

# Sledovanie osoby vo viacerých videozáznamoch

Meno študenta: Andrej Zbín

Vedúci práce: RNDr. Zuzana Černeková, PhD.

# Motivácia

- ▶ Bezpečnosť
- ▶ Autentifikácia
- ▶ Autorizácia
- ▶ Automatizácia
- ▶ ...

# Ciele práce

- ▶ Návrh a implementácia systému
- ▶ Metódy detekcie osôb a ich porovnanie
- ▶ Techniky rozpoznávania osôb a ich porovnanie

# Proces

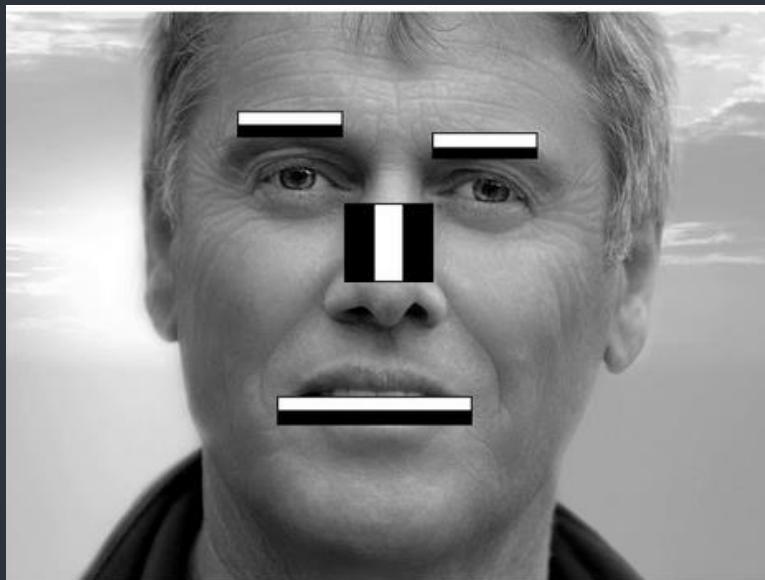
- ▶ Vstup
- ▶ Predspracovanie
- ▶ Normalizácia
- ▶ Detekcia
- ▶ Extrakcia príznakov
- ▶ Klasifikácia
- ▶ Výstup

# Detekcia osôb

- ▶ Haarové príznaky
- ▶ Histogram orientovaných gradientov
- ▶ Konvolučné neurónové siete
- ▶ ...

# Haarové príznaky

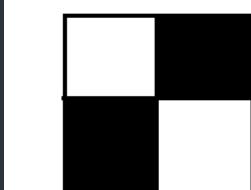
- ▶ Viola-Jones
- ▶ Rýchlosť
- ▶ Kontrolované prostredie



