



REPUBLIK INDONESIA
KEMENTERIAN HUKUM DAN HAK ASASI MANUSIA

SURAT PENCATATAN CIPTAAN

Dalam rangka perlindungan ciptaan di bidang ilmu pengetahuan, seni dan sastra berdasarkan Undang-Undang Nomor 28 Tahun 2014 tentang Hak Cipta, dengan ini menerangkan:

Nomor dan tanggal permohonan : EC00202269851, 29 September 2022

Pencipta

Nama : **Ramadhan Hardani Putra, Eha Renwi Astuti dkk**
Alamat : Bendul Merisi Selatan 7 No.40, Surabaya, JAWA TIMUR, 60239
Kewarganegaraan : Indonesia

Pemegang Hak Cipta

Nama : **Universitas Airlangga**
Alamat : Gedung AUP Lt.2, Kampus C, Universitas Airlangga, Mulyorejo, Surabaya, JAWA TIMUR, 60115
Kewarganegaraan : Indonesia

Jenis Ciptaan : **Laporan Penelitian**

Judul Ciptaan : **Akurasi Numerasi Gigi Pada Radiografi Panoramik Menggunakan YOLO V4**

Tanggal dan tempat diumumkan untuk pertama kali di wilayah Indonesia atau di luar wilayah Indonesia : 15 September 2022, di Surabaya

Jangka waktu perlindungan : Berlaku selama 50 (lima puluh) tahun sejak Ciptaan tersebut pertama kali dilakukan Pengumuman.

Nomor pencatatan : 000385590

adalah benar berdasarkan keterangan yang diberikan oleh Pemohon.

Surat Pencatatan Hak Cipta atau produk Hak terkait ini sesuai dengan Pasal 72 Undang-Undang Nomor 28 Tahun 2014 tentang Hak Cipta.



a.n Menteri Hukum dan Hak Asasi Manusia
Direktur Jenderal Kekayaan Intelektual
u.b.
Direktur Hak Cipta dan Desain Industri

Anggoro Dasananto
NIP.196412081991031002

Disclaimer:

Dalam hal pemohon memberikan keterangan tidak sesuai dengan surat pernyataan, Menteri berwenang untuk mencabut surat pencatatan permohonan.

LAMPIRAN PENCIPTA

No	Nama	Alamat
1	Ramadhan Hardani Putra	Bendul Merisi Selatan 7 No.40
2	Eha Renwi Astuti	Kalikepiting 55/4
3	Putri Alfa Meirani Laksanti	Perum Alam Gununganyar Blok F 7/8 No. 14-16



LAPORAN HASIL PENELITIAN

Akurasi Numerasi Gigi Otomatis pada Radiografi Panoramik Menggunakan *Deep Learning*

Ramadhan Hardani Putra, **Eha Renwi Astuti**, Putri Alfa Meirani Laksanti

ABSTRAK

Latar Belakang: Numerasi gigi merupakan langkah awal interpretasi pada radiografi panoramik. Numerasi gigi secara manual umumnya membutuhkan waktu lama dan rawan terjadi kesalahan karena beban kerja dokter gigi sehari-hari. Penerapan *deep learning* di bidang medis telah berkembang pesat dalam beberapa tahun terakhir, termasuk untuk mendeteksi objek dengan cepat dan akurat, sehingga berpotensi digunakan sebagai metode numerasi gigi otomatis. **Tujuan:** Penelitian ini bertujuan untuk mengetahui akurasi numerasi gigi otomatis pada radiografi panoramik dengan menggunakan *deep learning*. **Metode:** *Dataset* sebanyak 500 gambar radiografi panoramik dipilih sesuai dengan kriteria inklusi dan dibagi menjadi *data train* dan *data test* dengan rasio 80% : 20%. Anotasi pada *dataset* diklasifikasikan ke dalam 32 kelas berdasarkan numerasi gigi metode FDI menggunakan *software* LabelImg. Proses *training* dan *testing* dilakukan dengan menggunakan arsitektur *You Only Look Once* (YOLO) v4. Nilai akurasi dihitung dengan menggunakan nilai *true positive* (TP), *false positive* (FP), *false negative* (FN), dan *true negative* (TN) dari hasil *testing*. **Hasil:** Hasil numerasi gigi otomatis oleh YOLO v4 pada 100 gambar radiografi panoramik menunjukkan 2858 TP, 401 FP, 0 FN, dan 228 TN. Akurasi model *deep learning* ini dalam melakukan numerasi gigi otomatis adalah 88,50% dengan waktu deteksi rata-rata $20,58 \pm 0,29$ ms. **Kesimpulan:** *Deep learning* dengan model YOLO v4 dapat digunakan untuk membantu dokter gigi dalam praktik sehari-hari dengan melakukan numerasi gigi otomatis pada radiografi panoramik secara akurat.

