



Univerza v Mariboru

Fakulteta za elektrotehniko,
računalništvo in informatiko



Računalniška obdelava slik in
njena uporaba v Sloveniji



Laboratorij za sistemsko
programsko opremo

GLOBOKO UČENJE: OD SAMOVOZEČIH AVTOMOBILOV DO ANOTACIJE RENTGENSKIH SLIK

Gašper Sedej, Martin Šavc, Božidar Potočnik



UVOD

- Uporaba tehnik globokega učenja
- Detekcija kefalometričnih točk na rentgenski sliki glave
- Modifikacija obstoječe arhitekture nevronske mreže
- Uporaba in učenje na novih podatkih
- Vrednotenje rezultatov s statističnimi metodami

KEFALOMETRIJA

- Merjenje človeške glave
- Rentgenske slike
- Laterarni radiogram
- Naravni položaj glave
 - Ponovljivost meritev
- Karakteristične (kefalometrične) točke
- Kefalometrična analiza
 - Diagnosticiranje v ortodontstvu
 - Načrtovanje zdravljenja
 - Evalvacija sprememb med zdravljenjem
 - Forenzika



A Quick Revision







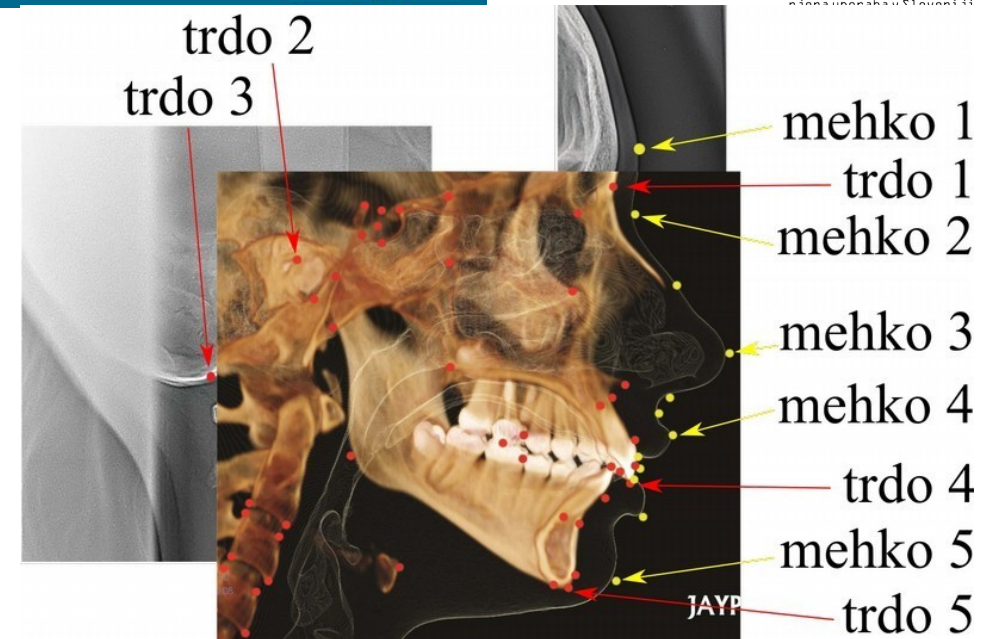
Fig 3 (A) Important lateral cephalometric landmarks identified on the lateral cephalogram

EKSPERIMENTALNO OKOLJE





- Rentgenske slike različnih kefalometričnih naprav oz. nastavitev
- 124 slik različnih oseb
- Različni formati (jpg, png, dicom, tiff)
- Različne ločljivosti in velikosti
- Različne osvetlitve



- Označevanje podatkov
- Kefalometrični atlas
- Izbira 10 kefalometričnih točk
 - 5 kostno (trdo) tkivo
 - 5 mehko tkivo
- Označevanje z lastno aplikacijo
 - Klik na točko
 - Pretvorba koordinat v točke na sliki
- Pretvorba v enotni format in ločljivost
 - Format PNG, 1 kanal (sivinska), 16 bit (floating)
 - Predpisana velikost 480 × 360 pikslov
 - Dodajanje črnega roba po potrebi




- Generiranje label (temeljna resnica)
 - Slika črne barve (vrednost 0), dimenzije 480×360 pikslov
 - Gaussovo jedro s centrom na točki (centralni piksel ima vrednost 1)
 - Vsaka vhodna slika ima 10 label
- Pretvorba v podatkovno bazo LMDB
 - Vse slike in njihove labele
 - Dve bazi – učna in testna



SEGNET (1)

- Segmentacija slik
- Ogradje Caffe
- Baza: Cambridge-driving Labeled Video Database (CamVid)
- Video







(VIDEO – SEGNET - CAMVID)

SEGNET (2)


