

Ulasan Sistematis

Aplikasi dan pengembangan terkini *artificial intelligence* untuk analisis implan gigi osseointegrasi berbasis radiografi: Scoping Review

Nabila Haditya Arius^{1*}
Farina Pramanik²
Yurika Ambar Lita²

¹Program Studi Sarjana Kedokteran Gigi, Fakultas Kedokteran Gigi, Universitas Padjadjaran, Bandung, Indonesia

²Departemen Radiologi Dentomaksilofasial, Fakultas Kedokteran Gigi, Universitas Padjadjaran, Bandung, Indonesia

*Korespondensi
nabila21024@mail.unpad.ac.id

Submisi: 03 April 2025
Revisi : 23 Oktober 2025
Penerimaan: 27 Oktober 2025
Publikasi Online: 31 Oktober 2025
DOI: [10.24198/pjdrs.v9i3.64986](https://doi.org/10.24198/pjdrs.v9i3.64986)

ABSTRAK

Pendahuluan: Osseointegrasi merupakan faktor kunci dalam keberhasilan implan gigi, namun evaluasi konvensional seperti radiografi 2D dan histomorfometri memiliki keterbatasan dalam subjektivitas dan efektivitas. Artificial Intelligence (AI) menawarkan solusi inovatif untuk meningkatkan presisi dan kecepatan analisis. Tujuan penelitian ini untuk menganalisis aplikasi dan pengembangan AI dalam analisis osseointegrasi implan gigi menggunakan radiografi melalui scoping review. **Metode:** Pencarian sistematis dilakukan di PubMed, Scopus, MEDLINE, Embase, dan Web of Science (2014–2024) dengan kerangka PCC (Population: pasien implan gigi, Concept: AI, Context: klinis) menggunakan *framework* Arksey dan O'Malley serta panduan dari Joanna Briggs Institute (JBI). **Hasil:** Dari 11 artikel terpilih (2019–2024), mayoritas menggunakan radiografi periapikal dan CBCT sebagai modalitas utama, dengan model deep learning berbasis CNN (*Convolution Neural Network*) (seperti YOLOv7 dan ResNet-50) menunjukkan kinerja optimal dalam memprediksi kehilangan tulang marginal (akurasi 70,2–96,13%) dan stabilitas implan. Radiografi periapikal unggul dalam akurasi (94,74%) dan presisi (100%), sementara CBCT (*Cone Beam Computed Tomography*) menawarkan analisis volumetrik lebih detail dengan kecepatan pemrosesan hingga 76 ms. Meski demikian, variasi parameter radiografi dan ketergantungan pada dataset kecil (44–2920 gambar) berpotensi menyebabkan overfitting. Kolaborasi multi-institusi dan standarisasi teknik radiografi diperlukan untuk meningkatkan kemampuan AI dalam praktik klinis. **Simpulan:** Model deep learning (CNN, YOLOv7) dan machine learning (SVM) terbukti efektif dalam analisis osseointegrasi, terutama untuk marginal bone loss menggunakan radiografi periapikal dan CBCT. AI berpotensi merevolusi evaluasi implan gigi, namun implementasi klinis memerlukan validasi eksternal dan standarisasi data.

KATA KUNCI: Artificial intelligence, implan gigi, osseointegrasi, deep learning, analisis radiografi

Current applications and development of artificial intelligence for osseointegration dental implant analysis: Scoping Review

ABSTRACT

Introduction: Osseointegration is a key factor in dental implant success, but conventional evaluations such as two dimensional (2D) radiography and histomorphometry are limited by subjectivity and restricted diagnostic capacity. Artificial Intelligence (AI) offers an innovative solution to improve both precision and speed of analysis. This study aims to explore current applications and advancements in AI-based osseointegration analysis of dental implants using radiographs through a scoping review. **Methods:** A systematic search was conducted in PubMed, Scopus, MEDLINE, Embase, and Web of Science (2014–2024), using the PCC framework (Population: dental implant patients, Concept: AI, Context: clinical). The review followed the Arksey and O'Malley methodological framework and the Joanna Briggs Institute (JBI) guidelines. **Results:** Of the 11 selected articles (2019–2024), the majority used periapical radiography and CBCT (Cone Beam Computed Tomography) as the primary imaging modalities, with CNN (Convolution Neural Network)-based deep learning models (such as YOLOv7 and ResNet-50) demonstrated strong predictive performance for marginal bone loss (accuracy 70.2–96.13%) and implant stability. Periapical radiographs achieved high accuracy (94.74%) and precision (100%), while CBCT enabled more detailed volumetric analysis with processing speeds of up to 76 ms. However, variability in radiographic parameters and reliance on small datasets (44–2920 images) could lead to model overfitting. Multi-institutional collaboration and standardization of imaging protocols are required to enhance AI performance and generalizability in clinical practice. **Conclusion:** Deep learning (CNN, YOLOv7) and machine learning (SVM) models have proven effective in osseointegration analysis, particularly in predicting marginal bone loss using periapical radiographs and CBCT. AI has the potential to revolutionize dental implant evaluation, but clinical implementation requires external validation and data standardization.

KEY WORDS: Artificial intelligence, dental implant, osseointegration, deep learning, radiographic analysis

PENDAHULUAN

Osseointegrasi, konsep yang diperkenalkan Brånemark hampir 50 tahun lalu, menjadi landasan utama kesuksesan implan gigi sebagai solusi rehabilitasi bagi pasien kehilangan gigi.^{1,2} Perkembangan pesat penggunaan implan gigi terlihat dari peningkatan prevalensi di Amerika Serikat dari 0,7% (1999-2000) menjadi 5,7% (2015-2016), dengan proyeksi mencapai 23% pada 2026.^{3,4} Keunggulan implan, seperti peningkatan stabilitas, fungsi bicara, pengunyahan, dan estetika, menjadikannya pilihan utama dibandingkan gigi tiruan tradisional.³ Meskipun tingkat keberhasilan implan mencapai 96,3–100%, risiko kegagalan tetap ada, terutama pada tahap awal (1-2% dalam 3 bulan pertama) dan jangka panjang (sekitar 5% karena peri-implantitis).^{2,5,6}

Kegagalan osseointegrasi dapat terjadi dalam dua fase: primer (≤ 3 bulan) dan sekunder (> 3 bulan). Kegagalan primer disebabkan faktor teknis seperti rendahnya densitas tulang, preparasi yang berlebihan, atau panas berlebih saat preparasi tulang, sementara kegagalan sekunder sering dipicu peri-implantitis atau beban biomekanis tidak seimbang.^{2,6} Studi Frumkin *et al.*⁷ menunjukkan pasien dengan osteopenia dan osteoporosis memiliki risiko kegagalan lebih tinggi, sementara Stoccheri *et al.*⁸ menemukan peningkatan suhu tulang selama pengeboran dapat memicu nekrosis termal.^{7,8}

Kegagalan osseointegrasi dapat berdampak kehilangan 20–40% volume tulang dalam satu bulan dan komplikasi lanjut seperti perforasi mukoperiosteum, sinusitis maksila, fraktur mandibula, kelainan tulang, dan lesi periapikal.^{9,10} Osseointegrasi yang optimal bergantung pada stabilitas primer (mekanis) dan sekunder (biologis). Stabilitas primer ditentukan oleh densitas tulang, geometri implan, dan teknik bedah, sementara stabilitas sekunder melibatkan regenerasi tulang yang dipengaruhi *maturation* tulang dan faktor biologis pasien.¹¹

Evaluasi osseointegrasi saat ini mengandalkan pemeriksaan klinis (mobilitas, infeksi) dan radiografi (CBCT, periapikal) untuk mengukur *bone-implant contact* (BIC) atau *bone loss*. Namun, radiografi konvensional kurang sensitif mendeteksi perubahan mikroskopis tulang, dan CBCT berisiko paparan radiasi berulang.^{12–15} Evaluasi radiografi, seperti pada studi Lubis *et al.*,¹⁶ kurang ideal karena format 2D yang tidak akurat merepresentasikan perubahan geometri, berpotensi menyebabkan misinterpretasi.¹⁷

Metode histomorfometri, meski presisi, bersifat invasif dan hanya menyediakan data 2D, sehingga tidak praktis untuk pemantauan klinis rutin.¹⁹ Selain itu, interpretasi hasil radiografi sering bersifat subjektif dan bergantung pada keahlian klinisi, seperti yang ditunjukkan oleh Putra *et al.*,²⁰ dan Alshenaiber *et al.*,²¹ di mana perbedaan penilaian dan pengalaman dapat berpotensi menimbulkan variasi diagnosis. Selain itu, metode konvensional seperti radiografi memakan waktu yang cukup lama bagi klinisi karena memerlukan pemeriksaan yang teliti dan berulang terhadap perubahan tulang di sekitar implan seiring waktu.²² Oleh karena itu, diperlukannya metode baru untuk menganalisis osseointegrasi pada implan gigi.

