

Primjena umjetne inteligencije u svrhu određivanja spola i dobi u forenzičnoj stomatologiji

Šarić, Tea

Master's thesis / Diplomski rad

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, School of Dental Medicine / Sveučilište u Zagrebu, Stomatološki fakultet**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:127:988931>

Rights / Prava: [Attribution-NonCommercial 4.0 International](#)/[Imenovanje-Nekomercijalno 4.0 međunarodna](#)

Download date / Datum preuzimanja: **2024-07-12**



Repository / Repozitorij:

[University of Zagreb School of Dental Medicine Repository](#)





Sveučilište u Zagrebu
Stomatološki Fakultet

Tea Šarić

**PRIMJENA UMJETNE INTELIGENCIJE U
SVRHU ODREĐIVANJA SPOLA I DOBI U
FORENZIČNOJ STOMATOLOGIJI**

DIPLOMSKI RAD

Zagreb, rujan 2021.

Rad je ostvaren na Zavodu za morfologiju i dentalnu antropologiju Stomatološkog fakulteta Sveučilišta u Zagrebu.

Mentor rada: izv. prof. dr. sc. Ivana Savić Pavičin, dr. med. dent. Stomatološki fakultet

Lektor hrvatskog jezika: Ivana Pavelić, mag. educ. philol. croat.

Lektor engleskog jezika: Maja Dukmeniće, mag. philol. angl. i russ.

Sastav Povjerenstva za obranu diplomskog rada:

1. _____

2. _____

3. _____

Datum obrane rada: _____

Rad sadrži: 42 stranice

7 tablica

20 slika

CD

Rad je vlastito autorsko djelo koje je u potpunosti samostalno napisano, uz naznaku izvora drugih autora i dokumenata korištenih u radu. Osim ako nije drukčije navedeno, sve su ilustracije (tablice, slike i dr.) u radu izvorni doprinos autora diplomskog rada. Autor je odgovoran za pribavljanje dopuštenja za korištenje ilustracija koje nisu njegov izvorni doprinos, kao i za sve eventualne posljedice, koje mogu nastati zbog nedopuštenog preuzimanja ilustracija odnosno propusta u navođenju njihovog podrijetla.

Zahvala

Veliko hvala mojoj dragoj i poštovanoj mentorici izv. prof. dr. sc. Ivani Savić Pavičin na pomoći i susretljivosti oko izrade ovog diplomskog rada.

Posebnu bih zahvalu uputila izv. prof. dr. sc. Marinu Vodanoviću na prenesenom znanju i podršci tijekom trajanja cjelokupnog projekta.

Neizmjereno hvala želim iskazati svojim roditeljima Mirjani i Tončiju te sestrama Ivoni i Danijeli na ljubavi, nemjerljivoj podršci i savjetima, koji su mi bili vodilja tijekom cijelog studija te dragom zetu Anti na pomoći oko tehničke izrade ovog diplomskog rada.

Hvala mom Dinu koji je velikim dijelom prošao sa mnom sve muke i nauke i vjerovao u mene onda kad ja nisam.

Hvala svim mojim kolegama i prijateljima, koji su moje studentske dane učinili nezaboravnima.

PRIMJENA UMJETNE INTELIGENCIJE U SVRHU ODREĐIVANJA SPOLA I DOBI U FORENZIČNOJ STOMATOLOGIJI

Sažetak

U ovom se radu bavimo primjenom metoda dubokog učenja na zadacima procjene zubnog statusa, procjene dobi i spola. Primjena je temeljena na analizi rendgenskih snimaka, na kojima je moguće vidjeti različite faze razvoja zuba, ali i histološke promjene na zubima već završenog razvoja. Korištenjem umjetnih konvolucijskih neuronskih mreža, navedene probleme rješavamo na vrlo efikasan i formalan matematički način. Objasnjen je koncept neuronskih mreža te je dan detaljan opis svih korištenih modela. Godine određujemo metodom regresije, spol metodom klasifikacije, a zubni status korištenjem sustava za lokalizaciju i klasifikaciju objekata YOLO i Faster RCNN. Prosječna greška pri procjeni godina iznosi 4,9 godina, točnost procjene spola je 97,11%, a modeli YOLO i Faster RCNN pri određivanju zubnog statusa ostvaruju mAP od 55,01% i 77,88%, respektivno.

Ključne riječi: zubni status; dentalna dob; spol; duboko učenje; neuronske mreže

APPLICATION OF ARTIFICIAL INTELLIGENCE FOR GENDER AND AGE ESTIMATION IN FORENSIC ODONTOLOGY

Summary

In this paper we present the application of deep-learning methods in dental status assessment and age and sex estimation. The application of deep-learning methods is based on the analysis of X-ray images which show different stages of tooth development, as well as histological changes in fully developed teeth. By using artificial convolutional neural networks, we solve these problems in a very effective and mathematically formal manner. We explain the concept of neural networks and provide a detailed insight into all models used. We use regression to determine age, classification to determine sex, and we assess dental status by utilizing localisation and classification systems such as YOLO and Faster RCNN. The average age estimation error is 4.9 years, and sex estimation accuracy is 97.11%. By using YOLO and Faster RCNN, we obtain the mAP score of 55.01% and 77.88% for dental status assessment, respectively.

Keywords: dental status; dental age; sex; deep learning; neural networks

SADRŽAJ

1. UVOD.....	1
2. MATERIJALI I METODE.....	5
2.1. Odabir ortopantomograma.....	6
2.1.1. Obrada ortopantomograma.....	6
2.1.2. Postupak obrade ortopantomograma.....	7
2.1.3. Koraci obrade ortopantomograma.....	11
2.2. Duboke neuronske mreže.....	14
2.2.1. Arhitektura neuronske mreže.....	16
2.2.2. Prednosti i mane.....	17
2.2.3. Duboke neuronske mreže.....	18
2.2.4. Konvolucijske mreže.....	18
2.2.5. Duboke neuronske mreže za detekciju i klasifikaciju.....	20
3. REZULTATI.....	23
3.1. Procjena dobi.....	24
3.2. Procjena spola.....	29
4. RASPRAVA.....	32
4.1. Primjeri praktične primjene.....	34
4.1.1. „Ljudi bez identiteta“.....	34
4.1.2. Utvrđivanje identiteta žrtava nesreća.....	35
4.1.3. Procjena dobi napuštene djece.....	35
5. ZAKLJUČAK.....	36
6. LITERATURA.....	38
7. ŽIVOTOPIS.....	41

Popis skraćenica

RTG - radiografija

CT - kompjutorizirana tomografija

CBCT - Cone Beam kompjuteriziranu tomografiju (Cone Beam Computer Tomography)

XML - proširivi jezik za označavanje (Extensible Markup Language)

FDI - Svjetska stomatološka federacija (Federation Dentaire Internationale)

WHO – Svjetska zdravstvena organizacija (World Health Organization)

IADR - Međunarodno udruženje za stomatološka istraživanja (International Association of Dental Research)

R-CNN - Konvolucijska neuronska mreža sa sjedištem u regiji (Region-based Convolutional Neural Network)

Fast R-CNN - Brza konvolucijska neuronska mreža sa sjedištem u regiji (Fast Region-based Convolutional Neural Network R-CNN)

Faster R-CNN - Brža konvolucijska neuronska mreža sa sjedištem u regiji (Faster Region-based Convolutional Neural Network)

YOLO - You Only Look Once

SSD - Single Shot Multibox Detector

GPU - jedinica za obradu grafike

UN – Ujedinjeni Narodi

Zubni status označava stanje svakog pojedinog zuba gornje i donje čeljusti, u usnoj šupljini pojedinca. Prilikom registracije zubnog statusa bilježi se broj prisutnih zuba, broj izvađenih zuba, broj zuba s karijesom, s ispunima te broj zuba opskrbljenih protetskim nadomjescima (krunice, mostovi, zubne proteze). Osim toga, zubni status uključuje registraciju svih ostalih obilježja karakterističnih za stanje pojedinog zuba, odnosno stomatognatog sustava u cjelini. U svakodnevnoj praksi, stomatolog raznim dijagnostičkim metodama određuje zubni status. Osim intraoralnim pregledom, koristi se i radiološkim pretragama, koje uključuju rendgenska snimanja (RTG), kompjutoriziranu tomografiju (CT), Cone Beam kompjuteriziranu tomografiju (CBCT) i slično.

Procjena dentalne dobi postupak je koji se rabi u dječjoj stomatologiji i ortodontiji u kliničke svrhe te u forenzičnoj stomatologiji, pri identifikaciji pojedinca i izradi dentalnog profila (1). Dentalnim se profiliranjem obično može osigurati informacija o životnoj dobi, spolu, socijalnom statusu, podrijetlu, a ponekad i podatci o zanimanju, prehrambenim navikama, sistemskim bolestima i bolestima zuba. Poznavanjem antropoloških obilježja zuba forenzični stomatolog/dentalni antropolog, može procijeniti etničku pripadnost na temelju izgleda i veličine kostiju kraniofacijalnog skeleta te izgleda i veličine zuba (2). Svrha procjene dobi na temelju ljudskih ostataka, utvrđivanje je biološkog profila umrle osobe. Dentalna identifikacija jedinstven je način identifikacije pri avionskim nesrećama, kada zbog visoke temperature stradavaju sva tkiva, a opstaju zubi. Njezino značenje dolazi do izražaja i prilikom drugih velikih prometnih katastrofa, gdje stradava velika skupina ljudi (3). Uz to, visoka je i potreba za dentalnom identifikacijom u ratnim i poslijeratnim situacijama.

Određivanje dobi neidentificiranih ljudskih ostataka pomoću zuba, temelji se na poznavanju bioloških promjena koje obilježavaju rast i razvoj zuba. Kronologija tih promjena ovisi o mnogim čimbenicima: općem tjelesnom razvoju, genetskom utjecaju, konstituciji, endokrinom statusu, prehrani, rasnoj pripadnosti. Stoga se može odrediti samo približna dob. Nakon završenog rasta i razvoja svih zuba određivanje dobi teže je, a temelji se na jedva vidljivim, ali trajnim promjenama u strukturi tvrdih zubnih tkiva.

Najčešće korištene metode za procjenu dentalne dobi utemeljene su na analizi rendgenskih snimaka, na kojima je moguće vidjeti različite faze u razvoju zuba, ali i histološke promjene na

zubima već završenog razvoja. Ubrzo nakon otkrića x-zraka, stomatološke su rendgenske snimke postale nezamjenjiv i trajan podatak, koji doktorima dentalne medicine daju uvid u stanje zubala te koštanih dijelova obiju čeljusti (1).

Određivanje spola također je moguće na temelju ortopantomograma. Skelet odrasle žene i muškarca razlikuje se po obliku i veličini. Morfološke razlike u građi kostura između spolova, počinju se razvijati već prije rođenja, a spolni se dimorfizam povećava tijekom djetinjstva i adolescencije. Nakon puberteta, otprilike oko osamnaeste godine života, spolne su razlike u kosturu toliko izražene da je moguće odrediti spol s točnošću većom od 90%. Ženski je kostur manjih dimenzija i nježnije građe, dok je muški veći i robusniji. Naravno, postoje individualne varijabilnosti, ali i varijabilnosti unutar samih populacija pa se i to, prilikom istrage, treba uzeti u obzir (4). Prema tome, kosti lubanje kod žena manje su i nježnije, a cijelo je lice više okruglo, dok su kod muškaraca kosti veće i lice četvrtastog oblika.

