

OCENJEVANJE STAROSTI OSEBE NA OSNOVI DIGITALNIH POSNETKOV Z UPORABO MODIFICIRANE MREŽE VGG-FACE

TILEN KREL¹ IN BOŽIDAR POTOČNIK²

¹ Krelware s.p., Selnica ob Dravi, Slovenija.

E-pošta: tilen.krel@krelware.com.

² Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko, Maribor, Slovenija.

E-pošta: bozidar.potocnik@um.si.

Povzetek V članku predstavimo model konvolucijske nevronske mreže za ocenjevanje starosti osebe iz digitalnega posnetka. Kot osnova za naš model je bila uporabljena in modificirana obstoječa arhitektura konvolucijske nevronske mreže VGG-Face, namenjena razpoznavanju obrazov. Za učenje in testiranje sta bili uporabljeni bazi podatkov IMDB-WIKI in FG-NET. Na bazi podatkov IMDB-WIKI je bila dosežena povprečna napaka med dejansko in ocenjeno starostjo 6,7 leta, na bazi podatkov FG-NET pa je z validacijsko metodo »izpusti-eno-osebo« bila izračunana povprečna napaka med dejansko in ocenjeno starostjo 3,9 leta. Dobljeni rezultati so primerljivi oziroma le malo zaostajajo za najuspešnejšimi metodami za ocenjevanje starosti osebe iz digitalnega posnetka. Na tej osnovi naš model ocenjujemo kot primeren za uporabo v produkcijskih rešitvah.

Prispevek temelji na:

Krel, T. (2021).

Ocenjevanje starosti osebe na osnovi digitalnih posnetkov z uporabo konvolucijskih nevronske mreže: magistrsko delo, Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko, Maribor.

Ključne besede:

računalniški vid, konvolucijske nevronske mreže, globoko učenje, ocenjevanje starosti, mreža VGG-Face

PERSON AGE ESTIMATION BASED ON DIGITAL IMAGES USING MODIFIED VGG-FACE NETWORK

The paper is
based on:

Krel, T. (2021).

Ocenjevanje
starosti osebe na
osnovi digitalnih
posnetkov z
uporabo
konvolucijskih
nevronskih mrež:
master's thesis,
University of
Maribor, Faculty
of Electrical
Engineering and
Computer Science.
Maribor.

Keywords:

computer
vision,
convolutional
neural
networks,
deep
learning,
age
estimation
VGG-Face
net

TILEN KREL¹ & BOŽIDAR POTOČNIK²

¹ Krelware s.p., Selnica ob Dravi, Slovenia.

E-mail: tilen.krel@krelware.com

² University of Maribor, Faculty of Electrical Engineering and Computer Science,
Maribor, Slovenia.

E-mail: bozidar.potocnik@um.si

Abstract In this article we present a convolutional neural network model for a person age estimation from an image. As a base for our model, we used and modified the existing convolutional neural network architecture VGG-Face, used for face recognition. For learning and testing, the IMDB-WIKI and FG-NET datasets were used. With the IMDB-WIKI dataset, we achieved the average error 6.7 years between the actual and the estimated age, while using the FG-NET dataset, we calculated the average error 3.9 years between the actual and the estimated age, whereas the »leave-one-person-out« validation method was employed. The obtained results are comparable to or only slightly behind the state-of-the-art methods for the age estimation from a digital image. On this basis, we evaluate our model as suitable for use in production solutions.

1 Uvod

Med uporabna področja računalniškega vida spada tudi področje analize oseb na osnovi posnetkov obrazov, kjer s postopki računalniškega vida iz posnetka obraza pridobimo želene informacije o osebi na sliki. Primeri uporabe informacij o obrazu so samodejno beleženje prisotnih študentov na predavanjih (Grover, 2019), samodejno preverjanje potnih listov na letališčih (MRZ, 2022) ali pa verifikacija identitete kot dodaten varnostni sloj pri dvigu gotovine na bankomatu (Murugesan, 2020).

Zelo koristna informacija, ki jo lahko pridobimo iz posnetka obraza, je starost osebe. Podatek o starosti osebe nam koristi na področjih, kot so nadzor dostopa do vsebin, biostatistika, profiliranje uporabnikov, pametno oglaševanje, simulacije staranja in varnostni sistemi.