Artificial Intelligence (AI) berkembang sebagai kemampuan suatu mesin untuk meniru kecerdasan dan perilaku manusia dalam melaksanakan tugas-tugas tertentu, mencakup bidang seperti *machine learning* (ML), *neural networks*, dan *deep learning* (DL).²³ ML, sebagai *subset* utama AI, memungkinkan mesin belajar dari data tanpa pemrograman eksplisit.²⁴ DL, turunan ML yang berbasis jaringan saraf tiruan (*artificial neural networks*), mengotomatisasi ekstraksi fitur kompleks dari data mentah, seperti gambar radiografi, melalui arsitektur *Convolutional Neural Networks* (CNN).²⁵ CNN memproses gambar melalui beberapa lapisan: *convolutional*, *pooling*, dan *fully connected* untuk mendeteksi pola sederhana hingga struktur yang lebih kompleks seperti karies gigi atau implan. Otomatisasi ini meningkatkan akurasi diagnosis dan mengurangi kebutuhan untuk pra pemrosesan manual.^{23,24}

Dalam bidang kedokteran gigi, AI telah merevolusi diagnosis dan perencanaan perawatan melalui analisis gambar radiografi dan data klinis. Hasil penelitian Lee *et al.*²⁶

dan Kühnisch *et al.*,²⁷ CNN terbukti efektif mendeteksi karies, dan Hartman *et al.*²⁸ dapat mendeteksi anomali gigi dengan akurasi rata-rata 85,38%.

Fase pra-implan, AI membantu mengoptimalkan penempatan implan, seperti yang ditunjukkan oleh penelitian Satapathy *et al.*,²⁹ AI tidak hanya meningkatkan akurasi diagnosis tetapi juga mengurangi waktu perencanaan dari 30 menjadi 10 menit per kasus dengan presisi posisi implan (<1 mm) dan sudut penempatan (<2°). Selain itu, Kwak *et al.*³⁰ menunjukkan keberhasilan deteksi kanal mandibula menggunakan CNN, meningkatkan presisi perencanaan implan.³⁰ Pasca-pemasangan, AI membantu memprediksi osseointegrasi dan mendeteksi kehilangan tulang marginal, seperti yang ditunjukkan Oh *et al.*³¹ dan Cha *et al.*,³³ serta memprediksi kegagalan implan dengan akurasi 87% dalam 5 tahun.

Berdasarkan penjelasan sebelumnya, penelitian ini bertujuan melakukan scoping review untuk memetakan aplikasi dan pengembangan terkini AI dalam analisis osseointegrasi implan gigi, khususnya fase pasca implan. Meskipun Elgarba *et al.*³⁴ telah mereview peran AI dalam perencanaan pra-bedah, dan Wu *et al.*³⁵ membahas AI untuk prognosis implan secara umum, kajian mendalam mengenai pemantauan osseointegrasi masih terbatas.

Keterbaruan penelitian ini terletak pada fokus pemetaan penerapan AI dalam analisis osseointegrasi fase pasca-pemasangan secara non-invasif, efisien, dan presisi guna mendukung keberhasilan implan jangka panjang. Melalui identifikasi gap penelitian sebelumnya, studi ini diharapkan memberikan rekomendasi implementasi AI untuk meningkatkan akurasi diagnosis dan efisiensi waktu klinis. Tujuan penelitian ini untuk menganalisis aplikasi dan pengembangan AI dalam analisis osseointegrasi implan gigi menggunakan radiografi melalui scoping review

METODE

Penelitian ini menggunakan metode *scoping review* yang mengikuti kerangka kerja Arksey dan O'Malley serta panduan dari Joanna Briggs Institute (JBI) untuk memetakan perkembangan aplikasi Artificial Intelligence (AI) dalam analisis implan gigi osseointegrasi.^{36,37} Penelitian dilaksanakan secara daring pada November 2024 hingga Januari 2025, dengan tahapan identifikasi pertanyaan, pencarian literatur, seleksi, ekstraksi data, dan pembuatan hasil. Pencarian literatur dilakukan di 5 database, yaitu PubMed, Scopus, MEDLINE, Embase, dan Web of Science.

Pertanyaan penelitian dirumuskan adalah "Bagaimana aplikasi dan pengembangan terkini *Artificial Intelligence* untuk analisis implan gigi osseointegrasi?" menggunakan *framework* PCC oleh JBI: Population (pasien implan gigi osseointegrasi), Concept (aplikasi AI), dan Context (klinis).³⁷ Pencarian literatur dilakukan dengan kata kunci kombinasi Boolean (AND/OR/NOT), yaitu "(Artificial intelligence OR Machine learning OR Deep learning OR Neural Networks) AND (Dental Implan OR Dental Prostheses Implan Supported) AND (Osseointegration OR Bone Healing OR Bone Regeneration OR Bone Loss OR Osteogenesis OR After Implan Placement OR Bone Formation OR Bone Measurement)".

Kriteria inklusi meliputi artikel (2014–2024) berbahasa Inggris, full-text, studi pada manusia, dan desain eksperimental atau observational studi yang membahas AI untuk implan gigi osseointegrasi. Kriteria eksklusi mencakup studi hewan, tinjauan pustaka, buku, atau penelitian AI di luar konteks osseointegrasi. Proses seleksi mengikuti PRISMA-ScR untuk memastikan transparansi dan akurasi pemilihan literatur. Prosedur diawali dengan penghapusan duplikat, dua peneliti (N.H. dan Y.A.) melakukan screening judul-abstrak, dilanjutkan evaluasi full-text berdasarkan kriteria inklusi/eksklusi. Perbedaan pendapat diselesaikan melalui diskusi dengan peninjau senior (F.P. dan Y.A.). Data yang diekstraksi mencakup kriteria artikel, sampel, dan outcome analisis AI.

HASIL

Diagram 1 memperlihatkan tahapan seleksi dan penyaringan artikel menggunakan diagram alur PRISMA-ScR. Pencarian awal pada lima database dan secara manual menghasilkan 315 artikel dengan rincian, 100 artikel didapatkan dari PubMed, 45 artikel didapatkan dari Scopus, 40 artikel didapatkan dari EBSCOhost, 18 artikel didapatkan dari Embase, 110 artikel didapatkan dari Web of Science dan 2 artikel yang didapatkan dari pencarian manual. Setelah menghilangkan 146 duplikasi menggunakan Mendeley, tersisa 169 artikel. Penyaringan berdasarkan judul dan abstrak mengurangi jumlah tersebut menjadi 23 artikel yang berpotensi relevan. Seleksi akhir menghasilkan 11 artikel (2019–2024) yang memenuhi kriteria kelayakan. Seleksi akhir menghasilkan 11 artikel (2019–2024) yang memenuhi kriteria kelayakan. Sebelas artikel yang didapat terdiri dari delapan artikel dengan desain penelitian *retrospective study*, satu artikel dengan desain *prospective cohort design*, satu artikel dengan desain *randomized controlled trial*, dan satu artikel dengan desain *cross-sectional study*.

Artikel yang diteliti dalam penelitian ini akan disajikan dalam tiga tabel. Tabel 1 yang memuat data karakteristik artikel, Tabel 2 yang memuat data karakteristik pasien, dan Tabel 3 membahas hasil penggunaan AI (*outcome*).