Glavna prednost određivanja zubnog statusa, dobi i spola pomoću ortopantomograma je neinvazivnost, što znači da je primjenjiv kod živih, ali i preminulih osoba. Pouzdanost, preciznost i točnost rendgenskih metoda za procjenu dentalne dobi, između ostaloga, ovisi o iskustvu stručnjaka koji vrši procjenu te o stupnju ponovljivosti očitavanja rendgenskih snimaka. Od presudne je važnosti da se, pri ponovljenim očitavanjima istih snimaka, dobiju isti rezultati. Nažalost, tu se zbog ljudskog čimbenika nerijetko događaju pogreške (1). Korištenjem metoda dubokog učenja, konkretno umjetnih neuronskih mreža, problem određivanja zubnog statusa te procjene spola i godina, formaliziramo na matematičkom nivou. Cijeli proces postaje kvantitativno mjerljiv, osigurava se konzistentnost i preciznost rezultata. Također, otklanja se potreba za visokom naobrazbom, iskustvom te subjektivnom procjenom pojedinca. Modele umjetnih neuronskih mreža moguće je koristiti bez posebne opreme i znanja, lako se unaprijeđuju, a sam proces dobivanja rezultata, uz priloženi ortopantomogram, traje svega nekoliko sekundi.

Cilj je istraživanja bilo razviti metode bazirane na dubokom učenju, koje će omogućiti računalnu identifikaciju zuba iz ortopantomograma, kao sastavnog dijela uzimanja zubnog statusa te metode za procjenu spola i dobi pojedinca. U ovom smo radu objasnili koncept umjetnih neuronskih mreža te smo prezentirali ukupno četiri korištena modela. Ako je suditi po dosadašnjim rezultatima, ostvarenim korištenjem metoda dubokog učenja u raznim područjima znanosti, mogli smo očekivati vrlo dobre rezultate i u ovom području. Ispitali smo mogućnosti i načine primjene metoda dubokog učenja za procjenu zubnog statusa, dobi i spola, stoga su specifični ciljevi ovog istraživanja bili identificirati prednosti i nedostatke primjene dubokog učenja za procjenu dentalne dobi i spola. Utvrditi teorijske i tehnološke pretpostavke, potrebne kako bi se duboko učenje primijenilo za procjenu dentalne dobi i spola, razviti i izraditi računalni model temeljen na dubokom učenju, koji će moći samostalno odrediti dentalnu dob i spol pojedinca. Zatim, dokazati da je primjenom trenutno dostupnih tehnologija na području dubokog učenja, moguće procijeniti dentalnu dob i spol uz prihvatljivu razinu preciznosti, pouzdanosti i ponovljivosti.

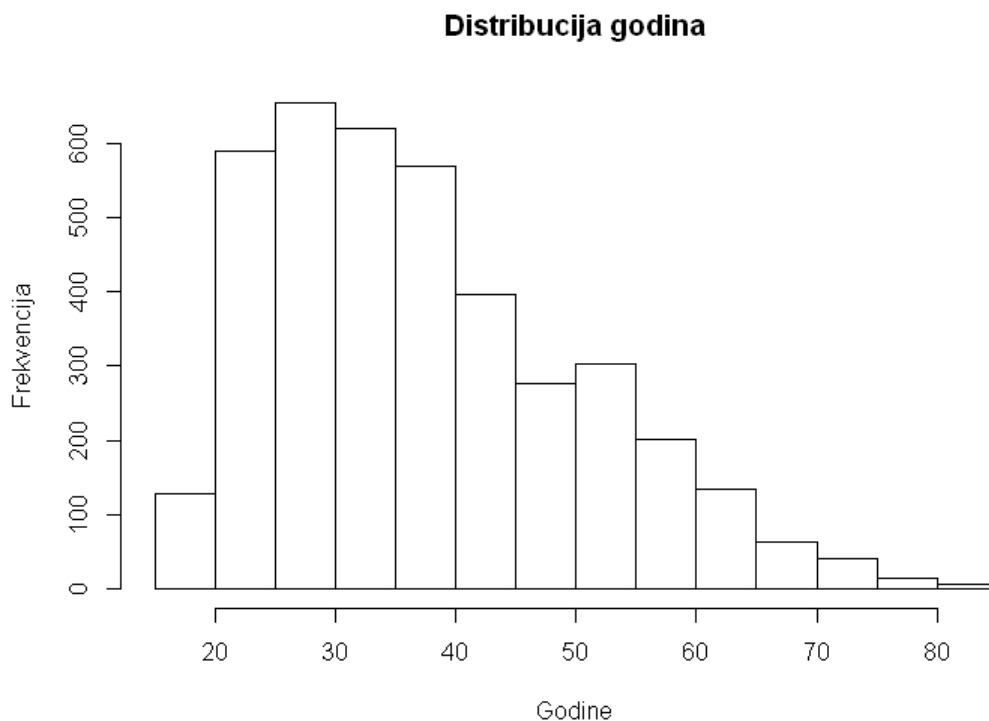
Hipoteza istraživanja glasi: primjenom trenutno dostupnih tehnologija na području dubokog učenja, moguće je procijeniti dentalnu dob, status te spol pojedinca uz prihvatljivu razinu preciznosti, pouzdanosti i ponovljivosti.

Svrha ovog istraživanja bila je ispitati mogućnosti primjene metoda dubokog učenja za potrebe računalnog uzimanja zubnog statusa, procjene spola i dobi pojedinca na temelju ortopantomograma (rendgenska snimka kompletne gornje i donje čeljusti s okolnim anatomskim strukturama, koja daje opću informaciju o kostima glave, sinusima, čeljustima, temporomandibularnim zglobovima i zubima). Kako bi to bilo moguće, osmislili smo i razvili u praksi primjenjivu metodu temeljenu na dubokom učenju, koja će moći samostalno određivati dentalnu dob i spol pojedinca.

2. MATERIJALI I METODE

2.1. Odabir ortopantomograma

Za istraživanje je korišteno 2683 digitalnih ortopantomograma poznate dobi i spola iz zbirke Zavoda za dentalnu antropologiju, Stomatološkog fakulteta Sveučilišta u Zagrebu. Ortopantomogrami su prikupljeni na Zavodu tijekom više godina, adekvatno su pohranjeni i koriste se u znanstveno-istraživačke svrhe. Sa ortopantomograma su uklonjeni podaci o identitetu. Nije bilo snimanja novih ortopantomograma za potrebe ovog istraživanja.



Slika 1. Distribucija ortopantomograma po godinama.

2.1.1. Obrada ortopantomograma

Obrada je provedena od strane članova tima, studenata Stomatološkog fakulteta u Zagrebu, koji su stručni u tome, kako bi baza označenih slika bila što pouzdanija. Korišteni ortopantomogrami obrađivani su pomoću besplatnog računalnog programa LabelImg (5). To je grafički alat za

označavanje slika, napisan u programskom jeziku Python. Oznake se spremaju kao XML datoteke u PASCAL VOC formatu za daljnje korištenje u neuronskim mrežama.

2.1.2. Postupak obrade ortopantomograma

Obrada je započeta unosom digitalnog oblika ortopantomograma u navedeni računalni program. Stvaranjem pravokutnika oko svakog pojedinog zuba, cilj je bio obuhvatiti cijeli opseg pojedinog zuba, uključujući krunu i korijen. Na mjestima izvađenog i nenadomještenog zuba, otprilike je postavljen pravokutnik u okvirima u kojima bi taj zub postojao. Zube smo označavali dualnim ili dvobrojnim sustavom, kojeg je predložila FDI (Federation Dentaire Internationale) u Bukureštu 1970. Godine. Prihvaćen od strane World Health Organization (WHO) i International Association of Dental Research (IADR). Svaki zub se označava dvjema brojkama: prva označava kvadrant, a druga broj. Kvadranti u trajnoj denticiji: 1, 2, 3, 4. Kvadranti u mliječnoj denticiji: 5, 6, 7, 8. Prilikom izgovora se izgovara svaka znamenka oznake pojedinačno, npr. za zub s oznakom 11 kažemo: “zub jedan jedan”, a ne “jedanaest”; oznaka 11 se odnosi na trajni gornji desni prvi sjekutić.

TRAJNI ZUBI															
gore desno								gore lijevo							
18	17	16	15	14	13	12	11	21	22	23	24	25	26	27	28
48	47	46	45	44	43	42	41	31	32	33	34	35	36	37	38
dolje desno								dolje lijevo							

Slika 2. Prikaz dvobrojnog (dualnog) označavanja trajnih zubi.

Kako bismo što preciznije odredili status zubi, osim dualnog sustava označavanja, dogovoreno je devet pojmova koji opisuju status pojedinog zuba. Te su oznake navedene u tablici. Postoji mogućnost da pojedini zub ima više oznaka, ovisno o njegovom stanju. Uz svaku oznaku stoji objašnjenje i primjer. Uz oznaku jednog zuba može biti pridruženo više dodatnih oznaka.

Tablica 1. Obašnjenje oznaka zuba gornje čeljusti.

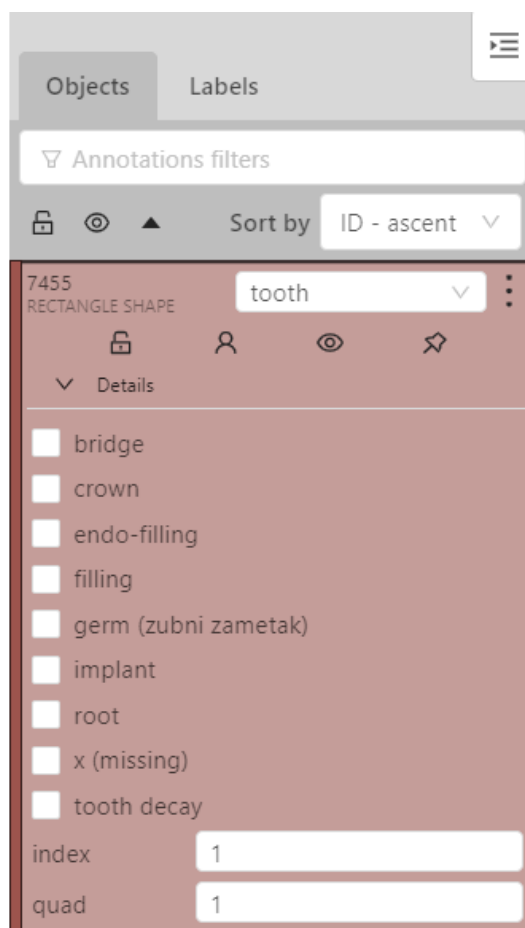
Oznaka	Značenje	Oznaka	Značenje
11	Trajni gornji desni središnji sjekutić	21	Trajni gornji lijevi središnji sjekutić
12	Trajni gornji desni bočni sjekutić	22	Trajni gornji lijevi bočni sjekutić
13	Trajni gornji desni očnjak	23	Trajni gornji lijevi očnjak
14	Gornji desni prvi pretkutnjak	24	Gornji lijevi prvi pretkutnjak
15	Gornji desni drugi pretkutnjak	25	Gornji lijevi drugi pretkutnjak
16	Trajni gornji desni prvi kutnjak	26	Trajni gornji lijevi prvi kutnjak
17	Trajni gornji desni drugi kutnjak	27	Trajni gornji lijevi drugi kutnjak
18	Gornji desni treći kutnjak	28	Gornji lijevi treći kutnjak

Tablica 2. Obašnjenje oznaka zuba donje čeljusti.

Oznaka	Značenje	Oznaka	Značenje
31	Trajni donji lijevi središnji sjekutić	41	Trajni donji desni središnji sjekutić
32	Trajni donji lijevi bočni sjekutić	42	Trajni donji desni bočni sjekutić
33	Trajni donji lijevi očnjak	43	Trajni donji desni očnjak
34	Donji lijevi prvi pretkutnjak	44	Donji desni prvi pretkutnjak
35	Donji lijevi drugi pretkutnjak	45	Donji desni drugi pretkutnjak
36	Trajni donji lijevi prvi kutnjak	46	Trajni donji desni prvi kutnjak
37	Trajni donji lijevi drugi kutnjak	47	Trajni donji desni drugi kutnjak
38	Donji lijevi treći kutnjak	48	Donji desni treći kutnjak

Tablica 3. Objašnjenje oznaka za određivanje zubnog statusa.