Določanje starosti osebe je zahtevno opravilo že za človeka, razlog za to pa so različni dejavniki, kot so na primer življenjski slog osebe (kajenje, slabo prehranjevanje), ki lahko osebo navidezno postarajo, okoljski vplivi (življenje v onesnaženih okoljih, visoka izpostavljenost soncu), genetika, poraščenost obraza ali uporaba ličil, različni vzorci staranja pri različnih rasah itd. Na zajetih posnetkih k temu dodamo še dodatne dejavnike, kot so poza osebe, izraz na obrazu in osvetlitev fotografije. Vse to še dodatno oteži analiziranje slike.

Za nov preboj pri ocenjevanju starosti na osnovi digitalnih posnetkov so poskrbele metode strojnega učenja, natančnejše globoke konvolucijske nevronske mreže, ki so se izkazale kot dobra rešitev že pri veliko drugih težavah procesiranja vizualnih podatkov (Glavez, 2018), (Sultana, 2020).

V tej raziskavi predstavimo naš razvit model konvolucijske nevronske mreže za ocenjevanje starosti osebe iz digitalnega posnetka. Nad modelom izvedemo več eksperimentov. Najprej preizkusimo natančnost razvitega modela ob različnih nastavitvah hiperparametrov in izvedemo primerjavo s sorodnimi deli. Preverimo tudi, v kolikšni meri spol osebe na digitalnem posnetku vpliva na natančnost ocenjevanje starosti, oziroma, ali lahko različne vzorce staranja zajamemo tudi med učenjem konvolucijske nevronske mreže in jih izkoristimo za natančnejše

ocenjevanje starosti osebe na digitalnem posnetku. Rezultate in ugotovitve natančno kvantificiramo.

2 Algoritem za ocenjevanje starosti z uporabo modela VGG-Face

Za osnovo za svoj algoritem smo izbrali arhitekturo VGG-16, saj na njej temelji veliko uspešnih algoritmov s področja računalniškega vida (Parlhi, 2015), (Rothe, 2015). Izbrali smo različico modela VGG-16, imenovano VGG-Face, ki je bila razvita za razpoznavanje obrazov (Parlhi, 2015). Za to različico modela smo se odločili, ker je bil za namen razpoznavanja obrazov model učen na več kot milijonu digitalnih posnetkov obrazov. Takšen model se je naučil prepoznavati značilnice obrazov, ki so uporabne tudi za naš sistem za ocenjevanje starosti. V naši raziskavi uporabimo prenosno učenje (angl. transfer learning). Da bi ohranili že naučeno znanje, ki smo ga pridobili z uporabo uteži drugega, že naučenega modela, smo v našem modelu zamrznili vse plasti, razen zadnjih treh konvolucijskih. Uteži zamrznjenih plasti se med učenjem niso spreminjale (Krel, 2021).

Ocenjevanje starosti smo opredelili kot klasifikacijski problem s 101 razredom, ki predstavljajo leta od 0 do vključno 100. Zadnja konvolucijska plast v VGG-Face za potrebe razpoznavanja obrazov vsebuje 2.622 izhodov, ki smo jih nadomestili s svojimi klasifikacijskimi razredi.

Tako smo dobili model, ki na vhodu pričakuje digitalni posnetek velikosti 224 x 224 slikovnih elementov s tremi barvnimi kanali, izhod pa predstavlja 101 klasifikacijski razred. Model ima trinajst konvolucijskih plasti in skupno 134.674.341 parametrov, pri čemer je 119.959.653 parametrov možno učiti, 14.714.688 parametrov pa je zamrznjenih.

3 Eksperimentalno okolje

Izvorno kodo algoritma smo pripravili v splošno namenskem programskem jeziku Python. Za delo z nevronskimi mrežami smo uporabili odprtokodno programsko ogrodje Keras (Keras, 2022), ki služi kot vmesnik do odprtokodne knjižnice TensorFlow (Tensorflow, 2022), ki ponuja širok nabor operacij za učenje in delo z nevronskimi mrežami (Krel, 2021).

