

Primjena umjetne inteligencije u otkrivanju radiolucenčnih lezija donje čeljusti na ortopantomogramima

Rašić, Mario

Doctoral thesis / Doktorski rad

2024

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:127:231233>

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

Download date / Datum preuzimanja: **2025-01-28**



Repository / Repozitorij:

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





Sveučilište u Zagrebu

Stomatološki fakultet

Mario Rašić

**PRIMJENA UMJETNE INTELIGENCIJE U
OTKRIVANJU RADIOLUCENTNIH
LEZIJA DONJE ČELJUSTI NA
ORTOPANTOMOGRAMIMA**

DOKTORSKI RAD

Zagreb, 2024.



Sveučilište u Zagrebu

Stomatološki fakultet

Mario Rašić

**PRIMJENA UMJETNE INTELIGENCIJE U
OTKRIVANJU RADIOLUCENTNIH
LEZIJA DONJE ČELJUSTI NA
ORTOPANTOMOGRAMIMA**

DOKTORSKI RAD

Mentori:

Prof.dr.sc. Predrag Knežević

Prof.dr.sc. Marko Subašić

Zagreb, 2024.



University of Zagreb

School of Dental Medicine

Mario Rašić

**ARTIFICIAL INTELLIGENCE BASED
DETECTION OF RADIOLUCENT LESIONS
OF THE LOWER JAW IN PANORAMIC
RADIOGRAPHS**

DOCTORAL DISSERTATION

Supervisors:

Professor Predrag Knežević, PhD

Professor Marko Subašić, PhD

Zagreb, 2024.

Izražavam svoju iskrenu zahvalnost mentorima, prof. dr. sc. Predragu Kneževiću i prof. dr. sc. Marku Subašiću, čija su izuzetna stručnost, beskrajno strpljenje i neupitna predanost bili ključni u mom procesu učenja i stjecanju novih vještina. Njihova neprocjenjiva podrška bila je od presudne važnosti, ne samo za moje akademsko napredovanje, već i za olakšavanje procesa pisanja znanstvenog rada.

Mario Tropčić bio je ključan u svakoj fazi našeg istraživačkoga procesa. Njegova neprestana podrška, stručni savjeti i vrijedni doprinosi bili su nezamjenjivi. Bez njegove uloge, ovaj doktorat ne bi dostigao visoku razinu kvalitete koju sada ima.

Ovaj doktorski rad posvećujem svojoj supruzi Boženi koja je uvijek uz mene i koja je, tijekom cijelog zajedničkog putovanja, moj stup snage, inspiracija i neizmjerena podrška te sinu Noelu koji je promijenio cijeli moj život nabolje.

Izražavam duboku zahvalnost svojim roditeljima, Miroslavu i Mariji, kao i bratu Tinu, koji su oslonac u mom životu i koji me neprestano motiviraju prema izvrsnosti pružajući mi bezuvjetnu podršku kroz sve životne izazove.

Prikupljanje i označavanje lezija izvedeno je u Klinici za kirurgiju lica, čeljusti i usta KB Dubrava, Zagreb i Zavodu za oralnu kirurgiju Stomatološkog fakulteta, Sveučilišta u Zagrebu.

Obrada i analiza uzoraka provedena je u Zavodu za elektroničke sustave i obradu informacija, Fakulteta elektrotehnike i računarstva, Sveučilišta u Zagrebu.

Lektorica hrvatskog jezika: Jelena Jonjić, prof. hrvatskog jezika

Lektorica engleskog jezika: Mira Petrović, prof. engleskog i talijanskog jezika

Sastav Povjerenstva za ocjenu doktorskog rada:

Sastav Povjerenstva za obranu doktorskog rada:

Datum obrane rada:

Rad sadrži: 97 stranica

59 slika

10 tablica

1 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 ilustracije (tablice, slike i dr.) u radu izvorni su doprinos autora poslijediplomskog doktorskog 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.

Sažetak

PRIMJENA UMJETNE INTELIGENCIJE U OTKRIVANJU RADIOLUCENTNIH LEZIJA DONJE ČELJUSTI NA ORTOPANTOMOGRAMIMA

Svrha ovog rada je razvijanje i testiranje modela umjetne inteligencije u otkrivanju radioluculentnih lezija donje čeljusti. Ciste i tumori čeljusti učestali su klinički entiteti u svakodnevnom radu oralnog i maksilofacijalnog kirurga te se često otkrivaju sasvim slučajno tijekom radiološkog snimanja čeljusti. U početnim stadijima ne uzrokuju simptome što dovodi do kasnog dijagnosticiranja, a samim time dolazi do otežanog liječenja i potencijalno lošijeg ishoda za pacijente. Umjetna inteligencija je izvrstan alat u rješavanju problema brzog dijagnosticiranja lezija čeljusti. Duboko učenje, kao jedan dio umjetne inteligencije, koristi algoritme inspirirane strukturom i funkcijom ljudskog mozga, poznate kao umjetne neuronske mreže i iznimno su korisne u području medicinske dijagnostike.

Istraživanje je obuhvatilo analizu 226 radioluculentnih lezija donje čeljusti dokumentiranih na ortopantomogramima s potvrđenim patohistološkim dijagnozama. Uključene lezije su: radikularna cista, folikularna cista, ameloblastom, odontogena keratocista i rezidualna cista. Kako bi se povećala pouzdanost razvijenog modela umjetne inteligencije, uzorak je dodatno obogaćen korištenjem različitih metoda augmentacije slika. Točnost razvijenog modela umjetne inteligencije analizirana je putem metrika: preciznost, osjetljivost, srednja prosječna preciznost i krivuljom Preciznost-Osjetljivost.

U zadatku detekcije, preciznost, osjetljivost i prosječna preciznost mAP@50 su: 92.5%, 81% i 95.2%. Slično, u zadatku segmentacije, razvijeni model imao je preciznost, osjetljivost i prosječnu preciznost: mAP@50 od 100%, 94.5% i 96.7%. Tijekom testiranja razvijenog modela u kombiniranom zadatku detekcije i dijagnostike, odnosno segmentacije i dijagnostike, došlo je do pada u metričkim rezultatima što je povezano s kompleksnosti zadatka.

Rezultati ovog istraživanja pokazali su metrički značajne mogućnosti razvijenog modela u detekciji, segmentaciji i dijagnosticiranju radioluculentnih lezija donje čeljusti, kao i njegovu buduću upotrebu u kliničkoj praksi.

Ključne riječi: umjetna inteligencija, radioluculentne lezije čeljusti, ortopantomogram, duboko učenje, maksilofacijalna kirurgija

EXTENDED SUMMARY

ARTIFICIAL INTELLIGENCE BASED DETECTION OF RADIOLUCENT LESIONS OF THE LOWER JAW IN PANORAMIC RADIOGRAPHS

Introduction:

Jaw cysts and tumors are common clinical entities encountered in the daily practice of oral and maxillofacial surgeons, as well as dentists. Typically, they remain asymptomatic until their growth begins to alter the shape of surrounding anatomical structures or inflammation develops. As a result, they are often discovered incidentally during radiological examinations, leading to delayed diagnoses and, consequently, less favorable treatment outcomes. For oral and maxillofacial surgeons, early detection is crucial for devising an appropriate treatment plan and ensuring the best possible patient outcomes. Deep learning, a subset of artificial intelligence, employs algorithms inspired by the structure and function of the human brain, known as artificial neural networks. Comprising layers of nodes or "neurons," each layer performs specific computations on input data, proving to be immensely valuable in the medical field. These networks can be utilized for the rapid diagnosis of radiolucent jaw lesions, enhancing patient care and treatment efficiency.

Aim:

The aim of this research is to design and evaluate an advanced artificial intelligence model capable of automatically detecting and segmenting radiolucent lesions of the lower jaw, utilizing the cutting-edge You Only Look Once (YOLO) version 8 technology.

Materials and methods:

In our study, we analyzed a collection of 226 panoramic radiographs, spanning from 2013 to 2023, sourced from the Clinical Hospital Dubrava and the School of Dental Medicine at the University of Zagreb. The panoramic radiographs in this study showcased a diverse array of radiolucent lesions, such as radicular cysts, ameloblastomas, odontogenic keratocysts (OKCs), dentigerous cysts, and residual cysts. Each lesion underwent verification through pathohistological analysis and received annotations within the GIMP software by a collaboration of radiologists and oral and maxillofacial surgeons. The development and evaluation of the artificial intelligence model were conducted at the Faculty of Electrical Engineering and Computing, University of Zagreb. To enrich our database and improve the model's performance, we enhanced the dataset through a series of

image augmentation techniques, such as translation, scaling, rotation, horizontal flipping, and the application of mosaic effects. To accomplish our objectives in detection, segmentation, and diagnosis, we utilized the sophisticated features of the YOLOv8 deep neural network, harnessing its advanced capabilities for precise and efficient analysis.

Results:

In the detection task, the precision, sensitivity, and mean Average Precision (mAP@50) were 92.5%, 81%, and 95.2%, respectively. Similarly, in the segmentation task, the developed model achieved a precision, sensitivity, and mean Average Precision (mAP@50) of 100%, 94.5%, and 96.7%. During the testing of the developed model on combined tasks of detection and diagnosis, as well as segmentation and diagnosis, there was a decrease in metric results, which is attributed to the complexity of the tasks. Specifically, in the detection and diagnosis task, the precision, sensitivity, and mean Average Precision in the augmented set were 55.6%, 79.8%, and 73.1%, while the metric data in the segmentation and diagnosis task were 64%, 66.2%, and 74.9%.

Conclusion:

Artificial intelligence can be used in the detection, segmentation, and diagnosis of radiolucent lesions of the lower jaw. A model developed based on YOLOv8 has the ability to quickly diagnose cysts and tumors of the jaw. To our knowledge, this is the first study that has unified detection, segmentation, and diagnosis of lower jaw lesions using an image resolution of 2776x1480 pixels.

Keywords: artificial intelligence, radiolucent lesions, panoramic radiographs, deep learning, maxillofacial surgery

SAŽETAK

1. UVOD	1
1.1. RADIKULARNA CISTA	2
1.2. FOLIKULARNA CISTA	4
1.3. ODONTOGENA KERATOCISTA	6
1.4. AMELOBLASTOM	7
1.5. REZIDUALNA CISTA	9
1.6. ORTOPANTOMOGRAM	10
1.7. UMJETNA INTELIGENCIJA	12
1.7.1. Povijest umjetne inteligencije.....	12
1.8. DUBOKO UČENJE	15
1.8.1. Konvulzijske neuronske mreže.....	16
1.8.2. Rekurentne neuronske mreže.....	17
1.8.3. Autoenkoderi	17
1.8.4. Generativne suparničke mreže	18
1.9. RAČUNALNI VID	18
1.9.1. Osnove računalnog vida.....	20
1.9.2. Prikupljanje slika	20
1.9.3. Obrada slika.....	20
1.9.4. Ekstrakcija značajki.....	20
1.9.5. Prepoznavanje uzoraka	21
1.10. YOU ONLY LOOK ONCE	21
1.11. UMJETNA INTELIGENCIJA I MAKSILOFACIJALNA KIRURGIJA	23
2. HIPOTEZE I CILJEVI ISTRAŽIVANJA	25
3. MATERIJALI I METODE	26
3.1. MATERIJALI	26
3.1.1. Prikupljanje ortopantomogramskih snimki.....	27
3.1.2. Označavanje ortopantomogramskih snimki.....	29
3.2. METODE	31
3.3. METRIČKA ANALIZA	37

4. REZULTATI	40
4.1. DETEKCIJA LEZIJA DONJE ČELJUSTI.....	40
4.2. SEGMENTACIJA LEZIJA DONJE ČELJUSTI.....	46
4.3. DIJAGNOSTICIRANJE LEZIJA DONJE ČELJUSTI POMOĆU RAZVIJENOG MODELA.....	51
4.3.1. Dijagnosticiranje radikularne ciste.....	54
4.3.2. Dijagnosticiranje folikularne ciste.....	57
4.3.3. Dijagnosticiranje odontogene keratociste.....	60
4.3.4. Dijagnosticiranje ameloblastoma.....	63
4.3.5. Dijagnosticiranje rezidualne ciste.....	65
4.4. VIZUALIZACIJA AKTIVACIJA I TOPLINSKIH MAPA.....	67
5. RASPRAVA	71
6. ZAKLJUČCI	83
7. LITERATURA	84
8. ŽIVOTOPIS	96

POPIS KRATICA:

2D	dvodimenzionalni
3D	trodimenzionalni
BIS	bolnički informacijski sustav
CBCT	engl. <i>cone beam computer tomography</i>
CNN	konvolucijske neuronske mreže (engl. <i>convolutional neural network</i>)
CT	komputerizirana tomografija (engl. <i>computerized tomography</i>)
GAN	generativna suparnička mreža (engl. <i>generative adversarial network</i>)
GIMP	engl. <i>GNU Image Manipulation Program</i>
IoU	<i>križanje preko unije</i> (engl. <i>Intersection over Union</i>)
JPEG	engl. <i>Joint Photographic Experts Group</i>
MIT	engl. <i>Massachusetts Institute of Technology</i>
MKB	Međunarodna klasifikacija bolesti
MR	magnetska rezonanca
OKC	odontogena keratocista
PR	preciznost-osjetljivost krivulja (engl. <i>precision-recall</i>)

RNN rekurentne neuronske mreže (engl. recurrent neural network)

SZO Svjetska zdravstvena organizacija

UI umjetna inteligencija

XCF engl. *eXperimental Computing Facility*

YOLO engl. *You Only Look Once*

1. UVOD

Cista je patološka šupljina kuglastog oblika unutar kosti ili mekih tkiva koja ima unutarnju epitelnu te vanjsku vezivnu stijenku i može biti ispunjena tekućim ili kašastim sadržajem. Posljedica je različitih etioloških faktora, uključujući upalne procese, razvojne poremećaje, ili može biti posljedica odontogenih anomalija (1,2). Simptomi cista čeljusti mogu varirati od asimptomatskih do izraženih, ovisno o veličini, lokaciji i prirodi ciste. Uobičajeni simptomi uključuju oticanje u području čeljusti, bol te poteškoće pri žvakanju ili govoru. U uznapredovalim slučajevima, ciste mogu uzrokovati deformaciju kostiju čeljusti, pomak zuba ili čak njihov gubitak (1,3).

Dijagnoza cista čeljusti obično uključuje kombinaciju kliničkog pregleda, radiografskih snimaka i biopsije. Liječenje varira ovisno o vrsti, veličini i lokaciji ciste, ali obično podrazumijeva kirurško uklanjanje ciste, što može uključivati enukleaciju ili marsupijalizaciju, ovisno o specifičnostima slučaja. E nukleacija je potpuno odstranjenje, odnosno izljuštenje ciste, i predstavlja metodu izbora u liječenju cista čeljusti promjera do 3 cm zbog svog potencijala da trajno riješi problem bez pojave recidiva. S druge strane, marsupijalizacija podrazumijeva stvaranje trajnog otvora u šupljini ciste, omogućavajući kontinuiranu drenažu cističnog sadržaja u usnu šupljinu. Marsupijalizacija je učinkovit tretman za veće ciste, omogućujući dugotrajno rješenje problema. Ovaj postupak pomaže u sprječavanju otežanog cijeljenja velikog defekta i nastanka patološkog prijeloma, čime se poboljšava kvaliteta života pacijenata (1,4).

Ciste čeljusti su česte lezije koje se mogu pojaviti u usnoj šupljini i zahtijevaju pažljivo rukovanje zbog mogućih komplikacija i morbiditeta (4).

Ciste se mogu kategorizirati na razne vrste, temeljeno na njihovu porijeklu, sastavu te načinu na koji se manifestiraju. Uobičajena klasifikacija zasniva se na etiologiji, histopatološkim karakteristikama i mjestu njihova nastanka. Danas se međunarodno priznaje klasifikacija koju je predložila Svjetska zdravstvena organizacija (SZO), a koja je detaljno prikazana u tablici 1. (5).

Tablica 1. Podjela cista čeljusti prema Svjetskoj zdravstvenoj organizaciji. Preuzeto iz (5).


CISTE ČELJUSTI		
ODONTOGENE		NEODONTOGENE
RAZVOJNE	UPALNE	Nazopalatinalna cista (cista incizivnog kanala)
Folikularna cista	Radikularna cista	
Odontogena keratocista	Kolateralna upalna cista	
Ortokeratinizirajuća odontogena cista		
Lateralna periodontalna i botrioidna cista		
Glandularna odontogena cista		
Gingivalna cista		
Kalcificirajuća odontogena cista		

1.1. RADIKULARNA CISTA

Radikularna cista, poznata kao i periapikalna cista, najčešća je cista čeljusti i predstavlja jednu od komplikacija zubnog karijesa (Slika 1). Naime, razvoj radikularnih cista primarno je povezan s kroničnom periapikalnom upalom koja proizlazi iz zubnog karijesa, iako njihov nastanak može biti potaknut i zubnom traumom ili neadekvatnim liječenjem korijena zuba. (6,7) Upalni proces stimulira proliferaciju Malassezovih epitelnih ostataka koji urastaju u granulacijsko tkivo kronične periapikalne upale i oblažu njegovu unutrašnju stranu. Kako epitelna masa raste, granulomatozno tkivo likvefakcijski nekrotizira jer gubi izvore prehrane te nastaje tlak tekućine koji predstavlja poticaj za daljnju sekreciju i širenje šupljine. (8,9) Radikularne ciste su obično asimptomatske i često se otkrivaju slučajno, tijekom rutinskih radioloških pregleda. Mnogi pacijenti s radikularnom cistom ne pokazuju simptome dok cista ne dostigne značajnu veličinu ili dok se ne pojavi sekundarna infekcija. Simptomi mogu uključivati blagu do umjerenu bol, oticanje u području zahvaćenog zuba i ponekad vidljivu promjenu u boji zuba. Također, zub uzročnik često je osjetljiv na perkusiju, redovito s negativnim testom senzibiliteta (10).

Radikularna cista obično je solitarna tvorba koja se može razviti i u gornjoj i donjoj čeljusti, pri čemu se češće javlja u gornjoj čeljusti. Razlog tome je vjerojatno povećana incidencija pulpnih oštećenja prednjih maksilarnih zubi zbog traume ili palatinalnih invaginacija (11). U donjoj čeljusti je najčešće lokalizirana u području kutnjaka i pretkutnjaka. Dijagnostički, radikularne ciste najčešće se identificiraju na radiografskim snimkama kao radiolucentne lezije u koje prominira korijen zuba, često okružene gustim rubom kortikalne kosti. Uobičajene radiografske tehnike uključuju panoramski rendgenski snimak (ortopantomogram), periapikalni rendgenski snimak, i kompjutersku tomografiju s konusnim zrakama (CBCT) (12).


Liječenje radikularnih cista uključuje kirurško uklanjanje koje može varirati od enukleacije do marsupijalizacije, ovisno o veličini i lokaciji ciste. Marsupijalizacija je posebno značajna za velike ciste jer omogućava smanjenje veličine lezije, olakšavajući eventualnu enukleaciju ili zacjeljivanje. Nedavne studije slučaja ističu uspješno upravljanje velikim radikularnim cistama kroz marsupijalizaciju, nakon čega slijedi ortodontsko liječenje za ispravljanje pomaka zuba. Dodatno, nove perspektive sugeriraju da se neke radikularne ciste mogu zacijeliti nakon konvencionalne terapije korijenskih kanala, naglašavajući važnost konzervativnih pristupa liječenju u određenim slučajevima (13,14,15).



Slika 1. Prikaz radikularne ciste donje čeljusti u području premolara

1.2. FOLIKULARNA CISTA

Folikularna cista je najčešća odontogena razvojna cista čeljusti koja nastaje iz odgođenog erupcijskog folikula oko neizniklog zuba (Slika 2). Najčešće je povezana s neeruptiranim trećim kutnjacima, poznatim kao umnjaci, iako se može pojaviti i kod drugih neeruptiranih zuba (16). Češće se pojavljuje u donjoj čeljusti i ima potencijal narasti do značajnih dimenzija, ponekad dostižući promjer od nekoliko centimetara. Kako raste, može izazvati različite strukturne promjene u okolnom tkivu, uključujući napuhavanje ili resorpciju kosti. Ovaj proces, ne samo da mijenja fizičku strukturu kosti, već može i utjecati na položaj i funkciju susjednih anatomskih struktura. Jedan od znakovitih primjera je postupno pomicanje donjeg alveolarnog živca što može dovesti do raznih simptoma, uključujući promjene u osjetu i boli u području koje živac inervira (17,18).



Slika 2. Prikaz folikularne ciste koja zahvaća dio tijela, angulusa i ulaznog kraka donje čeljusti

Histološka analiza otkriva očite razlike u strukturi i stanju folikularnih cista, ovisno o prisutnosti ili odsutnosti upalnih procesa. Kod cista koje nisu pogođene upalom, tipično se nalaze dva do tri reda kubičnih ili pločastih epitelnih stanica. Te stanice usko su povezane s okolnim fibroznim

vezivnim tkivom što ukazuje na stabilnu, neupalnu strukturu. U nekim slučajevima, unutar ovih epitelnih slojeva mogu se detektirati specifični tipovi stanica, uključujući cilindrične epitelne stanice, stanice opremljene trepetljikama, i masne stanice, dodajući složenost i raznolikost tkivne arhitekture (19,20). Jedinstveni nalaz unutar ovih neupalnih cista su kolestinski kristalici koji služe kao patognomoničan indikator specifičnih metaboličkih ili patoloških stanja unutar ciste. S druge strane, ciste koje su zahvaćene upalnim promjenama pokazuju histološki profil koji je znatno različit. Epitel u upaljenim cistama je puno deblji, često karakteriziran proliferacijom stanica i hiperplastičnim promjenama, što ukazuje na aktivni odgovor tkiva na upalni podražaj. Ove promjene u epitelu prate kronična upala, vidljiva kroz prisutnost inflamatornih stanica i promjene u tkivu koje odražavaju dugotrajnu borbu protiv upale (21,22). U nekim slučajevima, unutar upaljenih cista mogu se naći i specifične strukture kao što su hijalinizirani keratin, poznatiji kao Rushtonova tjelešca, koji su indikativni za određene tipove patoloških promjena i mogu pružiti dodatne informacije o prirodi i tijeku upalnog procesa (23).