Radiografi periapikal menjadi modalitas dominan dalam tujuh penelitian,^{38–44} dengan tiga diantaranya membandingkan atau mengombinasikannya dengan radiografi panoramik atau bitewing^{39,41,42}. Konfigurasi teknis radiografi bervariasi, seperti resolusi 96 dpi (300–500 × 300–400 piksel)³⁸ atau parameter eksposur 70 kV dan 7 mAs untuk periapikal, serta 80 kV dan 8 mA untuk panoramik, menghasilkan gambar 224 × 224 piksel.⁴² Empat penelitian menggunakan CBCT dengan parameter bervariasi, meliputi kV (65–110), mA (8–10), waktu eksposur (3,6–30,8 detik), ukuran voxel (80–250 µm), dan resolusi (256×256 piksel), dengan satu penelitian tidak menyebutkan parameter teknisnya.^{45–48} Jumlah pasien berkisar antara 44–580, dengan total implan 44–2336. Periode observasi dimulai dari penempatan implan (T0), 3-6 bulan setelah pemasangan (T1), lebih dari setahun setelah penempatan (T2). Tujuh dari sembilan penelitian menggunakan gambar radiografi tiga bulan pasca-implantasi^{39–42,45,46,48}, sementara empat lainnya tidak menjelaskan waktu pengambilan. Distribusi anatomis implan menunjukkan empat penelitian menganalisis maksila dan mandibula^{39,42,44,45}, satu fokus pada mandibula,⁴⁶ dan empat tidak menyebutkan lokasi. Selain itu, dua penelitian menggunakan sistem implan berbeda: satu menggunakan Straumann, dan satu lainnya menggunakan Brånemark Mk III, Implanium, dan XiVE..^{43,48}

Sejumlah 11 penelitian, sembilan menggunakan model *deep learning* (DL) mendominasi yang seluruhnya menggunakan algoritma *Convolutional Neural Network* (CNN).^{38,39,41–45,47,48} Menggunakan beberapa arsitektur seperti Faster R-CNN, ResNet-50, YOLOv3, YOLOv7, dan Mask R-CNN diterapkan untuk memprediksi *marginal bone loss*^{38,39,42–44}, sedangkan ResNet-18/34/50, DenseNet-121/201, dan MobileNet-V2/V3 untuk memprediksi *bone-implant-contact* (BIC)⁴¹, 3-D deep CNN untuk memprediksi kepadatan tulang alveolar (D1-D4)⁴⁵, serta ResNet-50 juga digunakan untuk memprediksi stabilitas implan.⁴⁸ Sementara itu, dua studi menggunakan machine learning (ML) dengan algoritma seperti SVM, ANN, LR, dan RF untuk memprediksi kehilangan tulang marginal⁴⁶, dan Naive Bayes, RF, Gradient Boosting, LR, K-NN, Tree, SMV, dan CN2 *rule inducer* dan YOLOv3 untuk memprediksi *Bone Remodeling*.^{39,40}

Terdapat 2 studi yang membandingkan kinerja AI dengan dokter,^{38,44} sementara 3 studi membandingkan beberapa arsitektur model.^{40,41,46} Satu studi membandingkan penilaian dengan bantuan AI dengan penilaian tradisional,⁴⁷ Dataset yang digunakan bervariasi dalam ukuran, mulai dari 44 gambar,⁴⁰ hingga 2920 gambar,³⁹ sebanyak sembilan penelitian membagi data ke dalam *training* (interval: 347–1440 sampel), *validation* (54–150), dan *testing* (43–1.460).^{38,39,41–46,48}

Dua studi menerapkan augmentasi data untuk meningkatkan jumlah sampel,^{42,45} seperti augmentasi radiografi periapikal dan panoramik, sedangkan 1 studi menggunakan *five-fold cross-validation* untuk validasi model.⁴² Kinerja model AI diukur menggunakan berbagai parameter, seperti *Accuracy*, *Sensitivity/Recall*, *Specificity*, AUROC (*Area Under the Receiver Operating Characteristic Curve*), PPV/*Precision*, NPV, F1-score, *Diagnostic error rates*, 95% *Confidence Interval* (CI), Kappa Statistic (κ), *Average Precision* (mAP@0.5), *Average Recall*, *Pixel Deviations*, t-test p-values, dan *Object Keypoint Similarity* (OKS).

Akurasi menggambarkan proporsi prediksi yang benar terhadap seluruh data uji, dengan rumus $((TP + TN)/(TP + FP + TN + FN))$. Sensitivity atau recall menunjukkan kemampuan model dalam mendeteksi kasus positif dengan benar, dihitung sebagai $(TP/(TP + FN))$, sedangkan specificity mengukur kemampuan model dalam mengidentifikasi kasus negatif secara tepat, dengan rumus $(TN/(FP + TN))$.

Precision atau PPV menggambarkan proporsi prediksi positif yang benar dari seluruh prediksi positif, yaitu $(TP/(TP + FP))$, sedangkan NPV menunjukkan proporsi prediksi negatif yang benar dari seluruh prediksi negatif, dengan rumus $(TN/(TN + FN))$. Selain itu, F1-score digunakan untuk menilai keseimbangan antara precision dan recall dengan rumus $(2 \times (\text{precision} \times \text{recall}) / (\text{precision} + \text{recall}))$.

Hubungan antar parameter tersebut divisualisasikan melalui Confusion Matrix, yang terdiri atas empat komponen utama, yaitu *True Positive (TP)*, *False Positive (FP)*, *True Negative (TN)*, dan *False Negative (FN)*, yang merepresentasikan distribusi hasil prediksi model terhadap data aktual. Akurasi dianalisis dalam enam penelitian,^{41–43,45,47,48} dengan nilai yang dilaporkan berkisar antara 70,2%–96,13%.

Metrik sensitivitas digunakan pada tujuh penelitian,^{38,40–43,46,48} dan spesifisitas pada enam penelitian,^{38,40,41,43,46,48} dengan sensitivitas berkisar antara 59,5%–97,53% dan spesifisitas antara 64,6%–100%. Presisi/PPV dievaluasi dalam enam penelitian^{38,40,42,43,45,48}, dengan nilai berkisar antara 73,3% hingga 100%, sedangkan NPV dievaluasi dua penelitian,^{40,48} dengan nilai berkisar 60,5%–99,20%. Skor F1 digunakan pada tiga penelitian,^{42,43,48} berkisar antara 66% hingga 97,10%, sedangkan Skor AUROC, indikator kemampuan diskriminatif model, berkisar antara 0,890 hingga 0,975 seperti yang dilaporkan dalam empat penelitian.^{40–42,46}

Kinerja model dievaluasi dengan metrik lainnya seperti *diagnostic error rates: mistake diagnostic rate* 13–17% dan *omission diagnostic rate* 25–33% dan kappa Statistic (κ) berkisar antara 0,547–0,568.³⁸ 95% *Confidence Interval* (CI) dilaporkan dalam satu penelitian (0,647–0,854).⁴⁰ *Pixel Deviations* digunakan dalam satu penelitian dengan kesalahan deteksi garis (2,75/1,01) dan titik (2,57/1,31) dengan Average Precision (mAP@0.5) berkisar antara 0,685–0,898) dan t-test 0,0106–0,0213.³⁹ Object Keypoint Similarity (OKS) juga dianalisis dalam satu penelitian dengan nilai 0,8885.⁴⁴




Diagram 1. Diagram alur analisis PRISMA-ScR

Tabel 1. Artikel yang disertakan untuk ditinjau: karakteristik literatur

No.	Penulis	Tahun	Judul Penelitian
1.	Liu <i>et al.</i> ³⁸	2022	A pilot study of a deep learning approach to detect marginal bone loss around implants
2.	Vera <i>et al.</i> ³⁹	2023	Artificial Intelligence Techniques for Automatic Detection of Peri-implant Marginal Bone Remodeling in Intraoral Radiographs
3.	Troiano <i>et al.</i> ⁴⁰	2023	Can radiomic features extracted from intra-oral radiographs predict physiological bone remodelling around dental implants? A hypothesis-generating study
4.	Sorkhabi <i>et al.</i> ⁴¹	2019	Classification of alveolar bone density using 3-D deep convolutional neural network in the cone-beam CT : A 6-month clinical study
5.	Zhang <i>et al.</i> ⁴²	2023	Deep learning based dental implant failure prediction from periapical and panoramic films
6.	Oh <i>et al.</i> ⁴³	2023	Deep learning-based prediction of osseointegration for dental implant using plain radiography
7.	Lee <i>et al.</i> ⁴⁴	2024	Establishing a novel deep learning model for Mendeteksi peri-implantitis
8.	Rajan <i>et al.</i> ⁴⁵	2024	Evaluating the role of AI in predicting the success of dental implants based on preoperative CBCT images: A randomized controlled trial
9.	Cha <i>et al.</i> ⁴⁶	2021	Peri-Implant Bone Loss Measurement Using a Region-Based Convolutional Neural Network on Dental Periapical Radiographs
10.	Huang <i>et al.</i> ⁴⁷	2022	The construction and evaluation of a multi-task convolutional neural network for a cone-beam computed-tomography-based assessment of implant stability
11.	Zhang <i>et al.</i> ⁴⁸	2020	Trabeculae microstructure parameters serve as effective predictors for marginal bone loss of dental implant in the mandible

