



Sveučilište u Zagrebu
Stomatološki fakultet

Ajla Zymber Česhko

**ISPITIVANJE PRECIZNOSTI I
POUZDANOSTI AUTOMATIZIRANE
REGISTRACIJE ZUBNOGA STATUSA
TEMELJENE NA KONVOLUCIJSKIM
NEURONSKIM MREŽAMA**

DOKTORSKI RAD

Zagreb, 2026.



Sveučilište u Zagrebu
Stomatološki fakultet

Ajla Zymber Česhko

**ISPITIVANJE PRECIZNOSTI I
POUZDANOSTI AUTOMATIZIRANE
REGISTRACIJE ZUBNOGA STATUSA
TEMELJENE NA KONVOLUCIJSKIM
NEURONSKIM MREŽAMA**

DOKTORSKI RAD

Mentor(i):

izv. prof. dr. sc. Ivana Savić Pavičin
prof. dr. sc. Marko Subašić

Zagreb, 2026.



University of Zagreb

School of Dental Medicine

Ajla Zymber Česhko

EVALUATION OF THE PRECISION AND RELIABILITY OF AUTOMATED DENTAL STATUS REGISTRATION BASED ON CONVOLUTIONAL NEURAL NETWORKS

DOCTORAL DISSERTATION

Supervisor(s):
Assoc. prof. Ivana Savić Pavičin
Prof. Marko Subašić

Zagreb, 2026

Rad je ostvaren u Zavodu za dentalnu antropologiju Stomatološkog fakulteta Sveučilišta u Zagrebu gdje su prikupljeni i označeni uzorci. Obrada i analiza uzoraka provedena je u Zavodu za elektroničke sustave i obradbu informacija Fakulteta elektrotehnike i računarstva Sveučilišta u Zagrebu.

Lektor hrvatskog jezika (ime i prezime, titula): Sandra Ćudina, prof.

Lektor engleskog jezika (ime i prezime, titula): Zinaida Gruda, prof.

Sastav Povjerenstva za ocjenu doktorskog rada:

(za svakog člana Komisije naknadno se rukom upisuje ime i prezime, akademska titula i ustanova)

1. _____
2. _____
3. _____
4. _____

Sastav Povjerenstva za obranu doktorske disertacije:

(za svakog člana Komisije naknadno se rukom upisuje ime i prezime, akademska titula i ustanova)

1. _____
2. _____
3. _____
4. _____

Datum obrane disertacije: _____

Rad sadrži:

-129 stranica,

-21 slike,

-18 tablica,

-6 formula,

-1 CD

Rad je autorsko djelo, koje je potpuno samostalno napisano uz navođenje izvora drugih autora i dokumenata korištenih u radu. Osim ako nije drukčije navedeno, sve ilustracije (tablice, slike itd.) u radu su originalni doprinos autora poslijediplomskoga doktorskog rada. Autor je odgovoran za dobivanje dopuštenja za korištenje ilustracija koje nisu njegov originalni doprinos, kao i za sve moguće posljedice koje mogu nastati zbog neovlaštenog preuzimanja ilustracija ili nenavođenja njihova podrijetla.

Zahvala

Želim izraziti najdublju zahvalnost svojoj mentorici, prof. dr. Ivani Savić Pavičin, na njezinu neprocjenjivu vodstvu, strpljenju i kontinuiranoj potpori tijekom moga doktorskog istraživanja. Njezina stručnost i ohrabrenje bili su ključni u oblikovanju ove disertacije. Također bih željela zahvaliti sumentoru, profesoru Marku Subašiću, na vodstvu tijekom cijeloga ovog istraživanja.

Duboko sam zahvalna svojim roditeljima, koji više nisu sa mnom, ali će uvijek biti u mom srcu, što su svjedočili završetku ovog putovanja kojem su svim srcem pridonijeli.

Iskrena zahvala ide mojoj obitelji, posebno mom suprugu i djeci, na njihovu razumijevanju, strpljenju i bezuvjetnoj potpori. Ne manje važni za mene su moja sestra i brat koji su mi s ljubavlju i ohrabrenjem bili motivacija da ustrajem i dovršim ovaj posao.

Ova disertacija ne bi bila moguća bez potpore i inspiracije svih vas. Hvala vam od srca.

Sažetak

Ispitivanje preciznosti i pouzdanosti automatizirane registracije zubnoga statusa temeljene na konvolucijskim neuronskim mrežama

Istraživanje je provedeno s ciljem razvoja i evaluacije modela dubokog učenja za automatiziranu registraciju zubnoga statusa na ortopantomografskim snimkama (OPG), s posebnim naglaskom na detekciju zuba i segmentaciju zuba te dentalnih zahvata. Istraživanje je obuhvatilo 1400 OPG-a prikupljenih u Zavodu za dentalnu antropologiju Stomatološkog fakulteta, podijeljenih na skupove za učenje, validaciju i testiranje. Za detekciju zuba korištene su varijante YOLOv5, uvježbane od početka i primjenom transfernog učenja, dok su za segmentaciju korištene arhitekture UNet, FCN i DeepLabV3. Uspješnost detekcije procjenjivana je pokazateljima preciznost, osjetljivost i mAP, a uspješnost segmentacije Sørensen-Diceovim koeficijentom. Rezultati su pokazali visoku uspješnost modela u zadatku detekcije. Najbolji rezultat ostvario je model YOLOv5x6 uvježban od početka, s vrijednošću mAP-a od 98,02% pri razlučivosti od 1820 px. Povećanje razlučivosti statistički je značajno poboljšalo uspješnost detekcije, pri čemu je najveći porast zabilježen između 256 px i 640 px. U segmentaciji zuba najuspješniji su bili UNet Big i DeepLabV3-HRNet V2 W32, oba s Diceovim koeficijentom od 95,94% na slici individualnog zuba. Pokazalo se da lokalizirani ulazi omogućuju bolju segmentaciju, dok se karijes pokazao kao najzahtjevniji zadatak. Dobiveni nalazi potvrđuju da konvolucijske neuronske mreže omogućuju pouzdanu i preciznu registraciju zubnoga statusa na OPG-u.

Ključne riječi: *duboko učenje; konvolucijske neuronske mreže; ortopantomogram; detekcija zuba; segmentacija; dentalna radiologija*

Summary

Evaluation of the precision and reliability of automated dental status registration based on convolutional neural networks

Objective: The aim of this study was to develop and evaluate deep learning models for automated dental status registration on panoramic radiographs, with particular emphasis on tooth detection and segmentation of teeth and dental interventions.

Materials and Methods: The study was conducted on 1,400 panoramic radiographs divided into training, validation, and test sets. A total of 39,441 teeth with different dental statuses were analyzed. Different YOLOv5 model variants, trained both from scratch and by transfer learning, were used for tooth detection. For the segmentation of teeth and dental interventions, UNet, FCN, and DeepLabV3 architectures were applied. Detection performance was evaluated using precision, recall, and mean average precision (mAP), while segmentation performance was assessed using the Dice coefficient. Statistical analysis included descriptive statistics, one-way analysis of variance, and Bonferroni post hoc comparisons.

Results: High performance was achieved in tooth detection. The best result was obtained by the YOLOv5x6 model trained from scratch, with an mAP of 98.02% at an input resolution of 1820 px. Increasing input image resolution significantly improved detection performance, with the greatest improvement observed between 256 px and 640 px. In tooth segmentation, the best performance was achieved by UNet Big and DeepLabV3-HRNet V2 W32, both with a Dice coefficient of 95.94% on individual tooth images. Localized inputs, especially individual and segmented teeth, yielded better segmentation results than full panoramic images. Among the evaluated categories, caries proved to be the most challenging segmentation task, whereas crowns, fillings, and root canal fillings achieved better results, particularly on localized tooth images.

Conclusion: The findings confirm that convolutional neural networks enable reliable and precise registration of dental status on panoramic radiographs. The study confirms the scientific validity and clinical relevance of deep learning methods in dental radiology and provides a strong basis for the development of standardized and reliable decision-support systems for automated panoramic radiograph interpretation.

Keywords: deep learning; convolutional neural networks; orthopantomogram; tooth detection; segmentation; dental radiology

SADRŽAJ

1.UVOD	1
1.1. Zubni status	2
1.2. Klinički značaj zubnog statusa	3
1.3. Dentalna identifikacija i forenzički značaj zubnog statusa.....	3
1.4. Radiografska analiza	9
1.5. Razvoj i vrste umjetne inteligencije	11
1.6. Tipovi učenja i računalni vid	13
1.7. Konvolucijske neuronske mreže.....	14
1.8. Modeli za detekciju objekata i računalni vid – YOLO.....	20
1.9. Primjena UI-ja u medicini i dentalnoj medicini	23
1.10. Automatizirano otkrivanje i segmentacija zuba na ortopantomogramima	24
1.11. Izazovi, perspektive te etičke i regulatorne implikacije primjene umjetne inteligencije .	28
1.12. Istraživačka praznina i opravdanost istraživanja	31
2. HIPOTEZA I CILJEVI ISTRAŽIVANJA	32
2.1. Ciljevi istraživanja.....	33
2.2. Istraživačka hipoteza	33
3. METODOLOGIJA ISTRAŽIVANJA	34
3.1. Prikupljanje podataka	35
3.1.1. Karakteristike skupa podataka	35
3.1.2. Postupak anotacije.....	35
3.1.3. Proširenje podataka.....	38
3.1.4. Etička razmatranja	38
3.2. Odabir modela.....	39
3.2.1. Prethodno uvježbani modeli.....	40
3.2.2. Modeli uvježbani od početka	40
3.2.3. Kombinirani pristup	41
3.2.5. Evaluacija performansi.....	42
3.3. Postupci vježbanja.....	43

3.4. Metrike evaluacije.....	45
3.4.1. Metrike detekcije	45
3.4.2. Metrike segmentacije.....	47
3.4.3. Metrike statističke analize.....	48
3.4.4. Evaluacija performansi prema razlučivosti slike	49
3.5. Eksperimentalni tijek rada.....	49
4. REZULTATI I ANALIZE	53
4.1. Karakteristike uzorka ortopantomograma i dentalnih nalaza.....	54
4.2. Detekcija zuba s pomoću YOLOv5 modela	57
4.3. Segmentacija zuba.....	69
4.4. Segmentacija karijesa	73
4.5. Segmentacija krunica	75
4.6. Segmentacija ispuna.....	77
4.7. Segmentacija endodontskog punjenja	79
5. RASPRAVA	82
5.1. Kritička analiza rezultata detekcije zuba	83
5.2. Kritička analiza rezultata segmentacije zuba.....	88
5.3. Kritička analiza rezultata segmentacije karijesa i dentalnih intervencija	93
5.3.1. Segmentacija karijesa.....	93
5.3.2. Segmentacija krunica	95
5.3.3. Segmentacija ispuna.....	96
5.3.4. Segmentacija endodontskih punjenja.....	98
5.4. Utjecaj arhitekture modela, vrste ulazne slike i metode uvježbavanja na uspješnost	99
detekcije i segmentacije	99
5.4.1. Usporedba arhitektura modela	100
5.4.2. Utjecaj vrste i rezolucije ulazne slike.....	101
5.4.3. Utjecaj metode uvježbavanja i kvalitete ulaza	102
5.5. Ograničenja istraživanja i implikacije za buduću primjenu.....	104
6. ZAKLJUČAK	105
7. LITERATURA	108

8.ŽIVOTOPIS.....	126
------------------	-----

POPIS KRATICA

Engleski naziv	Kratika	Hrvatski naziv
Artificial Intelligence	AI/UI	Umjetna inteligencija
Antemortem	AM	Antemortem (podaci prikupljeni tijekom života)
Analysis of Variance	ANOVA	Analiza varijance
Computer-Aided Design / Manufacturing	CAD/CAM	Računalno potpomognuto projektiranje / proizvodnja
Cone Beam Computed Tomography	CBCT	Konusno-snopna kompjutorizirana tomografija
Convolutional Neural Network	CNN/KNN	Konvolucijska neuronska mreža
Common Objects in Context (dataset)	COCO	Common Objects in Context (COCO)
DeepLab version 3	DeepLabV3	DeepLabV3 arhitektura
Sørensen–Dice Coefficient	Dice	Sørensen-Diceov koeficijent
Deep Learning	DL	Duboko učenje
Deoxyribonucleic acid	DNA/DNK	Deoksiribonukleinska kiselina
Digital Orthopantomogram	DOP	Digitalni ortopantomogram
Disaster Victim Identification	DVI	Identifikacija žrtava masovnih nesreća
F1-Score	F1	F1-mjera
Fully Convolutional Network	FCN	Potpuno konvolucijska mreža
World Dental	FDI	FDI dvoznamenkasti sustav označavanja zuba

Engleski naziv	Kratica	Hrvatski naziv
Federation notation		
False Negative	FN/LN	Lažno negativni
Field of View	FOV	Vidno polje
False Positive	FP/LP	Lažno pozitivni
Graphics Processing Unit	GPU	Grafički procesorski uređaj
High-Resolution Network	HRNet	Mreža visoke rezolucije
High-Resolution Network V2 W32	HRNet V2 W32	HRNet V2 W32 arhitektura
International Criminal Police Organization	INTERPOL	Međunarodna organizacija kriminalističke policije
Intersection over Union	IoU	Presjek nad unijom
Mean Average Precision	mAP	Srednja prosječna preciznost
Machine Learning	ML	Strojno učenje
Sample size	N	Veličina uzorka
Orthopantomogram / Panoramic Radiograph	OPG	Ortopantomogram
P-value	p	P-vrijednost (statistička značajnost)
Principal Component Analysis	PCA	Analiza glavnih komponenti
Postmortem	PM	Postmortem (podaci prikupljeni nakon smrti)
Panoramic Radiograph	PR	Panoramska radiografija
Precision	Prec	Preciznost
Pixel	px	Piksel

Engleski naziv	Kratica	Hrvatski naziv
Recall	Rec	Osjetljivost
Rectified Linear Unit	ReLU	Ispravljena linearna jedinica
Standard Deviation	SD	Standardna devijacija
True Negative	TN/IN	Istinski negativni
True Positive	TP/IP	Istinski pozitivni
U-Net (U-Shaped Neural Network)	Unet	U-Net mreža
U-Net Big	UNet Big	UNet Big arhitektura
You Only Look Once	YOLO	You Only Look Once (YOLO)
YOLO version 5	YOLOv5	YOLOv5 model
YOLO version 5x6	YOLOv5 x6	YOLOv5x6 model

1. UVOD

Detaljna registracija zubnog statusa, uključujući karijes, restauracije, protetske nadomjestke, implantate i endodontski liječene zube, ima važnu ulogu u kliničkoj stomatologiji, epidemiologiji i forenzičnoj medicini. U kliničkom kontekstu omogućuje procjenu oralnog zdravlja, planiranje terapije i praćenje ishoda liječenja, dok u forenzičkom području predstavlja jednu od temeljnih metoda identifikacije, usporedivu s analizom DNA i daktiloskopijom (1, 2). Jedinstvenost denticije proizlazi iz kombinacije anatomskih obilježja, položaja zuba, morfologije krune i korijena, restaurativnih zahvata, protetskih nadomjestaka i implantata, što dentalnu identifikaciju čini osobito vrijednom u slučajevima kada su druge metode ograničene (3-5).

Unatoč velikoj važnosti, tradicionalna registracija dentalnog statusa i dalje se u velikoj mjeri oslanja na vizualnu interpretaciju kliničkih i radiografskih nalaza. Takav pristup vremenski je zahtjevan i podložan subjektivnosti, međupromatračkoj i intrapromatračkoj varijabilnosti, razlikama u iskustvu te heterogenoj kvaliteti radioloških snimaka (6-11). Potreba za standardizacijom, objektivizacijom i ubrzanjem ovoga postupka posebno je izražena u forenzičkim situacijama s velikim brojem zapisa i ograničenim vremenom obrade (12-16). U tom kontekstu razvoj digitalnih alata i metoda umjetne inteligencije otvara mogućnost automatizirane, brže i dosljednije analize dentalnih snimaka.

1.1. Zubni status

Registracija dentalnog statusa predstavlja temeljni dijagnostički postupak u kliničkoj stomatologiji te jednu od osnovnih metoda identifikacije u forenzičkoj medicini. U kliničkom smislu omogućuje sustavnu procjenu zuba, gingive, parodontnog tkiva, oralne sluznice i pripadajućih anatomskih struktura te čini osnovu dijagnostike, planiranja terapije i praćenja promjena u oralnom zdravlju (17, 18).

Zubni status istodobno predstavlja standardizirani prikaz oralnog zdravlja pacijenta i važan je alat u svakodnevnoj stomatološkoj praksi, ali i u istraživačkom i epidemiološkom radu. Precizno vođena dokumentacija omogućuje usporedbu nalaza tijekom vremena, evaluaciju učinka terapije i planiranje daljnjih zahvata (17, 18). Zubni status obuhvaća ne samo prisutnost

ili odsutnost zuba, nego i detaljno bilježenje ispuna, krunica, mostova, implantata, endodontskih zahvata i drugih obilježja koja imaju dijagnostičku i identifikacijsku vrijednost.

1.2. Klinički značaj zubnog statusa

Precizno dokumentiran zubni status omogućuje ranu dijagnostiku oralnih bolesti i individualizirano planiranje terapije (19-21). U svakodnevnoj kliničkoj praksi on predstavlja osnovu za procjenu potrebe za restaurativnim, protetskim, endodontskim, parodontološkim i kirurškim zahvatima. Osim toga, omogućuje longitudinalno praćenje oralnog zdravlja i procjenu uspješnosti provedenih terapijskih postupaka.

U epidemiološkim istraživanjima standardizirana procjena zubnog statusa omogućuje praćenje trendova oralnog zdravlja, planiranje preventivnih mjera i evaluaciju provedenih postupaka (22, 23). Takva standardizacija osobito je važna pri usporedbi različitih populacijskih skupina i u procjeni opterećenja oralnim bolestima u širem javnozdravstvenom kontekstu.

Digitalna dokumentacija i računalni alati mogu dodatno unaprijediti dosljednost registracije i olakšati komunikaciju između liječnika i pacijenta. U tom smislu, automatizirana analiza dentalnih snimaka

ima potencijal pridonijeti većoj objektivnosti, bržoj obradi podataka i smanjenju subjektivnosti u interpretaciji nalaza (24-27).

1.3. Dentalna identifikacija i forenzički značaj zubnog statusa

Dentalna identifikacija predstavlja jednu od temeljnih metoda forenzičke identifikacije osoba te zauzima značajno mjesto u suvremenoj forenzičkoj medicini i stomatologiji. Zbog visoke otpornosti zubnih tkiva na postmortalne promjene, visoke temperature, mehanička oštećenja i kemijske utjecaje, denticija često ostaje očuvana i u slučajevima kada su druge identifikacijske metode ograničene ili neprimjenjive. Zbog tog razloga dentalna identifikacija smatra se metodom usporedivom s analizom DNK i daktiloskopijom, osobito u situacijama kada su raspoloživi fragmentarni ili oštećeni biološki ostaci (1, 2).

Osnovni princip dentalne identifikacije temelji se na sustavnoj usporedbi antemortem (AM) i postmortem (PM) podataka o zubnom statusu. Antemortem podaci obuhvaćaju informacije prikupljene tijekom života osobe, uključujući dentalne kartone, kliničke zapise, radiografske snimke, fotografsku dokumentaciju te ručne i digitalne zapise dentalnog statusa. Postmortem podaci dobivaju se tijekom forenzičkog pregleda i uključuju detaljnu registraciju svih dentalnih obilježja, restorativnih zahvata i prisutnih patoloških promjena (28-30). Uspješnost identifikacijskog postupka ovisi o kvaliteti, potpunosti i usporedivosti tih dviju skupina podataka.

Pouzdanost dentalne identifikacije temelji se na visokoj razini individualnosti denticije. Kombinacija anatomskih karakteristika, poput oblika krune i korijena zuba, položaja i rotacije zuba, prisutnosti kongenitalnih anomalija te terapijskih zahvata, uključujući ispune, krunice, mostove, implantate i ortodontske aparate, stvara jedinstveni skup obilježja karakterističan za svaku osobu (3-5). Upravo ta raznolikost i individualnost dentalnih nalaza omogućuje vrlo visoku razinu pouzdanosti identifikacije.

Proces dentalne identifikacije tradicionalno zahtijeva detaljnu analizu od strane educiranih i iskusnih forenzičkih stomatologa. Takva analiza uključuje sustavnu usporedbu svakog zuba, restauracije i radiografske karakteristike, pri čemu je potrebno uzeti u obzir i moguće promjene nastale tijekom vremena. Navedeni pristup zahtijeva značajno vrijeme i visoku razinu stručnosti, osobito u slučajevima kada su dostupni podaci nepotpuni ili heterogene kvalitete (6-11).

Radi povećanja pouzdanosti i standardizacije postupaka razvijeni su međunarodni protokoli za registraciju dentalnog statusa. Posebno važnu ulogu imaju standardizirani obrasci koje primjenjuje INTERPOL (Slika 1. i Slika 2.), a koji omogućuju sustavno prikupljanje i usporedbu antemortem i postmortem podataka. Standardizirani obrasci omogućuju jednoznačno bilježenje dentalnih nalaza, čime se smanjuje mogućnost interpretacijskih pogrešaka i olakšava međunarodna suradnja u forenzičkim istragama (12-16).

Ante Mortem (yellow)		INTERPOL DVI Form - Missing Person				Odontology	600's		
Family name: _____ AM No: _____									
First name(s): _____									
Date of birth: Day Month Year Age Male ☐ Female ☐ Other ☐ Unknown ☐									
a = Data not available b = Attachment c = Further info on page Sup. Info. (700's)									
ODONTOLOGY							a	b	c
600	Dental/clinic Name Street / No. Postcode / Town State / Country Phone / Email 01 Period covered 02 Enclosed	Records 1 ☐ From: _____ To: _____ Radiographs 1 ☐ Casts 2 ☐ Photos 3 ☐ Other (specify): 4 ☐ _____							
605	Dental/clinic Name Street / No. Postcode / Town State / Country Phone / Email 01 Period covered 02 Enclosed	Records 1 ☐ From: _____ To: _____ Radiographs 1 ☐ Casts 2 ☐ Photos 3 ☐ Other (specify): 4 ☐ _____							
615	Dental images available 01 PA 02 BW 03 OPG 04 CT 05 Other radiographs 06 Photographs	1 Digital ☐	2 State number of 	3 Non digital ☐	4 State number of 				
620	Further material								
Collected by		Duty Title : _____ Name : _____ Address : _____ Phone / Email : _____				Signature / Date : _____			

Ante Mortem (yellow)		INTERPOL DVI Form - Missing Person		Odontology 600's	
Family name: _____		AM No: _____			
First name(s): _____					
Date of birth: _____		Day: Month: Year: Age: Male: ☐ Female: ☐ Other: ☐ Unknown: ☐			
		a = Data not available b = Attachment c = Further info on page Sup. Info. (700's)			
ODONTOLOGY					
630 Dental findings (for primary teeth change specific FDI code)					
11					21
12					22
13					23
14					24
15					25
16					26
17					27
18					28
18 17 16 15 14 13 12 11 48 47 46 45 44 43 42 41 21 22 23 24 25 26 27 28 31 32 33 34 35 36 37 38 					

IBPa Version 2018

11 of 12

Slika 1. Interpolov DVI antemortem dentalni obrazac za registraciju podataka o nestaloj osobi. Izvor: INTERPOL DVI Form, 2023. Obrazac je javno dostupan za preuzimanje na službenoj stranici INTERPOL-a, <https://www.interpol.int/en/How-we-work/Forensics/Disaster-Victim-Identification-DVI>

Post Mortem (pink) INTERPOL DVI Form - Unidentified Human Remains Odontology 600's				
Place of disaster: _____ Nature of disaster: _____ Date of disaster: Day □ □ Month □ □ Year □ □ □ □ PM No: _____ Male □ Female □ Other □ Unknown □				
a = Data not available b = Attachment c = Further info on page Sup. Info. (700's)				
ODONTOLOGY		a	b	c
610	Material present for examination 01 Jaws with teeth 02 Jaws without teeth 03 Teeth only 04 Fragments 05 Other	Check ☐ Upper ☐ Lower ☐ Upper ☐ Lower FDI No's:	Specimen taken	
615	Dental images available 01 PA 02 BW 03 OPG 04 CT 05 Other radiographs 06 Photographs	1 Digital 2 State number of	3 Non digital 4 State number of	
625	Supplementary details 01 Condition of the body 02 Other details			
Registered by Duty Title : _____ Name : _____ Address : _____ Phone / Email : _____		Signature / Date		

Post Mortem (pink)		INTERPOL DVI Form - Unidentified Human Remains										Odontology 600's					
Place of disaster: _____												PM No: _____					
Nature of disaster: _____																	
Date of disaster: Day Month Year Male Female Other Unknown																	
a = Data not available b = Attachment c = Further info on page Sup. Info. (700's)																	
ODONTOLOGY																	
630 Dental findings (for primary teeth change specific FDI code)																	
11													21				
12													22				
13													23				
14													24				
15													25				
16													26				
17													27				
18													28				
RIGHT	18	17	16	15	14	13	12	11	21	22	23	24	25	26	27	28	LEFT
	48	47	46	45	44	43	42	41	31	32	33	34	35	36	37	38	
48													38				
47													37				
46													36				
45													35				
44													34				
43													33				
42													32				
41													31				
635	Specific data	1 ☐ Crowns			2 ☐ Pontics			3 ☐ Implants			a	b	c				
	01 Specify	4 ☐ Dentures			5 ☐ Other												
640	Other findings	1 ☐ Occlusion			2 ☐ Tooth wear			3 ☐ Periodontal status									
	01 Specify	4 ☐ Supernumeraries			5 ☐ Stains			6 ☐ Other									
645	Type of dentition	1 ☐ Primary dentition			2 ☐ Mixed dentition			3 ☐ Permanent dentition									
	01 Dentition																
647	Estimated age	Min _____ year / Max _____ year			Min _____ month / Max _____ month												
	01 Age (if other year or month)																
650	Quality check	Date: _____			Signature: _____												
	FOd 1	FOd 1 Name: _____			Signature: _____												
	FOd 2 (if available)	FOd 2 Name: _____															
Registered by										Signature / Date							
Duty Title : _____																	
Name : _____																	
Address : _____																	
Phone / Email : _____																	

IBPa Version 2018

11 of 12

Slika 2. Interpolov DVI postmortem dentalni obrazac za registraciju podataka o neidentificiranim ljudskim ostacima. Izvor: INTERPOL DVI Form, 2023. Obrazac je javno dostupan za preuzimanje na službenoj stranici INTERPOL-a, <https://www.interpol.int/en/How-we-work/Forensics/Disaster-Victim-Identification-DVI>

Digitalizacija dentalnih zapisa i primjena računalnih sustava dodatno su unaprijedile učinkovitost pohrane, razmjene i preliminarne usporedbe takvih podataka, osobito u slučajevima masovnih nesreća (12-16). U sklopu identifikacije žrtava masovnih nesreća primjenjuje se sustav Disaster Victim Identification (DVI), koji predstavlja standardizirani

organizacijski i metodološki okvir za identifikaciju većeg broja osoba. Automatizirana usporedba AM i PM zapisa omogućuje preliminarnu selekciju potencijalnih podudarnosti, nakon čega stručnjaci provode detaljnu analizu i konačnu verifikaciju rezultata (12-16).

U tom kontekstu razvoj metoda umjetne inteligencije predstavlja važan iskorak. Sustavi koji omogućuju automatiziranu detekciju i segmentaciju zuba, restauracija i drugih radiološki vidljivih obilježja mogli bi znatno ubrzati i standardizirati tradicionalne identifikacijske postupke, osobito u slučajevima velikog broja zapisa i ograničenog vremena obrade (12-15). Ipak, unatoč tehnološkom napretku, stručna prosudba forenzičkog stomatologa i dalje ostaje ključni element identifikacijskog postupka, dok automatizirani sustavi imaju ulogu potpore koja povećava objektivnost, ponovljivost i učinkovitost analize (16). U tom kontekstu razvoj digitalnih alata i metoda umjetne inteligencije otvara mogućnost automatizirane, brže i dosljednije analize dentalnih snimaka. Ovaj pristup potvrđuju i suvremena istraživanja temeljena na dubokom učenju koja pokazuju visoku učinkovitost automatizirane analize dentalnih radiografskih snimaka u detekciji i klasifikaciji dentalnih obilježja (31-36).

1.4. Radiografska analiza

Dentalno snimanje predstavlja temelj suvremene stomatološke dijagnostike jer omogućuje prikaz tvrdih i mekih tkiva nedostupnih kliničkom pregledu (31-33). U stomatologiji se danas primjenjuju različite vrste radioloških i digitalnih slikovnih metoda, uključujući intraoralne radiografije, panoramske snimke, konusno-snopnu kompjutoriziranu tomografiju (CBCT) i intraoralne optičke skenove (31-37, 19).

Među navedenim metodama ortopantomogram (OPG) zauzima posebno mjesto zbog mogućnosti prikaza cjelokupne denticije, alveolarnih nastavaka, mandibule, maksile i drugih okolnih anatomske struktura na jednoj slici (38, 39), Slika 3. Upravo zbog takvog sveobuhvatnog prikaza OPG se široko primjenjuje u svakodnevnoj kliničkoj praksi, ali i u forenzičnoj stomatologiji, gdje omogućuje pregled većeg broja važnih identifikacijskih obilježja u sklopu jedne radiografske snimke.



