# Pregled metoda za višerazrednu detekciju objekata

## Istraživački seminar

Valentina Zadrija, dipl. ing.

Mireo d.d.

Studeni, 2013

# Sadržaj


1. Uvod
2. Višerazredna detekcija objekata
   - Struktura klasifikatora
     - Udruživanje
     - Monolitni klasifikator
   - Postupci učenja
     - Učenje ulančavanjem
     - Učenje ojačavanjem
     - Stroj s potpornim vektorima
3. Višerazredna detekcija znakova
   - Prometni znakovi
   - Eksperimenti
4. Zaključak

# Uvod I

## Višerazredna detekcija objekata

Prepoznavanje različitih objekata u složenim scenama

- detekcija objekata s velikom unutar-razrednom varijacijom
  - razredi - različite poze, kutevi gledanja
  - problem particioniranja objekta u razrede
- istovremena detekcija različitih tipova objekata

## Nelinearna decizijska ravnina "objekti - pozadina"

- heterogeni razredi objekata
- pozadina - sve osim objekta
- utjecaj okoline (osvjetljenje, djelomično sakriveni objekti)

# Uvod II

## Automatizacija sigurnosnih inspekcija cestovne mreže

- verifikacija ispravnosti prometne signalizacije
- detekcija i raspoznavanje prometnih znakova

Primjena metoda višerazredne detekcije objekata za detekciju različitih tipova prometnih znakova

# Višerazredna detekcija objekata

Dva osnovna pristupa

1. treniranje nezavisnih detektora za svaki razred
   - [Viola and Jones, 2003]
2. treniranje zajedničke klasifikacijske funkcije za sve razrede
   - [Torralba et al., 2007]
   - [Huang et al., 2007]
   - [Wu and Nevatia, 2007]
   - [Yuan et al., 2011]
   - [Kim and Cipolla, 2013]

# Višerazredna detekcija objekata

Dva osnovna pristupa

1. treniranje nezavisnih detektora za svaki razred
   - [Viola and Jones, 2003]
2. treniranje zajedničke klasifikacijske funkcije za sve razrede
   - [Torralba et al., 2007]
   - [Huang et al., 2007]
   - [Wu and Nevatia, 2007]
   - [Yuan et al., 2011]
   - [Kim and Cipolla, 2013]

Pregled gore navedenih metoda s obzirom na

- strukturu klasifikatora
- metodu učenja

# Struktura klasifikatora i postupci učenja

Dvije temeljne strukture

- Monolitni klasifikator
  - postupci učenja: stroj s potpornim vektorima (SVM), neuronske mreže (ANN)
- Ansambl - klasifikator dobiven udruživanjem osnovnih algoritama
  - postupci učenja: glasanje (ECOC, stacking, bagging), ojačavanje (engl. *boosting*), ulančavanje (engl. *cascading*)
  - poboljšavalju točnost u odnosu na individualne modele

*Problem*: kako binarni klasifikator proširiti za detekciju $N$ razreda?

- kodiranje „višerazrednosti“ u klasifikacijsku fiju monolitnog ili ojačanog klasifikatora
- stablaste ulančane strukture udruženih klasifikatora za hijerarhijski uređene razrede

# Struktura klasifikatora - udruživanje

Ojačavanje (engl. boosting)

- linearna kombinacija osnovnih klasifikatora

Ulančavanje (engl. cascading)

- osnovni klasifikatori sortirani prema složenosti
- sljedbenik se primjenjuje samo ako prethodnik daje pozitivan ishod
- prednost je brzina izvođenja: jednostavni klasifikatori na početku lanca odbacuju većinu pozadina

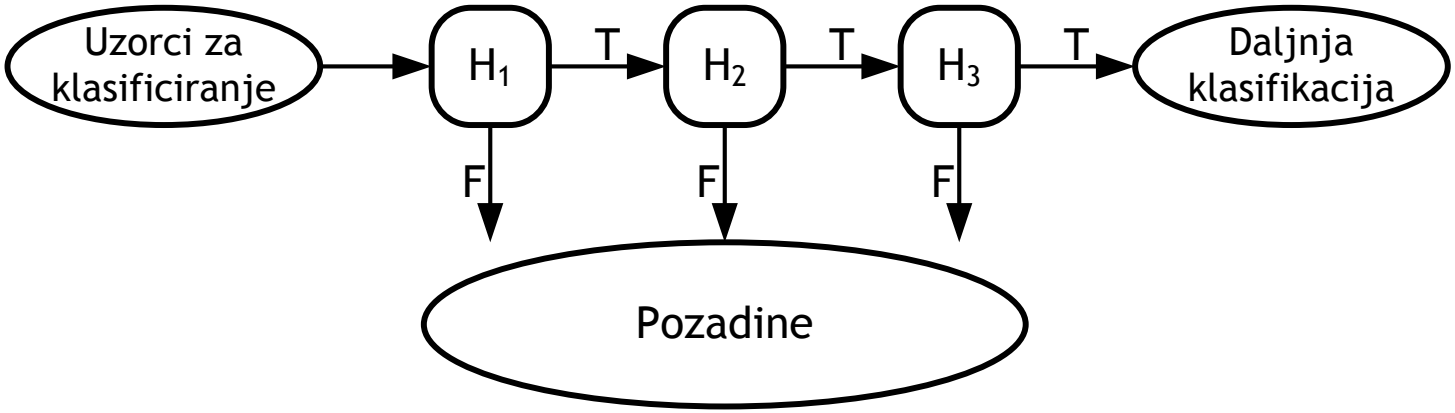

# Struktura klasifikatora - udruživanje

[Viola and Jones, 2003] - decizijsko stablo i $C$ individualno treniranih detektora za $C$ razreda

- pojedinačni detektor: lanac (kaskada) ojačanih klasifikatora
- detekcija iz različitih pogleda za lica
- primjeri za učenje ručno podijeljeni u razrede na temelju znanja o domeni
- značajan broj primjera po razredu
- broj detektora raste linearno sa brojem razreda $C$

# Struktura klasifikatora - udruživanje

[Torralba et al., 2007] - $C$ ojačanih detektora združeno treniranih za sve razrede

- ojačani klasifikatori dijele slabe klasifikatore (značajke)
- broj značajki raste logaritamski sa brojem razreda
- detekcija iz različitih pogleda i višerazredna detekcija za 21 razred
- primjeri za učenje ručno podijeljeni u razrede
- razredi nisu hijerarhijski strukturirani, preklapaju se