Tabel 2. Artikel yang disertakan untuk ditinjau: karakteristik sampel

No.	Modalitas	Radiografi		Jumlah Pasien	Jumlah Implan
		Exposure	Resolusi		
1.	Periapical	appropriate exposure	96 dpi, 300-500 x 300-400 pixels	N/A	1670 implan
2.	Bitewing, Periapical	70 kV, 7mA, 0,100s	410x340 pixels	62 pasien memberikan 10% dari dataset, masing-masing 4-6 radiografi	2336 implan
3.	Periapical	60 kV, 7 mA	N/A	44 pasien (19 laki-laki, 25 perempuan) usia rata-rata 58.30 SD $\pm$ 12.27 tahun	44 implan (88 sites: mesial dan distal)
4.	CBCT	65KV, 8 mA, 30.8 sec	voxel size 80–250 mm. 140x100 pixels	83 pasien usia rata-rata 57,3 SD $\pm$ 11,8 tahun	207 implan
5.	Periapical, Panoramic	70 kV, 7 mA, 0.08s; 80 kV, 8 mA, 7.2s	224x224 pixels	248 pasien (142 laki-laki dan 106 perempuan)	248 implan (89 gagal dan 159 berhasil)
6.	Periapical, Panoramic	Panoramic: Promax (12 mA, 72 kV, 15.8 s) atau PCH-2500 (10 .mA, 72 kV, .13.5 s). .Periapical: Planmeca .ProX.	256x256 pixels	580 pasien (311 laki-laki, 269 perempuan; rentang usia, 21-78 tahun)	1,206 implant
7.	Periapical	N/A.	640x640 pixels	N/A	800 implan
8.	CBCT	N/A.	N/A	150 pasien (75 bantuan AI dan 75 pemeriksaan tradisional)	150 implan (75 setiap grup)
9.	Periapical	N/A.	N/A	N/A	708 implan
10.	CBCT	90 k.V, 12.92 mAs, CTDIvoi: 1.61 mGy, exposure: 3.6 s	256x256 pixels	41 pasien (23 laki-laki dan 18 perempuan)	55 implan
11.	CBCT	110 kV, 10 mA, exposure: 3.6 s, scanning: 18 s	N/A	81 pasien (41 kasus MBL berat dan 40 normal)	N/A

Tabel 3. Artikel yang disertakan untuk ditinjau: hasil (outcome)

No.	Variabel Analisis	Model AI			Dataset			
		Sub-set	Algoritma	Arsitektur	Total	Latihan	Validasi	Uji Coba
1.	Memprediksi <i>marginal bone loss</i>	DL	CNN	Faster R-CNN	1670 periapical (835 dengan dan 835 tanpa marginal bone loss)	1370 periapical	150 periapical	150 periapical
2.	Memprediksi <i>marginal bone loss</i>	DL	CNN	YOLOv3 + Image Understanding (IU)	2920 intraoral (350 bitewing, 1986 periapical), 25% augmentasi	1314 intraoral	146 intraoral	1460 intraoral (15% bitewing dan 85% periapical)
3.	Memprediksi <i>physiological bone remodeling</i>	ML	Naive Bayes, RF, Gradient Boosting, LR, K-NN, Tree, SVM, CN2 rule inducer	N/A	44 implan (88 sites: mesial dan distal)	N/A	N/A	N/A
4.	Memprediksi <i>Alveolar bone density</i> (D1-D4)	DL	CNN	3-D deep CNN	207 CBCT	110 CBCT (620 setelah augmentasi)	54 CBCT	43 CBCT
5.	Memprediksi <i>marginal bone loss</i>	DL	CNN	ResNet-50	900 panoramic dan 900 periapical (augmentasi dari 529 dan 551)	720 panoramic dan 720 periapical	five-fold cross-validation	180 panoramic dan 180 periapical

6.	Memprediksi <i>Bone-implant contact</i> (BIC)	DL	CNN	ResNet-18,34,50, DenseNet-121,201, MobileNet-V2, V3	580 pasien (338 tanpa osseointegrasi, 242 dengan osseointegrasi)	347 pasien	116 pasien	117 pasien
7.	Memprediksi <i>marginal bone loss</i>	DL	CNN	YOLOv7	800 periapical	600 periapical	100 periapical	100 periapical
8.	Memprediksi <i>Bone Quality</i> dan <i>Density</i>	DL	CNN	N/A	150 implants (75 in each group)	N/A	N/A	75 Implant
9.	Memprediksi <i>marginal bone loss</i>	DL	CNN	Mask R-CNN	708 periapical	508 periapical	100 periapical	100 periapical
10.	Memprediksi implant stability	DL	CNN	ResNet-50	779 CBCT (20,488 cross-sectional images of the arch)	624 CBCT	N/A	155 CBCT (binary dan quaternary) 150 CBCT (ternary)
11.	Memprediksi <i>marginal bone loss</i>	ML	SVM, ANN, LR, RF	N/A	81 pasien (41 MBL berat, 40 normal)	70% dari dataset	N/A	30% dari dataset

DL = *deep learning*; ML = *machine learning*; CNN = *convolutional neural network*; RF = *random forest*; LR = *logistic regression*; K-NN = *k-nearest neighbors*; SVM = *support vector machine*; ANN = *artificial neural network*

PEMBAHASAN

Kecerdasan buatan (AI) telah merevolusi implanologi gigi dengan meningkatkan evaluasi klinis dan efisiensi waktu.^{49,50} Tinjauan ini menggarisbawahi aplikasi dan perkembangan AI dalam analisis osseointegrasi, mencakup akurasi diagnostik, kemampuan prediktif, dan implementasi klinis untuk meningkatkan keberhasilan implan. Model dalam studi-studi ini dikembangkan untuk mengidentifikasi kehilangan tulang marginal dan memprediksi kegagalan implan, membantu dokter gigi merancang rencana perawatan secara akurat.

Modalitas radiografi berperan penting dalam analisis implan berbasis AI. Tujuh dari sembilan penelitian melatih model menggunakan radiografi periapikal^{38–44}, dengan performa terbaik oleh Lee *et al.*⁴³ untuk memprediksi kehilangan tulang marginal menunjukkan (akurasi 94,74% dan presisi 100%), lebih unggul dibanding modalitas lain. Neto *et al.*,¹⁴ mengatakan bahwa radiografi periapikal dan CBCT lebih baik dibandingkan radiografi panoramik dalam mendeteksi osseointegrasi implan gigi. Empat penelitian menggunakan modalitas CBCT^{45–48} penelitian oleh Huang *et al.*,⁴⁸ dapat mengevaluasi stabilitas setiap implan hanya dalam waktu 3,76 detik dan penelitian Sorkhabi *et al.*,⁴⁵ menganalisis kepadatan tulang alveolar (D1-D4) menghasilkan performa yang tinggi dengan kecepatan klasifikasi dalam 76 ms, yang menunjukkan efisiensi yang tinggi.

Model berbasis CBCT, menurut Thurzo *et al.*⁵¹ dan Elsonbaty *et al.*,⁵² menawarkan akurasi segmentasi dan analisis volumetrik yang lebih unggul dibandingkan model yang dilatih dengan gambar panoramik atau periapikal, berkat kemampuannya menangkap detail anatomi yang sering terlewat pada modalitas 2D. Radiografi panoramik dan bitewing digunakan dalam 3 penelitian dan dibandingkan atau dikombinasikan dengan radiografi periapikal^{39,41,42}, hasilnya menunjukkan bahwa penggabungan dua modalitas dapat meningkatkan akurasi, sensitivitas, dan presisi dibandingkan hanya menggunakan satu modalitas.⁴² Oleh karena itu, pilihan modalitas radiografi secara signifikan mempengaruhi kinerja analisis implan berbasis AI untuk hasil diagnostik yang optimal.