Slika 3. Primjer ortopantomografske rendgenske snimke. Ovakva snimka predstavlja cjelovit prikaz zuba i okolnih struktura

Digitalna radiologija omogućila je poboljšanje kvalitete slike, smanjenje doze zračenja, digitalnu obradu i dugotrajno arhiviranje podataka bez gubitka kvalitete (34). Mogućnost prilagodbe kontrasta, uvećanja slike i jednostavne razmjene digitalnih zapisa dodatno je unaprijedila dijagnostički proces i olakšala integraciju radioloških podataka u suvremene informacijske sustave.

Naprednije metode, poput CBCT-a, omogućuju trodimenzionalni prikaz dentoalveolarnog kompleksa i imaju važnu ulogu u implantologiji, oralnoj kirurgiji i detaljnijoj procjeni anatomskih i patoloških promjena (19, 35, 40). Također, intraoralni skeneri omogućuju digitaliziran prikaz zubnih lukova, okluzije i mekih tkiva bez potrebe za klasičnim otiscima, čime dodatno pridonose digitalnoj transformaciji stomatološke dijagnostike i terapijskog planiranja (34, 37).

Ipak, s obzirom na dostupnost, cijenu, široku primjenu i dijagnostičku vrijednost u kliničkom i forenzičnom kontekstu, ortopantomogram ostaje osobito važan u razvoju

automatiziranih sustava za registraciju zubnog statusa. Osim što omogućuje pregled svih zuba i brojnih restaurativnih i patoloških promjena na jednoj slici, OPG je i najčešće korišten oblik slikovne dokumentacije u velikom broju dosadašnjih istraživanja primjene umjetne inteligencije u dentalnoj radiologiji (39, 41, 42).

Istodobno, interpretacija OPG snimaka povezana je s određenim ograničenjima. Projekcijska priroda panoramske snimke, preklapanje anatomskih struktura, prisutnost artefakata, razlike u ekspoziciji i pozicioniranju pacijenta te heterogena kvaliteta slike mogu utjecati na pouzdanost radiološke procjene (31, 43, 44). Upravo zbog tih izazova OPG predstavlja i zahtjevan, ali metodološki vrlo važan temelj za razvoj automatiziranih sustava detekcije i segmentacije dentalnih struktura.

1.5. Razvoj i vrste umjetne inteligencije

Umjetna inteligencija (UI) predstavlja interdisciplinarno područje računalnih znanosti usmjereno na razvoj sustava sposobnih za izvođenje zadataka koji zahtijevaju elemente ljudske inteligencije, uključujući učenje, zaključivanje, prepoznavanje uzoraka i donošenje odluka. Njezin razvoj rezultat je dugotrajnog znanstvenog napretka u području matematike, računalnih znanosti, neuroznanosti i kognitivne psihologije (45-47).

Počeci umjetne inteligencije sežu u sredinu 20. stoljeća, kada su se pojavili prvi teorijski pokušaji oblikovanja strojeva sposobnih za simulaciju ljudskog mišljenja. U tom je kontekstu Alan Turing 1950. godine predložio koncept strojnog testiranja inteligencije, poznat kao Turingov test, koji se smatra jednim od prvih formalnih pokušaja definiranja inteligentnog ponašanja stroja (45, 46). Daljnji važan korak predstavljala je Dartmouth konferencija 1956. godine, na kojoj je pojam umjetne inteligencije prvi put formalno uveden u znanstveni diskurs. U tom su razdoblju razvijeni i prvi algoritmi za logičko zaključivanje i rješavanje problema, čime su postavljeni temelji simboličke umjetne inteligencije (46). Tijekom 1970-ih i 1980-ih godina razvijeni su ekspertni sustavi koji su, primjenom baza znanja i pravila zaključivanja, simulirali donošenje odluka stručnjaka u određenim područjima (47).

Napredak računalne tehnologije tijekom 1990-ih i početkom 21. stoljeća omogućio je snažniji razvoj algoritama strojnog učenja, odnosno sustava koji uče iz podataka umjesto da budu isključivo eksplicitno programirani (48). Time je omogućen razvoj adaptivnih modela sposobnih za obradu velikih količina podataka i prepoznavanje složenih obrazaca.

Dodatni zamah razvoju umjetne

inteligencije dao je razvoj dubokog učenja početkom 2010-ih godina, kada su višeslojne neuronske mreže omogućile značajna poboljšanja u analizi slika, prepoznavanju govora i obradi prirodnog jezika (49). U medicini i stomatologiji umjetna inteligencija intenzivnije se primjenjuje upravo u posljednjem desetljeću, osobito u analizi medicinskih slika i automatizaciji dijagnostičkih procesa (50).

Među temeljnim konceptima umjetne inteligencije osobito su važni strojno učenje, duboko učenje, neuronske mreže, obrada prirodnog jezika i računalni vid (48-51). Strojno učenje obuhvaća skup metoda koje omogućuju računalnim sustavima učenje iz podataka i postupno poboljšavanje performansi bez potrebe za izravnim programiranjem svakog pojedinog koraka (48). Duboko učenje predstavlja podskup strojnog učenja koji se temelji na višeslojnim neuronskim mrežama i posebno je prikladan za obradu složenih podataka, poput radioloških slika i zvučnih zapisa (49). Računalni vid predstavlja područje umjetne inteligencije usmjereno na analizu digitalnih slika i videozapisa, a u stomatologiji ima osobitu važnost jer omogućuje automatiziranu analizu radiografskih snimaka i identifikaciju anatomskih struktura (50).

Umjetna inteligencija može se klasificirati prema razini složenosti i funkcionalnosti na slabu, opću i superinteligenciju. Slaba umjetna inteligencija odnosi se na sustave razvijene za izvršavanje specifičnih zadataka te obuhvaća većinu suvremenih sustava primijenjenih u medicinskoj dijagnostici i analizi slika (51). Takvi sustavi mogu postići vrlo visoku razinu uspješnosti u sklopu usko definirane domene, ali nemaju sposobnost opće inteligencije niti razumijevanja konteksta izvan područja za koje su razvijeni. Opća umjetna inteligencija predstavlja teorijski koncept sustava koji bi mogli obavljati bilo koji intelektualni zadatak

jednako uspješno kao čovjek, dok superinteligencija označava hipotetski oblik umjetne inteligencije koji bi nadmašio ljudsku inteligenciju u svim područjima (52).

Osim prema funkcionalnoj razini, umjetna inteligencija može se klasificirati i prema načinu učenja algoritama. Kod nadziranog učenja modeli se vježbaju na označenim skupovima podataka u kojima je unaprijed poznat točan rezultat, zbog čega je taj pristup osobito važan u medicinskom snimanju i dijagnostičkoj klasifikaciji (48). Nenadzirano učenje koristi se za otkrivanje skrivenih obrazaca i struktura u neoznačenim podacima (49). Učenje potkrepljenjem temelji se na interakciji algoritma s okolinom, pri čemu sustav uči optimizirati svoje ponašanje na temelju nagrada i kazni (51). U kontekstu medicinskog i dentalnog snimanja, najveću praktičnu važnost imaju upravo nadzirano učenje, duboko učenje i računalni vid, jer čine temelj suvremenih sustava za automatiziranu analizu radioloških slika.

1.6. Tipovi učenja i računalni vid

Nadzirano učenje predstavlja dominantan pristup u analizi radioloških slika jer se modeli vježbaju na označenim skupovima podataka u kojima je unaprijed poznat točan ishod (53-56). U takvom pristupu stručnjaci označavaju anatomske strukture ili patološke promjene, a model uči povezivati obilježja slike s odgovarajućim izlazom. Upravo je ovaj oblik učenja od ključne važnosti u zadacima detekcije i segmentacije, jer omogućuje razvoj modela sposobnih za prepoznavanje zuba, restorativnih zahvata i drugih obilježja na ortopantomografskim snimkama (57). S obzirom na to da se i ovo istraživanje temelji na stručno anotiranim radiografskim snimkama, nadzirano učenje predstavlja njegov metodološki temelj.

Nenadzirano učenje primjenjuje se na neoznačenim skupovima podataka, pri čemu algoritam samostalno prepoznaje skrivene obrasce i odnose među podacima (57). Takvi pristupi mogu se koristiti za grupiranje sličnih uzoraka, otkrivanje latentnih struktura i preliminarnu analizu velikih baza radiografskih snimaka (57-59). Iako nenadzirano učenje

nema središnju ulogu u ovom istraživanju, važno je kao konceptualni okvir za razumijevanje širih mogućnosti računalne analize dentalnih slika.


Za ovo istraživanje osobitu važnost ima računalni vid, kao područje umjetne inteligencije usmjereno na analizu i interpretaciju slikovnih podataka. U medicini i stomatologiji računalni vid omogućuje automatiziranu obradu radiografskih snimaka, identifikaciju anatomskih struktura te prepoznavanje patoloških i terapijskih promjena (50-56). U dentalnoj radiologiji njegova se primjena posebno ističe u zadacima detekcije zuba, segmentacije dentalnih struktura i registracije zubnog statusa na ortopantomogramima (57-60).

S obzirom na ciljeve ove disertacije, upravo kombinacija nadziranog učenja i računalnog vida čini metodološku osnovu provedenog istraživanja. Detekcija zuba i segmentacija zuba te stomatoloških zahvata na ortopantomografskim snimkama zahtijevaju modele koji mogu pouzdano učiti iz velikog


broja označenih primjera i zatim generalizirati naučene obrasce na nove slike. Stoga suvremeni sustavi dubokog učenja u dentalnoj radiologiji ne predstavljaju samo tehnički alat za obradu slike, nego i ključni korak prema standardiziranijoj, objektivnijoj i bržoj analizi radiografskih nalaza (57-60).

1.7. Konvolucijske neuronske mreže

Konvolucijske neuronske mreže (KNN) predstavljaju jednu od najvažnijih arhitektura dubokog učenja za analizu slikovnih podataka, osobito u području medicinskog snimanja. Njihova je arhitektura prilagođena obradi dvodimenzionalnih i trodimenzionalnih slikovnih zapisa te omogućuje automatsko učenje hijerarhijskih značajki iz ulaznih podataka bez potrebe za ručnim definiranjem relevantnih obilježja, Slika 4. (61). Za razliku od tradicionalnih algoritama strojnog učenja, kod kojih se značajke moraju unaprijed odabrati i definirati, KNN sustavi mogu samostalno prepoznavati obrasce, oblike i složene odnose u slikama, što ih čini osobito prikladnima za primjenu medicinskoj dijagnostici i analizi radioloških snimaka, Slika 5, Slika 6. (62, 44).




Slika 4. Primjer izlaza modela za segmentaciju zuba: ulazna slika, ručna anotacija, predikcija modela, konačni izlaz modela i razlika između ručne anotacije i izlaza modela.



Slika 5. Primjer segmentacijskog izlaza modela s prikazom ulazne slike, ručne anotacije, predikcije, konačnog binariziranog izlaza i razlike između anotacije i izlaza.

Arhitektura KNN-a sastoji se od konvolucijskih slojeva, slojeva objedinjavanja (pooling layers) i potpuno povezanih slojeva.



Slika 6. Prikaz postupka obrade segmentacijskog rezultata i razlike između ručne anotacije i izlaza neuronske mreže.

Konvolucijski slojevi omogućuju izdvajanje osnovnih vizualnih obilježja, poput rubova, kontrastnih prijelaza i tekstura, dok pooling slojevi smanjuju dimenzionalnost podataka i povećavaju otpornost modela na manje varijacije u prikazu slike (61, 31). U kasnijim slojevima mreže postupno se uče složeniji obrasci koji omogućuju prepoznavanje anatomskih struktura i patoloških promjena. Upravo ta sposobnost hijerarhijskog učenja čini KNN modele posebno učinkovitim u obradi radioloških snimaka (61, 63).

U medicinskoj dijagnostici KNN modeli danas se primjenjuju u analizi različitih slikovnih modaliteta, uključujući CT, MRI i radiografske snimke, gdje su u brojnim istraživanjima pokazali visoku razinu osjetljivosti i točnosti (64, 65). U dentalnoj medicini njihova se primjena osobito ističe u detekciji i segmentaciji zuba, analizi restaurativnih zahvata, procjeni parodontnih promjena te prepoznavanju karijesa, fraktura i drugih patoloških nalaza (66, 37, 63). Zbog sposobnosti učenja iz velikih skupova označenih podataka, KNN modeli omogućuju standardiziraniju i objektivniju analizu radiografskih nalaza te smanjuju varijabilnost među promatračima (67, 68).

Jedan od važnih metodoloških aspekata pri razvoju KNN modela odnosi se na izbor strategije vježbanja. Modeli se mogu razvijati treningom od početka (trained from scratch) ili primjenom transfernog učenja, pri čemu se koriste prethodno uvježbani modeli (pre-trained models) koji se dodatno prilagođavaju novom zadatku. U analizi medicinskih slika prethodno uvježbani modeli često postižu bržu konvergenciju i dobre rezultate čak i u uvjetima manjih skupova podataka, dok modeli uvježbani od početka omogućuju potpunije prilagođavanje specifičnostima ciljane domene. Usporedba tih pristupa prikazana je u Tablici 1., a upravo je njihov odnos jedan od važnih metodoloških elemenata i u ovom istraživanju, osobito u zadatku detekcije zuba na ortopantomografskim snimkama.

Tablica 1. Usporedba između prethodno uvježbanih modela i modela uvježbanih od početka

Karakteristika	Prethodno uvježbani modeli(pre-trained models)	Modeli uvježbani od početka (Trained from scratch)
Performanse	Često postižu višu početnu točnost zahvaljujući već naučenim reprezentacijama značajki iz velikih skupova podataka	Performanse ovise o veličini i kvaliteti dostupnog skupa podataka te često zahtijevaju opsežno vježbanje kako bi dostigli razinu pre-trained modela
Vrijeme vježbanja	Brža konvergencija modela jer su osnovne značajke već naučene	Dulje vrijeme vježbanja jer model mora naučiti sve značajke od početka
Veličina skupa podataka	Učinkoviti i pri manjim skupovima označenih podataka zahvaljujući transfer learning	Za postizanje dobre generalizacije potreban je velik i raznolik skup podataka
Vrijeme vježbanja	Niži računalni trošakzbog kraćeg vremena vježbanja	Veći računalni zahtjevi zbog duljeg procesa vježbanja i optimizacije
Računalni zahtjevi	Djelomično ograničena znanjem stečenim na izvornom skupu podataka	Potpuna fleksibilnost za učenje specifičnih značajki nove domene
Fleksibilnost modela	Djelomično ograničena znanjem stečenim na izvornom skupu podataka	Potpuna fleksibilnost za učenje specifičnih značajki nove domene
Prednosti	Omogućuju postizanje dobrih rezultata i u uvjetima ograničenog broja slika ili niže rezolucije podataka	Omogućuju potpuno prilagođavanje modela specifičnim značajkama medicinskih ili dentalnih slika
Ograničenja	Performanse mogu biti ograničene ako su modeli prethodno uvježbani na skupovima prirodnih slika koji se razlikuju od medicinskih podataka	Zahtijevaju velik broj označenih podataka i dulje vrijeme optimizacije

Tablica 1. prikazuje temeljne razlike između prethodno uvježbanih modela i modela uvježbanih od početka, s obzirom na veličinu skupa podataka, vrijeme vježbanja, računalne zahtjeve i mogućnost prilagodbe specifičnostima dentalne radiološke domene. U dentalnoj radiologiji posebno je važno da modeli mogu pouzdano generalizirati rezultate unatoč razlikama u kvaliteti snimki, anatomskoj varijabilnosti i prisutnosti artefakata. Stoga su kvaliteta i reprezentativnost skupa podataka, kao i preciznost stručne anotacije, ključni za razvoj pouzdanih KNN sustava (33, 69). Nedostatak standardiziranih skupova podataka i varijabilnost u označavanju dentalnih struktura i dalje predstavljaju važan izazov u njihovoj primjeni. Osim toga, iako KNN modeli postižu vrlo visoku razinu uspješnosti, njihova interpretabilnost i integracija u klinički radni tijek ostaju važna pitanja za daljnji razvoj (33, 68, 70).

U ovom istraživanju uspoređene su obje strategije vježbanja modela kako bi se procijenio njihov utjecaj na uspješnost detekcije zuba i segmentacije dentalnih zahvata na ortopantomografskim snimkama. Njihova primjena omogućuje sustavnu usporedbu različitih arhitektura, razlučivosti ulazne slike i strategija vježbanja, čime se može preciznije procijeniti koji čimbenici najviše utječu na uspješnost automatizirane registracije zubnog statusa.

1.8. Modeli za detekciju objekata i računalni vid – YOLO

Računalni vid predstavlja jedno od najvažnijih područja primjene umjetne inteligencije u medicinskom snimanju. Njegov je cilj omogućiti računalnim sustavima automatsko prepoznavanje, lokalizaciju i interpretaciju vizualnih informacija na digitalnim slikama i snimkama. U medicini i stomatologiji računalni vid omogućuje automatiziranu analizu radiografskih i trodimenzionalnih snimaka, čime se povećavaju brzina, objektivnost i dosljednost dijagnostičkih postupaka (51, 52, 57, 58). Upravo zbog toga računalni vid zauzima važno mjesto u razvoju sustava za automatiziranu analizu ortopantomograma i registraciju zubnoga statusa.

Jedan od najznačajnijih pristupa u području računalnog vida jest YOLO (You Only Look Once), arhitektura za detekciju objekata u stvarnom vremenu (53-56). Za razliku od ranijih

metoda koje analiziraju sliku u više uzastopnih koraka, YOLO pristup omogućuje detekciju objekata jednim prolaskom kroz neuronsku mrežu. Time se postiže vrlo velika brzina obrade uz zadržavanje visoke razine točnosti, što ovu arhitekturu čini posebno pogodnom za primjenu u analizi većeg broja medicinskih slika (71).

Osnovna ideja YOLO modela jest da se slika promatra kao cjelina, pri čemu mreža istodobno procjenjuje položaj objekata i njihovu pripadnost određenim klasama. U klasičnoj izvedbi YOLO pristupa slika se dijeli na mrežu ćelija, a svaka ćelija predviđa granice objekta i vjerojatnost njegove pripadnosti određenoj kategoriji (71, 72). Takav pristup omogućuje detekciju više objekata na jednoj slici i istodobno zadržava visoku računalnu učinkovitost.

Arhitektura YOLO modela u osnovi se sastoji od triju funkcionalnih dijelova: backbone, neck i head modula (71-73). Backbone je odgovoran za ekstrakciju značajki iz slike i prepoznavanje osnovnih vizualnih elemenata, poput rubova, oblika i tekstura. Neck modul služi integraciji informacija dobivenih iz različitih razina mreže, čime se poboljšava sposobnost detekcije objekata različitih veličina. Head modul odgovoran je za konačnu lokalizaciju objekata i njihovu klasifikaciju (71-73). Zahvaljujući takvoj strukturi, YOLO modeli mogu učinkovito analizirati cijelu sliku i prepoznati više anatomskih ili patoloških struktura u sklopu istog radiograma.

U dentalnoj medicini YOLO modeli osobito su važni u zadacima automatske detekcije zuba, restorativnih zahvata i pojedinih patoloških promjena na ortopantomogramima (74-77). Sustavi temeljeni na ovoj arhitekturi mogu automatski identificirati položaj zuba, prepoznati pojedine terapijske zahvate te detektirati promjene poput periapikalnih lezija, fraktura i drugih radiološki vidljivih nalaza (78-81). Takva primjena osobito je važna u

panoramskoj radiologiji, gdje jedna snimka istodobno sadrži velik broj anatomskih struktura i mogućih patoloških ili terapijskih nalaza.

Primjena YOLO modela omogućuje znatno ubrzanje analize radiografskih snimaka jer sustav može obraditi velik broj slika u kratkom vremenu (78-80). To je osobito važno u kliničkim sustavima s velikim brojem pacijenata, ali i u istraživanjima i forenzičkim situacijama u kojima je potrebno brzo

pretražiti velike baze snimaka. Dodatna prednost YOLO arhitekture jest mogućnost rada u stvarnom vremenu, što otvara mogućnost integracije takvih sustava u svakodnevni klinički rad i pružanje neposredne potpore liječniku tijekom interpretacije snimke (72).

Osim brzine, važna prednost YOLO modela jest i povećanje standardizacije dijagnostičkog procesa. Budući da algoritam analizira slike prema unaprijed definiranim pravilima učenja i konzistentno primjenjuje isti obrazac procjene na svaki ulaz, smanjuje se varijabilnost među kliničarima i povećava ponovljivost rezultata (73). U tom smislu sustavi temeljeni na računalnom vidu ne predstavljaju samo sredstvo ubrzanja rada, nego i alat za povećanje objektivnosti i ujednačenosti radiološke interpretacije.

Unatoč navedenim prednostima, postoje i određena ograničenja primjene YOLO modela. Njihova točnost uvelike ovisi o kvaliteti i reprezentativnosti podataka korištenih za vježbanje (72). Ako su podaci ograničeni, neuravnoteženi ili nereprezentativni za stvarne kliničke uvjete, performanse modela mogu biti smanjene. U dentalnoj radiologiji dodatni problem predstavljaju artefakti na snimkama, poput metalnih ispuna, krunica, implantata i ortodontskih bravica, koji mogu otežati detekciju objekata i smanjiti preciznost algoritma (77). Takva ograničenja posebno su važna pri analizi ortopantomograma, gdje projekcijska priroda slike i prisutnost više struktura mogu dodatno povećati složenost zadatka. Razvoj novijih verzija YOLO modela omogućio je značajna poboljšanja u pogledu točnosti, brzine obrade i detekcije manjih objekata. Moderne inačice, poput YOLOv5 i YOLOv8, pokazuju bolju generalizaciju na različite skupove podataka i veću osjetljivost na finije radiološke detalje (71-73, 78-82). Upravo zbog tih obilježja YOLOv5 arhitektura odabrana je i u ovom istraživanju kao temelj za analizu detekcije zuba na ortopantomografskim snimkama.

1.9. Primjena UI-ja u medicini i dentalnoj medicini

Primjena umjetne inteligencije u medicini i dentalnoj medicini posljednjih godina snažno se proširila zahvaljujući većim računalnim kapacitetima, dostupnosti digitalnih podataka i razvoju algoritama dubokog učenja. U medicini se takvi sustavi koriste za analizu radioloških slika, automatsku identifikaciju anatomske strukture i patoloških promjena te za prediktivne modele koji pomažu u procjeni ishoda i planiranju terapije (65, 83-88, 89-92.). U stomatologiji je njihova primjena osobito

važna u obradi radioloških i trodimenzionalnih snimaka, gdje omogućuju detekciju karijesa, fraktura i parodontnih promjena, automatiziranu segmentaciju i registraciju dentalnog statusa te ubrzanje dijagnostičkog rada, osobito u kliničkim i forenzičnim sustavima s velikom količinom podataka (11-17, 93-99).

Posebno je važno da umjetna inteligencija u dentalnoj radiologiji ne pridonosi samo brzini obrade, nego i većoj reproducibilnosti i standardizaciji analize. Rad Vodanovića i suradnika ističe da primjena UI-ja u dentalnoj dijagnostici može unaprijediti analizu ortopantomograma, identifikaciju restorativnih radova i periapikalnih lezija te integraciju podataka iz različitih slikovnih modaliteta (100). Sustavi dubokog učenja, uključujući KNN i YOLO arhitekture, pritom imaju ulogu potpore kliničkom odlučivanju, dok konačna interpretacija i dalje ostaje odgovornost stručnjaka.

Konvolucijske neuronske mreže pokazale su se osobito učinkovitima u analizi slikovnih podataka jer omogućuju automatsko učenje hijerarhijskih značajki iz velikih skupova označenih slika. Za razliku od tradicionalnih metoda strojnog učenja, ne zahtijevaju ručno definiranje značajki, nego samostalno prepoznaju relevantne obrasce na razini piksela, što ih čini posebno prikladnima za analizu radioloških snimaka. U dentalnoj medicini takvi modeli imaju velik potencijal u detekciji karijesa, segmentaciji zuba, procjeni parodontnoga gubitka kosti, identifikaciji implantata i analizi periapikalnih lezija, dok se u forenzičkom području primjenjuju i u analizi dobi, spola i morfoloških obilježja denticije (7, 36, 66).

Temeljni zadaci automatizirane registracije dentalnog statusa uključuju detekciju zuba, segmentaciju dentalnih zahvata i klasifikaciju patoloških promjena. Za detekciju objekata često se primjenjuju YOLO modeli, dok se za segmentaciju koriste UNet i srodne arhitekture. Međutim, unatoč obećavajućim rezultatima, usporedba različitih modela, njihovih varijanti i parametara još uvijek nije dovoljno sustavno razrađena u kontekstu dentalne i osobito forenzične primjene. To se posebno odnosi na utjecaj kvalitete ulaza, razlučivosti slike i izbora strategije vježbanja na konačne rezultate modela.

Kliničke prednosti automatizirane dentalne radiološke analize uključuju bržu obradu podataka, veću dijagnostičku ujednačenost, smanjenje subjektivnosti i povećanje ukupne učinkovitosti rada (36, 37, 66, 67, 69). Automatizirani sustavi mogu u kratkom vremenu analizirati radiološku snimku, označiti sumnjive regije i pružiti preliminarnu potporu interpretaciji, čime se smanjuje opterećenje kliničara i povećava protočnost rada. Istodobno, takvi sustavi pridonose standardizaciji analize jer primjenjuju iste kriterije na sve snimke, čime se smanjuju utjecaji umora, iskustva i individualnih razlika među promatračima (36, 37, 61, 66, 69).

YOLO modeli korišteni su u ovom istraživanju te predstavljaju temeljni pristup za analizu detekcije zuba na ortopantomografskim snimkama. Njihova primjena omogućuje sustavnu procjenu utjecaja razlučivosti slike, arhitekture modela i strategije vježbanja na konačnu uspješnost detekcije, čime računalni vid postaje ne samo tehnički alat, nego i važan metodološki okvir za istraživanje mogućnosti automatizirane registracije zubnog statusa.

1.10. Automatizirano otkrivanje i segmentacija zuba na ortopantomogramima

Ortopantomogrami predstavljaju jednu od najčešće korištenih radiografskih metoda u stomatološkoj praksi jer omogućuju prikaz cjelokupne denticije, alveolarnih nastavaka te okolnih anatomskih struktura na jednoj slici (38, 39). Zbog takve preglednosti OPG ima važnu ulogu u kliničkoj dijagnostici, planiranju terapije i forenzičnoj identifikaciji. Istodobno, interpretacija ortopantomograma zahtijeva značajnu stručnost i može biti podložna

međupromatračkoj varijabilnosti, osobito u složenim slučajevima i prilikom prisutnosti brojnih restaurativnih zahvata ili artefakata (3).

Automatizirano otkrivanje i segmentacija zuba na ortopantomogramima predstavljaju važan smjer razvoja računalne analize dentalnih radiografskih snimaka. U tom kontekstu razlikuju se tri temeljna zadatka: detekcija, segmentacija i klasifikacija. Detekcija podrazumijeva lokalizaciju zuba ili drugih struktura na slici, najčešće s pomoću omeđujućih okvira. Segmentacija omogućuje precizno izdvajanje pojedinih zuba ili dentalnih zahvata na razini piksela, dok klasifikacija služi određivanju vrste promjene ili statusa promatrane strukture (66, 42).

U suvremenim istraživanjima za detekciju zuba i drugih objekata na ortopantomogramima najčešće se primjenjuju modeli iz skupine detektora objekata, poput YOLO arhitektura, dok se za segmentacijske zadatke češće koriste encoder-decoder modeli, kao što su UNet, FCN i DeepLabV3 (20, 21, 38, 42, 43, 69, 101-109). Takva podjela proizlazi iz prirode samog zadatka: detekcija zahtijeva brzu i

pouzdanu lokalizaciju većeg broja objekata na jednoj slici, dok segmentacija zahtijeva precizno odvajanje zuba ili zahvata od okolnih struktura.

Pregled najčešćih zadataka i odgovarajućih arhitektura dubokog učenja u analizi ortopantomograma prikazan je u Tablici 2.

Tablica 2. Najčešći zadaci i arhitekture dubokog učenja u analizi ortopantomograma

Zadatak	Primjena u analizi OPG-a	Tipične arhitekture	Tipičan pristup učenju
Detekcija i numeracija zuba	Pronalaženje zuba i standardizirano označavanje.	YOLO, Faster R-CNN, Mask R-CNN, CNN detektori.	Prethodno uvježbani modeli kod manjih skupova; vježbanje od početka kod velikih anotiranih OPG baza.
Segmentacija zuba	Precizno odvajanje zuba od okolnih struktura.	U-Net, Mask R-CNN, DeepLab, FCN, attention U-Net.	Prethodno uvježbani encoder kod ograničenih podataka;

			od početka kod piksel-po-piksel anotacija.
Detekcija i segmentacija karijesa	Prepoznavanje i lokalizacija karijesnih lezija.	CNN, YOLO, Faster R-CNN, U-Net, nested U-Net.	Transfer learning za klasifikaciju; vježbanje od početka za preciznu segmentaciju lezija.
Procjena dentalne dobi i spola	Forenzička procjena dobi i spola iz dentalnih i mandibularnih značajki.	VGG, ResNet, DenseNet, EfficientNet, custom CNN.	Prethodno uvježbani modeli kod ograničenih podataka; specifično vježbanje kod velikih populacijskih baza.
Forenzička identifikacija	Usporedba antemortem i postmortem OPG-a ili dentalnog statusa.	Siamese CNN, VGG, ResNet, embedding mreže.	Prethodno uvježbani backbone za izdvajanje značajki; od početka za specifične identifikacijske sustave.
Restauracije, protetika i implantati	Prepoznavanje ispuna, krunica, mostova, implantata i endodontskih tretmana.	YOLO, Faster R-CNN, Mask R-CNN, ViT, CNN detektori.	Transfer learning za osnovnu detekciju; od početka kod više specifičnih klasa i velikih anotiranih skupova.
Impaktirani zubi	Detekcija impakcije, položaja i odnosa prema okolnim strukturama.	YOLO, Faster R-CNN, RT-DETR, CNN-transformer hibridi.	Transfer learning kod osnovne detekcije; specifično vježbanje kod složenih anatomskih odnosa.
Patološke promjene	Detekcija periapikalnih lezija, cista, tumora i drugih promjena.	CNN, YOLO, Faster R-CNN, U-Net, DeepLab, ViT.	Prethodno uvježbani modeli za klasifikaciju/detekciju; od početka za preciznu segmentaciju lezija.
Parodontni gubitak kosti	Detekcija i mjerenje alveolarnog gubitka kosti.	CNN, U-Net, segmentation CNN, regression CNN.	Transfer learning za klasifikaciju stupnja; od početka za kvantitativnu segmentaciju kosti.