U većini slučajeva, prisutnost folikularne ciste otkriva se tijekom rutinskih kontrolnih rendgenskih snimki koje se često izvode kao dio standardnog stomatološkog pregleda ili u evaluaciji specifičnih simptoma povezanih s čeljusti i zubima. Karakteristično za folikularne ciste je njihovo pojavljivanje kao unilokularno radiolucenno područje na rendgenskim snimkama, čime se indicira područje koje ne apsorbira zračenje i stoga se pojavljuje tamnije od okolnih tkiva. Ova radiolucencija odražava akumulaciju tekućine ili druge sadržaje unutar ciste što dovodi do stvaranja šupljine (24,25).

Za folikularnu cistu optimalna metoda liječenja je enukleacija, koja obuhvaća uklanjanje ciste zajedno s vađenjem zuba koji su impaktirani ili nepravilno smješteni unutar ciste. Ovaj pristup, ne samo da rješava problem ciste, već i sprječava potencijalne buduće komplikacije povezane s impaktiranim zubima, kao što su infekcije ili dodatne deformacije čeljusti i zuba (26, 27).


Međutim, kod pedijatrijskih pacijenata gdje je razvoj zuba i čeljusti još uvijek u tijeku, može se razmotriti alternativna metoda liječenja poznata kao marsupijalizacija. Ovaj postupak uključuje stvaranje kirurškog otvora u cisti kako bi se omogućilo dreniranje tekućine i smanjenje veličine ciste, čime se zadržava impaktirani zub i zubni pupoljak u razvoju (28).

1.3. ODONTOGENA KERATOCISTA

Odontogena keratocista (OKC) je razvojna cista čeljusti koja se razvija između vanjskog i unutarnjeg sloja caklinskog epitela, prije pojave kalcificiranog zubnog tkiva. U situacijama gdje je zub prisutan, postoji teorija da bi cista mogla proizlaziti iz zametka prekobrojnog zuba (16,29). Alternativno, postoji hipoteza da OKC može nastati iz bazalnih stanica oralnog epitela. Ove teorije ukazuju na složenu etiologiju OKC-a, sugerirajući da njihov razvoj može biti rezultat, kako specifičnih razvojnih anomalija zuba, tako i šireg spektra celularnih procesa unutar usne šupljine (30). OKC čini 4-12% svih cista čeljusti i najčešće je lokalizirana u donjoj čeljusti u području angulusa i ramusa (31).

Razvoj OKC-a može biti pod utjecajem raznolikih etioloških faktora, uključujući genetske i okolišne čimbenike. Među ključnim genetskim faktorima ističu se mutacije u PTCH1 genu koji se nalazi na kromosomu 9q22.3. Ove mutacije su posebno značajne u kontekstu Gorlin-Goltz sindroma, stanja koje predisponira pojedince na razvoj višestrukih OKC-a (32). Osim genetske predispozicije, na pojavu i razvoj OKC-a mogu utjecati i različiti okolišni faktori, poput upalnih procesa i hormonskih promjena. Ova kompleksna interakcija između genetskih i okolišnih čimbenika ključna je za razumijevanje etiopatogeneze OKC-a i podupire potrebu za multidisciplinarnim pristupom u dijagnostici i liječenju ovih lezija (33).

OKC može se pojaviti u bilo kojoj dobi, ali se najčešće dijagnosticira u drugom i trećem desetljeću života. Često se prezentiraju kao asimptomatske, polako rastuće lezije, obično otkrivene slučajno na rendgenogramu. Bol i oticanje mogu se pojaviti ako cista postane inficirana ili dostigne veliku veličinu. Na ortopantomogramskoj slici prikazuje se kao okrugla radiolucencija unilokularna ili multiokularna čiji je rub pravilan (Slika 3). Diferencijalno dijagnostički se može zamijeniti sa ameloblastomom ili folikularnom cistom (34).



Slika 3. Prikaz OKC-a u području uzlaznog kraka i angulusa donje čeljusti desno


Liječenje OKC-a može varirati od konzervativnih pristupa, kao što su marsupijalizacija ili enukleacija, do agresivnijih kirurških metoda, uključujući resekciju s sigurnosnim rubovima i primjenu Carnoyove otopine (35). Izbor tretmana često ovisi o veličini i lokaciji ciste, prisutnosti recidiva i želji da se očuva okolno tkivo i funkcija. Strategija liječenja i praćenja pacijenta s OKC-om također uključuje periodičku radiografsku kontrolu kako bi se rano identificirali recidivi. Iako je marsupijalizacija manje invazivna i može smanjiti rizik od oštećenja vitalnih struktura, enukleacija i resekcija mogu biti potrebne za lezije koje pokazuju agresivnije ponašanje ili za recidivirajuće OKC-ove (35).

1.4. AMELOBLASTOM

Ameloblastom je najčešći odontogeni tumor koji je prvi put opisan 1827. godine od strane Cusacka, dok su naziv "ameloblastom" uveli Ivey i Churchill 1930. godine (36,37). To je tumor koji proizlazi iz ameloblasta, odnosno stanica koje luče proteine cakline i amelogenin koji će se kasnije mineralizirati u caklinu, najtvrdju tvar u ljudskom tijelu. Uglavnom se pojavljuje u osoba u dobi od 30 do 60 godina i deset puta je češći u donjoj čeljusti u usporedbi s gornjom. Ne postoji značajnija razlika u prevalenciji među spolovima (38). Klinička slika ameloblastoma

nije specifična zbog njegovog asimptomatskog i sporo progresivnog razvoja, što često rezultira dijagnosticiranjem u kasnijim fazama bolesti. Kada tumor zahvati čeljusnu kost, ona može biti proširena u punom ospegu, zubi mogu biti pomaknuti s mjesta, a korijeni zuba koji su u kontaktu s ameloblastom mogu biti resorbirani (16,39). Moguća je i pojava ulceracija na alveolarnom grebenu, opstrukcija nosa ili deformacija lica. Konačna dijagnoza ameloblastoma postavlja se na temelju histološke analize. Prema klasifikaciji SZO iz 2017. godine, tumor je bio kategoriziran kao solidni/multicistični, ekstraosalni, monocistični i dezmodoplastični. Međutim, ova podjela je u kasnijim klasifikacijama pojednostavljena na konvencionalni ameloblastom, ekstraosalni/periferni i unicistični ameloblastom, uz dodatak novog metastazirajućeg ameloblastoma (40). Iako je ameloblastom pretežno benigni tumor, opisanu su vrlo rijetki oblici s limfogenim i hematogenim metastazama (41).

Dijagnoza i liječenje ameloblastoma zahtijevaju multidisciplinarni pristup koji uključuje oralne kirurge, patologe, radiologe i, u nekim slučajevima, onkologe, kako bi se osiguralo optimalno liječenje i praćenje pacijenata. Dijagnoza se uvelike oslanja na slikovne pretrage, pri čemu ortopantomogramska i kompjuterizirana tomografska snimka (CT) pruža detaljan prikaz opsega tumora. Radiološki, ameloblastom se najčešće manifestira kao velika šupljina koja se sastoji od brojnih manjih šupljina razdvojenih solidnim tračcima-pregradama (Slika 4) (42).



Slika 4. Ortopantomogramski prikaz čeljusti s ameloblastomom u donjoj čeljusti desno.

Kirurško odstranjenje ameloblastoma predstavlja temelj liječenja, no opseg kirurške intervencije izaziva žestoke debate među stručnjacima. Glavna briga u terapiji ovog tumora odnosi se na visoku frekvenciju povratka bolesti nakon primjene konzervativnijih metoda poput marsupijalizacije i enukleacije. Nasuprot tome, agresivniji pristupi kao što je segmentalna resekcija praćena neposrednom mikrovaskularnom rekonstrukcijom korištenjem autologne kosti, demonstrirali su značajno smanjenje rizika od recidiva. Trenutni uvidi u etiopatologiju ameloblastoma naglašavaju njegovu agresivnost i potencijal za ozbiljan morbiditet u slučajevima neadekvatnog upravljanja bolešću, čime se potvrđuje važnost resektivne kirurgije u terapiji kompleksnih oblika ameloblastoma. Osim toga, nedavna istraživanja ukazuju na značaj genetskih promjena, uključujući mutaciju BRAF V600E, u razvoju ameloblastoma, otvarajući perspektive za razvoj ciljanih terapijskih pristupa u budućnosti (43).


1.5. REZIDUALNA CISTA

Rezidualna cista nastaje kao upalni proces i tipično je posljedica prethodne radikularne ciste na čeljusti, koja se razvija na vrhu korijena zuba ili u području gdje je zub izvađen (Slika 5) (44). Rezidualne ciste obično dijele sličnosti s radikularnim cistama u svojim karakteristikama. Međutim, jednom kada se ukloni primarni uzrok, odnosno zahvaćeni zub ili njegov korijen, dolazi do smanjenja upalnog infiltrata unutar ovih preostalih cista. Kao posljedica toga, u stijenkama cista dominira neupalno fibrozno tkivo bogato kolagenom, što ukazuje na transformaciju prema stabilnijem i manje aktivnom stanju (45).

U istraživanjima se često naglašava važnost uvrštavanja rezidualnih cista u diferencijalnu dijagnostiku, osobito u slučajevima starijih pacijenata bez zuba koji pokazuju simptome cističnih lezija na čeljusnim kostima (46,47).

Klinički i patološki aspekti rezidualnih i radikularnih cista ilustriraju njihovu zajedničku etiologiju i naglašavaju važnost histološke dijagnoze za točno razlikovanje i učinkovito liječenje.

Liječenje rezidualnih cista varira ovisno o njihovoj veličini i lokaciji, uključujući strategije poput dekompresije, enukleacije i marsupijalizacije, koje su među najčešće primjenjivanim metodama. Ovaj pristup omogućuje uspješno rješavanje problema, minimizirajući potencijal za daljnje komplikacije (48,49).



Slika 5. Prikaz rezidualne ciste zaostale nakon ekstrakcije zuba u području donje čeljusti

1.6. ORTOPANTOMOGRAM

Otkriće X-zraka pripisuje se Wilhelmu Conradu Röntgenu, koji je ovo revolucionarno otkriće napravio 1895. godine. Röntgen je eksperimentirao s modificiranom Crooksovom cijevi kada je primijetio neobično zračenje koje je moglo proći kroz čvrste objekte i osvijetliti fotografske ploče. Röntgen je proveo dodatne eksperimente i utvrdio da ove "X-zrake", kako ih je privremeno nazvao zbog svoje nepoznate prirode, imaju sposobnost prodiranja kroz različite materijale, uključujući ljudsko tkivo, omogućavajući prve rendgenske snimke unutrašnjosti ljudskog tijela bez potrebe za kirurškim zahvatom. Jedan od njegovih prvih eksperimenata bio je snimanje rendgenskog prikaza ruke svoje supruge, Anne Bertha Röntgen. Na slici su se jasno vidjele kosti njene ruke i prsten koji je nosila, što je pokazalo izvanredan potencijal nove tehnologije za medicinsku dijagnostiku. Röntgenovo otkriće X-zraka bilo je revolucionarno, ne samo u medicini gdje je omogućilo dijagnostiku i tretmane koji su prije bili nezamislivi, već i u fizici, promijenivši razumijevanje elektromagnetskih zračenja. Za svoj rad, Röntgen je 1901. godine nagrađen prvom Nobelovom nagradom za fiziku, priznajući mu otkriće koje je imalo dalekosežne posljedice za znanost i medicinu i omogućilo razvoj ortopantomografskih uređaja (50-55). Ortopantomografija, poznata i kao panoramska radiografija ili ortopantomogram, predstavlja temeljnu i najznačajniju dijagnostičku sliku u dentalnoj medicini.

Ovaj dvodimenzionalni (2D) rendgenski postupak omogućava dobivanje sveobuhvatne slike cijelih usta u jednom kadru, obuhvaćajući zube, gornju i donju čeljust, kao i okolna tkiva i strukture (50,51). Panoramska radiografija djeluje na principu tomografije gdje se koristi uređaj koji s jedne strane ima montiranu rendgensku cijev, a s druge strane film ili detektor. Tijekom pregleda, glava pacijenta se pozicionira pomoću naslona za bradu, čelo i strane, a može se koristiti i blok za ugriz kako bi se usta neznatno otvorila za jasniju sliku. Dok se rendgenska cijev rotira u polukrugu oko glave pacijenta, projicira rendgenske zraku kroz pacijenta na film ili detektor koji se rotira nasuprot rendgenske cijevi, stvarajući sveobuhvatnu sliku zubnih lukova i susjednih struktura (52,53). Prvi digitalni ortopantomogram, koji je postao dostupan na tržištu 1995. godine, razvio je Catalin Stoichita, osnivač i direktor tvrtke Signet (56).

Priprema za ortopantomogramsku snimku je minimalna i zahtijeva uklanjanje nakita, naočala ili bilo kojih metalnih predmeta koji bi mogli ometati rendgenske snimke. Postupak je brz i traje oko minute, pri čemu stvarno vrijeme izloženosti zračenju varira između 5,5 i 22 sekunde dok se uređaj rotira oko lubanje (51).

Ova tehnika snimanja široko se primjenjuje za sljedeće potrebe:

- Identifikaciju dentalnih problema, uključujući karijes, impaktirane zube i anomalije čeljusti.
- Planiranje različitih stomatoloških zahvata, poput ortodontskih intervencija, umetanja implantata i vađenja zubi.
- Praćenje razvoja i rezultata liječenja, što obuhvaća nadzor nad napretkom stomatoloških procedura ili procjenu izbijanja umnjaka.

Ortopantomogramska snimka prikazuje koštane strukture i zube gornje i donje čeljusti, što olakšava procjenu veličine i pozicije ciste u odnosu na druge anatomske elemente. Proces snimanja je jednostavan i ne zahtijeva invazivne zahvate, a može se izvesti čak i kod pacijenata koji ne mogu otvoriti usta. Dodatno, panoramski rendgenski snimci su relativno povoljni i lako dostupni, čineći ih idealnim izborom kao prvu liniju dijagnostike u slučajevima sumnje na cistične lezije donje čeljusti (50,51).

Iako ova metoda pruža brojne prednosti, postoje i određena ograničenja koja treba uzeti u obzir. Panoramski rendgenski snimci ne pružaju istu razinu detalja kao CT snimke, posebice u složenijim situacijama. Može doći do preklapanja struktura, što otežava identifikaciju

manjih cista ili lezija u ranoj fazi razvoja. Budući da se radi o dvodimenzionalnom prikazu, precizno određivanje dubine i točnih prostornih odnosa može biti izazovno. Stoga je za pravilnu interpretaciju panoramskih snimki potrebno iskustvo i stručnost stomatologa, radiologa ili kirurga (53).

Ortopantomogramska snimka predstavlja temelj u području dentalne radiologije, pružajući jedinstven i sveobuhvatan pogled na usnu šupljinu te ima ključnu ulogu u dijagnostici, planiranju liječenja i praćenju različitih dentalnih i maksilofacijalnih stanja, unatoč određenim ograničenjima.

1.7. UMJETNA INTELIGENCIJA

Umjetna inteligencija (UI) predstavlja tehnološko područje koje omogućava stvaranje strojeva sposobnih za simulaciju aspekata ljudske inteligencije. To podrazumijeva programiranje uređaja da izvode operacije karakteristične za ljudsku misaonu aktivnost, uključujući učenje, analizu, shvaćanje prirodnog jezika i donošenje odluka (57). Koncept obuhvaća raznolike tehnologije i metodologije s namjerom opremanja strojeva kapacitetima za izvršavanje zadataka koji tradicionalno zahtijevaju ljudski intelektualni angažman. Ovi zadaci variraju od procesuiranja i interpretacije informacija do kompleksnog rješavanja problema i prepoznavanja uzoraka, što UI čini ključnim faktorom u napretku suvremenih tehnoloških dostignuća. Sustavi UI dizajnirani su za analizu ogromnih količina podataka, identifikaciju uzoraka, donošenje predviđanja i poduzimanje akcija temeljenih na uvidima dobivenim iz podataka. Tehnike UI uključuju strojno učenje, obradu prirodnog jezika, računalni vid, robotiku, ekspertne sustave i mnoge druge (58,59).

1.7.1. Povijest umjetne inteligencije

Koncept UI seže u drevnu povijest, ali njezino znanstveno istraživanje počelo je 1940-ih. Inovacije u matematici i računalnoj znanosti, od strane osoba poput Alana Turinga, postavile su temeljne teorije. Turingov rad iz 1950. "Računalni strojevi i inteligencija" predložio je ideju da strojevi mogu simulirati ljudsku inteligenciju, uvodeći poznati Turingov test kao kriterij inteligencije (60). Cilj testa je utvrditi može li stroj oponašati ljudsku inteligenciju dovoljno uvjerljivo da ljudi ne mogu razlikovati odgovore stroja od odgovora čovjeka. U testu sudjeluju

tri sudionika: stroj čije se sposobnosti ispituju, sudac koji postavlja pitanja i ljudski sudionik koji služi kao referentna točka. Test se obično izvodi kroz tzv. "imitacijsku igru", gdje sudac komunicira sa sudionicima, odnosno s čovjekom i strojem, oba skrivena od suca. Komunikacija se odvija preko računalnog sučelja kako bi se izbjegle predrasude zasnovane na fizičkom izgledu ili zvuku glasa. Ako sudac ne može pouzdano razlikovati stroj od čovjeka na temelju njihovih odgovora na postavljena pitanja, stroj se smatra "inteligentnim" (61).

Unatoč svojoj pionirskoj ulozi, Turingov test izložen je znatnim kritikama od strane akademske zajednice, koje se uglavnom svode na tri ključne točke zamjerke:

- Pojednostavljivanje problema: kritičari ističu da Turingov test previše pojednostavljuje složenost ljudske inteligencije i svijesti, svodeći ju isključivo na kapacitet za govornu komunikaciju
- Antropocentrizam: pretpostavka testa je da je oponašanje ljudske inteligencije jedini cilj za UI, ignorirajući mogućnost da strojevi mogu razviti druge forme inteligencije
- Iluzija oponašanja: postoji argumentacija da prolazak Turingovog testa ne implicira pravu inteligenciju ili razumijevanje, već samo sposobnost stroja da oponaša ljudsko ponašanje.

Bez obzira na navedeno, Turingov test predstavljao je inovativan korak u definiranju strojne inteligencije potaknuvši bogate filozofske, etičke i tehničke rasprave o biti UI i svijesti.

Dartmouthska konferencija, održana tijekom ljeta 1956. godine na Dartmouth Collegeu u Hanoveru, New Hampshire, SAD, smatra se rođenjem UI kao zasebnog znanstvenog polja (62). Konferencija je rezultat prijedloga koji su podnijeli John McCarthy, Marvin Minsky, Nathaniel Rochester i Claude Shannon (63). Glavni cilj konferencije bio je istražiti kako strojevi mogu simulirati različite aspekte ljudske inteligencije, uključujući učenje, rješavanje problema i razumijevanje jezika. Sudionici su bili uvjereni u mogućnost stvaranja strojeva sposobnih za korištenje jezika, provođenje apstraktnog mišljenja i rješavanje problema koji su do tada smatrani isključivo domenom ljudske inteligencije. Predložili su da bi kratkotrajno, intenzivno istraživačko razdoblje moglo rezultirati značajnim napretkom u ovom polju. Iako konferencija sama po sebi nije dovela do neposrednih proboja, njezin dugoročni utjecaj bio je ogroman.

Potaknula je osnivanje istraživačkih laboratorija i programa posvećenih UI na sveučilištima i istraživačkim institucijama širom svijeta (64).

Tijekom 1960-ih godina, svjedočili smo razvoju ranih programa UI. Jedan od primjera je ELIZA, razvijen od strane Josepha Weizenbauma na MIT-u (prema engl. *Massachusetts Institute of Technology*) između 1964. i 1966. godine. Program je dizajniran da imitira ponašanje psihoterapeuta tijekom razgovora s pacijentom koristeći vrlo jednostavnu metodu prepoznavanja ključnih riječi i odgovaranja pomoću unaprijed definiranih skripti (65,66). ELIZA radi tako što pretražuje uneseni tekst korisnika za ključne riječi ili fraze, a zatim odgovara koristeći pravila koja su povezana s tim ključnim riječima. Ako program ne pronade ključnu riječ, koristi se generički odgovor. Na taj način, ELIZA može voditi osnovni dijalog s korisnikom, često postavljajući pitanja koja potiču korisnika da nastavi razgovor. Najpoznatija skripta koju ELIZA koristi je "DOCTOR" koja simulira razgovor s psihoterapeutom po metodi Carla Rogersa, poznatom kao Rogerijanska psihoterapija. Ovaj pristup terapiji temelji se na stvaranju empatične i neosuđujuće atmosfere koja potiče ljude da govore o svojim osjećajima. ELIZA, koristeći DOCTOR skriptu, primarno odgovara ponavljanjem dijelova izjava korisnika ili postavljanjem otvorenih pitanja, što dovodi do iluzije razumijevanja i empatije (67,68).

Očekivanja postavljena u ranim danima UI nisu bila ispunjena do 1970-ih godina što je rezultiralo prvim razdobljem poznatim kao "Zima umjetne inteligencije". To je bilo vrijeme kada su se financiranje i interes za istraživanje umjetne inteligencije znatno smanjili zbog neuspjeha u ostvarivanju njenih ambicioznih ciljeva. Međutim, tijekom 1980-ih godina došlo je do ponovnog buđenja interesa za područje UI, primarno zahvaljujući komercijalnom uspjehu ekspertnih sustava. Ovi programi su razvijeni s ciljem oponašanja procesa donošenja odluka stručnjaka unutar određenih specijaliziranih područja. Ti sustavi primjenjuju akumulirano znanje i pravila zaključivanja kako bi riješili probleme za koje bi obično bilo potrebno angažiranje ljudskog stručnjaka (69).


Tijekom 1990-ih i 2000-ih, snažan rast interneta rezultirao je stvaranjem ogromnih količina podataka, čime je osiguran bogat izvor sirovog materijala za razvoj naprednijih algoritama strojnog učenja. Jedno od najvažnijih radova iz tog razdoblja objavio je Yann LeCun sa svojim suradnicima, u kojem su opisali uspješnu primjenu konvolucijskih neuronskih mreža za prepoznavanje rukom pisanih brojeva. Time su označili jedan od prvih uspješnih primjera upotrebe neuronskih mreža u nizu (70). Rad je citiran preko 32 000 puta.