Tujuh dari 11 penelitian menggunakan gambar radiografi pasien tiga bulan pasca-implanasi^{39–42,45,46} dengan waktu tercepat mulai 2,5 bulan,⁴² sesuai dengan penelitian Pinotti *et al.*,⁵³ yang menunjukkan osseointegrasi meningkat signifikan pada 28, 45, dan 90 hari. Penelitian oleh Zhang *et al.*⁴⁶ menggunakan model SMV menghasilkan sensitivitas, spesifisitas dan AUROC yang tinggi dengan menggunakan dataset homogen yang berfokus pada implan mandibula. Dataset homogen dari daerah atau kondisi anatomi tertentu dapat meningkatkan kinerja model AI tetapi dapat membatasi generalisasi dalam praktik klinis. Park *et al.*⁵⁴ menekankan pentingnya dataset beragam untuk klasifikasi ukuran implan

secara efektif, sejalan dengan Khatib Sulaiman Dalam et al. yang menyatakan bahwa database beragam meningkatkan deteksi dan klasifikasi AI.⁵⁵

AI telah menunjukkan potensi yang signifikan dalam menganalisis variabel untuk analisis osseointegrasi implan gigi, seperti kehilangan tulang marginal, yang dipelajari dalam enam studi.^{38,39,42–44,46} *Marginal bone loss* dihitung dengan mendeteksi 4-6 *keypoints* pada radiografi (puncak implan, batas kehilangan tulang, apeks implan), dengan klasifikasi oleh Vera et al.³⁹ dan Cha et al.⁴⁴ menjadi *normal* ($\leq 10\%$), *early* (10-25%), *moderate* (25-50%), dan *severe* ($\geq 50\%$), sementara Lee et al.⁴³ menggunakan Grade 1 ($< 15\%$ panjang implan), Grade 2 ($\geq 15\%$ -25%), Grade 3 ($\geq 25\%$ -50%), dan Grade 4 ($> 50\%$). *Physiological bone remodeling* diukur melalui perubahan jarak vertikal antara platform implan dan titik kontak tulang-implan pada radiografi, menggunakan ROI dari puncak tulang hingga ulir ketiga implan (ekstensi 2,5 mm), dengan klasifikasi Troiano et al.⁴⁰ *high* ($\geq 0,5$ mm) atau *low* ($< 0,5$ mm). Oh et al.⁴¹ menganalisis *bone-implant contact* dengan erosi dan dilasi morfologi untuk mendapatkan ROI peri-implant, sementara Huang et al.⁴⁸ mengevaluasi stabilitas implan. Sorkhabi et al.⁴⁵ dan Rajan et al.⁴⁷ memprediksi keberhasilan implan melalui analisis *alveolar bone density* (D1-D4) dan *bone quality* dan *density*. Kemajuan ini meningkatkan presisi pengambilan keputusan klinis dan hasil perawatan pasien.

Mayoritas penelitian menunjukkan bahwa model AI memiliki kinerja tinggi, seperti akurasi, sensitivitas, spesifisitas, presisi, skor F1, dan AUC, dalam memprediksi osseointegrasi dari gambar radiografi. Namun, parameter penilaian yang digunakan bervariasi di antara 9 studi. Dua studi membandingkan AI dengan dokter gigi: Cha et al.⁴⁴ tidak menemukan perbedaan signifikan, sedangkan Liu et al.³⁸ menyatakan AI setara dengan residen tetapi belum menyamai dokter berpengalaman. Hal ini menunjukkan bahwa efektivitas AI dalam memprediksi keberhasilan implan bervariasi, kemungkinan karena adanya perbedaan model AI, ukuran dataset, dan parameter penilaian yang digunakan. *Deep learning*, khususnya *convolutional neural network* (CNN), digunakan pada tujuh dari sembilan penelitian.^{38,39,41–45}

CNN mencapai akurasi diagnostik setara dengan ahli radiologi, mempercepat dan meningkatkan keandalan keputusan klinis, menjadikannya model yang paling banyak digunakan.^{56,57} Model arsitektur YOLOv7 yang digunakan pada penelitian Lee et al.⁴³ mendapatkan hasil yang paling tinggi dibandingkan dengan model arsitektur yang lainnya dan kecepatan dalam deteksi objek secara real-time. Hasil ini sejalan dengan pernyataan Sun et al. dan Liu et al. menyatakan bahwa YOLOv7 menyederhanakan deteksi objek menjadi masalah regresi, memungkinkan pemrosesan lebih cepat tanpa mengorbankan akurasi.^{58,59} Penelitian Rajan et al.⁴⁷ menunjukkan bahwa penilaian berbantuan AI meningkatkan keberhasilan implan, mengurangi komplikasi, dan meminimalkan intervensi pascaoperasi dengan akurasi 87,0%.

Selain itu, terdapat penelitian oleh Oh et al.⁴¹ yang membandingkan tujuh model DL, menemukan ResNet-50 (arsitektur 50 lapisan dengan desain *bottleneck*) lebih akurat dibanding model yang lainnya, seperti ResNet-18 yang lebih sederhana (18 lapisan).^{60,61} Hal ini didukung penelitian Huang et al.,⁴⁸ di mana ResNet-50 mencapai akurasi 96,13% pada klasifikasi biner, 95,33% pada ternary, dan 92,90% pada quaternary dalam evaluasi stabilitas implan.

Machine Learning (ML) digunakan pada dua penelitian.^{40,46} Pada penelitian Zhang et al.⁴⁶ membandingkan 4 model ML didapatkan algoritma SMV dengan hasil yang tinggi, kemungkinan karena menggunakan dataset homogen. Selain itu, SVM sering digunakan dalam analisis gambar medis karena kemampuannya dalam mengolah data berdimensi tinggi, membentuk batas keputusan yang kompleks, serta mengklasifikasikan fitur yang tidak dapat dipisahkan secara linear dengan efektif menggunakan fungsi kernel.⁶² Sedangkan penelitian Troiano et al.⁴⁰ membandingkan 8 ML dan menemukan Naive Bayes sebagai model terbaik dalam prediksi *Physiological Bone Remodeling* karena kompatibel dengan fitur radiomik berdimensi rendah, akan tetapi, penelitiannya memperoleh hasil yang lebih rendah dibandingkan model AI lainnya. Model ML sering mengalami kesulitan menangani variasi dan kompleksitas gambar, sehingga sulit mencapai akurasi yang konsisten. Cara untuk mengatasi tantangan ini secara efektif, ML membutuhkan dataset

yang besar, beragam, dan berkualitas tinggi karena kinerja algoritma sangat bergantung pada kuantitas dan kualitas data pelatihan. Seperti yang disebutkan dalam literatur Hsieh *et al.*,⁶³ dan Kaya *et al.*,⁶⁴ ketersediaan dataset gambar gigi yang luas dapat memfasilitasi pelatihan model yang kuat yang mampu menggeneralisasi di berbagai populasi dan kondisi pencitraan.^{63,64} Pemilihan model yang optimal bergantung pada karakteristik tugas klinis, kualitas data, dan kebutuhan efisiensi komputasi.

Ukuran dan kualitas dataset berpengaruh pada performa model AI dalam analisis implan gigi, di mana dataset besar seperti 2920 intraoral radiografi,³⁹ dan 1670 periapikal,^{38,40} menunjukkan hasil lebih baik dibanding dataset kecil seperti 44 gambar implan.⁴⁰ Teknik augmentasi data seperti rotasi, scaling, dan cropping dapat digunakan untuk mengatasi keterbatasan dataset kecil.^{65,66} Teknik ini dapat meningkatkan jumlah dataset yang digunakan seperti pada penelitian Zhang *et al.* dan Vera *et al.*^{39,42}. Menurut Garcea *et al.*,⁶⁷ augmentasi data merupakan strategi efektif untuk meningkatkan performa *deep neural network* dibandingkan dengan pelatihan tanpa augmentasi.⁶⁷ Selain itu juga bisa menggunakan teknik *cross-validation*, seperti pendekatan lima kali lipat yang digunakan oleh Troiano *et al.*,⁴⁰ untuk mengurangi bias dan memastikan evaluasi model yang seimbang. Metode ini sangat efektif untuk dataset kecil dengan memaksimalkan data pelatihan dan validasi yang digunakan dalam model.⁶⁸

Meskipun terdapat kemajuan, masih terdapat beberapa kendala dalam mengintegrasikan AI ke dalam aplikasi klinis. Salah satu keterbatasan yang sering ditemukan adalah kurangnya *external validation*.^{40–42,46}, karena sebagian besar model diuji pada dataset yang homogen atau terbatas pada satu institusi, sehingga hasilnya sulit digeneralisasi. Variasi dalam protokol radiografi, seperti sudut pengambilan gambar, resolusi, dan penyesuaian alat,^{39,41,42} mempengaruhi hasil model saat diterapkan dalam praktik klinis. Ukuran dataset yang kecil,^{40,42,46} serta ketergantungan pada satu modalitas,^{38,40,43–46} juga meningkatkan risiko *overfitting* yang mengurangi ketepatan diagnosis.

