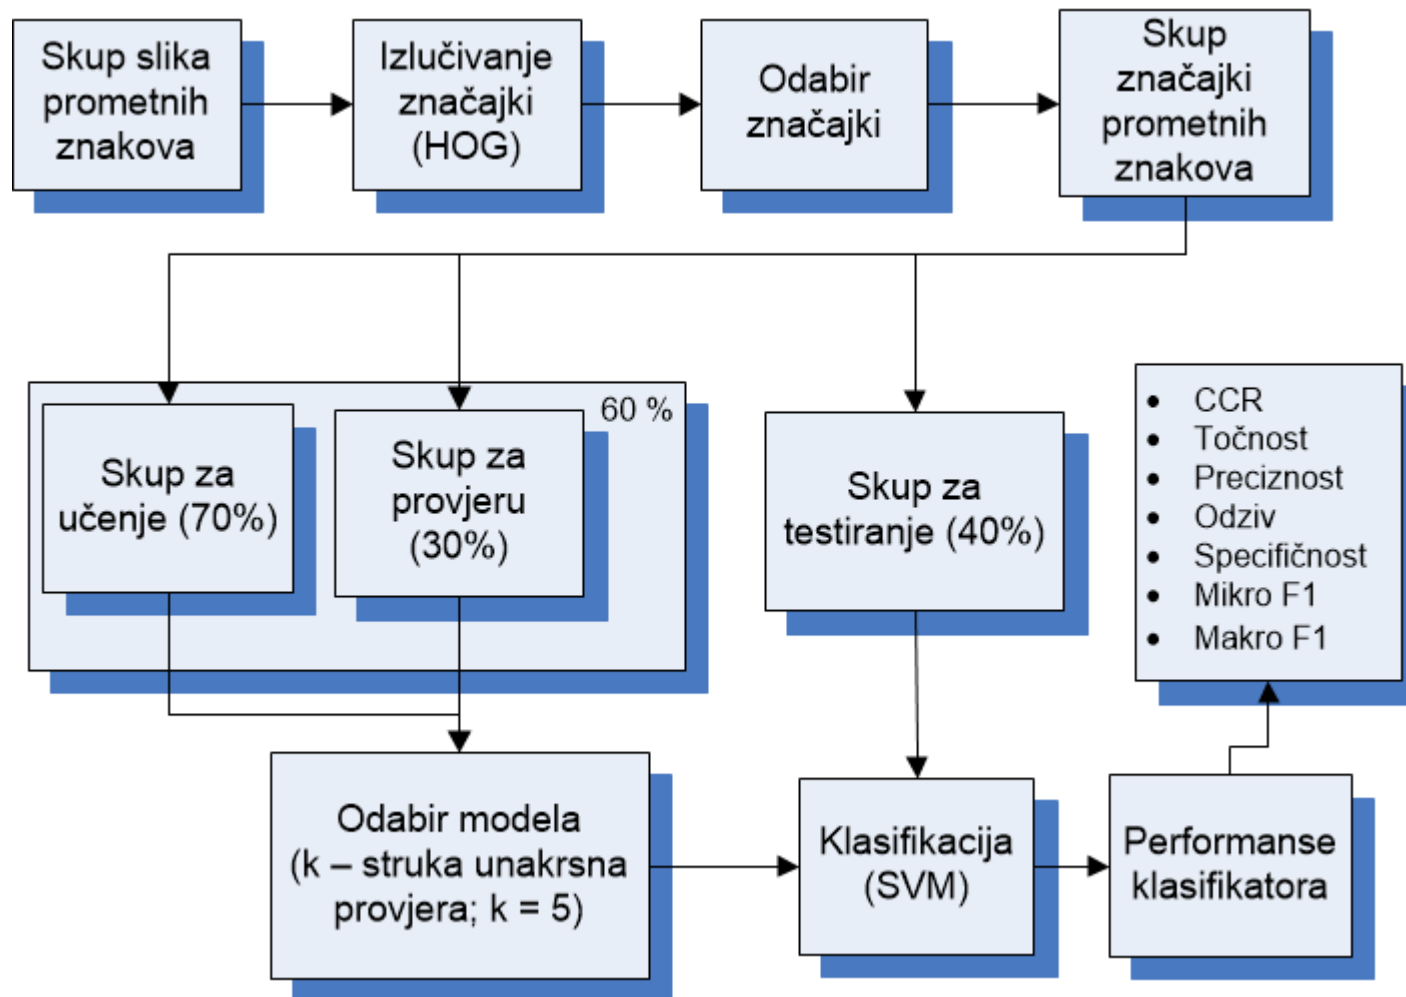
Uvod - Cilj

- Sustav raspoznavanja prometnih znakova
 - Robustan
 - Rad u realnom vremenu (ADAS)
 - Minimizirati troškove (jačina računala, karakteristike kamere; ADAS)
 - Maksimizirati performanse (ADAS)