1) Hranové príznaky



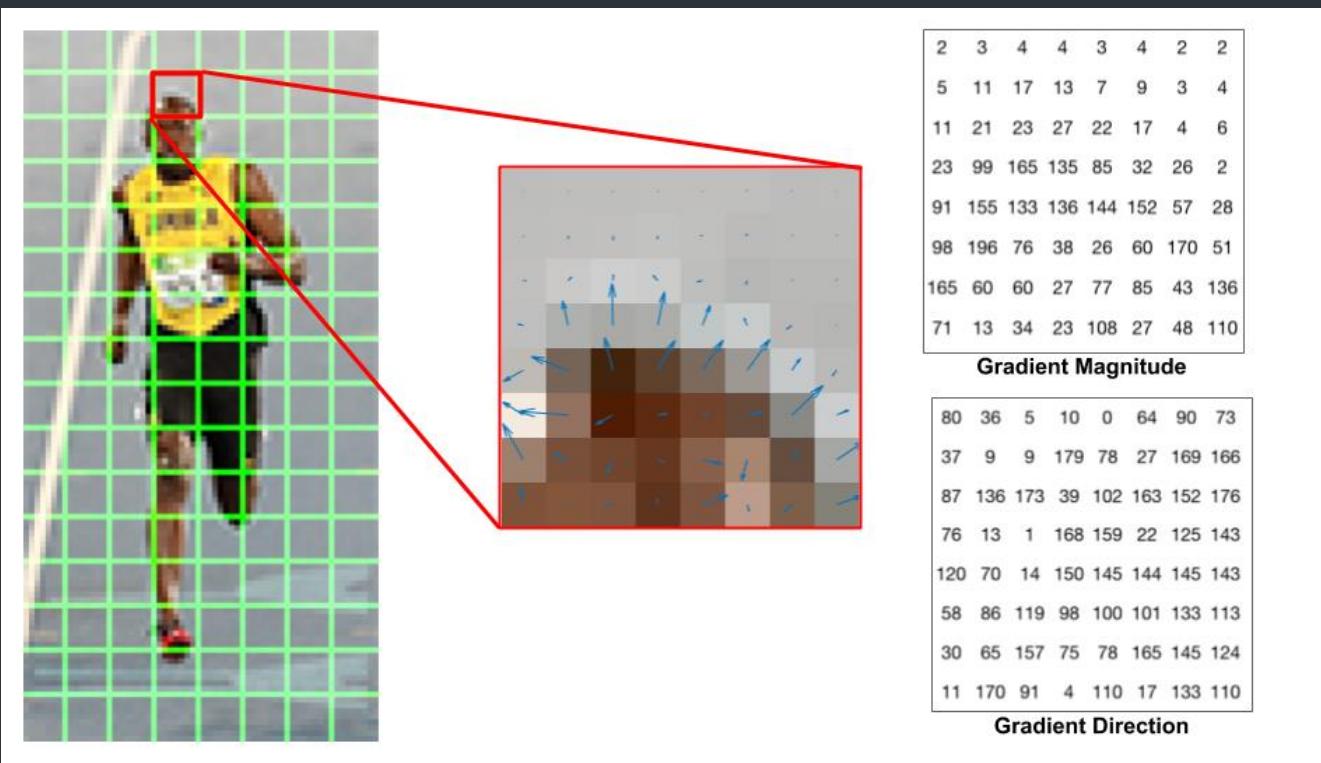
2) Čiarové príznaky



3) Príznaky 4 obdĺžnikov

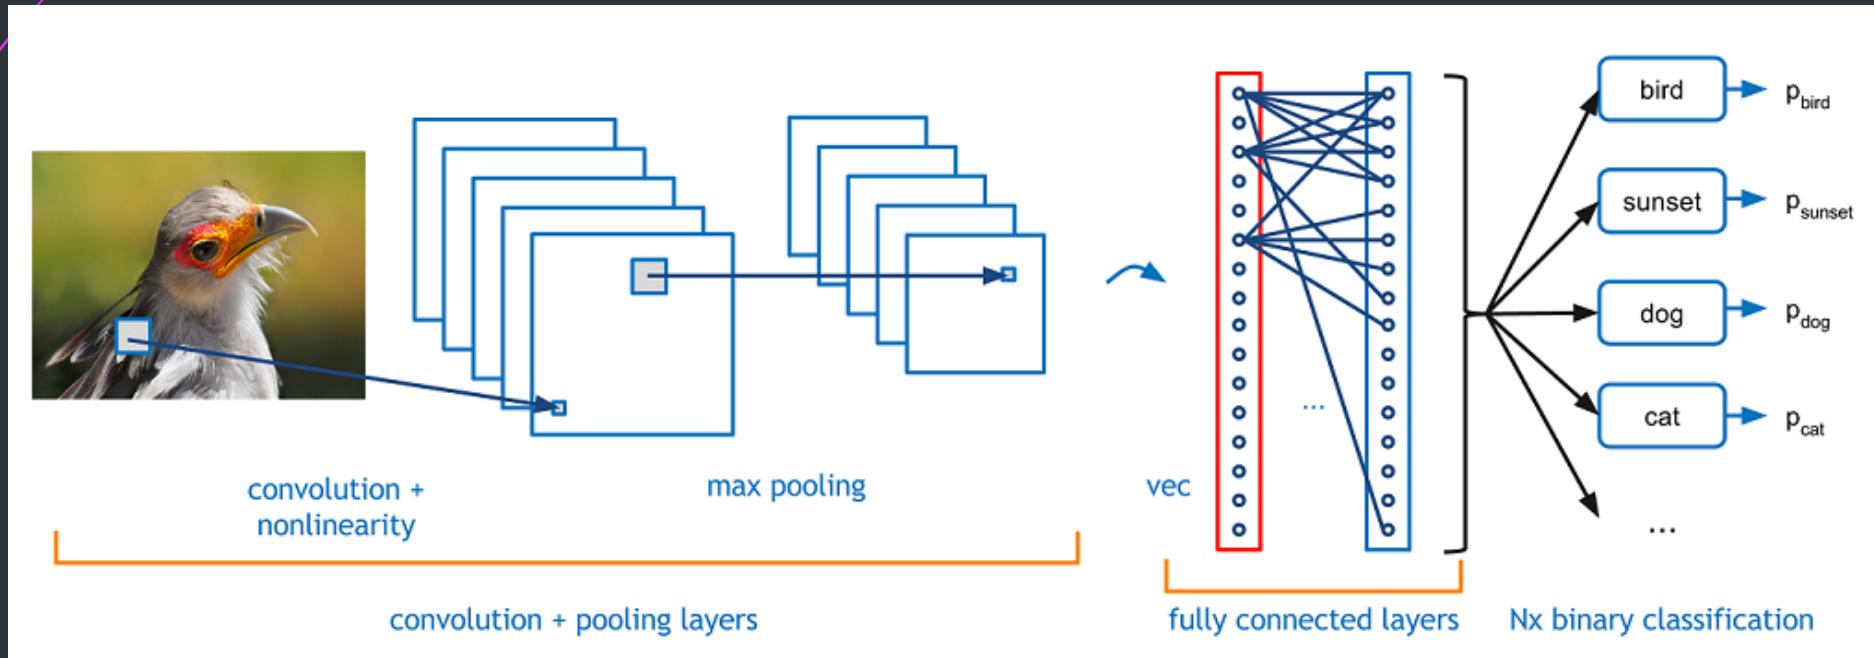
# Histogram orientovaných gradientov

- Rozdelenie na regióny
- Výpočet histogramu



# Konvolučné neurónové siete

- ▶ Klasifikácia vstupu