Penelitian selanjutnya perlu memperhatikan kolaborasi *multi-center* untuk meningkatkan keberagaman dataset dan *external validation*. Standarisasi teknik radiografi diperlukan untuk mendapatkan hasil yang lebih konsisten. Langkah-langkah ini dapat menjembatani AI dengan praktik klinis, meningkatkan akurasi diagnosis dan kualitas perawatan pasien. Keterbatasan dari penelitian ini adalah ruang lingkup tinjauan yang berfokus pada publikasi berbahasa Inggris dan periode waktu tertentu, sehingga kemungkinan masih ada studi relevan yang tidak teridentifikasi. Selain itu, variasi metodologi, model AI, dan parameter evaluasi antar penelitian dapat menimbulkan heterogenitas yang membatasi perbandingan langsung antar studi.

SIMPULAN

Model *deep learning* dengan algoritma CNN, analisis *marginal bone loss*, dan penggunaan radiografi periapikal merupakan karakteristik yang paling banyak digunakan, sedangkan model terbaik yang teridentifikasi adalah YOLOv7 (Deep Learning) dan SVM (Machine Learning). Implikasi dari penelitian ini adalah perkembangan AI saat ini dapat diaplikasikan untuk analisis berbagai variabel osseointegrasi, termasuk *Marginal Bone Loss*, *Bone Remodeling*, *Bone-Implant Contact (BIC)*, *Bone Quality* dan *Density*, serta Stabilitas Implan menggunakan radiografi periapikal, panoramik, bitewing, dan CBCT.

Kontribusi Penulis: Kontribusi Penulis: Kontribusi peneliti "Konseptualisasi, N.H.; F.P.; dan Y.A.L.; metodologi, N.H.; F.P.; dan Y.A.L.; perangkat lunak, N.H.; F.P.; dan Y.A.L.; validasi, N.H.; F.P.; dan Y.A.L.; analisis formal, N.H.; F.P.; dan Y.A.L.; investigasi, N.H.; F.P.; dan Y.A.L.; sumber daya, N.H.; F.P.; dan Y.A.L.; kurasi data, N.H.; F.P.; dan Y.A.L.; penulisan—penyusunan draft awal, N.H.; F.P.; dan Y.A.L.; penulisan—tinjauan dan penyuntingan, N.H.; F.P.; dan Y.A.L.; visualisasi, N.H.; F.P.; dan Y.A.L.; supervisi, X.X.; administrasi proyek, N.H.; F.P.; dan Y.A.L.; perolehan pendanaan, N.H.; F.P.; dan Y.A.L.; Semua penulis telah membaca dan menyetujui versi naskah yang diterbitkan."

Pernyataan Ketersediaan Data: Ketersediaan data penelitian akan diberikan izin oleh semua peneliti melalui email korespondensi dengan memperhatikan etika dalam penelitian.

Konflik Kepentingan: Penulis menyatakan tidak ada konflik kepentingan.

DAFTAR PUSTAKA

- Brånemark PI, Breine U, Adell R, Hansson BO, Lindström J, Ohlsson A. Intra-osseous anchorage of dental prostheses. I. Experimental studies. Scand J Oseointegration of Dental Implants in Patients with Congenital and Degenerative Bone Disorders: A Literature Review. *J Int Soc Prevent Community Dentistry*. 2023;13(3):167–172. https://doi.org/10.4103/jispcd.JISPCD_51_22
- Smeets R, Stadlinger B, Schwarz F, Beck-Broichsitter B, Jung O, Precht C, Kloss F, Gröbe A, Heiland M, Ebker T. Impact of Dental Implant Surface Modifications on Osseointegration. *Biomed Res Int*. 2016;2016:6285620. <https://doi.org/10.1155/2016/6285620>
- Ho K, Bahammam S, Chen CY, Hojo Y, Kim D, Kondo H, Da Silva J, Nagai S. A cross-sectional survey of patient's perception and knowledge of dental implants in Japan. *Int J Implant Dent*. 2022;8(1):14. <https://doi.org/10.1186/s40729-022-00410-w>
- Elani HW, Starr JR, Da Silva JD, Gallucci GO. Trends in Dental Implant Use in the U.S., 1999–2016, and Projections to 2026. *J Dent Res [Internet]*. 2018 Dec 1 [cited 2024 Sep 11];97(13):1424. Available from: <https://pmc/articles/PMC6854267/>
- Dioguardi M, Spirito F, Quarta C, Sovereto D, Basile E, Ballini A, et al. Guided Dental Implant Surgery: Systematic Review. *J Clin Med [Internet]*. 2023 Feb 1 [cited 2024 Sep 11];12(4):1490. Available from: <https://pmc/articles/PMC9967359/>
- Thiebot N, Hamdani A, Blanchet F, Dame M, Tawfik S, Mbapou E, et al. Implant failure rate and the prevalence of associated risk factors: a 6-year retrospective observational survey. *Journal of Oral Medicine and Oral Surgery [Internet]*. 2022 [cited 2024 Sep 11];28(2):19. Available from: https://www.iomos.org/articles/mbcb/full_html/2022/02/mbcb210065/mbcb210065.html
- Frumkin N, Iden JA, Schwartz-Arad D. Effect of osteopenia and osteoporosis on failure of first and second dental implants: a retrospective observational study. *International Journal of Implant Dentistry* 2024 10:1 [Internet]. 2024 Sep 4 [cited 2024 Oct 7];10(1):1–8. Available from: <https://journalimplantdent.springeropen.com/articles/10.1186/s40729-024-00556-9>
- Stocchero M, Jinno Y, Toia M, Ahmad M, Papia E, Yamaguchi S, et al. Intraosseous Temperature Change during Installation of Dental Implants with Two Different Surfaces and Different Drilling Protocols: An In Vivo Study in Sheep. *J Clin Med [Internet]*. 2019 Aug 1 [cited 2024 Oct 7];8(8). Available from: <https://pmc/articles/PMC6723378/>
- Shang Y, Gao Q, Lengas T, Deng S. Postsurgical Pain and Implant Osseointegration Failure: A Case Control Study. *Int J Dent [Internet]*. 2022 [cited 2024 Sep 18];2022. Available from: <https://pmc/articles/PMC9283066/>
- Gupta A, Kale B, Masurkar D, Jaiswal P, Gupta A, Kale B, et al. Etiology of dental implant complication and failure—an overview. *AIMS Bioengineering* 2023 2:141 [Internet]. 2023 [cited 2024 Sep 18];10(2):141–52. Available from: <http://www.aimspress.com/article/doi/10.3934/bioeng.2023010>
- Kastala V. Methods to measure implant stability. *Journal of Dental Implants [Internet]*. 2018 [cited 2024 Sep 18];8(1):3. Available from: https://journals.lww.com/jodi/fulltext/2018/08010/methods_to_measure_implant_stability.2.aspx
- Soylu E, Coşgunarslan A, Çelebi S, Soydan D, Demirbaş AE, Demir O. Fractal analysis as a useful predictor for determining osseointegration of dental implant? A retrospective study. *Int J Implant Dent [Internet]*. 2021 Dec [cited 2024 Sep 12];7(1). Available from: <https://pmc/articles/PMC7904985/>
- Sanjay D, Lagdive B, Shah RJ, Himanshu D, Vadher M. Success Criteria For Dental implant – A Literature Review. *Int J Recent Sci Res [Internet]*. 2019;10(05(A)):30693–6. Available from: <http://dx.doi.org/10.24327/ijsr.2019.1005.3105>
- Neto JDP, Melo G, Marin C, Rivero ERC, Cruz ACC, Flores-Mir C, et al. Diagnostic performance of periapical and panoramic radiography and cone beam computed tomography for detection of circumferential gaps simulating osseointegration failure around dental implants: A systematic review. *Oral Surg Oral Med Oral Pathol Oral Radiol [Internet]*. 2021 Dec 1 [cited 2025 Jan 19];132(6):e208–22. Available from: <https://pubmed.ncbi.nlm.nih.gov/34580020/>
- Kormas I, Pedercini C, Pedercini A, Raptopoulos M, Alassy H, Wolff LF. Peri-Implant Diseases: Diagnosis, Clinical, Histological, Microbiological Characteristics and Treatment Strategies. A Narrative Review. *Antibiotics [Internet]*. 2020 Nov 1 [cited 2024 Sep 11];9(11):1–19. Available from: <https://pmc/articles/PMC7700146/>
- Lubis RT, Azhari A, Pramanik F. Analysis of Bone Density and Bone Morphometry by Periapical Radiographs in Dental Implant Osseointegration Process. *Int J Dent [Internet]*. 2023 [cited 2024 Sep 11];2023. Available from: <https://pmc/articles/PMC10085658/>
- He T, Cao C, Xu Z, Li G, Cao H, Liu X, et al. A comparison of micro-CT and histomorphometry for evaluation of osseointegration of PEO-coated titanium implants in a rat model. *Sci Rep [Internet]*. 2017 Dec 1 [cited 2024 Sep 18];7(1). Available from: <https://pmc/articles/PMC5701240/>
- Pikner SS. Radiographic follow-up analysis of Brånemark dental implants. *Swed Dent J Suppl*. 2018;(194):5–69.
- Zanetti EM, Pascoletti G, Cali M, Bignardi C, Franceschini G. Clinical Assessment of Dental Implant Stability During Follow-Up: What Is Actually Measured, and Perspectives. *Biosensors (Basel) [Internet]*. 2018 Jul 13 [cited 2024 Sep 18];8(3). Available from: <https://pmc/articles/PMC6165397/>
- Putra RH, Doi C, Yoda N, Astuti ER, Sasaki K. Current applications and development of artificial intelligence for digital dental radiography. *Dentomaxillofacial Radiology*. 2022;51(1).
- Alshenaiber R, Alharbi R, Alzahrani B, AlShehri K, Alnafisah F, Aljulyfy I, et al. A Prediction of Tooth Restorability Using Artificial Intelligence versus Natural Intelligence: Preliminary Study. 2024 Jun 26 [cited 2025 Feb 17]; Available from: <https://www.researchsquare.com>
- Meng HW, Chien EY, Chien HH. Immediate Implant Placement and Provisionalization in the Esthetic Zone: A 6.5-Year Follow-Up and Literature Review. *Case Rep Dent [Internet]*. 2021 [cited 2025 Mar 21];2021:4290193. Available from: <https://pmc.ncbi.nlm.nih.gov/articles/PMC8457954/>
- Putra RH, Doi C, Yoda N, Astuti ER, Sasaki K. Current applications and development of artificial intelligence for digital dental radiography. *Dentomaxillofacial Radiology [Internet]*. 2022 Jan 1 [cited 2024 Sep 11];51(1):51. Available from: <https://pmc/articles/PMC8693331/>
- Li S, Deng YQ, Zhu ZL, Hua HL, Tao ZZ. A Comprehensive Review on Radiomics and Deep Learning for Nasopharyngeal Carcinoma Imaging. *Diagnostics* 2021, Vol 11, Page 1523 [Internet]. 2021 Aug 24 [cited 2024 Sep 12];11(9):1523. Available from: <https://www.mdpi.com/2075-4418/11/9/1523/htm>
- Talaei Khoei T, Ould Slimane H, Kaabouch N. Deep learning: systematic review, models, challenges, and research directions. *Neural Comput Appl [Internet]*. 2023 Nov 1 [cited 2024 Sep 28];35(31):23103–24. Available from: <https://link.springer.com/article/10.1007/s00521-023-08957-4>