Od 2010. napredak u neuronskim mrežama, posebno dubokom učenju, dramatično je povećao sposobnosti sustava UI. Ti sustavi sada mogu nadmašiti ljude u specifičnim zadacima poput prepoznavanja slika, igranja složenih igara i više (71).

1.8. DUBOKO UČENJE

Duboko učenje predstavlja specijaliziranu disciplinu unutar strojnog učenja, usmjerenu na rješavanje problema iz područja umjetne inteligencije. Tehnike dubokog učenja revolucionirale su način na koji računala prepoznaju obrasce i daju smisao složenim, nestrukturiranim podacima, omogućavajući napredak u različitim područjima kao što su prepoznavanje govora, vizualno prepoznavanje objekata, autonomna vozila, medicinsku dijagnostiku i mnoge druge. Njegova sposobnost da izvlači složene uzorke iz velikih skupova podataka čini ga idealnim za rješavanje problema koji su bili nedostižni tradicionalnim algoritmima (72,73).

Duboko učenje koristi algoritme inspirirane strukturom i funkcijom ljudskog mozga, poznate kao umjetne neuronske mreže. Ove mreže sastoje se od slojeva čvorova ili "neurona" gdje svaki sloj izvršava specifične izračune na ulaznim podacima (74). Podaci prolaze kroz slojeve, pri čemu svaki sloj ekstrahira i pojačava značajke relevantne za zadatak (Slika 6).



Slika 6. Dijagram jednostavne neuronske mreže s jednim ulaznim slojem koji ima 3 neurona, dva skrivena sloja sa po 5 neurona svaki i jednim izlaznim slojem s 2 neurona. Svaki neuron u jednom sloju povezan je sa svakim neuronima u sljedećem sloju što omogućuje mreži da uči kompleksne obrasce iz podataka.

"Duboko" u kontekstu dubokog učenja odnosi se na korištenje višeslojnih mreža koje mogu modelirati složene obrasce na visokoj razini apstrakcije. Kao što je već navedeno, arhitektura dubokog učenja karakterizira se slojevitim rasporedom umjetnih neuronskih mreža, čime se modelima omogućava učenje iz podataka na način sličan funkcioniranju ljudskog mozga, no s izraženom većom točnošću i efikasnošću. (75) Ove arhitekture dubokog učenja mogu se kategorizirati na temelju različitih faktora, uključujući tip podataka koje obrađuju, specifične probleme koje rješavaju ili složenost i dizajn same mreže.

1.8.1. Konvolucijske Neuronske Mreže (CNN)

CNN-ovi predstavljaju specijalizirane varijante umjetnih neuronskih mreža razvijene za obradu podataka s jasno utvrđenom rešetkastom strukturom, poput vizualnih slika. Ključni koncept CNN-a leži u njegovoj sposobnosti automatskog i učinkovitog izvlačenja relevantnih značajki iz slika putem procesa konvolucije, uvođenja nelinearnosti i grupiranja. Grupirajući slojevi, od kojih je maksimalno grupiranje najučestaliji oblik, služe za redukciju dimenzionalnosti značajki dobivenih konvolucijskim slojevima. Ovo smanjenje broja parametara i potrebnih izračuna unutar mreže znatno povećava njenu efikasnost. Nakon niza konvolucijskih i grupirajućih slojeva, CNN obično sadrži jedan ili više potpuno povezanih slojeva koji služe za klasifikaciju ili regresiju na temelju izvučenih značajki (76). Ovi slojevi funkcioniraju slično kao slojevi u tradicionalnim višeslojnim perceptronima. Konvolucijske neuronske mreže imaju široku primjenu u područjima koja zahtijevaju analizu vizualnih podataka, uključujući:

- Prepoznavanje objekata i lica u slikama i videima
- Klasifikacija slika i videa
- Detekcija objekata i praćenje u realnom vremenu
- Analiza medicinskih slika za dijagnostiku
- Autonomna vozila za vizualnu navigaciju

1.8.2. Rekurentne Neuronske Mreže (RNN)

Rekurentne neuronske mreže su posebno dizajnirane da zadrže informaciju o prethodnim koracima u sekvenci, čime se omogućuje da izlaz iz jednog koraka postane ulaz za sljedeći, stvarajući memoriju o prethodno obrađenim podacima. Ovo omogućuje mreži da donosi odluke temeljene na ranijim informacijama u sekvenci, što je ključno za zadatke poput generiranja teksta ili razumijevanja govora (77).

RNN-ovi se primjenjuju u širokom spektru disciplina, uključujući različite složene zadatke kao što su:

- Prevođenje jezika, generiranje teksta i analiza sentimenta
- Prepoznavanje govora
- Generiranje glazbe, omogućujući kreaciju novih glazbenih djela na temelju uzoraka naučenih iz postojećih kompozicija
- Predviđanje vremenskih serija, koristi se u financijskom sektoru za projekcije cijena dionica, ili u meteorologiji za anticipiranje meteoroloških prilika (78).

1.8.3. Autoenkoderi

Autoenkoderi su vrsta neuronske mreže dizajnirane za učenje efikasnih reprezentacija (enkodiranja) neoznačenih podataka. Tipično se koriste za smanjenje dimenzionalnosti ili za generiranje podataka. Autoenkoderi rade tako što prvo komprimiraju ulazne podatke u manju, gustu reprezentaciju, a zatim ih dekodiraju natrag u originalni format. Osnovna struktura autoenkodera sastoji se od dva glavna dijela: enkodera i dekodera. Enkoder prima ulazne podatke i transformira ih u kompaktniju, latentnu reprezentaciju. Ova latentna reprezentacija sadrži ključne značajke ulaznih podataka, ali u mnogo manjem prostoru, što omogućava efikasnije pohranjivanje ili obradu. Dekoder uzima kompaktnu latentnu reprezentaciju i pokušava rekonstruirati originalne ulazne podatke. Idealno, rekonstrukcija bi trebala biti što je moguće bliža originalu, što znači da latentna reprezentacija mora sadržavati dovoljno informacija za vjernu rekonstrukciju (79,80).

1.8.4. Generativne suparničke mreže (GAN)

Generativne suparničke mreže (GAN), koje su 2014. godine razvili Ian Goodfellow i njegov tim, označile su prekretnicu u području umjetne inteligencije, predstavljajući inovativnu kategoriju umjetnih neuronskih mreža specijaliziranih za učenje bez nadzora. Koncept GAN-ova temelji se na dinamici između dvije međusobno suprotstavljene mreže: generativne mreže, poznate kao generator, čija je zadaća stvarati podatke i diskriminatorne mreže ili diskriminatora, čiji je cilj razlikovati originalne podatke od onih koje je stvorio generator. Proces učenja GAN-a može se opisati kao igra s nulturnom sumom u kojoj generator pokušava maksimalno prevariti diskriminator generiranjem sve uvjerljivijih podataka, dok diskriminator pokušava postati sve bolji u otkrivanju lažnih podataka. Kroz iteracije generator postaje sve vještiji u stvaranju realističnih podataka, dok diskriminator postaje sve precizniji u razlikovanju. Generativne suparničke mreže našle su primjenu u širokom spektru područja, uključujući stvaranje realističnih slika osoba, tekstura ili predmeta koji ne postoje u stvarnosti te povećavanje rezolucije slika, uklanjanje šuma ili popravak oštećenih slika (81).

Iako duboko učenje nudi izvanredne mogućnosti, postoji nekoliko izazova i ograničenja. Jedan od glavnih izazova je potreba za velikim količinama označenih podataka za treniranje. Također, duboke neuronske mreže mogu biti izuzetno zahtjevne za resurse, uključujući računalnu snagu i memoriju. Osim toga, interpretacija modela dubokog učenja može biti teška, što dovodi do problema s transparentnošću i povjerenjem u donošenje odluka (82).

1.9. RAČUNALNI VID

Računalni vid predstavlja sofisticirano područje unutar UI, osmišljeno kako bi se računalima omogućilo dešifriranje i razumijevanje vizualnog okruženja. Procesuiranjem digitalnih slika iz različitih izvora kao što su kamere i videozapisi kroz primjenu naprednih algoritama dubokog učenja, ti sustavi postižu sposobnost preciznog prepoznavanja i kategoriziranja objekata. To im zauzvrat omogućava da inteligentno reagiraju na vizualne podražaje s kojima se susreću (83,84, 85).

Koncept računalnog vida počeo se razvijati s pojavom računala. Početni pokušaji bili su usmjereni na osnovno prepoznavanje uzoraka i sposobnost tumačenja jednostavnih slika. Projekt Ljetne vizije na MIT-u iz 1966., pod mentorstvom Marvina Minskog, predstavlja jedan

od pionirskih pothvata u sferi računalnog vida, s ambicijom da se kamera integrira s računalom koje bi zatim moglo "opisivati što promatra". Unatoč inovativnom pristupu, ograničenja tehnologije tog vremena spriječila su ostvarenje zacrtanih ciljeva (86,87).

Tijekom 70-ih godina prošlog stoljeća, došlo je do značajnih napredaka u razvoju sofisticiranijih metoda obrade slika. U tom razdoblju, istraživači su ostvarili značajne korake u razumijevanju i manipulaciji digitalnim slikama na razini pojedinačnih piksela. Ovaj napredak omogućio je poboljšanja u tehnikama detekcije rubova i ekstrakcije značajki, kao i u prvim pokušajima kreiranja 3D modela. Jedan od ključnih figura tog vremena bio je David Marr, neuroznanstvenik s MIT-a, čija su istraživanja cerebeluma, hipokampusa i korteksa - ključnih komponenti ljudske percepcije - postavila temelje suvremenog računalnog vida (88,89). Marr je proučavao kako mozak obrađuje vizualne informacije i predložio teorije koje su duboko utjecale na način na koji strojevi "vide" i interpretiraju vizualne podatke. Njegova vizija i radovi na području percepcije i vizualnog procesuiranja učinili su ga poznatim kao "oca suvremenog računalnog vida". Tijekom osamdesetih godina prošlog stoljeća, istraživanje u području računalnog vida prešlo je na detaljniju analizu vizualnog sadržaja, usmjeravajući se na prepoznavanje specifičnih elemenata unutar slike kao što su rubovi, kutovi i različiti objekti. Ovo razdoblje obilježeno je pokušajima razumijevanja i interpretacije složenijih vizualnih informacija, što je predstavljalo ključan korak prema naprednijem računalnom vidu. Devedesete godine donijele su revoluciju u obliku integracije tehnika strojnog učenja s područjem računalnog vida, čime je započela nova era inovacija i napretka. Algoritmi strojnog učenja, uključujući stabla odlučivanja, neuronske mreže i strojeve s potpornim vektorima, počeli su nalaziti svoju primjenu u različitim zadacima povezanim s računalnim vidom. Primjene su se proširile na klasifikaciju slika, prepoznavanje objekata te analizu i interpretaciju složenih vizualnih scena. Ova integracija, ne samo da je poboljšala točnost i efikasnost računalnog vida, već je otvorila vrata za razvoj sofisticiranih aplikacija koje su transformirale kako interagiramo s digitalnim svijetom oko nas (90,91,92).

1.9.1. Osnove računalnog vida

Osnove računalnog vida obuhvaćaju širok spektar koncepta, tehnika i metodologija osmišljenih kako bi se omogućilo računalima da interpretiraju i razumiju vizualne informacije iz svijeta oko nas. Te osnove proizlaze iz više disciplina, uključujući matematiku, fiziku, informatiku i umjetnu inteligenciju. Ovaj multidisciplinarni pristup omogućava razvoj sofisticiranih sustava koji mogu analizirati i interpretirati slike i videozapise s razinom detalja i preciznošću koja se približava ljudskoj sposobnosti percepcije.

1.9.2. Prikupljanje slika

Započinjanje procesa računalnog vida s prikupljanjem slika, ključni je korak gdje digitalne slike postaju dostupne putem snimanja korištenjem kamera, senzora ili sličnih uređaja. Važnost ove faze leži u činjenici da kvaliteta i specifičnosti snimljenih slika imaju izravan utjecaj na uspješnost i efikasnost svih nadolazećih faza obrade i analize. Raznovrsnost formata, rezolucija i kutova snimanja prilagođava se specifičnim potrebama i zahtjevima pojedine primjene (93).

1.9.3. Obrada slika

Nadalje, nakon inicijalnog prikupljanja, slike se često podvrgavaju detaljnoj obradi s ciljem unaprjeđenja njihove kvalitete i optimizacije za daljnju analizu. Ovaj proces obrade uključuje različite tehnike i operacije poput poboljšanja kvalitete slike, redukcije šuma, detekcije rubova i segmentacije, sve s krajnjim ciljem ekstrakcije korisnih informacija i pripreme slika za složenije analitičke postupke. Temeljni je cilj osigurati da slike budu što bolje pripremljene za detaljnu analizu, čime se povećava preciznost i efikasnost cjelokupnog sistema računalnog vida (94).

1.9.4. Ekstrakcija značajki

Proces ekstrakcije značajki podrazumijeva precizno prepoznavanje i vađenje ključnih elemenata iz slike, koji su ključni za dublju analizu ili proces donošenja odluka. Takvi elementi obuhvaćaju, među ostalim, rubove, kutove te različite oblike. Ove značajke čine osnovu za detaljnije analitičke postupke, nudeći pojednostavljeni prikaz sadržaja slike za lakše razumijevanje i obradu (93,94).

1.9.5. Prepoznavanje uzoraka

S druge strane, sposobnost prepoznavanja uzoraka omogućuje identifikaciju i kategorizaciju različitih obrazaca unutar vizualnih podataka. Ovaj proces se oslanja na napredne tehnike i algoritme koji računalima omogućavaju da efikasno prepoznaju objekte, oblike i teksture sadržane u slikama. Za ovakve zadatke koriste se, kako tradicionalni algoritmi strojnog učenja poput Strojeva s Potpornim Vektorima (SVM), tako i kompleksniji modeli bazirani na principima dubokog učenja (95,96).

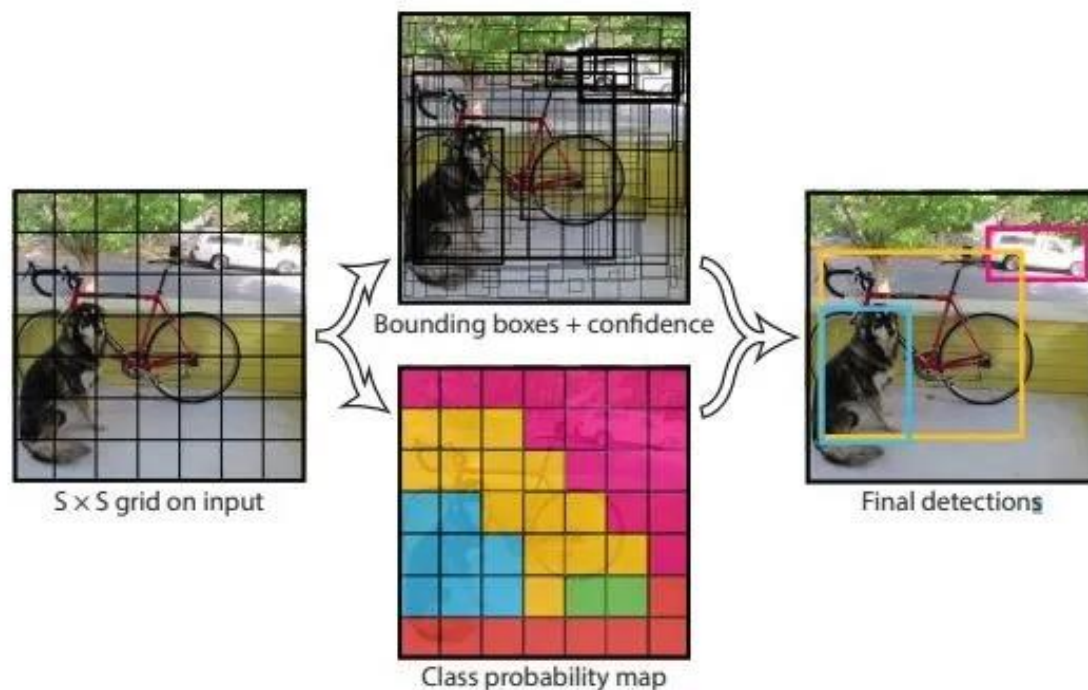
Usklađivanje ključnih faza, prikupljanje slika, njihova obrada te ekstrakcija značajki i prepoznavanje obrazaca, ključno je za omogućavanje sustavima računalnog vida da izvršavaju zahtjevne zadatke poput detekcije objekata, kategorizacije slika i analize različitih scena. Performanse sustava računalnog vida znatno zavise od efikasnosti svake pojedinačne faze i njihove međusobne koordinacije. Svaka od ovih etapa pridonosi ultimativnom cilju, a to je interpretacija vizualnih podataka na način sličan ljudskoj percepciji. Stoga, uspješnost ovih sustava leži u njihovoj sposobnosti da integriraju i harmoniziraju ove korake, čime se postiže razvoj sofisticiranih i pouzdanih alata za računalni vid.

1.10. YOU ONLY LOOK ONCE (YOLO)

YOU ONLY LOOK ONCE (YOLO) označava algoritam za detekciju objekata, predstavljajući ključni preokret u području tehnologije računalnog vida. Ovaj algoritam je postavio nove standarde u učinkovitosti i točnosti, premašujući performanse renomiranih metoda poput R-CNN, Fast R-CNN, Faster R-CNN i SSD (97-100).

YOLO je prvi put predstavljen na konferenciji u Las Vegasu od strane Redmona i sur. 2016. i temelji se na ideji da se detekcija objekata može izvršiti kao jedinstveni zadatak regresije umjesto klasifikacije, koji izravno preslikava ulazne piksele slike u koordinate graničnih okvira i vjerojatnosti klasa. YOLO algoritam može se promatrati kao kombinacija nadziranog dubokog učenja, računalnog vida i prikupljanja te analize podataka. Arhitektura ove prve verzije YOLO algoritma se sastoji od 24 konvulcijska sloja praćena sa dva potpuno vezana sloja (101).

YOLOv1 podijeli ulaznu sliku u SxS ćelije i za svaku ćeliju predviđa granične okvire i vjerojatnosti klasa (Slika 7).



Slika 7. Prikaz YOLO modela. Preuzeto iz (101).

Od svog prvog predstavljanja 2016. s YOLOv1, modeli YOLO prošli su kroz nekoliko različitih nadogradnji i novih verzija, sve do najnovije verzije, YOLOv8, koju je razvio tim Ultralytics. Svaka verzija donijela je poboljšanja u brzini, točnosti i arhitekturi modela, znatno doprinoseći detekciji objekata (102,103).

YOLOv8 unijela je značajne nadogradnje u odnosu na prijašnje modele te koristi pristup bez sidrenih okvira. Drugim riječima, model predviđa položaj objekta odmah, bez ikakvih prilagodbi, iz unaprijed definiranog sidrenog okvira čime se olakšava proces detekcije, i također smanjuje broj potrebnih predviđenih. Uvedene su promjene u konvolucijske blokove modela, gdje je prva 6x6 konvolucija zamijenjena s 3x3, a tijekom treninga koristi se mozaik augmentacija gdje se četiri različite slike iz skupa podataka spajaju u jednu sliku tako da svaka od originalnih slika zauzima jedan kvadrant nove slike. Ova tehnika omogućava modelu prepoznavanje objekta s manje vidljivih dijelova te u različitim okruženjima i pozadinama (104,105).

1.11. UMJETNA INTELIGENCIJA I MAKSILOFACIJALNA KIRURGIJA

UI sve se više integrira u oralnu i maksilofacijalnu kirurgiju, nudeći značajna poboljšanja u dijagnostici, planiranju liječenja i izvođenju kirurških operacija. UI može brzo i točno interpretirati rendgenske i CT snimke, identificirajući anomalije poput tumora, prijeloma i drugih patologija s visokom preciznošću. Chai i suradnici u svom radu pokazali su da model temeljen na dubokoj neuronskoj mreži može bolje dijagnosticirati i razlikovati ameloblastom i OKC od oralnog i maksilofacijalnog kirurga (110). Kako je već navedeno, ortopantomogramska snimka je 2D prikaz struktura čeljusti. UI korištenjem naprednih algoritama stvara detaljne 3D modele iz 2D slika, pomažući kirurzima da vizualiziraju složene anatomske strukture i učinkovitije planiraju operacije. Ovi 3D modeli omogućuju kirurzima da bolje razumiju prostorne odnose i pripreme se za operacije s većom preciznošću, smanjujući rizik od komplikacija (107,108).

Algoritmi strojnog učenja mogu analizirati ogromnu količinu podataka iz prethodnih slučajeva kako bi preporučili personalizirane planove liječenja temeljem jedinstvenih karakteristika svakog pacijenta. Ovi algoritmi uzimaju u obzir specifične anatomske i patološke osobitosti svakog slučaja, čime se poboljšava uspješnost liječenja i skraćuje vrijeme oporavka (108). Upotrebom računalnog vida moguće je analizirati simetriju i estetske podjedinice lica te preporučiti daljnje korake s ciljem najboljeg estetskog ishoda za pacijenta. UI može predložiti optimalne kirurške pristupe kako bi se postigli prirodni i estetski zadovoljavajući rezultati, što je posebno važno u rekonstruktivnoj kirurgiji (109).

Kako tehnologija UI nastavlja napredovati, njezina uloga u ovom području vjerojatno će se proširiti, nudeći još veće prednosti u smislu učinkovitosti, preciznosti i skrbi za pacijente. Međutim, zahtijeva pažljivo implementiranje i nadzor kako bi se osigurala točnost, sigurnost i etičnost u praksi.

U dostupnoj literaturi postoji mali broj istraživanja na temu primjene UI u dijagnostici lezija donje čeljusti.

Svrha ovog rada je primjena suvremenih tehnika dubokoga učenja, obrade slike i računalnog vida te razvitak sveobuhvatnog računalnog okvira sposobnog za detekciju, segmentaciju i dijagnostiku lezija donje čeljusti.

Originalnost i izvornost ovoga istraživanja proizlaze iz činjenice da do sada, prema nama dostupnoj literaturi, nema niti jedan model UI-a koji objedinjuje sve tri navedene stavke.