Kata kunci: akurasi; numerasi gigi; radiografi panoramik; *deep learning*; *artificial intelligence*

LATAR BELAKANG

Radiografi panoramik merupakan salah satu teknik radiografi di bidang kedokteran gigi yang menghasilkan gambaran tomografi dengan memperlihatkan struktur fasial termasuk lengkung maksila dan mandibula serta struktur pendukungnya dalam satu radiograf¹. Teknik radiografi panoramik digunakan untuk menggambarkan morfologi dan mendeteksi adanya deviasi, mengetahui pertumbuhan dan perkembangan gigi, mendeteksi adanya kelainan patologi di dentomaksilofasial, serta mengestimasi usia seseorang². Penggunaan radiografi

panoramik di antaranya adalah untuk mendeteksi fraktur rahang, lokasi dan posisi molar ketiga, penyakit gigi atau tulang, sisa akar, gigi impaksi, nyeri sendi temporomandibular (TMJ), serta anomali gigi dan jaringan sekitarnya. Selain itu, pemeriksaan ini sering digunakan sebagai evaluasi awal yang dapat memberikan gambaran untuk menentukan kebutuhan proyeksi lainnya¹.

Interpretasi gigi serta struktur anatomi di sekitarnya pada radiografi panoramik merupakan langkah utama yang penting untuk mendeteksi adanya kelainan patologi³. Hal pertama yang dilakukan dalam interpretasi radiografi panoramik adalah penentuan jenis gigi atau numerasi geligi berdasarkan anatomi dan lokasinya. Numerasi geligi secara manual pada banyak gambar radiografi panoramik tentu membutuhkan waktu yang cukup lama serta rentan terhadap terjadinya kesalahan akibat kelelahan dokter gigi⁴. Selain itu, interpretasi hasil radiografi sangat tergantung terhadap keahlian dan keterampilan seorang dokter gigi, sehingga cenderung subjektif karena tidak memiliki cukup waktu untuk mendiagnosis secara rinci⁵.

Kecerdasan buatan merupakan kemampuan suatu mesin yang dapat meniru kecerdasan dan perilaku manusia dalam melakukan tugas tertentu. Dalam beberapa tahun terakhir, kecerdasan buatan telah mengalami perkembangan yang pesat dan menjadi salah satu hal yang sangat berpengaruh di dunia. Banyak aplikasi kecerdasan buatan yang telah membantu kehidupan sehari-hari manusia, seperti mesin pencari *online*, deteksi dan klasifikasi objek, pengenalan bahasa, hingga asisten virtual⁶. Perkembangan dan penerapan kecerdasan buatan ini juga muncul di bidang kedokteran gigi. Metode berbasis kecerdasan buatan dapat digunakan untuk membantu dokter gigi dalam menginterpretasikan hasil radiografi. Metode ini dapat memungkinkan identifikasi dan klasifikasi data yang lebih cepat dan mengurangi terjadinya kesalahan akibat kelelahan dokter gigi dalam melakukan interpretasi radiograf⁴.

Deep learning (DL) termasuk bagian dari kecerdasan buatan yang dapat memproses data dengan jumlah besar, seperti teks, suara, dan gambar⁷. Salah satu jenis arsitektur dasar yang dapat berjalan dengan baik dalam DL adalah *Convolutional Neural Network* (CNN)⁸. CNN telah terbukti memiliki kemampuan yang baik dalam deteksi gambar serta menilai karakteristik batas dan warna. CNN juga sering digunakan untuk menganalisis hasil citra biomedis karena kemampuannya yang baik dan efektif dalam pengolahan gambar⁹. Dalam kedokteran gigi, CNN telah terbukti dapat digunakan untuk mendeteksi *landmark* sefalometrik¹⁰, segmentasi struktur gigi¹¹, klasifikasi¹², deteksi, dan penomoran gigi pada radiografi di bidang kedokteran gigi¹³.