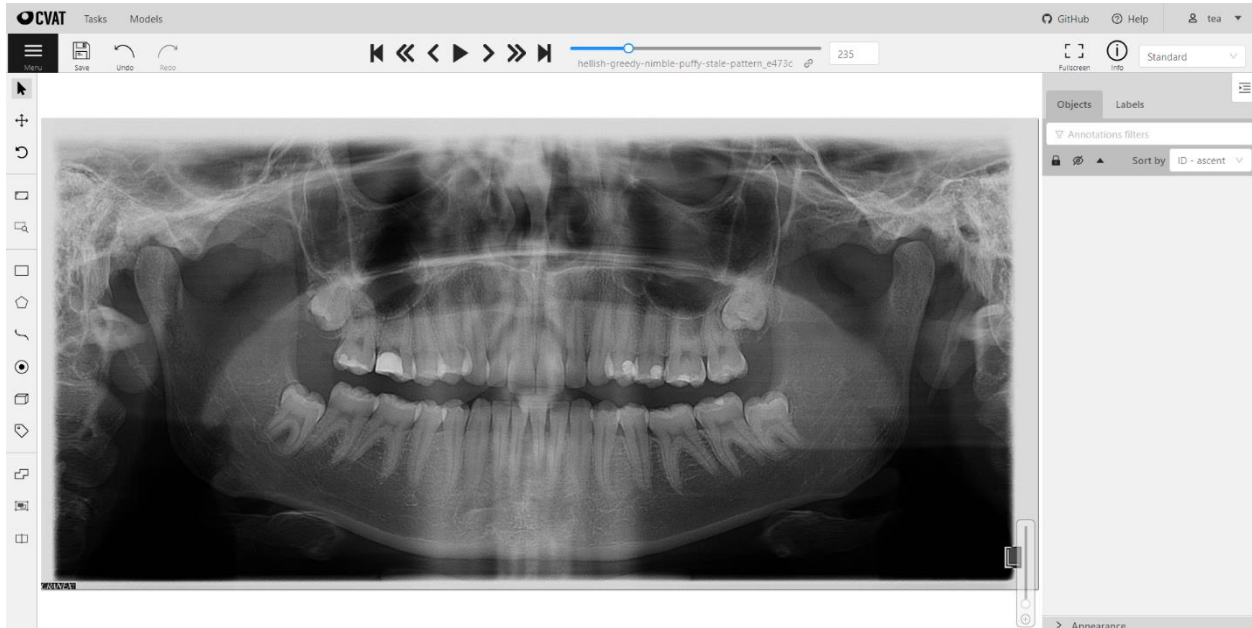
BRIDGE	Protetski most
CROWN	Protetska krunica
ENDO-FILLING	Endodontski liječen zub
FILLING	Kompozitni/amalgamski ispun
GERM	Zubni zametak
IMPLANT	Implantat
ROOT	Zaostali korijen zuba
X (missing)	Zub koji nedostaje
TOOTH DECAY	Karijes
INDEX	Zub koji označavamo
QUAD	Broj kvadranta u kojem se zub nalazi



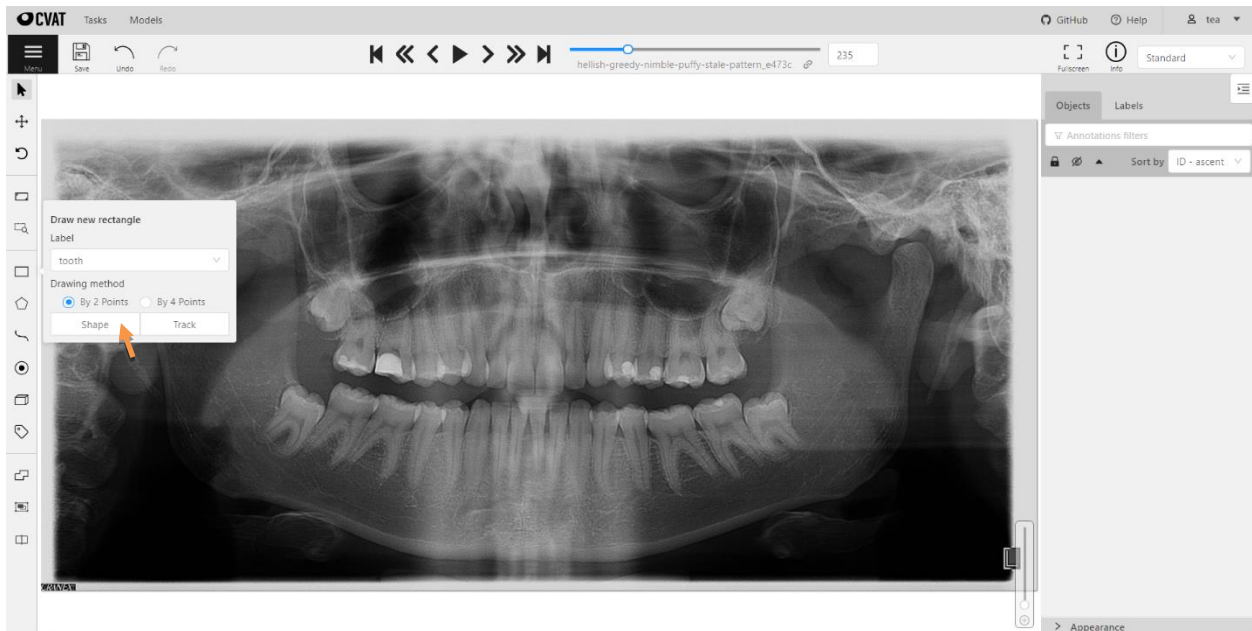
Slika 3. Pregled načina određivanja statusa svakog pojedinog zuba.

2.1.3. Koraci obrade ortopantomograma

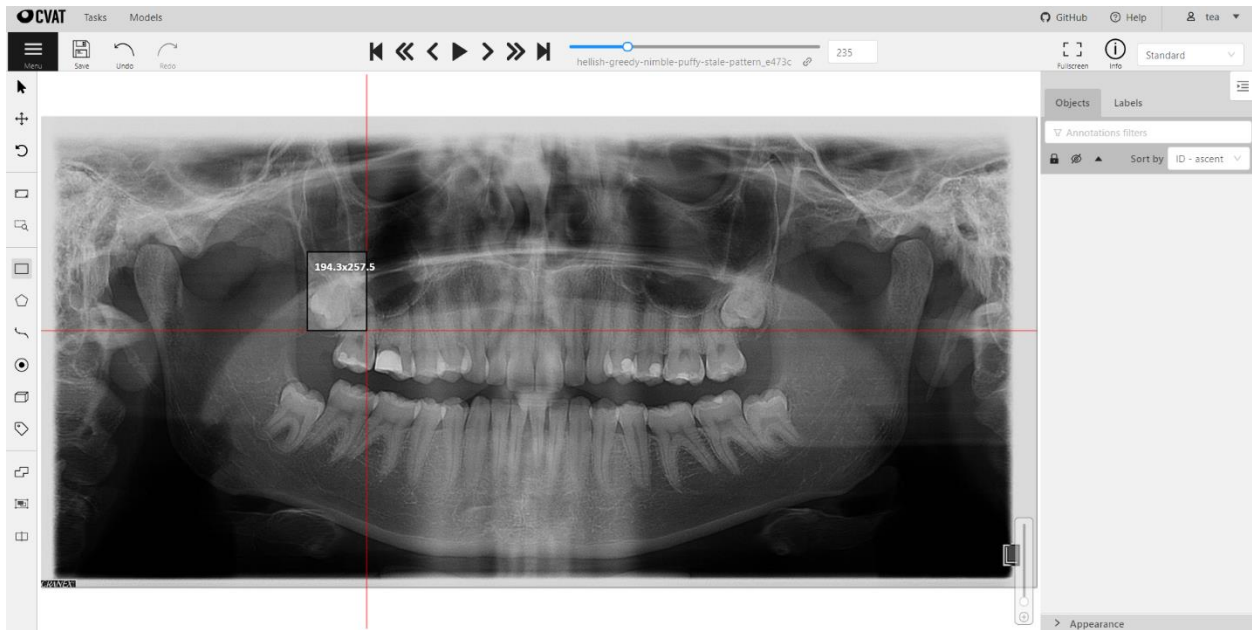
Sljedećim su slikama ilustrirani koraci označavanja zubi.



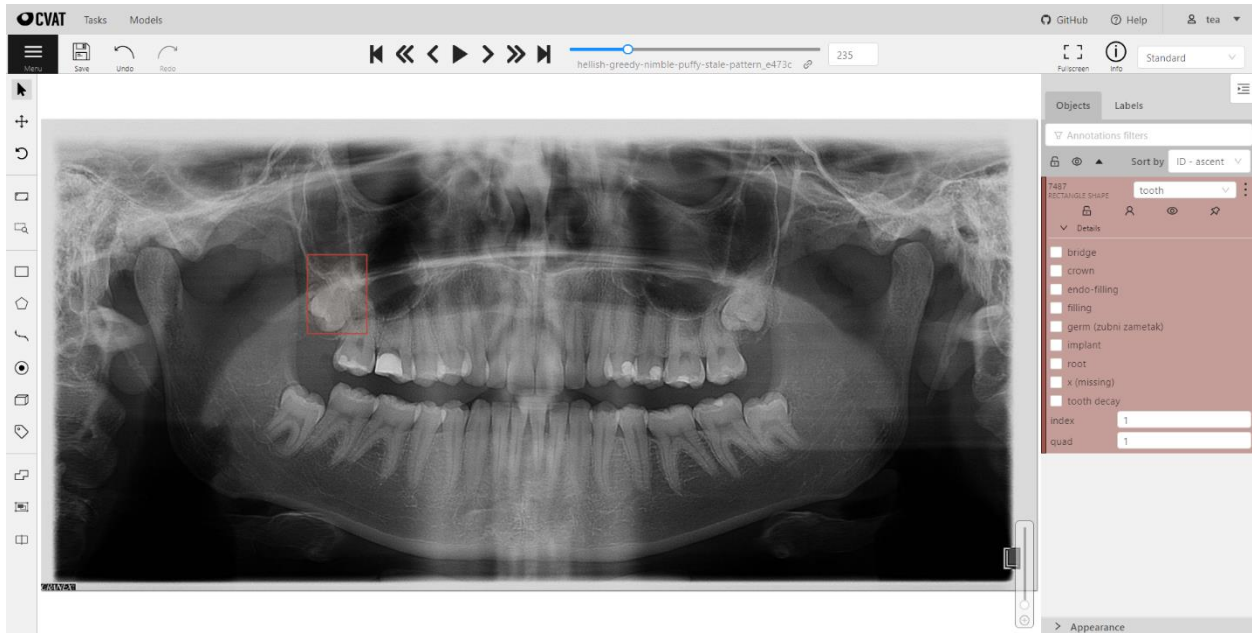
Slika 4. Unošenje ortopantomograma u računalni program LabelImg.



Slika 5. Priprema postave pravokutnika oko granica zuba.