Ker je učenje konvolucijske nevronske mreže računsko zahtevno in težko izvedljivo na povprečnem osebem računalniku, smo za učenje uporabili storitev Google Colaboratory (Google Colaboratory, 2022). Google Colaboratory omogoča izvedbo kode Python v oblaku prek spletnega brskalnika. Storitev je priljubljena predvsem pri razvijalcih algoritmov strojnega učenja, saj omogoča dostop do zmogljivih grafičnih procesnih enot.

3.1 Uporabljene slikovne baze podatkov za ocenjevanje starosti

V tej raziskavi smo za učenje in eksperimente uporabili podatkovni bazi FG-NET in IMDB-WIKI.

Baza podatkov FG-NET (FG-NET, 2022) vsebuje 1.002 digitalnih posnetkov 82 različnih oseb. Razpon starosti oseb je med 0 in 69 let. Informacija o starosti osebe na digitalnem posnetku je shranjena v imenu slikovne datoteke v formatu: id_osebe_A_starost_osebe.jpg (primer: datoteka, poimenovana 065A09.jpg, vsebuje digitalni posnetek obraza osebe z identifikatorjem 065 in starostjo 9 let).

Baza podatkov IMDB-WIKI (IMDB-WIKI, 2022) vsebuje 524.230 digitalnih posnetkov obrazov različnih znanih oseb, samodejno pridobljenih s spletnih strani IMDB in Wikipedija. Posnetkom je dodana datoteka s končnico .mat, iz katere lahko z orodjem Matlab preberemo različne metapodatke o osebi na digitalnem posnetku (npr. datum rojstva, spol). Baza je razdeljena na več direktorijev z digitalnimi posnetki, metapodatki o posnetkih pa so zapisani v dveh ločenih datotekah za digitalne posnetke, pridobljene s spletne strani IMDB in za digitalne posnetke, pridobljene iz Wikipedije. Ker so posnetki pridobljeni samodejno s spleta, vsebujejo tudi napačne in neustrezne posnetke ter napačne metapodatke, zato moramo podatkovno bazo prečistiti.

4. Eksperimenti

Izvedli smo več različnih eksperimentov. Najprej smo večkrat ponovili učenje nevronske mreže za iskanje optimalnih nastavitvev hiperparametrov. Zatem smo izvedli eksperimente, s katerimi smo preverili vpliv spola na uspešnost ocenjevanja starosti ter opravili primerjavo našega algoritma s sorodnimi rešitvami (Krel, 2021).

4.1 Eksperiment 1: Učenje modela na podatkovni bazi IMDB-WIKI

Najprej smo preverili, kako dobro se je naš model sposoben naučiti ocenjevanja starosti. Za učenje in validacijo smo uporabili prečiščeno bazo IMDB-WIKI, kjer smo za učenje uporabili 95.121 digitalnih posnetkov iz podmnožice IMDB. Učenje smo izvedli v 500 epohah. V vsaki epohi smo naključno prebrali 10.240 digitalnih posnetkov, ki smo jih razdelili v razmerju 80:20; 8.192 posnetkov za učenje in 2.048 posnetkov za validacijo. Uspešnost smo ovrednotili s povprečno napako med dejansko in ocenjeno starostjo osebe nad 5.000 posnetkih iz podmnožice WIKI.

Eksperiment smo izvedli večkrat, s preizkusom različnih nastavitvev hiperparametrov in optimizacijskih algoritmov. Preizkusili smo dva različna optimizacijska algoritma, in sicer stohastični gradientni sestop (angl. Stochastic Gradient Descent, SGD) ter optimizacijski algoritem Adam.

Pri optimizacijskem algoritmu SGD smo uporabili dva načina, in sicer s konstantno stopnjo učenja (angl. learning rate) in s spremenljivo stopnjo učenja, hiperparametre pa nastavili kot:

- moment (angl. momentum): 0,9,
- stopnjo učenja: 0,01,
- upad stopnje učenja (uporabljeno le pri modelu s spremenljivo stopnjo učenja): 0,001.

Pri optimizacijskem algoritmu Adam smo izbrali stopnjo učenja 0,01. Vrednosti vseh omenjenih hiperparametrov so nastavljene glede na priporočila oziroma privzete vrednosti v ogrodju Keras.