- ▶ Učenie s učiteľom
- ▶ Konvolučné vrstvy

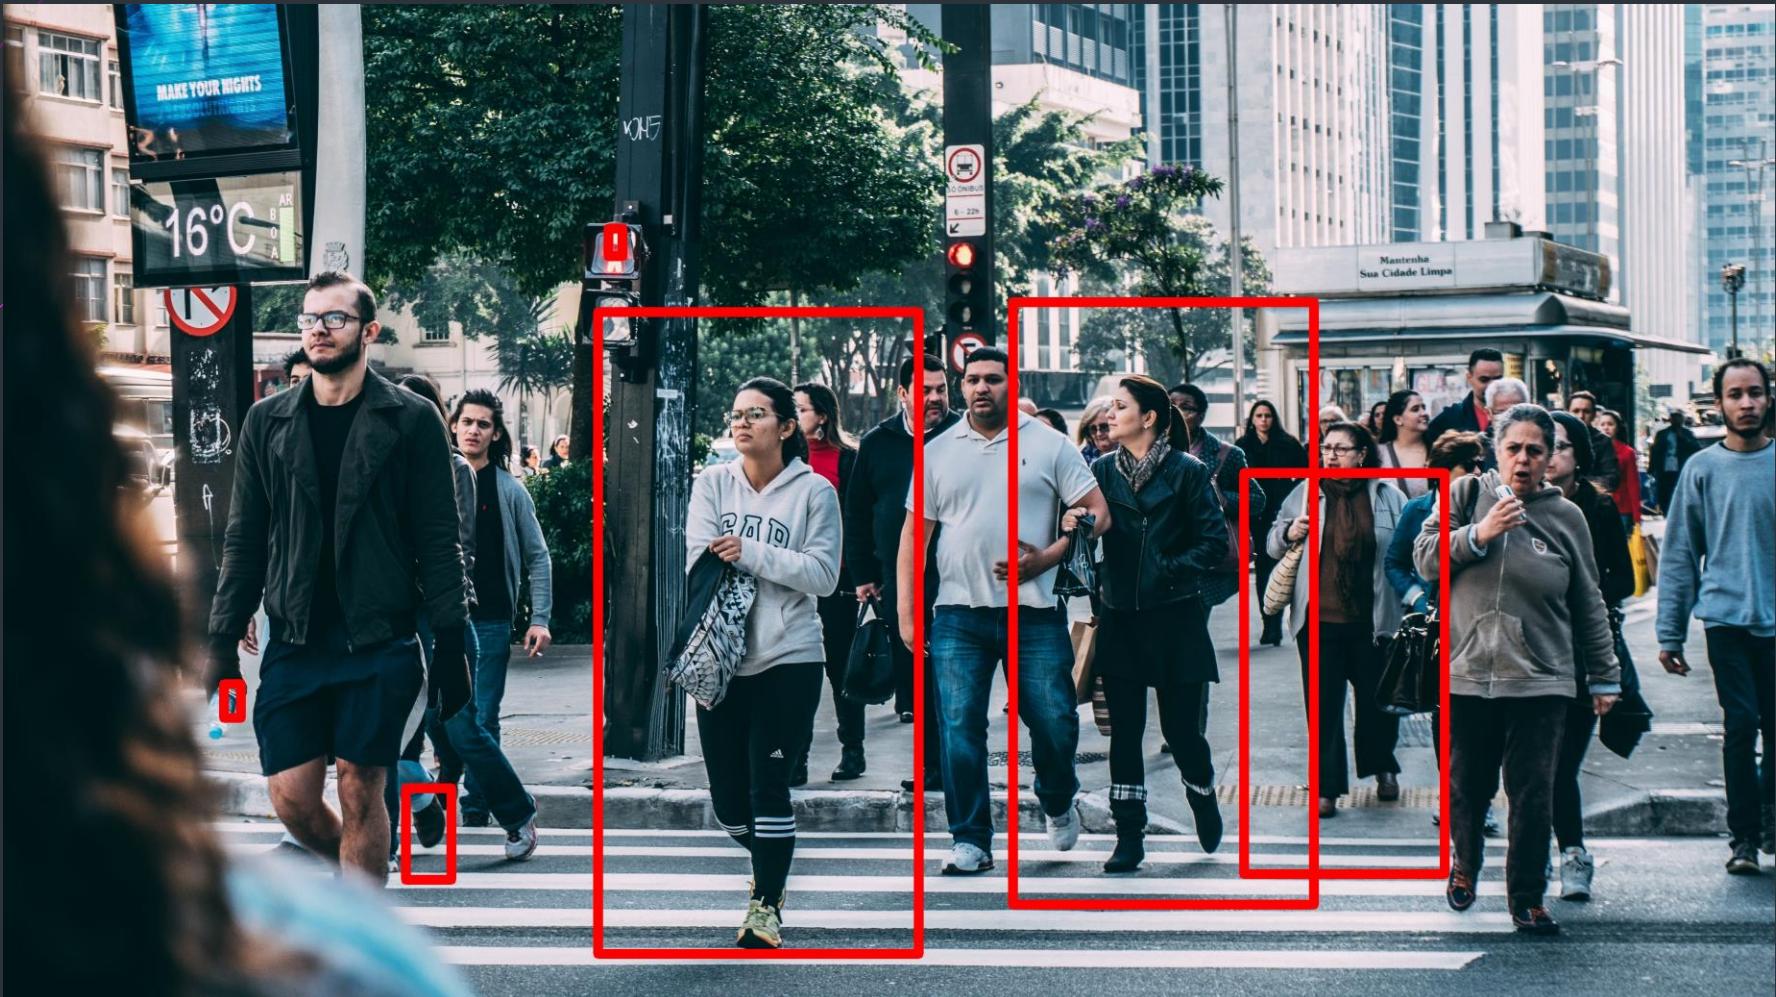


# Porovnanie

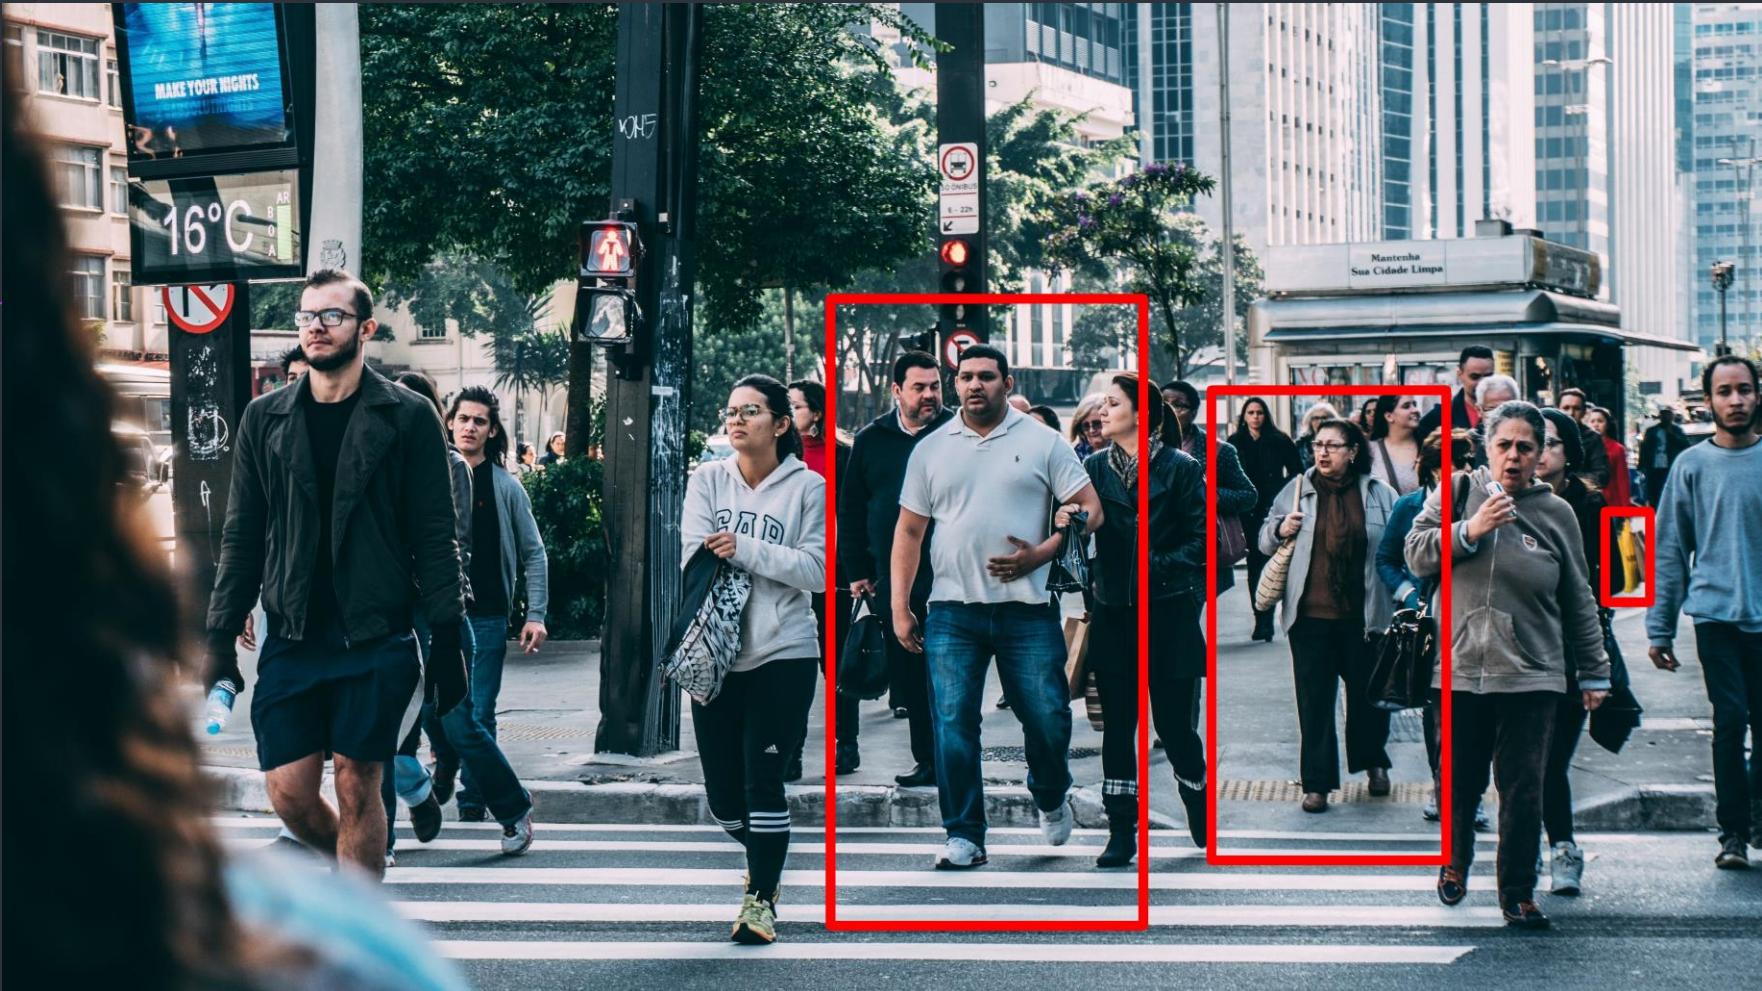
- ▶ OpenCV
- ▶ MobileNet-SSD

Metóda	Čas potrebný na detekciu
Haarové príznaky	168ms
Histogram orientovaných gradientov	8 188ms
Neurónová siet	4 901ms