Sustav za raspoznavanje prometnih znakova

- Raspoznavanje prometnih znakova → problem strojnog učenja (nadzirano učenje)
 - Najvažnije - kvalitetan skup podataka (skup prometnih znakova) koji dobro reprezentira dani problem
- Višerazredni klasifikacijski problem s neujednačenom zastupljenosti razreda
- **Problem:** 322 različita prometna znaka u Hrvatskoj → 322 razreda → težak klasifikacijski problem
- **Rješenje:** problem razdvojiti na više podproblema
 - Podskup prometnih znakova (npr. trokutasti, okrugli, znakovi ograničenja brzine) → novi problem

Sustav za raspoznavanje prometnih znakova



Skupovi podataka prometnih znakova

- 4 javno dostupna skupa podataka:
 - MASTIF - ***M**apping and **A**ssessing the **S**tate of **T**raffic **I**nfrastructure* skup podataka
 - GTSRB - ***G**erman **T**raffic **S**ign **R**ecognition **B**enchmark* skup podataka
 - BTSC - ***B**elgium **T**raffic **S**ign **C**lassification* skup podataka
 - STS - ***S**wedish **T**raffic **S**ign* skup podataka
- **Terminologija:**
 - Jedan fizički prometni znak = instanca prometnog znaka
 - Trag prometnog znaka - primjeri za učenje instance prometnog znaka

MASTIF skup podataka

- FER
- Kamera:
 - Pričvršćena na prednji dio automobila
 - SDTV rezolucija: 720 x 576
 - FOV (engl. *Field of View*): 48°
 - FPS: 25
- Tri podskupa snimljena 2009, 2010 i 2011 godine
- **Problemi:**
 - Primjeri za učenje male rezolucije (20 x 20 do 90 x 90)
 - Prisutno zamućenje uslijed gibanja vozila
 - Korištena *interlaced* kamera za podskup 2009
 - Mali broj primjera za učenje nekih razreda



MASTIF skup podataka

- Podskup 2009:
 - # primjera za učenje: 6428
 - # razreda: 84
 - # traga: ~
 - # primjer/trag: 4-5
- Podskup 2010:
 - # primjera za učenje: 3889
 - # razreda: 78
 - # traga: ~
 - # primjer/trag: 4-5
- Podskup 2011:
 - # primjera za učenje: 1015
 - # razreda: 43
 - # traga: ~
 - # primjer/trag: 4-5



GTSRB skup podataka

- Stalkamp, Schlipsing, Salmen, Igel
- Kamera:
 - Prosilica GC 1380CH
 - 10 sati slikovne sekvence dobivene kamerom pričvršćenom na prednji dio vozila tijekom dana (Ožujak, Listopad i Studeni 2010)
 - Rezolucija: 1360 x 1024
 - FPS: 25
- # primjera za učenje: 51 840
- # razreda: 43
- # traga: 9
- # primjera/trag: barem 30
- Rezolucija primjera:
 - 15 x 15 do 222 x 193
- HOG1, HOG2, HOG3




Histogram Orijentiranih Gradijenata (HOG)

- Prebrojavanje različitih orijentacija gradijenata u lokaliziranim dijelovima slike
- Invarijantni na geometrijska i fotometričke transformacije
- Gusta mrežu uniformno raspoređenih ćelija
- **Ideja:** lokalni izgled i oblik objekta se može opisati razdiobom orijentacije gradijenta (rubova)

Parametri:

- Veličina ćelije (sl. el. x sl. el)
- Veličina bloka (#ćelija x #ćelija)
- #histograma po ćeliji
- Normalizacija
- Veličina odjeljka histograma
- Raspon histograma