Registracija dentalnih slika	Poravnanje OPG-a, CBCT-a, intraoralnih skenova i 3D modela.	U-Net, VoxelMorph, Siamese CNN, encoder-decoder CNN i spatial transformer networks.	Transfer learning iz medicinske registracije; od početka kod dentalno specifičnih 2D/3D sustava.
Kontrola kvalitete OPG-a	Procjena artefakata, pozicioniranja i dijagnostičke upotrebljivosti snimke.	CNN, ResNet, EfficientNet, Vision Transformer.	Prethodno uvježbani modeli za klasifikaciju kvalitete; od početka kod specifičnih uređaja ili protokola.
CNN i transformer modeli	Usporedba lokalnog prepoznavanja CNN-a i globalnog konteksta transformera.	CNN, ViT, Swin Transformer, CNN-transformer hibridi.	CNN češće kod manjih skupova i lokalnih struktura; transformeri kod većih skupova i globalnog konteksta.

Iz prikazanog pregleda vidljivo je da se za zadatke detekcije najčešće primjenjuju modeli koji istodobno analiziraju cijelu sliku i lokaliziraju objekte, dok se za segmentaciju koriste arhitekture koje omogućuju preciznu pikselnu klasifikaciju. Takva podjela predstavlja i metodološku osnovu ovoga istraživanja, u kojem su YOLOv5 modeli korišteni za detekciju zuba, a UNet, FCN i DeepLabV3 arhitekture za segmentaciju zuba i dentalnih zahvata.

Dosadašnja istraživanja pokazala su da automatizirani sustavi mogu postići visoku uspješnost u detekciji i segmentaciji dentalnih struktura na OPG snimkama (20, 21, 38, 42, 43, 69, 101-109). Posebno se ističe mogućnost brze analize velikog broja slika, standardizacije interpretacije te smanjenja međupromatračke varijabilnosti. Ujedno, takvi sustavi mogu služiti kao osnova za daljnju analizu karijesa, restorativnih zahvata, implantata i drugih klinički važnih obilježja (42, 66).

Međutim, uspješnost modela i dalje ovisi o nizu čimbenika. Među najvažnijima su kvaliteta i razlučivost ulazne slike, prisutnost artefakata, složenost anatomskog konteksta te izbor odgovarajuće arhitekture i strategije vježbanja (38, 91, 105). Poseban izazov predstavljaju

panoramske snimke s brojnim restauracijama, superpozicijama i varijabilnim kontrastom, gdje se preciznost detekcije i segmentacije može smanjiti (107). Stoga je pri razvoju automatiziranih sustava nužno istodobno uzeti u obzir i vrstu zadatka i karakteristike ulaznih podataka.

U kontekstu ove disertacije osobito je važno da dosadašnja literatura, unatoč velikom broju radova, još uvijek ne daje dovoljno sustavan odgovor na pitanje kako na uspješnost modela utječu razlučivost slike, vrsta ulaza i strategija vježbanja. Upravo zato automatizirano otkrivanje i segmentacija zuba na ortopantomogramima ne predstavljaju samo tehnički izazov, nego i važno metodološko područje istraživanja u kojem se mogu preciznije definirati uvjeti za razvoj pouzdanih sustava za automatiziranu registraciju dentalnog statusa.

1.11. Izazovi, perspektive te etičke i regulatorne implikacije primjene umjetne inteligencije u dentalnoj radiologiji

Unatoč značajnom napretku u primjeni metoda dubokog učenja u dentalnoj radiologiji, razvoj pouzdanih i klinički primjenjivih sustava i dalje je povezan s nizom metodoloških i tehničkih izazova. Točnost modela u velikoj mjeri ovisi o kvaliteti i reprezentativnosti podataka na kojima su uvježbani. Varijacije u razlučivosti, kontrastu, ekspoziciji i pozicioniranju pacijenta mogu značajno utjecati na sposobnost modela da prepozna anatomske strukture i patološke promjene (37, 61). To je osobito važno u analizi ortopantomograma, gdje projekcijska priroda slike, prisutnost superpozicija i heterogena kvaliteta snimki dodatno povećavaju složenost interpretacije (31, 43, 44).

Jedan od ključnih izazova odnosi se na veličinu i reprezentativnost skupova podataka. Razvoj robusnih modela zahtijeva velike, dobro anotirane i demografski raznolike baze radiografskih snimaka. Međutim, dostupnost takvih standardiziranih skupova podataka u dentalnoj radiologiji i dalje je ograničena, što može negativno utjecati na generalizaciju modela u različitim populacijama i kliničkim uvjetima (89, 90). Dodatni problem predstavlja preciznost anotacije podataka. Budući da ručnu segmentaciju i označavanje struktura provode stručnjaci, kvaliteta oznaka može biti opterećena određenom razinom subjektivnosti i međupromatračke varijabilnosti, osobito kod dijagnostički zahtjevnijih slučajeva (69).

Važan metodološki izazov predstavlja i izbor strategije vježbanja modela. U analizi medicinskih slika često se primjenjuje transfer learning, pri čemu se modeli prethodno uvježbani na velikim skupovima prirodnih slika dodatno prilagođavaju medicinskim podacima. Takav pristup može biti koristan u uvjetima ograničenog broja označenih slika, ali njegova učinkovitost ovisi o sličnosti između izvornog i ciljnog domenskog problema (110, 111). U području dentalne radiologije još uvijek nije u potpunosti razjašnjeno u kojim uvjetima transfer learning daje stvarnu prednost u odnosu na modele uvježbane od početka. Posebno važan, ali nedovoljno istražen čimbenik jest utjecaj razlučivosti ulazne slike na performanse modela. Različite rezolucije radiografskih snimaka mogu utjecati na sposobnost modela da prepozna fine anatomske detalje i manje patološke promjene, no sustavna analiza optimalne razlučivosti za

detekciju i segmentaciju dentalnih struktura još uvijek je ograničena (112). Slično tomu, sve je više istraživanja koja upućuju na važnost vrste ulazne slike, odnosno razlike između analize cijelog ortopantomograma i lokaliziranih prikaza pojedinačnih ili segmentiranih zuba (113).

Dodatni izazov u analizi ortopantomograma predstavljaju artefakti uzrokovani metalnim ispunama, kronicama, implantatima i ortodontskim elementima. Takvi artefakti mogu degradirati kvalitetu slike, otežati razlikovanje anatomske strukture i smanjiti preciznost modela (41, 105, 114). Uz to, velika anatomsko-morfološka varijabilnost pacijenata, uključujući razlike u položaju zuba, gustoći kosti i prisutnosti ranije provedenih terapijskih zahvata, zahtijeva modele koji mogu pouzdano generalizirati rezultate na heterogenim skupovima podataka (43, 61, 63).

Unatoč navedenim ograničenjima, dosadašnja istraživanja potvrđuju da umjetna inteligencija ima veliki potencijal u kliničkoj i forenzičnoj stomatologiji. Automatizirani sustavi mogu pridonijeti bržoj obradi radioloških snimaka, većoj standardizaciji interpretacije i smanjenju subjektivnosti dijagnostičkog procesa (11, 98, 99). U kliničkom okruženju takvi sustavi mogu biti korisni u detekciji karijesa, fraktura, parodontnih promjena i restorativnih zahvata na panoramskim, periapikalnim i CBCT snimkama (93-97). U forenzičkom kontekstu imaju

potencijal ubrzati preliminarnu obradu i usporedbu AM i PM podataka, osobito u situacijama s velikim brojem zapisa (12-16).

Perspektive budućeg razvoja usmjerene su prema robusnijim i fleksibilnijim modelima, uključujući hibridne arhitekture koje kombiniraju konvolucijske neuronske mreže s drugim pristupima dubokog učenja, poput transformera i multimodalnih modela (42, 78, 106, 115, 116.). Budući razvoj trebao bi uključivati i veće, demografski raznolikije skupove podataka, bolju standardizaciju protokola snimanja i anotacije te integraciju različitih slikovnih modaliteta, uključujući CBCT i intraoralne skenove (35, 117-121). U tom kontekstu sve veću važnost imaju i pristupi objašnjive umjetne inteligencije, koji bi trebali povećati transparentnost algoritama i povjerenje korisnika u njihov rad (89-91, 115).

Primjena umjetne inteligencije u stomatologiji otvara i važna etička te regulatorna pitanja. Potrebno je osigurati transparentnost algoritama, zaštitu privatnosti pacijenata i sigurnost obrade medicinskih podataka (33, 62, 66). Automatizirani sustavi trebaju djelovati kao podrška kliničkom odlučivanju, dok konačna odgovornost za dijagnostičke odluke mora ostati na liječniku (33, 122). Dodatni problem predstavlja mogućnost algoritamske pristranosti ako su modeli uvježbani na nereprezentativnim podacima, što može dovesti do različite razine uspješnosti među populacijskim skupinama (43, 119, 120). Stoga je za sigurnu primjenu takvih sustava nužna ne samo tehnička validacija, nego i regulatorna usklađenost, uključujući standarde za medicinske uređaje, zaštitu podataka i auditabilnost sustava (37, 39, 41, 65, 119, 122-124).

S obzirom na navedene izazove i perspektive, jasno je da daljnji razvoj umjetne inteligencije u dentalnoj radiologiji ne ovisi samo o poboljšanju performansi modela, nego i o kvaliteti ulaznih podataka, standardizaciji metodologije, transparentnosti algoritama i mogućnosti njihove sigurne integracije u klinički i forenzični rad. Upravo ta pitanja čine važan okvir za razumijevanje istraživačke praznine i opravdanosti provedenog istraživanja.

1.12. Istraživačka praznina i opravdanost istraživanja

Unatoč značajnom napretku u primjeni umjetne inteligencije u dentalnoj radiologiji, brojna metodološka pitanja i dalje nisu dostatno razjašnjena. Posebno nedostaju sustavne usporedbe različitih arhitektura modela, strategija vježbanja, razlučivosti ulazne slike i vrste ulaznog segmenta u analizi ortopantomografskih snimaka. Dosadašnja istraživanja pretežno su usmjerena na pojedinačne zadatke ili specifične eksperimentalne uvjete, zbog čega još uvijek nije dovoljno jasno koji čimbenici u najvećoj mjeri određuju uspješnost automatizirane detekcije zuba i segmentacije dentalnih struktura i zahvata.

Dodatno, većina objavljenih radova promatra pojedine modele ili izolirane dijagnostičke zadatke, dok su istraživanja koja istodobno obuhvaćaju detekciju zuba, segmentaciju dentalnih struktura i terapijskih zahvata te usporedbu različitih pristupa obradi slike i vježbanju modela i dalje ograničena. Nedovoljno su istraženi i učinci razlučivosti slike te razlike između analize cijelog ortopantomograma i lokaliziranih prikaza pojedinačnih ili segmentiranih zuba, iako upravo ti čimbenici mogu bitno utjecati na konačnu uspješnost modela.

S obzirom na klinički i forenzični značaj pouzdane registracije zubnoga statusa, opravdano je provesti sustavno istraživanje koje će istodobno obuhvatiti različite modele dubokog učenja, različite

razlučivosti ulaznih slika te različite pristupe obradi i vježbanju podataka. Takav pristup omogućuje cjelovitiju procjenu čimbenika koji određuju uspješnost automatizirane analize ortopantomograma i pruža znanstveno utemeljenu osnovu za razvoj pouzdanijih i standardiziranih sustava u kliničkoj i forenzičnoj stomatologiji. Na temelju tako definiranog istraživačkog okvira formulirani su ciljevi i hipoteze ovoga rada.

2. HIPOTEZA I CILJEVI ISTRAŽIVANJA

2.1. Ciljevi istraživanja

Primarni cilj istraživanja bio je razviti i evaluirati modele dubokog učenja za automatiziranu detekciju zuba te segmentaciju zuba i odabranih dentalnih zahvata na ortopantomografskim snimkama, uz procjenu njihove podudarnosti s ručno anotiranim referentnim podacima.

Sekundarni ciljevi istraživanja bili su:

1. procijeniti uspješnost različitih varijanti YOLOv5 modela u zadatku detekcije zuba na ortopantomografskim snimkama
2. usporediti uspješnost različitih arhitektura konvolucijskih neuronskih mreža u zadacima segmentacije zuba, karijesa, krunica, ispuna i endodontskih punjenja
3. ispitati utjecaj razlučivosti ulazne slike na uspješnost modela u zadatku detekcije zuba
4. ispitati utjecaj tipa ulazne slike (cijeli ortopantomogram, individualni zub, segmentirani zub) na uspješnost segmentacije zuba i dentalnih zahvata
5. usporediti uspješnost modela uvježbanih od početka i modela razvijenih primjenom transfernog učenja u zadatku detekcije zuba.

2.2. Istraživačka hipoteza

Na temelju postavljenih ciljeva formulirana je sljedeća hipoteza:

Modeli temeljeni na konvolucijskim neuronskim mrežama omogućuju pouzdanu i visoko preciznu detekciju zuba te segmentaciju zuba i odabranih dentalnih zahvata na ortopantomografskim snimkama, uz visoku razinu podudarnosti s ručno anotiranim referentnim podacima.

3. METODOLOGIJA ISTRAŽIVANJA

3.1. Prikupljanje podataka

Istraživanje je provedeno na uzorku od 1400 ortopantomografskih snimaka (OPG) prikupljenih u Zavodu za dentalnu antropologiju Stomatološkog fakulteta Sveučilišta u Zagrebu. Uzorak rendgenskih snimaka obuhvaćao je odraslu populaciju s raznolikim rasponom dentalnih stanja, kako bi se osigurala reprezentativnost podataka i omogućila analiza različitih stomatoloških nalaza, uključujući ispune, krunice, mostove, endodontsko liječenje i karijes.

3.1.1. Karakteristike skupa podataka

Skup podataka sadržavao je ukupno 39.441 segmentirani zub s različitim obilježjima dentalnog statusa. U analiziranom uzorku zabilježene su sljedeće stomatološke intervencije i promjene: 420 krunica, 828 mostova, 2.172 endodontski liječena zuba, 9.869 ispuna i 795 karijesnih lezija.

3.1.2. Postupak anotacije

Anotacije je ručno izradila doktorica dentalne medicine A. Z. Č., specijalistica endodoncije sa 17 godina kliničkog iskustva, koristeći program GIMP 2.10.22, alat za grafičku obradu i anotaciju slika (36). Izrađene anotacije pregledao je iskusni stomatolog I. S. P., specijalist endodoncije.

Na ortopantomografskim snimkama pojedinačni zubi i s njima povezani stomatološki zahvati označeni su omeđujućim okvirima, Slika 7-10). Tako dobivene oznake pohranjene su u PASCAL VOC XML formatu, prikladnom za procese učenja konvolucijskih neuronskih mreža (42). Provedeni postupak anotacije osigurao je visokokvalitetne podatke za vježbanje i evaluaciju modela.




Slika 7. Segmentacija zuba na ortopantomografskoj snimci u programu GIMP



Slika 8. Segmentacija zuba na ortopantomografskoj snimci u programu GIMP



Slika 9. Prikaz segmentacije dentalnih intervencija na ortopantomografskoj snimci



Slika 10. Prikaz segmentacije dentalnih intervencija na ortopantomografskoj snimci korištenjem programa GIMP

Radi razvoja i evaluacije modela, skup podataka podijeljen je na skupove za vježbanje, validaciju i testiranje u omjeru 75%: 12,5%: 12,5%. Sukladno tome, 1.050 OPG snimaka korišteno je za vježbanje modela konvolucijskih neuronskih mreža, dok je po 175 OPG snimaka bilo uključeno u validacijski i testni skup. Validacijski skup korišten je za praćenje procesa učenja i optimizaciju modela, a testni skup za završnu procjenu njihove uspješnosti.

3.1.3. Proširenje podataka

U svrhu povećanja sposobnosti generalizacije modela i smanjenja rizika od prekomjernog prilagođavanja primijenjene su tehnike proširenja podataka. Takav pristup omogućuje simulaciju varijabilnosti koja se javlja u stvarnim kliničkim uvjetima te pridonosi većoj robusnosti modela. Prošireni skup podataka, utemeljen na kombinaciji stručno izrađenih anotacija i postupaka obrade slike, predstavljao je pouzdanu osnovu za testiranje metoda temeljenih na konvolucijskim neuronskim mrežama u analizi dentalnih radiografskih snimaka. Time su osigurani veća ponovljivost i pouzdanost dobivenih rezultata te bolja primjenjivost modela u kliničkom i forenzičkom kontekstu.

3.1.4. Etička razmatranja

Etičko odobrenje za provedbu istraživanja izdalo je Etičko povjerenstvo Stomatološkog fakulteta Sveučilišta u Zagrebu (broj odobrenja: 05-PA-30-XXX-10/2021), a istraživanje je provedeno u skladu s načelima Helsinške deklaracije. Radi zaštite privatnosti i osiguravanja usklađenosti s etičkim standardima, iz svih ortopantomografskih snimaka uklonjeni su identifikacijski podaci pacijenata. Za korištenje rendgenskih snimaka u znanstvene svrhe svi ispitanici su potpisali suglasnost.

3.2. Odabir modela

Odabir odgovarajuće arhitekture konvolucijske neuronske mreže bio je ključan za postizanje visoke uspješnosti i pouzdanosti u automatiziranoj registraciji zubnoga statusa. U ovom istraživanju primijenjeni su modeli razvijeni primjenom transfernog učenja i modeli uvježbani od početka, ovisno o prirodi pojedinog zadatka. Takav pristup omogućio je usporedbu različitih strategija vježbanja u detekciji zuba te segmentaciji zuba, restorativnih zahvata, karijesa i drugih promjena vidljivih na ortopantomografskim snimkama.

U istraživanju su korištene različite varijante arhitekture YOLOv5, i to YOLOv5s, YOLOv5s6, YOLOv5m, YOLOv5m6, YOLOv5l, YOLOv5l6, YOLOv5x i YOLOv5x6. Oznake s (small), m (medium), l (large) i x (extra large) označavaju modele različitog kapaciteta, odnosno različitog broja parametara i dubine mreže. Manje varijante imaju niže računalne zahtjeve i bržu obradu, dok veće varijante raspolažu većim kapacitetom za učenje složenijih vizualnih obrazaca, ali zahtijevaju više memorije i dulje vrijeme vježbanja.

Varijante s oznakom 6 predstavljaju izvedbe prilagođene radu s većim ulaznim razlučivostima. U odnosu na standardne YOLOv5 modele, ove varijante koriste arhitekturne prilagodbe koje omogućuju učinkovitiju obradu slika većih dimenzija, uz očuvanje finijih prostornih detalja. To ih čini osobito prikladnima za analizu ortopantomografskih snimaka, na kojima uspješnost detekcije uvelike ovisi o mogućnosti prepoznavanja sitnih anatomskih obilježja i jasnoći granica zubnih struktura.

Primjena više varijanti YOLOv5 modela omogućila je sustavnu usporedbu utjecaja kapaciteta modela i razlučivosti ulazne slike na uspješnost detekcije zuba. Time je bilo moguće procijeniti ne samo koji model postiže najbolju ukupnu uspješnost, nego i kako se pojedine arhitekture ponašaju u uvjetima različite kvalitete i veličine ulazne slike.

3.2.1. Prethodno uvježbani modeli

Prethodno uvježbani modeli temelje se na inicijalnom učenju provedenom na velikim skupovima podataka, poput COCO (Common Objects in Context), što im omogućuje prepoznavanje općih vizualnih obrazaca i osnovnih strukturnih obilježja slike. U ovom istraživanju takav je pristup primijenjen na modelima iz skupine YOLOv5 za detekciju te na dijelu segmentacijskih arhitektura, uključujući DeepLabV3 i pojedine izvedenice UNet modela. Primjena prethodno uvježbanih modela bila je osobito važna u zadacima u kojima se željela ispitati korist prijenosa prethodno naučenih značajki na dentalne radiografske podatke. U detekciji zuba prethodno uvježbani modeli korišteni su za inicijalnu identifikaciju zuba na OPG snimkama, dok su u segmentacijskim zadacima omogućili bržu prilagodbu modela specifičnim dentalnim strukturama i zahvatima. Prednost takvih modela očituje se u bržoj konvergenciji, manjoj potrebi za velikim brojem označenih dentalnih snimaka i većoj stabilnosti u uvjetima varijabilne kvalitete slike ili prisutnosti artefakata. S druge strane, prethodno uvježbani modeli imaju i određena ograničenja. Budući da su inicijalno razvijeni na skupovima prirodnih slika, njihova prilagodba specifičnim dentalnim intervencijama i rjeđim patološkim promjenama može biti ograničena. Također, moguće je da dio naučenih obilježja bude manje primjenjiv u radiološkoj dentalnoj domeni, osobito kada je riječ o finim anatomskim detaljima i visoko specifičnim kliničkim nalazima (18, 78, 79).

3.2.2. Modeli uvježbani od početka

Za zadatke koji zahtijevaju veću domenski specifičnu prilagodbu korišteni su modeli uvježbani od početka. Takvi modeli razvijeni su izravno na skupu ortopantomografskih snimaka uključenih u ovo istraživanje, bez prethodnog oslanjanja na već naučene reprezentacije iz drugih domena. Time je omogućeno učenje obilježja specifičnih za dentalne strukture, restorativne zahvate i patološke promjene vidljive na OPG snimkama.

Modeli uvježbani od početka korišteni su osobito u zadacima u kojima je bila potrebna visoka preciznost i osjetljivost na fine strukturne razlike, poput segmentacije složenijih dentalnih intervencija te analize karijesa. Njihova glavna prednost jest potpuna prilagodba obilježjima ciljnog skupa podataka, što može rezultirati boljom uspješnošću u slučajevima rijetkih, složenih ili radiološki specifičnih promjena. Takav pristup također omogućuje veću fleksibilnost u oblikovanju mrežne arhitekture, uključujući dubinu mreže, veličinu filtera i način očuvanja prostornih informacija.

Ograničenja modela uvježbanih od početka odnose se prije svega na dulje vrijeme vježbanja, veće računalne zahtjeve te veću ovisnost o količini i kvaliteti dostupnih označenih podataka. Za postizanje stabilne i pouzdane generalizacije nužan je dostatan broj reprezentativnih primjera, osobito u zadacima koji uključuju heterogene i rjeđe zastupljene nalaze (11, 78, 80).

3.2.3. Kombinirani pristup

U ovom istraživanju primijenjen je kombinirani pristup, pri čemu su prethodno uvježbani modeli korišteni u zadacima gdje se očekivala korist od prijenosa općih vizualnih reprezentacija, dok su modeli uvježbani od početka korišteni u zadacima koji su zahtijevali veću specifičnost i prilagodbu dentalnim radiografskim podacima. Takva strategija omogućila je usporedbu dvaju pristupa unutar istoga istraživačkog okvira i procjenu njihove učinkovitosti u odnosu na vrstu zadatka, kvalitetu ulazne slike i obilježja skupa podataka.

3.2.4. Arhitekture korištene u istraživanju

U istraživanju su korištene sljedeće arhitekture:

- YOLOv5 – za detekciju zuba na ortopantomografskim snimkama, uz usporedbu više varijanti modela i različitih strategija vježbanja
- DeepLabV3 – za segmentaciju zuba i dentalnih zahvata uz očuvanje prostornih informacija slike

- UNet i FCN – za detaljnu segmentaciju zuba, karijesa i dentalnih intervencija
- modeli uvježbani od početka – za zadatke u kojima je bilo potrebno ispitati učinak potpune prilagodbe dentalnom skupu podataka.

Odabir navedenih arhitektura temeljen je na njihovoj širokoj primjeni u analizi medicinskih slika, kao i na mogućnosti usporedbe detekcijskih i segmentacijskih pristupa unutar jedinstvenoga eksperimentalnog dizajna.

3.2.5. Evaluacija performansi

Odabrani modeli evaluirani su primjenom standardnih pokazatelja uspješnosti, uključujući osjetljivost, specifičnost, F1-score, preciznost i IoU (Intersection over Union). Prethodno uvježbani modeli pokazali su visoku uspješnost u prepoznavanju zuba, dok su modeli uvježbani od početka ostvarili bolje rezultate u segmentaciji složenijih restorativnih struktura (15, 79, 80, 81, 125-129). Kombinirani pristup omogućio je uravnoteženje brzine obrade i točnosti modela. Odabir arhitekture konvolucijske neuronske mreže predstavljao je važan dio ovog istraživanja, čiji je cilj bio utvrditi najučinkovitiji pristup za automatiziranu registraciju dentalnog statusa. Prethodno uvježbani modeli korišteni su u zadacima u kojima je bilo važno iskoristiti već naučene opće vizualne značajke, dok su modeli uvježbani od početka primijenjeni u zadacima koji su zahtijevali veću prilagodbu specifičnostima ortopantomografskih snimaka.

Prethodno uvježbani modeli, uključujući YOLOv5 i DeepLabV3, inicijalno su razvijeni na velikim skupovima podataka, poput COCO, što im omogućuje prepoznavanje općih obrazaca na slikama. Primjena transfernog učenja omogućila je prilagodbu tih modela dentalnim radiografskim podacima uz smanjenje vremena vježbanja i računalnih zahtjeva. Odabrane varijante arhitektura YOLOv5 i DeepLabV3 pokazale su se prikladnima za analizu medicinskih slika i omogućile usporedbu učinka različitih pristupa u detekciji i segmentaciji.

S druge strane, modeli uvježbani od početka razvijeni su izravno na skupu ortopantomografskih snimaka korištenih u ovom istraživanju. Takav pristup omogućio je modelima učenje obilježja specifičnih za dentalne strukture, uključujući morfologiju zuba i različite stomatološke zahvate, bez oslanjanja na prethodno naučene reprezentacije iz drugih domena. Ovi modeli bili su osobito prikladni za zadatke segmentacije i klasifikacije koji zahtijevaju visoku osjetljivost na fine strukturne razlike.

U segmentacijskim zadacima implementirane su napredne arhitekture poput UNet-a i FCN-a. Veće varijante UNet modela pokazale su vrlo visoku uspješnost u segmentaciji zuba, ispuna, krunica i endodontskih punjenja, zahvaljujući encoder-decoder strukturi koja omogućuje očuvanje prostornih informacija tijekom procesa segmentacije. Modeli su odabrani tako da omoguće usporedbu performansi pri različitim razlučivostima slike i u različitim zadacima, čime je osigurana sveobuhvatna procjena njihove primjenjivosti u analizi dentalnih snimaka. Ukupno gledano, kombinacija prethodno uvježbanih i modela uvježbanih od početka omogućila je iskorištavanje prednosti oba pristupa te optimizaciju detekcije i segmentacije dentalnih struktura u različitim uvjetima snimanja. Takva strategija pridonijela je većoj robustnosti i točnosti modela u zadacima automatizirane analize ortopantomograma.

3.3. Postupci vježbanja

Postupak vježbanja modela osmišljen je s ciljem optimizacije performansi konvolucijskih neuronskih mreža u zadacima detekcije i segmentacije dentalnog statusa. Vježbanje je uključivalo odgovarajuću pripremu podataka, odabir hiperparametara i korištenje prikladnih računalnih resursa kako bi se osigurali robusni i pouzdani rezultati.

Vježbanje modela provedeno je uz korištenje NVIDIA GPU grafičkih procesora s CUDA podrškom, što je omogućilo učinkovitu obradu velikog skupa podataka i slika visoke razlučivosti. Modeli su implementirani u okvirima TensorFlow i PyTorch, koji su široko

primjenjivani u razvoju sustava dubokog učenja zbog svoje fleksibilnosti i prikladnosti za vježbanje neuronskih mreža.

Skup podataka sastojao se od 1400 ručno anotiranih ortopantomografskih snimaka, podijeljenih na skupove za vježbanje, validaciju i testiranje. U skupu za vježbanje primijenjene su tehnike proširenja podataka kako bi se simulirala varijabilnost stvarnih kliničkih uvjeta. Te su tehnike uključivale transformacije poput skaliranja, rotacije i zrcaljenja slike. Dodatno je provedena analiza utjecaja rezolucije ulazne slike, pri čemu su modeli uvježbani i evaluirani na slikama različitih veličina, od 256 px do 1820 px.