Učenje smo opravili v paketnem načinu, kjer smo kot del eksperimenta spreminjali število posnetkov v paketu, in sicer smo uporabili pakete s 64, 128 in 256 posnetki.

4.2 Eksperiment 2: Vpliv spola na uspešnost ocenjevanja starosti

V naslednjem eksperimentu smo preverjali, ali lahko s poznavanjem spola osebe izboljšamo natančnost ocenjevanja starosti. Ponovno smo uporabili podatkovno bazo IMDB-WIKI, kjer metapodatki vsebujejo tudi podatek o spolu osebe. Iz podmnožice IMDB smo tvorili novi podmnožici s posnetki samo moških (45.413 posnetkov) in s posnetki samo žensk (48.673 posnetkov). Učenje smo izvedli dvakrat od začetka, in sicer prvič le na podmnožici posnetkov s samo moškimi, pri čemer smo posnetke moških razdelili v razmerju 80 % (36.330 posnetkov) za učenje in 20 % (9.083 posnetkov) za validacijo, nato pa še na podmnožici posnetkov s samo ženskami, kjer smo posnetke razdelili v enakem razmerju 80:20 (38.938 posnetkov za učenje in 9.735 posnetkov za validacijo). Pri učenju obeh modelov smo uporabili optimizacijski algoritem SGD z momentom 0,9, stopnjo učenja 0,01 in pakete z velikostjo 128 posnetkov. Za ocenjevanje uspešnosti smo pripravili tri različne testne baze podatkov iz podmnožice WIKI, pri čemer smo v prvi izbrali 5.000 posnetkov obeh spolov, v drugi 5.000 posnetkov le moških in v tretji 5.000 posnetkov le žensk. Uspešnosti smo vrednotili s povprečno napako med dejansko in ocenjeno starostjo osebe nad vsemi tremi testnimi bazami ločeno za model, učen le na posnetkih moških in za model, učen le na posnetkih žensk (Krel, 2021).

4.3 Eksperiment 3: Primerjava s sorodnimi deli

V zadnjem eksperimentu smo primerjali naš algoritem in s sorodnimi deli. Za eksperiment smo uporabili model z optimizacijskim algoritmom SGD, momentom 0,9, stopnjo učenja 0,01 ter pakete velikosti 128 posnetkov. Model smo učili na posnetkih iz podatkovne baze FG-NET po metodi validiranja LOPO (angl. Leave-One-Person-Out).

4.4 Metrike za vrednotenje rezultatov

Za vrednotenje smo uporabili metriko povprečne absolutne napake MAE (angl. Mean Absolute Error) in metodo validiranja LOPO. Z metriko MAE merimo razliko med ocenjeno in dejansko starostjo osebe. Izračunamo jo kot:

$$MAE = \frac{1}{K} \sum_{i=1}^K |y'_i - y_i| \quad (1)$$

kjer y'_i pomeni ocenjeno starost osebe na i -tem posnetku, y_i dejansko starost osebe na i -tem posnetku in K število testnih posnetkov. Manjša izračunana napaka seveda pomeni boljši rezultat.

Primerjavo svojega algoritma z obstoječimi rešitvami smo opravili z metodo LOPO na bazi podatkov FG-Net, ki vsebuje 1.002 posnetkov 82 različnih oseb, posnetih pri različnih starostih. V eksperimentu smo pripravili isto število modelov, kot je različnih oseb v množici. Za vsakega izmed modelov smo pripravili testno in učno množico tako, da smo tvorili novo učno množico na način, da smo iz originalne učne množice izločili vse posnetke izbrane osebe. Te izločene posnetke, ki vsi pripadajo izbrani osebi, smo uporabili kot testno množico, na kateri smo izračunali MAE. Postopek smo ponovili za vse osebe v bazi podatkov. Na koncu smo izračunali še povprečje vseh izračunanih MAE (kar označimo z LOPO) kot:

$$LOPO = \frac{1}{L} \sum_{i=1}^L MAE_i \quad (2)$$

kjer L pomeni število vseh različnih oseb v bazi podatkov, MAE_i pa izračunano napako med ocenjenimi in dejanskimi starostmi na posnetkih i -te osebe.