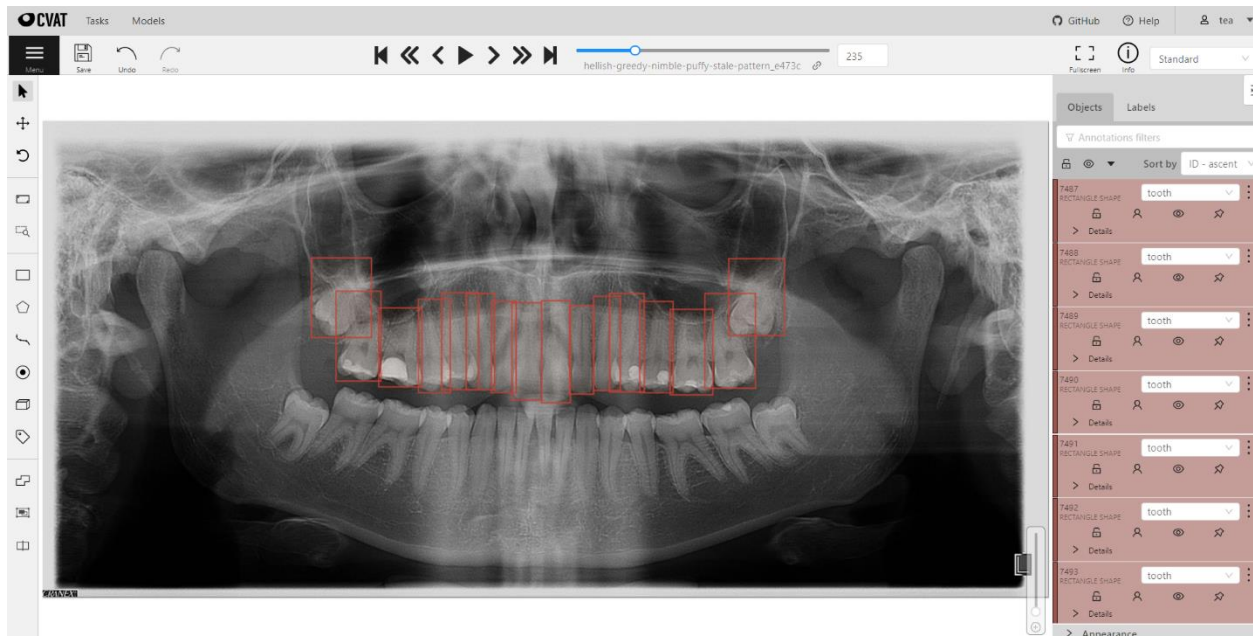
Slika 6. Postavljanje pravokutnika oko granica zuba.




Slika 7. Postavljen pravokutnik oko granica zuba.



Slika 8. Označavanje zuba dvobrojnim sustavom (zub 18).



Slika 9. Prikaz označenih zubi unutar pravokutnika u maksili.



Slika 10. Prikaz označenih zubi u maksili i mandibuli, na ortopantomogramu.

2.2. Duboke neuronske mreže

Strojno učenje predstavlja područje računalne znanosti koje se bavi proučavanjem algoritama, koji omogućavaju rješavanje problema kroz učenje, na temelju podataka (6). Jedan od najpopularnijih pristupa strojnog učenja jesu umjetne neuronske mreže.

Umjetna se neuronska mreža može opisati kao model zaključivanja, inspiriran radom ljudskog mozga. Mozak se sastoji od približno 10 milijardi neurona i 60 bilijuna veza između njih, a pomoću istovremenog korištenja više neurona, mozak obavlja svoje funkcije brže od najbržih svjetskih računala. Najbitnije je svojstvo neuronskih mreža upravo svojstvo plastičnosti. Na svaki simulacijski uzorak, događaju se dugotrajne promjene u snazi veza među neuronima, stvaraju se veze s drugim neuronima, a ponekad se i cijele kolekcije neurona sele s jednog mjesta na drugo. Ljudski se mozak može definirati kao vrlo složen, nelinearan i paralelan sustav za obradu informacija. Podtaci koji dolaze do mozga, pohranjuju se i obrađuju u neuronskim mrežama istovremeno kroz cijelu mrežu, a ne na pojedinim lokacijama, tj. podtaci i njihova obrada jesu globalni, a ne lokalni. Zbog svojstva plastičnosti, veze koje dovode do “točnog

odgovora” jačaju, a ostale slabe. Rezultat svojstva plastičnosti sposobnost je učenja kroz iskustvo.

Učenje je sposobnost koja razlikuje živa bića od stvari, a omogućiti računalu učenje, veliki je korak naprijed u području umjetne inteligencije.

Prvi su model za umjetne neuronske mreže stvorili Warren McCulloch i Walter Pitts 1943. (7) godine, a istraživanje se temeljilo na dva pristupa. Prvi se pristup temeljio na istraživanju bioloških procesa u mozgu, dok se drugi temeljio na primjenivanju neuronskih mreža, u području umjetne inteligencije. Nemogućnost rješavanja “isključivo-ili”, kao i računala, koja nisu imala dovoljno jake procesore za upravljanje velikim neuronskim mrežama, dovelo je do stagniranja istraživanja neuronskih mreža. Ključni trenutak u istraživanju neuronskih mreža bio je algoritam *backpropagation*, koji je osmislio Paul Werbos 1975. (7) godine. *Backpropagation* je omogućio treniranje modela koji mogu taj problem riješiti te je generalno ubrzao treniranje višeslojnih mreža. Istraživanje neuronskih mreža, nakon stvaranja *backpropagation* algoritma, opet postaju tema mnogih istraživanja.


Razlika je između mreža u arhitekturi, načinu učenja i signalima. Arhitektura se dijeli na mreže s vezama isključivo prema naprijed i na mreže s povratnim vezama. Kod mreža s povratnim vezama, veze su zatvorene na način da se rezultat analize vraća na početak i uvježbavanje ponavlja, s ciljem minimiziranja pogreške. Po načinu učenja mreže se dijele na nadgledane, pojačane (podtaci se pribavljaju interaktivno iz okoline) te nenadgledane. Nadgledane neuronske mreže rade s označenim tipom podataka (engl. *labeled*) i moguće je procjeniti točnost, dok nenadgledane rade s neoznačenim tipom podataka.

2.2.1. Arhitektura neuronske mreže

Umjetnu neuronsku mrežu čini hijerarhija slojeva, a neuroni su u mreži raspoređeni uzduž tih slojeva. Ulazne i izlazne slojeve čine neuroni povezani s vanjskom okolinom.

Cilj je uskladiti ponašanje mreže s vanjskom okolinom.

Najjednostavnija umjetna neuronska mreža sastoji se od ulaznog, izlaznog i barem jednog skrivenog sloja. Signali se prenose unaprijed na “sloj po sloj” osnovi.



Slika 11. Primjer arhitekture neuronske mreže.

Svaki sloj gledamo kao jedan korak obrade - podatak stigne na ulaz, obradi se (u sloju) i šalje se dalje. Točnije, ulazni sloj redistribuira zaprimljene signale iz vanjskog svijeta na sve neurone u skrivenom sloju i nikad ne obrađuje podatke (8). U odnosu na njega, izlazni sloj prihvaća uzorke iz skrivenih slojeva i uspostavlja izlazni uzorak cijele mreže. Neuroni, koji pripadaju skrivenom sloju, otkrivaju značajke koje pripadaju ulaznim uzorcima, a te se značajke koriste pri određivanju izlazne sheme, u izlaznom sloju.

Backpropagation je odgovor na pitanje "a kako se to mreža uči?". Upravo je taj algoritam najpopularnija metoda učenja umjetnih neuronskih mreža. Za treniranje korištenjem *backpropagation* algoritma, računa se greška između dobivenih i očekivanih vrijednosti. Backpropagation nam omogućava izračun derivacije za svaku komponentu mreže. Drugim riječima, kako je svaki sloj "korak obrade", detalji su obrade te komponente ("parametri"). Općenito vrijedi da je optimum funkcije (najveća ili najmanja točka) tamo gdje je derivacija te funkcije jednaka nuli. Backpropagation nam omogućava da tražimo gdje je derivacija mreže jednaka nuli.

Koristeći izračunatu grešku, težine se na čvoru povećavaju množenjem greške globalnim skalarom.

Kompleksni dio učenja, s praćenjem unaprijed, procjena je koji ulaz jest razlog najlošije procjene i kako promijeniti taj element, kako bi se ispravila greška.

Tijekom procesa treniranja primjenjuje se prosljeđivanje unaprijed, a izlaz se svakog neurona računa postepeno za pojedinačni sloj. Razlika između očekivanog i dobivenog izlaza u završnom se sloju vraća u protekle čvorove. Uglavnom je modificirana derivacijom prijenosne funkcije i prilagođavaju se težine. Ovaj se proces izvršava za svaki sloj.

2.2.2. Prednosti i mane

Neuronske su mreže pristup rješavanju problema koji će uvijek rezultirati rješenjem, ali kvaliteta rješenja ovisi o mnogo čimbenika. Na temu umjetnih neuronskih mreža, izvršeno je iznimno puno akademskih istraživanja, kojima je cilj unaprijediti kvalitetu njihovog korištenja. Njihovoj je popularnosti potpomogla jednostavnost koncepta i korištenja, a dosad su stvorene brojne implementacije i okviri za njihovo korištenje. Iz istih se razloga već dugo uspješno koriste u industriji. Međutim, neuronske su mreže u jako malo slučajeva optimalno rješenje za određeni problem. Skoro uvijek postoje alternative koje su brže, jednostavnije za treniranje i daju bolja rješenja. Što je veći broj neurona, teže ih je trenirati i potrebno je sve više memorije.

Način kako neuronska mreža rješava problem za inženjera je "crna kutija", tj. nitko ne može procijeniti kako dolazi do rješenja i u slučaju krivog rada, jako je teško pronaći grešku. Stoga ne treba za svaki problem odmah primijeniti ovakav pristup rješenju, jer u mnogo slučajeva postoji

bolje i optimalnije rješenje. Međutim, za probleme koji su iznimno kompleksni i složeni i za koje ne postoje kvalitetna alternativna rješenja, neuronske su mreže najbolji pristup.

2.2.3. Duboke neuronske mreže


Kroz povijest razvoja neuronskih mreža, najveći je problem bio manjak memorije i nemogućnost obrade velikih količina podataka. Stoga su mreže uvijek bile ograničene na najviše četiri skrivena sloja (veoma sporo). U zadnjih se desetak godina pojavom jačih procesora, računala i sve većih količina podataka, kreiraju mreže s mnogo većim brojem skrivenih slojeva. Takve se mreže nazivaju “duboke neuronske mreže”. Dodatnu prepreku za duboke neuronske mreže predstavljala su teoretska ograničenja za učenje dubokih slojeva, no istraživači su u zadnjih desetak godina predložili neka uspješna rješenja, koja su otvorila brojne mogućnosti primjene.

2.2.4. Konvolucijske mreže

Trenutno su vrlo popularan tip dubokih neuronskih mreža, konvolucijske neuronske mreže (engl. *convolutional neural networks*). One se vrlo često koriste u problemima vezanim za analizu slike, a uspješne su i u brojnim drugim područjima. Glavna je prednost konvolucijskih mreža jest ta da su sposobne samostalno naučiti detektirati bitne uzorke u slici, za razliku od umjetnih neuronskih mreža, gdje programer mora odlučiti koji su bitni uzorci. To je iznimno korisno u prepoznavanju objekata jer je teško odrediti koji su uzorci zapravo bitni za izvršavanje zadatka. Memorijski su vrlo učinkovite, iz razloga što je smanjen broj težina i parametara, što omogućuje univerzalnu iskoristivost. Zbog pomicanja filtera po slici, moguće je detektirati objekt bez obzira na njegovu lokaciju.