HOG

*veličina vektora značajki =
#blokova x #ćelija po bloku x #odjeljaka po ćeliji*

- Pseudo kod:
 1. Postavi područje od interesa na prometni znak u slici
 2. Promijeni veličinu ulazne slike na 40 x 40 (npr. bilinearna interpolacija)
 3. Prebaci sliku iz RGB sustava boja u HSV sustav boja
 4. Izračunaj gradijentne slike u x i y smjeru (npr. Sobelov, Robertsov, Perwittov operator)



HOG


5. Izračunaj histograme orijentacije

- Amplituda gradijenta:

$$M = \sqrt{G_x^2 + G_y^2}$$

- Orijentacija gradijenta:

$$\Theta = \text{arc tg}\left(\frac{G_y}{G_x}\right)$$




HOG

5. Izračunaj pripadajuće integralne slike

$$I[x, y] = \sum_{\substack{x' \leq x \\ y' \leq y}} i[x', y']$$


- Zbroj vrijednosti svih slikovnih elemenata iznad i lijevo od slikovnog elementa $[x, y]$
- Nema operacija s pomičnim zarezom
- *Look-up* tablice



Histogram Orijentiranih Gradijenata (HOG)

6. Izračunaj vektor značajki

$$\text{značajka} = I[C] + I[A] - I[B] - I[D]$$



HOG

- Normalizacija bloka
 - Robusnost na promjene osvjetljenja

$$L2 - norma: \vec{f} = \frac{\vec{v}}{\sqrt{\|\vec{v}\|_2^2 + e^2}}$$

$$L1 - norma: \vec{f} = \frac{\vec{v}}{\|\vec{v}\|_1 + e}$$

$$L1 - korijen: \vec{f} = \sqrt{\frac{\vec{v}}{\|\vec{v}\|_1 + e}}$$

$$\|\vec{v}\|_k = \left(\sum_{i=1}^k |v_i|^k \right)^{\frac{1}{k}} ; k = 1, 2; e - mala konstanta (izbjegavanje singulariteta)$$

- invari

HOG


- HOG1 (1568)
 - skaliranje slika na 40 x 40 slikovnih elemenata pomoću bilinearne interpolacije
 - veličina ćelija je 5 x 5 slikovnih elemenata
 - veličina blokova je 2 x 2 ćelije
 - blokovi pomaknuti za 5 slikovnih elemenata u oba smjera
 - histogram ima 8 odjeljaka (orijentacija)
 - raspon histograma: 0 do 180 stupnjeva
 - pretprocesiranje: korišteni gradijenti iz \sqrt{RGB}
 - normalizacija: L2 norma
- HOG2(1568)
 - raspon histograma: 0 do 360 stupnjeva

HOG

- HOG3 (2916)
 - skaliranje slika na 40 x 40 slikovnih elemenata pomoću bilinearne interpolacije
 - veličina ćelija je 4 x 4 slikovnih elemenata
 - veličina blokova je 2 x 2 ćelije
 - blokovi pomaknuti za 5 slikovnih elemenata u oba smjera
 - histogram ima 9 odjeljaka (orijentacija)
 - raspon histograma: 0 do 180 stupnjeva
 - pretprocesiranje: korišteni gradijenti iz \sqrt{RGB}
 - normalizacija: L2 norma

Stroj s potpornim vektorima

- Jedan-naspram-ostali ($K - 1$ klasifikatora)
- Pronalazak hiperravnine koja maksimizira marginu razdvajanja
 - Hiperravnina definirana primjerima (potporni vektori)
- Linearni SVM (C)
 - C malen: margina razdvajana velika nauštrb pogrešne klasifikacije
 - C velik: manja margina



Evaluacija klasifikatora

- **Stopa točne klasifikacije**

$$CCR = \frac{TP}{\#primjera}$$

- **Točnost** – udio točno klasificiranih primjera u skupu svih

$$Acc = \frac{TP + TN}{TP + TN + FP + FN}$$

- **Preciznost** – udio točno klasificiranih primjera u skupu pozitivno klasificiranih