2. HIPOTEZE I CILJEVI ISTRAŽIVANJA

Hipoteza predloženog istraživanja je:

- UI može se koristiti u dijagnosticiranju prozračnosti donje čeljusti na ortopantomogramima

Opći cilj istraživanja je razviti neuronsku mrežu koja će prepoznavati i obilježavati na ortopantomogramima različite radioludentne lezije donje čeljusti.

Specifični ciljevi su:

- razviti model UI koji će diferencijalno dijagnosticirati različite radioludentne lezije na donjoj čeljusti
- razviti algoritam UI koji će segmentirati različite radioludentne lezije na donjoj čeljusti
- razviti algoritam UI koji će označavati šupljinu različitih radioludentnih lezija na ortopantomogramima donje čeljusti
- testirati UI na ortopantomogramima

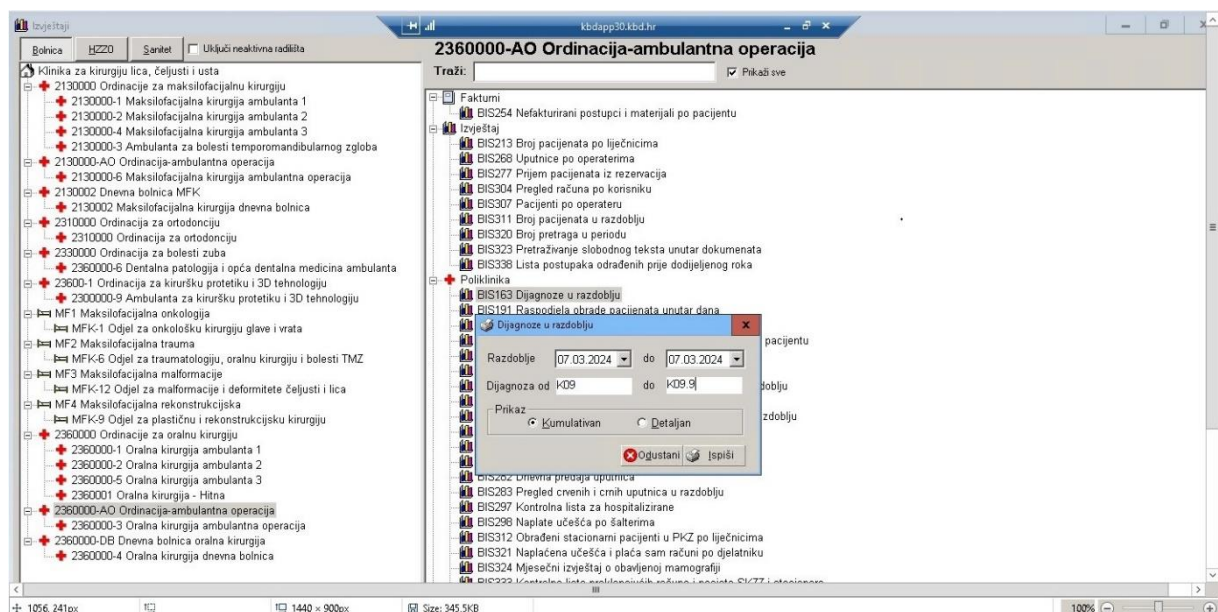
3. MATERIJALI I METODE

Istraživanje je provedeno tijekom 2021., 2022. i 2023. godine na Klinici za kirurgiju lica, čeljusti i usta, Kliničke bolnice Dubrava, Zavodu za oralnu kirurgiju Stomatološkog fakulteta, Sveučilišta u Zagrebu i Zavodu za elektroničke sustave i obradu informacija, Fakulteta elektrotehnike i računarstva, Sveučilišta u Zagrebu. Za potrebe izrade doktorske disertacije, zaposlenici Zavoda za elektroničke sustave i obradu informacija, su na temelju prikupljenih i dostavljenih podataka te označenih ortopantomogramskih snimki razvili algoritam duboke neuronske mreže.

Ovo istraživanje odobrilo je Etičko povjerenstvo Kliničke bolnice Dubrava (2023/2103-01 ;), Etičko povjerenstvo Stomatološkog fakulteta Sveučilišta u Zagrebu (05-PA-30-16-3/2023) i provedeno je u skladu s načelima Helsinške deklaracije.

3. 1. MATERIJALI

Pacijenti su bili pretraživani u okviru Bolničkog informacijskog sustava (BIS) Kliničke bolnice Dubrava i Zavoda za oralnu kirurgiju u razdoblju od 2013. do 2023. godine, koristeći dijagnoze koje su kategorizirane prema Međunarodnoj klasifikaciji bolesti (MKB) (Slika 8).



Slika 8. Prikaz BIS pretrage radiolucenih lezija prema MKB kasifikaciji.

Dijagnoze uključene u pretraživanje su:

- K09.0 Razvojne odontogene ciste
- K09.1 Razvojne (neodontogene) ciste oralnog područja
- K09.2 Ostale ciste čeljusti
- K09.8 Ostale ciste oralnog područja, nesvrstane drugamo
- K09.9 Cista oralnog područja, nespecificirana
- K04.8 Radikularna cista
- K00.8 Ostali poremećaji razvoja zubi
- K00.9 Poremećaj razvoja zuba, nespecificiran
- D16.5 Benigne promjene donje čeljusti

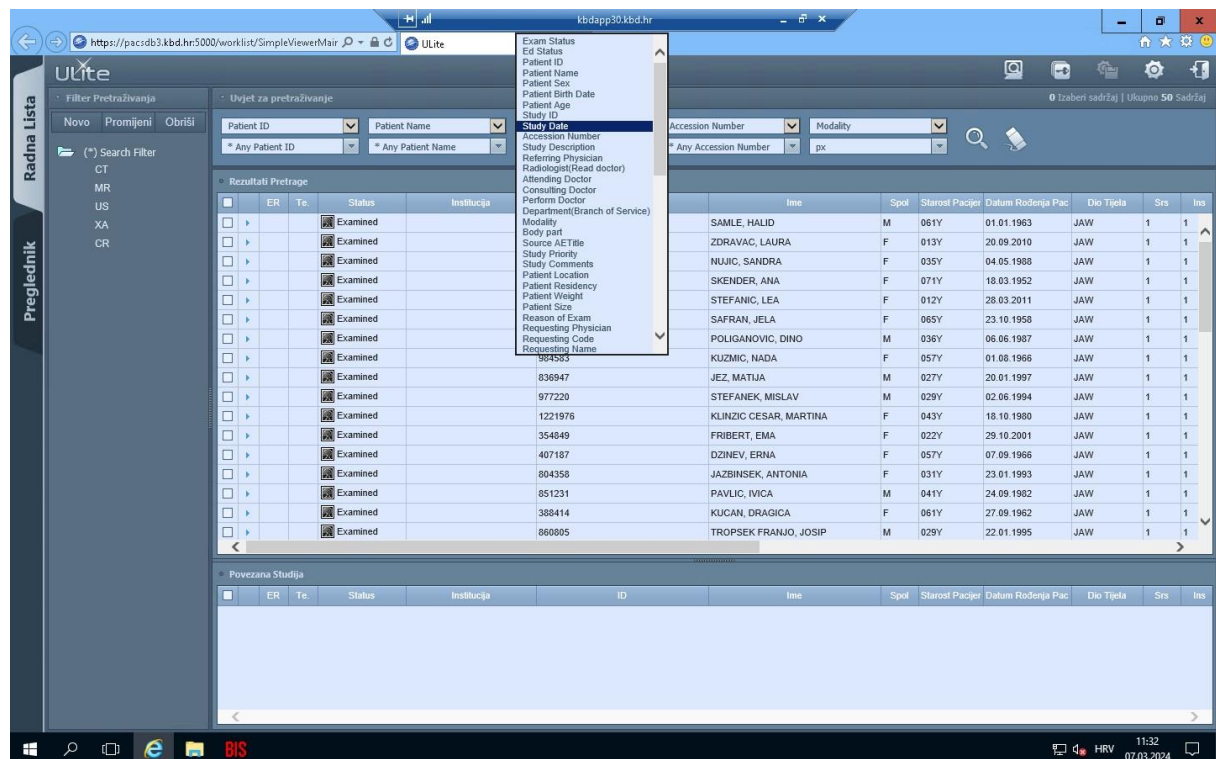
Nakon dobivenih rezultata pretraživanjem sustava BIS, daljni glavni uključni kriterij istraživanja bila je pristunost radiolucentne lezije i patohistološka verifikacija jedne slijedećih lezija donje čeljusti:

- Radikularna cista
- Folikularna cista
- OKC
- Ameloblastom
- Rezidualna cista

3.1.1. Prikupljanje ortopantomogramskih snimki

Kao materijal za izradu modela UI korištene su ortopantomogramske snimke pacijenata koji su zadovoljavali prethodno opisane kriterije. Snimke su pretraživane u posebnom računalnom programu Ulite INFINITT (INFINITT Healthcare Co. Ltd, Seoul, Južna Koreja) (Slika 9). Nakon što se dobije informacija iz BIS-a koji pacijent zadovoljava kriterije, u Ulite INFINITT programu se odaberu posebne značajke da bi se istražila baza podataka Ustanove i skratilo vrijeme pretrage iste. S obzirom na to da je uključno razdoblje liječenja ispitanika bilo od 2013. do 2023.godine, ta činjenica je određena kao prva odabrana značajka programa. Zbog toga što se u ovom istraživanju koriste samo ortopantomogramske snimke, a Ulite INFINITT sadrži i

sve ostale snimke poput CT-a i magnetske rezonance (MR), slijedeća odabrana značajka je digitalna ortopantomogramski snimka. Budući da u bazi podataka dolazi do podudaranja u imenu i prezimu određenih pacijenata, točan datum rođenja je jedna od bitnijih odabranih značajki.



Slika 9. Prikaz pretrage ortopantomogramskih snimki čeljusti u ulite INFINITT programu

Na prethodno opisani način iz baze podataka dviju Ustanova prikupljeno je dvjesto ortopantomogramskim snimki koje su sadržavale 226 radiolucentnih lezija donje čeljusti koje su prikazane na tablici 2.

Tablica 2. Raspodjela ulaznih podataka s kojima će se razvijati model UI


RADIOLUCENTNA LEZIJA	BROJ PODATAKA
RADIKULARNA CISTA	138
FOLIKULARNA CISTA	29
ODONTOGENA KERATOCISTA	33
AMELOBLASTOM	13
REZIDUALNA CISTA	13
Ukupno	226

Sve snimke su spremljene putem komprimiranog slikovnog formata JPEG(*eng. Joint Photographic Experts Group*) dimenzija 2776x1480 pixela.

3.1.2. Označavanje ortopantomogramskih snimki


Za razvijanje modela UI koji će označavati i dijagnosticirati radiolucentne lezije donje čeljusti, potrebno je prethodno spremljene snimke pripremiti za anotaciju. Priprema je vršena od strane specijalizanta maksilofacijalne kirurgije uz nadzor, provjeru i popravke oralnog kirurga, radiologa i maskilofacijalnog kirurga. Priprema se odvija tako da se na svakoj snimci označi radiolucentna lezija pomoću GIMP programa (prema engl. *GNU Image Manipulation Program*, hrv. *GNU program za manipulaciju slika*). GIMP je slobodan i otvoren program za uređivanje slika, dostupan za razne operativne sisteme, uključujući Linux, macOS i Windows. Razvijen je od strane volonterskog tima programera putem projekta pod nazivom GNU te nudi bogat skup alata za obradu slika, crtanje, korekciju boja i pretvorbu formata slika. Najvažnija stavka GIMP-a je unos i spremanje datoteka različitih formata čime zadovoljava potrebe velikog broja korisnika, a ujedno je i softver otvorenog koda.

Prethodno spremljene slike u JPEG formatu importiraju se u GIMP softver, a zatim se u sučelju slika pretvori u poluprozirni sloj na način da se promijeni parametar opacitet na 60 posto. Tim postupkom, slika koja je učitana bit će 60 posto vidljiva, 40 posto propusna što omogućuje lakše označavanje lezije. Da bi označavanje bilo što preciznije, treba postaviti postavke kista kojim će se crtati rubovi lezije. U ovom istraživanju je korišten kist oblika kružnice čija je čvrstoća postavljena na 100 posto. Na taj način je spriječeno pojavljivanje nepoželjnih polupropusnih rubova radiolucentne lezije. Nakon toga se odabere novi sloj i imenuje se prema nazivu lezije koju želimo označiti (Slika 10).



Slika 10. Prikaz GIMP programa za ručno označavanje radiolucentnih lezija s postavljenim opacitetom na 60%.

Nakon što su obavljene svi prethodni koraci, izabere se opcija povećanja na leziju, nakon čega se lezija označava kistom. Tijekom označavanja dogodile su se pogreške u ispunjavanju lezije kistom crvene boje, a što se ispravilo korištenjem opcije kantice s bojom. Potpuno označena radiolucentna lezija se sprema u xcf (prema *engl. eXperimental Computing Facility*) formatu zbog daljnjeg pripremanja za izradu modela UI (Slika 11).



Slika 11. Prikaz ručno označene ciste u GIMP programu

3.2. METODE

Nakon preciznog označavanja svake ciste u GIMP-u i njihovog spremanja kao .xcf datoteka, sljedeći korak uključivao je izdvajanje segmentacijskih maski iz tih datoteka. Za tu svrhu razvijena je Python skripta koja se može vidjeti na Slici 12. Ova skripta efikasno prolazi kroz sve .xcf datoteke, izdvajajući i spremajući samo slojeve koji sadrže označena maskirana područja kao .jpg slike. Nakon završetka procesa ekstrakcije, sljedeći neophodni korak je kreiranje odgovarajućih oznaka koje su ključne za učenje modela. Budući da je odabrani model za ovaj zadatak baziran na YOLO arhitekturi, oznake su formatirane u .txt datoteke u skladu s tim.

```
1 import glob
2 import os
3
4 parent_dir = os.getcwd()
5 directory = "masks"
6 path = os.path.join(parent_dir, directory)
7
8 if not os.path.exists(path): os.mkdir(path)
9
10 for fname in glob.glob("*.xcf"):
11     img = pdb.gimp_file_load(fname, fname)
12     img.remove_layer(img.layers[0])
13     img.flatten()
14     new_name = fname[:-4] + ".jpg"
15     output_path = os.path.join(path, new_name)
16     pdb.gimp_file_save(img, img.layers[0], output_path, new_name)
```

Slika 12. Prikaz razvijene Python skripte koja služi za izdvajanje segmentacijskih maski.

Svaka oznaka u skupu podataka odgovara pojedinoj slici, pružajući detaljne informacije o položaju svih označenih objekata zajedno s njihovim odgovarajućim klasama. Kao što je ilustrirano na slici 13. deskriptor klase modela označen je prvim brojem (u ovom slučaju 0), dok sljedeći brojevi označavaju relativne položaje objekata ili, preciznije, poligone koji ih obuhvaćaju. Svaki par brojeva predstavlja određenu točku (X i Y os) na slici. U slučaju više objekata na istoj slici, opis svakog objekta nalazi se u posebnom retku datoteke.

```
0 0.8038773669972948 0.578125 0.8043282236248873 0.5771484375 0.8174030658250676 0.5771484375 0.8178539224526601 ...
```

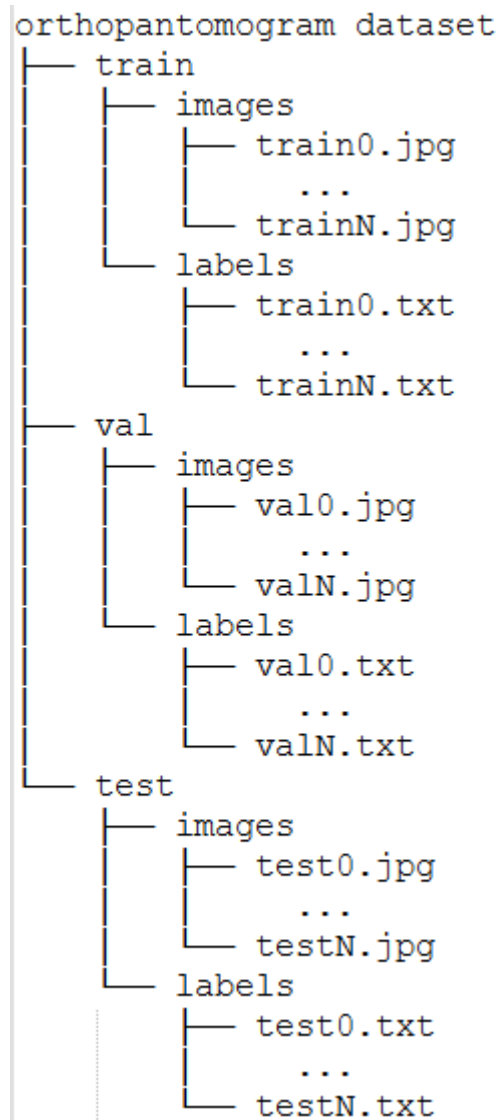
Slika 13. Prikaz označavanja deskriptora klase modela i relativnih položaja objekta

U ovom istraživanju su za različite zadatke kreirani različiti skupovi oznaka. Za zadatke detekcije naglasak je stavljen na "okvire" koji se sastoje od samo četiri para brojeva, koji definiraju granični okvir objekta. Suprotno tome, za zadatke segmentacije, poligoni mogu sadržavati bilo koji broj "točaka" - u ovom slučaju, pozicije koje predstavljaju piksele koji se nalaze na rubu maske. Za dijagnostičke zadatke, oznake su zadržale sličnu strukturu, osim što su pojedinačnim klasama dodijeljeni jedinstveni brojevi radi jednostavnijeg razlikovanja tipova cisti. Sve oznake su pažljivo generirane korištenjem programskog jezika Python, uz korištenje

javno dostupne biblioteke OpenCV, osiguravajući tako preciznost i dosljednost u procesu stvaranja skupa podataka.

Nakon što su oznake stvorene, skup podataka je podijeljen nasumičnom raspodjelom u skupove za treniranje, testiranje i validaciju, s održavanjem uravnotežene distribucije u omjeru 60%, 20% i 20%. Nakon toga, za rješavanje gore navedenih zadataka korišten je YOLOv8 model. Ovaj model, dostupan putem Ultralytics programskog okvira, pruža robustnu platformu za treniranje vlastitih modela.

Inicijalni trening napravljen je s neaugmentiranim skupom podataka kako bi se dobili osnovni rezultati, nakon čega su uslijedile iterativne sesije treniranja koristeći različite tehnike augmentacija podataka kako bi se dobio najbolji model. Za treniranje vlastitog modela, potrebno je izvršiti još nekoliko koraka. Prvo, potrebno je kreirati prilagođenu YAML datoteku koja sadrži nazive klasa i putanje koje ukazuju na lokaciju trening, testnih i validacijskih podataka. Organizacija podataka je prikazana na slici 14 gdje svaka od mapa u .yaml datoteci sadrži dvije podmape: jedna sadrži slike, a druga odgovarajuće oznake. Primjeri .yaml datoteka za dijagnostički i ne-dijagnostički zadatak prikazani su na slikama 15 i 16.



Slika 14. Prikaz organizacije podataka.

```
1 train: ../data/train
2 val: ../data/val
3 test: ../data/test
4
5 # number of classes
6 nc: 1
7
8 # class names
9 names: [ 'cista' ]
```

Slika 15. Prikaz YAML datoteke za zadatak detekcije

```
1 train: ../data/train
2 val: ../data/val
3 test: ../data/test
4
5 # number of classes
6 nc: 5
7
8 # class names
9 names: [ 'radikalna cista',
10         'folikularna cista',
11         'ameloblastom',
12         'odontogena keratocista',
13         'rezidualna cista' ]
```

Slika 16. Prikaz YAML datoteke za dijagnostički zadatak

Nakon instalacije Ultralytics programskog okvira korištenje YOLOv8 modela postaje jednostavno (Slika 17).

```
1 pip install ultralytics
```

Slika 17. Prikaz instalacije programskog okvira YOLOv8 razvijenog od strane Ultralytics tima

Kako je prikazano na slici 18, potrebno je samo nekoliko redaka koda za pokretanje procesa treniranja. Dodatno, prilagođavanje parametara treninga moguće je putem konfiguracijske

datoteke čiji je manji, relevantni dio prikazan na slici 19. Ova konfiguracijska datoteka korištena je za provođenje treniranja modela s različitim kombinacijama augmentacijskih tehnika.

```
1 from ultralytics import YOLO
2
3 # Load the model.
4 model = YOLO('yolov8m-seg.pt')
5
6 # ARGS are arg=value pairs like that override default value
7 model.train(ARGS)
8 model.val(split='test')
```

Slika 18. Prikaz koda potrebnog za pokretanje procesa treniranja razvijenog modela.

```
# Hyperparameters -----
lr0: 0.01 # (float) initial learning rate (i.e. SGD=1E-2, Adam=1E-3)
lrf: 0.01 # (float) final learning rate (lr0 * lrf)
momentum: 0.937 # (float) SGD momentum/Adam beta1
weight_decay: 0.0005 # (float) optimizer weight decay 5e-4
warmup_epochs: 3.0 # (float) warmup epochs (fractions ok)
warmup_momentum: 0.8 # (float) warmup initial momentum
warmup_bias_lr: 0.1 # (float) warmup initial bias lr
box: 7.5 # (float) box loss gain
cls: 0.5 # (float) cls loss gain (scale with pixels)
dfl: 1.5 # (float) dfl loss gain
pose: 12.0 # (float) pose loss gain
kobj: 1.0 # (float) keypoint obj loss gain
label_smoothing: 0.0 # (float) label smoothing (fraction)
nbs: 64 # (int) nominal batch size
hsv_h: 0.015 # (float) image HSV-Hue augmentation (fraction)
hsv_s: 0.7 # (float) image HSV-Saturation augmentation (fraction)
hsv_v: 0.4 # (float) image HSV-Value augmentation (fraction)
degrees: 0.0 # (float) image rotation (+/- deg)
translate: 0.1 # (float) image translation (+/- fraction)
scale: 0.5 # (float) image scale (+/- gain)
shear: 0.0 # (float) image shear (+/- deg)
perspective: 0.0 # (float) image perspective (+/- fraction), range 0-0.001
flipud: 0.0 # (float) image flip up-down (probability)
fliplr: 0.5 # (float) image flip left-right (probability)
mosaic: 1.0 # (float) image mosaic (probability)
mixup: 0.0 # (float) image mixup (probability)
copy_paste: 0.0 # (float) segment copy-paste (probability)
auto_augment: randaugment # (str) auto augmentation policy for classification (randaugment, autoaugment, augmix)
erasing: 0.4 # (float) probability of random erasing during classification training (0-1)
crop_fraction: 1.0 # (float) image crop fraction for classification evaluation/inference (0-1)

# Custom config.yaml -----
cfg: # (str, optional) for overriding defaults.yaml
```

Slika 19. Prikaz konfiguracijske datoteke korištene za treniranje modela s različitim augmentacijskim tehnikama

Za treniranje odabrane su predtreniran varijante YOLOv8 - yolov8m i yolov8l, a metodama augmentacije su uključivale prevođenje, skaliranja, horizontalnog zrcaljenja, rotaciju i mozaik. Odluka o uključivanju ovih tehnika proizlazi iz njihove prirode koja je kompatibilna s postavljenim zadatkom. Zaključeno je da, osim tehnike mozaika, ove metode imaju smisla jer uvode manje promjene koje oponašaju varijacije koje se prirodno pojavljuju tijekom snimanja slika. Iako ove promjene mogu izgledati neznatne ljudskom oku, iz perspektive modela one se mogu tumačiti kao nove slike, što povećava njegovu sposobnost generalizacije. Mozaik je odabran zbog izvanrednih rezultata kojima je pridonijela u različitim zadacima računalnog vida (110).