Tijekom postupka vježbanja korišteni su različiti hiperparametri. Početna brzina učenja iznosila je 0,001, uz primjenu rasporeda njezina postupnog smanjivanja radi postizanja stabilnijeg procesa optimizacije. Veličina serije postavljena je na 16, kako bi se postigla ravnoteža između memorijskih zahtjeva i učinkovitosti vježbanja. Ukupan broj epoha iznosio je 100, što je omogućilo dostatno vrijeme za optimizaciju modela. Kao optimizator korišten je Adam, zbog svoje prilagodljivosti i učinkovitosti u optimizaciji dubokih neuronskih mreža.

Funkcije gubitka odabrane su u skladu s vrstom zadatka. U modelima za detekciju korištene su funkcije gubitka temeljene na unakrsnoj entropiji i fokalnom gubitku, radi boljeg nošenja s neravnotežom među klasama. U segmentacijskim modelima korištene su kombinacije Dice gubitka i binarne unakrsne entropije, kako bi se postigla što veća preciznost u određivanju granica segmentiranih struktura.

Nakon svake epohe vježbanja performanse modela procjenjivane su na validacijskom podskupu primjenom odgovarajućih metrika, uključujući preciznost, osjetljivost, srednju prosječnu preciznost i Sørensen-Diceov koeficijent. Takav pristup omogućio je pravodobno prepoznavanje prekomjernog prilagođavanja i prilagodbu hiperparametara tijekom procesa učenja. Strukturirani postupak vježbanja bio je usmjeren na razvoj robusnih, pouzdanih i prilagodljivih modela sposobnih za rješavanje izazova dentalne radiološke analize.

3.4. Metrike evaluacije

Performanse konvolucijskih neuronskih mreža analizirane su primjenom više evaluacijskih metrika, odabranih s obzirom na prirodu zadataka detekcije i segmentacije. Takav pristup omogućio je sveobuhvatnu procjenu točnosti, preciznosti i pouzdanosti modela u automatiziranoj registraciji dentalnog statusa.

3.4.1. Metrike detekcije

U zadatku detekcije naglasak je bio na identifikaciji pojedinačnih zuba i zubnih struktura na ortopantomografskim snimkama. Ključne metrike uključivale su preciznost, osjetljivost i srednju prosječnu preciznost (mAP).

Preciznost označava udio točno pozitivno klasificiranih nalaza u odnosu na sve nalaze koje je model označio kao pozitivne, odnosno mjeri pouzdanost pozitivnih predikcija modela:

$$Preciznost = \frac{IP}{IP+LP}$$


gdje je IP broj istinski pozitivnih nalaza, a LP broj lažno pozitivnih nalaza.

Osjetljivost označava udio točno pozitivno klasificiranih nalaza u odnosu na sve stvarno pozitivne nalaze te odražava sposobnost modela da prepozna relevantne objekte:

$$Osjetljivost = \frac{IP}{IP+LN}$$

gdje je LN broj lažno negativnih nalaza.

Srednja prosječna preciznost (mAP) predstavlja standardnu i jednu od najčešće korištenih metrika za procjenu uspješnosti detekcijskih modela. Ona sažima odnos preciznosti i osjetljivosti u različitim pragovima preklapanja između stvarnih i predviđenih omeđujućih okvira, odnosno pri različitim vrijednostima mjere Intersection over Union (IoU), te time omogućuje sveobuhvatnu procjenu uspješnosti modela u lokalizaciji i prepoznavanju objekata. U ovom istraživanju mAP je korišten kao glavni pokazatelj ukupne uspješnosti detekcije zuba, pri čemu viša vrijednost ove metrike upućuje na bolju ukupnu izvedbu modela, Slika 11.



Slika 11. Srednja prosječna preciznost (mAP) modela YOLOv5x6 za detekciju zuba

3.4.2. Metrike segmentacije

U zadacima segmentacije cilj je bio procijeniti koliko se dobro predviđena maska preklapa sa stvarnom, ručno anotiranom maskom strukture ili zahvata. U tu svrhu korišteni su Sørensen-Diceov koeficijent, IoU, F1-score, specifičnost i osjetljivost.

Sørensen-Diceov koeficijent predstavlja mjeru preklapanja između predviđene i referentne segmentacije te se široko koristi u evaluaciji medicinskih slikovnih modela:

$$\text{Sørensen – Diceov koeficijent} = \frac{2IP}{2IP + LP + LN}$$

Veće vrijednosti Sørensen-Diceova koeficijenta upućuju na veće preklapanje između predviđene i stvarne segmentacije, odnosno na veću uspješnost modela.

Intersection over Union (IoU) označava omjer presjeka i unije između predviđene i stvarne segmentirane regije:

$$IoU = \frac{IP}{IP + LP + LN}$$

IoU predstavlja strožu mjeru segmentacijske uspješnosti jer zahtijeva veći stupanj podudarnosti između predviđene i referentne maske.

F1-score predstavlja harmonijsku sredinu preciznosti i osjetljivosti te se koristi za uravnoteženu procjenu modela, osobito u uvjetima neravnoteže među klasama:

$$F1 = \frac{2 \times \text{Preciznost} + \text{Osjetljivost}}{\text{Preciznost} + \text{Osjetljivost}}$$

Specifičnost označava udio točno negativno klasificiranih nalaza u odnosu na sve stvarno negativne nalaze:

$$\text{Specifičnost} = \frac{IN}{IN + LP}$$

gdje je IN broj istinski negativnih nalaza.

U ovom istraživanju primjena više različitih metrika omogućila je detaljniju procjenu performansi modela. Dok su u detekcijskim zadacima ključni pokazatelji bili preciznost, osjetljivost i mAP, u segmentacijskim zadacima najveći su značaj imali Sørensen-Diceov koeficijent i IoU, kao pokazatelji podudarnosti između predviđenih i referentnih maski.

3.4.3. Metrike statističke analize

Za statističku obradu podataka korištene su metode deskriptivne i inferencijalne statistike. Deskriptivna analiza obuhvaćala je broj opažanja, aritmetičku sredinu, standardnu devijaciju, standardnu pogrešku, minimalnu i maksimalnu vrijednost te 95-postotne intervale pouzdanosti. Normalnost distribucije numeričkih varijabli procijenjena je Kolmogorov-Smirnovljevim testom. Za usporedbu rezultata među skupinama primijenjena je jednosmjerna analiza varijance (ANOVA). U analizi detekcije zuba ANOVA je korištena za usporedbu vrijednosti preciznosti, osjetljivosti i srednje prosječne preciznosti (mAP) između različitih razlučivosti ulazne slike, zasebno za modele uvježbane od početka i za modele razvijene primjenom transfernog učenja.

U analizi segmentacije ANOVA je korištena za usporedbu vrijednosti Diceova koeficijenta između različitih vrsta ulazne slike.

Nakon statistički značajnih ANOVA rezultata provedene su Bonferronijeve post hoc usporedbe radi utvrđivanja razlika između pojedinih skupina. Veličina učinka procijenjena je pokazateljem eta kvadrat (η^2). Statistička značajnost procjenjivana je na razini $p < 0,05$.

3.4.4. Evaluacija performansi prema razlučivosti slike

Performanse modela analizirane su pri različitim razlučivostima ulazne slike: 256 px, 640 px, 1280 px i 1820 px. Uspješnost modela procjenjivana je primjenom više metrika, uključujući preciznost, osjetljivost, srednju prosječnu preciznost (mAP) i Sørensen-Diceov koeficijent, kako bi se utvrdio utjecaj razlučivosti slike na rezultate detekcije i segmentacije. Dobiveni rezultati pokazali su da veća razlučivost slike u pravilu dovodi do bolje uspješnosti modela. Primjerice, model uvježban na slikama razlučivosti 1820 px ostvario je mAP od 98,02%, dok su modeli uvježbani na slikama razlučivosti 256 px pokazali osjetno niže vrijednosti.

Primjena više evaluacijskih metrika omogućila je sveobuhvatniji uvid u prednosti i ograničenja pojedinih modela u zadacima detekcije i segmentacije zubnih struktura. Takav pristup pridonio je pouzdanijoj procjeni uspješnosti modela i većoj metodološkoj utemeljenosti istraživačkih nalaza.

3.5. Eksperimentalni tijek rada

Eksperimentalni tijek rada proveden u ovom istraživanju slijedio je strukturiran i sustavan postupak s ciljem učinkovitog vježbanja i evaluacije konvolucijskih neuronskih mreža za automatiziranu registraciju dentalnog statusa. Svaki korak osmišljen je tako da omogućiti

optimizaciju performansi modela i procjenu njihove primjenjivosti u zadacima detekcije i segmentacije na ortopantomografskim snimkama.

Korak 1: Priprema podataka

Prvi korak obuhvaćao je pripremu podataka kako bi se osigurala njihova kompatibilnost s modelima dubokog učenja. U tu svrhu provedena je ručna anotacija zuba i stomatoloških zahvata, uključujući ispune, krunice i karijesne lezije, korištenjem alata GIMP 2.10.22. Izrađene anotacije pohranjene su u PASCAL VOC XML formatu, prikladnom za primjenu u suvremenim okvirima dubokog učenja. Skup podataka, koji se sastojao od 1400 OPG snimaka, podijeljen je na skupove za vježbanje, validaciju i testiranje, uz uravnoteženu zastupljenost različitih dentalnih stanja u svim podskupovima. Radi povećanja sposobnosti generalizacije modela primijenjene su tehnike proširenja podataka, uključujući skaliranje, rotaciju, zrcaljenje i dodavanje šuma.

Korak 2: Odabir i analiza modela

U drugom koraku odabrane su i analizirane arhitekture modela u skladu s vrstom zadatka. U skupini modela razvijenih primjenom transfernog učenja korištene su arhitekture YOLOv5 i DeepLabV3, pri čemu su prethodno naučene težine iz velikih skupova podataka iskorištene radi brže konvergencije i bolje generalizacije. Istodobno su ispitani i modeli uvježbani od početka, s nasumično inicijaliziranim težinama, koji su vježbani isključivo na skupu ortopantomografskih snimaka. Takvi modeli bili su usmjereni na specifične zadatke dentalnog snimanja, osobito detekciju i segmentaciju zuba i stomatoloških zahvata.

Korak 3: Postupak vježbanja

Treći korak uključivao je postupak vježbanja modela, odnosno iterativnu optimizaciju njihovih parametara. Označene slike i pripadajuće anotacije korištene su kao ulaz u modele konvolucijskih neuronskih mreža. Proces vježbanja obuhvaćao je propagaciju unaprijed i propagaciju unatrag radi izračuna predikcija i optimizacije funkcije gubitka. Modeli su uvježbavani tijekom 100 epoha, uz brzinu učenja od 0,001, veličinu serije od 16 i primjenu

Adam optimizatora. Funkcije gubitka odabrane su prema vrsti zadatka: u detekciji su korištene funkcije primjerene klasifikaciji i lokalizaciji objekata, dok je u segmentaciji primijenjen Dice gubitak. Nakon svake epohe izračunavane su validacijske metrike, uključujući preciznost, osjetljivost i Sørensen-Diceov koeficijent, radi praćenja uspješnosti modela i optimizacije procesa vježbanja.

Korak 4: Evaluacija modela

U četvrtom koraku modeli su testirani na prethodno izdvojenome testnom podskupu kako bi se procijenila njihova sposobnost generalizacije na novim podacima. U tu svrhu korištene su različite metrike evaluacije, ovisno o vrsti zadatka, čime je omogućena usporedba performansi modela u detekciji i segmentaciji. Takav pristup omogućio je identifikaciju najuspješnijih modela za svaki pojedini zadatak.

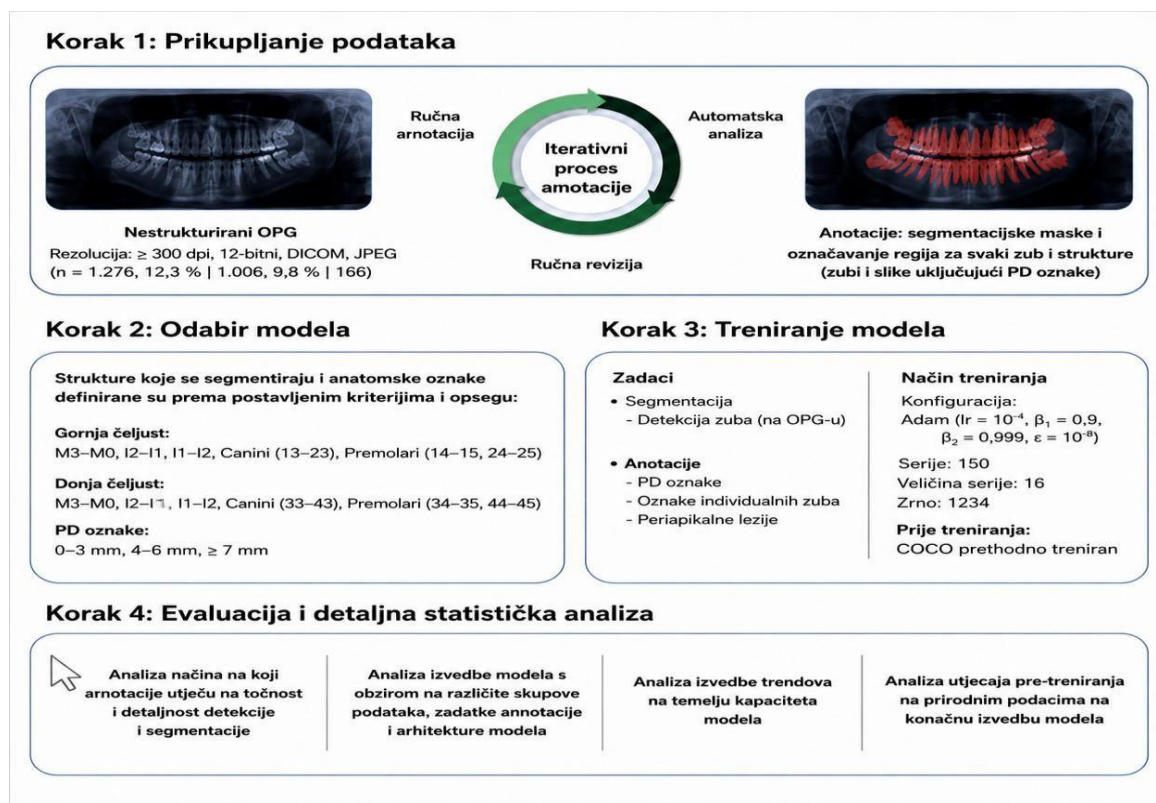
Korak 5: Statistička analiza

Peti korak uključivao je statističku obradu rezultata s ciljem provjere značajnosti opaženih razlika među modelima i eksperimentalnim uvjetima. U tu je svrhu primijenjena jednosmjerna analiza varijance (ANOVA) za usporedbu metrika uspješnosti između različitih arhitektura modela i različitih razlučivosti ulazne slike. Vrijednosti $p < 0,05$ smatrane su pokazateljem statistički značajnih razlika među promatranim skupinama.

Korak 6: Prikaz i vizualizacija rezultata

Posljednji korak obuhvaćao je prikaz i vizualizaciju rezultata. Analizirani su omeđujući okviri, segmentacijske maske i vrijednosti evaluacijskih metrika, a rezultati su prikazani u tablicama i slikama radi usporedbe prednosti i ograničenja pojedinih modela. Takav pristup omogućio je identifikaciju najprikladnijih arhitektura za automatiziranu registraciju dentalnog statusa. Cjelokupni eksperimentalni tijek rada osigurao je sustavan okvir za procjenu performansi konvolucijskih neuronskih mreža te pružio metodološku osnovu za njihovu buduću primjenu u dentalnom snimanju i forenzičnoj analizi.

Slika 12. prikazuje glavne korake eksperimentalnog tijeka rada primijenjenog u istraživanju automatizirane registracije zubnoga statusa na ortopantomografskim snimkama. Prikazani su postupci prikupljanja i anotacije podataka, odabira modela, vježbanja modela te evaluacije i statističke analize rezultata. Dijagram sažeto prikazuje organizaciju istraživanja i povezanost pojedinih metodoloških faza.



Slika 12. Shematski prikaz eksperimentalnog tijeka rada istraživanja. Prikazane su glavne faze istraživanja, od prikupljanja i anotacije podataka do uvježbavanja modela, evaluacije i statističke analize rezultata. Prilagođeno i prevedeno prema Zymber Çeshko i sur (18).

4. REZULTATI I ANALIZE

4.1. Karakteristike uzorka ortopantomograma i dentalnih nalaza

Opće značajke analiziranog uzorka i analitičkog pristupa

Istraživanje je provedeno na 1400 digitalnih ortopantomograma, podijeljenih na skupove za učenje, validaciju i testiranje u omjeru 75%: 12,5%: 12,5%, pri čemu su procjenjivani modeli za detekciju zuba i segmentaciju zuba te dentalnih intervencija. Za segmentacijske zadatke glavni pokazatelj uspješnosti bio je Sørensen-Diceov koeficijent, dok su za detekciju korišteni preciznost, osjetljivost i mAP.

Statistička analiza u radu temeljila se na provjeri normalnosti Kolmogorov-Smirnovljevom testom te na ANOVA analizi za usporedbu skupina, uz prag značajnosti $p < 0,05$.

Ukupno je analizirano 39.441 zub, uz 420 krunica, 2.172 endodontski liječena zuba, 9.869 ispuna i 795 zuba s karijesom. Ovakva veličina i heterogenost uzorka daju dodatnu težinu rezultatima jer smanjuju vjerojatnost da se opaženi učinci mogu pripisati uskom ili selektivnom skupu podataka.

Prikaz karakteristika uzorka s obzirom na broj zuba i različitih karakteristika zubnog statusa podijeljen je prema dobnim skupinama, prikazan je u Tablici 3.

Tablica 3. Skupni podaci o zubima i stomatološkim intervencijama prema dobnim skupinama

Dobna skupina (godine)	Zubi (N)	Krunice	Mostovi	Endodontsko punjenje	Ispuni	Zubi s karijesom
(18, 20)	277	0	0	2	35	2
(21, 25)	6017	10	51	109	1115	75
(26, 30)	8162	22	17	306	1663	170
(31, 35)	6130	35	31	283	1514	63
(36, 40)	4775	55	38	304	1361	89
(41, 45)	3426	57	60	267	1051	73
(46, 50)	2339	23	88	236	858	58
(51, 55)	2813	72	142	236	858	58
(56, 60)	2198	59	218	208	583	79
(61, 65)	902	11	81	59	219	37
(66, 70)	959	35	32	62	244	49
(71, 75)	979	27	35	78	220	30
(76, 80)	361	8	16	15	132	12
(56, 60)	2198	59	218	208	583	79
(61, 65)	902	11	81	59	219	37
(66, 70)	959	35	32	62	244	49
(71, 75)	979	27	35	78	220	30
(76, 80)	361	8	16	15	132	12
(81, 85)	56	4	9	2	6	0
(86, 90)	23	2	3	0	2	0
(91, 95)	24	0	7	5	8	0
Ukupno	39.441	420	828	2172	9869	795

Analiza podataka pokazuje jasnu povezanost između dobi ispitanika i prevalencije stomatoloških intervencija. U mlađim dobnim skupinama zabilježen je relativno mali broj restaurativnih zahvata. Primjerice, u dobnoj skupini od 18 do 20 godina evidentirano je ukupno 277 zuba, pri čemu su zabilježena samo dva slučaja liječenja korijenskog kanala te dva zuba s karijesom. Ovi rezultati upućuju na relativno dobro oralno zdravlje u najmlađoj skupini ispitanika.

U dobnoj skupini od 20 do 25 godina zabilježen je značajno veći broj zuba (6.017), uz istodobno povećanje broja zuba s ispunom (1.115) te zuba s karijesom (75). Iako je razina restaurativnih zahvata i dalje relativno niska, uočava se trend postupnog povećanja stomatoloških intervencija, što može biti povezano s promjenama životnih navika, prehrane i oralne higijene u populaciji mladih odraslih osoba.

U skupini od 25 do 30 godina zabilježen je najveći broj analiziranih zuba (8.162), uz povećanje broja krunica, mostova i ispuna korijenskih kanala. Također je zabilježen značajan porast broja zuba s ispunom (1.663) i zuba s karijesom (170), što upućuje na progresivno povećanje potrebe za restaurativnim stomatološkim zahvatima.

Srednje dobne skupine (30-50 godina) karakterizira daljnje povećanje kompleksnosti stomatoloških intervencija. Posebno je izražen porast broja krunica, mostova i endodontskih zahvata. Primjerice, u skupini od 40 do 45 godina zabilježeno je 3426 zuba, uz 57 krunica, 60 mostova i 267 ispuna korijenskog kanala.

U starijim dobnim skupinama primjećuje se smanjenje ukupnog broja zuba, što je očekivano zbog gubitka zuba tijekom života. Istodobno se smanjuje i broj restaurativnih zahvata, što je dijelom posljedica manjeg broja preostalih zuba. Primjerice, u dobnoj skupini od 75 do 80 godina zabilježeno je ukupno 361 zub, uz relativno mali broj krunica (8), mostova (16) i ispuna korijenskih kanala (15).

Ukupno gledano, rezultati upućuju na jasnu dobnu dinamiku stomatoloških stanja. S porastom dobi povećava se vjerojatnost pojave karijesa i potrebe za restaurativnim zahvatima, dok se u starijoj populaciji smanjuje ukupan broj zuba, ali i broj intervencija zbog smanjenog broja zuba.

4.2. Detekcija zuba s pomoću YOLOv5 modela

Uspješnost različitih varijanti YOLOv5 modela u zadatku detekcije zuba na OPG snimkama različite rezolucije prikazuje Tablica 4.

Modeli su uvježbani u dvije konfiguracije:

1. vježbanje od početka (trained from scratch)
2. vježbanje primjenom transfernog učenja na prethodno uvježbanom COCO skupu podataka.

Tablica 4. Performanse modela detekcije ovisno o rezoluciji slike

		Model uvježban od početka			Prethodno uvježbani model (COCO)		
Arhitektura	Veličina slike (px)	Preciznost	Osjetljivost	mAP	Preciznost.1	Osjetljivost.1	mAP.1
YOLOv5s	256	68,33	70,23	65,81	88,26	74,95	83,29
YOLOv5s	640	97,78	93,02	96,69	98,1	93,91	97,35
YOLOv5s	1280	98,48	93,85	97,55	98,36	94,08	97,6
YOLOv5s	1820	98,55	93,89	97,79	98,52	94,22	97,87
YOLOv5s6	256	70,08	70,61	64,75	84,97	76,61	82,15
YOLOv5s6	640	97,67	93,7	97,17	98,29	93,96	97,69
YOLOv5s6	1280	98,48	93,54	97,57	98,31	93,97	97,78
YOLOv5s6	1820.	98,58	93,9	97,89	98,36	94,22	97,87
YOLOv5m	256	69,78	71,74	67,83	86,98	74,82	83,51
YOLOv5m	640	98,16	93,73	97,04	97,5	93,71	97,18
YOLOv5m	1280	98,47	93,93	97,67	98,38	94,11	97,54
YOLOv5m	1820	98,61	93,95	97,9	98,53	94,95	97,77
YOLOv5m6	256	73,04	71,43	67,76	89,53	76,2	85,02
YOLOv5m6	640	97,74	93,86	97,42	98,22	94,1	97,82
YOLOv5m6	1280	98,16	93,96	97,88	98,27	94,27	97,84
YOLOv5m6	1820.	98,47	94,26	97,89	98,42	94,45	97,98
YOLOv5l	256	70,34	73,29	69,89	87,9	76,6	83,26
YOLOv5l	640	98,1	93,81	97,16	97,95	94,2	97,43
YOLOv5l	1280	98,5	93,49	97,77	98,17	94,29	97,6
YOLOv5l	1820	98,58	93,94	97,79	98,26	94,36	97,81

Ajla Zymber Çeshko, disertacija

YOLOv5l6	256	74,14	73,29	70,25	86,96	76,46	82,59
YOLOv5l6	640	98,16	93,54	97,61	91,19	90,84	88,06
YOLOv5l6	1280	98,37	93,7	97,83	95,39	94,47	95,99
YOLOv5l6	1820	98,5	93,9	97,96	97,75	94,61	97,94
YOLOv5x	256	69,73	73,75	70,05	91,19	75,02	85,25
YOLOv5x	640	98,18	93,68	97,13	97,56	94,09	97,16
YOLOv5x	1280	98,33	93,41	97,56	98,3	94,19	97,67
YOLOv5x	1820	98,37	93,91	97,59	98,48	95,02	97,89
YOLOv5x6	256	77,02	72,01	70,76	85,16	76,15	80,78
YOLOv5x6	640	98,32	93,79	97,71	97,17	94,79	97,63
YOLOv5x6	1280	98,41	93,92	97,86	97,31	95,05	97,69
YOLOv5x6	1820	98,55	94,12	98,02	97,78	95,12	97,82

Rezultati detekcije jasno pokazuju da je razlučivost slike bila jedan od najsnažnijih prediktora uspješnosti modela. Najbolji pojedinačni rezultat postigao je YOLOv5x6 uvježban od početka, s mAP = 98,02% pri rezoluciji 1820 px, dok je najbolji prethodno uvježbani model bio YOLOv5m6 s mAP = 97,98%, također pri 1820 px. Za isti najbolji model mAP je iznosio 96,41% za gornju čeljust i 99,82% za donju čeljust, što dodatno potvrđuje vrlo visoku razinu detekcijske točnosti.

Dodatna statistička analiza pokazuje da se prosječne vrijednosti svih testiranih YOLO arhitektura ponašaju vrlo konzistentno, Tablica 5.

Tablica 5. Deskriptivni statistički pokazatelji preciznosti, osjetljivosti i mAP-a modela za detekciju zuba ježbanih od početka i transfer učenjem pri različitim razlučivostima ulazne slike

	Veličina slike (px)	N	Aritmetička sredina	Standard - na devijacija	95% Interval pouzdanosti Donja granica	95% Interval pouzdanost i Gornja granica	Minimum	Maximum
Model uvježban od početka: preciznost	256	78936	71,56	2,72	71,54	71,54	68,33	77,02
	640	78936	98,01	0,23	98,01	98,01	97,67	98,32
	1280	78936	98,40	0,11	98,40	98,40	98,16	98,50
	1820	78936	98,53	0,07	98,53	98,53	98,37	98,61
	Total	315744	91,62	11,67	91,58	91,58	68,33	98,61
Model uvježban od početka: osjetljivost	256	78936	72,04	1,22	72,04	72,05	70,23	73,75
	640	78936	93,64	0,25	93,64	93,64	93,02	93,86
	1280	78936	93,73	0,21	93,72	93,73	93,41	93,96
	1820	78936	93,98	0,13	93,98	93,98	93,89	94,26
	Total	315744	88,35	9,44	88,32	88,38	70,23	94,26
Model uvježban od početka: mAP	256	78936	68,39	2,08	68,37	68,40	64,75	70,76
	640	78936	97,24	0,31	97,24	97,24	96,69	97,71
	1280	78936	97,71	0,13	97,71	97,71	97,55	97,88
	1820	78936	97,85	0,12	97,85	97,85	97,59	98,02
	Total	315744	90,30	12,70	90,25	90,34	64,75	98,02
Prethodn o uvježban model (COCO): preciznost	256	78936	87,62	1,96	87,61	87,63	84,97	91,19
	640	78936	97,00	2,23	96,98	97,01	91,19	98,29
	1280	78936	97,81	0,97	97,80	97,82	95,39	98,38
	1820	78936	98,26	0,30	98,26	98,26	97,75	98,53
	Total	315744	95,17	4,66	95,16	95,19	84,97	98,53
Prethodn o uvježban model (COCO): osjetljivost	256	78936	75,85	0,73	75,85	75,86	74,82	76,61
	640	78936	93,70	1,12	93,69	93,71	90,84	94,79
	1280	78936	94,30	0,32	94,30	94,31	93,97	95,05
	1820	78936	94,62	0,34	94,62	94,62	94,22	95,12
	Total	315744	89,62	7,99	89,59	89,65	74,82	95,12
Prethodn o uvježban model (COCO): mAP	256	78936	83,23	1,37	83,22	83,24	80,78	85,25
	640	78936	96,29	3,12	96,27	96,31	88,06	97,82
	1280	78936	97,46	0,56	97,46	97,47	95,99	97,84
	1820	78936	97,87	0,06	97,87	97,87	97,77	97,98
	Total	315744	93,71	6,32	93,69	93,74	80,78	97,98

Kratice: OPG – ortopantomogram; mAP – srednja prosječna preciznost (mean average precision); COCO – Common Objects in Context.

Kod modela uvježbanih od početka srednja vrijednost preciznosti porasla je sa 71,56% pri 256 px na 98,01% pri 640 px, a zatim na 98,40% pri 1280 px i 98,53% pri 1820 px. Slično tome, mAP je porastao s približno 68,40% na 97,27%, zatim na 97,71% i konačno na 97,85-97,87%. Kod prethodno uvježbanog pristupa srednji mAP porastao je s 83,23% pri 256 px na 96,29% pri 640 px, zatim na 97,46% pri 1280 px i 97,87% pri 1820 px. Ti podaci pokazuju da se najveći dobitak ostvaruje prijelazom s vrlo niske na srednju rezoluciju, dok su daljnja poboljšanja iznad 640 px manja, ali i dalje prisutna.