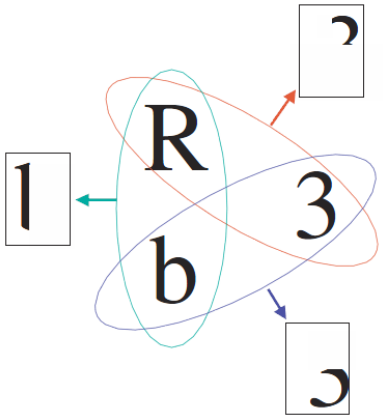

# Struktura klasifikatora - udruživanje

[Huang et al., 2007] - Stablo Pretraživanja u Dubinu (engl. *Width-First-Search tree*) (WFS)

- detekcija iz različitih pogleda za lica
- primjeri za učenje ručno podijeljeni razrede
- čvor stabla je ojačani klasifikator
- WFS stablo konstruirano na temelju znanja od domeni

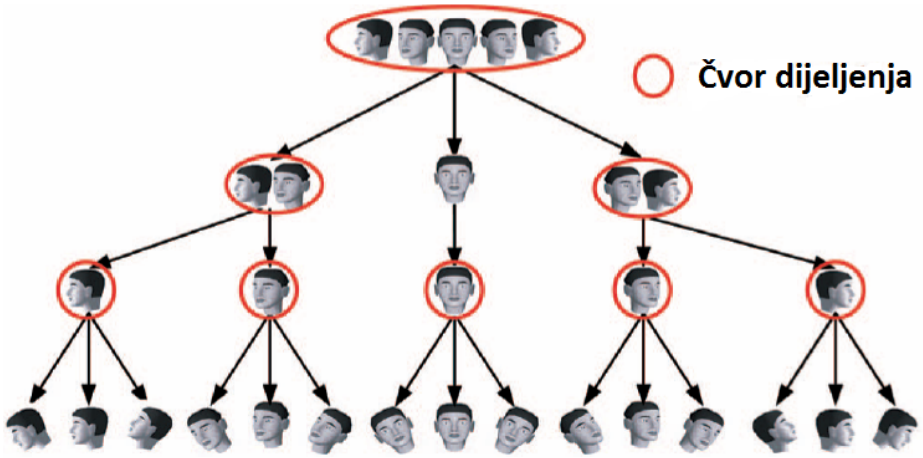

# Struktura klasifikatora - udruživanje

[Huang et al., 2007] - Stablo Pretraživanja u Dubinu (engl. *Width-First-Search tree*) (WFS)

- detekcija iz različitih pogleda za lica
- primjeri za učenje ručno podijeljeni razrede
- čvor stabla je ojačani klasifikator
- WFS stablo konstruirano na temelju znanja od domeni
  - svakom čvoru pridružen vektor odluke $G(x)$ - određuje kojim čvorovima djece se prosljeđuje uzorak

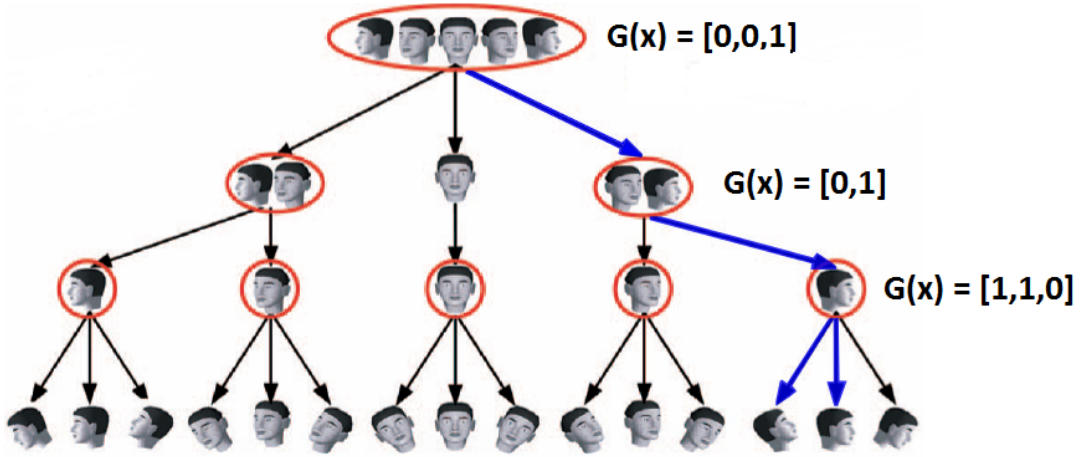

# Struktura klasifikatora - udruživanje

[Wu and Nevatia, 2007] - Grupiranjem izgrađeno Ojačano Stablo (engl. *Cluster Boosted Tree*) (CBT)

- ekvivalent WFS strukturi
- detekcija iz različitih pogleda za pješake i automobile
- CBT konstruirano pomoću grupiranja - automatska podjela objekta u razrede

# Struktura klasifikatora - udruživanje

[Wu and Nevatia, 2007] - učenje ojačanog klasifikatora integrirano s ulančavanjem te izgradnjom CBT

1. Čvor stabla na razini $l$ - slabi klasifikatori koji dijele značajku
   - jaki klasifikator $H_{kl}$ - čvorovi od korijena do razine $l$ u grani $k$
   - ulančavanje - određivanje granične vrijednosti $b_{kl}$ jakog klasifikatora $H_{kl}$