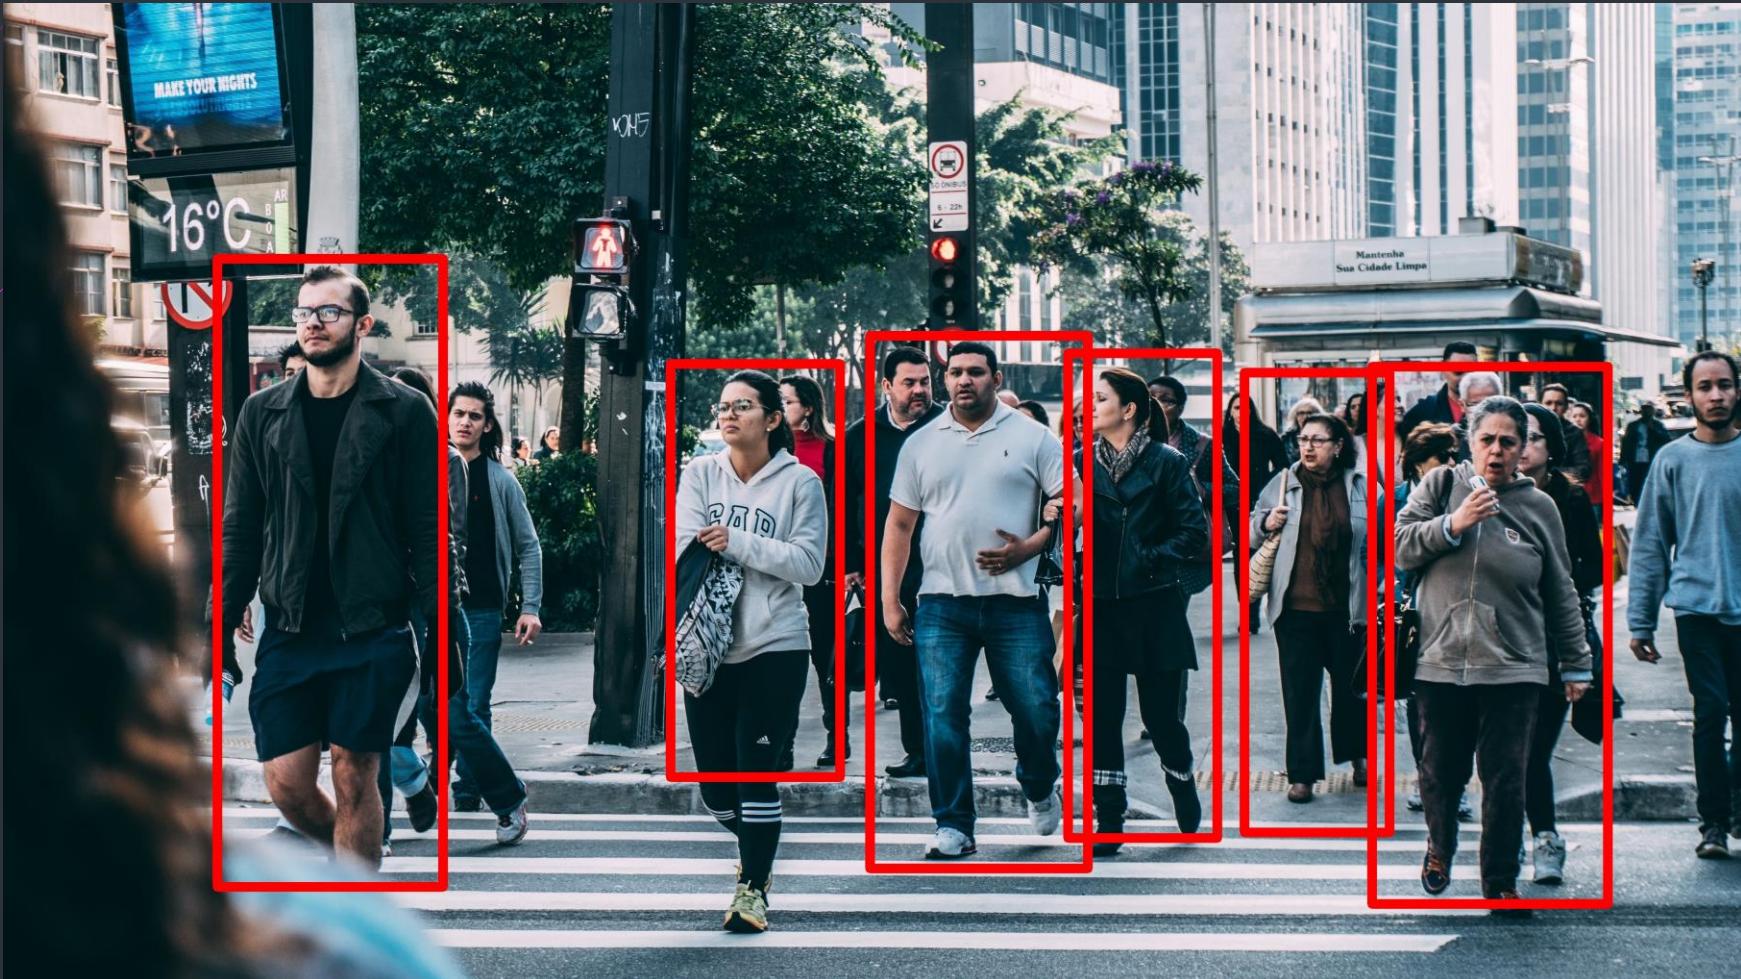
# Haarové príznaky



# Histogram orientovaných gradientov



# Konvolučná neurónová siete



# Extrakcia príznakov

- ▶ HSV histogram (Hue, Saturation, Value)
  - ▶ Pixel (h, s, v) -> histogram[h][s][v] += 1
  - ▶ Rozdelenie na regióny
  - ▶ Spojenie histogramov
- ▶ Škálovo invariantný lokálny ternárny vzor
  - ▶ Porovanie pixelu so susedmi
  - ▶ Paremetre p – počet susedov, r – polomer kružnice, c - threshold