Mengenai deteksi dan numerasi gigi pada radiografi dengan menggunakan kecerdasan buatan, beberapa peneliti sebelumnya telah mengujinya menggunakan berbagai macam

metode. Oktay menggunakan arsitektur AlexNet dengan versi yang telah dimodifikasi untuk mendeteksi gigi pada radiografi panoramik mendapatkan hasil akurasi mencapai lebih dari 90%¹⁴. Chen et al. juga menguji deteksi dan penomoran gigi menggunakan *Region-with Convolutional Neural Network* (R-CNN) pada radiografi peripalatal dengan 1.250 data dan mendapatkan nilai akurasi mencapai 91%¹⁵. Tuzoff et al. juga melakukan penelitian serupa menggunakan VGG-16 CNN dengan 1.352 data. Mereka mendapatkan akurasi hasil mencapai 99,45%¹³. Leite et al. mendeteksi dan mensegmentasi gigi menggunakan kombinasi dari dua deep-CNN dengan 3.576 data mendapatkan akurasi sebesar 99,6%⁴. Walaupun hasil berbagai penelitian tersebut sangat menjanjikan, penelitian ini masih dalam tahap awal dan harus terus dikembangkan.

You Only Look Once (YOLO) merupakan algoritma deteksi objek satu tahap yang dapat mendeteksi objek secara *real-time* dengan menggunakan CNN¹⁶. YOLO sendiri telah dikembangkan dari satu hingga empat versi. Bochkovskiy, Wang, dan Liao telah membuktikan bahwa versi terbaru, YOLO v4, adalah detektor canggih yang lebih cepat dan akurat daripada detektor lain yang tersedia¹⁷. Dalam radiologi kedokteran gigi, YOLO v4 telah diteliti untuk digunakan dalam mendeteksi beberapa hal, yaitu resorpsi tulang periodontal¹⁸, lokasi gigi molar ketiga¹⁹, dan fraktur mandibula yang akurasi hampir mencapai 100%²⁰. Dari penelitian tersebut, didapatkan hasil bahwa YOLO v4 merupakan metode yang lebih efektif dalam mendeteksi suatu objek.

Penelitian ini bertujuan untuk mengetahui akurasi numerasi gigi otomatis pada radiografi panoramik menggunakan YOLO v4. Hasil penelitian ini diharapkan dapat menjadi alternatif pilihan untuk melakukan numerasi gigi secara otomatis dengan akurasi yang tinggi dan dalam waktu yang singkat, sehingga dapat mempermudah dokter gigi dalam menentukan diagnosis pada radiografi panoramik.

MATERIAL DAN METODE

Penelitian ini merupakan penelitian untuk mengetahui akurasi numerasi gigi otomatis pada radiografi panoramik dengan menggunakan *deep learning*. Desain penelitian ini adalah deskriptif observasional. Penelitian ini telah memperoleh persetujuan etik dari Rumah Sakit Khusus Gigi dan Mulut Pendidikan Universitas Airlangga dengan nomor sertifikat 26/UN3.9.3/Etik/PT/2022.

Dataset

Dataset yang digunakan dalam penelitian ini adalah data sekunder berupa *softfile* radiografi panoramik dari pasien di Rumah Sakit Khusus Gigi dan Mulut Pendidikan

Universitas Airlangga periode Januari 2016 hingga April 2022. *Dataset* dengan jumlah 500 data dibagi menjadi *data train* dan *data test* dengan rasio 80% : 20%, sehingga 400 data digunakan sebagai *data train* dan 100 data digunakan sebagai *data test*. *Dataset* diambil dengan metode *purposive sampling*.

Kriteria inklusi sampel data train yang digunakan adalah fase geligi permanen, kondisi gigi sehat atau terdapat lesi karies yang tidak merusak *outline* mahkota gigi, kondisi geligi lengkap dari insisif pertama hingga molar kedua pada tiap regio, gigi molar ketiga tidak harus ada, kualitas radiograf yang baik dan berfokus pada gigi dan tulang alveolar. Fase geligi campuran atau sulung, terdapat kerusakan struktur gigi yang merusak sebagian besar *outline* gigi, misalnya karies, sisa akar, atau resorpsi akar, terdapat restorasi pada gigi yang mengubah *outline* mahkota gigi, misalnya mahkota selubung atau gigi tiruan jembatan, terdapat perawatan saluran akar, gigi dengan piranti ortodonti, implant gigi, persistensi, gigi berdesakan, *supernumerary teeth*, dan *edentulous* atau agenisi merupakan kriteria eksklusi. Kriteria *data test* yang digunakan dalam penelitian ini hampir sama dengan kriteria *data train*, kecuali *edentulous*, agenisi, gigi sedikit berdesakan, dan adanya perawatan saluran akar juga termasuk dalam kriteria inklusi.