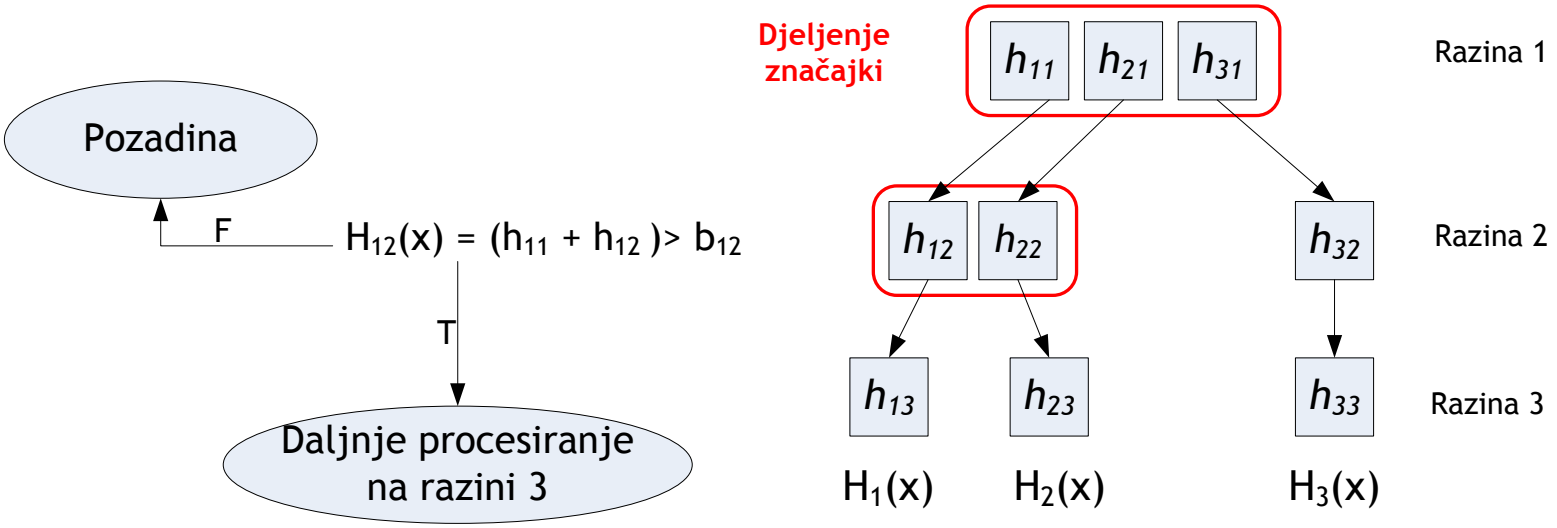

# Struktura klasifikatora - udruživanje

[Wu and Nevatia, 2007] - učenje ojačanog klasifikatora integrirano s ulančavanjem te izgradnjom CBT

2. Dijeljenje čvora - snaga slabog klasifikatora nije dovoljna za rješavanje problema
   - podjela primjera za učenje algoritmom $k$-srednjih vrijednosti na temelju do tad pronađenih značajki u grani

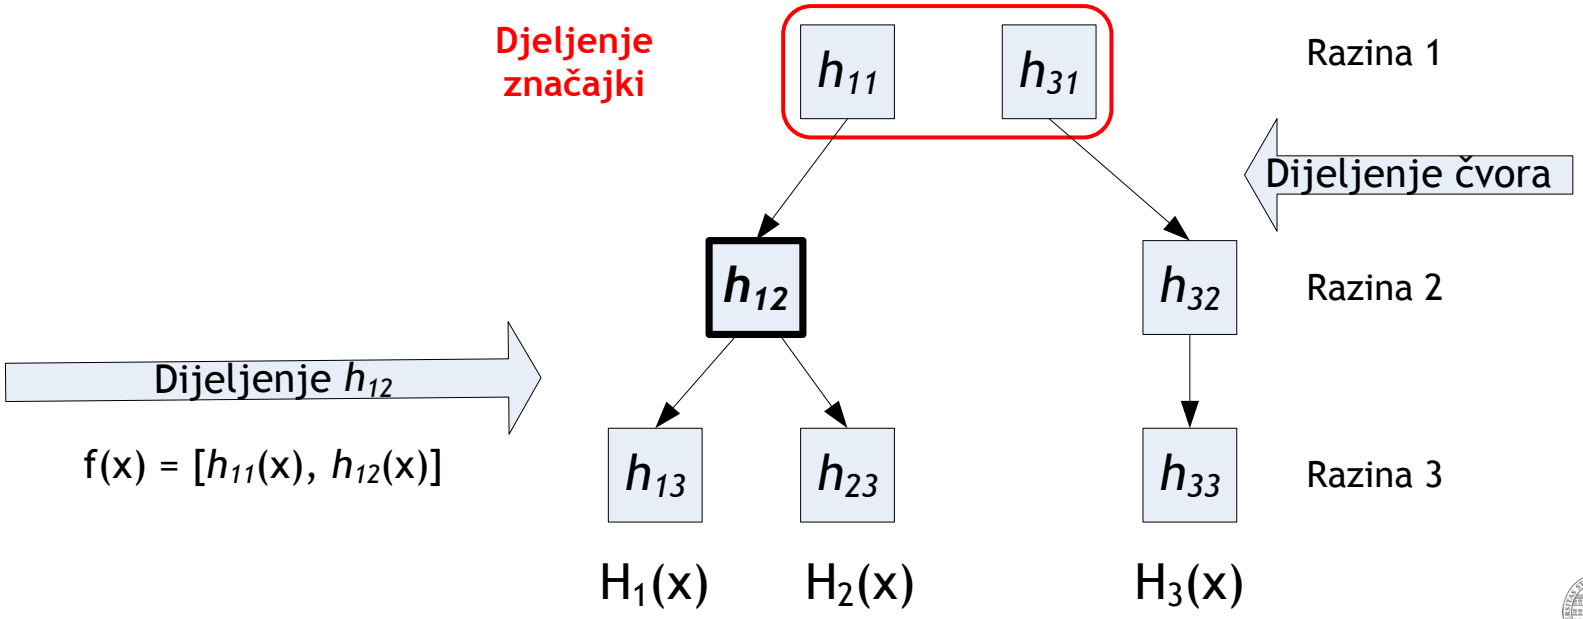

# Struktura klasifikatora - udruživanje

[Wu and Nevatia, 2007] - učenje ojačanog klasifikatora integrirano s ulančavanjem te izgradnjom CBT

3. Ponovno treniranje roditelja čvora dijeljenja od razine *l* prema korijenu
   - čvor roditelj - slabi klasifikator se dijeli na dva koja djele značajku
   - postupak dijeljenja od dna prema vrhu (engl. *bottom-up*)