ANOVA rezultati potvrđuju da ove razlike nisu slučajne, Tablica 6. Rezultati jednosmjerne analize varijance pokazali su da razlučivost ulazne slike statistički značajno utječe na preciznost, osjetljivost i mAP kod svih analiziranih modela. Za modele uvježbane od početka dobivene su izrazito visoke F-vrijednosti ($F = 7\,556\,478$ za preciznost, $F = 23\,307\,591$ za recall i $F = 15\,095\,629$ za mAP), dok su kod prethodno uvježbanih modela također utvrđene vrlo visoke vrijednosti ($F = 822\,789$, $F = 13\,272\,348$ i $F = 1\,305\,793$), uz $p < 0,001$ u svim analizama. Na temelju suma kvadrata može se dodatno izračunati da je veličina učinka rezolucije iznimno velika, Tablica 6. Na temelju podataka iz analize varijance izračunan je eta kvadrat (η^2) kao mjera veličine učinka rezolucije ulazne slike na uspješnost detekcije. Za modele uvježbane od početka vrijednosti η^2 iznosile su 0,329 za preciznost, 0,996 za osjetljivost i 0,993 za mAP, dok su za prethodno uvježbane modele iznosile 0,887 za preciznost, 0,992 za osjetljivost i 0,925 za mAP. Dobivene vrijednosti upućuju na vrlo velik učinak rezolucije slike, pri čemu razlike među razlučivostima objašnjavaju znatan dio ukupne varijance rezultata detekcije. Navedeni nalazi potvrđuju da razlučivost ulazne slike nije samo tehnička značajka obrade, nego jedan od ključnih čimbenika koji određuju uspješnost detekcijskog modela.

Tablica 6. Rezultati jednosmjerne analize varijance preciznosti, osjetljivosti i mAP-a modela za detekciju zuba uvježbanih od početka i prethodno uvježbanih pri različitim razlučivostima ulazne slike

		Zbroj kvadrata	Stupnjevi slobode	Srednji kvadrat	F	P
Model uvježban od početka: preciznost	Između grupa	42392465	3	14130822	7556478	<0,001
	Unutar grupa	590443	315740	1,870		
	Ukupno	42982907	315743			
Model uvježban od početka: osjetljivost	Između grupa	27984459	3	9328153	23307591	<0,001
	Unutar grupa	126365	315740	0,400		
	Ukupno	28110825	315743			
Model uvježban od početka: mAP	Između grupa	50544644	3	16848215	15095629	<0,001
	Unutar grupa	352397	315740	1,116		
	Ukupno	50897041	315743			
Prethodno uvježban model: (COCO) preciznost	Između grupa	6070247	3	2023416	822789	<0,001
	Unutar grupa	776472	315740	2,459		
	Ukupno	6846719	315743			
Prethodno uvježban model: (COCO) osjetljivost	Između grupa	19982639	3	6660880	13272348	<0,001
	Unutar grupa	158458	315740	0,502		
	Ukupno	20141097	315743			
Prethodno uvježban model: (COCO) mAP	Između grupa	11670403	3	3890134	1305793	<0,001
	Unutar grupa	940633	315740	2,979		
	Ukupno	12611036	315743			

Kratice: mAP – srednja prosječna preciznost (*mean average precision*); COCO – *Common Objects in Context*; F – vrijednost F-testa; P – razina statističke značajnosti.

Post hoc Bonferroni usporedbe dodatno objašnjavaju strukturu tog učinka, Tablica 7.

Tablica 7. Bonferroni post hoc usporedbe mAP vrijednosti modela za detekciju zuba pri različitim razlučivostima ulazne slike

	Zavisna varijabla	Razlika aritmetičkih sredina	Standardna pogreška	P	95% Interval pouzdanosti Donja granica	95% Interval pouzdanosti Gornja granica
Model uvježban od početka: preciznost	256	640 -26,45625*	0,00688	<0,001	-26,4744	-26,4381
		1280 -26,84250*	0,00688	<0,001	-26,8607	-26,8243
		1820 -26,96875*	0,00688	<0,001	-26,9869	-26,9506
	640	256 26,45625*	0,00688	<0,001	26,4381	26,4744
		1280 -,38625*	0,00688	<0,001	-0,4044	-0,3681
		1820 -,51250*	0,00688	<0,001	-0,5307	-0,4943
	1280	256 26,84250*	0,00688	<0,001	26,8243	26,8607
		640 ,38625*	0,00688	<0,001	0,3681	0,4044
		1820 -,12625*	0,00688	<0,001	-0,1444	-0,1081
	1820	256 21,94000*	0,00688	<0,001	26,9506	26,9869
		640 ,34250*	0,00688	<0,001	0,4943	0,5307
		1280 ,25875*	0,00688	<0,001	0,1081	0,1444
Model uvježban od početka: osjetljivost	256	640 -21,59750*	0,00318	<0,001	-21,6059	-21,5891
		1280 -21,68125*	0,00318	<0,001	-21,6897	-21,6728
		1820 -21,94000*	0,00318	<0,001	-21,9484	-21,9316
	640	256 21,59750*	0,00318	<0,001	21,5891	21,6059
		1280 -,08375*	0,00318	<0,001	-0,0922	-0,0753
		1820 -,34250*	0,00318	<0,001	-0,3509	-0,3341
	1280	256 21,68125*	0,00318	<0,001	21,6728	21,6897
		640 ,08375*	0,00318	<0,001	0,0753	0,0922
		1820 -,25875*	0,00318	<0,001	-0,2672	-0,2503
	1820	256 21,94000*	0,00318	<0,001	21,9316	21,9484
		640 ,34250*	0,00318	<0,001	0,3341	0,3509
		1280 ,25875*	0,00318	<0,001	0,2503	0,2672
Model uvježban od početka: mAP	256	640 -28,85375*	0,00532	<0,001	-28,8678	-28,8397
		1280 -29,32375*	0,00532	<0,001	-29,3378	-29,3097
		1820 -29,46625*	0,00532	<0,001	-29,4803	-29,4522
	640	256 28,85375*	0,00532	<0,001	28,8397	28,8678
		1280 -,47000*	0,00532	<0,001	-0,4840	-0,4560
		1820 -,61250*	0,00532	<0,001	-0,6265	-0,5985
	1280	256 29,32375*	0,00532	<0,001	29,3097	29,3378
		640 ,47000*	0,00532	<0,001	0,4560	0,4840
		1820 -,14250*	0,00532	<0,001	-0,1565	-0,1285
	1820	256 29,46625*	0,00532	<0,001	29,4522	29,4803
		640 ,61250*	0,00532	<0,001	0,5985	0,6265

		1280	,14250*	0,00532	<0,001	0,1285	0,1565
Prethodno uvježban model (COCO): preciznost	256	256	9,37875*	0,00789	<0,001	-9,3996	-9,3579
		1280	-,81375*	0,00789	<0,001	-10,2133	-10,1717
		1820	-1,26500*	0,00789	<0,001	-10,6646	-10,6229
	640	256	9,37875*	0,00789	<0,001	9,3579	9,3996
		1280	-,81375*	0,00789	<0,001	-0,8346	-0,7929
		1820	-1,26500*	0,00789	<0,001	-1,2858	-1,2442
	1280	256	10,19250*	0,00789	<0,001	10,1717	10,2133
		640	,81375*	0,00789	<0,001	0,7929	0,8346
		1820	-,45125*	0,00789	<0,001	-0,4721	-0,4304
	1820	256	10,64375*	0,00789	<0,001	10,6229	10,6646
		640	1,26500*	0,00789	<0,001	1,2442	1,2858
		1280	,45125*	0,00789	<0,001	0,4304	0,4721
Prethodno uvježban model (COCO): osjetljivost	256	256	17,84875*	0,00357	<0,001	-17,8582	-17,8393
		1280	-,60375*	0,00357	<0,001	-18,4619	-18,4431
		1820	-,91875*	0,00357	<0,001	-18,7769	-18,7581
	640	256	17,84875*	0,00357	<0,001	17,8393	17,8582
		1280	-,60375*	0,00357	<0,001	-0,6132	-0,5943
		1820	-,91875*	0,00357	<0,001	-0,9282	-0,9093
	1280	256	18,45250*	0,00357	<0,001	18,4431	18,4619
		640	,60375*	0,00357	<0,001	0,5943	0,6132
		1820	-,31500*	0,00357	<0,001	-0,3244	-0,3056
	1820	256	18,76750*	0,00357	<0,001	18,7581	18,7769
		640	,91875*	0,00357	<0,001	0,9093	0,9282
		1280	,31500*	0,00357	<0,001	0,3056	0,3244
Prethodno uvježban model (COCO): mAP	256	640	-13,05875*	0,00869	<0,001	-13,0817	-13,0358
		1280	-14,23250*	0,00869	<0,001	-14,2554	-14,2096
		1820	-14,63750*	0,00869	<0,001	-14,6604	-14,6146
	640	256	13,05875*	0,00869	<0,001	13,0358	13,0817
		1280	-1,17375*	0,00869	<0,001	-1,1967	-1,1508
		1820	-1,57875*	0,00869	<0,001	-1,6017	-1,5558
	1280	256	14,23250*	0,00869	<0,001	14,2096	14,2554
		640	1,17375*	0,00869	<0,001	1,1508	1,1967
		1820	-,40500*	0,00869	<0,001	-0,4279	-0,3821
	1820	256	14,63750*	0,00869	<0,001	14,6146	14,6604
		640	1,57875*	0,00869	<0,001	1,5558	1,6017
		1280	,40500*	0,00869	<0,001	0,3821	0,4279

* Razlika aritmetičkih sredina značajana je na razini od 0.05

Kratice: OPG – ortopantomogram; UNet – U-shaped Neural Network; FCN – potpuno konvolucijska mreža (*Fully Convolutional Network*); DeepLabV3 – arhitektura DeepLab verzija 3; HRNet V2 W32 – High-Resolution Network Version 2 W32.

U svim kombinacijama 256 px naspram 640, 1280 i 1820 px razlike su bile statistički značajna je na razini za sve pokazatelje i oba načina uvježbavanja, uz $p < 0,001$. Primjerice, kod modela uvježbanih od početka srednja razlika u mAP-u između 256 px i 640 px iznosi približno 28,85 postotnih bodova, između 256 px i 1280 px 29,32 postotna boda, a između 256 px i 1820 px 29,47 postotnih bodova. Nasuprot tome, razlike između 640 px i 1280 px te između 1280 px i 1820 px ostaju statistički značajne, ali su numerički male, najčešće u rasponu od 0,1 do 1,6 postotnih bodova. To potvrđuje obrazac „platoa”: najveći skok događa se pri izlasku iz niske rezolucije, dok se nakon toga dobivaju inkrementalna poboljšanja.


Usporedba modela uvježbanih od početka i prethodno uvježbanih modela

Iako se u literaturi često očekuje prednost transfer learning pristupa, ovi rezultati pokazuju nijansiraniju sliku. Pri 256 px prethodno uvježbani modeli ostvaruju osjetno bolje rezultate od modela uvježbanih od početka, što se vidi već iz prosječnog mAP-a (83,23% prema 68,40%). Međutim, kako raste razlučivost, ta se prednost smanjuje, a u najvišim razlučivostima modeli uvježbani od početka dosežu ili blago nadmašuju prethodno uvježbane varijante. To je u skladu s pretpostavkom istraživanja da modeli uvježbani od početka, kada raspolažu dostatno informativnim ulazom, bolje usvajaju značajke specifične za dentalne radiološke slike od modela inicijalno uvježbanih na prirodnim slikama.


Statistički gledano, prijelaz s 256 px na više rezolucije smanjuje prednost transfer learninga i istodobno povećava konkurentnost modela uvježbanih od početka. To je važan nalaz za interpretaciju hipoteze koji sugerira da korisnost prethodne uvježbanosti nije apsolutna, nego ovisi o kvaliteti i rezoluciji ulazne slike.

Rezultati pokazuju da povećanje rezolucije ulaznih slika značajno utječe na poboljšanje performansi modela (Slika 13-16). Kod modela uvježbanih od nule vrijednost mAP-a povećava se sa 65,81 pri rezoluciji od 256 piksela na 97,79 pri rezoluciji od 1820 piksela. Sličan trend zabilježen je i kod prethodno uvježbanih modela.

Najbolje rezultate ostvarili su modeli YOLOv5x6, koji su pri rezoluciji od 1820 piksela postigli mAP vrijednost od 98,02% kod modela uvježbanih od nule te 97,82% kod prethodno uvježbanih modela. Ovi rezultati potvrđuju da kompleksnije arhitekture s većim brojem parametara mogu ostvariti višu razinu preciznosti u zadacima detekcije objekata.




Slika 13. Promjena preciznosti modela za detekciju zuba uvježbanog od početka s obzirom na veličinu ulazne slike (px).




Kratica: mAP – srednja prosječna preciznost (mean average precision).

Slika 14. Promjena srednje vrijednosti mAP-a modela za detekciju zuba uvježbanog od početka s obzirom na veličinu ulazne slike (px).



Slika 15. Promjena preciznosti prethodno uvježbanog modela za detekciju zuba (COCO) s obzirom na veličinu ulazne slike (px).




Slika 16. Promjena osjetljivosti prethodno uvježbanog modela za detekciju zuba (COCO) s obzirom na veličinu ulazne slike (px).

4.3. Segmentacija zuba

Uspješnost segmentacije analizirana je u odnosu na različitu ulaznu sliku: ortopan, izolirani zub (unutar boxa) i segmentiran zub (isključivo zub bez ikakvih susjednih struktura).

U segmentaciji zuba najuspješniji su bili UNet Big i DeepLabV3-HRNet V2 W32, oba s 95,94% Dice vrijednosti na slici individualnog zuba, dok je najbolji rezultat na cijelom OPG-u ostvario UNet Big s 95,25% Dice vrijednosti. Segmentirani isječak zuba ovdje nije bio primjenjiv, Slika 17.



Slika 17. Prosječna uspješnost segmentacije zuba na cijelom ortopantomogramu (OPG) i slici individualnog zuba (unutar označenog okvira) s 95-postotnim intervalima pouzdanosti

Tablica 8. Usporedba Diceovih koeficijenata različitih modela u segmentaciji zuba, karijesa, krunica, ispuna i endodontskih punjenja s obzirom na vrstu ulazne slike (OPG, individualni zub i segmentirani zub)

Model	Zub	Karijes	Krunica	Ispun	Endodontsko punjenje
OPG					
Unet Micro	92,12	0,12	0,29	52,52	0,04
Unet Mini	93,73	10,03	38,84	69,74	67,91
Unet	95,14	24,77	46,01	76,21	71,6
Unet Big	95,25	21,36	48,14	77,3	74,34
FCN32	87,53	0,09	0,27	51,17	31,92
FCN16	90,79	0,12	0,39	59,15	53,15
FCN8	93,44	0,1	4,33	66,63	55,98
DeepLab V3 - MobileNet	92,1	0,09	12,31	56,62	49,61
DeepLab V3 - HRNet V2 W32	94,47	0,11	44,02	73,09	70,82
DeepLab V3 - ResNet50	93,13	4,84	44,67	70,21	62,48
DeepLab V3 - ResNet101	92,86	0,33	31,45	67,03	60,03
DeepLab V3 - HRNet V2 W48	94,48	0,56	45,22	73,11	70,01
POJEDINAČNI ZUB					
Unet Micro	95,04	7,41	19,97	78,12	72,22
Unet Mini	95,42	36,56	72,41	81,96	76,39
Unet	95,81	57,04	88,39	84,81	79,14

Unet Big	95,94	59,53	88,78	84,90	79,53
FCN32	94,99	6,9	74,64	80,59	70,12
FCN16	95,51	36,02	81,05	82,38	75,78
FCN8	95,56	40,83	82,11	83,66	76,82
DeepLab V3 - MobileNet	95,19	17,44	77,16	79,81	72,23
DeepLab V3 - HRNet V2 W32	95,94	50,31	80,65	80,78	77,91
DeepLab V3 - ResNet50	95,72	46,85	84,04	82,16	75,57
DeepLab V3 - ResNet101	95,53	34,96	82,93	82,11	74,74
DeepLab V3 - HRNet V2 W48	95,75	15,38	85,21	83,15	76,55
SEGMENTIRANI ZUB					
Unet Micro		41,19	71,11	77,68	73,39
Unet Mini		50,91	87,56	82,41	75,24
Unet		64,68	88,02	83,27	79,09
Unet Big		60,76	89,14	83,49	79,06
FCN32		19,92	67,61	77,91	71,31
FCN16		31,14	81,63	81,12	75,23
FCN8		53,73	83,39	82,03	76,42
DeepLab V3 - MobileNet		37,77	78,68	79,44	72,56
DeepLab V3 - HRNet V2 W32		57,15	86,71	80,53	77,23
DeepLab V3 - ResNet50		57,91	85,93	80,75	76

DeepLab V3 - ResNet101		55,64	85,82	80,6	75,27
DeepLab V3 - HRNet V2 W48		59,08	86,76	80,26	77,67

Na razini svih modela zajedno, prosječna uspješnost segmentacije zuba iznosila je 92,92% na OPG-u i 95,53% na pojedinačnom zubu, Tablica 9.

Kako bi se ispitala statistička značajnost razlika u uspješnosti segmentacije zuba s obzirom na vrstu ulazne slike, provedena je jednosmjerna analiza varijance, a rezultati su prikazani u Tablici 6 ANOVA je pokazala da je ta razlika statistički vrlo značajna ($F = 742.660,23$; $p < 0,001$).

Tablica 9. Deskriptivni statistički pokazatelji Diceova koeficijenta za segmentaciju zuba prema vrsti ulazne slike Izvor: izravni doprinos autora.

	N	Aritmetička sredina	Standardna devijacija	Standardna pogreška	95% Interval pouzdanosti Donja granica	95% Interval pouzdanosti Gornja granica	Minimum	Maximum
OPG	473292	92,9200	2,06295	0,00300	92,9141	92,9259	87,53	95,25
Pojedinačni zub	473292	95,5333	0,31087	0,00045	95,5324	95,5342	94,99	95,94
Ukupno	946584	94,2267	1,97068	0,00203	94,2227	94,2306	87,53	95,94

Tablica 10. Rezultati jednosmjerne analize varijance Diceova koeficijenta za segmentaciju zuba između OPG snimke i prikaza pojedinačnog zuba

	Zbroj kvadrata	Stupnjevi slobode	Srednji kvadrat	F	P
Između grupa	1616176,486	1	1616176,49	742660,23	<0,001
Unutar grupa	2059950,842	946582	2,176		
Ukupno	3676127,328	946583			

Kratice: OPG – ortopantomogram; UNet – U-shaped Neural Network; FCN – potpuno konvolucijska mreža; DeepLabV3 – arhitektura DeepLab verzija 3; HRNet V2 W32 – High-Resolution Network Version 2 W32.

Na temelju podataka iz ANOVA tablice izračunan je $\eta^2 \approx 0,440$, što znači da gotovo 44% ukupne varijance rezultata segmentacije zuba proizlazi iz same vrste ulaza slike. Iako je apsolutna razlika u srednjim vrijednostima relativno mala, samo oko 2,61 postotnih bodova, zbog iznimno velikog broja opažanja i vrlo malih standardnih pogrešaka riječ je o stabilnom i robusnom učinku. Kliničko-metodološki, to znači da segmentacija zuba uspijeva vrlo dobro i na OPG-u, ali dodatna izolacija pojedinačnog zuba ipak donosi statistički i praktično mjerljivo poboljšanje, Tablica 10.

4.4. Segmentacija karijesa

Segmentacija karijesa pokazala se kao najsloženiji segmentacijski zadatak u cijelom istraživanju. Najuspješniji pojedinačni model bio je UNet na slici segmentiranog zuba, s Diceovim koeficijentom od 64,68%, Tablica 8. Modeli su općenito najbolje rezultate postizali kad je analiza bila ograničena na lokalizirani prikaz zuba, a ne na cijeli OPG, Tablica 11. Kada se promatraju svi modeli zajedno, prosječna uspješnost segmentacije karijesa iznosila je samo 5,21% na OPG-u, zatim 34,10% na pojedinačnom zubu, dok je najbolji prosjek postignut na segmentiranom zubu s 49,16%.

Tablica 11. Deskriptivni statistički pokazatelji Diceova koeficijenta za segmentaciju karijesa s obzirom na vrstu ulazne slike


	N	Aritmetička sredina	Standardna devijacija	Standardna pogreška	95% Interval pouzdanosti Donja granica	95% Interval pouzdanosti Gornja granica	Minim -um	Maxim -um
OPG	9540	5,21	8,51	0,09	5,04	5,38	0,09	24,77
Segmentirani zub	9540	49,16	13,08	0,13	48,89	49,42	19,92	64,68
Pojedinačni zub	9540	34,10	17,64	0,18	33,75	34,46	6,90	59,53
Ukupno	28620	29,49	22,75	0,13	29,23	29,75	0,09	64,68

ANOVA analiza pokazala je da su te razlike statistički vrlo značajne ($F = 25.734, 182$; $p < 0,001$), Tablica 12.

Tablica 12. Rezultati jednosmjerne analize varijance Diceova koeficijenta za segmentaciju karijesa s obzirom na vrstu ulazne slike

	Zbroj kvadrata	Stupnjevi slobode	Srednji kvadrat	F	P
Između grupa	9516830,524	2	4758415,262	25734,182	<0,001
Unutar grupa	5291466,808	28617	184,906		
Ukupno	14808297,332	28619			

Ovaj obrazac jasno potvrđuje da je karijes radiološki najteže prepoznatljiva promjena među analiziranim kategorijama te da modelima izrazito pomaže uklanjanje okolnih anatomskih struktura i fokusiranje na izolirani zub, Slika 18.



Slika 18. Usporedba prosječne uspješnosti modela u segmentaciji karijesa na cijelom ortopantomogramu (OPG), segmentiranom zubu i slici individualnog zuba.

4.5. Segmentacija krunica

U segmentaciji krunica najbolji rezultat ostvario je UNet Big na segmentiranom zubu, s Diceovim koeficijentom od 89,14%, Tablica 8. To pokazuje da je za prepoznavanje krunica najkorisnije prethodno izdvojiti i segmentirati zub, čime se smanjuje utjecaj okolnih struktura i povećava jasnoća rubova restauracije.

Na razini svih modela zajedno, prosječna uspješnost segmentacije krunica iznosila je 26,33% na OPG-u, 76,45% na pojedinačnom zubu i 82,10% na segmentiranom zubu, Tablica 13, Slika


19. Statistička analiza potvrdila je vrlo izražene razlike među skupinama ($F = 19\,157,065$; $p < 0,001$), Tablica 14.

Tablica 13. Deskriptivni statistički pokazatelji Diceova koeficijenta za segmentaciju krunica s obzirom na vrstu ulazne slike

	N	Aritmetička sredina	Standardna devijacija	Standardna pogreška	95% Interval pouzdanosti Donja granica	95% Interval pouzdanosti Gornja granica	Minim -um	Maxim -um
OPG	5040	26,33	19,92	0,28	25,78	26,88	0,27	48,14
Segmentirani zub	5040	82,70	6,62	0,09	82,51	82,88	67,61	89,14
Pojedinačni zub	5040	76,45	17,68	0,25	75,96	76,93	19,97	88,78
Ukupno	15120	61,82	29,79	0,24	61,35	62,30	0,27	89,14

Tablica 14. Rezultati jednosmjerne analize varijance Diceova koeficijenta za segmentaciju krunica s obzirom na vrstu ulazne slike

	Zbroj kvadrata	Stupnjevi slobode	Srednji kvadrat	F	P
Između grupa	9623296,396	2	4811648,198	19157,065	<0,001
Unutar grupa	3796911,776	15117	251,168		
Ukupno	13420208,172	15119			



Slika 19. Usporedba prosječne uspješnosti modela u segmentaciji krunica na cijelom ortopantomogramu (OPG), segmentiranom zubu i slici pojedinačnog zuba.

Takvi rezultati pokazuju da krunice, iako radiološki relativno uočljive, zahtijevaju lokaliziran ulaz kako bi modeli postigli stabilnu i klinički korisnu segmentaciju.

4.6. Segmentacija ispuna

Rezultati segmentacije ispuna pokazali su visoku uspješnost modela kada je analiza provedena na lokaliziranom prikazu zuba. Najbolji pojedinačni rezultat postigao je UNet Big na slici pojedinačnog zuba, s Diceovim koeficijentom od 84,90%, dok je na segmentiranom zubu ostvarena gotovo jednaka vrijednost od 83,49%, Tablica 8. Ovakva bliskost rezultata upućuje na to da je za ispun ključna sama lokalizacija zuba, dok dodatna segmentacija zuba u odnosu na njegov pojedinačni prikaz donosi tek ograničenu dodatnu korist, Slika 20.


Prosječne vrijednosti svih modela zajedno iznosile su 66,07% na OPG-u, 82,04% na pojedinačnom zubu i 80,79% na segmentiranom zubu (Tablica 15), a ANOVA analiza pokazala je statistički značajne razlike ($F = 341.834,17$; $p < 0,001$), Tablica 16.

Tablica 15. Deskriptivni statistički pokazatelji Diceova koeficijenta za segmentaciju ispuna s obzirom na vrstu ulazne slike

	N	Aritmetička sredina	Standard - na devijacija	Standardna pogreška	95% Interval pouzdanosti Donja granica	95% Interval pouzdanosti Gornja granica	Minim -um	Maxim -um
OPG	118428	66,07	8,67	0,03	66,02	66,11	51,17	77,30
Segmentirani zub	118428	80,79	1,78	0,01	80,78	80,80	77,68	83,49
Pojedinačni zub	118428	82,04	1,91	0,01	82,02	82,05	78,12	84,90
Ukupno	355284	76,30	8,94	0,02	76,27	76,33	51,17	84,90

Tablica 16. Rezultati jednosmjerne analize varijance Diceova koeficijenta za segmentaciju ispuna s obzirom na vrstu ulazne slike

	Zbroj kvadrata	Stupnjevi slobode	Srednji kvadrat	F	P
Između grupa	18690611,309	2	9345305,654	341834,17	<0,001
Unutar grupa	9712924,561	355281	27,339		
Ukupno	28403535,870	355283			



Slika 20. Usporedba prosječne uspješnosti modela u segmentaciji ispuna na cijelom ortopantomogramu (OPG), segmentiranom zubu i slici pojedinačnog zuba.

4.7. Segmentacija endodontskog punjenja

U segmentaciji endodontskih punjenja najviši pojedinačni rezultat ostvario je UNet Big na slici pojedinačnog zuba s Diceovim koeficijentom od 79,53%, dok je UNet na segmentiranom zubu ostvario gotovo jednak rezultat od 79,09%, Tablica 8. Ovi podaci pokazuju da su modeli za ovu kategoriju vrlo robusni kada im je ulaz ograničen na izolirani zub, neovisno o tome je li riječ o pojedinačnom ili dodatno segmentiranom prikazu.


Na razini svih modela zajedno prosjeci su iznosili 55,66% na OPG-u, 75,58% na pojedinačnom zubu i 75,71% na segmentiranom zubu, Tablica 17. ANOVA analiza pokazala je statistički značajnu razliku među skupinama ($F = 8950,3467$; $p < 0,001$), Tablica 18.

Tablica 17. Deskriptivni statistički pokazatelji Diceova koeficijenta za segmentaciju endodontskih punjenja s obzirom na vrstu ulazne slike

	N	Aritmetička sredina	Standardna devijacija	Standardna pogreška	95% Interval pouzdanosti Donja granica	95% Interval pouzdanosti Gornja granica	Minim -um	Maxim -um
OPG	9540	55,66	20,32	0,21	55,25	56,07	0,04	74,34
Segmentirani zub	9540	75,71	2,32	0,02	75,66	75,75	71,31	79,09
Pojedinačni zub	9540	75,58	2,74	0,03	75,53	75,64	70,12	79,53
Ukupno	28620	68,98	15,19	0,09	68,81	69,16	0,04	79,53

Tablica 18. Rezultati jednosmjerne analize varijance Diceova koeficijenta za segmentaciju endodontskih punjenja s obzirom na vrstu ulazne slike

	Zbroj kvadrata	Stupnjevi slobode	Srednji kvadrat	F	P
Između grupa	2540786,641	2	1270393,320	8950,347	<0,001
Unutar grupa	4061836,565	28617	141,938		
Ukupno	6602623,206	28619			



Slika 21. Usporedba prosječne uspješnosti modela u segmentaciji endodontskih punjenja na cijelom ortopantomogramu (OPG), segmentiranom zubu i slici individualnog zuba.

Glavna razlika pritom proizlazi iz osjetno slabijeg rezultata na OPG-u, dok su dvije lokalizirane varijante praktično izjednačene, Slika 21. To upućuje na zaključak da je za segmentaciju endodontskih punjenja presudna lokalizacija zuba, ali ne nužno i njegovo dodatno segmentiranje.

Iz toga proizlazi da je prijelaz s cijelog OPG-a na lokalizirani prikaz zuba ključan korak za uspješnu segmentaciju ispuna, dok razlika između dvije lokalizirane varijante ostaje mala.

5. RASPRAVA

Primjena umjetne inteligencije u medicini i stomatologiji predstavlja jedno od najvažnijih područja suvremenoga tehnološkog razvoja. Sustavi temeljeni na dubokom učenju omogućuju automatiziranu analizu radioloških snimaka, smanjenje subjektivnosti i povećanje reproducibilnosti dijagnostičkih postupaka. Posebno važnu ulogu imaju konvolucijske neuronske mreže koje omogućuju učinkovitu ekstrakciju značajki iz složenih medicinskih slika (130).

U stomatologiji, automatizirana analiza ortopantomograma omogućuje preciznu identifikaciju zuba i stomatoloških intervencija te ima značajnu primjenu u kliničkoj i forenzičkoj stomatologiji. Cilj ovog istraživanja bio je procijeniti mogućnosti sustava temeljenih na dubokom učenju za automatiziranu registraciju dentalnog statusa.