26. 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 Oct 1;77:106–11.
27. Kühnisch J, Meyer O, Hesenius M, Hickel R, Gruhn V. Caries Detection on Intraoral Images Using Artificial Intelligence. *J Dent Res*. 2022 ;101(2):158.
28. Hartman H, Nurdin D, Akbar S, Cahyanto A, Setiawan AS. Exploring the potential of artificial intelligence in paediatric dentistry: A systematic review on deep learning algorithms for dental anomaly detection. *Int J Paediatr Dent [Internet]*. 2024 Sep 1 [cited 2024 Sep 27];34(5):639–52. Available from: <https://onlinelibrary.wiley.com/doi/full/10.1111/ipd.13164>
29. Satapathy SK, Kunam A, Rashme R, Sudarsanam PP, Gupta A, Kiran Kumar HS. AI-Assisted Treatment Planning for Dental Implant Placement: Clinical vs AI-Generated Plans. *J Pharm Bioallied Sci [Internet]*. 2024 Feb 1 [cited 2024 Sep 27];16(Suppl 1):S939. Available from: /pmc/articles/PMC11001018/
30. Kwak GH, Kwak EJ, Song JM, Park HR, Jung YH, Cho BH, et al. Automatic mandibular canal detection using a deep convolutional neural network. *Scientific Reports* 2020 10:1 [Internet]. 2020 Mar 31 [cited 2024 Sep 27];10(1):1–8. Available from: <https://www.nature.com/articles/s41598-020-62586-8>
31. Oh S, Kim YJ, Kim J, Jung JH, Lim HJ, Kim BC, et al. Deep learning-based prediction of osseointegration for dental implant using plain radiography. *BMC Oral Health [Internet]*. 2023 Dec 1 [cited 2024 Sep 11];23(1):1–7. Available from: <https://bmcoralhealth.biomedcentral.com/articles/10.1186/s12903-023-02921-3>
32. Cha JY, Yoon HI, Yeo IS, Huh KH, Han JS. Peri-Implant Bone Loss Measurement Using a Region-Based Convolutional Neural Network on Dental Periapical Radiographs. *J Clin Med [Internet]*. 2021 Mar 1 [cited 2024 Sep 27];10(5):1–12. Available from: /pmc/articles/PMC7958615/
33. Huang N, Liu P, Yan Y, Xu L, Huang Y, Fu G, et al. Predicting the risk of dental implant loss using deep learning. *J Clin Periodontol [Internet]*. 2022 Sep 1 [cited 2024 Sep 27];49(9):872–83. Available from: <https://onlinelibrary.wiley.com/doi/full/10.1111/jcpe.13689>
34. Elgarba BM, Fontenele RC, Tarce M, Jacobs R. Artificial intelligence serving pre-surgical digital implant planning: A scoping review. *J Dent*. 2024 Apr 1;143:104862.
35. Wu Z, Yu X, Wang F, Xu C. Application of artificial intelligence in dental implant prognosis: A scoping review. *J Dent [Internet]*. 2024 May 1 [cited 2025 Feb 17];144. Available from: <https://pubmed.ncbi.nlm.nih.gov/38467177/>
36. Westphal KK, Regoezi W, Masotya M, Vazquez-Westphal B, Lounsbury K, McDavid L, Lee H, Johnson J, Ronis SD. From Arksey and O'Malley and Beyond: Customizations to enhance a team-based, mixed approach to scoping review methodology. *MethodsX*; 2021 [cited 2024 Oct 9];8:101375. <https://doi.org/10.1016/j.mex.2021.101375>
37. Hadie SNH. ABC of a scoping review: a simplified JBI scoping review guideline. *Educ Med J*. 2024;16(2):185–197. <https://doi.org/10.21315/eimj2024.16.2.14>
38. Liu M, Wang S, Chen H, Liu Y. A pilot study of a deep learning approach to detect marginal bone loss around implants. *BMC Oral Health*. 2022 Dec 1;22(1).
39. Vera M, Gómez-Silva MJ, Vera V, López-González CI, Aliaga I, Gascó E, et al. Artificial Intelligence Techniques for Automatic Detection of Peri-implant Marginal Bone Remodeling in Intraoral Radiographs. *J Digit Imaging*. 2023 Oct 1;36(5):2259–77.
40. Troiano G, Fanelli F, Rapani A, Zotti M, Lombardi T, Zhurakivska K, et al. Can radiomic features extracted from intra-oral radiographs predict physiological bone remodelling around dental implants? A hypothesis-generating study. *J Clin Periodontol*. 2023 Jul 1;50(7):932–41.
41. Oh S, Kim YJ, Kim J, Jung JH, Lim HJ, Kim BC, et al. Deep learning-based prediction of osseointegration for dental implant using plain radiography. *BMC Oral Health*. 2023 Dec 1;23(1).
42. Zhang C, Fan L, Zhang S, Zhao J, Gu Y. Deep learning based dental implant failure prediction from periapical and panoramic films. *Quant Imaging Med Surg*. 2023 Feb 1;13(2):935–45.
43. Lee WF, Day MY, Fang CY, Nataraj V, Wen SC, Chang WJ, et al. Establishing a novel deep learning model for detecting peri-implantitis. *J Dent Sci [Internet]*. 2024 Apr 1 [cited 2024 Nov 16];19(2):1165–73. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/38618118>
44. Cha JY, Yoon HI, Yeo IS, Huh KH, Han JS. Peri-Implant Bone Loss Measurement Using a Region-Based Convolutional Neural Network on Dental Periapical Radiographs. *J Clin Med [Internet]*. 2021 Mar 2 [cited 2024 Nov 16];10(5):1–12. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/33801384>
45. Sorkhabi MM, Khajeh MS. Classification of alveolar bone density using 3-D deep convolutional neural network in the cone-beam CT images: A 6-month clinical study. *MEASUREMENT*. 2019;148.
46. Zhang H, Shan J, Zhang P, Chen X, Jiang H. Trabeculae microstructure parameters serve as effective predictors for marginal bone loss of dental implant in the mandible. *Sci Rep*. 2020 Dec 1;10(1).
47. Rajan RSS, Kumar KHS, Sekhar A, Nadakkavukaran D, Feroz SMA, Gangadharappa P. Evaluating the Role of AI in Predicting the Success of Dental Implants Based on Preoperative CBCT Images: A Randomized Controlled Trial. *J Pharm Bioallied Sci [Internet]*. 2024 Feb 1 [cited 2025 Mar 20];16(Suppl 1):S889–91. Available from: <https://pubmed.ncbi.nlm.nih.gov/38595393/>
48. Huang Z, Zheng H, Huang J, Yang Y, Wu Y, Ge L, et al. The Construction and Evaluation of a Multi-Task Convolutional Neural Network for a Cone-Beam Computed-Tomography-Based Assessment of Implant Stability. *Diagnostics (Basel) [Internet]*. 2022 Nov 1 [cited 2025 Mar 20];12(11). Available from: <https://pubmed.ncbi.nlm.nih.gov/36359516/>
49. Shujaat S, Riaz M, Jacobs R. Synergy between artificial intelligence and precision medicine for computer-assisted oral and maxillofacial surgical planning. *Clin Oral Investig [Internet]*. 2023 Mar 1 [cited 2025 Jan 19];27(3):897–906. Available from: <https://pubmed.ncbi.nlm.nih.gov/36323803/>
50. Revilla-León M, Gómez-Polo M, Vyas S, Barmak BA, Galluci GO, Att W, et al. Artificial intelligence applications in implant dentistry: A systematic review. *Journal of Prosthetic Dentistry [Internet]*. 2023 Feb 1 [cited 2024 Sep 12];129(2):293–300. Available from: <http://www.thejpd.org/article/S0022391321002729/fulltext>
51. Thurzo A, Urbanová W, Novák B, Czako L, Siebert T, Stano P, et al. Where Is the Artificial Intelligence Applied in Dentistry? Systematic Review and Literature Analysis. *Healthcare (Basel) [Internet]*. 2022 Jul 1 [cited 2025 Feb 14];10(7). Available from: <https://pubmed.ncbi.nlm.nih.gov/35885796/>