Konfiguracijska datoteka učinkovito upravlja primjenom ovih metoda određivanjem vjerojatnosti za mozaik i horizontalno zrcaljenje te određivanjem raspona za translaciju, skaliranje i rotaciju. Proširenje podataka primijenjeno je u svakoj epohi tijekom obuke, osiguravajući da model uči iz raznolikog i obogaćenog skupa podataka.

Između ostalih hiperparametara, broj epoha postavljen je na 100, dok je veličina grupe postavljena na 4, što je bila maksimalna moguća veličina s obzirom na memorijske mogućnosti računala, grafičke kartice i prirodu visoke rezolucije slika korištenih prilikom treniranja (2776 x 1480). Kao algoritam optimizacije odabran je stohastički gradijentni spust, a eksperimenti su izvršeni na NVIDIA RTX A6000 grafičkoj kartici, što je omogućilo bržu obradu. Također, svi treninzi su bili determinističke prirode kako bi se osigurala dosljedna usporedba evaluacija provedenih na testnom skupu.

3. 3. METRIČKA ANALIZA

Kako bi se ispitala segmentacijska, detekcijska i dijagnostička točnost napravljenog modela UI, korištene su metričke analize preciznost, osjetljivost i srednja prosječna preciznost.

Matematički, preciznost se može definirati kao omjer između točno pozitivnih predikcija (TP) i zbroja točno pozitivnih i lažno pozitivnih predikcija (TP + FP), gdje su:

TP (eng. *True Positives*): Broj primjera koji su ispravno klasificirani kao pozitivni.

FP (eng. *False Positives*): Broj primjera koji su pogrešno klasificirani kao pozitivni.

Matematička formula glasi:

$$P = \frac{TP}{TP + FP}$$

Visoka preciznost ukazuje na to da je model učinkovito izbjegao lažno pozitivne greške, što znači da kada model nešto klasificira kao pozitivno, postoji velika vjerojatnost da je to točno. Međutim, preciznost ne uzima u obzir sve stvarno pozitivne primjere (uključujući one koje model nije uspio identificirati), što može biti ograničenje. Zbog toga smo koristili i metriku srednja prosječna preciznost i osjetljivost, kako bi se dobila sveobuhvatnija slika o performansama modela.

Osjetljivost pokazuje koliki dio stvarnih pozitivnih primjera je model uspješno prepoznao kao pozitivne. Matematički, osjetljivost se definira kao omjer između točno pozitivnih predikcija (TP) i zbroja točno pozitivnih i lažno negativnih predikcija (TP + FN), gdje su:

TP (eng. True Positives): Broj primjera koji su ispravno klasificirani kao pozitivni.

FN (eng. False Negatives): Broj primjera koji su pogrešno klasificirani kao negativni, iako su zapravo pozitivni.

Formula za izračunavanje osjetljivosti je:

$$R = \frac{TP}{TP + FN}$$

Visoka osjetljivost ukazuje na to da model dobro prepoznaje stvarno pozitivne primjere. Također, da bi pokazali uspješnost modela korištena je srednja prosječna preciznost (mAP prema eng. *Mean average precision*) i prosječna preciznost (AP prema engl. *average precision*).

mAP uzima u obzir kako preciznost tako i osjetljivost modela, pružajući sveobuhvatan uvid u kvalitetu i točnost modela uzimajući u obzir cijeli skup predikcija.

Matematička formula glasi:

$$mAP = \frac{1}{C} \sum_{n=1}^c AP$$

gdje je C broj klasa ili upita, a AP prosječna preciznost za klasu ili upit. U kontekstu detekcije objekata, mAP se može izračunati na različitim pragovima križanja preko presjeka (IoU). IoU je mjera preklapanja između predviđenog okvira ograničenja i stvarnog okvira ograničenja. Na primjer, $mAP@50$ odnosi se na mAP izračunat na IoU pragu od 50.

Također, s obzirom na nesrazmjer podataka u istraživanju, gdje imamo više lezija jednog tipa, korištena je Preciznost-Osjetljivost krivulja (PR krivulja).

Podaci su prikupljeni i pohranjeni u bazi podataka u programu MS Excel.

4. REZULTATI

4.1. DETEKCIJA LEZIJA DONJE ČELJUSTI


Razumijevanje performansi modela u zadatku detekcije zahtijeva usporedbu okvira koje je model predvidio s okvirima označenim na referentnim slikama. U Tablici 3 sažeti su rezultati metrika evaluacije za detekciju lezija donje čeljustio. Primijećena su značajna poboljšanja u performansama kada se koristi augmentirani skup podataka u odnosu na osnovni skup. Preciznost (P), osjetljivost (R) te srednja prosječna preciznost (mAP) bilježe konzistentna poboljšanja pri različitim pragovima preklapanja Intersection over Union (IoU) kao što su: mAP50, mAP75, i mAP50-95. Ovi rezultati pružaju dublji uvid u sposobnost modela u detekciji lezija donje čeljusti te potvrđuju korist odabira augmentiranog skupa podataka za poboljšanje kvalitete detekcije.

Tablica 3. Usporedba metričke analize detekcije modela kod augmentiranih i ne-augmentiranih podataka.

	P	R	mAP@50	mAP@75	mAP@50-95
bez augmentacije	0.918	0.571	0.732	0.489	0.462
s augmentacijom	0.925	0.81	0.952	0.830	0.731

*P-preciznost, R-osjetljivost, mAP-srednja prosječna vrijednost


Na slici 20 prikazana je krivulja preciznosti i osjetljivosti augmentiranih i ne-augmentiranih podataka




Slika 20. PR krivulja augmentiranih (plavo) i neaugmentiranih (crveno) podataka gdje je na y-osi preciznost, a na x-osi osjetljivost

Visoka preciznost sugerira da veći postotak detekcija koje je algoritam izvršio zaista odgovara stvarnim cistama mandibule. U kontekstu otkrivanja lezija, visoka preciznost znači da kada algoritam identificira leziju unutar ortopantomograma, izuzetno je vjerojatno da će to biti stvarna pozitivna lezija, a ne lažno pozitivna. Visoka osjetljivost ukazuje na to da algoritam uspješno detektira veliki broj stvarnih lezija donje čeljusti prisutnih u ortopantomogramima.


Slike 21 i 24 prikazuju primjer ulazne ortopantomografske snimke dok slike 22 i 25 prikazuju ručno označene lezije donje čeljusti u GIMP programu Nasuprot tome, Slike 23 i 26 ilustriraju rezultate detekcije koje je generirao model UI za iste primjere.




Slika 21. Ortopantomogramska snimka s lezijom u prednjem dijelu donje čeljusti




Slika 22. Prikaz ortopantomogramska snimke s označenom lezijom u GIMP programu od strane radiologa i maksilofacijalnog kirurga




Slika 23. Prikaz uspješnosti razvijenog modela u detekcije cistične lezije frontalnog dijela donje čeljusti



Slika 24. Ortopantomogramska snimka čeljusti s lezijom u uzlaznom kraku donje čeljusti



Slika 25. Ortopantomogramska snimka s lezijom označenom u GIMP programu



Slika 26. Prikaz uspješnosti razvijenog modela u detekciji ciste u uzlaznom kraku donje čeljusti

Usporedbom rezultata detekcije modela s referentnim slikama postaje očito da je izvedba modela dobar odraz metrika.

4.2. SEGMENTACIJA LEZIJA DONJE ČELJUSTI


Razvijanje prethodnog modela za segmentaciju ključni je korak u unapređenju njegovih performansi. Učinkovitost modela procijenjena je uspoređujući segmentirane regije s ulaznim podacima označenim u GIMP-u. To je osiguralo dosljednost u metodama evaluacije u svim zadacima i omogućilo glatku tranziciju s detekcije na segmentaciju. Konkretno, uporaba proširenog skupa podataka nastavila je donositi značajna poboljšanja u usporedbi s neproširenim skupom podataka kako je prikazano u Tablici 4. Osjetljivost modela s augmentacijom je 94.5%, dok je preciznost 100%.

Tablica 4. Metrička analiza uspješnosti modela u zadatku segmentacije kod augmentiranih i ne-augmentiranih podataka

	P	R	mAP@50	mAP@75	mAP@50-95
bez augmentacije	0.726	0.757	0.726	0.483	0.478
s augmentacijom	1	0.945	0.967	0.762	0.725


U segmentaciji, postizanje visoke preciznosti znači da algoritam precizno definira granice mandibularnih cista uz minimalno obuhvaćanje područja bez lezija. Postizanje visoke osjetljivosti u segmentaciji ukazuje na to da algoritam učinkovito identificira većinu lezija donje čeljusti unutar ortopantomograma.

Slika 27. prikazuje PR krivulju za segmentaciju razvijenog modela UI.




Slika 27. Prikaz PR krivulje segmentacijskog dijela modela UI


Testiranje uspješnosti modela tijekom segmentacijskog postupka i njegova usporedba s ulaznim snimkama označenim na GIMP-u prikazano je na slikama 28, 29,30,31, 32 i 33.



Slika 28. Prikaz ortopantomogramske snimke donje čeljusti s lezijom na tijelu i dijelu kraka donje čeljusti lijevo




Slika 29. Prikaz lezije donje čeljusti označene od strane radiologa i maksilofacijalnog kirurga u GIMP programu




Slika 30. Prikaz uspješnosti segmentacije lezije donje čeljusti razvijenog modela UI.



Slika 31. Prikaz ortopantomogramske snimke čeljusti s lezijom u prednjem dijelu donje čeljusti



Slika 32. Prikaz lezije donje čeljusti označene crvenom bojom u GIMP programu



Slika 33. Prikaz uspješnosti modela u segmentacijskog zadatku označavanja lezije donje čeljusti.

4.3. DIJAGNOSTICIRANJE LEZIJA DONJE ČELJUSTI POMOĆU RAZVIJENOG MODELA UI

Tablica 5 pruža sveobuhvatan pregled učinkovitosti zadataka otkrivanja i dijagnostike, prikazujući dva seta rezultata za neaugmentirane i augmentirane podatke. Ona ilustrira kombinirane rezultate, ističući sposobnosti modela u otkrivanju i dijagnosticiranju cista.

Tablica 5. Kombinirani rezultati dijagnostike i detekcije lezija donje čeljusti s i bez augmentacije

	P	R	mAP@50	mAP@75	mAP@50-95
bez augmentacije	0.168	0.72	0.504	0.286	0.324
s augmentacijom	0.556	0.798	0.731	0.639	0.606

Na isti način Tablica 6 prikazuje rezultate segmentacije i dijagnostike, također s dva seta rezultata. Ova tablica pruža uvid u sposobnost modela da precizno segmentira lezije i kategorizira ih prema vrsti lezije.

Tablica 6. Kombiniranih rezultati dijagnostike i segmentacije lezija donje čeljusti s i bez augmentacije

	P	R	mAP@50	mAP@75	mAP@50-95
bez augmentacije	0.159	0.68	0.476	0.283	0.306
s augmentacijom	0.64	0.662	0.749	0.676	0.602

Tablice 7 i 8 pružaju detaljan pregled detekcije i segmentacije kombinirane s dijagnostičkom učinkovitosti razvijenog modela za svaki tip lezije s ne-augmentiranim skupom podataka. S druge strane, tablice 9 i 10 pružaju uvid u preformanse modela s augmentiranim skupom podataka za svaku od promatranih lezija.

Tablica 7. Metrički podatci za učinkovitost modela detekcije i dijagnostike na ne-augmentiranim slikama

	P	R	mAP@50	mAP@50-95
radikularna cista	0.3	1	0.854	0.597
ameloblastom	0.143	1	0.695	0.406
odontogena keratocista	0.13	0.6	0.251	0.104
folikularna cista	0.267	1	0.717	0.515
rezidualna cista	0.13	0.6	0.251	0.104

Tablica 8. Prikaz podataka za učinkovitost segmentacije i dijagnostike pojedinih lezija na ne-augmentiranim slikama

	P	R	mAP@50	mAP@50-95
radikularna cista	0.3	1	0.854	0.603
ameloblastom	0.143	1	0.695	0.29
odontogena keratocista	0.087	0.4	0.114	0.0804
folikularna cista	0.267	1	0.717	0.556
rezidualna cista	0	0	0	0

Tablica 9. Metrički podatci učinkovitosti modela tijekom detekcije i dijagnosticiranja lezija u augmentiranom skupu podataka


	P	R	mAP@50	mAP@50-95
radikularna cista	0.778	0.889	0.846	0.648
ameloblastom	0.329	1	0.995	0.946
odontogena keratocista	0.311	0.6	0.313	0.179
folikularna cista	0.549	0.5	0.508	0.359
rezidualna cista	0.814	1	0.995	0.895

Tablica 10. Metrički podatci učinkovitosti modela tijekom segmentacije i dijagnosticiranja lezija u augmentiranom skupu podataka


	P	R	mAP@50	mAP@50-95
radikularna cista	0.74	0.778	0.893	0.706
ameloblastom	0.824	0.5	0.586	0.489
odontogena keratocista	0.402	0.282	0.403	0.26
folikularna cista	0.782	0.75	0.87	0.66
rezidualna cista	0.455	1	0.995	0.895

4.3.1. DIJAGNOSTICIRANJE RADIKULARNE CISTE


Konačni rezultat razvoja modela UI i njegovo primjena prilikom detekcije, segmentacije i dijagnosticiranja radikularne ciste na slučajno odabranom ortopantomogramu s radikularnom cistom prikazan je na slijedećem nizu slika.




Slika 34. Prikaz slučajno odabrane testne slike s radikularnom cistom donje čeljusti



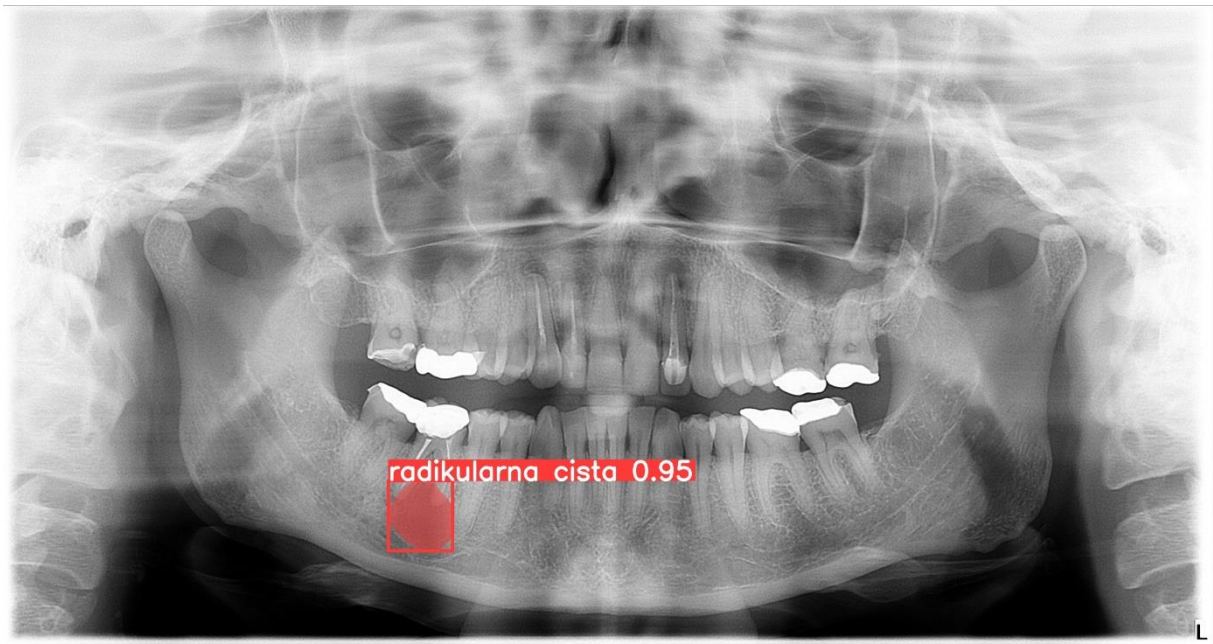
Slika 35. Prikaz detekcije radikularne ciste sa sigurnošću modela od 93%



Slika 36. Prikaz detekcije i dijagnosticiranja radikularne ciste razvijenim modelom




Slika 37. Prikaz segmentacije radikularne ciste razvijenim modelom




Slika 38. Prikaz uspješnosti modela u segmentaciji i dijagnosticiranju radikularne ciste donje čeljusti

4.3.2. DIJAGNOSTICIRANJE FOLIKULARNE CISTE


Testiranje modela UI prilikom detekcije, segmentacije i dijagnosticiranja folikularne ciste prikazan je na slijedećem nizu slika.




Slika 39. Prikaz ortopantomograma s folikularnom cistom na donjoj čeljusti lijevo




Slika 40. Prikaz uspješnosti modela tijekom detekcije folikularne ciste



Slika 41. Prikaz detekcije i dijagnostike folikularne ciste razvijenog modela UI




Slika 42. Prikaz uspješnosti modela od 94% tijekom segmentacije folikularne ciste




Slika 43. Prikaz uspješnosti modela sa sigurnošću od 98% tijekom segmentacije i dijagnosticiranja folikularne ciste

4.3.3. DIJAGNOSTICIRANJE ODONTOGENE KERATOCISTE

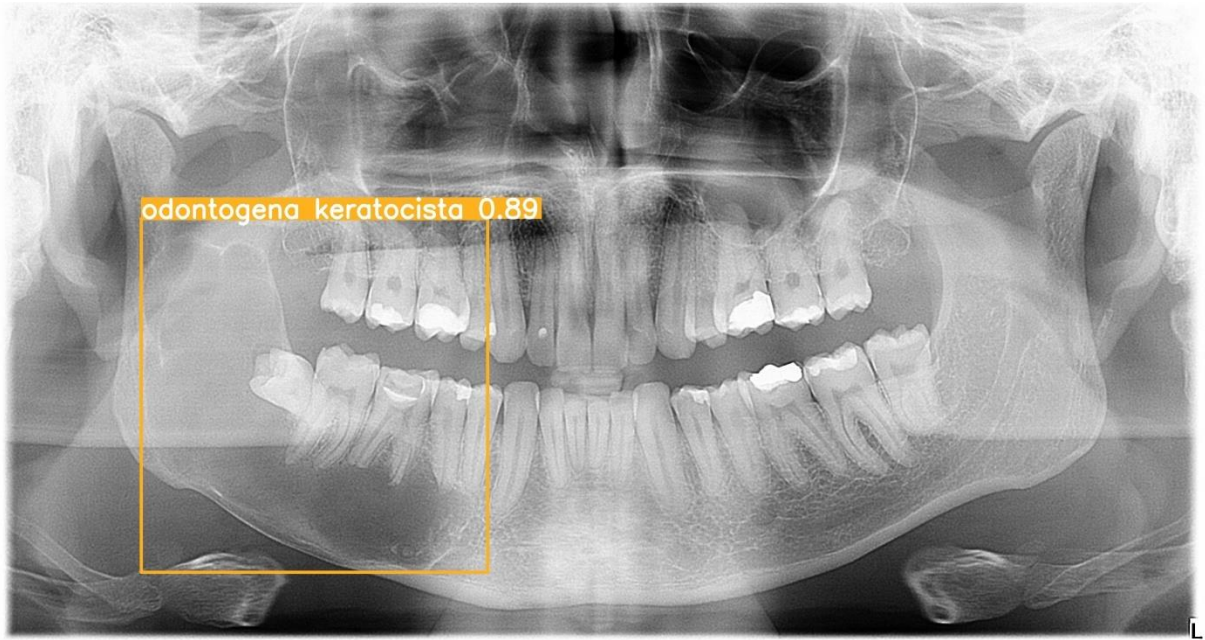
Na sljedećem nizu slika prikazana je uspješnost razvijenog modela UI tijekom detekcije, segmentacije i dijagnosticiranja odontogene keratociste.




Slika 44. Prikaz ortopantomogramam odontogene keratociste donje čeljusti




Slika 45. Prikaz uspješnog detektiranja odontogene keratociste od 87%



Slika 46. Prikaz primjene modela u detekciji i dijagnostici odontogene keratociste donje čeljusti.




Slika 47. Prikaz segmentacije odontogene keratociste razvijenim modelom




Slika 48. Prikaz segmentacije i uspješnog dijagnosticiranja odontogene keratociste razvijenim modelom UI.

4.3.4. DIJAGNOSTICIRANJE AMELOBLASTOMA


Prikaz uspješnosti razvijenog modela u detekciji, segmentaciji i dijagnosticiranju ameloblastoma, kao jedine lezije u promatranom istraživanju koja nije cista, nalazi se u sljedećem nizu slika.



Slika 49. Prikaz ortopantomograma čeljusti s ameloblastomom




Slika 50. Prikaz uspješnosti modela u detekciji i dijagnosticiranju ameloblastoma




Slika 51. Prikaz uspješnosti modela u segmentaciji i dijagnosticiranju ameloblastoma od 98%.

4.3.5. DIJAGNOSTICIRANJE REZIDUALNE CISTE


Uspješnost testiranja razvijenog modela tijekom detekcije, segmenacije i dijagnostike rezidualnih cisti je prikazan sljedećim slikama.