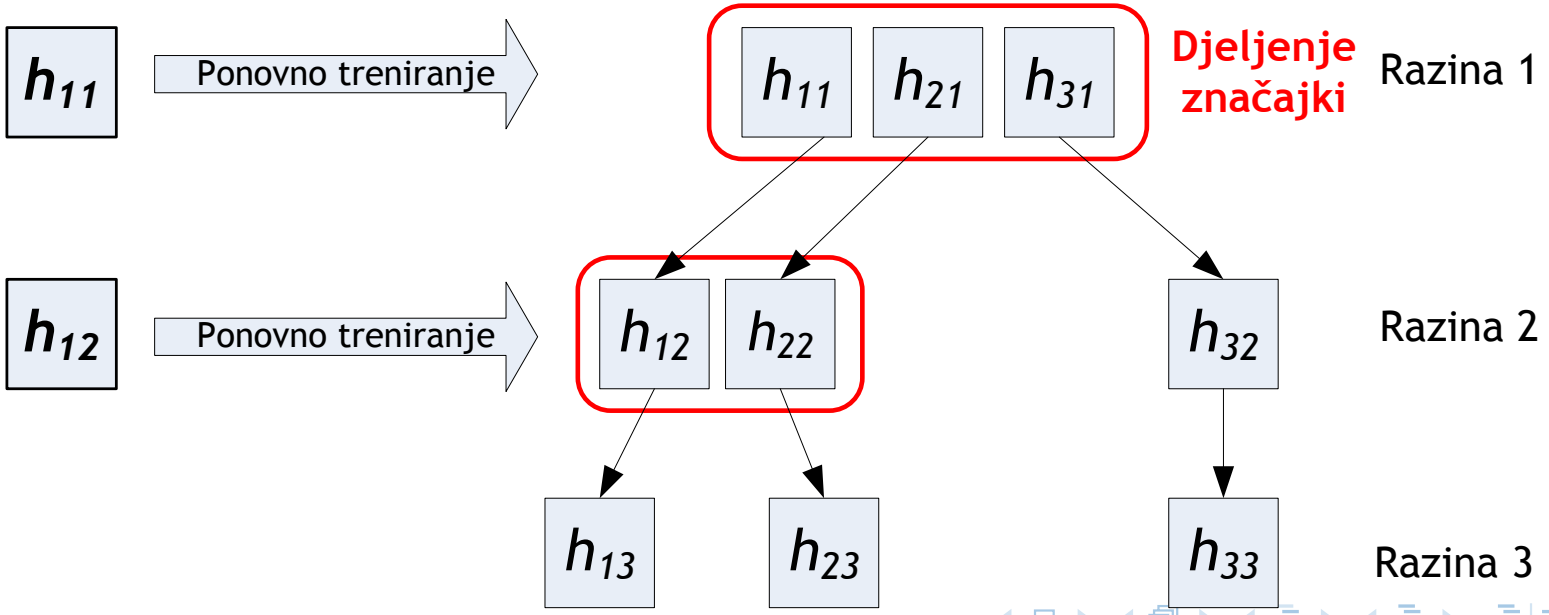

# Struktura klasifikatora - udruživanje

[Kim and Cipolla, 2013] - $K$ ojačanih klasifikatora

- ne dijele ekspicitno značajke
- nisu nezavisni - primjeri za učenje se preraspodjeljuju između njih tijekom učenja $\rightarrow$ automatsko particioniranje primjera
- *Noisy OR* udruživanje glasanjem - svi klasifikatori moraju klasificirati uzorak kao pozadinu, u suprotnom dovoljno je da jedan klasificira kao objekt
- ubrzanje - pretvorba ojačanog klasifikatora u stablo odlučivanje, tzv. *Super tree*
- *Super tree* - mnoštvo kratkih putanja reducira prosječan broj evaluacija slabih klasifikatora
- dodatno ubrzanje - ulančavanje Super tree struktura

# Struktura klasifikatora - monolitni klasifikator

[Yuan et al., 2011] - $k$ združeno treniranih linearnih detektora $w$
Treniranje - klasifikacijska fija $C(x, i)$

$$C(x,i) \begin{cases} > 0, \text{x je objekt iz jednakog razreda kao i } x_i \\ \leq 0, \text{inače} \end{cases} \tag{1}$$

- $x$ - uzorak za klasificiranje
- parametar $i$ - pripadnost razredu, određuje se
  - parametarski - na temelju znanja od domeni problema, ili
  - *neparametarski* - razredi nisu unaprijed definirani, odgovara pozitivnom primjeru za učenje $x_i$