$$P = \frac{TP}{TP + FP}$$

- **Odziv** – udio točno klasificiranih primjera u skupu pozitivnih

$$R = \frac{TP}{TP + FN}$$

- **Specifičnost** – udio točno klasificiranih primjera u skupu negativnih

$$S = \frac{TN}{TN + FP}$$

- **Mikro F1**

$$F_1^{micro} = \frac{2PR}{P + R}$$

- **Makro F1**

$$F_1^{macro} = \frac{1}{K} \sum_{j=1}^K F_j$$

$$F_j = \frac{2P_j R_j}{P_j + R_j}$$

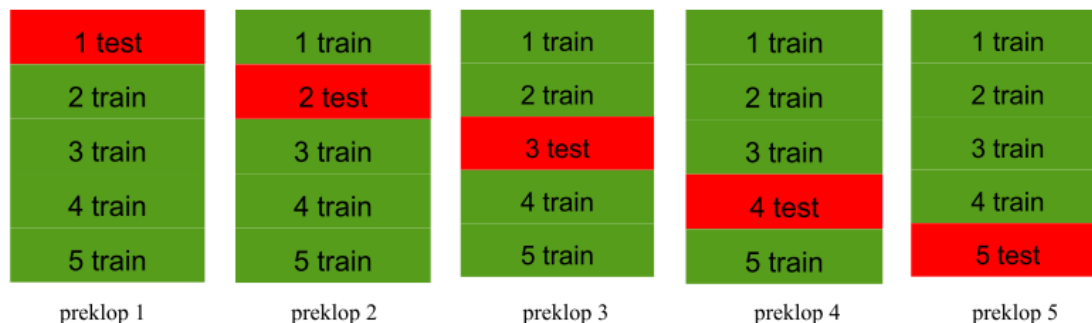
Evaluacija klasifikatora

- Višerazredna klasifikacija
 - Neke mjere nemaju smisla