$$SILTP(I) = \sum_{n=0}^{P-1} s(V_I, V_{I_n}) * 3^n$$

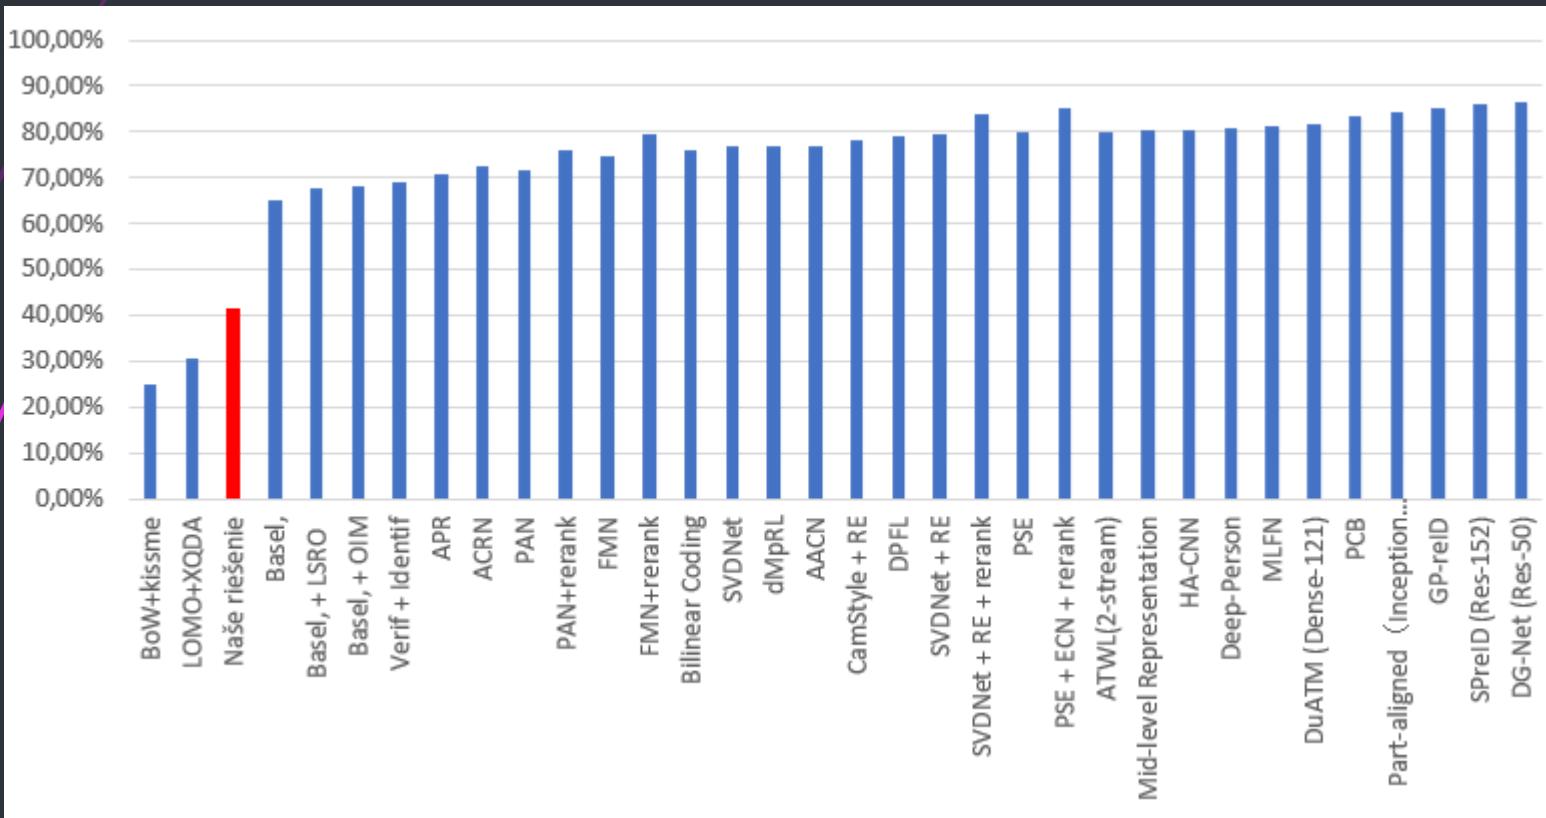
$$s(c, p) = \begin{cases} 2 & \text{ak } (1 + T) * c < p \\ 1 & \text{ak } (1 - T) * c > p \\ 0 & \text{inak} \end{cases}$$

# Klasifikácia

- ▶ Metóda k-najbližších susedov
  - ▶ Vzdialenosť medzi vektormi príznakov
- ▶ Metóda podporných vektorov (SVM)
  - ▶ Hľadanie nadroviny rozdelennej priestoru vektorov
- ▶ Dataset - DukeMTMC-reID
- ▶ Redukcia dimenzie - PCA

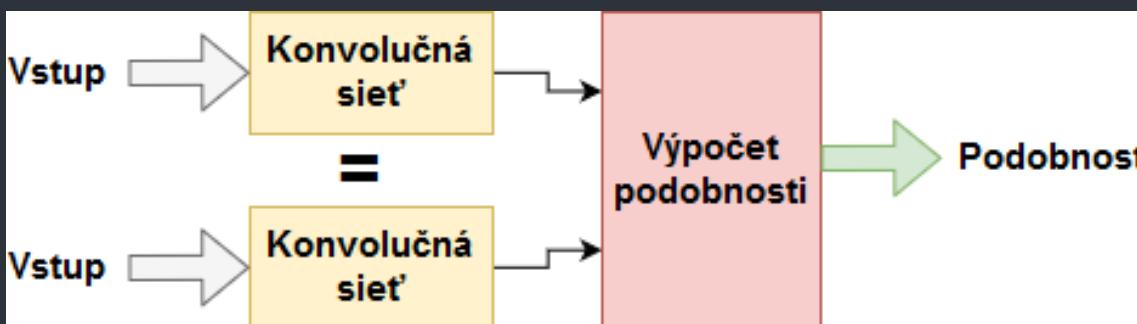
# Porovnanie

- ▶ SVM dosahuje lepšie výsledky
- ▶ Porovnanie s ďalšími riešeniami:



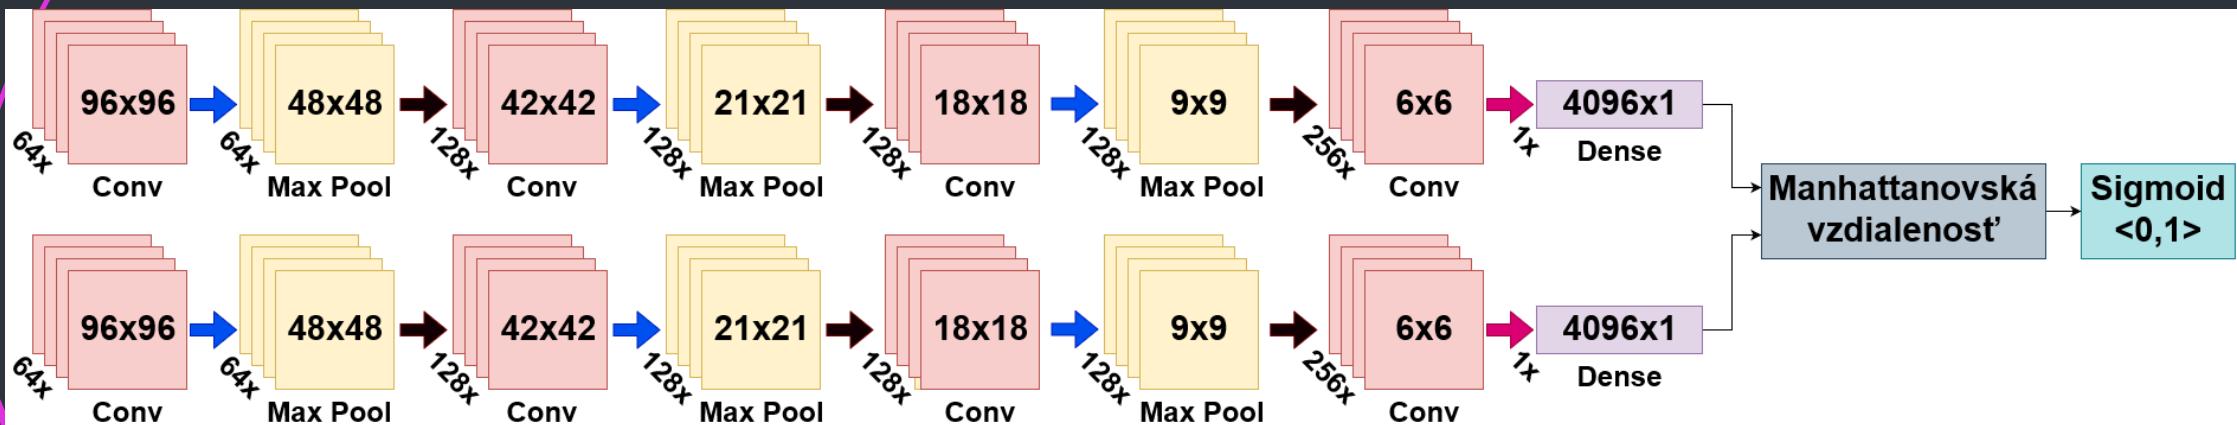
# Siamská konvolučná neurónová sieť

- ▶ Hľadanie podobnosti 2 vstupov
- ▶ Výpočet vzdialenosť:
  - ▶ Manhattanovská vzdialenosť
  - ▶ Euklidovská vzdialenosť
- ▶ Klasifikácia
  - ▶ podobnosť so záberom z databázy



# Architektúra siete

- ▶ 4 kovolučné vrstvy
- ▶ ReLU vrstvy
- ▶ 3 Max pool vrstvy
- ▶ Manhattanovská vzdialenosť
- ▶ Sigmoid



# Trénovanie

- ▶ 2 siete
  - ▶ Celá postava
  - ▶ Tvár
- ▶ Dataset tvári - ChokePoint
- ▶ Chybová funkcia – Binárna entropia

$$L(p, q) = t(p, q) * \log(s(p, q)) + (1 - t(p, q)) * \log(1 - s(p, q))$$

$$t(p, q) = \begin{cases} 1 & \text{ak } p \text{ a } q \text{ patria do rovnakej triedy} \\ 0 & \text{inak} \end{cases}$$

$s(p, q) = \text{predikcia podobnosti}$

# Výsledky

Klasifikácia tváří

		Predikcia	
		Zhoda	Nezhodna
Realita	Zhoda	5084	3601
	Nezhoda	420	8265

Presnosť	0,769
Senzitivita	0,585
Špecificita	0,952
Precíznosť	0,924
Negatívna predikčná hodnota	0,697

Klasifikácia postáv

		Predikcia	
		Zhoda	Nezhodna
Realita	Zhoda	1661	540
	Nezhoda	158	2043

Presnosť	0,841
Senzitivita	0,755
Špecificita	0,928
Precíznosť	0,913
Negatívna predikčná hodnota	0,791

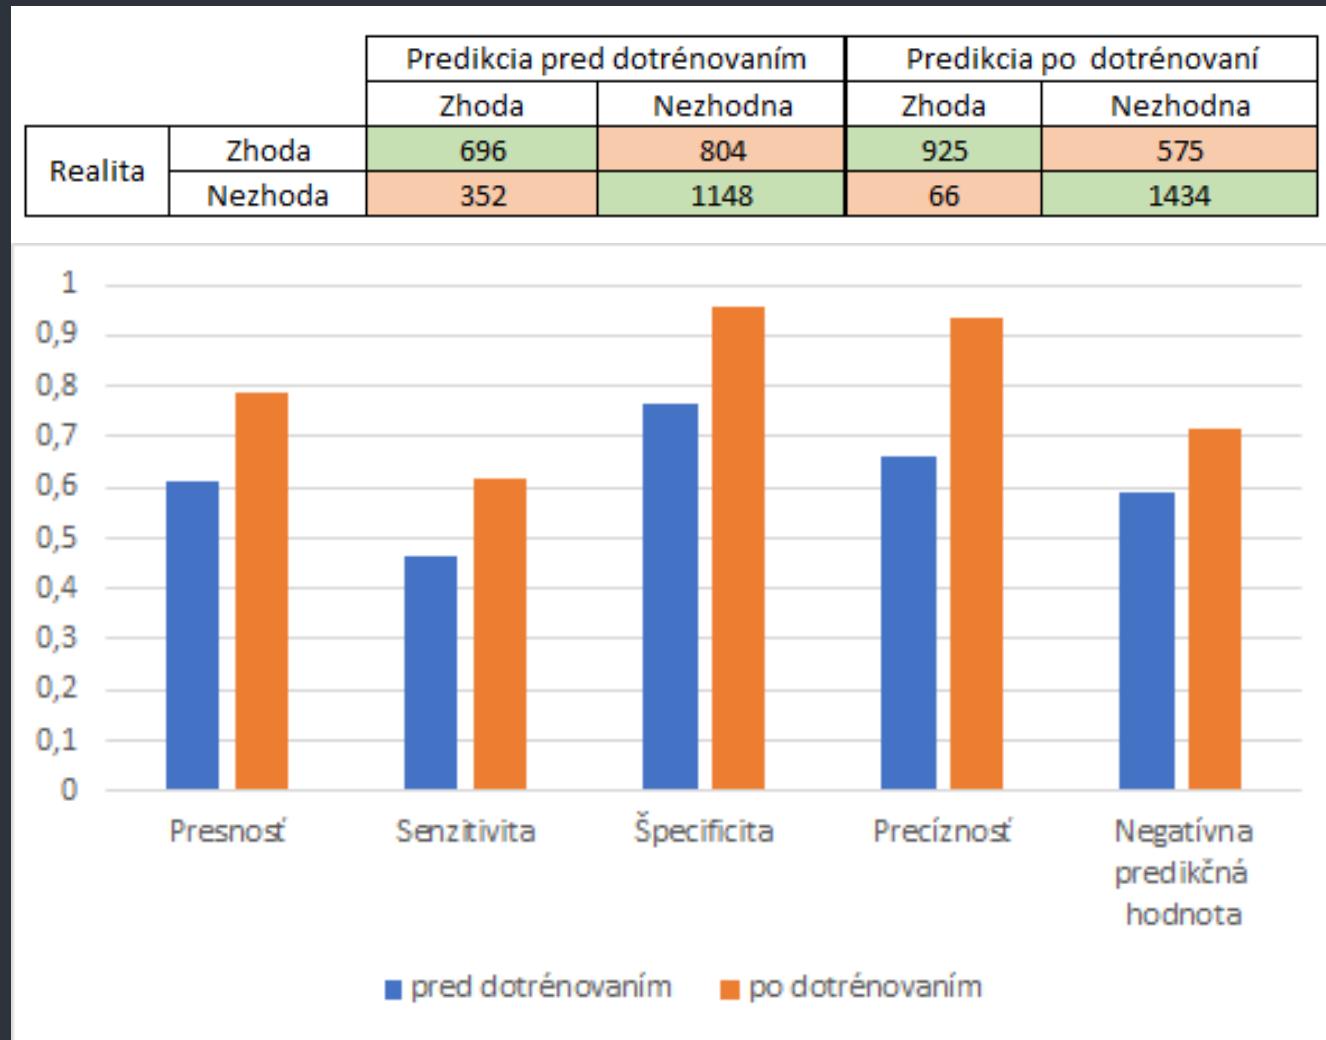
# Implementácia

- ▶ Python3, OpenCV, MobileNet-SSD, Siamská konvolučná neurónová sieť
- ▶ Rozpoznanie uloženej osoby, sledovanie a rozpoznávanie neznámych osôb
- ▶ Dotrénovanie
- ▶ Dataset ChokePoint