# Struktura klasifikatora - monolitni klasifikator

[Yuan et al., 2011] - Neparametarski pristup

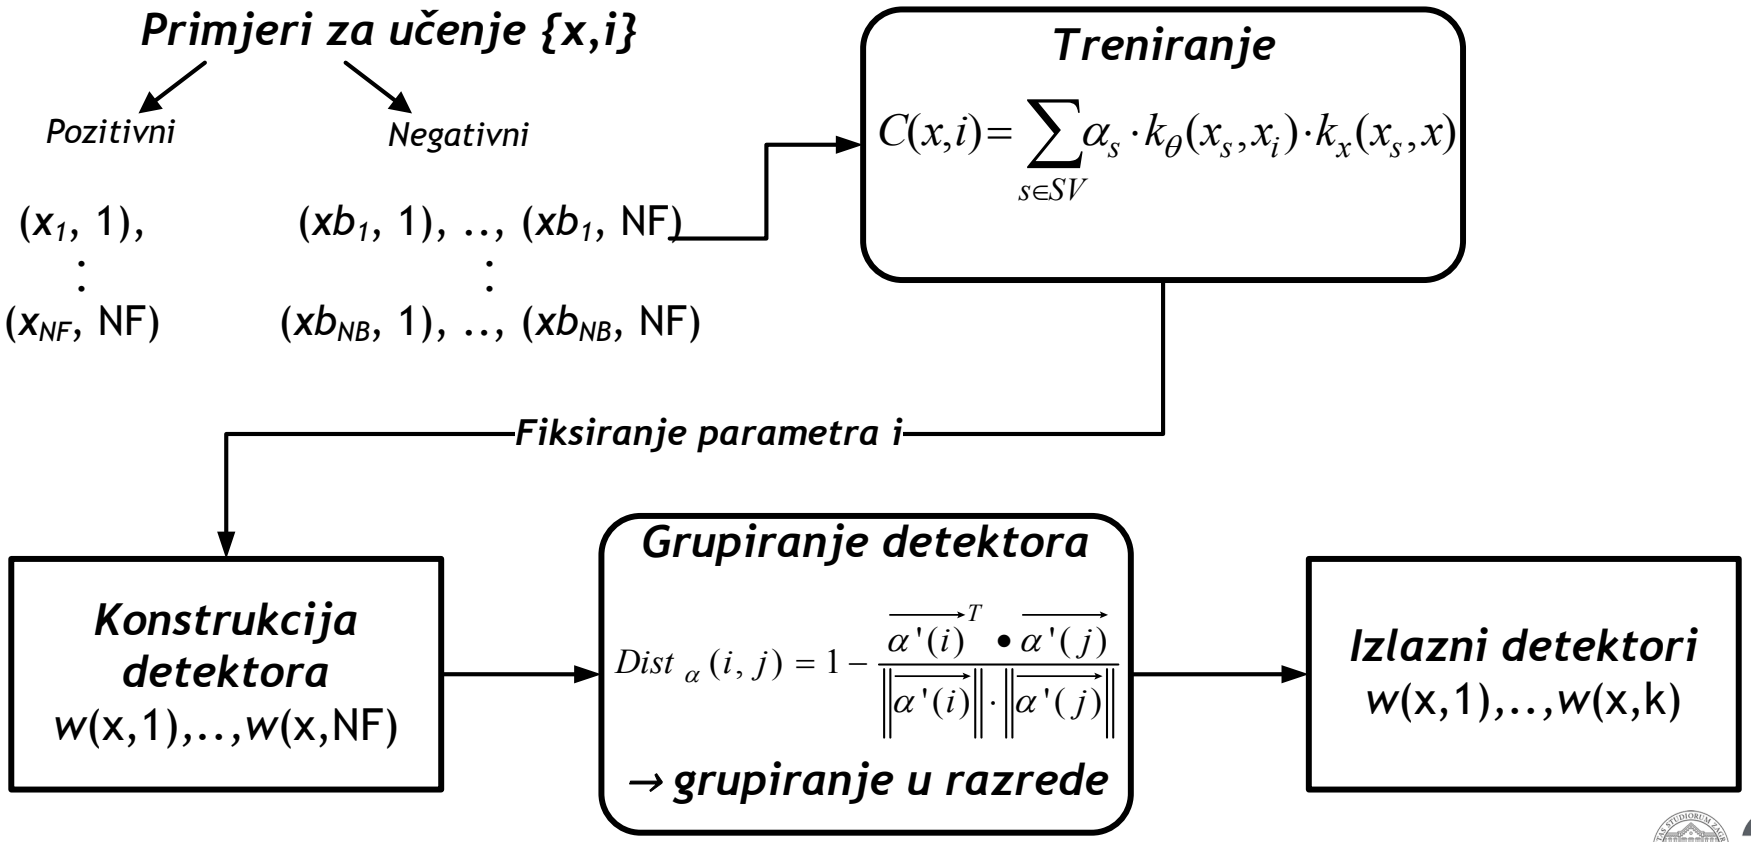

# Struktura klasifikatora - monolitni klasifikator

[Yuan et al., 2011] - Struktura klasifikacijske fije $C(x, i)$ - multiplikativna jezgra

$$C(x, i) = \sum_{s \in SV} \alpha_s \cdot k_\theta(x_s, x_i) \cdot k_x(x_s, x) \tag{2}$$

- među-razredna jezgra $k_x$ (engl. *between-class*) - detekcija objekta u odnosu na pozadinu: *linearna* jezgra
- unutar-razredna jezgra $k_\theta$ (engl. *within-class*) - raspoznavanje različitih razreda objekata: nelinearna jezgra (npr. RBF)

Konstrukcija detektora - fiksiranje $i$

- posljedica - $k_\theta$ se ne evaluira tijekom detekcije $\rightarrow w(x, i)$ linearni detektor

# Postupci učenja

Popularni algoritmi učenja opisanih struktura klasifikatora u računalnom vidu

- ojačavanje (engl. *boosting*)
- ulančavanje (engl. *cascading*)
- stroj sa potpornim vektorima (engl. *Support Vector Machine*) (SVM)

# Postupci učenja - ulančavanje

[Viola and Jones, 2003] - učenje ulančanog klasifikatora za pojedini razred

- dodavanje novih razina upravljano stopom lažnih pozitiva $F_{target}$ ulančanog klasifikatora
- jaki klasifikator $H_i(x)$ na razini $i$ treniran *AdaBoostom*
  - dodavanje značajki u $H_i(x)$ upravljano stopom lažnih pozitiva za pojedinu razinu $f_i$
  - granična vrijednost za $H_i(x)$ određena stopom detekcija za pojedinu razinu $d_i$
- negativni primjeri za razinu *i+1*: evaluacija $H_0(x)..H_i(x)$ na skupu pozadina $\rightarrow$ identifikacija lažnih pozitiva

# Postupci učenja - ojačavanje

[Viola and Jones, 2003] - učenje stupnja ulančanog klasifikatora AdaBoostom

- slabi klasifikator $h(x)$ - plitko stablo odluke (engl. *decision stump*) vezano uz jednu značajku
- minimizacija težinske sume pogrešaka $J$, uz $z_i$ oznaku razreda

$$J = \sum_{i=1}^{N} w_i |z_i - h(x, c)| \tag{3}$$

- jaki klasifikator $H(x)$ - linearna kombinacija slabih

$$H(x) = \sum_{m=1}^{M} \log \frac{1}{\beta_m} h_m(x) \tag{4}$$

- faktor promjene težine primjera $\beta_m = J_m/(1 - J_m)$ : $h(x)$ sa manjom pogreškom ima veći utjecaj
- krivo klasificirani primjeri imaju veće težine

# Postupci učenja - ojačavanje

[Torralba et al., 2007] - JointBoost algoritam

- proširenje GentleBoost algoritma za $C$ razreda - svakom primjeru za učenje dodjeljeno $C$ težina $w_i^c$
- temeljna ideja - *grupiranje razreda u podskupove $S(n)$ koji dijele slabi klasifikator*
- slabi klasifikator $h(x, c)$ - plitko stablo odluke (engl. *decision stump*) vezano uz jednu značajku
- minimizacija funkcije cijene $J$ za podskup $S(n)$

$$J(S(n)) = \sum_{c=1}^{C} \sum_{i=1}^{N} w_i^c (z_i^c - h(x_i, c))^2 \tag{5}$$

# Postupci učenja - ojačavanje

[Huang et al., 2007] - VectorBoost algoritam

- treniranje čvora WFS stabla $H(x)$
- temeljna ideja - unutarnji vektori projekcije $\widetilde{v} = (v, b)$ za pojedini razred
  - defnirani vektorom normale $v$ i pomakom $b$
  - koriste se umjesto oznaka razreda $z_i^c$ u [Torralba et al., 2007]
- minimizacija funkcije cijene $J$, pri čemu je $h(x)$ slabi klasifikator

$$J((H(x)) = \sum_{i=1}^{m} \frac{e^{-\widetilde{v}_i \cdot H(x_i)}}{m} \exp\left[-v_i \cdot h(x_i)\right] \qquad (6)$$

# Postupci učenja - ojačavanje

[Kim and Cipolla, 2013] - *AdaBoost* algoritam

- treniranje $K$ klasifikatora
- inicijalno, primjeri particionirani algortimom $k$-srednjih vrijednosti među klasifikatorima
- temeljna ideja - preraspodjela primjera među klasifikatorima
  - podskup se dodjeljuje onom klasifikatoru koji ima najveću vjerojatnost klasificiranja tog primjera
  - KAKO?
    Povećavanjem težina primjerima koji su združeno krivo klasificirani, ali mogu biti ispravno klasificirani pojedinim klasifikatorima u sljedećim iteracijama ojačavanja

# Postupci učenja - ojačavanje

[Kim and Cipolla, 2013] - algoritam binarne optimizacije

- konstrukcija stabla odlučivanja (*Super tree*) iz pojedinog ojačanog klasifikatora
- $K$ ojačanih klasifikatora $\rightarrow$ $K$ *Super tree* struktura
- temeljna ideja - konstrukcija stabla na temelju regija odlučivanja
  - za $n$ slabih klasifikatora, $2^n$ regija odlučivanja
  - svaka regija je kodirana binarnim kodom oznaka razreda