5 Rezultati

V prvem eksperimentu smo našo mrežo učili na bazi podatkov IMDB-WIKI, pri čemer smo uporabili 95.121 posnetkov iz podmnožice IMDB za učenje, testirali pa na 5.000 še nevidenih posnetkih iz podmnožice WIKI. Tabela 1 prikazuje rezultate, ovrednotene z metriko MAE, za različne optimizacijske algoritme in različne velikosti paketov ob različnem številu epoh, pri čemer je za vsako kombinacijo nastavitve poudarjen najboljši rezultat (najmanjša metrika MAE).

Tabela 1: Rezultati eksperimenta 1. Podana metrika MAE (v letih), pri čemer je najboljši rezultat označen krepko.

Nastavitev učenja	Epoch 100	Epoch 200	Epoch 300	Epoch 400	Epoch 500
SGD (64 posnetkov v paketu)	6,99	6,80	6,72	6,85	7,02
SGD (128)	7,43	7,09	6,83	6,75	6,68
SGD (256)	8,94	7,68	7,20	6,99	6,83
SGD LR (64)	7,00	7,23	7,38	7,38	7,31
SGD LR (128)	7,10	7,12	7,34	7,45	7,58
SGD LR (256)	6,99	7,39	7,42	7,41	7,60
ADAM (64)	7,00	6,99	7,08	7,20	7,39
ADAM (128)	6,97	7,40	7,45	7,43	7,44
ADAM (256)	7,29	7,40	7,62	7,77	7,69

Opazimo, da z uporabo spreminjajoče se stopnje učenja (SGD s spremenljivo stopnjo učenja in Adam) dosežemo dobre rezultate že po 100 oziroma 200 epochah, vendar pa najboljši rezultat med vsemi dosežemo z uporabo učnega algoritma SGD s konstantno stopnjo učenja po 500 epochah.

Trajanje neprekinjenega učenja modela z učnim algoritmom SGD in 128 posnetki v paketu je trajalo 564 minut, učenje modela z učnim algoritmom Adam in 128 posnetki v paketu pa 447 minut. Med učenji prihaja do razlik v potrebnem času za učenje, saj se v okolju Google Colaboratory razpoložljiva sredstva dodeljujejo dinamično glede na zasedenost virov.

V drugem eksperimentu smo našo nevronske mrežo učili ločeno za posnetke moških in žensk na bazi podatkov IMDB-WIKI, pri čemer smo za učenje uporabili 45.413 posnetkov moških in 48.673 posnetkov žensk iz podmnožice IMDB. Tabela 2 prikazuje rezultate modela, učenega na posnetkih moških, in ovrednotenega z metriko MAE nad 5.000 še nevidenimi posnetki moških, žensk in obeh spolov skupaj iz podmnožice WIKI, tabela 3 pa prikazuje po enakem protokolu še rezultate modela, učenega na posnetkih žensk.

Tabela 2: Rezultati eksperimenta 2 (različica A): Model je bil naučen le na posnetkih moških. V tabeli je podana metrika MAE (v letih).

Testna množica WIKI	MAE
Moški	6,71
Ženske	10,45
Vsi	7,88

Tabela 3: Rezultati eksperimenta 2 (različica B): Model je bil naučen le na posnetkih žensk. V tabeli je podana metrika MAE (v letih).

Testna množica WIKI	MAE
Moški	9,20
Ženske	7,51
Vsi	8,71

V zadnjem eksperimentu smo naredili primerjavo med našo metodo in sorodnimi deli. Rezultate, ki smo jih nad bazo podatkov FG-NET ovrednotili z validacijsko metodo LOPO, prikazuje tabela 4. Najboljša metoda ima najnižjo vrednost MAE.

Tabela 4 Rezultati eksperimenta 3: Primerjava s sorodnimi deli na množici FG-NET s pomočjo validacije LOPO. V tabeli je podana metrika MAE (v letih).