 - Točnost
 - Specifičnost
 - CCR = Preciznost = Odziv = Mikro F1
 - Makro F1 je tipično stroža mjera
 - Slabo zastupljene klase → klasifikacija lošija

Odabir modela – k-struka unakrsna provjera

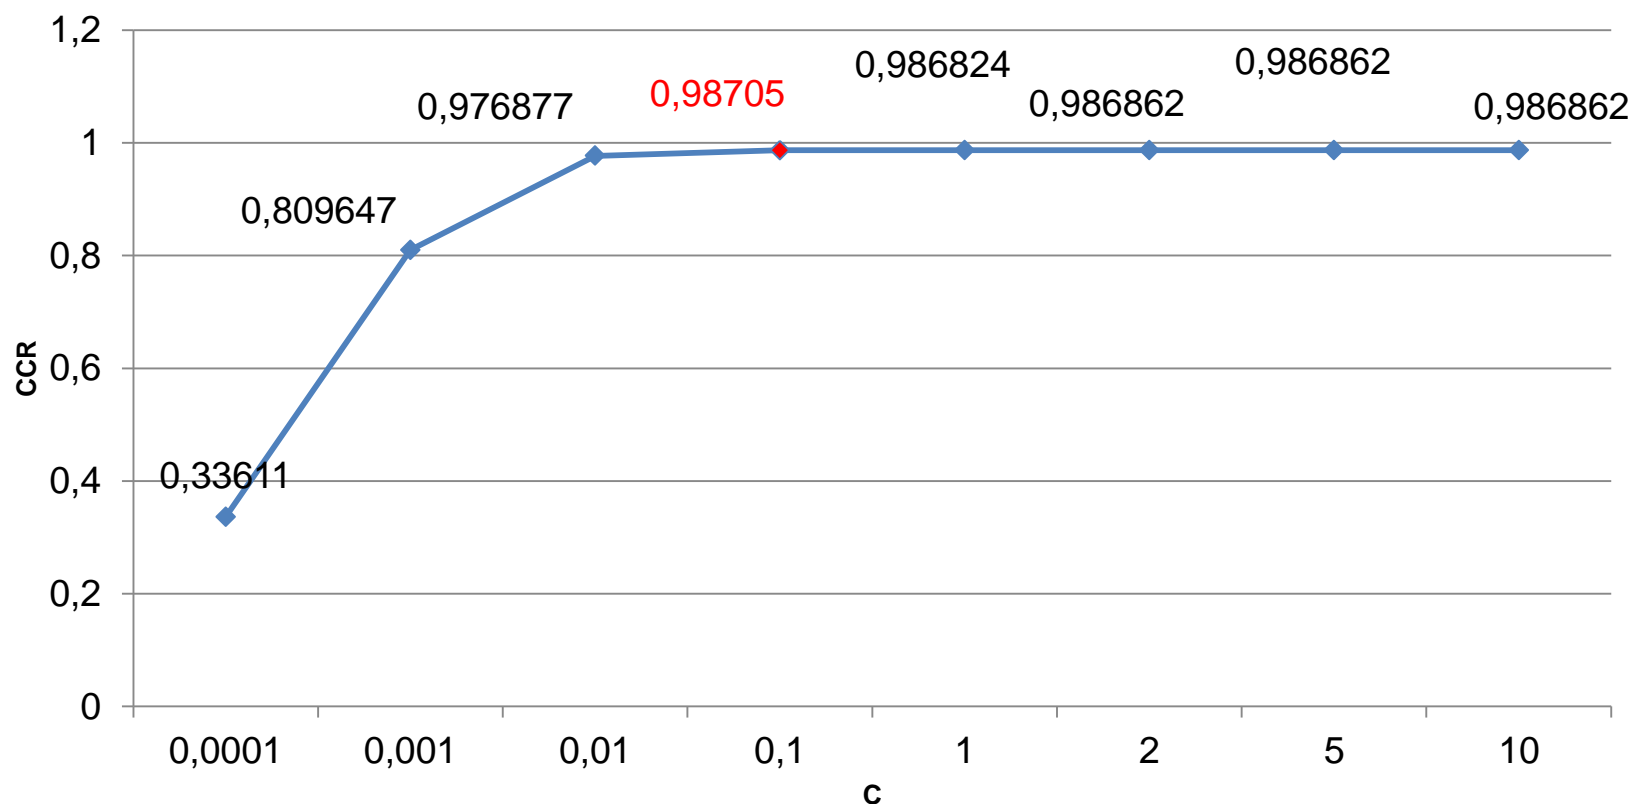
- Skup podataka prometnih znakova se dijeli na tri skupa:
 - Skup za učenje
 - Skup za provjeru
 - Skup za testiranje
- **VAŽNO:**
 - Skupove dijeliti na rezoluciji traga
 - Inače nepoštена procjena točnosti generalizacije
- Procjena pogreške – prosječna pogreška na k preklopa