# Postupci učenja - stroj s potpornim vektorima

[Yuan et al., 2011] - SVM za treniranje klasifikacijske fije $C(x, i)$ sa multiplikativnom jezgrom

***Primjeri za učenje {x,i}***

*Pozitivni $X_f$*

$(x_1, 1)$,
$\vdots$
$(x_{NF}, NF)$

*Negativni $X_b$*

$(xb_1, 1), .., (xb_1, NF)$
$\vdots$
$(xb_{NB}, 1), .., (xb_{NB}, NF)$

***SVM "bootstrap" treniranje***

$$C(x,i) = \sum_{s \in SV} \alpha_s \cdot k_\theta(x_s, x_i) \cdot k_x(x_s, x)$$

- **PROBLEM:** memorijska ograničenja - nemogućnost uključivanja svih negativnih primjera odjednom
- **RJEŠENJE:** postupak „samopunjenja" (engl. *boostrapping*)
  - inicijalno, uključivanje ograničenog broja slučajno odabranih primjera
  - evaluacija svih negativnih primjera, dodavanje lažno pozitivnih u skup negativa

# Prometni znakovi

- kategorizacija u 7 heterogenih kategorija prema [Vienna, 1968]
- skupovi podataka *TS2010* za treniranje i *TS2009* za detekciju
  - dominantni trokutni znakovi opasnosti

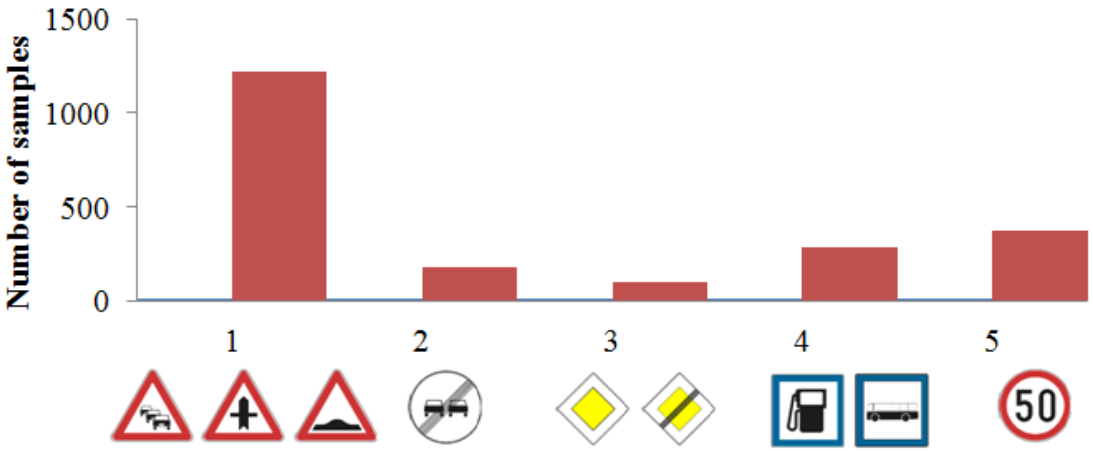

# Detekcija prometnih znakova

Značajke i zahtjevi

1. heterogenost → particioniranje u razrede
   - particioniranje na temelju znanja o domeni [Viola and Jones, 2003], [Torralba et al., 2007], [Huang et al., 2007] - problematičan izbor kriterija, vremenski zahtjevno
   - automatsko particioniranje [Wu and Nevatia, 2007], [Yuan et al., 2011], [Kim and Cipolla, 2013] - bolji izbor

# Detekcija prometnih znakova

Značajke i zahtjevi

1. heterogenost → particioniranje u razrede
   - particioniranje na temelju znanja o domeni [Viola and Jones, 2003], [Torralba et al., 2007], [Huang et al., 2007] - problematičan izbor kriterija, vremenski zahtjevno
   - automatsko particioniranje [Wu and Nevatia, 2007], [Yuan et al., 2011], [Kim and Cipolla, 2013] - bolji izbor
2. neujednačen skup podataka → detekcija znakova sa malim brojem primjera
   - izgradnja zasebnog detektora za pojedini razred [Viola and Jones, 2003] - loše performanse
   - treniranje zajedničke klasifikacijske fije za sve razrede [Torralba et al., 2007], [Huang et al., 2007], [Wu and Nevatia, 2007], [Yuan et al., 2011] - dijeljenje značajki razreda u odnosu na pozadinu

*Zaključak* - metode [Wu and Nevatia, 2007] i [Yuan et al., 2011] zadovoljavaju zahtjeve

# Eksperimenti

Primjena metode multiplikativnih jezgri [Yuan et al., 2011]
Kategorija znakova opasnosti - velik broj različitih znakova

- **eksperiment**: variranje broja trokutnih znakova $N_T$
- **cilj**: odrediti potreban broj primjera da bi se postgli zadovoljavajući rezultati detekcije
- neujednačeni skup podataka - mogućnost da se znakovi sa malim brojem primjera tretiraju kao šum