Ground Truth

Setelah *dataset* terkumpul, selanjutnya dilakukan anotasi dengan memberi label pada objek (setiap gigi) pada setiap gambar dalam *dataset* dengan menggambar *bounding box* untuk mendapatkan *ground truth*. *Ground truth* merupakan data yang bersifat *real* dan benar serta digunakan untuk validasi. Pada proses anotasi ini, jumlah kelas yang digunakan adalah 32 kelas sesuai dengan jumlah gigi manusia dan dengan numerasi berdasarkan metode *Federation Dentaire Internationale (FDI)*²¹.


Bounding box dibuat menggunakan *software* LabelImg (Tzotalin dari Github), yang merupakan perangkat lunak untuk anotasi grafis. Proses anotasi ini divalidasi oleh dua ahli radiologi kedokteran gigi. Proses anotasi ini akan menghasilkan *file txt* untuk setiap gambar. *File* tersebut berisi format anotasi pada setiap baris untuk setiap objek sebagai berikut.

$$(\text{object-id}) (x_{\text{center}}) (y_{\text{center}}) (w) (h)$$

Arti dari anotasi teks tersebut yaitu *object-id* adalah nomor kelas (dimulai dari 0 untuk kelas pertama), x_{center} adalah koordinat pusat *bounding box* terhadap lebar objek, y_{center} adalah koordinat pusat *bounding box* terhadap tinggi objek, w adalah lebar *bounding box*, dan h adalah tinggi *bounding box*.

Model Arsitektur

Arsitektur model yang digunakan dalam penelitian ini adalah YOLO v4. Model YOLO v4 memiliki tiga struktur utama, yaitu *backbone*, *neck*, dan *head*. Struktur *backbone* berfungsi untuk menggabungkan dan membentuk fitur gambar pada berbagai jenis detail gambar yang terdiri dari CSP (*cross-stage-partial-connection*)-Darknet53. Struktur *neck* berfungsi untuk mencampur dan menggabungkan fitur gambar dan sebagai lapisan perantara fitur gambar ke lapisan prediksi yang terdiri dari *spatial pyramid pooling* (SPP) dan *path aggregation network* (PAN). Struktur *head* berfungsi untuk memprediksi fitur gambar, menghasilkan bounding box, dan memprediksi kelas yang terdiri dari YOLO v3 untuk mendeteksi. Selain itu, YOLO v4 menggunakan teknik baru untuk augmentasi data, seperti CutMix dan Mosaic guna melatih kumpulan data dan meningkatkan kemampuan deteksi¹⁷. Gambaran model YOLO v4 dapat dilihat pada Gambar 1.



Gambar 1. Model YOLO v4

Training dan Testing

Setelah anotasi selesai, dilakukan *training* pada model YOLO v4 dengan 400 *data train* yang telah dianotasi untuk mendapatkan model detektor objek yang diinginkan. Selanjutnya, dilakukan *testing* terhadap 100 *data test* menggunakan model YOLO v4 yang telah dilakukan *training* sebelumnya. Pada proses *testing*, terdapat informasi mengenai waktu yang dibutuhkan untuk mendeteksi setiap gambarnya.

Pada penelitian ini, proses *training* dan *testing* menggunakan media Google Collaboratory (Google Colab). Google Colab merupakan media edukasi serta riset *machine learning* yang terhubung dengan *cloud* dari Google. Media ini menyediakan CPU dan GPU yang merupakan komponen penting dalam pengembangan deep learning. Media ini juga dapat digunakan bersama dengan Google Drive sebagai tempat penyimpanan *notebook* sekaligus *dataset*.