• $k = 5$



Odabir modela – primjer

- Klasifikator: linearni SVM
- Značajke: HOG1

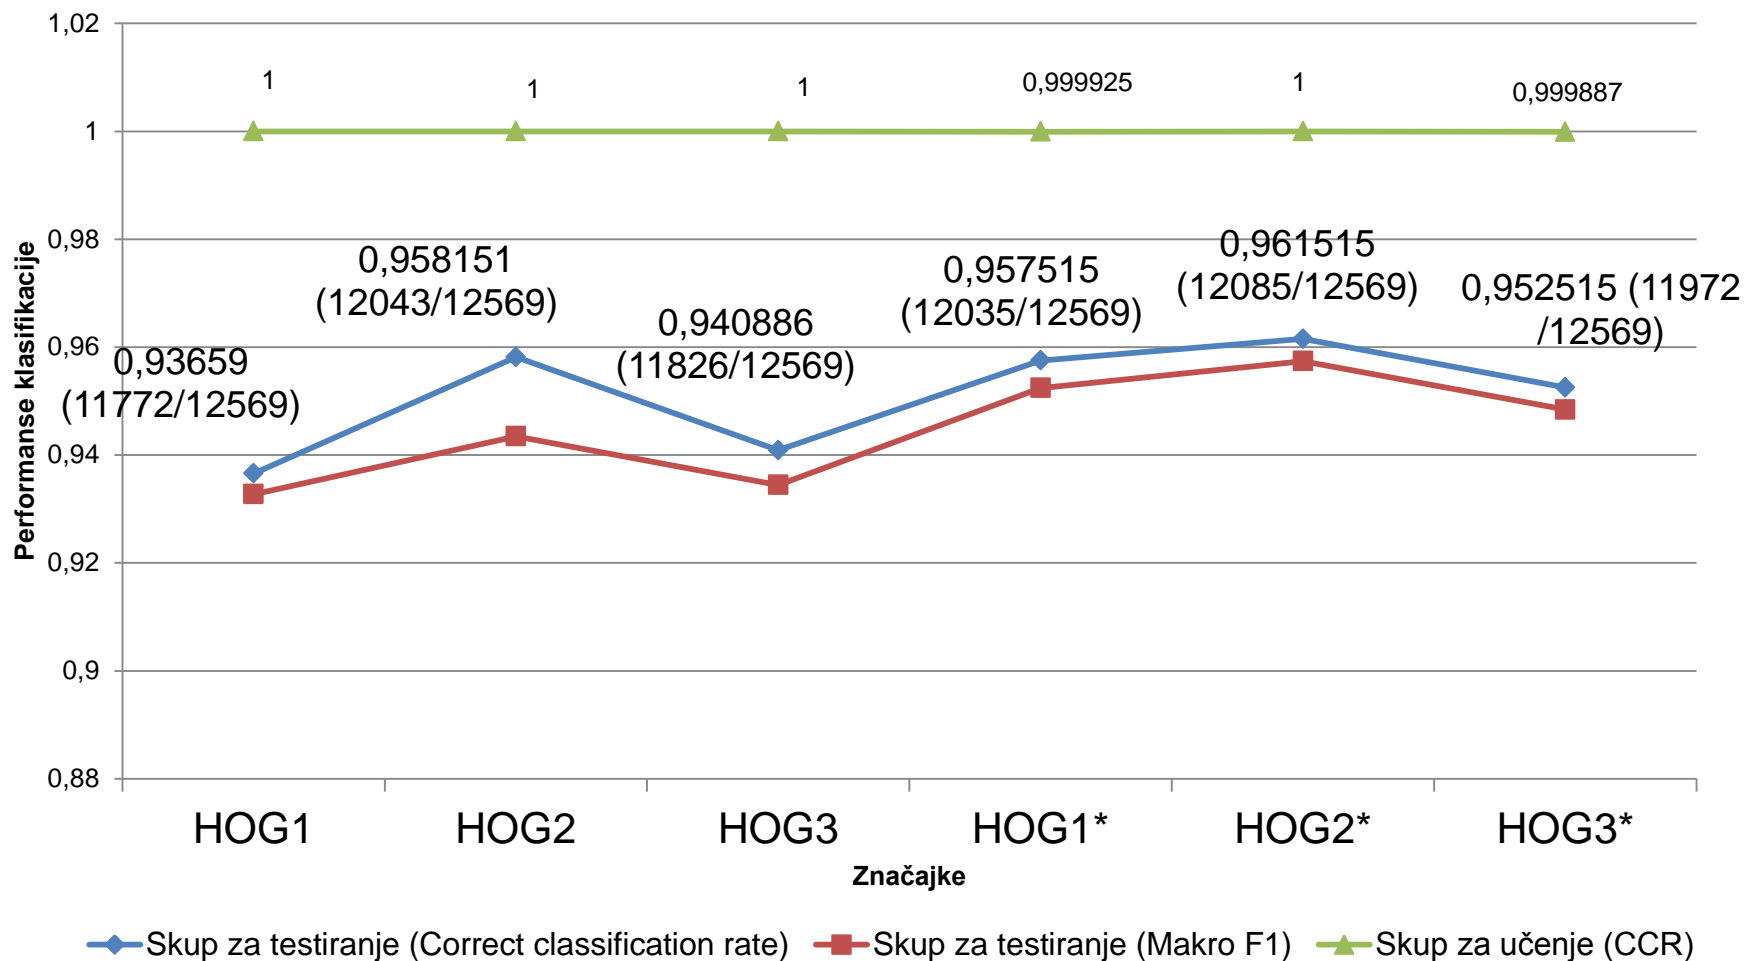


Implementacija

- C++
- OpenCV
- libSVM
- *Shark machine learning library*

Rezultati testiranja

- GTSRB, linearni SVM, $C = 0,01$



Zaključak, budući ciljevi

- Metode strojnog učenja su dobar put
 - Preliminarni rezultati
 - Literatura
- Klasifikatori
 - Diskriminativni/Generativni modeli (SVM / Logistička regresija)
 - Parametarski/Neparametarski modeli (Bayes / k- NN, Konvolucijske NN, DT)
 - Linearni/Nelinearni modeli
- Značajke
 - Boja
 - Haar
 - SIFT
 - LRF
 - Kombinacije
- Odabir značajki
 - LDA
 - PCA
 - Kombinacije
- Skupovi podataka
 - BTSC
 - STS
- Usporediti ispitne skupove podataka
 - Sličnosti
 - Razlike

Hvala!