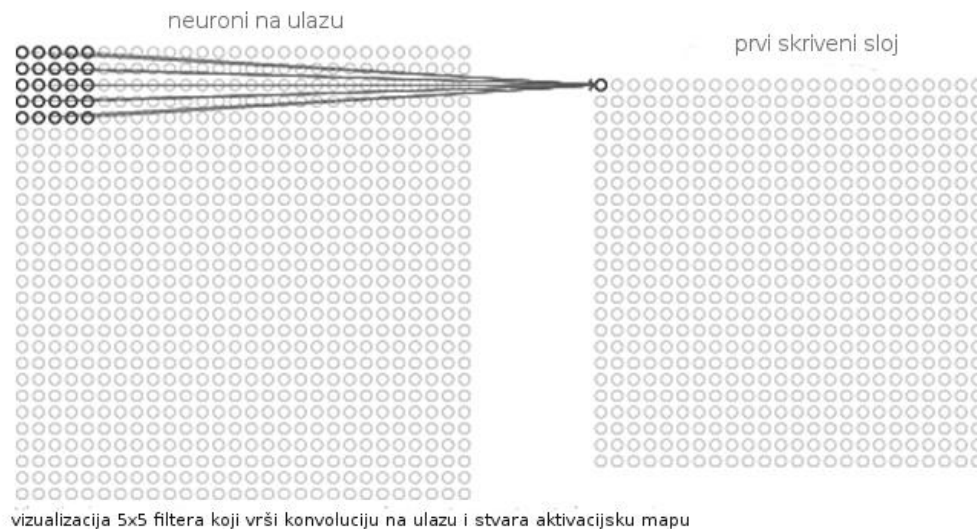
Struktura konvolucijskih mreža sastoji se od ulaznog, skrivenog i izlaznog sloja. Za razliku od običnih neuronskih mreža, skriveni sloj mora sadržavati odgovarajuće slojeve, a to su:

- Konvolucijski slojevi
- Slojevi sažimanja
- Potpuno povezani slojevi
- Normalizacijski slojevi



Slika 12. Primjer arhitekture konvolucijske mreže.

Konvolucijski slojevi primjenjuju operaciju konvolucije nad ulazom, te prenose rezultat operacije do sljedećeg sloja. Konvolucija zapravo predstavlja reakciju neurona na ulaz, a svaki neuron obrađuje podatke samo za njegovo receptivno polje. Konvolucijski se sloj sastoji od filtera čije je težine potrebno naučiti, kako bi se poboljšala uspješnost mreže.



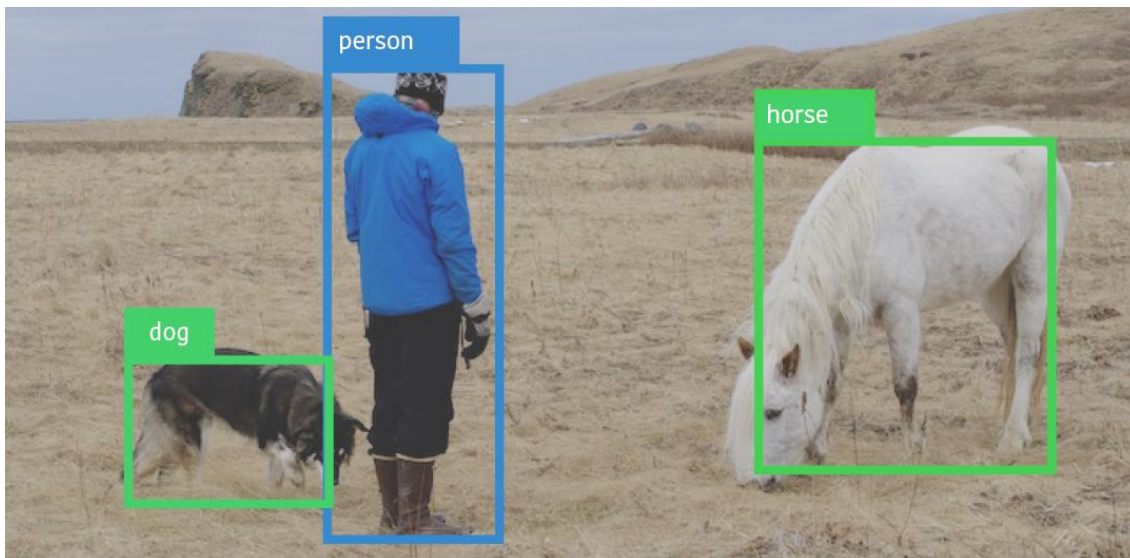
Slika 13. Obavljanje konvolucije na ulazu.

Rezultat je konvolucije dvodimenzionalna aktivacijska mapa i ona predstavlja odziv filtra na svakoj lokaciji. Cilj je postići da se filter aktivira kad prepozna slikovna svojstva s kojima se već susreo. Primjerice, to mogu biti rubovi, kutovi i slično, a što je mreža dublja, svojstva postaju sve kompleksnija i mreža može početi prepoznavati objekte, životinje i slično.

2.2.5. Duboke neuronske mreže za detekciju i klasifikaciju

Detekcija objekata zadatak je iz područja računalnog vida, kojem je cilj pronalazak instanci objekata određene klase, na digitalnim slikama i video zapisima. Detekcija objekata objedinjuje dva problema računalnog vida, koji dobivaju poseban značaj jednom kada ih kombiniramo. Prvi problem nazivamo lokalizacija, tj. određivanje konkretne i precizne lokacije objekta na slici. Drugi pak problem nazivamo klasifikacija, a cilj je odrediti semantički značaj objekta (je li locirani objekt automobil, avion, osoba, itd.). Sustav za detekciju objekata na slici locirat će sve željene objekte te će odrediti njihove pripadne klase.

Ovakvi sustavi imaju vrlo široku primjenu. Igraju bitnu ulogu u područjima poput detekcije ljudskog lica, detekcije pješaka i automobila kod autonomnih vozila, u industrijskim sustavima te brojnim drugim područjima.



Slika 14. Primjer detekcije objekata.

Sustav za detekciju objekata možemo gledati i izvesti kao dvije zasebne komponente, spojene u jednu. Prva komponenta rješava problem lokalizacije, tj. ima ulogu pronalaženja i predlaganja mogućih lokacija objekata. Druga komponenta rješava problem klasifikacije, na temelju predložene lokacije određuje o kojem se točno objektu radi. Za svaki objekt na slici računaju se koordinate, pripadna klasa te vjerojatnost koja opisuje sigurnost detekcije.

Poseban se naglasak stavlja na problem lokalizacije objekta na digitalnoj slici ili video zapisu. Problem se popularno naziva predlaganje regija (engl. *region proposal*), a neuronsku mrežu, koja rješava takav problem, nazivamo neuronskom mrežom za predlaganje regija (engl. *region proposal network*).

S obzirom na taj problem, algoritme detekcije bazirane na dubokim konvolucijskim neuronskim mrežama, možemo podijeliti u dvije skupine:

1. Algoritmi bazirani na predlaganju regija (engl. *region based algorithms*) poput Region-based Convolutional Neural Network (skraćeno R-CNN), Fast Region-based Convolutional Neural Network R-CNN (skraćeno Fast R-CNN) te Faster Region-based Convolutional Neural Network (skraćeno Faster R-CNN)
2. Algoritmi bazirani na regresiji lokacije (engl. *regression based algorithms*) poput You Only Look Once (skraćeno YOLO) i Single Shot Multibox Detector (skraćeno SSD)

Od velike nam je važnosti da naš sustav za detekciju objekata možemo trenirati s kraja na kraj (engl. *end-to-end training*). Trenirati duboku neuronsku mrežu s kraja na kraj znači optimirati težine simultano, u jednom hodu, uzimajući u obzir piksele na ulazu neuronske mreže te njihovo direktno mapiranje na izlazu. Neuronska mreža koja nema mogućnost treniranja s kraja na kraj, zahtijevat će nekoliko zasebnih postupaka treniranja, prije nego li dobijemo konačan sustav.

Duboka konvolucijska neuronska mreža bazirana na regresiji, kao ulaz također prima cijelu sliku (bilo koje veličine) te na izlazu daje listu prijedloga lokacija mogućih objekata i kao takva sadrži vjerojatnost da se baš u tom području nalazi neki objekt (engl. *objectness score*). Slika se dijeli na ćelije, a svaku ćeliju gledamo kao zasebnu sliku u kojoj tražimo objekte. Za traženje granica objekata koristi se metoda regresije. Neuronska mreža bazirana na regresiji lokacije, također se može trenirati s kraja na kraj korištenjem backpropagation, uz bilo koji optimizacijski algoritam (najčešće gradijentni spust).

3. REZULTATI

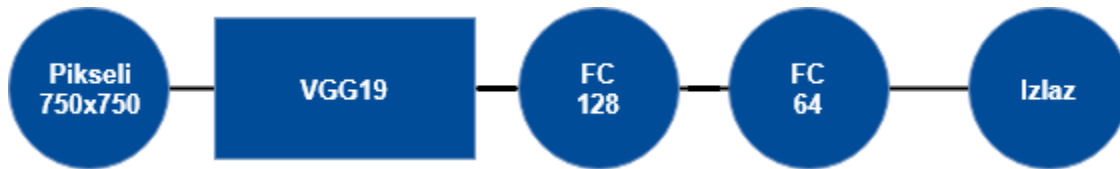
Naša implementacija u pozadini koristi Tensorflow biblioteku (9). Tensorflow je jedna od najpopularnijih i najrazvijenijih open-source programskih biblioteka za rad, s visoko performansnim računanjem. Tensorflow je razvijen od strane Google Brain tima za internu upotrebu, a 2015. godine biblioteka je javno objavljena na korištenje javnosti. Tensorflow je napisan u programskim jezicima Python i C++ te koristi CUDA (10) sučelje za paralelno programiranje. Podržava paraleliziran rad na NVIDIA grafičkim procesorima te je iz tog razloga uvelike korištena u svrhe strojnog učenja. Bazira se na paradigmi protoka podataka (engl. *dataflow*), koja omogućuje puno bržu obradu podataka nego li konvencionalna paradigma upravljačkog toka (engl. *controlflow*), korištena na procesorima.

Koristimo biblioteku Keras (11) koja nudi jednostavnije sučelje za programiranje dubokih neuronskih mreža, dizajnirano s idejom brzih eksperimenata. Keras u pozadini radi sa prethodno spomenutom Tensorflow bibliotekom.

Također, koristili smo platformu Docker (12) za izolaciju poslova treniranja od OS-a te za osiguravanje reproducibilnih uvjeta. Korišten je službeni Docker image koji podržava GPU implementaciju Tensorflow biblioteke. Svi su modeli neuronskih mreža trenirani na serveru sa dva NVIDIA Titan X grafička procesora, koji su pribavljeni putem donacija u NVIDIA GPU Grant programu.

3.1. Procjena dobi

Za problem procjene dentalne dobi dizajnirali smo duboku konvolucijsku neuronsku mrežu, kao spoj već postojeće VGG19 mreže (13) i potpuno povezanih slojeva, koje smo sami dodali. Problem rješavamo metodom regresije. Mreža na ulazu prima sliku dimenzija 750×750 piksela.



Slika 15. Prikaz arhitekture.

Na prethodnoj slici prikazana je arhitektura neuronske mreže za procjenu dobi. Ulaz za piksele je spojen na VGG19 neuronsku mrežu za ekstrakciju konvolucijskih značajki. Izlaz VGG19 mreže spajamo na dva potpno povezana spoja, sa 128 i 64 neurona, respektivno. Koristimo ReLu aktivacijsku funkciju na izlaznom sloju.