Dobiveni rezultati potvrđuju da je primjena konvolucijskih neuronskih mreža tehnički izvediva te da omogućuje visoku razinu točnosti i pouzdanosti u analizi ortopantomograma.

5.1. Kritička analiza rezultata detekcije zuba

Dobiveni rezultati pokazuju da su YOLOv5 modeli postigli vrlo visoku uspješnost u zadatku detekcije zuba na ortopantomogramima, pri čemu je razlučivost ulazne slike bila jedan od najsnažnijih čimbenika koji su određivali konačnu izvedbu modela. Najbolji pojedinačni rezultat ostvaren je modelom YOLOv5x6 uvježbanim od početka, s vrijednošću mAP = 98,02% pri rezoluciji 1820 px, dok je najbolji model uvježban transfornim učenjem ostvario mAP = 97,98%, također pri 1820 px. Takvi rezultati upućuju na to da su suvremene jednokoračne detekcijske arhitekture sposobne vrlo precizno lokalizirati zube na panoramskim snimkama, uz razinu točnosti koja je već sada klinički vrlo relevantna.

Posebno je važan nalaz da se najveći napredak performansi ostvaruje prijelazom s 256 px na 640 px, dok su dodatna poboljšanja između 640 px, 1280 px i 1820 px statistički značajna, ali

numerički znatno manja. Takav obrazac upućuje na postojanje svojevrsnog praga informativnosti slike: pri vrlo niskoj rezoluciji modeli gube dio morfoloških i rubnih informacija potrebnih za pouzdanu lokalizaciju zuba, dok se pri srednjoj i visokoj rezoluciji većina tih informacija očuva. Nakon toga daljnje povećanje broja piksela donosi uglavnom inkrementalna poboljšanja. U metodološkom smislu, to je važan doprinos rada jer pokazuje da razlučivost nije samo tehnički detalj obrade slike, nego ključna eksperimentalna varijabla koja izravno utječe na ishod detekcije.

Dodatno, rezultati pokazuju da su modeli uvježbani od početka pri najvišim razlučivostima dosegili ili blago nadmašili modele uvježbane transfernim učenjem. Pri 256 px transfer learning daje jasnu prednost, što je i očekivano jer prethodno naučene reprezentacije mogu pomoći kada je informacija u slici ograničena. Međutim, kako kvaliteta ulaza raste, ta se prednost smanjuje, a modeli uvježbani isključivo na dentalnom skupu podataka postaju jednako dobri ili bolji. Ovakav nalaz sugerira da kod dovoljno kvalitetnog i opsežnog stomatološkog skupa podataka specifično učenje obilježja prilagođenih domeni može imati veću vrijednost od inicijalnog oslanjanja na reprezentacije naučene na prirodnim slikama. Drugim riječima, transfer learning u ovom kontekstu nije univerzalno superioran pristup, nego njegova korist ovisi o kvaliteti ulazne slike i specifičnostima zadatka.

Rezultati ovog istraživanja sukladni su s podacima iz recentne literature o automatiziranoj detekciji i numeriranju zuba na panoramskim radiogramima. Beşer i sur. u radu objavljenom 20

24. prikazali su vrlo visoke performanse YOLOv5 modela za detekciju zuba u mješovitoj denticiji, uz osjetljivost, preciznost i mAP-0.5 od približno 0,99, 0,99 i 0,98 (137). Ti rezultati vrlo su bliski ovdje dobivenim vrijednostima, osobito pri višim razlučivostima, što potvrđuje da YOLOv5 arhitektura predstavlja robustan izbor za dentalne panoramske snimke. Ipak, izravna usporedba mora biti oprezna jer je istraživanje Beşer i sur. provedeno na pedijatrijskoj populaciji u razdoblju mješovite denticije, s drukčijim anatomske-morfološkim obrascima i drukčijim odnosom izniklih i neizniklih zuba nego u ovom istraživanju.

Usporedba s ranijim YOLO pristupima dodatno potvrđuje napredak novijih arhitektura. Putra i sur. su 2024. za YOLOv4 u zadatku automatskog numeriranja trajnih zuba na panoramskim radiogramima prikazali preciznost 87,7% i osjetljivost 100%, uz vrlo brzo izvođenje modela (138). U odnosu na takve rezultate, ovdje dobivene vrijednosti preciznosti i mAP-a pri razlučivostima 640 px i više jasno pokazuju višu ukupnu uravnoteženost modela, osobito kada se u obzir uzme da se osjetljivost zadržava na vrlo visokoj razini uz istodobno povećanje preciznosti i mAP-a. To sugerira da novije YOLOv5 varijante, osobito veće izvedenice poput m6 i x6, učinkovitije iskorištavaju višerezolucijske informacije i bolje balansiraju lažno pozitivne i lažno negativne nalaze.

Zanimljivo je da i noviji radovi s kasnijim YOLO generacijama ne pokazuju nužno značajan kvalitativni skok u odnosu na najbolje rezultate postignute u ovom istraživanju. Primjerice, Peker i Kurtoğlu su 2025. za YOLOv10 na pedijatrijskim panoramskim snimkama naveli ukupni mAP od 0,968, uz snažan odnos preciznosti i osjetljivosti u cijelome rasponu pragova pouzdanosti (139). Ta je vrijednost vrlo visoka, no i dalje nije viša od najboljih rezultata zabilježenih u ovom radu pri razlučivostima 1280 px i 1820 px. Slično tome, u novijem radu iz 2026. u *BMC Oral Health* YOLOv11 na panoramskim snimkama dječje populacije postiže mAP od 0,8715 u ukupnoj analizi, dok u starijim dobnim skupinama doseže i 0,9817, što autori tumače većom

stabilnošću denticije (trajna denticija) i lakšom detekcijom kod starije djece (140). Ovi nalazi nadopunjuju rezultate ovog istraživanja te potvrđuju da uspješnost modela ne ovisi samo o arhitekturi, nego i o strukturi uzorka, osobito o dobi ispitanika, stadiju denticije, prisutnosti neizniklih zuba i složenosti klasifikacijskog zadatka.

Potrebno je naglasiti da se rezultati različitih istraživanja ne mogu tumačiti kao potpuno i izravno usporedivi. Naime, u dostupnoj literaturi isti istraživački problem nije uvijek definiran na jednak način. Pojedine studije usmjerene su isključivo na detekciju prisutnosti zuba, druge istodobno uključuju i njihovo numeriranje, dok treće obuhvaćaju i dodatne zadatke, poput segmentacije ili razvrstavanja prema statusu denticije. Dodatni razlog ograničene usporedivosti jest činjenica da se u različitim istraživanjima uspješnost modela procjenjuje različitim statističkim i računalnim pokazateljima. Najčešće se pritom koristi mAP pri različitim pragovima, preciznost, osjetljivost, F1-score kao i druge izvedene mjere uspješnosti. Zbog navedene metodološke heterogenosti rezultate ovoga rada potrebno je ponajprije promatrati kao potvrdu da je predloženi pristup pokazao visoku i stabilnu uspješnost unutar vlastitoga, jasno definiranoga eksperimentalnog okvira. Tek se zatim ti nalazi mogu oprezno razmatrati u odnosu na rezultate drugih istraživanja. Rezultati ovog istraživanja također podupiru zaključke novijih preglednih radova. Sustavni pregled i metaanaliza Bonfanti-Gris i sur. iz 2025. zaključuju da duboko učenje pokazuje značajan potencijal za detekciju i segmentaciju zuba na ortopantomogramima, ali istodobno upozoravaju na metodološku heterogenost i potrebu za oprezom pri kliničkoj implementaciji (39). Slično tome, sustavni pregled Maganur i sur. iz 2024. navodi da su u literaturi za detekciju zuba zabilježene vrlo visoke vrijednosti preciznosti, do približno 99,4%, ali uz varijabilnu kvalitetu studija i izražen rizik pristranosti povezan s odabirom uzorka, anotacijama i nedostatkom vanjske validacije (141). U tom kontekstu, ovdje dobiveni rezultati dodatno potvrđuju da je automatska detekcija zuba na OPG-u metodološki

sazrela do razine na kojoj više nije glavno pitanje može li model postići visoku točnost, nego pod kojim se uvjetima ta točnost održava, generalizira i prevodi u svakodnevni klinički rad.

Jedan od najzanimljivijih nalaza ovog rada jest i razlika između uspješnosti detekcije u maksili i mandibuli, pri čemu je za najbolji model zabilježen mAP 96,41% za gornju čeljust i 99,82% za donju čeljust. Iako ta razlika nije središnji predmet većine usporednih studija, ona je klinički logična. Maksilarna regija na OPG-u češće je opterećena superpozicijama anatomskih struktura, projekcijskim distorzijama i manjom jasnoćom prikaza apeksnih i krunskih kontura zuba, dok je prikaz zuba u mandibuli pregledniji i jasnije odvojen od okolnih struktura. Stoga se može pretpostaviti da modeli lakše usvajaju stabilne obrasce za donje zube nego za gornje. Ovaj nalaz otvara prostor za daljnja istraživanja usmjerena na regijski specifične strategije uvježbavanja ili na prilagodbu augmentacije podataka upravo za anatomske složene dijelove slike.

S praktičnog stajališta, dobiveni rezultati imaju nekoliko važnih implikacija. Prvo, potvrđuju da se detekcija zuba može koristiti kao robustan početni korak u višestupanjskim AI sustavima, primjerice za automatsko numeriranje zuba, izdvajanje ROI regija za daljnju segmentaciju ili za mapiranje patoloških promjena na točno određeni zub. Drugo, pokazuju da optimizacija ulazne rezolucije može biti gotovo jednako važna kao i izbor same arhitekture. Treće, sugeriraju da u okruženjima gdje je dostupna dovoljna količina kvalitetno anotiranih dentalnih podataka uvježbavanje od početka može biti potpuno opravdano, osobito ako je cilj maksimalna prilagodba modela radiološkim obilježjima stomatoloških snimaka.

Unatoč vrlo visokim rezultatima, nekoliko ograničenja treba uzeti u obzir. Visoke vrijednosti preciznosti, osjetljivosti i mAP-a same po sebi ne znače nužno i jednaku razinu kliničke generalizabilnosti na snimke različitih uređaja, ustanova i populacija. Usporedbe s literaturom pokazuju da se performanse modela mogu mijenjati ovisno o dobi, statusu denticije, protetskim

radovima, prisutnosti artefakata i načinu anotiranja (140). Upravo zato sljedeći korak ne bi trebao biti samo razvoj još složenijih arhitektura, nego i vanjska validacija na neovisnim, heterogenim skupovima podataka te procjena otpornosti modela na realne kliničke varijacije.

Zaključno, rezultati ovoga istraživanja nedvojbeno potvrđuju da YOLOv5 modeli omogućuju vrlo visoku točnost detekcije zuba na panoramskim radiogramima. Uspješnost modela pritom je u značajnoj mjeri određena kvalitetom ulazne slike, pri čemu se razlučivost pokazala kao jedan od ključnih čimbenika izvedbe. Usporedba s recentnim objavljenim istraživanjima pokazuje da su postignute vrijednosti usporedive s najvišim dosad prijavljenim rezultatima, a u pojedinim segmentima i povoljnije. Znanstveni doprinos ovoga rada nije ograničen samo na potvrdu visoke učinkovitosti primijenjenog pristupa, nego obuhvaća i jasno utvrđivanje eksperimentalnih uvjeta koji tu učinkovitost određuju. Time ovo istraživanje pruža čvrstu metodološku osnovu za daljnji razvoj i primjenu automatiziranih sustava za analizu ortopantomografskih snimaka.

5.2. Kritička analiza rezultata segmentacije zuba

Rezultati ovoga istraživanja pokazuju da je segmentacija zuba na ortopantomogramima ostvarila vrlo visoku razinu uspješnosti neovisno o korištenoj arhitekturi, ali i da je vrsta ulazne slike imala jasan i statistički potvrđen utjecaj na konačni ishod. Najbolji pojedinačni rezultat postigli su UNet Big i DeepLabV3-HRNet V2 W32 na slici individualnog zuba, oba s Diceovim koeficijentom od 95,94%, dok je najbolji rezultat na razini cijelog OPG-a ostvario UNet Big s vrijednošću 95,25%.

Na razini svih modela zajedno prosječna uspješnost segmentacije zuba iznosila je 92,92% na OPG-u i 95,53% na individualnom zubu, a ANOVA je pokazala da je ta razlika statistički vrlo

značajna, uz $F = 742\,660,23$; $p < 0,001$ i procijenjeni $\eta^2 \approx 0,440$. To znači da se gotovo 44% ukupne varijance rezultata može objasniti samom vrstom ulaza slike, što potvrđuje da način prezentacije anatomskih informacija modelu bitno određuje uspješnost segmentacije.

Takav nalaz ima jasnu metodološku logiku. Segmentacija zuba na cijelom OPG-u opterećena je prisutnošću brojnih susjednih struktura, preklapanjem anatomskih sjena, varijacijama kontrasta i složenim međuosobnim odnosima između zuba, alveolarne kosti i okolnih mekih tkiva. Upravo su nejasne interdentalne granice i slab kontrast između zuba i alveolarne kosti među glavnim razlozima zbog kojih je segmentacija na panoramskim snimkama i dalje izazovan zadatak, što ističu i drugi autori (142, 143). U tom kontekstu nije iznenađujuće da individualni zub, izdvojen unutar vlastitog okvira, omogućuje modelu da veći dio kapaciteta usmjeri na stvarne granice zuba, a manji dio na potiskivanje irelevantnoga pozadinskog šuma. Dobivena razlika od oko 2,61 postotnih bodova možda na prvi pogled djeluje umjereno, ali u svjetlu vrlo visokih početnih Dice vrijednosti ona predstavlja stvarno i sadržajno važno poboljšanje.

Dobiveni rezultati također upućuju na to da je UNet obitelj modela ostala najkonzistentnija među testiranim arhitekturama. Iako su i DeepLab varijante, osobito DeepLabV3-HRNet V2 W32, ostvarile izvrsne rezultate, UNet Big je bio najbolji ili među najboljima u oba relevantna ulazna scenarija za segmentaciju zuba. Ovakav obrazac dobro se uklapa u širi razvoj područja, u kojem se U-Net i njegove izvedenice i dalje smatraju svojevrsnom referentnom osnovom za dentalnu medicinsku segmentaciju, osobito kad je riječ o zadacima u kojima su granice objekta relativno kontinuirane, ali lokalno slabo kontrastne. Nedavni rad u *Diagnostics* iz 2025. o simultanoj segmentaciji i detekciji ageneze u djece također koristi U-Net kao središnju arhitekturu i pokazuje da je upravo takav pristup prikladan za panoramske radiograme, iako na znatno zahtjevnijem pedijatrijskom uzorku postiže niži Dice od 0,8773 (144). To dodatno

podupire zaključak da visoke vrijednosti zabilježene u ovom istraživanju nisu slučajne, nego odražavaju dobru prilagodbu arhitekture zadatku segmentacije zuba na OPG-u.

Usporedba s drugim objavljenim istraživanjima pokazuje da se rezultati ovog rada nalaze u samom vrhu recentno prijavljenih performansi za panoramsku segmentaciju zuba. U radu Hou i sur. model Teeth U-Net postigao je Dice od 94,28%, uz preciznost 95,62% i osjetljivost 94,51% za segmentaciju zuba na panoramskim snimkama (142). U odnosu na taj rezultat, najbolji modeli u ovom istraživanju ostvaruju nešto bolje rezultate, osobito pri uporabi individualnog zuba kao ulaza. Slično tome, Özçelik i sur. su 2024. za svoj SE-IB-ED model naveli F1-score 92,65%, mIoU 86,38%, preciznost 92,49% i osjetljivost 99,92% u segmentaciji zuba na panoramskim radiogramima (140). Iako se njihove metrike ne mogu izravno poistovjetiti s Diceovim koeficijentom iz ovog istraživanja, opći dojam je da se i njihov model i naši najbolji modeli kreću u rasponu vrlo visoke segmentacijske uspješnosti. Naši nalazi pritom dodaju važnu dimenziju koju mnoga druga istraživanja ne analiziraju dovoljno eksplicitno - koliki dio uspjeha proizlazi iz same vrste ulaza slike, a ne iz samog izbora arhitekture.

Posebno je važna činjenica da u ovom istraživanju segmentacija zuba ostaje vrlo uspješna čak i kada se provodi na cijelom OPG-u. Prosječna vrijednost od 92,92% pokazuje da je zadatak segmentacije zuba, u usporedbi s kasnijom segmentacijom pojedinih intervencija i patoloških promjena, anatomske i radiološke znatno stabilniji. Drugim riječima, zub kao cjelina predstavlja relativno robustan objekt segmentacije, čak i kada je prisutan složeniji kontekst slike. To je u skladu s recentnim sustavnim pregledom i metaanalizom Bonfanti-Gris i sur. iz 2025., koji zaključuju da duboko učenje pokazuje snažan potencijal za detekciju i segmentaciju zuba na panoramskim radiogramima, ali istodobno upozoravaju na metodološku heterogenost i varijabilnost među studijama (39). Upravo zato je važno istaknuti da se u ovom radu ne

pokazuje samo „visoka točnost”, nego i obrazac prema kojem se točnost dosljedno poboljšava kada se modelu pruži fokusiraniji anatomski ulaz.

S druge strane, izravna usporedba između studija mora biti oprezna. U dostupnoj literaturi razlikuju se veličina i sastav uzorka, dob pacijenata, prisutnost mješovite ili trajne denticije, kvaliteta uređaja, kriteriji isključenja, način anotiranja i sama definicija segmentacijskog cilja. Primjerice, pedijatrijski uzorci s neizniklim ili djelomično razvijenim zubima predstavljaju složeniji problem od uzoraka s potpuno formiranom trajnom denticijom, što vjerojatno pridonosi nižim rezultatima u nekim pedijatrijskim studijama (144). Također, pojedini radovi koriste klasno specifično numeriranje svakog zuba, a drugi tretiraju zube kao jednu zajedničku klasu. Ti metodološki detalji mogu značajno utjecati na prijavljene metrike, pa se slične brojčane vrijednosti ne smiju tumačiti potpuno izvan konteksta.

Naši rezultati imaju i važnu praktičnu implikaciju. Budući da je segmentacija zuba postigla vrlo visoke Dice vrijednosti već na razini OPG-a, može se zaključiti da je automatsko izdvajanje zuba realno primjenjiv međukorak u višestupanjskim AI sustavima za analizu dentalnih radiograma. Takva segmentacija može služiti kao osnova za daljnju detekciju karijesa, krunica, ispuna, endodontskih punjenja, impakcija ili drugih anomalija razvoja. Istodobno, rezultat da individualni zub daje još bolje rezultate upućuje da bi u složenijim zadacima mogla biti korisna dvostupanjska pipeline logika: najprije lokalizacija zuba, zatim precizna segmentacija na izdvojenom isječku. Ovakav pristup dobro se nadovezuje i na istraživanja koja kombiniraju segmentaciju i identifikaciju zuba u jedinstvenim ili kolaborativnim modelima. Chandrashekar i sur. su 2022. pokazali da kolaborativni pristup segmentaciji i identifikaciji na panoramskim radiogramima može znatno poboljšati ukupni učinak, prijavivši segmentacijski rezultat od 98,77% u svojem eksperimentalnom okviru (145). Iako se ta vrijednost ne može izravno

usporediti s ovdje prikazanim Dice koeficijentima bez uvida u identičan evaluacijski protokol, ona potvrđuje da je segmentacija zuba ključni temelj za šire AI sustave u dentalnoj radiologiji.

Tumačenje veličine učinka u ovom radu zaslužuje posebnu pažnju. Vrijednost $\eta^2 \approx 0,440$ pokazuje da vrsta ulaza slike ima velik učinak, no istodobno ne objašnjava svu varijabilnost rezultata. To sugerira da na uspješnost segmentacije i dalje djeluju i drugi čimbenici: sama arhitektura, kapacitet modela, raspored slojeva, strategije augmentacije, kvaliteta anotacija i radiološka heterogenost uzorka. Zanimljivo je pritom da je standardna devijacija na individualnom zubu bila vrlo mala (0,31087), dok je na OPG-u bila znatno veća (2,06295), što znači da segmentacija na individualnom zubu nije samo točnija nego i stabilnija među modelima. Drugim riječima, izolacija zuba ne poboljšava samo prosjek, nego smanjuje i varijabilnost arhitektura. To je važan nalaz za budući razvoj sustava jer implicira da kvalitetan preprocessing može djelomično smanjiti ovisnost uspjeha o izboru točno određene mrežne arhitekture.

Unatoč vrlo visokim rezultatima, treba uzeti u obzir nekoliko ograničenja. Prvo, uspješna segmentacija zuba na internom skupu podataka ne jamči automatski jednaku razinu performansi na vanjskim skupovima snimljenima drugim uređajima ili u drugim ustanovama. Drugo, Dice koeficijent kao globalna mjera preklapanja može prikriti lokalne pogreške na klinički važnim mjestima, primjerice u apiklanom dijelu korijena ili u kontaktnim područjima između susjednih zuba. Treće, iako individualni zub daje bolji rezultat, takav ulaz u stvarnoj primjeni prethodno zahtijeva točnu detekciju i izdvajanje zuba, pa je stvarna klinička vrijednost takvog pristupa uvjetovana uspješnošću prethodnog stupnja obrade. Upravo zato je snaga ovog rada i u tome što rezultati detekcije i segmentacije zajedno sugeriraju da je takav dvostupanjski pristup tehnički ostvariv.

Zaključno, rezultati ovog istraživanja pokazuju da je segmentacija zuba na panoramskim radiogramima metodološki zrela AI zadaća, s vrlo visokim Dice vrijednostima i na razini cijelog OPG-a i na razini individualnog zuba. Usporedba s relevantnim objavljenim istraživanjima pokazuje da su ostvareni rezultati usporedivi s najboljim recentnim radovima, a u pojedinim segmentima i viši. Najvažniji doprinos ovoga rada nije samo potvrda visoke uspješnosti, nego i jasno pokazivanje da vrsta ulazne slike predstavlja jedan od ključnih determinanata segmentacijskog ishoda. Time se stvara čvrsta osnova za sljedeće korake analize, odnosno za segmentaciju pojedinih dentalnih intervencija i patoloških promjena, gdje se očekuje veća osjetljivost na složenost radiološkog konteksta.

5.3. Kritička analiza rezultata segmentacije karijesa i dentalnih intervencija

Rezultati ovog istraživanja pokazuju jasan i dosljedan obrazac koji upućuje na činjenicu - što je ulazna slika anatomski fokusiranija, to je segmentacija manjih i radiološki složenijih struktura uspješnija. Taj uzorak bio je prisutan u svim analiziranim kategorijama, ali je njegova izraženost bila različita ovisno o prirodi ciljne strukture. Dok je segmentacija samog zuba već na razini cijelog OPG-a postizala vrlo visoke vrijednosti, segmentacija karijesa, krunica, ispuna i endodontskih punjenja pokazala je znatno veću ovisnost o lokaliziranom ulazu. To potvrđuje da se težina segmentacijskog zadatka povećava kako ciljana promjena postaje manja, kontrastno slabije definirana i morfološki raznolikija.

5.3.1. Segmentacija karijesa

Među svim analiziranim kategorijama, karijes se pokazao kao najzahtjevniji cilj segmentacije. U ovom istraživanju najbolji rezultat postigao je UNet na segmentiranom zubu s Diceovim koeficijentom 64,68%, dok je prosjek svih modela iznosio samo 5,21% na OPG-u, 34,10% na individualnom zubu i 49,16% na segmentiranom zubu. Takav trend rezultata vrlo jasno

pokazuje da je karijes izrazito osjetljiv na radiološki kontekst: kada je model izložen cijelom panoramskom prikazu, prisutnost susjednih zuba, preklapanje anatomskih struktura i varijacije sivih tonova otežavaju razgraničenje lezije. Nasuprot tome, uklanjanje okolnih struktura i zadržavanje isključivo samog zuba znatno povećava vjerojatnost da model prepozna relevantne radiolucetne promjene.

Ovakav nalaz u skladu je s literaturom koja ističe da je segmentacija karijesa na panoramskim snimkama jedan od najtežih zadataka u dentalnoj AI dijagnostici. U radu Alharbi i sur. autori naglašavaju da neujednačena ekspozicija, razlike u gustoći tkiva te refleksije i superpozicije različitih anatomskih struktura osobito otežavaju precizno ocrtavanje karijesnih lezija na panoramskim slikama (146). Slično tomu, Mărginean i sur. primijenili su u sustavu CariSeg dvostupanjski pristup, u kojem se najprije segmentira područje zuba, a zatim zasebni model segmentira karijesne lezije. Unatoč primijenjenom pristupu, prijavili su srednji Dice od 68,2% za segmentaciju karijesa na panoramskim radiogramima (147). Taj rezultat vrlo je blizak najboljem rezultatu dobivenom u ovom istraživanju, što dodatno potvrđuje da se segmentacija karijesa na OPG-u trenutačno kreće u području umjerene do dobre, ali ne i izrazito visoke uspješnosti.

S druge strane, postoje i radovi koji navode osjetno više vrijednosti. Zhu i sur. u radu o CariesNetu prijavljuju srednji Dice od 93,64% za segmentaciju triju stupnjeva karijesa na panoramskim snimkama (148). Međutim, takav rezultat treba tumačiti oprezno. Riječ je o posebno konstruiranome modelu razvijenom upravo za višestupanjsku segmentaciju karijesa, na skupu s 3127 pažljivo delineiranih lezija, uz drukčiji dizajn eksperimenta i drukčiju razinu specijalizacije zadatka. Upravo zato usporedba s ovim istraživanjem nije potpuno izravna. Ipak, ona je korisna jer sugerira da se za karijes dodatni pomaci vjerojatno neće postići samo

promjenom ulaza, nego i razvojem specijaliziranih arhitektura optimiranih za vrlo male i slabo kontrastne lezije.

U cjelini gledano, naši rezultati upućuju na to da je karijes najosjetljivija kategorija s obzirom na vrstu ulaza i da za segmentaciju karijesa na panoramskim snimkama još uvijek nije pronađeno optimalno rješenje. Klinički gledano, to je logično: karijes često nema oštro definirane granice, njegova radiološka manifestacija može biti diskretna, a diferencijacija od anatomskih varijacija, cervikalnog efekta ili preklapanja susjednih struktura dodatno otežava zadatak. Stoga je jedan od najvažnijih zaključaka ovog dijela istraživanja da se za segmentaciju karijesa lokalizacija i izolacija zuba ne smiju promatrati kao pomoćni korak, nego kao gotovo nužan preduvjet za prihvatljivu uspješnost modela.

5.3.2. Segmentacija krunica

Za razliku od karijesa, segmentacija krunica pokazala je znatno bolje rezultate. Najbolji pojedinačni rezultat ostvaren je modelom UNet Big na segmentiranom zubu s Diceovim koeficijentom 89,14%, dok su prosjeci svih modela iznosili 26,33% na OPG-u, 76,45% na individualnom zubu i 82,10% na segmentiranom zubu. Ovakav obrazac sugerira da su krunice na radiogramu u načelu dobro prepoznatljive, ali da njihovo precizno segmentiranje snažno ovisi o uklanjanju okolnog konteksta.

To je djelomično u skladu s ranijim istraživanjima. Gardiyanoğlu i sur. su 2023. za segmentaciju krunica i mostova na OPG-u prijavili Dice od 0,93, što je više od prosjeka OPG-a u ovom istraživanju, ali usporedivo ili nešto više od najboljih rezultata dobivenih na segmentiranom zubu (34). Razlika vjerojatno proizlazi iz metodoloških čimbenika: u njihovu radu primjenjen je jedinstven U-Net pristup na OPG-u, dok je u ovom istraživanju naglašena i usporedba različitih vrsta ulaza te više arhitektura. Drugim riječima, izravna numerička usporedba nije

potpuno ekvivalentna, ali ipak potvrđuje da su krunice među najsegmentabilnijim restaurativnim strukturama na panoramskim snimkama.

Noviji radovi češće izvještavaju o detekciji nego o segmentaciji krunica, što također nešto govori o prirodi zadatka. U studiji Turosz i sur. AI sustav pokazao je za krunice vrlo visoku osjetljivost, specifičnost i točnost, ali je preciznost bila umjerenija, pri čemu su autori naglasili da AI često pogrešno zamjenjuje opsežne ispune, direktne ljuskice i ortodontske bravice s kunicama (149). Slično tome, Khurshid i sur. u višeregionalnom istraživanju o detekciji dentalnih restauracija navode da su krunice jedna od uspješnijih klasa u objektnoj detekciji, s AP-om oko 0,88, ali istodobno pokazuju da je radiološka raznolikost restauracija i dalje izazov za modele (150). Ove studije indirektno podupiru nalaz našeg istraživanja: krunice jesu dovoljno radiopaktne i morfološki upadljive da ih model dobro uoči, ali za preciznu segmentaciju rubova ipak je potrebno smanjenje pozadinskog šuma i susjednih struktura.

Stoga se može zaključiti da krunice predstavljaju kategoriju u kojoj je AI već dosegao vrlo dobru razinu izvedbe, ali u kojoj se najbolji rezultati ostvaruju kada se modelu ponudi segmentirani zub umjesto cijeloga panoramskog prikaza. To ima praktičnu važnost jer sugerira da će sustavi koji kombiniraju prethodnu lokalizaciju zuba i naknadnu segmentaciju restoracija vjerojatno biti pouzdaniji od jednofaznih sustava koji pokušavaju segmentirati sve strukture izravno na cijelom OPG-u.