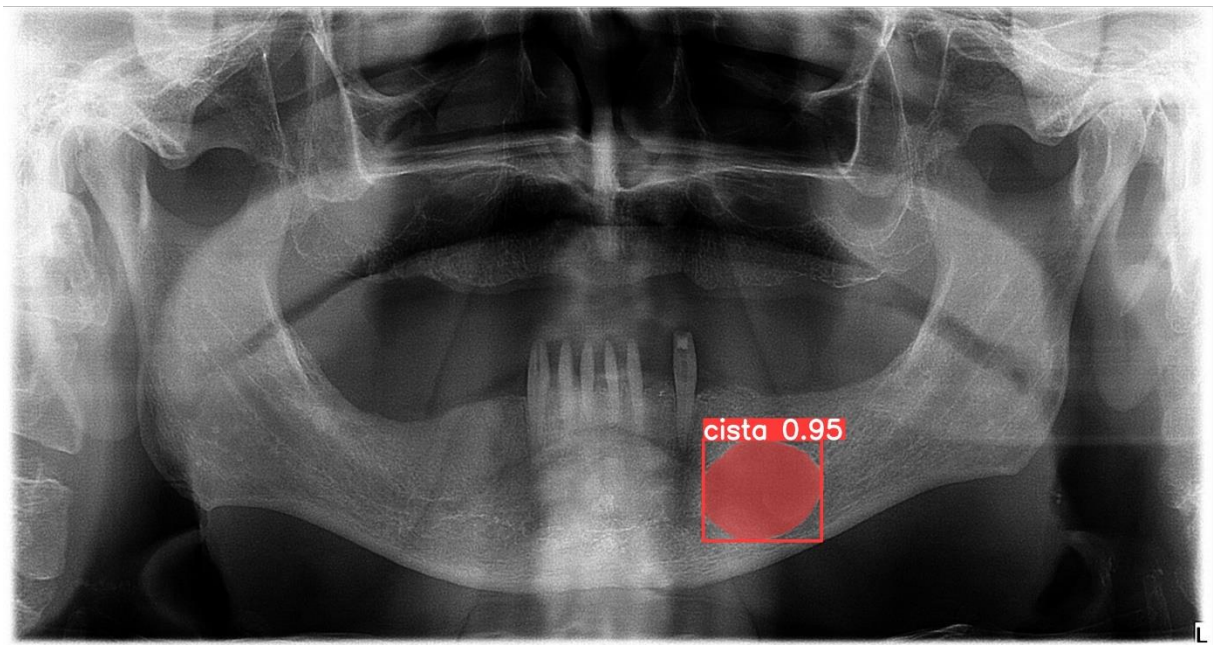
Slika 52. Prikaz ortopantomogramske snimke donje čeljusti s rezidualnom cistom




Slika 53. Prikaz uspješne detekcije rezidualne ciste razvijenim modelom



Slika 54. Prikaz detekcije i dijagnosticiranja rezidualne ciste modelom UI




Slika 55. Prikaz uspješnosti modela od 95% u segmentaciji rezidualne ciste



Slika 56. Prikaz točnog segmentiranja i dijagnosticiranja rezidualne ciste razvijenim modelom.


4.5. VIZUALIZACIJA AKTIVACIJA I TOPLINSKIH MAPA

Prediktivne sposobnosti modela proizlaze iz kompleksne dinamike njegove neuronske arhitekture, koja detaljno analizira slike kako bi prepoznala obrasce i značajke koje upućuju na lezije donje čeljusti. Dublje istraživanje specifičnih slojeva neuronske mreže i vizualizacija unutarnjih aktivacija, omogućuje nam bolji uvid u proces donošenja odluka modela i samim time buduće sprječavanje pogrešnog dijagnosticiranja, što se dogodilo tijekom testiranja na leziji gdje je prethodno izvađen zub (Slika 57).




Slika 57. Prikaz ortopantomogramske snimke na kojoj razvijeni model nije prepoznao leziju na mjestu izvađenog zuba.

Slika 58 prikazuje upotrebu tehnike EigenCAM (prema eng. *Eigen-Class Activation Mapping*) koja omogućuje generiranje toplinskih mapa i pruža vizualni prikaz područja koja model smatra najznačajnijima za predviđanje. Koncentracija intenziteta toplinske karte oko područja donje čeljusti potvrđuje prijašnju tvrdnju i ističe sposobnost modela da uoči značajke relevantne za otkrivanje cista mandibule.



Slika 58. Prikaz upotrebe EigenCAM zbog boljeg razumijevanja rada modela, Vidljiva je pojačana toplinska zona u području donje čeljusti.

Uz zajednički doprinos vizualizacija aktivacija u određenim slojevima i generiranih toplinskih karata, dobivamo djelomično razumijevanje procesa donošenja odluka u razvijenom modelu (Slika 59).



Slika 59. Prikaz vizualizacije aktivacija u području lezija donje čeljusti.

Važno je napomenuti kako je konačni prediktivni model u početnoj fazi razvoja i zahtjeva daljnje postupke da bi se primijenio u kliničkoj praksi.

5. RASPRAVA

Radiolucetne lezije donje čeljusti, zbog svoje različite morfologije i mogućih komplikacija, predstavljaju složene izazove u kliničkoj dijagnozi i liječenju. Posljedično, razvoj automatiziranih alata za precizno otkrivanje, točnu segmentaciju i pouzdanu dijagnostičku klasifikaciju, ima velik potencijal u unaprijeđenju njege pacijenata i ishoda liječenja u području oralne radiologije i maksilofacijalne kirurgije.

Primarni cilj ovog istraživanja bio je riješiti ograničenja postojećih metodologija za analizu lezija donje čeljusti kroz primjenu suvremenih tehnika dubokoga učenja i obrade slike te razvitak sveobuhvatnog računalnog okvira sposobnog za ispunjenje sljedećih ključnih ciljeva: detekcije, segmentacije i njihovu kombinaciju s dijagnostičkom klasifikacijom. Uspješnost modela pri svim zadacima mjeri se u skladu s prethodno opisanim metodama evaluacije, pri čemu se izvedba modela vrednuje kroz usporedbu njegove točnosti na testnom setu s prethodno označenim slikama u GIMP programu.

Prema dostupnoj literaturi, nema nijedan model UI-a koji objedinjuje sve tri navedene stavke.

UI je našla primjene u različitim područjima među kojima je medicina i stomatologija. Još je 1970. godine razvijen MYCIN sustav dijagnosticiranja bakterijskih infekcija koji je bio značajan zbog svoje sposobnosti formuliranja zaključaka na temelju neizvjesnih ili nepotpunih informacija, koristeći pravila temeljena na znanju stručnjaka iz područja medicine. MYCIN je funkcionirao na temelju upitnika koji je liječnik ispunio o pacijentu i 600 pravila kojima bi diferencijalno dijagnosticirao različite bakterijske infekcije i preporučio antibiotik (111,112). Koristeći platformu MYCIN, Henry Pople je razvio algoritam za medicinsku dijagnostiku INTERNIST-1, a kasnije ga nadogradio u CADUCEUS ekspertni sustav. CADUCEUS se temeljio na znanju američkog molekularnog biologa John Edgar Myersa i mogao je dijagnosticirati više od tisuću različitih bolesti (113,114). Dxpain razvijen na Sveučilištu u Massachusettsu je omogućavao studentima i liječnicima uvid u listu diferencijalnih dijagnoza više od pet tisuća različitih bolesti na temelju kompleksnih simptoma (115).

Esteva i sur. su trenirali neuronsku mrežu u prepoznavanju i razlikovanju melanoma od drugih kožnih lezija. Koristili su bazu podataka od preko 120 tisuća lezija te postigli mogućnost

razlikovanja u razini s iskusnim dermatolozima (116).

Gargeya i sur. su razvili impresivan algoritam prepoznavanja dijabetičke retinopatije, koja je jedan od glavnih uzorka sljepoće na svijetu. Njihov algoritam je postigao senzitivnost i specifičnost od 94 odnosno 98 posto (117).

Od iznimne je važnosti istaknuti algoritam koji su razvili Kim i sur. s Yonsei Sveučilišta u Južnoj Koreji. Oni su na temelju duboke neuronske mreže i baze podataka, koja se sastojala od preko 2000 ispitanika, razvili algoritam probira infarkta miokarda. Model im je pokazao impresivne metričke rezultate uključujući preciznost, opoziv i F1-rezultat od 99.38 posto (118). Nadalje, UI je korištena i u dijagnosticiranju Alzheimerove bolesti analizirajući amiloidne slikovne baze podataka i s velikom preciznošću detektirala odgovor na terapiju (119,120).

U navedenim istraživanjima prisutne su velike količine ulaznih podataka koje su se koristile za razvijanje modela UI, što je ujedno i jedan od potencijalnih problema na koji smo naišli.

Naime, većina zemalja zapadnog svijeta izrađuje baze podataka i zapošljava ljude u zdravstvenim ustanovama i sveučilištima koji se isključivo bave unosom podataka. Zbog toga i broja stanovnika, u mogućnosti su imati desetke tisuća ulaznih podataka na kojima će razvijati algoritme pomoću neuronskih mreža.

Zanimljivo je kako je tek uz napredak tehnika strojnog učenja i računalnog vida došlo do ekspanzije i sveobuhvatne primjene UI u stomatologiji i maksilofacijalnoj kirurgiji (121).

Chattopadhyay i sur. razvili su algoritam računalnog vida koji može prepoznati poremećaj okluzije gornje i donje čeljusti s preciznošću od 81%, dok su Xi i sur. upotrijebili automatsku segmentaciju za određivanje volumena i gustoće kosti (122,123).

Xiong i sur. u svojoj pilot studiji napravili su model duboke neuronske mreže za detekciju karijesa na temelju intraoralne snimke. Uspješnost modela testirali su u usporedbi sa doktorom dentalne medicine koji ima godinu dan iskustva rada u struci. Razvijeni model dijagnosticirao je karijes u većem postotku u odnosu na kliničara (124).

Ma i sur. na temelju konvulcijske neuronske mreže uspješno su razvili algoritam detekcije upale zubne pulpe. Uzorak se sastojao od 348 intraoralnih periapikalnih snimki te je preciznost algoritma bila 85% (125).

Dijagnostika i liječenje periapikalnih lezija može predstavljati problem za kliničara (126).

Karakteristike periapikalnih radiolucencija i resorpcije alveolarne kosti omogućuju razvijanje različitih algoritama UI. Endras i sur. su razvili model za dijagnosticiranje periapikalne lezije i testirali ga u odnosu na maksilofacijalne kirurge. Model je pokazao bolje rezultate u dijagnostici u odnosu na 14 od 24 maksilofacijalna kirurga koja su sudjelovala u istraživanju (127).

Ryong Ha i sur. su pokušali pomoću strojnog učenja raspoznati faktore koji utječu na prognozu osteintegracije i uspješnosti postavljanja zubnog implantata. Istraživanje je provedeno u Sveučilišnoj bolnici u Seuli i pokazalo da implantat postavljen mezio-distalno ima najveći utjecaj na konačnu uspješnost zubne rehabilitacije (128). Nadalje, u forenzičkoj stomatologiji sve je veća upotreba duboke neuronske mreže u analizi ugriznih tragova te procjene dobi i spola na temelju trajne denticije (129).

U svjetlu široke primjene UI unutar patologije oralne i maksilofacijalne sfere, ističe se imperativ za iniciranje istraživačkih projekata usmjerenih na integraciju ovakvih tehnoloških rješenja u koherentni sustav podrške donošenju kliničkih odluka.

U ovom istraživanju model za dijagnosticiranje i segmentiranje lezija donje čeljusti razvijen je koristeći najnapredniju verziju YOLOv8. Kao što je navedeno, prema dostupnoj literaturi, yolov8 nije korišten u navedene svrhe. Kwon i sur. u svom istraživanju su koristili YOLOv3 te koristili skup podataka od 1282 radiolucente lezije. Preciznost razvijenog modela u detekciji radiolucenih lezija donje čeljusti je 87%, dok je osjetljivost 83% (130). Unatoč tome što su imali puno veći skup podataka, metrički podatci o detekciji manji su nego u našem istraživanju.

Preciznost u zadatku detekcije radiolucenih lezija donje čeljusti našeg modela je 92.5%, dok je mAP50 95.2%, a osjetljivost 81%. (tablica 3) . Visoka preciznost sugerira da veći postotak detekcija koje je algoritam izvršio zaista odgovara stvarnim lezijama donje čeljusti.

U kontekstu otkrivanja lezija, visoka preciznost znači da kada algoritam identificira leziju unutar ortopantomograma, izuzetno je vjerojatno da će to biti stvarna pozitivna lezija, a ne lažno pozitivna (pogrešno identificirana regija). Drugim riječima, algoritam pokazuje nisku stopu lažno pozitivnih rezultata, što je ključno za osiguranje točne i pouzdane detekcije lezija donje čeljusti. Ova visoka preciznost pruža osjećaj povjerenja u sposobnost algoritma da pouzdano

razlikuje stvarne lezije od drugih struktura ili artefakata na snimci.

Visoka osjetljivost ukazuje na to da algoritam uspješno detektira veliki broj stvarnih lezija donje čeljusti prisutnih u ortopantomogramima. To znači da algoritam ima nisku stopu lažno negativnih rezultata gdje stvarne lezije nisu prepoznate ili nisu otkrivene. U kontekstu detekcije lezija, visoka osjetljivost implicira da algoritam učinkovito prepoznaje većinu lezija unutar snimki, smanjuje rizik od propuštanja klinički značajnih nalaza i osigurava sveobuhvatnu pokrivenost potencijalnih abnormalnosti. Ova sposobnost razvijenog modela pruža pouzdanost u identifikaciji lezija donje čeljusti i osigurava da se što manje stvarnih abnormalnosti propusti.

U kontekstu detekcije lezija donje čeljusti, visoka prosječna preciznost ukazuje na to da model, ne samo da održava visoku preciznost i osjetljivost općenito, već također održava te razine performansi na različitim razinama pouzdanosti. Time se osigurava robusna i pouzdana izvedba u cijelom spektru detekcija.

U još jednom istraživanju, Ariji i sur. su koristili Detect-Net duboku neuronsku mrežu u pokušaju razvoja modela UI za detekciju lezija čeljusti. Imali su sličan skup podataka kao i mi u svom istraživanju. Koristili su 210 ortopantomogramskih snimki i razvili algoritam s preciznošću od 88%. (131). U našem istraživanju preciznost detekcije bez augmentacije je 91.8% (tablica 3) (slika 20).

S obzirom da smo u ovom istraživanju imali relativno malu količinu podataka od 226 radiolucentnih lezija čeljusti, bitno je napomenuti da su rezultati detekcije i segmentacije mjereni metričkim metodama u rangu ranije prikazanih radova s mnogo većom bazom podataka.

Algoritam modela detekcije precizno identificira lezije donje čeljusti unutar ortopantomogramskih snimki. Ova faza detekcije djeluje kao ključni prvi korak prije segmentacije i dijagnostičke klasifikacije te pruža početnu točku za precizno ocrtavanje granica radiolucentnih i njihovo kategoriziranje u odgovarajuće kliničke tipove.

Segmentacija u medicinskoj dijagnostici, posebno s fokusom na primjenu dubokih neuronskih

mreža, predstavlja revolucionaran pristup obradi i analizi radioloških snimaka. Ova tehnologija omogućava detaljno razdvajanje različitih struktura unutar snimke, što je od vitalnog značaja u identificiranju, kvantificiranju i praćenju patoloških promjena. U kontekstu dijagnostike, precizna segmentacija, ne samo da omogućuje bolje razumijevanje obima i prirode bolesti, već i igra ključnu ulogu u planiranju terapije i praćenju njenog učinka. Segmentacija lezija omogućava detaljnu analizu karakteristika tumora, kao što su njihova veličina, oblik i tekstura. Ove informacije su ključne za razumijevanje prirode tumora, uključujući njegovu agresivnost i potencijalno širenje. Time se omogućava personalizirani pristup liječenju gdje se terapije mogu prilagoditi specifičnim karakteristikama bolesti kod svakog pojedinca. Osim toga, segmentacija pomaže u praćenju promjena tumora tijekom vremena što je ključno za evaluaciju učinkovitosti terapije. Promjene u veličini i obliku tumora mogu se precizno kvantificirati što pruža objektivne pokazatelje o tome kako pacijent reagira na određeni tretman. To može pomoći liječnicima da brzo prilagode terapijske strategije u skladu s odgovorom pacijenta (132-135).

U razvoju modela UI koji ima široku primjenu u kliničkoj praksi, segmentacija je bila prirodan korak naprijed od zadatka detekcije. Razvijeni model pokazao je iznimne performanse u kompleksnom zadatku segmentacije gdje su preciznost, osjetljivost i mAP@50 bili 72.6%, 75.7% i 72.6% u ne-augmentiranom skupu podataka. Korištenjem suvremenih metoda augmentacije ulaznih podataka, preciznost, osjetljivost i mAP@50 modela narasli su na 100%, 94.5% i 96.7%.

U zadatku segmentacije, postizanje visoke preciznosti znači da algoritam precizno definira granice lezija donje čeljusti uz minimalno obuhvaćanje područja bez lezija. Ovo ukazuje na to da su segmentirana područja uglavnom sastavljena od stvarno pozitivnih područja lezije što rezultira preciznim i točnim rezultatima segmentacije. Visoka preciznost osigurava da se segmentirana područja tijesno podudaraju s stvarnim granicama radiolucentnih lezija.

Postizanje visoke osjetljivosti u segmentaciji ukazuje na to da algoritam učinkovito identificira većinu područja lezije unutar ortopantomograma. To znači da algoritam ima nisku stopu podsegmentacije, gdje su stvarna područja lezije ili propuštena ili netočno segmentirana. Visoka osjetljivost osigurava sveobuhvatnu pokrivenost lezija donje čeljusti unutar snimki, smanjujući vjerojatnost propuštanja klinički značajnih područja i pružajući potpun prikaz morfologije i

distribucije lezija.

Visoka srednja prosječna preciznost u segmentaciji ukazuje na dosljednu točnost algoritma u ocrtavanju područja lezije preko različitih pragova segmentacije. Time se osigurava pouzdana izvedba usklađivanjem segmentiranih područja s referentnim oznakama te se minimiziraju nedosljednosti.

Vizualni prikaz uspješnosti modela u zadatku segmentacije je prikazan na slikama 30 i 33. Ove slike ističu rezultate segmentacije koje generira model, što jasno pokazuje njegovu sposobnost preciznog ocrtavanja područja lezije donje čeljusti. Nakon usporedbe segmentiranih područja modela s odgovarajućim područjima na označenim snimkama u programu GIMP, primjetna je značajna konzistentnost između ta dva skupa podataka.

Kauke i sur. su u svom istraživanju, koristeći softver otvorenog tipa, pokušali segmentirati odontogene lezije donje čeljusti i odrediti volumen istih. Uzorak im se sastojao od 150 pacijenata s lezijama što gornje, što donje čeljusti. Uspješnost programa u zadatku segmentacije su uspoređivali s ručnim mjerenjem promjera lezija čeljusti. Softver je statistički značajnije određivao volumen pojedine lezije u odnosu na čovjeka (136).

Značajno je i spomenuti istraživanje koje su proveli Safi i sur. u vidu utjecaja segmentacije na klinički rad oralnih i maksilofacijalnih kirurga. Istraživali su volumen ameloblastoma kao potencijalni biomarker agresivnosti. Istraživanje su proveli u na Sveučilištu u Cologni gdje su koristili polu-automatsko segmentiranje koje se sastoji od ručnog segmentiranja dijelova ameloblastoma nakon što program segmentira dio lezije. Zaključili su da lezija veća od 20cm^3 pokazuje lokalno agresivne karakteristike. Međutim, ovo istraživanje je bazirano samo na 40 lezija čeljusti te zahtijeva velik utrošak vremena radiologa koji mora ručno segmentirati svaku leziju nakon softvera (137).

Usporedba softverskog mjerenja volumena cističnih lezija donje čeljusti i ručnog mjerenja putem matematičkih formula, predmet je istraživanja El-Beblawija i sur. Oni su, koristeći InVesalius kompjutersku asistenciju putem segmentacije lezija, određivali volumen na in vitro donjim čeljustima (138).

Model UI razvijem u našem istraživanju otklanja potrebu za ručnim segmentiranjem lezija te pruža visoke performanse koje mogu dovesti do značajnog utjecaja na rad kliničara i odluku o načinu liječenja pojedine lezije.

Evaluacija razvijenog modela za dijagnosticiranje cista donje čeljusti igra presudnu ulogu u usavršavanju medicinskih postupaka i pružanju najvišeg kvaliteta zdravstvene zaštite. U kontekstu kliničke prakse, takva evaluacija, ne samo da potvrđuje pouzdanost i točnost modela u identifikaciji patoloških promjena, već i postavlja temelje za njegovu primjenu u realnim dijagnostičkim scenarijima. Proširenjem rasprave na temu segmentacije i detekcije, naglasak se stavlja na važnost kategorizacije identificiranih regija lezija, što dodatno produbljuje dijagnostičku analizu i omogućava preciznije planiranje terapije.

Cilj dijagnostičkog zadatka, stoga, prelazi granice same detekcije, teži prema kategorizaciji lezija u klinički relevantne tipove. Takva kategorizacija omogućuje razlikovanje između različitih vrsta lezija donje čeljusti, što je ključno za razumijevanje etiologije, potencijalnih rizika i odabira najprikladnijeg terapijskog pristupa.

Tablica 5 pruža sveobuhvatan pregled učinkovitosti zadataka otkrivanja i dijagnostike, prikazujući dva seta rezultata za ne-augmentirane i augmentirane podatke. Ona ilustrira kombinirane rezultate, ističući sposobnosti modela u otkrivanju i dijagnosticiranju lezija. Primjena augmentiranog skupa podataka rezultira poboljšanjima u metričkoj izvedbi, ali se uočava opći pad izvedbe, što je u skladu s povećanom složenošću dijagnostičkog zadatka.

Na isti način Tablica 6 prikazuje rezultate segmentacije i dijagnostičkih zadataka, također s dva seta rezultata. Ova tablica pruža uvid u sposobnost modela da precizno segmentira regije u kojima se nalaze radiolucetne lezije i kategorizira ih prema klinički relevantnim tipovima. Također, može se primijetiti opće smanjenje izvedbe u usporedbi s prethodnim zadatkom, što naglašava izazove u segmentaciji i dijagnozi.