# Implementácia

- ▶ Uložené predchádzajúce snímky pre každú osobu
- ▶ Detekcia každých 30 snímok
- ▶ Klasifikácia: Porovnanie so všetkými
- ▶ Korelačný tracker (dlib) – každú snímku
- ▶ Centroid tracker – pri detekcii
  - ▶ Priradenie detegovaných osôb k osobám detegovaným v predchádzajúcej fáze
  - ▶ Kontrola: porovnanie snímky s predtým uloženými
- ▶ Dotrénovanie: potvrdzovanie zhody

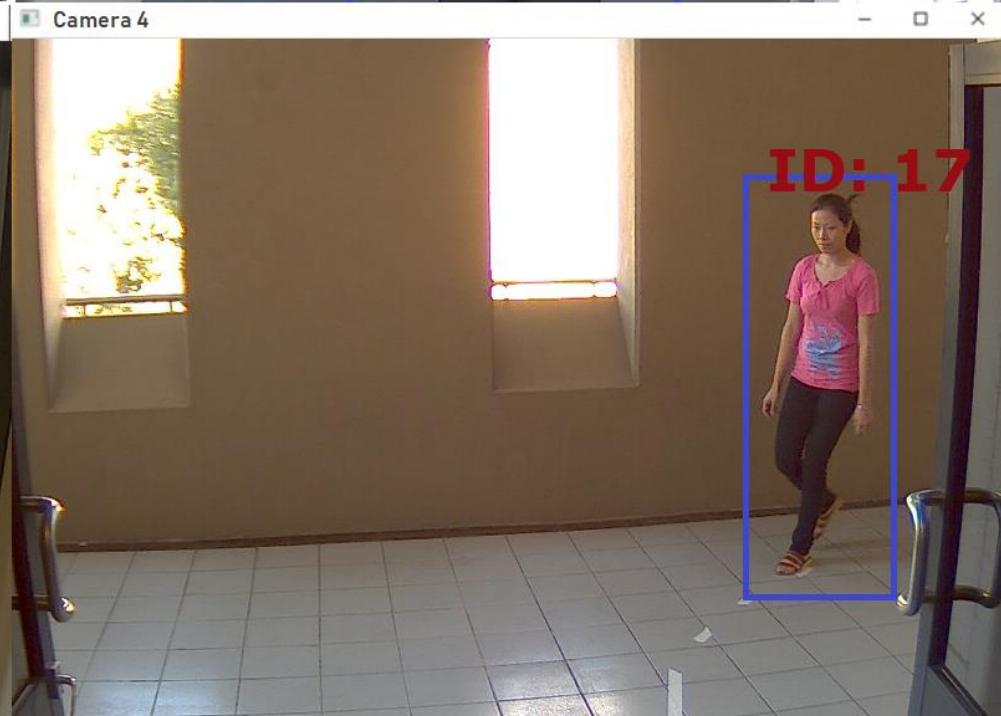
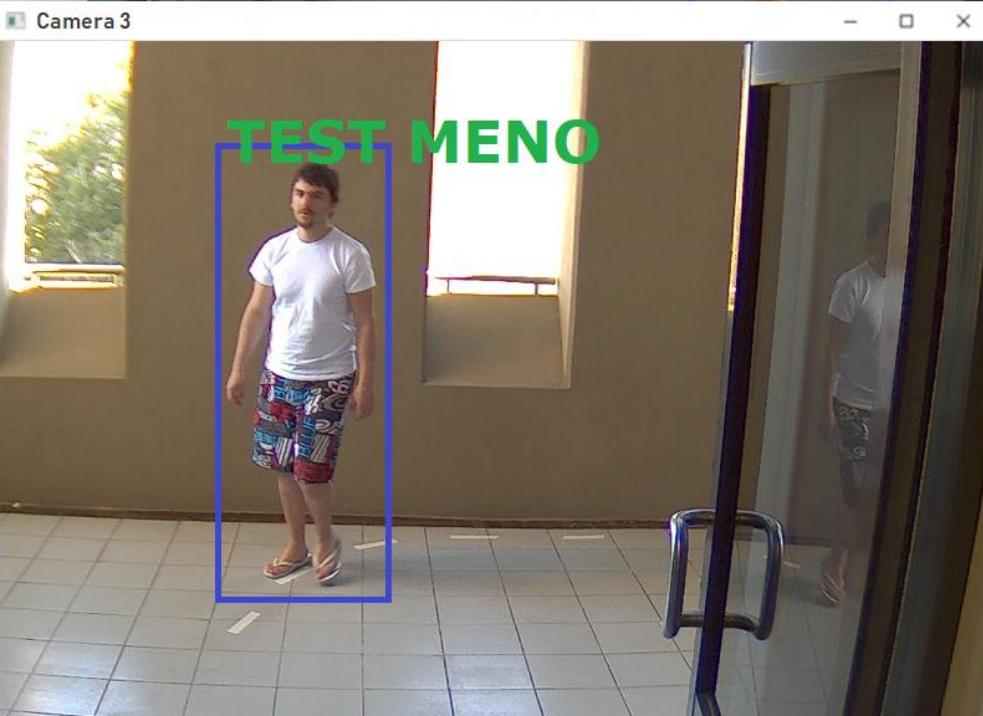
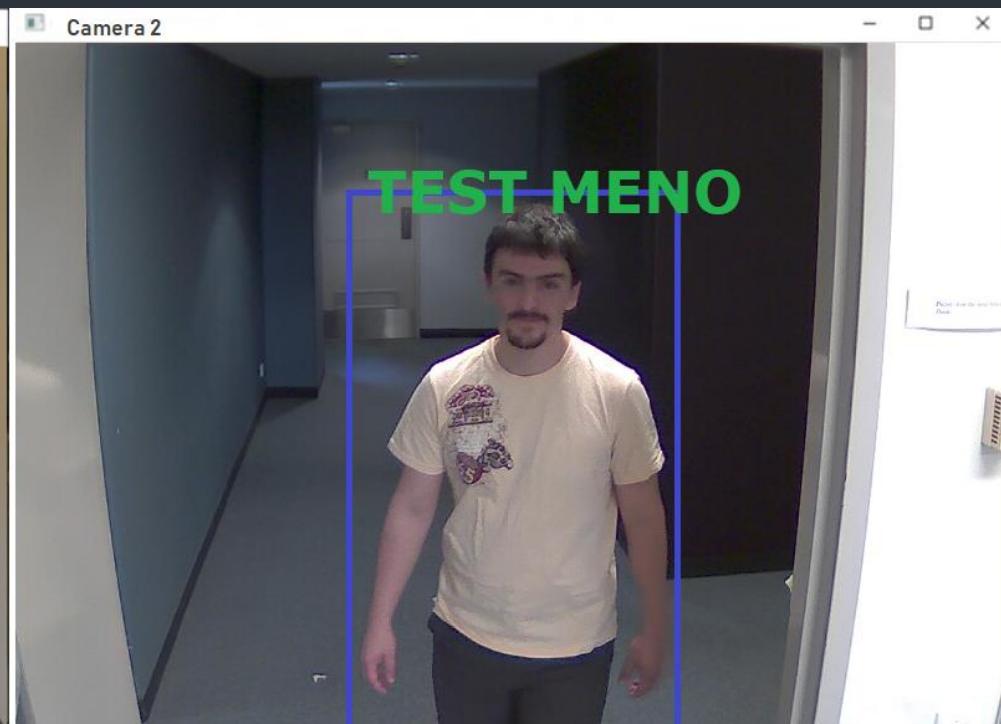
# Porovnanie výsledkov (podľa postavy)