52. Elsonbaty S, Elgarba BM, Fontenele RC, Swaity A, Jacobs R. Novel AI-based tool for primary tooth segmentation on CBCT using convolutional neural networks: A validation study. *Int J Paediatr Dent* [Internet]. 2025 Jan 1 [cited 2025 Feb 14];35(1). Available from: <https://pubmed.ncbi.nlm.nih.gov/38769619/>
53. Pinotti FE, Aroni MAT, de Oliveira GJPL, Silva BLG, Marcantonio Junior E, Marcantonio RAC. Osseointegration of implants with superhydrophilic surfaces in rats with high serum levels of nicotine. *Braz Dent J* [Internet]. 2023 [cited 2025 Feb 14];34(2):105–12. Available from: <https://pubmed.ncbi.nlm.nih.gov/37194848/>
54. Park JH, Moon HS, Jung HI, Hwang JJ, Choi YH, Kim JE. Deep learning and clustering approaches for dental implant size classification based on periapical radiographs. *Scientific Reports* 2023 13:1 [Internet]. 2023 Oct 6 [cited 2024 Oct 4];13(1):1–11. Available from: <https://www.nature.com/articles/s41598-023-42385-7>
55. Khatib Sulaiman Dalam No J, Salah Nooraldaim A, Ali Saed A. Artificial Intelligence for Caries and Tooth Detection in Dental Imaging: A Review. *The Indonesian Journal of Computer Science* [Internet]. 2023 Dec 30 [cited 2025 Feb 14];12(6):2023–3201. Available from: <http://ijcs.net/ijcs/index.php/ijcs/article/view/3522>
56. Gao T, Wang G. Chest X-ray image analysis and classification for COVID-19 pneumonia detection using Deep CNN. *medRxiv* [Internet]. 2020 Oct 12 [cited 2025 Feb 14];2020.08.20.20178913. Available from: <https://www.medrxiv.org/content/10.1101/2020.08.20.20178913v2>
57. Nakagawa F, Fujima N, Hirata K, Tang M, Tsuneta S, Suzuki J, et al. Utility of the deep learning technique for the diagnosis of orbital invasion on CT in patients with a nasal or sinonasal tumor. *Cancer Imaging* [Internet]. 2022 Dec 1 [cited 2025 Feb 14];22(1). Available from: <https://pubmed.ncbi.nlm.nih.gov/36138422/>
58. Liu S, Wang Y, Yu Q, Liu H, Peng Z. CEAM-YOLOv7: Improved YOLOv7 Based on Channel Expansion and Attention Mechanism for Driver Distraction Behavior Detection. *IEEE Access*. 2022;10:129116–24.
59. Sun Y, Li Y, Li S, Duan Z, Ning H, Zhang Y. PBA-YOLOv7: An Object Detection Method Based on an Improved YOLOv7 Network. *Applied Sciences* 2023, Vol 13, Page 10436 [Internet]. 2023 Sep 18 [cited 2025 Feb 14];13(18):10436. Available from: <https://www.mdpi.com/2076-3417/13/18/10436/html>
60. Wang S, Tong X, Cheng Q, Xiao Q, Cui J, Li J, et al. Fully automated deep learning system for osteoporosis screening using chest computed tomography images. *Quant Imaging Med Surg* [Internet]. 2024 Apr 3 [cited 2025 Feb 14];14(4):2816–27. Available from: <https://pubmed.ncbi.nlm.nih.gov/38617137/>
61. Bukhari SUK, Mehtab U, Hussain SS, Syed A, Armaghan SU, Shah SSH. The assessment of Computer Vision Algorithms for the Diagnosis of Prostatic Adenocarcinoma in Surgical Specimens. *medRxiv* [Internet]. 2020 Jul 17 [cited 2025 Feb 14];2020.07.14.20152116. Available from: <https://www.medrxiv.org/content/10.1101/2020.07.14.20152116v1>
62. Glembin M, Obuchowski A, Klaudel B, Rydzinski B, Karski R, Syty P, et al. Enhancing Renal Tumor Detection: Leveraging Artificial Neural Networks in Computed Tomography Analysis. *Medical Science Monitor* [Internet]. 2023 Jun 6 [cited 2025 Feb 14];29:0–0. Available from: <https://www.medscimonit.com/abstract/full/idArt/939462>
63. Hsieh ST, Cheng YA. Multimodal feature fusion in deep learning for comprehensive dental condition classification. *J Xray Sci Technol* [Internet]. 2024 [cited 2025 Feb 14];32(2):303–21. Available from: <https://pubmed.ncbi.nlm.nih.gov/38217632/>
64. Kaya E, Gunec HG, Gokyay SS, Kutal S, Gulum S, Ates HF. Proposing a CNN Method for Primary and Permanent Tooth Detection and Enumeration on Pediatric Dental Radiographs. *J Clin Pediatr Dent* [Internet]. 2022 Sep 13 [cited 2025 Feb 14];46(4):293–8. Available from: <https://pubmed.ncbi.nlm.nih.gov/36099226/>
65. Alshammari K, Alshammari R, Alshammari A, Alkhudaydi T. An improved pear disease classification approach using cycle generative adversarial network. *Scientific Reports* 2024 14:1 [Internet]. 2024 Mar 20 [cited 2025 Feb 14];14(1):1–11. Available from: <https://www.nature.com/articles/s41598-024-57143-6>
66. Shorten C, Khoshgoftaar TM. A survey on Image Data Augmentation for Deep Learning. *J Big Data* [Internet]. 2019 Dec 1 [cited 2025 Feb 14];6(1):1–48. Available from: <https://journalofbigdata.springeropen.com/articles/10.1186/s40537-019-0197-0>
67. Garcea F, Serra A, Lamberti F, Morra L. Data augmentation for medical imaging: A systematic literature review. *Comput Biol Med*. 2023 Jan 1;152:106391.
68. Yates LA, Aandahl Z, Richards SA, Brook BW. Cross validation for model selection: A review with examples from ecology. *Ecol Monogr* [Internet]. 2023 Feb 1 [cited 2025 Feb 14];93(1):e1557. Available from: <https://onlinelibrary.wiley.com/doi/full/10.1002/ecm.1557>