Tablice 7 i tablica 8 pružaju detaljan pregled detekcije i dijagnostičke učinkovitosti za svaki podtip ciste na ne-augmentiranom skupu podataka. Srednje prosječne preciznosti mAP@50 za

detekciju i dijagnosticiranje radikularne ciste, ameloblastom, odontogenu keratociste, folikularne ciste i rezidualne ciste iznose 85,4 %, 69.5%, 25.1%, 71,7% i 25.1%.

S druge strane, tablica 9 i tablica 10 pružaju uvid u izvedbu na proširenom skupu podataka. Srednje prosječne preciznosti mAP@50 za detekciju i dijagnosticiranje radikularne ciste, ameloblastom, odontogenu keratociste, folikularne ciste i rezidualne ciste iznose 84.6 % 99.5%, 31.3%, 50.8% i 99.5%. Iako se može zamijetiti poboljšanje rezultata po tipovima kada se promatraju rezultati na augmentiranom setu, što je u skladu s prethodnim zaključcima, rezultati jasno ukazuju na suboptimalne performanse u svim vrstama lezija što implicira potrebu za daljnjim usavršavanjem i optimizacijom.

Dijagnostička procjena otkriva varijabilne rezultate izvedbe u različitim zadacima i skupovima podataka. Iako su primijećena poboljšanja s proširenim skupom podataka, opaža se opći pad u ukupnoj izvedbi. Ovo ističe složenost dijagnostičkog zadatka i izazove vezane uz precizno kategoriziranje različitih lezija donje čeljusti. Iako je trenirani model pokazao zadovoljavajuću izvedbu u svom zadatku, još uvijek se suočava s uobičajenim izazovima koji su slični onima s kojima se suočavaju i kliničari tijekom dijagnosticiranja lezija čeljusti. Postoji nekoliko čimbenika koji utječu na sposobnost modela da učinkovito identificira ciste:

- varijabilnost veličine i položaja: lezije se mogu pojaviti u različitim veličinama i na različitim dubinama unutar kosti, što otežava njihovo otkrivanje na rendgenskim snimkama.
- radiografski izgled: izgled lezija na rendgenskim snimkama može varirati ovisno o faktorima kao što su vrsta lezije, njezin razvojni stadij te okolne strukture, što predstavlja izazov za preciznu identifikaciju.
- preklapanje struktura: dvodimenzionalni prikaz snimaka često rezultira preklapanjem zuba, kostiju i mekih tkiva, što može otežati vidljivost lezija i komplicirati njihovo otkrivanje.

Ilustrativan primjer prikazan je na slici 57, gdje je model nije uspio detektirati leziju, vjerojatno zbog njenog položaja koji se nalazio u području gdje je zub izvađen.

S obzirom na nagli porast upotrebe UI, velik je broj istraživanja koja se bave primjenom iste u

svrhu dijagnosticiranja različitih medicinskih bolesti. Međutim, mali je broj istraživanja na temu dijagnosticiranja lezija donje čeljusti.

Unsal i sur. su razvili model detekcije folikularnih cisti putem konvolucijskih neuronskih mreži. Ulazni podatci za razvoj modela sastojali su se od 112 ortopantomogramskih snimki rezolucije 1024x514. Metrička analiza pokazala je preciznost od 50% i osjetljivost od 100% (139).

Kako je već spomenuto u uvodu ovog istraživanja, ameloblastom i odontogena keratocista dijele zajednička obilježja na ortopantomogramskim snimkama.

Liu i sur. u svom istraživanju pokušali su razviti algoritam koji se temelji na metodi transfer učenja i može razlikovati odontogenu keratocistu od ameloblastoma. Ulazni skup podataka sastojao se od 420 ortopantomogramskih snimki. Razvijeni model je tijekom testiranja imao preciznost od 69.88% i osjetljivost od 78.31% (140).

Yang i sur. su, u radu objavljenom 2020. godine korištenjem YOLOv2, razvili model za prepoznavanje radiolucentnih lezija gornje i donje čeljusti. Također su uspoređivali mogućnost detektiranja lezija razvijenog modela u odnosu na radiologa i maksilofacijalnog kirurga. Zaključili su da nema statistički značajne razlike u detekciji radiolucentnih lezija modela i profesionalnog medicinskog radnika (141).

Hong lee i sur. su, korištenjem arhitekture GoogLeNet Inception-v3 i prijenosnog učenja, razvili algoritam prepoznavanja odontogene keratociste, folikularne ciste i periapikalne ciste. Također su razvijeni algoritam upotrijebili na CBCT snimkama i ortopantomogramskim snimkama. Fascinantno je da su dobili bolje metričke rezultate u prepoznavanju cisti na CBCT snimkama u odnosu na ortopantomogram. Preciznost i osjetljivost algoritma na CBCT-u je 77.1% i 96.1% dok je za ortopantomogram 77% i 88.2% (142).

Kako je već i spomenuto, ne postoji istraživanje koje je ujedinilo razvoj modela UI za detekciju, segmentaciju i dijagnosticiranje.

Testiranje modela u ujedinjenim zadacima detekcije, segmentacije i dijagnosticiranja pojedine radiolucentne lezije prikazano je na slikama 38, 43, 47, 51 i 55.

Ilustrirana je zavidna uspješnost modela tijekom testiranja na slučajnom uzorku testnog skupa.

Prediktivne sposobnosti modela zasnovanog na dubokom učenju za dijagnostiku lezija donje čeljusti emaniraju iz složene dinamike i strukture njegove neuronske arhitekture. Kao što je već opisano u uvodu, ova arhitektura omogućava modelu da analizira slike, identificirajući obrasce i značajke karakteristične za prisutnost lezije. Nadalje, sposobnost detaljne analize proizlazi iz modelove mogućnosti da "vidi" izvan površinskih karakteristika, zaranjajući u bogatstvo podataka koji čine sliku i prepoznaje suptilne signale koji bi ljudskom oku mogli ostati skriveni.

Istraživanje specifičnih slojeva unutar neuronske mreže i vizualizacija njihovih unutarnjih aktivacija pruža dublji uvid u procese koji stoje iza donošenja odluka modela. Ovaj proces možemo zamisliti kao uvid u "mozak" modela gdje pratimo kako informacije prolaze kroz složenu mrežu, sa svakim slojem koji dodaje sloj razumijevanja pa sve do precizne identifikacije ključnih područja interesa povezanih s lezijama donje čeljusti (143,144,145).

Inovativne tehnike vizualizacije, poput EigenCAM-a, dodatno obogaćuju naše razumijevanje kako modeli donose predikcije. EigenCAM generira toplinske mape koje vizualno predstavljaju regije koje model smatra ključnima za svoje predikcije. Ove mape nude jasan, vizualni uvid u dijelove slike koji su presudni za prepoznavanje patoloških stanja, često ističući specifične regije, poput donje čeljusti, s povišenim intenzitetom koji naglašava moguće lokacije radiolucenih lezija (146,147,148). Konkretno, toplinske mape generirane metodom EigenCAM često pokazuju povećanu aktivnost oko područja donje čeljusti čime se jasno označavaju područja gdje model predviđa prisutnost lezija (Slika 58). Primjerice, prilikom analize ortopantomogramskih snimki, EigenCAM mape mogu otkriti područja s povećanim intenzitetom topline oko područja donje čeljusti, čime se vizualno određuju regije gdje se lezije najvjerojatnije nalaze. Ova vizualizacija, ne samo da ističe ključne regije od interesa, već i služi kao empirijski dokaz sposobnosti modela da izvršava zadani zadatak detekcije cista (Slika 59).

Važnost tehnika poput EigenCAM-a leži u njihovoj sposobnosti da potvrde i objasne fokus i predikcije modela, čime se potvrđuje njegova efikasnost u identifikaciji relevantnih karakteristika za dijagnozu lezija donje čeljusti. Kroz kombiniranu analizu aktivacija unutar

mreže i vizualizacije toplinskih mapa, dobivamo vrijedan uvid u procese donošenja odluka modela, omogućavajući tako bolje razumijevanje i interpretaciju njegovih prediktivnih sposobnosti. Ovo razumijevanje, ne samo da doprinosi pouzdanosti i transparentnosti modela, već i omogućava kliničkim praktičarima da s većim povjerenjem koriste ove alate u dijagnostičkim postupcima, osiguravajući tako precizniju i učinkovitiju dijagnostiku i planiranje terapije za pacijente.

Rezultati ovog istraživanja pokazali su metrički značajne mogućnosti razvijenog modela u detekciji, segmentaciji i dijagnosticiranju radiolucentnih lezija donje čeljusti.

Ograničenje ove studije je relativno mali broj ulaznih podataka koji su se koristili za razvijanje modela i testiranje, međutim u rangu je sa sličnim istraživanjima.

Nadalje, važno je napomenuti da je naše istraživanje bilo ograničeno na radiolucentne lezije donje čeljusti. Buduća istraživanja mogla bi proširiti primjenu YOLOv8 na gornju čeljust, čime bi se povećala njegova potencijalna korisnost.

Također, dodatno ograničenje je neravnomjerna raspodjela radiolucentnih lezija s dominantnim uzorkom radikularnih cisti. Značajne rezultate bi svakako trebalo potvrditi kroz naredne fokusirane studije na većem broju uzoraka, što je u planu za nastavak rada. Generalizacija algoritma ključna je za osiguravanje njegove učinkovitosti i pouzdanosti u kliničkoj primjeni. Buduća istraživanja usredotočit će se na prikupljanje ortopantomogramskih snimki iz različitih izvora i demografskih skupina, kao i na prilagodbu algoritma na temelju povratnih informacija iz kliničke prakse. Osim toga, planirano je kontinuirano testiranje na novim, neviđenim podacima kako bi se osiguralo da algoritma održava visoku razinu točnosti čak i u novim situacijama.

Jedan od ključnih aspekata budućeg razvoja algoritma i napredovanja u polju medicinske dijagnostike je zalaganje za uspostavu nacionalne baze podataka. Takva baza podataka sadržavala bi anonimne medicinske podatke prikupljene od pacijenata diljem zemlje. Naime, najveća poteškoća u izradi ovog studija je prikupljanje ortopantomogramskih snimki. Bolnice nemaju povezani informacijski sustav te su podatci spremljeni uglavnom u fizičkom obliku. Uspostava nacionalne sveobuhvatne baze podataka omogućila bi sustavima UI učenje iz ogromne količine informacija, čime bi se poboljšala točnost dijagnostičkog algoritma.

Nadalje, procesom automatizacije dijagnostičkih postupaka smanjuje se administrativno opterećenje za zdravstvene radnike, omogućujući im da se usredotoče na pružanje izravne skrbi pacijentima. Međutim, potrebno je uspostaviti jasne smjernice i standarde za prikupljanje, pohranu i korištenje medicinskih podataka te za razvoj modela temeljenih na UI.

6. ZAKLJUČCI

Uz ograničavajuće faktore ove studije zaključeno je:

1. Umjetna inteligencija predstavlja moćan alat sposoban za detaljnu analizu medicinskih snimaka.
2. Razvijeni algoritam dubokog učenja sposoban je detektirati radiolucentne lezije donje čeljusti uz impresivne metričke pokazatelje.
3. Razvijeni algoritam dubokog učenja sposoban je segmentirati radiolucentne lezije donje čeljusti s visokom razinom preciznosti.
4. Razvijeni algoritam dubokog učenja učinkovito dijagnosticira različite tipove lezija na ortopantomogramskim snimkama.
5. Analiziranjem načina na koji razvijeni model procesira podatke, kroz vizualizacijske aktivacije i toplinske mape, otvaramo put prema njegovom daljnjem usavršavanju.

7. LITERATURA

1. Knežević G. Ciste čeljusti i mekih tkiva usne šupljine. In: Knežević G. et al. *Oralna kirurgija 1st ed.* Zagreb: Medicinska naklada; 2003. p. 85-132.
2. Philbert RF, Sandhu NS. Nonodontogenic Cysts. *Dent Clin North Am.* 2020 Jan;64(1):63-85.
3. Kuna T. Ciste čeljusti, mekih tkiva usne šupljine i okolnih područja. *Sonda.* 2003;5(8,9):42-56.
4. Andersson L, Kahnberg K. E, Pogrel M. A, *Cystic lesions of the jaw in Oral and maxillofacial surgery. 1st ed.* Chichester, West Sussex: Wiley-Blackwell; 2010. 31: 621-629.
5. Soluk-tekkessin M, Wright JM. The world health organization classification of odontogenic lesions: a summary of the changes of the 2017 (4th) edition. *TJPATH [Internet].* 2013 [cited 2024 February 14]; Available from: <http://www.turkijpath.org/doi.php?doi=10.5146/tjpath.2017.01410>
6. Goswami M, Chauhan N. Radicular Cyst with Primary Mandibular Molar: A Rare Occurrence. *Int J Clin Pediatr Dent.* 2023 Sep-Oct;16(5):769-773.
7. Lai PT, Chen IJ, Li CY, Chiang CP. Radicular cyst with actinomycosis. *J Dent Sci.* 2024 Jan;19(1):666-668.
8. Haylaz E, Şeker Ç, Geduk G, İçen M, Gülşen E. Retrospective Analysis of Oral and Maxillofacial Pathologies Oral ve Maksillofasiyal Patolojilerin Retrospektif Analizi. *J Contemp Med.* 2022;12:877-883.
9. Acikgoz A, Uzun-Bulut E, Ozden B, Gunduz K. Prevalence and distribution of odontogenic and nonodontogenic cysts in a Turkish population. *Med Oral Patol Oral Cir Bucal.* 2012;17:e108–e115.
10. Kammer PV, Mello FW, Rivero ERC. Comparative analysis between developmental and inflammatory odontogenic cysts: retrospective study and literature review. *Oral Maxillofac Surg.* 2020;24:73-84.
11. Nayyer NV, Macluskey M, Keys W. Odontogenic cysts – an overview. *Dent Update.* 2015;42(6):548–55.
12. Gliga A, Imre M, Grandini S, Marruganti C, Gaeta C, Bodnar D, Dimitriu BA, Foschi F. The Limitations of Periapical X-ray Assessment in Endodontic Diagnosis—A Systematic Review. *J Clin Med.* 2023;12(14):4647.

13. Umer F, Adnan N, Khan M, Qureshi MB. *The Dilemma Of Management Of Cystic Lesions; An Uncertain Way Forward: A Case Report. J Pak Med Assoc. 2023 Nov;73(11):2269-2272.*
14. Jurt A, Stanowska O, Braun D, Schulze R. *Atypisch grosse radikuläre Zyste. Operative Entfernung einer atypisch grossen ausgedehnten radikulären Zyste im Unterkiefer, ein Fallbericht [Surgical removal of an atypically large extensive radicular cyst in the mandible: a case report.]. Swiss Dent J. 2023 Dec 4;133(12):810-815.*
15. Ahmed T, Kaushal N. *Treatment of Radicular Cyst with Marsupialization in Children: Report of Two Rare Cases. Int J Clin Pediatr Dent. 2022;15:462–467.*
16. Lukšić I. *Ciste čeljusti i diferencijalna dijagnoza prozračnosti čeljusti. In Maksilofacijalna kirurgija 1st ed. Zagreb: Ljevak; 2019. p. 64-83.*
17. Mane BS, Chavan RP, Naikwadi KB, Gavali RM. *A Case Series of Dentigerous Cyst in Paediatric Patients at Our Tertiary Institution. Indian J Otolaryngol Head Neck Surg. 2023 Sep;75(3):2444-2452.*
18. Summersgill KF. *Pediatric Oral Pathology: Odontogenic Cysts. Pediatr Dev Pathol. 2023 Nov-Dec;26(6):609-620. doi: 10.1177/10935266231176245. Epub 2023 May 22.*
19. Lin HP, Wang YP, Chen HM, Cheng SJ, Sun A, Chiang CP. *A clinicopathological study of 338 dentigerous cysts. J Oral Pathol Med. 2013 Jul;42(6):462-7.*
20. Zhang LL, Yang R, Zhang L, Li W, MacDonald-Jankowski D, Poh CF. *Dentigerous cyst: a retrospective clinicopathological analysis of 2082 dentigerous cysts in British Columbia, Canada. Int J Oral Maxillofac Surg. 2010 Sep;39(9):878-82.*
21. Yeo JF, Rosnah BZ, Ti LS, Zhao YY, Ngeow WC. *Clinicopathological study of dentigerous cysts in Singapore and Malaysia. Malays J Pathol. 2007 Jun;29(1):41-7.*
22. Ramani P, Krishnan RP, Pandiar D, Behera A, Ramasubramanian A. *Squamous odontogenic tumor like proliferations in dentigerous cyst- a great mimicker. Oral Oncol. 2022 Feb;125:105699.*
23. Thompson, LDR. *Dentigerous Cyst. Ear Nose Throat J. 2018;97(3):57.*
24. Jokić D, Knežević G, Kotarac Knežević A. *Kirurško – ortodontsko liječenje razvojnih odontogenih cista čeljusti. Acta Stomal Croat. 2005;39:113-9.*
25. Austin RP, Nelson BL. *Sine Qua Non: Dentigerous Cyst. Head Neck Pathol. 2021 Dec;15(4):1261-1264. doi: 10.1007/s12105-021-01327-3. Epub 2021 Apr 21.*

26. Assael LA. *Surgical management of odontogenic cysts and tumors*. In: Peterson LJ, Indresano TA, Marciani RD, Roser SM, editors. *Principles of oral and maxillofacial surgery*. Vol. 2. Philadelphia: JB Lippincott; 1992. pp. 685–8.
27. Romano A, Norino G, Dell'Aversana Orabona G, Barone S, Ordano D, Calvanese C, Troise S, Califano L, Iaconetta G. *A Large Follicular Dentigerous Cyst: A New Multi-portal Access: Intraoral and Endoscopic Technique*. *J Maxillofac Oral Surg*. 2024 Feb;23(1):189-192.
28. Kirtaniya BC, Sachdev V, Singla A, Sharma AK. *Marsupialization: A conservative approach for treating dentigerous cyst in children in the mixed dentition*. *J Indian Soc Pedod Prev Dent*. 2010;28:203–8.
29. Monteiro L, Santiago C, Amaral BD, Al-Mossallami A, Albuquerque R, Lopes C. *An observational retrospective study of odontogenic cyst's and tumours over an 18-year period in a Portuguese population according to the new WHO Head and Neck Tumour classification*. *Med Oral Patol Oral Cir Bucal*. 2021 Jul 1;26(4):e482-e493.
30. Ezsias A. *Longitudinal in vivo observations on odontogenic keratocyst over a period of 4 years*. *Int J Oral Maxillofac Surg*. 2001;30:80-2.
31. Grasmuck EA, Nelson BL. *Keratocystic odontogenic tumor*. *Head Neck Pathol*. 2010 Mar;4(1):94-6.
32. Bartoš V, Kullová M, Adamicová K, Paučinová I. *Gorlin-Goltz syndrome*. *Klin Onkol*. 2019;32(2):124-8.
33. Jabbarzadeh M, Hamblin MR, Pournaghi-Azar F, Vakili Saatloo M, Kouhsoltani M, Vahed N. *Ki-67 expression as a diagnostic biomarker in odontogenic cysts and tumors: A systematic review and meta-analysis*. *J Dent Res Dent Clin Dent Prospects*. 2021 Winter;15(1):66-75.
34. Otonari-Yamamoto M, Nakajima K, Sato H, Wada H, Matsumoto H, Nishiyama A, Hoshino T, Matsuzaka K, Katakura A, Goto TK. *Dentigerous cysts suspected the other odontogenic lesions on panoramic radiography and CT*. *Oral Radiol*. 2024 Jan 2.
35. Sivanmalai S, Kandhasamy K, Prabu N, Prince CN, Prabu CS. *Carnoy's solution in the mangement of odontogenic keratocyst*. *J Pharm Bioallied Sci*. 2012;4(2):183-5.
36. Cusack JW. *Report of the amputations of the lower jaw*. *Dubl Hosp Rec*. 1827;4:1–38.

37. Cakur B, Caglayan F, Altun O, Miloglu O. Plexiform ameloblastoma. *Erciyes Med J.* 2009.
38. Peter J, Emmatty TB, Jose B, Methippara JJ, Sebastian R, Vasu S. Unicystic Ameloblastoma Associated with Primary Mandibular Second Molar: A Case Report. *Int J Clin Pediatr Dent.* 2023 Nov;16(Suppl 3):335-338.
39. Mendenhall, William M. MD*; Werning, John W. MD†; Fernandes, Rui DMD, MD‡; Malyapa, Robert S. MD, PhD*; Mendenhall, Nancy P. MD*. Ameloblastoma. *American Journal of Clin Onc.* 30(6):p 645-648, December 2007.
40. Soluk-Tekkesin M, Wright JM. The World Health Organization Classification of Odontogenic Lesions: A Summary of the Changes of the 2022 (5th) Edition. *Turk Patoloji Derg.* 2022;38(2):168-184.
41. Pandiar D, Anand R, Kamboj M, Narwal A, Shameena PM, Devi A. Metastasizing Ameloblastoma: A 10 Year Clinicopathological Review with an Insight Into Pathogenesis. *Head Neck Pathol.* 2021 Sep;15(3):967-974.
42. Ariji Y, Morita M, Katsumata A, Sugita Y, Naitoh M, Goto M, Izumi M, Kise Y, Shimozato K, Kurita K, Maeda H, Ariji E. Imaging features contributing to the diagnosis of ameloblastomas and keratocystic odontogenic tumours: logistic regression analysis. *Dentomaxillofac Radiol.* 2011 Mar;40(3):133-40.
43. Mamat Yusof MN, Ch'ng ES, Radhiah Abdul Rahman N. BRAF V600E Mutation in Ameloblastoma: A Systematic Review and Meta-Analysis. *Cancers (Basel).* 2022 Nov 14;14(22):5593.
44. Shear M, Speight P. *Cysts of the Oral and Maxillofacial Regions.* 4th Ed Oxford: Blackwell and Munksgaard; 2007: 123–140.
45. Tsvetanov TS. Residual cysts: a brief literature review. *Int J Med Dent Sci.* 2016;1:1341-1346.
46. Sridevi K, Nandan SR, Ratnakar P, Srikrishna K, Pavani BV. Residual cyst associated with calcifications in an elderly patient. *J Clin Diagn Res.* 2014;8(2):246-249.
47. Titinchi F, Morkel J. Residual cyst of the jaws: A clinico-pathologic study of this seemingly inconspicuous lesion. *PLoS One.* 2020 Dec 17;15(12).
48. Torul D, Bereket CM, Özkan E. Management of large residual cyst in elderly patient with decompression alone: case report. *Balk J Dent Med.* 2018;22(3):171-174.