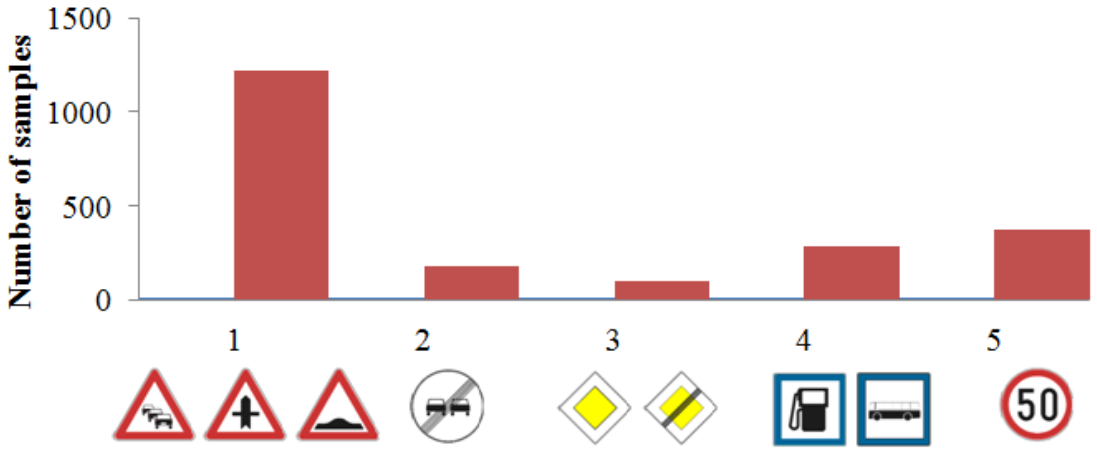

# Rezultati: automatsko particioniranje u razrede

- djeljenje značajki u odnosu na pozadine

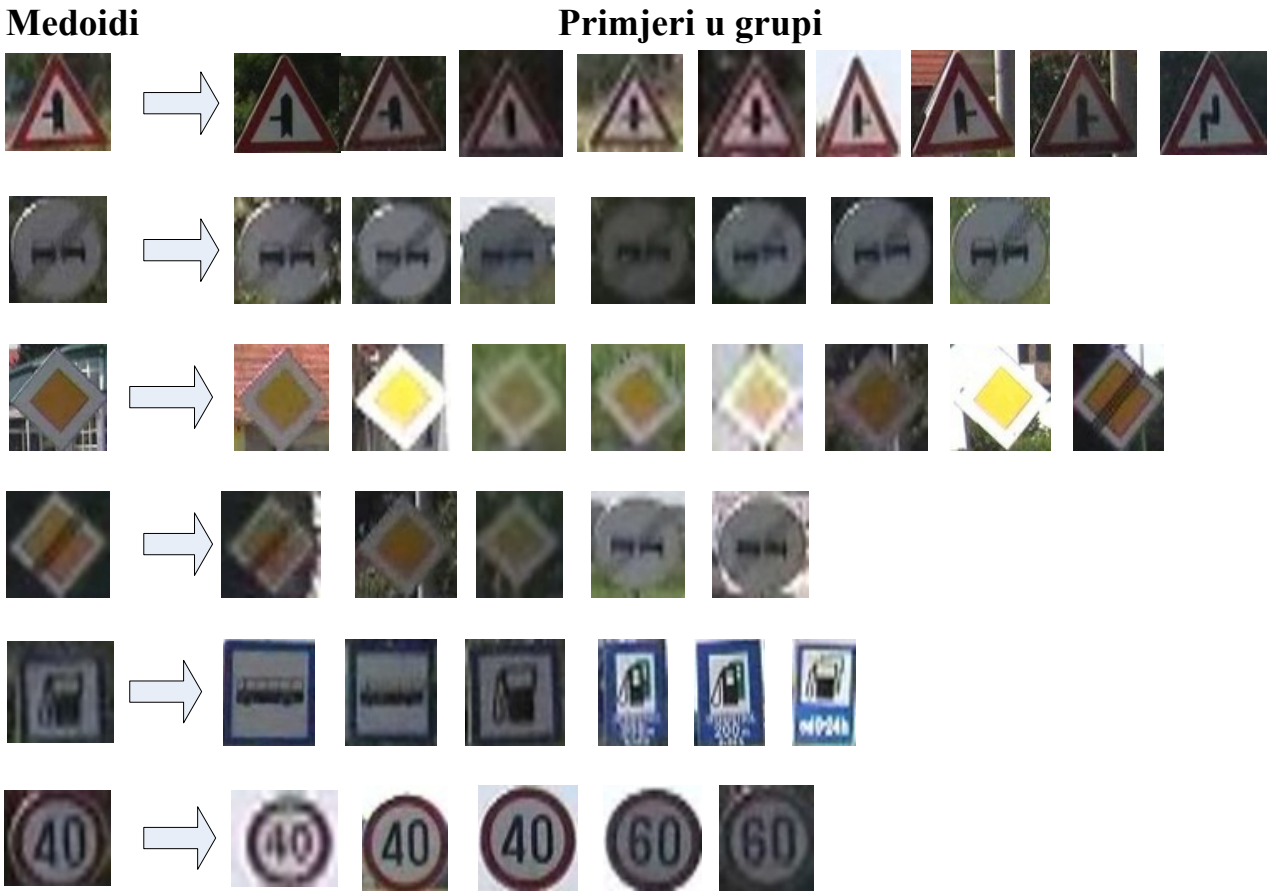

# Rezultati: detekcija i klasifikacija

Stopa detekcije 94% uz stopu lažnih detekcija od 55%

- Stopa detekcije = Br. detektiranih znakova / Br. znakova
- Stopa klasifikacije = Br. ispravnih klasifikacija / Br. znakova
  - *Ispravna klasifikacija* - na temelju automatskog particioniranja
- FP stopa = Br. lažnih detekcija / Br. znakova
- Stopa FP/slici = Br. lažnih detekcija / Br. slika