- Popolnoma konvolucijska
- Kodirnik – izdvajanje nizkoločljivostnega zemljevida značilnic
- Dekodirnik – preslikava nizkoločljivostnega zemljevida v izvorno ločljivost razredov
- Vhod: barvna slika in segmentirana (sivinska) slika (temeljna resnica)
- Izhod: izguba (loss) po aktivacijskem sloju softmax (učna faza)





KEYPOINTNET

- Modifikacija SegNet
- Ohranitev sredinskega dela
- Sprememba vhodnega sloja:
 - Sivinska slika + 10 label z Gaussovimi jedri (11 sivinskih globin)
 - $11 \times 360 \times 480$
 - Sloj LMDB
- Sprememba izhodnega sloja:
 - Softmax (klasifikacija/segmentacija)
 - Sigmoidna funkcija (zamenjava)
 - »Verjetnostna slika« za vsako točko







UČENJE NEVRONSKE MREŽE

- Zagon učenja v ogrodju Caffe z zastavico »-train« in datoteko »solver«
 - Pot do mreže (»KeypointNet.prototxt«)
 - Pot do podatkov (LMDB)
 - Ostale nastavitve
- Učenje uteži nevronov glede na izgubo (loss)
 - Mrežo naučimo izdelovati »labele«, takšne kot so naše označbe
 - Mreža se ne zaveda napake v smislu evklidske razdalje med napovedjo in temeljno resnico
- Strojna oprema: GeForce Titan X (Pascal)
 - Grafična postaja Inštituta za računalništvo
- Trajanje učenja: 3 ure
- Število uteži: ~1.400.000 (5,6 MB)



- 124 kefalometričnih slik iz različnih naprav
- Učna in testna množica
 - Naključna razporeditev
 - 100 slik v učni množici
 - 24 slik v testni množici
- 100.000 učnih iteracij
- 5 ponovitev
- Primer grafa izgube





Vhodna slika



iteracija 20




iteracija 160



iteracija 2.700



iteracija 3.400



iteracija 6.000



iteracija 30.000



kompozitni rezultat



HIPERPARAMETRI PRI KEYPOINTNET

- Večje število hiperparametrov
 - Maksimalno število iteracij, hitrost učenja, frekvenca testne faze, tip koraka, velikost koraka, gama, moment
- Gama:
 - Razmerje med trenutnim korakom in hitrostjo učenja
 - Formula: $\alpha = base_lr * \gamma^{\text{floor}(iter / step)}$
 - Hitrost učenja se s poznejšimi koraki manjša
- Moment
 - Del učnega algoritma Stohastični gradientni spust (SGD)
 - Definira, s kakšno utežjo upoštevamo uteži iz prejšnje iteracije učenja



HIPERPARAMETRI - IZBIRA

- Iskanje hiperparametrov po mreži (*angl. Grid Search*)
- Gama: 0,8
- Moment: 0,5
- Učni algoritem: SGD
- Ostali parametri na priporočenih vrednostih




METRIKA ZA OCENJEVANJE NAPAKE

- Izguba (loss) ni ustrezna metrika
- Napako merimo kot evklidsko razdaljo med
 - Označeno točko (temeljna resnica)
 - Napovedano točko (tj. položaj maksimalne vrednosti na labeli)
 - Napaka podana v pikslih

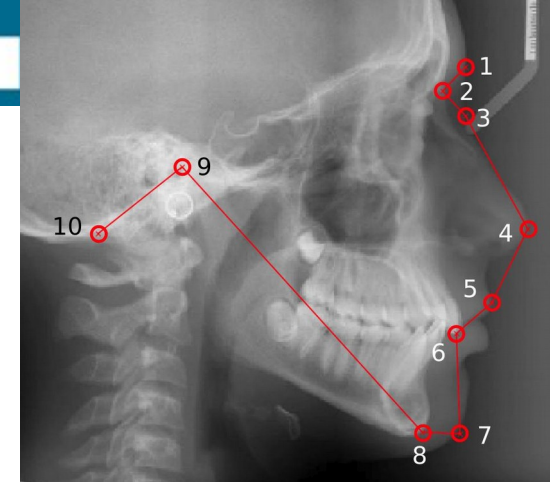
REZULTATI – NAPAKA PO TESTNIH SLIKAH

Prikaz po posameznih testnih slikah






REZULTATI – NAPAKA PO TOČKAH



Prikaz po posameznih kefalometričnih točkah





POVZETEK

- Razvili postopek za detektiranje kefalometričnih točk na kefalogramih
- Uporaba ogrodja Caffe in modifikacija obstoječe arhitekture (SegNet)
- Na voljo le 124 slik različnih naprav
- Razvili orodje za označevanje 10 kefalometričnih točk (označevanje žal brez pomoči ekspertov)
- Povprečna napaka detekcije točk je 2,7 piksla
- Sklep: Uporaba globokega učenja za zaznavanje točk je primerna



ANIMIRANI PRIKAZ UČENJA (VIDEO)