Zbog zakrivljenosti distribucije ulaznog skupa slika, odlučili smo trenirati mrežu na slikama čiji je podatak o godina u intervalu [20, 50]. Nakon filtriranja slika, ostale su nam 3148 slike, koje smo dalje koristili za treniranje modela. Također, kako bi spriječili eventualnu stagnaciju optimizacije, koristimo mehanizam za reduciranje stope učenja s faktorom smanjenja, u iznosu 0,8.

Neki od korištenih hiperparametara su:

- konstanta učenja: 0.001
- optimizator: Adam sa parametrima $\beta_1=0.9$, $\beta_2=0.999$, $\epsilon=1e-08$
- broj epoha: 100
- batch size: 10

Nakon treniranja, testirali smo model nad testnim skupom od 39 slika, čiji je podatak o godinama u intervalu [20, 50] te smo dobili rezultate s prosječnom apsolutnom greškom od 4,9 godina. Nastavljamo raditi na ovom problemu jer smatramo da je moguće ostvariti puno bolje rezultate, do trenutne stagnacije dolazi zbog male baze slika i nedovoljnih resursa memorije za treniranje.



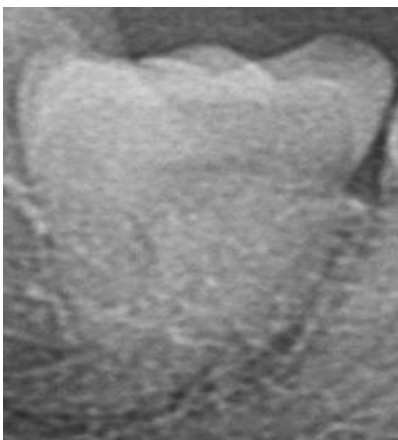
Slika 16. Primjer slike s koje je vrlo teško utvrditi starost osobe.

Prethodna slika primjer je ortopantomograma za koji mreža radi iznadprosječne greške pri procjeni dobi. Vidljivo je vrlo loše dentalno stanje osobe pa je razumljivo zašto se takve greške događaju.

Treniran je i model za procjenu dobi na temelju slike pojedinog zuba. Skup podataka za taj uzorak se sastoji od 76293 slike zuba, koje su izrezane iz 2683 ortopana. Primjer uzoraka iz tog skupa podataka možemo vidjeti na slici 17. i na slici 18.



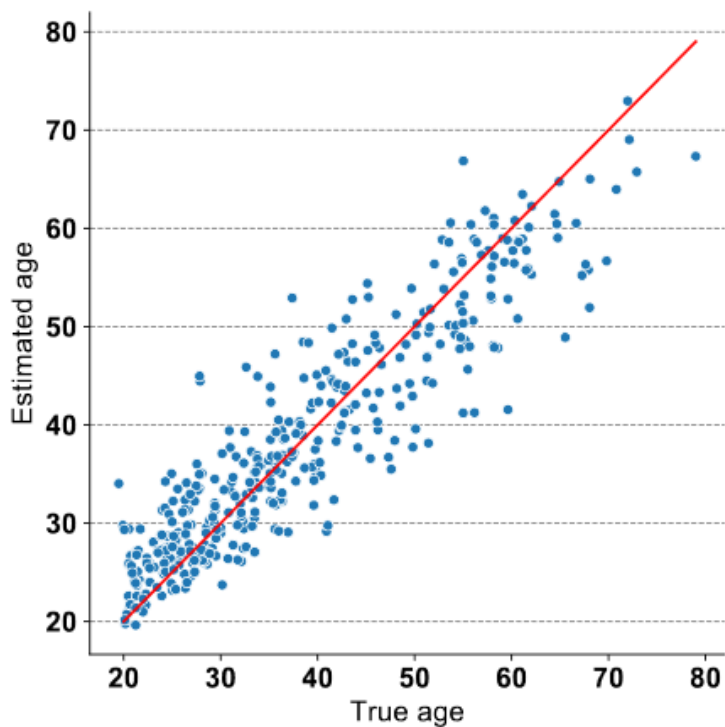
Slika 17. Slika zuba 48 generirana maksimalnih koordinata.



Slika 18. Slika zuba 48 generirana pomoću promjenom veličine na prosječne vrijednosti.

Najuspješniji model sastoji se od VGG16 kao baze, 1x1 konvolucijskog sloja s 40 filtera te potpuno povezanim slojem od 128 elemenata. Distribuciju procjena po pravoj dobi, možemo vidjeti na slici 19. X- os predstavlja dob koju je model procijenio. Crvena linija predstavlja idealnu procjenu. Svaka točka predstavlja jednu procjenu i udaljenost točke od dijagonale pokazuje točnost procjene. Možemo vidjeti da su procjene za mlađe uzorke točnije, dok kod starijih uzoraka dolazi do većeg raspršenja.

Prosječna se i medialna greška ukupno i po dobnim skupinama može vidjeti u tablici 4. za gornje zube, a u tablici 5. za donje zube. Uočljivo je da su greške za mlađe dobne skupine značajno manje.



Slika 19. Prikaz predikcija modela.

Tablica 4. Prosječna i medialna greška ukupno i po dobnim skupinama za gornje zube


Age	Up-1		Up-2		Up-3		Up-4		Up-5		Up-6		Up-7		Up-8	
	μ	\hat{y}	μ	\hat{y}	μ	\hat{y}	μ	\hat{y}	μ	\hat{y}	μ	\hat{y}	μ	\hat{y}	μ	\hat{y}
[15, 20)	8.75	8.35	9.99	10.87	8.05	7.17	12.17	11.95	7.35	8.83	7.55	4.94	6.62	6.73	9.87	9.76
[20, 25)	11.16	11.03	11.11	10.36	10.32	9.47	10.65	10.27	8.36	7.91	5.83	5.36	8.51	8.18	7.31	7.24
[25, 30)	7.33	6.25	7.24	6.79	6.04	4.88	7.34	6.46	5.40	4.20	3.90	3.58	5.45	4.23	5.15	3.90
[30, 35)	4.39	3.60	4.80	3.62	4.35	3.21	5.48	4.54	4.69	4.12	4.70	3.60	4.47	3.98	5.29	4.35
[35, 40)	3.61	3.26	4.00	3.31	4.91	4.09	4.74	3.13	4.42	3.75	5.49	5.36	4.57	3.38	4.74	4.14
[40, 45)	4.28	3.72	4.56	3.75	5.71	5.54	5.16	5.09	5.99	5.50	6.78	6.19	5.31	5.05	6.37	5.94
[45, 50)	7.22	7.34	6.60	5.88	5.67	5.05	6.55	5.74	7.11	6.07	7.98	7.05	4.99	4.32	7.35	7.42
[50, 55)	10.77	10.87	9.84	8.74	10.97	10.11	7.92	6.93	11.68	11.52	12.48	11.75	8.66	8.74	13.89	15.23
[55, 60)	12.83	13.51	12.41	12.39	12.45	11.78	11.67	10.40	13.60	13.80	12.88	12.99	10.78	11.02	13.89	14.96
[60, 65)	15.95	15.91	14.98	14.98	14.17	14.02	12.61	12.69	14.65	13.11	14.56	13.62	11.66	11.51	15.16	17.24
[65, 70)	21.89	23.83	20.06	19.32	23.00	23.24	21.02	20.84	22.44	20.77	24.99	23.53	18.05	16.51	21.18	22.50
[70, 75)	25.42	25.11	20.78	22.53	24.45	23.89	18.41	16.99	19.01	22.42	22.80	23.31	22.76	23.67	35.20	36.02
[75, 80)	30.59	29.81	27.56	25.78	26.88	27.44	27.57	29.29	23.35	24.51	32.25	34.31	24.40	25.35	29.31	29.31
Total	8.30	6.52	8.11	6.79	8.14	6.43	8.01	6.77	7.65	6.11	7.52	5.69	6.87	5.68	7.32	5.89

Tablica 5. Prosječna i medialna greška ukupno i po dobnim skupinama za donje zube

Age	Down-1		Down-2		Down-3		Down-4		Down-5		Down-6		Down-7		Down-8	
	μ	\hat{y}	μ	\hat{y}	μ	\hat{y}	μ	\hat{y}	μ	\hat{y}	μ	\hat{y}	μ	\hat{y}	μ	\hat{y}
[15, 20)	8.67	8.26	12.60	11.10	12.38	11.48	13.75	15.49	13.37	10.68	9.19	7.87	8.30	5.54	4.91	5.56
[20, 25)	8.98	9.00	9.44	8.95	10.84	10.37	11.01	10.06	9.30	8.76	7.13	6.60	6.56	6.30	4.03	3.67
[25, 30)	6.21	5.64	6.22	5.75	7.77	7.58	7.57	6.90	6.89	6.08	4.74	3.57	5.37	4.10	3.94	3.19
[30, 35)	5.01	4.13	4.38	3.55	4.68	3.87	4.75	4.44	4.45	3.72	3.68	2.83	4.37	3.36	4.09	3.07
[35, 40)	4.00	3.78	4.09	3.29	4.45	3.54	4.62	3.84	4.50	3.62	4.21	3.19	4.45	3.87	4.57	3.61
[40, 45)	5.83	5.54	5.49	5.09	5.44	4.82	5.43	5.26	4.68	4.31	5.55	5.46	4.90	4.29	6.31	4.83
[45, 50)	6.29	5.57	7.28	7.51	6.27	6.41	7.18	6.85	6.40	6.39	7.41	7.37	6.04	4.90	7.76	7.44
[50, 55)	12.89	12.90	12.23	11.72	11.42	11.59	10.71	10.38	9.60	8.26	11.59	11.08	8.14	7.74	12.00	13.27
[55, 60)	12.42	12.55	13.50	13.24	12.44	11.71	11.36	11.21	11.47	13.12	12.82	13.96	11.00	12.26	11.71	11.55
[60, 65)	14.48	14.39	17.05	18.12	15.61	15.85	13.00	11.87	15.97	15.11	13.31	12.83	11.81	12.47	16.40	14.76
[65, 70)	20.45	20.55	23.18	22.72	23.50	23.79	20.47	21.93	20.83	21.62	22.49	22.20	18.92	20.52	22.64	24.72
[70, 75)	25.23	26.03	24.53	24.14	24.54	26.87	23.53	23.83	22.27	19.47	23.48	24.80	21.28	21.67	31.95	31.95
[75, 80)	38.81	37.22	31.30	30.93	32.50	35.44	34.93	35.60	30.17	28.92	24.71	25.38	22.75	21.58	26.48	26.48
Total	8.23	6.64	8.43	6.71	8.65	7.33	8.43	6.96	7.87	6.40	6.87	5.39	6.53	5.13	6.39	4.68

3.2. Procjena spola

Procjena spola još je jedan primjer klasifikacije. Dizajnirali smo vlastitu duboku konvolucijsku neuronsku mrežu za rješavanje ovog problema. Jedini ulaz koji nam je potreban, slika je veličine 512×512 . Referentne podatke o spolu kodiramo kao polje sa jednim aktivnim elementom (engl. *one-hot*).



Slika 20. Arhitektura neuronske mreže za procjenu spola.

Na prethodnoj je slici prikazana arhitektura korištene neuronske mreže. Neuronska se mreža sastoji od 4 konvolucijska sloja. Svaki je konvolucijski sloj praćen slojem za sažimanje. Nakon posljednjeg sloja za sažimanje nalazi se potpuno povezani sloj sa 1024 neurona te još jedan potpuno povezani izlazni sloj sa 2 neurona (po 1 za svaki spol). Aktivacijska funkcija na izlazu je softmax. Mrežu smo trenirali na 4000 slika bez dodatnog agumentiranja.

Neki od korištenih hiperparametara su:

- konstanta učenja: 0.0001
- optimizator: Adam
- broj epoha: 100
- batch size: 50

Nakon treniranja, testirali smo model nad testnim skupom od 104 slike te smo imali svega tri pogrešne procjene, što rezultira sa točnošću od 97.11%.