Metoda	MAE
AGES (Geng, 2007)	6,77
CPNN (Geng, 2013)	4,76
<i>Človeški opazovalec (Han, 2015)</i>	4,70
MV (Pan, 2018)	4,10
Naša rešitev	3,91
DRFs (Shen, 2018)	3,85
DEX (Rothe, 2015)	3,09
BridgeNet (Li, 2019)	2,56

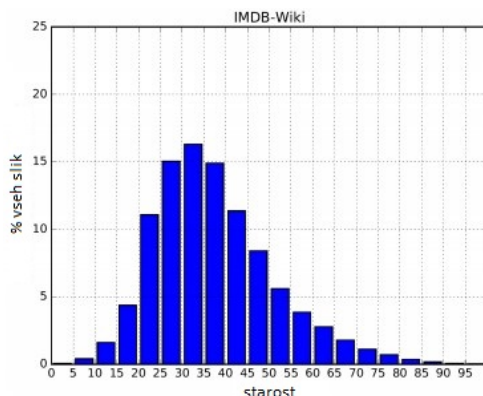
6 Diskusija in zaključek

V tem članku smo predstavili modificirano arhitekturo VGG-Face, namenjeno ocenjevanju starosti osebe na osnovi enega digitalnega posnetka. Pri učenju smo si pomagali s prenosnim učenjem. Rezultati testiranja so pokazali, da smo se približali sodobnim metodam, še bolj spodbudno pa je spoznanje, da smo na bazi podatkov FG-NET s pomočjo validacije LOPO dosegli boljše ocenitev starosti kot človeški opazovalec.

Menimo, da je povprečna napaka ocene 6,7 leta na podatkovni bazi IMDB-WIKI in 3,9 leta na podatkovni bazi FG-NET dovolj dober rezultat, da ocenimo svoj model kot primeren za uporabo v produkcijskih rešitvah. Ob ocenjevanju starosti namreč le redkokdaj potrebujemo natančnejšo oceno starosti, pogosteje nas zanimajo določeni širši razponi let, na primer, v kakšne starostne skupine spadajo udeleženci dogodka, ki jih posnamemo pri vходу v dvorano, ali pa s kakšno gotovostjo lahko

ocenimo, da je oseba pri nakupu alkoholne pijače na avtomatu polnoletna (Krel, 2021).


Kot glavni prednosti predlagane metode navajamo primerno uspešnost ocenjevanja starosti osebe in zmožnost hitrega prilaganja naše rešitve z uporabo prenosnega učenja. Med slabosti pa štejemo omejitve, da je naša rešitev trenutno zmožna obdelati le en obraz naenkrat, ter slabše ocenjevanje starosti mlajših otrok in starejših oseb. Slednje je nedvomno posledica pomanjkanja posnetkov v teh starostnih skupinah oziroma neenakomerne porazdelitve učnih vzorcev po starosti v bazi podatkov IMDB-WIKI (glej sliko 1). Pomanjkanje kakovostne baze podatkov z zadostnim in uravnoteženim številom označenih digitalnih posnetkov je sicer težava, ki jo omenjajo tudi avtorji sorodnih del (Rothe, 2015).



Slika 1: Porazdelitev posnetkov po starosti v bazi podatkov IMDB-WIKI

Vir: lasten


Na sliki 2 smo predstavili nekaj testnih primerov dobro ocenjenih starosti z modelom, učenim pri 500 epohah na podmnožici IMDB iz podatkovne baze IMDB-WIKI z učnim algoritmom SGD in 128 posnetki v paketu (eksperiment 1). Opazimo, da z našo rešitvijo dobro ocenimo starost osebe na posnetku za različen spol, položaj obraza ali izraz na obrazu.



Slika 2: Primeri dobrega ocenjevanja starosti osebe na štirih testnih posnetkih s pomočjo modificiranega modela VGG-Face

Vir: lasten

Na sliki 3 pa predstavljamo nekaj testnih primerov slabo ocenjenih starosti osebe, pri čemer smo uporabili enak naučen model, kot je bil opisan zgoraj. Opazimo, da gre najpogosteje za posnetke otrok, mlajših od deset let, ali pa za osebe, starejše od osemdeset let. Problem je v pomanjkanju podatkov v teh starostnih skupinah v bazi IMDB-WIKI (glej še tekst zgoraj). Pogosto je napačna ocenitev posledice razlike med navidezno in biološko starostjo osebe (na primer tretja slika z leve na sliki 3).