49. Etemadi Sh M, Aghamohseni M, Norouzi A, Sadeghi S, Ranjbarian P. Functional denture obturator for marsupialization of residual cyst: A novel approach. *Clin Case Rep.* 2022 Nov 27;10(11):e6641.
50. Krolo I, Zadavec D i suradnici, *Dentalna radiologija, Medicinska naklada, Zagreb.*2016.
51. Molander B. Panoramic radiography in dental diagnostics. *Swedish Dental journal. Supplement.* 1996 ;119:1-26.
52. Rondon RH, Pereira YC, do Nascimento GC. Common positioning errors in panoramic radiography: A review. *Imaging Sci Dent.* 2014 Mar;44(1):1-6.
53. Rushton VE, Horner K. The use of panoramic radiology in dental practice. *J Dent.* 1996 May;24(3):185-201.
54. Glasser O. WC Roentgen and the discovery of the Roentgen rays. *AJR. American journal of roentgenology,* 1995, 165.5: 1033-1040.
55. Novelize R. *Squire's Fundamentals of Radiology. 5th ed. Harvard University Press; 1997.*
56. Campbell DJ. A brief history of dental radiography. *N Z Dent J.* 1995 Dec;91(406):127-33.
57. Jackson PC. *Introduction to artificial intelligence. Courier Dover Publications; 2019.*
58. Ginsberg M. *Essentials of artificial intelligence. Newnes; 2012.*
59. Cambria E, White B. Jumping NLP Curves: A Review of Natural Language Processing Research [Review Article]. *IEEE Comput Intell Mag.* 2014 May;9(2):48–57.
60. Turing AM. Computing machinery and intelligence. *Mind.* 1950 Oct;59(236):433–460.
61. Copeland J, editor. *The Essential Turing: the ideas that gave birth to the computer age. Oxford, England: Clarendon Press; 2004.*
62. McCarthy J, Minsky M, Rochester N, Shannon C. A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. August 31, 1955. *AI Mag.* 2006;27(4):12.
63. Russell SJ, Norvig P. *Artificial Intelligence: A Modern Approach. 4th ed. Hoboken: Pearson; 2021.*
64. Crevier D. *AI: The Tumultuous Search for Artificial Intelligence. New York, NY: BasicBooks; 1993.*

65. Berry DM. Weizenbaum, *ELIZA and the End of Human Reason*. In: Baranovska M, Hölting S, editors. *Hello, I'm Eliza: Fünfzig Jahre Gespräche mit Computern [Hello, I'm Eliza: Fifty Years of Conversations with Computers]* (in German). 1st ed. Berlin: Projekt Verlag; 2018. pp. 53–70.
66. Epstein J, Klinkenberg WD. *From Eliza to Internet: A brief history of computerized assessment*. *Comput Human Behav*. 2001;17(3):295–314.
67. Weizenbaum J. *Eliza—a computer program for the study of natural language communication between man and machine*. *Commun ACM*. 1966;9:36–45.
68. Weizenbaum J. *Computer Power and Human Reason: From Judgment to Calculation*. New York: W. H. Freeman and Company; 1976.
69. Luger G, Stubblefield W. *Artificial Intelligence: Structures and Strategies for Complex Problem Solving*. 5th ed. Benjamin/Cummings; 2004.
70. LeCun Y, Bottou L, Bengio Y, Haffner P. *Gradient-based learning applied to document recognition*. *Proc IEEE*. 1998 Nov;86(11):2278-2324.
71. Wirtz BW, Weyerer JC, Geyer C. *Artificial Intelligence and the Public Sector – Applications and Challenges*. *Int J Public Adm*. 2018 Jul 24;42(7):596–615.
72. I. Goodfellow, Y. Bengio i A. Courville, *Deep Learning, Adaptive Computation and Machine Learning series*, MIT Press, 2016.
73. Bengio Y, "Learning Deep Architectures for AI", *Foundations and Trends® in Machine Learning*: Vol. 2: No. 1, pp 1-127.
74. LeCun Y, Bengio Y, Hinton G. *Deep learning*. *Nature*. 2015 May 28;521(7553):436-44.
75. Schmidhuber, J. "Deep Learning in Neural Networks: An Overview". *Neural Networks*. 2015; 61: 85–117.
76. Krizhevsky A, Sutskever I, Hinton GE. *Imagenet classification with deep convolutional neural networks*. *Adv Neural Inform Process Syst*. 2012;25:1097-1105.
77. Hochreiter, S., Schmidhuber, J. *Long short-term memory*. *Neural computation*, 1997;9(8):1735-80.
78. Arjovsky M, Shah A, Bengi Y. *Unitary evolution recurrent neural networks*. In *International Conference on Machine Learning*, 2016. p. 1120-8.

79. Kramer, Mark A. *Nonlinear principal component analysis using autoassociative neural networks*. *AIChE Journal*. 1991;37(2):233-43.
80. Hinton, G. E.; Salakhutdinov, R.R. *Reducing the Dimensionality of Data with Neural Networks*. *Science*. 2006 Jul 28;313(5786):504-7.
81. Goodfellow I; Pouget-Abadie J, Mehdi M, Xu, B, Warde-Farley D, Ozair S; Courville A, Bengio Y. *Generative Adversarial Nets (PDF)*. In: *Proceedings of the International Conference on Neural Information Processing Systems*; 2014. p. 2672-80.
82. Li X, Xiong H, Li X, Wu X, Zhang X, Liu J, Bian J, Dou D. *Interpretable deep learning: interpretation, interpretability, trustworthiness, and beyond*. *Knowl Inf Syst*. 2022;64.
83. Kim TK, Cipolla R. *Multiple classifier boosting and tree-structured classifiers*. In: *Machine Learning for Computer Vision*. Springer, Berlin, Heidelberg; 2013.
84. Klette R. *Concise Computer Vision*. Springer; 2014.
85. Morris T. *Computer Vision and Image Processing*. Palgrave Macmillan; 2004.
86. Boden MA. *Mind as Machine: A History of Cognitive Science*. Clarendon Press; 2006. p. 781.
87. Sejnowski TJ. *The deep learning revolution*. Cambridge, Massachusetts London, England: The MIT Press; 2018. p. 28.
88. Marr D. *A theory of cerebellar cortex*. *J Physiol*. 1969 Jun;202(2):437–70.
89. Marr D. *Simple memory: a theory for archicortex*. *Philos Trans R Soc Lond B Biol Sci*. 1971 Jul;262(841):23–81.
90. Szeliski R. *Computer Vision: Algorithms and Applications*. Springer Science & Business Media; 2010. pp. 10–16.
91. Sonka M, Hlavac V, Boyle R. *Image Processing, Analysis, and Machine Vision*. Thomson; 2008.
92. Kanade T. *Three-Dimensional Machine Vision*. Springer Science & Business Media; 2012.
93. Davies ER. *Machine Vision: Theory, Algorithms, Practicalities*. Morgan Kaufmann; 2005.
94. Chaki J, Dey N. *A beginner's guide to image preprocessing techniques*. CRC Press; 2018.
95. Zheng N, et al. *Computer vision and pattern recognition*. 2007.

96. Wiley V, Lucas T. *Computer vision and image processing: a paper review*. *Int J Artif Intell Res*. 2018;2(1):29-36.
97. Girshick R, Donahue J, Darrell T, Malik J. *Rich feature hierarchies for accurate object detection and semantic segmentation [Internet]*. *arXiv*. 2013 Nov 11 [cited 2024 Feb]; Available from: <http://arxiv.org/abs/1311.2524>
98. Girshick R. *Fast R-CNN [Internet]*. *arXiv*. 2015 Sep 27 [cited 2024 Feb]; Available from: <http://arxiv.org/abs/1504.08083>
99. Ren S, He K, Girshick R, Sun J. *Faster R-CNN: Towards real-time object detection with region proposal networks [Internet]*. *arXiv*. 2016 Jan 6 [cited 2024 Feb]; Available from: <http://arxiv.org/abs/1506.01497>
100. W. Liu et al., “SSD: Single Shot MultiBox Detector,” 2016, pp. 21–37.
101. Redmon J, Divvala S, Girshick R, Farhadi A. *You only look once: Unified, real-time object detection*. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*; 2016 Jun 27-30; Las Vegas, NV, USA. p. 779-88.
102. Wang G, Chen Y, An P, Hong H, Hu J, Huang T. *UAV-YOLOv8: A Small-Object-Detection Model Based on Improved YOLOv8 for UAV Aerial Photography Scenarios*. *Sensors (Basel)*. 2023 Aug 15;23(16):7190.
103. Diwan T, Anirudh G, Tembhurne JV. *Object detection using YOLO: Challenges, architectural successors, datasets and applications*. *Multimed Tools Appl*. 2023;82:9243–9275.
104. Terven J, Córdova-Esparza DM, Romero-González JA. *A comprehensive review of YOLO architectures in computer vision: From YOLOv1 to YOLOv8 and YOLO-NAS*. *Mach Learn Knowl Extr*. 2023;5:1680-1716.
105. Jocher G, Chaurasia A, Qiu J. *YOLO by Ultralytics [Internet]*. 2023 [cited 2023 Feb 28]. Available from: <https://github.com/ultralytics/ultralytics>
106. Chai ZK, Mao L, Chen H, Sun TG, Shen XM, Liu J, Sun ZJ. *Improved Diagnostic Accuracy of Ameloblastoma and Odontogenic Keratocyst on Cone-Beam CT by Artificial Intelligence*. *Front Oncol*. 2022 Jan 27;11:793417.
107. Azarafza M, Ghazifard A, Akgün H, et al. *Development of a 2D and 3D computational algorithm for discontinuity structural geometry identification by artificial intelligence based on image processing techniques*. *Bull Eng Geol Environ*. 2019;78:3371-3383.

108. Grillo R, Quinta Reis BA, Melhem-Elias F. The risks and benefits of utilizing artificial intelligence in oral and maxillofacial surgery. *J Stomatol Oral Maxillofac Surg.* 2023 Oct;124(5):101492.
109. Balaji SM. Maxillofacial Surgery and Artificial Intelligence. *Ann Maxillofac Surg.* 2023 Jan-Jun;13(1):1-2.
110. Hendrawan A, Gernowo R, Nurhayati OD, Warsito B, Wibowo A. Improvement object detection algorithm based on YoloV5 with BottleneckCSP. In: *2022 IEEE International Conference on Communication, Networks and Satellite (COMNETSAT)*; 2022. p. 79-83.
111. Buchanan, B.G.; Shortliffe, E.H. *Rule Based Expert Systems: The MYCIN Experiments of the Stanford Heuristic Programming Project.* Reading, MA: Addison-Wesley, 1984.
112. Kulikowski CA. *Beginnings of artificial intelligence in medicine (AIM): computational artifice assisting scientific inquiry and clinical artd with reflections on present AIM challenges.* *Yearb Med Inform* 2019;28:249-56.
113. Wolfram DA. An appraisal of INTERNIST-I. *Artif Intell Med.* 1995 Apr;7(2):93-116.
114. Banks G. Artificial intelligence in medical diagnosis: the INTERNIST/CADUCEUS approach. *Crit Rev Med Inform.* 1986;1(1):23-54.
115. London, Sue. *DXplainTM: a web-based diagnostic decision support system for medical students.* *Medical Reference Services Quarterly*, 1998, 17.2: 17-28.
116. Esteva A, Kuprel B, Novoa RA, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature* 2017;542:115-8.
117. Gargeya R, Leng T. Automated identification of diabetic retinopathy using deep learning. *Ophthalmology* 2017;124:962-9.
118. Kim Y, Jo H, Jang TG, Park SY, Park HY, Cho SP, Park J, Kim SH, Urtnasan E. *SleepMI: An AI-based screening algorithm for myocardial infarction using nocturnal electrocardiography.* *Heliyon.* 2024 Feb 16;10(4):e26548.
119. Trzepacz PT, Yu P, Sun J, Schuh K, Case M, Witte MM, Hochstetler H, Hake A. Comparison of neuroimaging modalities for the prediction of conversion from mild cognitive impairment to Alzheimer's dementia. *Neurobiol Aging.* 2014;35:143-51.

120. Mathotaarachchi S, Pascoal TA, Shin M, et al. Identifying incipient dementia individuals using machine learning and amyloid imaging. *Neurobiol Aging* 2017;59:80-90.
121. Bijo A, Sunil J K. Artificial intelligence in dentistry: Current concepts and a peep into the future. *Int J Adv Res*, 2018, 6.12: 1105-1108.
122. Chattopadhyay J, Deb A, Sharma K, Nawaid KA, Gandhi R, Joshi P, Makkad RS. Creating and Testing a New Computer Vision System for Detecting Dental Problems in Orthodontic Patients. *J Pharm Bioallied Sci.* 2024 Feb;16(Suppl 1):S466-S468.
123. Xi R, Ali M, Zhou Y, Tizzano M. A reliable deep-learning-based method for alveolar bone quantification using a murine model of periodontitis and micro-computed tomography imaging. *J Dent.* 2024 May 8:105057.
124. Xiong Y, Zhang H, Zhou S, Lu M, Huang J, Huang Q, Huang B, Ding J. Simultaneous detection of dental caries and fissure sealant in intraoral photos by deep learning: a pilot study. *BMC Oral Health.* 2024 May 12;24(1):553
125. Ma T, Zhu J, Wang D, Xu Z, Bai H, Ding P, Chen X, Xia B. Deep learning-based detection of irreversible pulpitis in primary molars. *Int J Paediatr Dent.* 2024 May 9. Epub ahead of print.
126. Chapman MN, Nadgir RN, Akman AS, Saito N, Sekiya K, Kaneda T, Sakai O. Periapical lucency around the tooth: radiologic evaluation and differential diagnosis. *Radiographics.* 2013 Jan-Feb;33(1):E15-32.
127. Endres MG, Hillen F, Salloumis M, Sedaghat AR, Niehues SM, Quatela O, Hanken H, Smeets R, Beck-Broichsitter B, Rendenbach C, Lakhani K, Heiland M, Gaudin RA. Development of a Deep Learning Algorithm for Periapical Disease Detection in Dental Radiographs. *Diagnostics (Basel).* 2020 Jun 24;10(6):430.
128. Ha SR, Park HS, Kim EH, Kim HK, Yang JY, Heo J, Yeo IL. A pilot study using machine learning methods about factors influencing prognosis of dental implants. *J Adv Prosthodont.* 2018 Dec;10(6):395-400.
129. Khanagar SB, Vishwanathaiah S, Naik S, A Al-Kheraif A, Devang Divakar D, Sarode SC, Bhandi S, Patil S. Application and performance of artificial intelligence technology in forensic odontology - A systematic review. *Leg Med (Tokyo).* 2021 Feb;48:101826.

130. Kwon O, Yong TH, Kang SR, Kim JE, Huh KH, Heo MS, Lee SS, Choi SC, Yi WJ. *Automatic diagnosis for cysts and tumors of both jaws on panoramic radiographs using a deep convolution neural network. Dentomaxillofac Radiol.* 2020 Dec 1;49(8):20200185.
131. Arijji Y, Yanashita Y, Kutsuna S, Muramatsu C, Fukuda M, Kise Y, Nozawa M, Kuwada C, Fujita H, Katsumata A, Arijji E. *Automatic detection and classification of radiolucent lesions in the mandible on panoramic radiographs using a deep learning object detection technique. Oral Surg Oral Med Oral Pathol Oral Radiol.* 2019 Oct;128(4):424-430.
132. Isensee, F., Jaeger, P. F., Kohl, S. A., Petersen, J. & Maier-Hein, K. H. *nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. Nat. Method.* 2021 Feb;18(2):203-211.
133. De Fauw, J. *Clinically applicable deep learning for diagnosis and referral in retinal disease. Nat. Med.* 2018 Sep;24(9):1342-1350.
134. Ouyang, D. *Video-based AI for beat-to-beat assessment of cardiac function. Nature.* 2020 Apr;580(7802):252-256.
135. Wang, G. *Deepigeos: a deep interactive geodesic framework for medical image segmentation. In IEEE Transactions on Pattern Analysis and Machine Intelligence* 2019 Jul;41(7):1559-1572.
136. Kauke M, Safi AF, Grandoch A, Nickenig HJ, Zöllner J, Kreppel M. *Image segmentation-based volume approximation-volume as a factor in the clinical management of osteolytic jaw lesions. Dentomaxillofac Radiol.* 2019 Jan;48(1):20180113.
137. Safi AF, Kauke M, Timmer M, Grandoch A, Nickenig HJ, Gültekin E, Büttner R, Kreppel M, Zöllner J. *Does volumetric measurement serve as an imaging biomarker for tumor aggressiveness of ameloblastomas? Oral Oncol.* 2018 Mar;78:16-24.
138. El-Beblawy YM, Bakry AM, Mohamed MEA. *Accuracy of formula-based volume and image segmentation-based volume in calculation of preoperative cystic jaw lesions' volume. Oral Radiol.* 2024 Apr;40(2):259-268.
139. Ünsal G, Of E, Turkan İ, Bayrakdar İŞ, Çelik Ö. *Automatic Detection of Dentigerous Cysts on Panoramic Radiographs: A Deep Learning Study. EADS.* 2022;49(1):1-4.

140. Liu, Z., Liu, J., Zhou, Z. et al. *Differential diagnosis of ameloblastoma and odontogenic keratocyst by machine learning of panoramic radiographs. Int J CARS* 2021.,16, 415–422.
141. Yang, H.; Jo, E.; Kim, H.J.; Cha, I.-h.; Jung, Y.-S.; Nam, W.; Kim, J.-Y.; Kim, J.-K.; Kim, Y.H.; Oh, T.G.; et al. *Deep Learning for Automated Detection of Cyst and Tumors of the Jaw in Panoramic Radiographs. J. Clin. Med.* 2020, 9, 1839.
142. Lee JH, Kim DH, Jeong SN. *Diagnosis of cystic lesions using panoramic and cone beam computed tomographic images based on deep learning neural network. Oral Dis.* 2020 Jan;26(1):152-158.
143. Lee, J. G., Jun, S., Cho, Y. W., Lee, H., Kim, G. B., Seo, J. B., & Kim, N. *Deep learning in medical imaging: General overview. Korean Journal of Radiology*, 2017, 18(4), 570–584.
144. Nurtanio, I., Astuti, E. R., Purnama, I. K. E., Hariadi, M., & Purnomo, M. H. *Classifying cyst and tumor lesion using support vector machine based on dental panoramic images texture features. IAENG International Journal of Computer Science* 2013, 40(4), 04.
145. Shin, H. C., Roth, H. R., Gao, M., Lu, L. E., Xu, Z., Nogues, I., ... Summers, R. M. *Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning. IEEE Transactions on Medical Imaging*, 2016. 35(5), 1285–1298.
146. Mohammed Bany M, Yeasin, M. *Eigen-cam: Class activation map using principal components. In: 2020 international joint conference on neural networks (IJCNN). IEEE, 2020. p. 1-7.*
147. Chen W, Xiong C, Yue S. *Mechanical implementation of kinematic synergy for continual grasping generation of anthropomorphic hand. IEEE/ASME Trans Mechatron.* 2015 Jun;20(3):1249-63.
148. Bany Muhammad M, Yeasin M. *Eigen-CAM: Visual explanations for deep convolutional neural networks. SN Comput Sci.* 2021;2:47.

8. ŽIVOTOPIS

Mario Rašić rođen je 24.10.1990. godine u Splitu. Završio je Prirodoslovno-matematičku gimnaziju 'dr. Mate Ujević' u Imotskom s odličnim uspjehom. 2016. završio je Medicinski fakultet u Zagrebu tijekom kojeg je dobio Dekanovu nagradu te Rektorovu nagradu za najbolji znanstveni rad. Nakon završenog fakulteta, godinu dana je radio kao obiteljski liječnik u domu zdravlja Zagreb-Centar, a 2019. godine započinj se sa specijalizacijom iz maksilofacijalne kirurgije u Klinici za tumore, Kliničke bolnice Sestre Milosrdnice. Tijekom specijalizacije je sudjelovao na brojnim kongresima i edukacijama u europskim centrima izvrsnosti poput Madrida, Pariza i Amsterdama.

2021. godine upisuje poslijediplomski doktorski studij na Stomatološkom fakultetu, Sveučilišta u Zagrebu te polaže sve ispite uz prosjek 5.0.

Oženjen je i otac sina Noela.

Popis objavljenih radova:

1. Rašić M, Tropčić M, Karlović P, Gabrić D, Subašić M, Knežević P. Detection and segmentation of radiolucent lesions in the lower jaw on panoramic radiographs using deep neural networks. *Medicina*. 2023;59(12):2138. (**Q2, SCIE, rad proistekao iz doktorata**)
2. Rašić M, Pupić-Bakrač J, Milenović A. Upper blepharoplasty-anatomy, planning, surgical procedure and case report. *Acta Stomatol Croat*. 2022;56(4). (**Q2, ESCI**)
3. Pupić-Bakrač J, Rašić M. Prognostic significance of cystic nodal metastasis in HPV-positive oropharyngeal cancer. *Ear Nose Throat J*. 2022:01455613221112340. (**Q3, SCIE**)
4. Petricevic M, Knezevic J, Biocina B, Mikus M, Konosic L, Rašić M, et al. Association among Clopidogrel cessation, platelet function, and bleeding in coronary bypass surgery: an observational trial. *Thorac Cardiovasc Surg*. 2021;69(07):630-638. (**Q2, SCIE**)

5. *Rašić M, Cupurdija K, Kozul D, Lisek V, Mamic J, Vergles D. Ventral hernia repair due to large defect of abdominal wall caused by right iliac crest flap and myocutaneous flap harvesting. Acta Chir Croatica. 2021;18(1):33-35.*

6. *Plazibat M, Katušić Bojanac A, Himerleich Perić M, Gamulin O, Rašić M, et al. Embryo-derived teratoma in vitro biological system reveals antitumor and embryotoxic activity of valproate. FEBS J. 2021;287(21):4783-4800. (WOS CC/SCIE Q1)*