# Výsledky

- ▶ V praxi nepresné výhodnotenie veľmi nevadí
  - ▶ Kombinácia pomocou tváre a postavy
  - ▶ Viacero uložených snímok

21/22



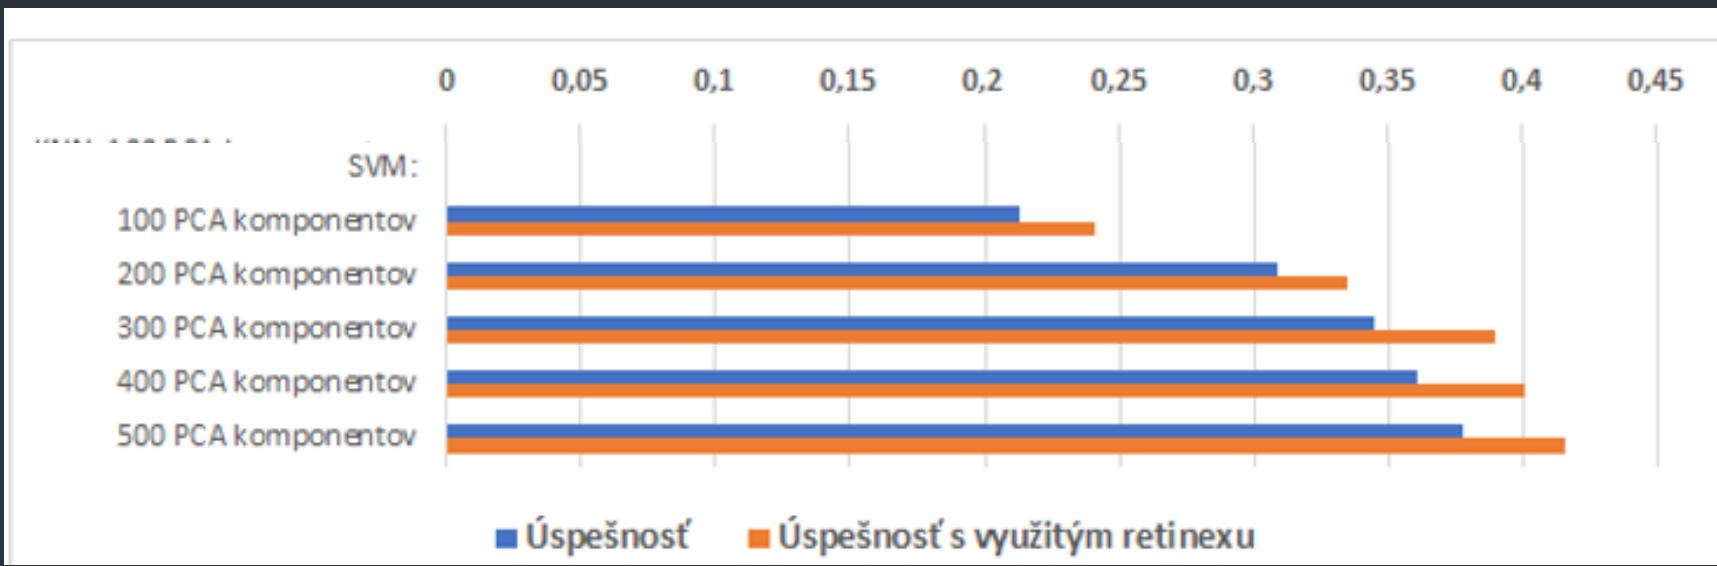
# Možnosti ďalšej práce

- ▶ Spoľahlivosť
- ▶ Rýchlosť
- ▶ Sledovanie v dave



Ďakujem za pozornosť

- ▶ Na Obr. 2.3 kde autor píše, že porovnáva výsledky popísaných riešení s rôznymi parametrami nie je jasné čo je na x-ovej osi. Ktoré príznaky boli využité pri klasifikácii?
- ▶ Pomer správnej klasifikácie k celkovému počtu
  - 0 = žiadny testovaný príklad správne klasifikovaný
  - 1 = všetky testované príklady správne klasifikované
- ▶ Kombinácia 2x škálovo invariantného lokálneho ternárneho vzoru s rôznymi parametrami a HSV histogramu



- ▶ Vyšie uvedená formulácia cieľov má aspoň dve rôzne interpretácie: 1. na základe fotografie osoby určiť vo videu časové intervaly, kedy (prípadne aj kde) je daná osoba v obrazu; 2. v každom momente určí, ktoré osoby z danej databázy sa nachádzajú v obrazu. V prvom rade bolo potrebné upresniť, ktorý z týchto dvoch problémov sa rieši - a potom tiež to, či sa rieši offline alebo v reálnom čase. Prirodzená sa mi zdá prvá interpretácia, avšak z textu práce postupne vyplýva, že sa rieši ten druhý, všeobecnejší problém.
  
- ▶ Implementácia rieši všeobecnejší problém a teda rieši oboje interpretácie
- ▶ Riešenie funguje offline – načíta záznam z disku, aj online – záznam načíta z webkamery alebo internetového streamu
- ▶ Offline riešenie je spolahlivejšie, nevynecháva snímky

- ▶ V časti 2.4 na str. 15 sa píše, že počet tried KNN klasifikátora musí byť vopred určený. Tento problém sa rieši použitím siamskej neurónovej siete. Pozná diplomant nejaké alternatívne riešenie? (V práci žiadne neuvádza.) Ak áno, aké výhody resp. nevýhody má voľba siamskej neurónovej siete v porovnaní s iným riešením či riešeniami?
- ▶ Počítanie vzdialenosťí medzi extrahovanými príznakmi
  - ▶ Sieť pravdepodobne nájde lepšie príznaky, vylepšuje sa na základe vzdialenosťí