Slika 3: Primeri slabšega ocenjevanja starosti osebe na štirih testnih posnetkih s pomočjo modificiranega modela VGG-Face

Vir: lasten

V prihodnosti želimo ovrednotiti vpliv drugih hiperparametrov, ki jih v tem delu še nismo analizirali. Na tak način bi poskusili izboljšati natančnost ocenjevanja starosti in tudi hitrost učenja. Prav tako bi lahko odpravili omejitev zaznavanja in ocenjevanja le ene osebe na posnetek. Nadaljnje delo bomo usmerili še v preizkušanje drugih modernih arhitektur CNN za določanje starosti osebe.

Verjamemo, da bi natančnost naše rešitve še izboljšali, če bi pripravili ali pridobili večjo in kakovostnejšo učno množico.

Literatura

- Antipov G., Baccouche M., Berrani S., Dugelay J. Apparent age estimation from face images combining general and children-specialized deep learning models. *IEEE Conference on Computer Vision and Pattern Recognition Workshops*, (2016), str. 801-809.
- FG-NET dataset by Yanwei Fu. Dostopno na: https://yanweifu.github.io/FG_NET_data/index.html [1.2.2022]
- Galvez R., Bandala A., Dadios E., Vicerra R., Maningo J. Object Detection Using Convolutional Neural Networks, *TENCON IEEE Region 10 Conference*, (2018), str. 2023-2027.
- Geng X., Zhou Z., Miles K. Automatic age estimation based on facial aging patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29, (2007), str. 2234-2240.
- Geng X., Yin C., Zhou Z. Facial age estimation by learning from label distributions, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35, (2013), str. 2401-2412.
- Google Colaboratory. Dostopno na: <https://colab.research.google.com/> [1.2.2022].
- Grover V., Chhabra N., Attendance Monitoring system Through Face Recognition, *2019 6th International Conference on Computing for Sustainable Global Development (INDIACom)*, (2019), str. 179-183.
- Han H., Otto C., Liu X., Jain A.K. Demographic estimation from face images: Human vs. Machine Performance, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 37, (2015), str. 1148-1161.
- IMDB-WIKI – 500k+ face images with age and gender labels. Dostopno na: <https://data.vision.ee.ethz.ch/cvl/rrothe/imdb-wiki/> [1.2.2022]
- Keras. Dostopno na: <https://keras.io/> [1.2.2022].
- Kerl T. Ocenjevanje starosti osebe na osnovi digitalnih posnetkov z uporabo konvolucijskih nevronske mreže. *Magistrsko delo*, 2021.
- Li W., Lu J., Feng J., Xu C., Zhou J., Tian Q. BridgeNet: A continuity-aware probabilistic network for age estimation, *IEEE Computer Vision and Pattern Recognition*, (2019), str. 1146-1154.
- MRZ code extraction from visa and passport documents using convolutional neural networks. Dostopno na: <https://arxiv.org/abs/2009.05489> [1.2.2022].
- Murugesan M., Santhosh M., Sasi T., Sasiwarman M., Valanarasu I. Securing ATM Transactions using Face Recognition, *International Journal of Advanced Trends in Computer Science and Engineering*, 9, (2020), str. 1295-1299.
- Pan H., Han H., Shan S., Chen X. Mean-variance loss for deep age estimation from face, *IEEE Computer Vision and Pattern Recognition*, (2018), str. 5285-5294.
- Parlhi O., Vedaldi A., Zisserman A., Deep Face Recognition, *British Machine Vision Conference*, (2015), str 41.1-41.12.
- Rothe R., Timofte R., Gool L. DEX: Deep EXpectation of Apparent Age from a Single Image. *IEEE International Conference on Computer Vision Workshop*, (2015), str. 252-257.
- Shen W., Guo Y., Wang Y., Zhao K., Wang B., Yuille A.L. Deep regression forests for age estimation, *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, (Junij 2018), str. 2304-2313.
- Sultana F., Sufian A., Dutta P. Evolution of Image Segmentation using Deep Convolutional Neural Network: A survey, *Knowledge-Based Systems*, 201-202, (2020), str. 1-38.
- Tensorflow: An end-to-end open source machine learning platform. Dostopno na: <https://tensorflow.org> [1.2.2022]