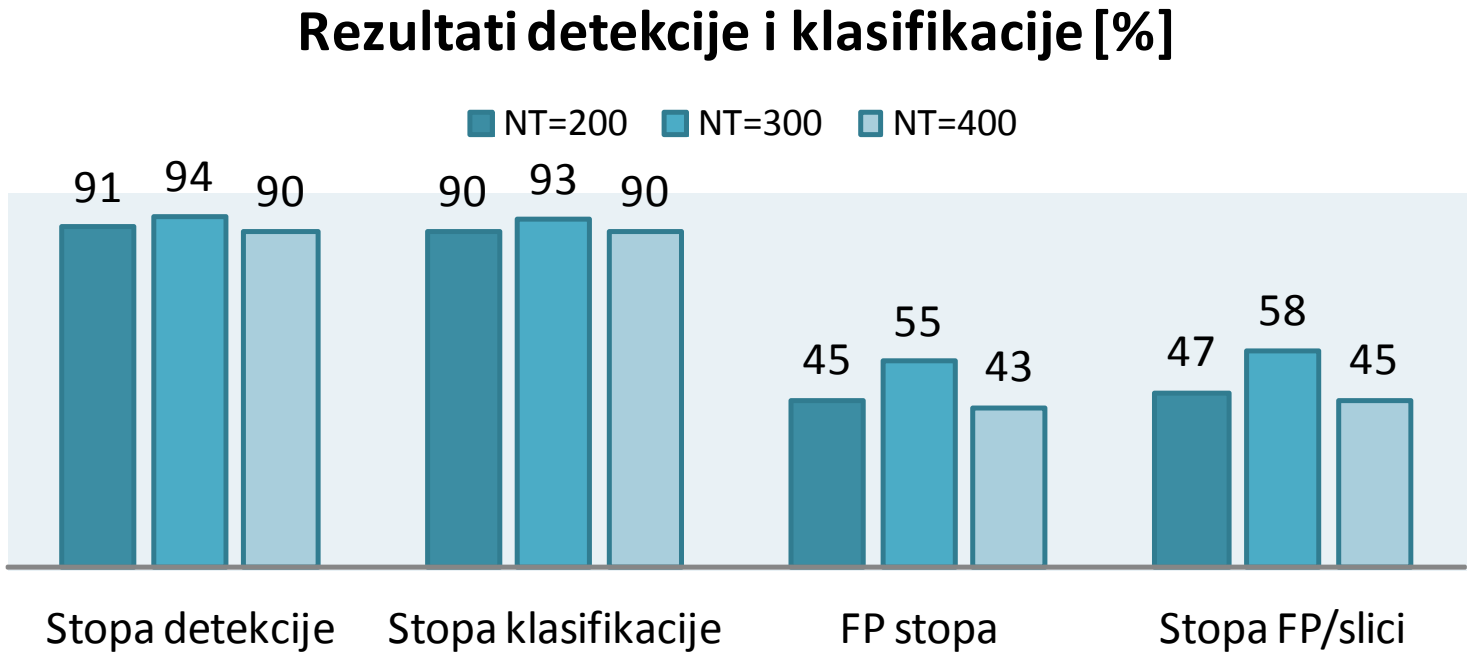

# Rezultati: detekcija i klasifikacija

# Zaključak

- pregled metoda višerazredne detekcije
- primjenjivost opisanih metoda za detekciju prometnih znakova
- eksperimentalni rezultati metode multipilkativnih jezgri
  - stopa detekcije od 94 % uz stopu lažnih pozitiva of 55%
  - uspješna detekcija znakova sa malim brojem primjera za učenje
  - automatsko particioniranje znakova u razrede

# Reference I

Yoav Freund and Robert E. Schapire. A decision-theoretic generalization of on-line learning and an application to boosting. In *Proceedings of the Second European Conference on Computational Learning Theory*, EuroCOLT '95, pages 23–37, London, UK, UK, 1995. Springer-Verlag. ISBN 3-540-59119-2. URL `http://dl.acm.org/citation.cfm?id=646943.712093`.

Chang Huang, Haizhou Ai, Yuan Li, and Shihong Lao. High-performance rotation invariant multiview face detection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 29(4):671–686, 2007. ISSN 0162-8828. doi: 10.1109/TPAMI.2007.1011.

# Reference II


Tae-Kyun Kim and Roberto Cipolla. *Multiple classifier boosting and tree-structured classifiers.*, pages 163–196. Berlin: Springer, 2013. ISBN 978-3-642-28660-5. doi: 10.1007/978-3-642-28661-2_7.

A. Torralba, K.P. Murphy, and W.T. Freeman. Sharing visual features for multiclass and multiview object detection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 29(5): 854–869, 2007. ISSN 0162-8828. doi: 10.1109/TPAMI.2007.1055.

Vienna. Inland transport comitee, convention on road signs and signals, 1968.

Paul Viola and Michael J. Jones. Fast multi-view face detection. Technical Report MERL-TR-2003-96, Mitsubishi Electric Research Laboratories, July 2003.

# Reference III

Bo Wu and R. Nevatia. Cluster boosted tree classifier for multi-view, multi-pose object detection. In *Computer Vision, 2007. ICCV 2007. IEEE 11th International Conference on*, pages 1–8, 2007. doi: 10.1109/ICCV.2007.4409006.

Quan Yuan, A. Thangali, V. Ablavsky, and S. Sclaroff. Learning a family of detectors via multiplicative kernels. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 33(3):514–530, 2011. ISSN 0162-8828. doi: 10.1109/TPAMI.2010.117.

# Postupci učenja - AdaBoost ojačavanje

**Algoritam 1** AdaBoost

**Ulaz:** primjeri za učenje $\{x_i, z_i\}$, skup težina $\{w_i\}$

**Izlaz:** klasifikator $H(x)$, granična vrijednost $1/2 \sum_m \log 1/\beta_m$

**za** $m = 1 \ldots M$

normaliziraj težine $\{w_i\}$

pronađi $h_m(x)$ koji minimizira $J_m$

izračunaj $\beta_m = J_m/(1 - J_m)$

osvježi $H(x) := H(x) + \log(1/\beta_m) h_m(x)$

osvježi težine $w_i := w_i \beta_m^{1-e_i}$; $e_i = 0$ za $h(x_i) = z_i$, inače 1

# Postupci učenja - JointBoost ojačavanje

**Algoritam 2** JointBoost

**Ulaz:** primjeri za učenje $\{x_i, z_i^c\}$, skup težina $\{w_i^c\}$

**Izlaz:** $C$ klasifikatora $H(x, c)$

**za** $m = 1 \ldots M$

**za** podskup $S(n)$, $n = 1 \ldots 2^C$

pronađi $h_m^n(x, c)$ koji minimizira $J(S(n))$

pronađi najboji podskup $S(n)^* = \arg\min J(S(n))$

osvježi $H(x, c) := H(x, c) + h_m^{n*}(x, c)$

osvježi težine $w_i^c := w_i^c \exp\left[-z_i^c h_m^{n*}(x, c)\right]$

# Postupci učenja - VectorBoost ojačavanje

**Algoritam 3** VectorBoost

**Ulaz:** primjeri za učenje $\{x_i, \widetilde{v_i}\}$, skup težina $\{w_i\}$

**Izlaz:** Jaki klasifikator $H(x)$

**za** $m = 1 \ldots M$

pronađi $f_m(x)$ koji minimizira $J$

osvježi $F_m(x) := F_{m-1}(x) + f_m(x)$

osvježi težine $w_i^m := w_i^{m-1} \frac{\exp[-v_i \cdot h(x_i)]}{Z_m}$, $Z_m$ normalizacijski faktor

# Postupci učenja - Bootstrap SVM

**Algoritam 4** SVM sa multiplikativnom jezgrom

**Ulaz:** primjeri za učenje $X_f \cup X_b'$

$X_f = \{x_i, x_i\}$, $i \in \{1..NF\}$

$X_b = \{x_{bj}, x_i\}$, $j \in \{1..NB\}$, $i \in \{1..NF\}$

$X_b' =$ slučajno odaberi $NB$ dvojki iz $X_b$

**Izlaz:** Potporni vektori i težine $\{x_s, \alpha_s\}$, $s \in \{1..SV\}$

**ponavljaj**

izračunaj $K_G[(x_l, x_m), (x_k, x_n)] = k_\theta(x_m, x_n) k_x(x_l, x_k)$

SVM treniranje sa $K_G \rightarrow \{x_s, \alpha_s\}$

evaluiraj sve primjere iz $X_b$, identificiraj lažne pozitive $X_{FP}$

**ako** $X_{FP} = \varnothing$

**vrati** $\{x_s, \alpha_s\}$

dodaj lažne pozitive $X_b' = X_b' \cup X_{FP}$