Mrežu smo za procjenu spola zatim trenirali na slikama pojedinačnih zubi. Usporedbom rezultata između dva modela, možemo provjeriti saznaje li mreža informacije o spolu iz slike cijele čeljusti ili su joj dovoljne informacije o korijenu pojedinog zuba. Slike pojedinih zuba možemo manualno generirati ili koristiti Faster R-CNN model opisan u nastavku.

S obzirom da je ulaz mreže fiksne veličine, potrebno je promjeniti veličinu slika pojedinih zubi na istu veličinu. To postizemo rastezanjem ili skupljanjem slike na prosječnu vrijednost širine i visine ili rezanjem svih slika na maksimalne dimenzije za pojedini zub. Prvim načinom gubimo na informaciji, zbog nepoštivanja originalnog omjera visine i širine slike, dok drugim načinom dobivamo slike koje, uglavnom sadrže dio susjednog zuba.

Mreža je trenirana na 1700 slika zubi klase 48, 44 te 41 koristeći oba načina rezanja slike, čime se dobije 6 treniranih modela spremnih za evaluaciju. Najbolje smo rezultate dobili za zub klase 48, koristeći rezanje slike pomoću maksimalnih dimenzija, a točnost takve evaluacije iznosi 55.37%, što je relativno loš rezultat i malo je bolje od "bacanja novčića". S obzirom na visoku

točnost procjene spola iz cijelog ortopantomograma, može se zaključiti da sami zubi u sebi ne nose korisne informacije za procjenu spola, već da te informacije dolaze iz strukture čeljusti.

Treniran je i model za procjenu dobi na temelju slike pojedinog zuba. Skup podataka za taj uzorak sastoji se od 76293 slike zuba, koje su izrezane iz 2683 ortopana.

Najuspješniji model sastavljen je od VGG16 modela, kao baze na koji se nadovezuje jedan 1x1 konvolucijski sloj od 40 kanala, nakon kojeg slijedi potpuno povezani sloj od 128 elementa, iz kojih se onda radi procjena. Trenirane su dvije varijante modela – jedan model koji radi procjenu na temelju bilo kojeg zuba te jedan model koji radi procjenu na temelju specifičnog zuba. Drugim riječima, drugi je model zapravo serija modela koji su specijalizirani za svaki tip zuba. Rezultati generalnog modela mogu se vidjeti u tablici 6., dok se rezultati specijaliziranih modela mogu vidjeti u tablici 7.

Tablica 6. Rezultati generalnog modela.

TABLE IV
ACCURACY OF SEX ASSESSMENT PER AGE GROUP OF THE GENERAL MODEL. UP REFERS TO MAXILLARY TEETH, AND DOWN REFERS TO MANDIBULAR TEETH.

Age	1		2		3		4		5		6		7		8	
	Up	Down	Up	Down	Up	Down	Up	Down	Up	Down	Up	Down	Up	Down	Up	Down
[15, 20)	83.33%	83.33%	66.67%	100%	66.67%	100%	100%	100%	80.00%	83.33%	100%	80.00%	100%	83.33%	100%	75.00%
[20, 25)	66.33%	67.35%	61.86%	68.37%	71.43%	73.47%	66.67%	70.10%	66.32%	73.20%	64.89%	75.82%	77.55%	73.47%	73.75%	73.81%
[25, 30)	74.17%	70.59%	77.31%	76.27%	79.66%	75.63%	81.74%	79.66%	81.31%	79.46%	78.76%	83.81%	78.45%	85.84%	70.53%	79.17%
[30, 35)	68.55%	79.03%	74.19%	73.39%	78.69%	66.94%	68.10%	76.86%	80.00%	73.11%	69.16%	79.09%	68.64%	76.27%	65.22%	62.65%
[35, 40)	62.50%	70.34%	70.43%	72.27%	65.25%	73.73%	62.73%	66.10%	61.90%	68.10%	55.66%	70.11%	68.81%	61.86%	62.50%	73.24%
[40, 45)	71.58%	72.16%	79.38%	76.53%	72.92%	78.57%	66.67%	75.79%	71.95%	78.02%	80.56%	73.85%	75.86%	73.49%	76.67%	74.07%
[45, 50)	76.92%	71.15%	71.15%	73.08%	75.00%	62.75%	69.05%	67.31%	65.91%	65.31%	72.50%	78.12%	80.00%	73.33%	73.33%	70.00%
[50, 55)	71.15%	76.92%	73.08%	71.15%	68.00%	78.85%	65.96%	68.00%	67.50%	71.74%	61.36%	70.97%	69.57%	76.19%	61.90%	64.00%
[55, 60)	77.78%	68.75%	72.09%	75.00%	76.09%	68.75%	66.67%	76.47%	66.67%	60.00%	76.00%	75.00%	78.95%	57.89%	85.00%	85.00%
[60, 65)	88.37%	69.77%	72.50%	84.09%	84.21%	79.07%	65.62%	76.74%	63.33%	83.78%	77.78%	82.76%	78.57%	76.92%	66.67%	78.95%
[65, 70)	80.95%	68.18%	81.82%	72.73%	63.64%	65.00%	30.00%	80.95%	41.18%	84.21%	78.57%	72.73%	62.50%	69.23%	25.00%	41.67%
[70, 75)	92.86%	78.57%	64.29%	71.43%	78.57%	100%	53.85%	92.86%	50.00%	92.31%	100%	100%	88.89%	100%	75.00%	100%
[75, 80)	100%	83.33%	66.67%	100%	66.67%	83.33%	100%	83.33%	60.00%	50.00%	40.00%	100%	100%	40.00%	100%	100%
Total	71.98%	72.22%	72.68%	74.28%	73.79%	73.65%	68.05%	73.54%	70.54%	73.97%	69.66%	77.41%	74.44%	75.00%	68.46%	72.31%

Tablica 7. Rezultati specijaliziranih modela.

TABLE III
ACCURACY OF SEX ASSESSMENT PER AGE GROUP OF THE MODELS SPECIALIZED TO SPECIFIC TOOTH TYPES. UP REFERS TO MAXILLARY TEETH, AND DOWN REFERS TO MANDIBULAR TEETH.

Age	1		2		3		4		5		6		7		8	
	Up	Down	Up	Down	Up	Down	Up	Down	Up	Down	Up	Down	Up	Down	Up	Down
[15, 20)	50.00%	100%	50.00%	83.33%	83.33%	66.67%	80.00%	100%	80.00%	83.33%	60.00%	80.00%	100%	66.67%	75.00%	100%
[20, 25)	73.47%	70.41%	78.35%	69.39%	77.55%	73.47%	75.00%	79.38%	65.26%	77.32%	69.15%	71.43%	75.51%	67.35%	78.75%	84.52%
[25, 30)	71.67%	73.95%	72.27%	69.49%	82.20%	85.71%	81.74%	78.81%	71.96%	81.25%	60.18%	80.00%	70.69%	81.42%	75.79%	77.08%
[30, 35)	78.23%	75.00%	72.58%	68.55%	81.97%	72.58%	75.86%	73.55%	73.04%	80.67%	57.94%	77.27%	70.34%	81.36%	70.65%	72.29%
[35, 40)	69.17%	62.71%	66.96%	69.75%	74.58%	82.20%	77.27%	72.03%	64.76%	70.69%	58.49%	60.92%	72.48%	74.23%	68.06%	63.38%
[40, 45)	72.63%	70.10%	78.35%	67.35%	71.88%	75.51%	74.71%	68.42%	75.61%	73.63%	65.28%	75.38%	66.67%	75.90%	70.00%	61.11%
[45, 50)	71.15%	65.38%	61.54%	59.62%	71.15%	76.47%	69.05%	71.15%	75.00%	63.27%	67.50%	68.75%	68.00%	75.56%	86.67%	73.33%
[50, 55)	75.00%	84.62%	71.15%	63.46%	66.00%	69.23%	72.34%	60.00%	50.00%	63.04%	45.45%	54.84%	76.09%	78.57%	61.90%	64.00%
[55, 60)	73.33%	62.50%	79.07%	68.75%	80.43%	72.92%	62.86%	73.33%	52.94%	88.10%	50.00%	64.00%	75.00%	76.32%	68.42%	55.00%
[60, 65)	83.72%	76.74%	82.50%	79.55%	78.95%	74.42%	56.25%	72.09%	86.67%	67.57%	70.37%	65.52%	64.29%	76.92%	73.33%	89.47%
[65, 70)	76.19%	72.73%	77.27%	68.18%	77.27%	65.00%	60.00%	66.67%	58.82%	84.21%	57.14%	72.73%	56.25%	46.15%	62.50%	50.00%
[70, 75)	78.57%	85.71%	92.86%	92.86%	85.71%	78.57%	69.23%	85.71%	80.00%	69.23%	75.00%	100%	55.56%	75.00%	50.00%	100%
[75, 80)	66.67%	83.33%	33.33%	66.67%	83.33%	100%	40.00%	83.33%	80.00%	50.00%	40.00%	75.00%	66.67%	40.00%	100%	50.00%
Total	73.62%	71.59%	73.19%	69.04%	77.10%	76.66%	73.86%	73.41%	69.09%	75.17%	60.84%	71.76%	70.83%	75.58%	72.85%	72.11%

4. RASPRAVA

Uzimanje zubnog statusa i procjena dentalne dobi, postupak je koji se vrši u mnogim granama stomatologije (ortodontiji, dječjoj stomatologiji, dentalnoj antropologiji). Može se vršiti na živim osobama, ali i na mrtvima, u sklopu stomatološkog područja kojeg nazivamo forenzička stomatologija. S obzirom da zubi ostaju dugo sačuvani nakon smrti, mnogo je puta zubalo jedino dostupno antropološko obilježje za identifikaciju žrtava avionskih nesreća, prirodnih katastrofa, ali i drugih situacija u kojima nije poznat identitet preminule osobe. Tako su nakon rata forenzični stomatolozi sudjelovali pri otkrivanju žrtava iz masovnih grobnica, na temelju njihovih postmortalnih ostataka. S druge strane, pojavom migrantskog vala, određivanje starosti na živim osobama sve je potrebnije, zbog ljudi koje dolaze bez ikakvih dokumenata i nemoguće ih je registrirati pri dolasku ili pokrenuti proces dobivanja azila. Nadalje, određivanje starosti na živim osobama potrebno je da bi se odredila dob napuštene djece i ljudi koji prikrivaju svoju dob, radi raznih sudskih procesa.

Metode određivanja dentalne dobi dijelimo na neinvazivne i invazivne. Invazivne metode podrazumijevaju vađenje zuba te mikroskopsko određivanje promjena na vanjskim i unutarnjim dijelovima zuba. Najpoznatija je metoda ona po Gustafsonu, koja koristi 6 parametara za određivanje dentalne dobi. To su izraženost atricije zuba, resorpcija alveolne kosti, nakupljenost sekundarnog dentina, nakupljenost acelularnog cementa, translucencija korijena zuba i resorpcija korijena (1). Iz etičkih razloga, invazivne metode nisu prikladne za uporabu kod živih osoba, već samo u forenzičkoj stomatologiji. S druge strane, neinvazivne se metode temelje na radiološkim snimkama, najčešće ortopantomogramima, iz kojih se dobivaju informacije o zamecima zuba, stadijima mineralizacije i erupcije krune u oralnu šupljinu. Jedna od najčešće korištenih metoda je po Demirijanu, gdje se na ortopantomogramu koristi 7 zuba lijeve strane mandibule, od središnjeg sjekutića do drugog kutnjaka. Svaki se zub obilježi jednim od 8 opisanih stadija mineralizacije, od A do H. Oznake se zatim pretvore u bodove prema vrijednosnoj tablici i zajedno daju zrelosne bodove, na temelju kojih se zatim može odrediti dob pojedinca (14).