5.3.3. Segmentacija ispuna

Segmentacija ispuna pokazala je vrlo dobru uspješnost, uz zanimljiv obrazac: razlika između individualnog i segmentiranog zuba bila je mala, dok je razlika u odnosu na OPG ostala izražena. U istraživanju najbolji rezultat ostvario je UNet Big na individualnom zubu s Diceovim koeficijentom 84,90%, dok su prosjeci svih modela iznosili 66,07% na OPG-u,

82,04% na individualnom zubu i 80,79% na segmentiranom zubu. Ovaj nalaz sugerira da je za segmentaciju ispuna ključno prije svega lokalizirati zub, dok dodatno uklanjanje okolnih struktura na razinu segmentiranog zuba donosi tek ograničenu dodatnu korist.

Takvo tumačenje podupire i dostupna literatura. Gardiyanoglu i sur. su za segmentaciju ispuna na OPG-u naveli Dice od 0,87, što je usporedivo s najboljim rezultatima u ovom istraživanju na individualnim i segmentiranim zubima, a osjetno više od prosjeka na cijelom OPG-u (34). U tom smislu ovdje dobiveni rezultati nadopunjuju postojeću literaturu jer pokazuju da ispun nije jedinstvena kategorija koja se ponaša jednako u svim ulaznim uvjetima: kada se ispuni promatraju izolirano unutar pojedinačnog zuba, modeli postižu vrlo stabilne i visoke Dice vrijednosti, ali se na razini cijelog OPG-a dio te prednosti gubi.

To je i radiološki razumljivo. Ispuni su često vrlo radiopaktni, ali njihova morfologija može biti izrazito varijabilna: od malih aproksimalnih ispuna do velikih okluzalnih i MOD restauracija. Na cijelom OPG-u njihova vizualna sličnost s drugim radiopaktnim strukturama - primjerice kronicama, ortodontskim elementima ili preklapajućim projekcijama - može dovesti do pogrešaka segmentacije. Khurshid i sur. navode da su ispuni među solidnije detektiranim klasama u panoramskoj objektnoj detekciji, ali istodobno naglašavaju da varijabilna kvaliteta slike i složenost izgleda tretiranih zuba ostaju izazov za modele (150). To je u skladu s našim nalazom da je lokalizirani ulaz za ispune više nego dovoljan za dobru segmentaciju, dok je globalni panoramski kontekst nepotrebno opterećujući.

Praktično gledano, to znači da za ispune nije nužno ići do krajnje redukcije slike na segmentirani zub, nego je često dovoljno kvalitetno izdvajanje pojedinačnog zuba unutar odgovarajućeg okvira. To je korisna spoznaja za dizajn budućih pipelineova, jer individualni zub može

predstavljati optimalnu ravnotežu između očuvanoga lokalnog konteksta i uklanjanja globalnog šuma slike.

5.3.4. Segmentacija endodontskih punjenja

Rezultati segmentacije endodontskih punjenja u ovom istraživanju pokazuju da je riječ o zadatku srednje do visoke težine, ali s jasnom prednosti prilikom korištenja lokaliziranog ulaza. Najbolji pojedinačni rezultat postigao je UNet Big na individualnom zubu s Diceovim koeficijentom 79,53%, dok je na segmentiranom zubu UNet ostvario vrlo sličnih 79,09%. Prosjeci svih modela iznosili su 55,66% na OPG-u, 75,58% na individualnom zubu i 75,71% na segmentiranom zubu. Drugim riječima, glavna prednost dolazi iz prijelaza s OPG-a na lokalizirani zub, dok između individualnog i segmentiranog zuba gotovo da nema razlike.

Takav rezultat izrazito je zanimljiv jer je u skladu s ranijim opažanjima iz literature. Gardiyanoğlu i sur. su za segmentaciju endodontskih punjenja na OPG-u prijavili Dice od 0,78, praktički vrlo blizak najboljim rezultatima dobivenima u ovom istraživanju na individualnim i segmentiranim zubima (34). U istom radu autori navode i glavne uzroke slabijih segmentacija: neadekvatna punjenja, punjenja koja se ne pružaju cijelom dužinom kanala, superpozicija s korijenima susjednih zuba te pogrešno tumačenje restauracije u pulpnoj komori kao gutaperke. Upravo ti razlozi vrlo dobro objašnjavaju i obrazac dobiven u ovom istraživanju: na cijelom OPG-u takve fine, tanke i linearne strukture lako se izgube u složenoj slici, dok lokalizirani prikaz zuba bitno povećava njihovu prepoznatljivost.

Srodni radovi koji su koristili objektno-detektorske, a ne segmentacijske pristupe, također upućuju na sličan zaključak. Turosz i sur. su pokazali da AI može postići vrlo visoke performanse u detekciji korijenskih punjenja na panoramskim radiogramima, s ukupnim pokazateljima iznad 90%, ali pritom i sami naglašavaju da interpretacija finih endodontskih

nalaza ostaje osjetljiva na kvalitetu prikaza i zahtijeva provjeru kliničara. Khurshid i sur. u radu o višeregionalnoj detekciji dentalnih restauracija navode da su upravo male endodontske strukture i elementi punjenja kanala teže prepoznatljivi od većih protetskih radova zbog slabijeg kontrasta, preklapanja anatomskih elemenata i nejasnih granica (150). Iako ti radovi ne mjere isto što i semantička segmentacija, smjer nalaza je isti: endodontska punjenja jesu detektabilna i segmentabilna, ali njihova točna analiza traži fokusiran i dovoljno čist ulaz.

Važan je i metodološki zaključak da za endodontska punjenja dodatna segmentacija zuba nije nužno bolja od individualnog zuba. To sugerira da ovdje mali dio okolnog anatomskog konteksta možda čak pomaže modelu u orijentaciji unutar korijena, osobito u višekorijenskim zubima. Dakle, za ovu kategoriju optimalan ulaz nije onaj sa što manje konteksta, nego onaj koji je dovoljno lokaliziran.

Zaključno, rezultati segmentacije karijesa i dentalnih intervencija pokazuju da duboko učenje na panoramskim radiogramima ima najveći potencijal kada se primjenjuje na lokalizirane prikaze pojedinačnih zuba. Karijes ostaje najzahtjevnija kategorija i vjerojatno će zahtijevati dodatno specijalizirane modele i bogatije anotirane skupove podataka. Krunice i ispuni pokazuju vrlo dobru segmentabilnost, dok su endodontska punjenja nešto zahtjevnija, ali i dalje dovoljno prepoznatljiva za klinički relevantnu AI analizu. Najvažnija metodološka poruka ovog dijela istraživanja jest da se optimalna uspješnost ne postiže samo izborom arhitekture, nego ponajprije odabirom odgovarajuće razine ulaznog anatomskog fokusa (38, 131, 132).

5.4. Utjecaj arhitekture modela, vrste ulazne slike i metode uvježbavanja na uspješnost detekcije i segmentacije

Rezultati istraživanja upućuju na glavne eksperimentalne čimbenike koji su određivali uspješnost modela, a to su arhitekture modela, vrsta ulazne slike te metoda uvježbavanja, budući da njihov doprinos nije bio jednak u svim zadacima. Upravo promatranje tih čimbenika u

međusobnom odnosu omogućuje potpunije razumijevanje uvjeta u kojima modeli dubokog učenja postižu optimalne rezultate u analizi ortopantomografskih snimaka.

5.4.1. Usporedba arhitektura modela

Dobiveni rezultati pokazali su da uspješnost modela ovisi o vrsti arhitekture, ali i o prirodi samoga zadatka. U detekciji zuba vrlo visoke rezultate ostvarile su sve ispitivane YOLOv5 varijante, pri čemu su najbolje rezultate uglavnom postizale veće i kapacitetski snažnije izvedenice modela. Međutim, razlike među njima pri višim razlučivostima ulazne slike nisu bile velike, što upućuje na zaključak da u uvjetima informativnog i kvalitetnog ulaza i manje varijante mogu postići vrlo visoku razinu uspješnosti. Time se pokazuje da sama veličina modela nije jedini čimbenik koji određuje uspješnost detekcije, nego da njezin učinak treba promatrati u odnosu na kvalitetu ulaza i specifičnosti zadatka.

U segmentacijskim zadacima razlike među arhitekturama bile su izraženije. UNet i njegove veće izvedenice pokazale su najveću konzistentnost i najviše vrijednosti Diceova koeficijenta u većini analiziranih kategorija, osobito u segmentaciji zuba, krunica, ispuna i endodontskih punjenja. Pojedine DeepLabV3 arhitekture također su ostvarile vrlo visoke rezultate, osobito u segmentaciji zuba, ali se UNet obitelj modela pokazala stabilnijom u širem rasponu zadataka. Takav nalaz upućuje na zaključak da optimalna arhitektura nije univerzalna za sve zadatke, ali da su modeli s izraženom sposobnošću očuvanja prostornih informacija i precizne rekonstrukcije kontura posebno prikladni za dentalnu radiološku segmentaciju.

Promatrajući rezultate zajedno, može se zaključiti da izbor arhitekture ima stvaran, ali ne i samostalan učinak. Njegov doprinos postaje posebno važan u složenijim segmentacijskim zadacima dok se u detekciji, uz dostatnu kvalitetu slike, razlike među arhitekturama djelomično smanjuju. Time se potvrđuje da arhitekturu modela treba birati u odnosu na vrstu zadatka, a ne kao izolirani tehnički parametar.

5.4.2. Utjecaj vrste i rezolucije ulazne slike

Vrsta ulazne slike pokazala se kao jedan od ključnih čimbenika uspješnosti segmentacijskih modela. Dok je detekcija zuba analizirana na razini cijelog ortopantomograma, segmentacijski zadaci jasno su pokazali da lokalizirani prikazi zuba, odnosno individualni i segmentirani zub, omogućuju bolje rezultate od analize cijelog OPG-a. Taj obrazac bio je prisutan u segmentaciji zuba, a još izraženiji u segmentaciji karijesa, krunica, ispuna i endodontskih punjenja.

Navedeni nalaz može se objasniti prirodom panoramske snimke. Cijeli OPG sadrži velik broj anatomskih i projekcijskih informacija koje nisu neposredno relevantne za pojedinu ciljanu strukturu, uključujući susjedne zube, alveolarnu kost, sjene mekih tkiva, superpozicije i različite radiološke artefakte. Takav složen kontekst povećava razinu šuma i otežava modelu izdvajanje morfološki finih ili slabo ograničenih promjena. Suprotno tomu, individualni ili segmentirani zub smanjuje količinu irelevantnih informacija i usmjerava model na anatomske ograničeno područje interesa, čime se povećava vjerojatnost točne segmentacije.

Važno je pritom naglasiti da korist lokaliziranog ulaza nije bila jednaka za sve kategorije. U segmentaciji zuba razlika između OPG-a i individualnog zuba bila je relativno umjerena, što pokazuje da je zub kao anatomska cjelina dovoljno robustan cilj segmentacije čak i u složenijem panoramskom kontekstu. Nasuprot tome, kod karijesa i finijih restaurativnih nalaza učinak lokalizacije bio je znatno izraženiji, što potvrđuje da važnost vrste ulaza raste s porastom složenosti zadatka i smanjenjem radiološke jasnoće ciljne strukture. Time se pokazuje da vrsta ulazne slike nije samo tehnički detalj obrade, nego jedan od temeljnih metodoloških čimbenika uspješnosti segmentacijskih modela.

Rezultati istraživanja pokazali su da razlučivost slike ima značajan utjecaj na performanse modela. Najniže vrijednosti točnosti zabilježene su pri rezoluciji od 256 piksela. Ovaj rezultat može se objasniti gubitkom dijagnostičkih informacija tijekom smanjenja rezolucije slike.

Značajno poboljšanje performansi zabilježeno je pri rezoluciji od 640 piksela. Daljnje povećanje rezolucije rezultiralo je samo minimalnim poboljšanjem. Ovaj rezultat upućuje na to da razlučivost od približno 640 piksela predstavlja optimalan kompromis između točnosti i računalne učinkovitosti. Slični rezultati opisani su u drugim istraživanjima (133, 134). Usklađeno s redoslijedom navođenja literature, dodatni metodološki i forenzički kontekst potkrjepljuje se izvorima o standardizaciji DVI postupka i prethodnim istraživanjima dubokog učenja u dentalnoj radiologiji (135, 136).

5.4.3. Utjecaj metode uvježbavanja i kvalitete ulaza

Jedan od ključnih ciljeva istraživanja bio je usporediti performanse prethodno uvježbanih modela i modela uvježbanih od početka. Usporedba modela uvježbanih od početka i modela razvijenih primjenom transfernog učenja pokazala je da učinak metode uvježbavanja nije jednoznačan, nego ovisi o kvaliteti ulazne slike. Rezultati pokazuju da prethodno uvježbani modeli postižu bolje rezultate pri manjim razlučivostima slike, što upućuje na zaključak da prethodna uvježbanost na općim skupovima može olakšati prepoznavanje specifičnih obrazaca kada je informativnost ulaza ograničena. U takvim okolnostima model raspolaže manjom količinom korisnih vizualnih podataka pa prethodno stečeno znanje može djelovati kao važna početna prednost.

Međutim, s povećanjem razlučivosti slike ta se prednost postupno smanjivala, a modeli uvježbani od početka postizali su usporedive, a u pojedinim slučajevima i bolje rezultate. Ovakav nalaz pokazuje da se pri kvalitetnijem ulazu i dovoljno reprezentativnome dentalnom skupu podataka modeli mogu vrlo učinkovito prilagoditi specifičnostima stomatološke radiološke domene i bez oslanjanja na prethodno uvježbane reprezentacije iz drugih područja. Drugim riječima, korisnost transfernog učenja u ovom istraživanju bila je uvjetovana eksperimentalnim okolnostima, a ne univerzalnim.

Ovaj rezultat ima važnu metodološku implikaciju. Pokazuje da se način uvježbavanja ne može procjenjivati odvojeno od kvalitete ulaza, jer njihovo djelovanje nije neovisno. U uvjetima slabije kvalitete slike transfer learning može nadoknaditi dio informacijskog deficita, dok u uvjetima veće razlučivosti i prikladno oblikovanog skupa podataka modeli uvježbani od početka mogu u većoj mjeri usvojiti specifična obilježja dentalnih radiograma. Time se potvrđuje da optimalna metoda uvježbavanja ovisi o stvarnim karakteristikama podataka i ciljnog zadatka (18).

Promatrani zajedno, dobiveni nalazi pokazuju da uspješnost modela dubokog učenja u analizi ortopantomografskih snimaka nije određena jednim izoliranim čimbenikom, nego međudjelovanjem arhitekture modela, kvalitete ulaza i stupnja anatomske lokalizacije slike. U detekcijskim zadacima ključnu ulogu imala je razlučivost ulazne slike, dok je u segmentacijskim zadacima presudniji čimbenik bio tip ulaza, odnosno razina fokusiranosti slike na ciljanu strukturu. Učinak arhitekture modela bio je prisutan u svim analizama, ali se njegova važnost osobito istaknula u složenijim segmentacijskim zadacima. Slično tomu, metoda uvježbavanja pokazala se korisnom, ali ne apsolutno nadmoćnom, budući da je njezina vrijednost ovisila o informativnosti ulaza i specifičnostima skupa podataka.

Iz toga proizlazi da optimalna konfiguracija modela ne može biti jednaka za sve zadatke dentalne radiološke analize. Za detekciju zuba presudni su dovoljna razlučivost slike i prikladna detekcijska arhitektura, dok je za segmentaciju dentalnih zahvata od osobite važnosti prethodna lokalizacija anatomskeg područja interesa. Time se potvrđuje da je za razvoj pouzdanih sustava umjetne inteligencije u dentalnoj radiologiji nužno istodobno razmatrati više metodoloških razina: izbor arhitekture, način uvježbavanja i karakteristike ulaznih podataka. Upravo takav višedimenzionalni pristup predstavlja jedan od važnijih doprinosa ovoga istraživanja.

5.5. Ograničenja istraživanja i implikacije za buduću primjenu

Unatoč vrlo visokim rezultatima detekcije i segmentacije, potrebno je uzeti u obzir nekoliko ograničenja provedenog istraživanja. Prije svega, modeli su razvijeni i evaluirani na podacima prikupljenima u ograničenom institucionalnom i tehničkom okviru, što može ograničiti mogućnost njihove izravne generalizacije na snimke dobivene drugim uređajima, u drugim ustanovama i na populacijama različitih demografskih i kliničkih obilježja. Dodatno, uspješnost modela ovisi o kvaliteti ulaznih podataka, uključujući razlučivost slike, standardizaciju protokola snimanja i konzistentnost anotacija. Poseban izazov predstavljaju dijagnostički složeniji slučajevi, prisutnost artefakata i varijabilnost stomatoloških intervencija, što može utjecati na stabilnost modela, osobito u segmentaciji karijesa i finijih endodontskih struktura.

Važno je istaknuti i da visoka razina tehničke uspješnosti sama po sebi nije dostatna za rutinsku kliničku ili forenzičnu primjenu. Za širu implementaciju nužna je dodatna validacija na heterogenim i neovisnim skupovima podataka, kao i razvoj standardiziranih protokola za pripremu i anotaciju slika. Jednako tako, buduća primjena zahtijevat će veću razinu interpretabilnosti modela, kako bi se osigurala transparentnost algoritamskih odluka i njihova usklađenost s etičkim i regulatornim zahtjevima. U tom smislu, daljnji razvoj trebao bi biti usmjeren prema vanjskoj validaciji modela, uključivanju raznolikijih skupova podataka, integraciji pristupa objašnjive umjetne inteligencije te optimizaciji sustava za primjenu u stvarnim kliničkim i forenzičnim uvjeti

6. ZAKLJUČAK

Rezultati istraživanja pokazali su da sustavi temeljeni na konvolucijskim neuronskim mrežama omogućuju pouzdanu i visoko preciznu automatiziranu analizu ortopantomografskih snimaka. Potvrđeno je da je računalna detekcija zuba i segmentacija dentalnih zahvata izvediva uz visoku razinu podudarnosti s ručno anotiranim referentnim podacima, koji u ovom istraživanju predstavljaju zlatni standard.

U zadatku detekcije zuba ostvareni su iznimno visoki rezultati. Najuspješniji model, YOLOv5x6 uvježban od početka, postigao je mAP od 98,02% pri rezoluciji od 1820 px, dok je najbolji model uvježban transfernim učenjem ostvario mAP od 97,98%. Statistička analiza pokazala je da razlučivost ulazne slike značajno utječe na uspješnost modela, pri čemu je najveći porast performansi ostvaren prijelazom s 256 px na 640 px, dok su poboljšanja pri višim razlučivostima bila manja, ali i dalje statistički značajna.

U segmentaciji zuba najbolji rezultati postignuti su na prikazu individualnog zuba, gdje su UNet Big i DeepLabV3-HRNet V2 W32 ostvarili Dice od 95,94%, dok je najbolji rezultat na cijelom OPG-u iznosio 95,25%. Prosječna uspješnost segmentacije bila je statistički značajno viša na individualnom zubu nego na cijelom ortopantomogramu. Time je potvrđena važnost lokalizacije ulazne slike za postizanje optimalnih rezultata segmentacije.

Kod segmentacije dentalnih zahvata i promjena utvrđen je jasan gradijent složenosti. Karijes se pokazao kao najzahtjevnija kategorija, dok su krunice, ispuni i endodontska punjenja pokazali znatno bolju segmentabilnost, osobito kad je ulaz bio ograničen na individualni ili segmentirani zub. Time je potvrđeno da morfološka definiranost i radiološka uočljivost ciljne strukture bitno određuju uspješnost modela.

Na temelju dobivenih rezultata, istraživačka hipoteza je potvrđena. Automatizirani sustavi temeljeni na konvolucijskim neuronskim mrežama omogućuju pouzdanu i visoko preciznu detekciju zuba te segmentaciju dentalnih zahvata na ortopantomografskim snimkama, uz rezultate usporedive s ručno anotiranim referentnim podacima.

Između različitih arhitektura modela utvrđene su razlike u uspješnosti detekcije i segmentacije. Povećanje razlučivosti ulazne slike statistički značajno je poboljšalo performanse modela. Modeli uvježbani na individualnim ili segmentiranim zubima postigli su bolje rezultate od modela uvježbanih na cijelim ortopantomogramima. Transferno učenje pokazalo je prednost u uvjetima niže kvalitete ulaza, ali pri višim razlučivostima modeli uvježbani od početka postigli su usporedive ili bolje rezultate.

Primarni cilj istraživanja ostvaren je razvojem i evaluacijom metode temeljene na dubokom učenju za automatizirano očitavanje ortopantomograma. Ostvareni su i sekundarni ciljevi, uključujući usporedbu arhitektura i metoda uvježbavanja, analizu utjecaja rezolucije, identi-

fikaciju prednosti i ograničenja sustava te statističku potvrdu njegove pouzdanosti.

Zaključno, ovo istraživanje potvrđuje da duboko učenje predstavlja znanstveno i klinički opravdan pristup za automatiziranu analizu ortopantomografskih snimaka. Ključni čimbenici uspješnosti sustava bili su razlučivost ulazne slike, izbor arhitekture i stupanj lokalizacije analiziranog područja. Dobiveni rezultati pružaju čvrstu osnovu za daljnji razvoj i kliničku primjenu automatiziranih sustava u dentalnoj radiologiji i forenzičnoj stomatologiji.

7. LITERATURA

1. Sweet D, Pretty IA. A look at forensic dentistry—Part 2: teeth as weapons of violence—identification of bitemark perpetrators. *Br Dent J.* 2001 Apr 28;190(8):415-8. doi:10.1038/sj.bdj.4800990.
2. Pretty IA, Sweet D. Forensic dental identification: an overview. *Br Dent J.* 2007;202:305-12. doi:10.1038/bdj.2007.182.
3. Pretty IA, Sweet D. The scientific basis for human identification: dental evidence. *J Forensic Sci.* 2001;46:1049-53. doi:10.1520/JFS15521J.
4. Bowers CM. Forensic odontology: an overview. *Dent Clin North Am.* 2014;58:369-80. doi:10.1016/j.cden.2014.01.001.
5. Palmela Pereira C, Carvalho R, Augusto D, Almeida T, Francisco AP, Salvado e Silva F, et al. Development of artificial intelligence-based algorithms for the process of human identification through dental evidence. *Int J Legal Med.* 2025 Jul;139(4):1835-50. doi:10.1007/s00414-025-03453-x.
6. Radu CC, Hoge T, Carașca C, Radu CM. Forensic odontology in the digital era: a narrative review of current methods and emerging trends. *Diagnostics (Basel).* 2025 Oct 10;15(20):2550. doi:10.3390/diagnostics15202550.
7. Mohammad N, Ahmad R, Kurniawan A, Mohd Yusof MYP. Applications of contemporary artificial intelligence technology in forensic odontology as primary forensic identifier: a scoping review. *Front Artif Intell.* 2022 Dec 6;5:1049584. doi:10.3389/frai.2022.1049584.
8. Milošević D, Vodanović M, Galić I, Subašić M. Automated estimation of chronological age from panoramic dental X-ray images using deep learning. *Expert Syst Appl.* 2022;189:116038. doi:10.1016/j.eswa.2021.116038.

9. Wang J, Dou J, Han J, Li G, Tao J. A population-based study to assess two convolutional neural networks for dental age estimation. *BMC Oral Health*. 2023 Feb 17;23(1):109. doi:10.1186/s12903-023-02817-2.
10. Kshatri SS, Singh D. Convolutional neural network in medical image analysis: a review. *Arch Comput Methods Eng*. 2023;30(4):2793-810. doi:10.1007/s11831-023-09898-w.
11. Mienye ID, Swart TG, Obaido G, Jordan M, Ilono P. Deep convolutional neural networks in medical image analysis: a review. *Information (Basel)*. 2025 Mar 3;16(3):195. doi:10.3390/info16030195.
12. Schwendicke F, Golla T, Dreher M, Krois J. Convolutional neural networks for dental image diagnostics: a scoping review. *J Dent*. 2019 Dec;91:103226. doi:10.1016/j.jdent.2019.103226.
13. Anwar SM, Majid M, Qayyum A, Awais M, Alnowami M, Khan MK. Medical image analysis using convolutional neural networks: a review. *J Med Syst*. 2018;42:226. doi:10.1007/s10916-018-1088-1.
14. Felek T, Tercanlı H, Şendişçi Gök R. Evaluating vision transformers and convolutional neural networks in the context of dental image processing: a systematic review. *BMC Oral Health*. 2025 Oct 15;25(1):1626. doi:10.1186/s12903-025-07036-5.
15. Khattak O, Hashem AS, Alqarni MS, Almufarrij RAS, Siddiqui AY, Anis R, et al. Deep learning applications in dental image-based diagnostics: a systematic review. *Healthcare (Basel)*. 2025 Jun 18;13(12):1466. doi:10.3390/healthcare13121466.
16. ForouzeshFar P, Safaei AA, Ghaderi F, Hashemikamangar SS. Dental caries diagnosis from bitewing images using convolutional neural networks. *BMC Oral Health*. 2024 Feb 10;24(1):211. doi:10.1186/s12903-024-03973-9.
17. Hadden AM, FGDP(UK). Clinical examination and record-keeping: Part 3: electronic records. *Br Dent J*. 2017;223(3):159-64. doi:10.1038/sj.bdj.2017.627.

18. Česhko AZ, Pavičin IS, Milošević D, Banjšak L, Subašić M, Vodanović M. A forensic odontology application: impact of image quality on CNNs for dental status analysis from orthopantomograms. *Appl Sci*. 2025;15(18):10265.
19. Stephens MB, Wiedemer JP, Kushner GM. Dental problems in primary care. *Am Fam Physician*. 2018 Dec 1;98(11):654-60.
20. Emam ANM. Role of forensic odontology in identification of persons: a review article. *Cureus*. 2024 Mar 20;16(3):e56570. doi:10.7759/cureus.56570.
21. Matsuda S, Yoshida H, Ebata K, Shimada I, Yoshimura H. Forensic odontology with digital technologies: a systematic review. *J Forensic Leg Med*. 2020;74:102004. doi:10.1016/j.jflm.2020.102004.
22. Cheplygina V, de Bruijne M, Pluim JPW. Not-so-supervised: a survey of semi-supervised, multi-instance, and transfer learning in medical image analysis. *Med Image Anal*. 2019;54:280-96. doi:10.1016/j.media.2019.03.009.
23. Fletcher JO, Townsend GC. Forensic odontology—a review of dental evidence. *Forensic Sci Int*. 2015;254:108-17. doi:10.1016/j.forsciint.2015.08.021.
24. Prajapati G, Sarode SC, Sarode GS, Shelke P, Awan KH, Patil S. Role of forensic odontology in the identification of victims of major mass disasters: a systematic review. *PLoS One*. 2018;13:e0199791. doi:10.1371/journal.pone.0199791.
25. Boedi RM, Angelakopoulos N, Nuzzolese E, Pandey H, Mânica S, Franco A. Positive identification through comparative dental analysis in mass disasters: a systematic review and meta-analysis. *Forensic Sci Med Pathol*. 2025;21:916-25. doi:10.1007/s12024-024-00876-7.
26. Lacasella GV, Signorini L, Ballini A, Bizzoca ME, Musella G, Lo Muzio E, et al. Forensic odontology: a comprehensive review. *Minerva Dent Oral Sci*. 2025. doi:10.23736/S2724-6329.25.05187-3.

27. Alwohaibi RN, Almaimoni RA, Alshrefy AJ, AlMusaiet LI, AlHazzaa SA, Menezes RG. Dental implants and forensic identification: a systematic review. *J Forensic Leg Med.* 2023;96:102508. doi:10.1016/j.jflm.2023.102508.
28. Ata Ali J, Ata Ali F. Forensic dentistry in human identification: a review. *J Clin Exp Dent.* 2014;6:e162-e167. doi:10.4317/jced.51387.
29. Zahrani AA. Current trends in identification in forensic dentistry. *Int J Community Med Public Health.* 2025;12:456-62.
30. Krishan K, Kanchan T, Garg AK. Dental evidence in forensic identification: an overview, methodology and present status. *Open Dent J.* 2015 Jul 31;9:250-6. doi:10.2174/1874210601509010250.
31. Thrall JH, Li X, Li Q, Cruz C, Do S, Dreyer K, Brink J. Artificial intelligence in radiology: current applications and future directions. *J Am Coll Radiol.* 2018;15:512-20. doi:10.1016/j.jacr.2018.01.029.
32. Hung K, Montalvao C, Tanaka R, Kawai T, Bornstein MM. The use and performance of artificial intelligence applications in dental and maxillofacial radiology: a systematic review. *Dentomaxillofac Radiol.* 2020 Jan;49(1):20190107. doi:10.1259/dmfr.20190107.
33. Shan T, Tay FR, Gu L. Application of artificial intelligence in dentistry. *J Dent Res.* 2021 Mar;100(3):232-44. doi:10.1177/0022034520969115.
34. Gardiyanoglu E, Ünsal G, Akkaya N, Aksoy S, Orhan K. Automatic segmentation on orthopantomographs. *Diagnostics (Basel).* 2023;13:876. doi:10.3390/diagnostics13050876.
35. Dashti M, Londono J, Ghasemi S, Tabatabaei S, Hashemi S, Baghaei K, et al. Evaluation of accuracy of deep learning and conventional neural network algorithms in detection of dental implant type using intraoral radiographic images: a systematic review and meta-analysis. *J Prosthet Dent.* 2025;133(1):56-67. doi:10.1016/j.prosdent.2023.11.030.