Cilj je ovog istraživanja bio razviti metodu temeljenu na dubokom učenju, koja bi iz ortopantomograma mogla odrediti zubni status te procijeniti dob i spol osobe. Razvijene su 4 metode bazirane na dubokim neuronskim mrežama, koje su ispitivanjem dale vrlo dobre rezultate. Temeljem dobivenih rezultata, dokazana je moguća primjena razvijenih metoda u

procjeni spola, dobi i određivanju zubnog statusa te samim time one dobivaju na važnosti i potencijalnoj primjenjivosti u budućnosti. Jedna je od prednosti navedenih metoda ta da pripadaju neinvazivnim tehnikama, što povećava opseg njihovih mogućih primjena. S obzirom da je identifikacija preminulih osoba često dug i težak posao (posebice kod masovnih stradavanja), ove bi metode računalnim uzimanjem zubnog statusa, procjene dobi i spola znatno olakšale i ubrzale taj process, čineći ga znatno jeftinijim. Osim toga, smanjila bi se mogućnost ljudskih pogrešaka, posebno onih koje bi bile izazvane visokom razinom emocionalnog stresa koji se javlja kod forenzičnih stomatologa. Upravo su oni intenzivno izloženi stresu, tijekom identifikacije žrtava masovnih stradavanja u kratkom vremenskom razdoblju. Isto tako, kod živih osoba određivanje zubnog statusa i dobi bilo bi jednostavnije te bi se time svakodnevni rad stomatologa unaprijedio. Nadalje, prednost je ovih metoda i njihova jednostavna uporaba, bez potrebnog predznanja, posebne obuke ili opreme. Mogući nedostatak ranije navedenih metoda jest trenutačna nemogućnost prepoznavanja krunica, implantata, mostova, ispuna, itd., prilikom određivanja zubnog statusa. To je moguće riješiti daljnjim usavršavanjem modela, uz korištenje veće baze ortopantomograma.

4.1. Primjeri praktične primjene

Primjena istraživanja može ići u dvama smjerovima: automatizirano uzimanje zubnog statusa, na temelju računalne analize ortopantomograma, u svrhu dentalne identifikacije u individualnim i masovnim stradavanjima (prometne nesreće - npr. zrakoplovne, pomorske; prirodne katastrofe - npr. tsunami, potresi; teroristički napadi, ratovi i dr.). Kod masovnih stradavanja, automatizirano uzimanje zubnog statusa bilo bi posebno važno jer može značajno ubrzati otkrivanje identiteta stradale osobe, posebno ukoliko postoje adekvatni prijesmrtni podatci (zubni karton, ortopantomogram i dr.). S druge strane, primjena koja se nadovezuje na ranije opisanu, jest određivanje dentalne dobi, što također uključuje prethodno opisanu praktičnu upotrebu.

4.1.1. „Ljudi bez identiteta“

Prema procjeni UN-a, danas u Republici Hrvatskoj živi 3000 ljudi bez državljanstva i osobnih dokumenata, koji u formalno-pravnom smislu ne postoje. Oni nisu uvedeni u bilo kakve popise ili evidencije te o njima nitko ništa ne zna. Na svijetu je čak 12 milijuna tzv. „ljudi bez identiteta“.

Ovom brzom i jednostavnom metodom pružila bi se mogućnost uvida u njihovu dob, što bi već bilo od velikog značaja.

Najvažniji podatak, koji se ovom metodom može približno odrediti jest punoljetnost, odnosno maloljetnost neidentificirane osobe.

Kronologija razvoja zuba manje je promjenjiva nego u razvoju kostiju pa je zato preciznija za identifikaciju dobi.

4.1.2. Utvrđivanje identiteta žrtava nesreća

Utvrđivanje identiteta, pomoću dentalnih parametara, ima vrijednost otisaka prstiju živih ljudi. To vrlo važno svojstvo denticije pronašlo je primjenu u nesrećama, u kojima je čitavo ljudsko tijelo uništeno dugotrajnom izlaganju vodi, karbonizirano utjecajem vatre i slično. Zubi su otporni na visoke temperature, mnogo više nego li kosti, budući da caklina počinje dekrystalizirati tek pri izloženosti 1300° C. Tako je nerijetko zubno tkivo jedini izvor informacija o unesrećenima (15).

Denticija je apsolutno individualna osobitost pojedinca te ne postoji identičan nalaz dviju osoba. Nakon utvrđivanja dobi unesrećenih, postupak povezivanja identiteta i postmortalnih ostataka, znatno je jednostavniji.

Nadalje, ukoliko je stanje zubnih tkiva rendgenski zabilježeno za života, kompjutorski je mnogo lakše i brže pronaći podudarnosti s postmortalnom snimkom denticije. Tako utvrđivanje identiteta može biti olakšano uz pomoć umjetne inteligencije (16).

4.1.3. Procjena dobi napuštene djece

U nerazvijenim zemljama, gdje vladaju loše ekonomske i socijalne prilike, sve je više napuštene djece, koja nemaju dokumente i nije poznata njihova starost. Primjena bi navedene metode omogućila brži i jednostavniji uvid u njihovu dob.

Iako je druga po redu najveća ekonomska sila na svijetu, broj siročadi u Republici Kini kreće se od 600 000 pa do milijun. Unatoč svojem radu, Kina nije osmislila prihvatljivu mrežu socijalne podrške, za one kojima je ona najpotrebnija. Kako kineski zakon o posvajanju nalaže da nije dozvoljeno posvojiti siročad nakon što napuni 14 godina, primjena ove metode, dobiva na važnosti.

Nakon provođenja niza eksperimenata, ustanovili smo kako je korištenjem trenutno dostupnih tehnologija, metode dubokog učenja itekako moguće primijeniti na rješavanje problema određivanja zubnog statusa, procjene godina i spola osobe.

Korištenjem relativno jednostavne konvolucijske neuronske mreže, postižu se iznimno dobri rezultati sa točnošću od 97,11%.

Sljedeći je u nizu problem određivanja dentalne dobi s prosječnom apsolutnom greškom od 4,9 godina. Iako je ovo vrlo dobar rezultat, smatramo da ima dosta mjesta za napredak. Jedan od problema konvolucijskih neuronskih mreža, na koji smo i sami naišli prilikom procjene godina, je potreba za većom količinom podataka za treniranje. Iz tog smo razloga mrežu za procjenu godina morali ograničiti na interval od 20 do 50 godina, budući da izvan tih granica nismo imali dovoljan broj ortopantomograma, na kojima bi neuronska mreža mogla “učiti”.

Naposljetku, problem određivanja zubnog statusa korištenjem YOLO i Faster RCNN modela isto se pokazao vrlo uspješnim. YOLO ostvaruje mAP rezultate od 55,01%, dok superiorniji Faster RCNN ostvaruje 77,88%. Potencijalni je problem, prilikom određivanja zubnog statusa, kao i ranije, nedovoljan broj ortopantomograma na kojima bi mreža mogla učiti o krunicama, implantatima, mostovima, itd., s obzirom da ti slučajevi nisu česti.

Procjena dobi, temeljem pojedinog zuba, na ortopantomogramu daje dobre rezultate, a procjena je spola iz pojedinog zuba primjetno slabija od procjene iz cijelog ortopana.

Spomenute je probleme moguće riješiti većom bazom ortopantomograma.

1. Brkić H. Forenzična stomatologija. Zagreb; Školska knjiga; 2000.
2. Brkić H. Procjena dentalne dobi u forenzičnim postupcima, Sonda. 2015; 8(3):67-75.
3. Brkić H, Škavić J, Strinović D. Postmortalna identifikacija tijela postignuta statusom zubala. Acta Stomatol Croat. 1994;28:231-236.
4. Rajić Šikanjić P, Janković I. Metode određivanja spola na ljudskom skeletnom materijalu: glasilo Arheološkog muzeja u Zadru. 2003;21:241-252.
5. GitHub, Inc. Labelling[Internet].GitHub,Inc;c2021[cited 2012 Spt 09]. Available from: <https://github.com/tzutalin/labelImg>
6. Hastie T, Tibshirani R, Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. 2. Stanford California: Springer; 2009.455-461.
7. Hastie T, Tibshirani R, Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. 2. Stanford California: Springer; 2009.632-644.
8. Patterson J, Gibson A. Deep Learning: A Practitioner's Approach. 2017 [Internet]. Sebastopol: O'Reilly Media Inc.; 2017. [cited 2017. Aug 02]. Available from: <https://www.safaribooksonline.com/library/view/deep-learning/9781491924570/ch04.html>
9. Abadi M, Agarwal A, Barham P, Brevdo E, Chen Z, Citro C, Corrado S, Davis A, Dean J, Devin M, Ghemawat S, Goodfellow I, Harp S, Irving G, Isard M, Jozefowicz R, Jia Y, Kaiser L, Kudlur M, Levenberg J, Mané D, Schuster M, Monga R, Moore S, Murray D, Olah C, Shlens J, Steiner B, Sutskever I, Talwar K, Tucker P, Vanhoucke V, Vasudevan V, Viégas F, Vinyals O, Warden P, Wattenberg M, Wicke M, Yu Y, Zheng X. Large-scale machine learning on heterogeneous systems. TensorFlow [Internet]. 2016. November [cited 2016. Nov 4]; 2(265-283): [about 21 p.]. Available from: <https://research.google/pubs/pub45381/>
10. Ghorpade J, Parande J, Kulkarni M, Bawaskar A. GPGPU Processing in CUDA Architecture. An International Journal [Internet]. 2012. January [cited 2012 Jan 17]; [about 16 p.]. Available from: <https://research.google/pubs/pub45381/>
11. Chollet F, Keras [Internet]. GitHub,Inc; 2021 [cited 2015. Aug 09]. Available from: <https://github.com/fchollet/keras>

12. Merkel D, Docker. Lightweight linux containers for consistent development and deployment. Linux journal [Internet]. 2014 March [cited 2014 Mar 01]; 2(239): [about 11 p.]. Available from: <https://dl.acm.org/doi/10.5555/2600239.2600241>
13. Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [Internet] 2015. April [cited 2015 Apr 10]; Available from: <https://arxiv.org/pdf/1409.1556.pdf>
14. Demirjian A, Goldstein H, Tanner JM. A new system of dental age assessment. Hum Biol. 1973 May;45(2):211-27
15. Galić J, Brkić H, Kaić Z, Čadež J. Postmortalna identifikacija dobi postignuta zubalom. Acta stomatol Croat. 1995;29(3):197-201.
16. Dumančić J, Kaić Z, Njemirovskij V, Brkić H, Zečević D. Dental identification after two mass disasters in Croatia. Croat Med J. 2001 Dec;42(6):657-62.

7. ŽIVOTOPIS

Tea Šarić, rođena je 05. travnja 1995. godine u Makarskoj. Osnovnu školu Stjepana Ivičevića u Makarskoj, završila je 2009.godine, kao i Osnovnu glazbenu školu u Makarskoj (smjer klavir). Potom upisuje opću Gimnaziju u Makarskoj te ju završava 2013.te godine. Iste godine upisuje Veterinarski fakultet Sveučilišta u Zagrebu, a nakon završene prve godine studija, prebacuje se na Stomatološki fakultet Sveučilišta u Zagrebu, gdje nastavlja svoje visoko obrazovanje. Dobitnica je Rektorove nagrade za timski znanstveni i umjetnički rad u akademskoj godini 2017./2018. Nastavila je daljnje istraživanje na temu kojeg je napisala ovaj diplomski rad.