36. Küçük DB, Imak A, Özçelik STA, Çelebi A, Türkoğlu M, Sengur A, et al. Hybrid CNN-Transformer model for accurate impacted tooth detection in panoramic radiographs. *Diagnostics (Basel)*. 2025 Jan 22;15(3):244. doi:10.3390/diagnostics15030244.
37. Morid MA, Borjali A, Del Fiol G. A scoping review of transfer learning research on medical image analysis using ImageNet. *Comput Biol Med*. 2021 Jan;128:104115. doi:10.1016/j.compbiomed.2020.104115.
38. Rubiu G, Bologna M, Cellina M, Cè M, Sala D, Pagani R, et al. Teeth segmentation using Mask R-CNN. *Appl Sci*. 2023;13:8765. doi:10.3390/app13158765.
39. Bonfanti-Gris M, Herrera A, Salido-Rodríguez MP, Martínez-Rus F, Pradíes G. Deep learning for tooth detection and segmentation in panoramic radiographs: a systematic review and meta-analysis. *BMC Oral Health*. 2025;25:1280. doi:10.1186/s12903-025-06349-9.
40. Khan SF, Siddique A, Khan AM, Shetty B, Fazal I. Artificial intelligence in periodontology and implantology. *J Med Artif Intell*. 2024;7:45-56.
41. Anil S, Sudeep K, Saratchandran S, Sweetey VK. Revolutionizing dental caries diagnosis using artificial intelligence. In: *Perspectives of dental caries*. London: IntechOpen; 2024.
42. Miki Y, Muramatsu C, Hayashi T, Zhou X, Hara T, Katsumata A, et al. Tooth classification in cone beam CT using deep convolutional neural networks. *Comput Biol Med*. 2017;80:24-9.
43. Rivetti L, Studen A, Sharma M, Chan J, Jeraj R. Uncertainty evaluation and registration assessment of deformable image registration using CNNs. *Phys Med Biol*. 2024;69(11):115045.
44. Khanagari SB. Development, applications and performance of artificial intelligence in dentistry: a systematic review. *J Dent Sci*. 2021;16(1):508-22. doi:10.1016/j.jds.2020.06.019.
45. Russell SJ, Norvig P. *Artificial intelligence: a modern approach*. 3rd ed. Upper Saddle River (NJ): Prentice Hall; 2010.

46. Nilsson NJ. The quest for artificial intelligence: a history of ideas and achievements. Cambridge: Cambridge University Press; 2010.
47. Russell S, Norvig P. Artificial intelligence: a modern approach. 4th ed. Harlow: Pearson; 2021.
48. McCarthy J. What is artificial intelligence? Stanford (CA): Stanford University; 2007.
49. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015;521:436-44. doi:10.1038/nature14539.
50. Ng A. Machine learning yearning [Internet]. deeplearning.ai; 2018 [cited 2026 Jun 5]. Available from: <https://info.deeplearning.ai/machine-learning-yearning-book>.
51. Goodfellow I, Bengio Y, Courville A. Deep learning. Cambridge (MA): MIT Press; 2016.
52. Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. *Med Image Anal*. 2017;42:60-88.
53. Ali ML, Zhang Z. The YOLO framework: a comprehensive review of evolution, applications, and benchmarks in object detection. *Computers*. 2024;13:336.
54. Kotthapalli M, Ravipati D, Bhatia R. YOLOv1 to YOLOv11: a comprehensive survey of real-time object detection innovations and challenges [Preprint]. arXiv. 2025 Aug 4. Available from: <https://arxiv.org/abs/2508.02067>. doi:10.48550/arXiv.2508.02067.
55. Wang L, Wang H, Letchmunan S, Xiao R, Ahmed OH, Liu Z. A systematic literature review of lightweight YOLO models for object detection. *PeerJ Comput Sci*. 2025;11:e3357. doi:10.7717/peerj-cs.3357.
56. Cai Z, Zhou K, Liao Z. A systematic review of YOLO-based object detection in medical imaging: advances, challenges, and future directions. *Comput Mater Contin*. 2025;85:2255-303.
57. Mitchell TM. Machine learning. New York: McGraw-Hill; 1997.

58. Kaplan A, Haenlein M. Siri, Siri, in my hand: Who's the fairest in the land? *Bus Horiz.* 2019;62:15-25.
59. Bishop CM. *Pattern recognition and machine learning*. New York (NY): Springer; 2006.
60. Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*. 2017;542:115-8.
61. Ying S, Huang F, Shen X, Liu W, He F. Performance comparison of deep networks on caries detection. *J Dent.* 2024;120:104234. doi:10.1016/j.jdent.2023.104234.
62. Liu Y, Xia K, Cen Y, Ying S, Zhao Z. Artificial intelligence for caries detection. *Oral Radiol.* 2024;40:212-23. doi:10.1007/s11282-024-00572-x.
63. Česhko AZ, Subašić M, Milošević D, Savić Pavićin I, Vodanović M. Testing accuracy and reliability of automated dental status registration based on convolutional neural networks. **In:** *Proceedings of the Third International Organization for Forensic Odonto-Stomatology Congress*; 2024.
64. Chen LC, Papandreou G, Kokkinos I, Murphy K, Yuille AL. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs. *IEEE Trans Pattern Anal Mach Intell.* 2018 Apr;40(4):834-48. doi:10.1109/TPAMI.2017.2699184.
65. Ting DSW, Cheung CY, Lim G, Tan GSW, Quang ND, Gan A, et al. Artificial intelligence and deep learning in ophthalmology. *Lancet Digit Health.* 2020;2:e350-e356.
66. Stavrianos C, Dietrich EM, Stavrianos I, Petalotis N. The role of dentistry in the management of mass disasters and bioterrorism. *Acta Stomatol Croat.* 2010;44(2):110-9.
67. Chawla K, Garg V. CNN in diagnosis of alveolar bone loss. *J Datta Meghe Inst Med Sci Univ.* 2023;18:98-104.
68. Ghods K, Azizi A, Jafari A, Ghods K. Application of artificial intelligence in clinical dentistry: a comprehensive literature review. *J Stomatol.* 2023;24(4):356-70.

69. Savić Pavičin I, Zymber Ceshko A, Subašić M, Milošević D, Vodanović M. Automated detection and segmentation of teeth and dental procedures from orthopantomograms. **In:** Proceedings of the 28th EADPH Congress; 2024 Oct 3-5; Heraklion, Greece.
70. Scarano A, Inchingolo F, Dipalma G, Mastrangelo F. A digital clinical record versus paper records in dental practice: a comparative study. *Biomed Res Int.* 2025;2025:5527391. doi:10.1155/2025/5527391.
71. Redmon J, Farhadi A. YOLOv3: an incremental improvement [Preprint]. arXiv. 2018 Apr 8 [cited 2026 Jun 5]. Available from: <https://arxiv.org/abs/1804.02767>. doi:10.48550/arXiv.1804.02767.
72. Bochkovski A, Wang CY, Liao HYM. YOLOv4: optimal speed and accuracy of object detection [Preprint]. arXiv. 2020 Apr 23 [cited 2026 Jun 5]. Available from: <https://arxiv.org/abs/2004.10934>. doi:10.48550/arXiv.2004.10934.
73. Liu L, Ouyang W, Wang X, Fieguth P, Chen J, Liu X, et al. Deep learning for generic object detection: a survey. *Int J Comput Vis.* 2020;128:261-318.
74. Fadilah RPN, Rikmasari R, Akbar S, Setiawan AS. Examination of new clinical dental caries in school children using real intra oral photos with artificial intelligence model YOLO-V8x. *BMC Oral Health.* 2025 Dec 20;26:164. doi:10.1186/s12903-025-07486-x.
75. Şevik U, Mutlu O. Detection of dental anomalies in digital panoramic images using YOLO: a next-generation approach based on single-stage detection models. *Diagnostics (Basel).* 2025;15:1961.
76. Tekis H, Zirek T, Tassoker M. AI-powered detection of dental anatomy: a YOLO-based approach. *Oral Surg Oral Med Oral Pathol Oral Radiol.* 2026 Apr;141(4):558-65. doi:10.1016/j.oooo.2025.12.011.
77. Schwendicke F, Samek W, Krois J. Artificial intelligence in dentistry: chances and challenges. *J Dent Res.* 2020;99:769-74.

78. Preda F, Lombardo G, Pultrone C, Gherlone EF, Mangano FG, Mangano C. Automated segmentation from CBCT for dental applications. *J Dent.* 2022;120:104203.
79. Wang CY, Bochkovskiy A, Liao HYM. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*; 2023. p.7464-7475.
80. Chen LC, Zhu Y, Papandreou G, Schroff F, Adam H. Encoder-decoder with atrous separable convolution for semantic image segmentation. In: *Proceedings of the European Conference on Computer Vision*; 2018. p.801-818. doi:10.1007/978-3-030-01234-2_49.
81. He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*; 2016. p.770-778.
82. Redmon J, Farhadi A. YOLO9000: better, faster, stronger. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*; 2017.
83. Galante N, Cotroneo R, Furci D, Lodetti G, Casali MB. Applications of artificial intelligence in forensic sciences: current potential benefits, limitations and perspectives. *Int J Legal Med.* 2023;137(2):445-58. doi:10.1007/s00414-022-02928-5.
84. Hasan F, Tantawi ME, Haque F, Foláyan MO, Virtanen JI. Early childhood caries risk prediction using machine learning approaches in Bangladesh. *BMC Oral Health.* 2025;25(1):49. doi:10.1186/s12903-025-05419-2.
85. Najeeb M, Islam S. Artificial intelligence (AI) in restorative dentistry: current trends and future prospects. *BMC Oral Health.* 2025;25(1):592. doi:10.1186/s12903-025-05989-1.
86. Araidy S, Batshon G, Mirochnik R. Artificial intelligence applications in dentistry: a systematic review. *Oral.* 2025;5(4):90. doi:10.3390/oral5040090.
87. Ding H, Wu J, Zhao W, Matinlinna JP, Burrow MF, Tsoi JKH. Artificial intelligence in dentistry—a review. *Front Dent Med.* 2023;4:1085251. doi:10.3389/fdmed.2023.1085251.

88. Esteva A, Robicquet A, Ramsundar B, Kuleshov V, DePristo M, Chou K, et al. A guide to deep learning in healthcare. *Nat Med.* 2019;25:24-9.
89. Parikh RB, Kakad M, Bates DW. Machine learning for clinical decision making: pitfalls and pathways. *JAMA.* 2019;322:825-6.
90. Price WN II, Gerke S, Cohen IG. Ethical considerations in artificial intelligence for health care. *JAMA.* 2020;324:653-4.
91. Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez AN, et al. Attention is all you need. In: Guyon I, von Luxburg U, Bengio S, Wallach H, Fergus R, Vishwanathan S, et al., editors. *Advances in Neural Information Processing Systems*. Vol. 30. Red Hook (NY): Curran Associates; 2017.
92. Rajkomar A, Dean J, Kohane I. Machine learning in medicine. *N Engl J Med.* 2019;380:1347-58.
93. Arsiwala-Scheppach LT, Kollmuss M, Schwendicke F. Artificial intelligence in dentistry: a bibliometric analysis. *J Dent.* 2023;135:104601. doi:10.1016/j.jdent.2023.104601.
94. Pethani F. Promises and perils of artificial intelligence in dentistry. *Aust Dent J.* 2021;66(2):124-35. doi:10.1111/adj.12812.
95. Krois J, Ekert T, Meinhold L, Dörfer CE, Schwendicke F. Deep learning for the radiographic detection of periodontal bone loss. *J Clin Periodontol.* 2021;48(5):649-59. doi:10.1111/jcpe.13445.
96. Tuzoff DP, Tuzova LV, Bornstein MM, Krasnov AS, Kharchenko MA, Nikolenko SI. Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofac Radiol.* 2019;48:20180051. doi:10.1259/dmfr.20180051.
97. Putra RH, Doi C, Yoda N, Astuti ER, Sasaki K. Current applications and development of artificial intelligence for digital dental radiography. *Dentomaxillofac Radiol.* 2022 Jan 1;51(1):20210197. doi:10.1259/dmfr.20210197.

98. Preda F, Nogueira-Reis F, Stanciu EM, Smolders A, Jacobs R, Shaheen E. Validation of automated registration of intraoral scan onto cone beam computed tomography for an efficient digital dental workflow. *J Dent*. 2024;149:105282. doi:10.1016/j.jdent.2024.105282.
99. McBee MP, Awan OA, Colucci AT, Ghobadi CW, Kadom N, Kansagra AP, et al. Deep learning in radiology. *Acad Radiol*. 2018;25(11):1472-80. doi:10.1016/j.acra.2018.02.018.
100. Vodanović M, Subašić M, Milošević DP, Galić I, Brkić H. Artificial intelligence in forensic medicine and forensic dentistry. *J Forensic Odontostomatol*. 2023 Aug 27;41(2):30-41.
101. Shen D, Wu G, Suk HI. Deep learning in medical image analysis. *Annu Rev Biomed Eng*. 2017;19:221-48. doi:10.1146/annurev-bioeng-071516-044442.
102. Yao X, Wang X, Wang SH, Zhang YD. A comprehensive survey on convolutional neural network in medical image analysis. *Multimed Tools Appl*. 2022;81(29):41361-405. doi:10.1007/s11042-020-09634-7.
103. Özçelik STA. Improved tooth segmentation and identification using attention-based encoder-decoder networks. *Diagnostics (Basel)*. 2024;14(23):2719.
104. Ali MA, Fujita D, Kobashi S. Detection of teeth and prostheses on panoramic radiographs using a CNN-based object detector and a priori knowledge algorithm. *Sci Rep*. 2023;13:16542.
105. Tanikawa C, Yamashiro T. Development of AI systems for predicting facial morphology after orthognathic surgery and orthodontic treatment. *Sci Rep*. 2021;11:15853.
106. Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation. In: *Medical Image Computing and Computer-Assisted Intervention (MICCAI 2015)*. Cham: Springer; 2015. p.234-241.
107. Kingma DP, Ba J. Adam: a method for stochastic optimization. *arXiv preprint arXiv:1412.6980*. 2014.

108. Zhang H, Yuan T, Li T, Du J, Ye M, Jiang Q. A review of tooth AI segmentation on medical data. *Discover Imaging*. 2025;2:17. doi:10.1007/s44352-025-00021-2.
109. Brahmi W, Jdey I. Automatic segmentation and identification of teeth in panoramic radiographs using deep CNNs. *Multimed Tools Appl*. 2024;83(18):55565-85.
110. Tajbakhsh N, Shin JY, Gurudu SR, Hurst RT, Kendall CB, Gotway MB, et al. Convolutional neural networks for medical image analysis: full training or fine tuning? *IEEE Trans Med Imaging*. 2016;35(5):1299-312. doi:10.1109/TMI.2016.2535302.
111. Raghu M, Zhang C, Kleinberg J, Bengio S. Transfusion: understanding transfer learning for medical imaging. In: Wallach H, Larochelle H, Beygelzimer A, d'Alché-Buc F, Fox EB, Garnett R, editors. *Advances in Neural Information Processing Systems*. Vol. 32. Red Hook (NY): Curran Associates; 2020.
112. Yamashita R, Nishio M, Do RKG, Togashi K. Convolutional neural networks: an overview and application in radiology. *Insights Imaging*. 2018 Aug;9(4):611-29. doi:10.1007/s13244-018-0639-9.
113. Yang R, Yu Y. Artificial convolutional neural network in object detection and semantic segmentation for medical imaging analysis. *Front Oncol*. 2021 Mar 8;11:638182. doi:10.3389/fonc.2021.638182.
114. Musleh D, Almossaeed H, Balhareth F, Alqahtani G, Alobaidan N, Altalag J, et al. Advancing dental diagnostics: a review of artificial intelligence applications and challenges in dentistry. *Big Data Cogn Comput*. 2024 Jun 7;8(6):66. doi:10.3390/bdcc8060066.
115. Choi HR, Siadari TS, Ko DY, Kim JE, Huh KH, Yi WJ, et al. Can deep learning identify humans by automatically constructing a database with dental panoramic radiographs? *PLoS One*. 2024;19:e0312537. doi:10.1371/journal.pone.0312537.
116. McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. *Bull Math Biophys*. 1943;5:115-33. doi:10.1007/BF02478259.

117. Zhang J, Wang N, Li J, Hu L. Application of deep learning on CBCT in dentistry. *Diagnostics* (Basel). 2023;13(12):2056. doi:10.3390/diagnostics13122056.
118. Görürgözi C. Performance of a convolutional neural network algorithm for tooth detection and numbering on periapical radiographs. *Dentomaxillofac Radiol*. 2022;51(3):20210246.
119. Chen Y, Gu K, Fu H, Wang J, Peng Y, Zhu H, et al. CoTrFuse: a novel CNN and transformer fusion framework for medical image segmentation. *Phys Med Biol*. 2023;68(17):175027. doi:10.1088/1361-6560/ace3e4.
120. Lee JH, Han SS, Kim YH, Lee C, Kim I. Application of fully deep convolutional neural networks for tooth segmentation on panoramic radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol*. 2020;129(6):635-42.
121. Lin TY, Maire M, Belongie S, Hays J, Perona P, Ramanan D, et al. Microsoft COCO: common objects in context. In: *Computer Vision – ECCV 2014*. Cham: Springer; 2014. p.740-755. doi:10.1007/978-3-319-10602-1_48.
122. Kunz F, Stellzig-Eisenhauer A, Zeman F, Boldt J. Artificial intelligence in orthodontics: evaluation of a fully automated cephalometric analysis using a customized convolutional neural network. *J Orofac Orthop*. 2020 Jan;81(1):52-68. doi:10.1007/s00056-019-00203-8.
123. Kim M, Chung M, Shin YG, Kim B. Automatic registration of dental CT and 3D scanned model using deep learning. *Comput Methods Programs Biomed*. 2023;233:107467.
124. Kwak GH. Automatic detection of mandibular canal using deep convolutional neural network. *Sci Rep*. 2020;10:5711.
125. Hua Y, Chen R, Qin H. YOLO-DentSeg: a lightweight real-time model for dental disease detection and segmentation. *Electronics*. 2025;14:805.

126. Mureşanu S, Almăşan O, Hedeşiu M, Dioşan L, Dinu C, Jacobs R. Artificial intelligence models for clinical usage in dentistry with a focus on dentomaxillofacial CBCT: a systematic review. *Oral Radiol.* 2023;39(1):18-40. doi:10.1007/s11282-022-00660-9.
127. Bornstein MM, Scarfe WC, Vaughn VM, Jacobs R. Cone beam computed tomography in implant dentistry: a systematic review focusing on guidelines, indications, and radiation dose risks. *Int J Oral Maxillofac Implants.* 2014;29:55-77.
128. Revilla-León M, Gómez-Polo M, Vyas S, Barmak AB, Gallucci GO, Att W. Artificial intelligence applications in implant dentistry: a systematic review. *J Prosthet Dent.* 2023;130(4):533-47. doi:10.1016/j.prosdent.2022.06.018.
129. Park JH, Kim DH, Kim HJ, Lee JH, Kim YH, Lee SS, et al. Automatic detection and numbering of teeth on panoramic radiographs using deep learning. *J Clin Med.* 2021;10(16):3567. doi:10.3390/jcm10163567.
130. Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. In: *Advances in Neural Information Processing Systems.* 2012;25:1097-105.
131. Lee JH, Kim DH, Jeong SN, Choi SH. Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *J Dent.* 2018;77:106-11. doi:10.1016/j.jdent.2018.07.015.
132. Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift. In: *Proceedings of the International Conference on Machine Learning;* 2015. p.448-456.
133. Çiçek Ö, Abdulkadir A, Lienkamp SS, Brox T, Ronneberger O. 3D U-Net: learning dense volumetric segmentation from sparse annotation. In: *Medical Image Computing and Computer-Assisted Intervention (MICCAI 2016).* Cham: Springer; 2016. p.424-432. doi:10.1007/978-3-319-46723-8_49.

134. Krois J, Schwendicke F. Artificial intelligence in dentistry. *J Dent*. 2021;110:103849. doi:10.1016/j.jdent.2021.103849.
135. INTERPOL. Disaster Victim Identification Guide. Lyon: INTERPOL; 2018.
136. Milošević D. Deep learning-based analysis of dental X-ray images for forensic estimation of age and sex [dissertation]. Zagreb: University of Zagreb, Faculty of Electrical Engineering and Computing; 2022.
137. Beser B, Reis T, Berber MN, Topaloglu E, Gungor E, Kilic MC, et al. YOLO-V5 based deep learning approach for tooth detection and segmentation on pediatric panoramic radiographs in mixed dentition. *BMC Med Imaging*. 2024;24(1):172. doi:10.1186/s12880-024-01338-w.
138. Putra RH, Astuti ER, Putri DK, Widiastri M, Laksanti PAM, Majidah H, et al. Automated permanent tooth detection and numbering on panoramic radiograph using a deep learning approach. *Oral Surg Oral Med Oral Pathol Oral Radiol*. 2024;137(5):537-44. doi:10.1016/j.oooo.2023.06.003.
139. Peker RB, Kurtoglu CO. Evaluation of the performance of a YOLOv10-based deep learning model for tooth detection and numbering on panoramic radiographs of patients in the mixed dentition period. *Diagnostics (Basel)*. 2025;15(4):405. doi:10.3390/diagnostics15040405.
140. Ozcelik E, Simsek H, Aktas A, Ilhan HO, Yasa Y. Teeth identification and numbering in mixed dentition: evaluating deep learning models for pediatric panoramic radiographs. *BMC Oral Health*. 2026;26:727. doi:10.1186/s12903-026-08097-w.
141. Maganur PC, Vishwanathaiah S, Mashyakhy M, Abumelha AS, Robaian A, Almohareb T, et al. Development of artificial intelligence models for tooth numbering and detection: a systematic review. *Int Dent J*. 2024;74(5):917-29. doi:10.1016/j.identj.2024.04.021.

142. Hou S, Zhou T, Liu Y, Dang P, Lu H, Shi H. Teeth U-Net: a segmentation model of dental panoramic X-ray images for context semantics and contrast enhancement. *Comput Biol Med.* 2023;152:106296. doi:10.1016/j.compbiomed.2022.106296.
143. Chen X, Ma N, Xu T, Xu C. Deep learning-based tooth segmentation methods in medical imaging: a review. *Proc Inst Mech Eng H.* 2024;238(2):115-31. doi:10.1177/09544119231217603.
144. Tunç H, Akkaya N, Aykanat B, Ünsal G. U-Net-based deep learning for simultaneous segmentation and agenesis detection of primary and permanent teeth in panoramic radiographs. *Diagnostics (Basel).* 2025;15(20):2577. doi:10.3390/diagnostics15202577.
145. Chandrashekar G, AlQarni S, Bumann EE, Lee Y. Collaborative deep learning model for tooth segmentation and identification using panoramic radiographs. *Comput Biol Med.* 2022;148:105829. doi:10.1016/j.compbiomed.2022.105829.
146. Alharbi SS, AlRugaibah AA, Alhasson HF, Khan RU. Detection of cavities from dental panoramic X-ray images using nested U-Net models. *Appl Sci.* 2023;13(23):12771. doi:10.3390/app132312771.
147. Mărginean AC, Mureşanu S, Hedeşiu M, Dioşan L. Teeth segmentation and carious lesions segmentation in panoramic X-ray images using CariSeg, a networks' ensemble. *Heliyon.* 2024;10(10):e30836. doi:10.1016/j.heliyon.2024.e30836.
148. Zhu H, Cao Z, Lian L, Ye G, Gao H, Wu J. CariesNet: a deep learning approach for segmentation of multi-stage caries lesion from oral panoramic X-ray image. *Neural Comput Appl.* 2022. doi:10.1007/s00521-021-06684-2.
149. Turosz N, Chęcińska K, Chęciński M, Sielski M, Sikora M. Evaluation of dental panoramic radiographs by artificial intelligence compared to human reference: a diagnostic accuracy study. *J Clin Med.* 2024;13(22):6859. doi:10.3390/jcm13226859.

150. Khurshid Z, Faridoon F, Silkosessak OCUD, Trachoo V, Waqas M, Hasan S, et al. Multi-regional deep learning models for identifying dental restorations and prosthesis in panoramic radiographs. BMC Oral Health. 2025;25(1):1750. doi:10.1186/s12903-025-07138-0.

8. ŽIVOTOPIS

Ajla Zymber-Češko rođena je 22. travnja 1974. godine u Mitrovici, Republika Kosovo. Osnovnu školu i gimnaziju završila je u Mitrovici školske godine 1991. /1992.

Godine 1993. upisala je Medicinski fakultet, Odsjek za stomatologiju Sveučilišta u Prištini, gdje je diplomirala 2008. godine i stekla zvanje doktorice dentalne medicine.

Godine 2009. osnovala je privatnu stomatološku ordinaciju OS Ammsar Dent, u kojoj kao doktorica dentalne medicine radi do danas.

Specijalističko usavršavanje iz endodoncije pohađala je na Sveučilištu u Prištini „Hasan Priština” od 2013. do 2017. godine te je stekla naziv specijalista bolesti zuba s endodoncijom.

Od 2017. godine zaposlena je kao zdravstvena inspektorica u Ministarstvu zdravstva Republike Kosovo.

Akadske godine 2018. /2019. upisala je poslijediplomski doktorski studij Dentalna medicina na Stomatološkom fakultetu Sveučilišta u Zagrebu pod mentorstvom prof. dr. sc. Ivane Savić Pavičin. U okviru dokorskog istraživanja bavi se primjenom metoda dubokog učenja u analizi dentalnog statusa na ortopantomografskim snimkama u području forenzične odontologije.

Autorica je i koautorica četiriju znanstvenih radova objavljenih u časopisima indeksiranim u WoS SCIE, WoS ESCI, Scopusu i MEDLINE-u te četiriju kongresnih sažetaka. Rezultate dokorskog istraživanja predstavila je na međunarodnim znanstvenim skupovima.

Od 2022. godine sudjeluje u nastavi na Stomatološkom fakultetu te na Alma Mater Europaea Campus College „Rezonanca”.

Udana je, majka dvoje djece te živi i radi u Prištini.

POPIS RADOVA

i) Radovi objavljeni u časopisima u WoS Science Citation Indexu Expanded (WoS SCIE)
- kvartil prema Journal Citation Reports (JCR)

Ćeshko AZ, Savić Pavićin I, Milošević D, Banjšak L, Subašić M, Vodanović M. A forensic odontology application: impact of image quality on CNNs for dental status analysis from orthopantomograms. Appl Sci. 2025;15(18):10265. doi:10.3390/app151810265. (Q2) – **rad proizašao iz doktorskog istraživanja**

ii) Radovi objavljeni u časopisima u drugim bazama (WoS ESCI, Scopus itd.)

1) Savić Pavićin I, Jonjić A, Maretić I, Dumančić J, **Ćeshko AZ**. Maintenance of dental records and forensic odontology awareness: a survey of Croatian dentists with implications for dental education. Dent J (Basel). 2021;9(4):37. doi:10.3390/dj9040037. **rad vezan uz temu doktorskog istraživanja**

2) Savić Pavićin I, Lovrić Ž, **Ćeshko AZ**, Vodanović M. Occupational injuries among dentists in Croatia. Acta Stomatol Croat. 2020;54(1):51–59. doi:10.15644/asc54/1/6.

3) Demjaha G, Kapushevska B, **Ćeshko AZ**, Pejkovska Shahpaska B. Dental treatment on cephalic from orofacial origin. Prilozi (Makedonska Akademija na Naukite i Umetnostite, Oddelenie za Medicinski Nauki). 2019;40(3):109–115. doi:10.2478/prilozi-2020-0010.

iii) Sažetci s međunarodnih kongresa

4) **Ćeshko AZ**, Subašić M, Milošević D, Savić Pavićin I, Vodanović M. Automated recording of dental status using convolutional neural networks. Acta Stomatologica Croatica. 2022;56(2):187. Abstract presented at: 8th International Congress of the School of Dental

Medicine, University of Zagreb; 8.–9. travnja 2022.; Rovinj, Hrvatska. (međunarodni, **oralna prezentacija rezultata doktorskog istraživanja**)

5) **Česhko AZ**, Subašić M, Milošević D, Savić Pavičin I, Vodanović M. Testing of the accuracy and reliability of automated dental status registration based on convolutional neural networks. In: Programme & Book of Abstracts. International Organization for Forensic Odonto-Stomatology; School of Dental Medicine, University of Zagreb; 6–8. rujna 2023.; Zagreb, Hrvatska. p. 50. (međunarodni, **oralna prezentacija rezultata doktorskog istraživanja**)

6) Savić Pavičin I, Adamić Hadžić A, Čivljak T, Lauc T, **Česhko AZ**, Šlaus M. Mandibular bone quality in three different archaeological series from Croatia. In: Programme & Book of Abstracts. International Organization for Forensic Odonto-Stomatology; School of Dental Medicine, University of Zagreb; 6–8. rujna 2023.; Zagreb, Hrvatska. p. 77. (međunarodni, koautor kongresnog sažetka)

7) Savić Pavičin I, **Zymber Česhko A**, Milošević D, Subašić M, Vodanović M. Automated detection and segmentation of teeth and dental procedures from orthopantomograms. Community Dent Health. 2024;41(4 Suppl): S53-S54. doi:10.1922/CDH_EAPDHAAbstracts2024. Abstract presented at: 28th Annual European Association of Dental Public Health (EADPH) Congress; 4. listopada 2024.; Heraklion, Kreta, Grčka. (međunarodni, koautor kongresnog sažet