Analisis Data

Analisis data dilakukan dengan menghitung nilai *confusion matrix* terlebih dahulu pada hasil pengujian numerasi menggunakan YOLO v4 yang divalidasi dengan pengamatan manual sebagai *ground truth* oleh peneliti dan dua ahli radiologi kedokteran gigi. Dalam *confusion matrix*, terdapat empat kategori, yaitu :

- a. True Positive (TP) yaitu apabila sistem mendeteksi objek gigi dengan benar sesuai dengan *ground truth*.
- b. False Positive (FP) yaitu apabila sistem mendeteksi objek gigi tertentu tetapi objek tersebut bukan merupakan gigi yang dimaksud berdasarkan *ground truth*.
- c. False Negative (FN) yaitu apabila sistem tidak dapat mendeteksi objek gigi.
- d. True Negative (TN) yaitu apabila sistem tidak mendeteksi objek gigi tertentu dan objek gigi tersebut sebenarnya tidak ada/*edentulous*.

Selanjutnya, dilakukan perhitungan nilai akurasi keseluruhan dan tiap kelas yang didapatkan menggunakan rumus berikut.

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN}$$


Hasil perhitungan nilai akurasi digunakan untuk mengetahui bagaimana YOLO v4 dapat melakukan numerasi gigi dan mendeteksi gigi yang divalidasi dengan pengamatan secara manual oleh ahli radiologi kedokteran gigi.

HASIL PENELITIAN

Pada penelitian ini, proses *training* pada 400 *data train* dengan 32 kelas membutuhkan waktu 148,78 jam. Setelah proses *training* selesai, selanjutnya dapat dilakukan pengujian atau *testing* untuk menentukan apakah model YOLO v4 dapat mendeteksi dan melakukan numerasi gigi pada radiografi panoramik dengan benar. Selama proses *testing* pada 100 *data test*, waktu rata-rata yang dibutuhkan untuk mendeteksi tiap gambarnya yaitu $20,58 \pm 0,29$ ms. Waktu tersebut dapat dikatakan sangat cepat karena hanya dalam hitungan milidetik, sistem dapat melakukan numerasi gigi pada radiografi panoramik.

Contoh hasil numerasi gigi pada radiografi panoramik oleh YOLO v4 yang tepat dapat dilihat pada Gambar 2. Berdasarkan hasil *testing* dari 100 *data test* radiografi panoramik yang telah dilakukan, jumlah *bounding box* yang dihasilkan dalam melakukan numerasi gigi sebanyak 32 kelas, yaitu 3.487 *bounding box* dengan rincian yang dapat dilihat pada Tabel 1. Tidak adanya *false negative* yang berarti semua gigi terdeteksi dengan terbentuknya *bounding*

box pada penelitian ini merupakan keunggulan dari model YOLO v4 yang telah dilakukan *training* karena hal itu dapat membuat nilai akurasi menjadi tinggi. Berdasarkan jumlah TP, TN, FP, dan FN yang dihasilkan, nilai akurasi dari model YOLO v4 dalam melakukan numerasi gigi pada radiografi panoramik secara keseluruhan didapatkan sebesar 88,50%.



Gambar 2. Numerasi Gigi oleh YOLO v4

N (Jumlah Data Test)	Kelas	Confusion Matrix	
		True Positive (TP)	False Positive (FP)
100	32	2.858	401
		False Negative (FN)	True Negative (TN)
		0	228

Tabel 1. Hasil *confusion matrix*


Selain nilai akurasi secara keseluruhan, rincian nilai akurasi dari tiap kelas juga dihitung dan didapatkan hasil seperti yang tertera pada Tabel 2. Dari tabel tersebut, pada rahang atas, dapat dilihat bahwa nilai akurasi paling tinggi dimiliki oleh kelas gigi 17 dengan akurasi sebesar 97,03% dan nilai akurasi paling rendah dimiliki oleh kelas gigi 13 dengan akurasi sebesar 80,15%. Pada rahang bawah, dapat dilihat bahwa nilai akurasi paling tinggi dimiliki oleh kelas gigi 38 dan 46 dengan akurasi sebesar 99,01% dan nilai akurasi paling rendah dimiliki oleh kelas gigi 42 dengan akurasi sebesar 76,61%. Selain itu, dapat dilihat juga bahwa regio anterior rahang bawah memiliki nilai akurasi yang relatif lebih rendah dibandingkan regio lainnya.


Gigi		Akurasi (%)	Gigi		Akurasi (%)
Maxilla	18	95,15	Mandibula	38	99,01
	17	97,03		37	96,12
	16	92,45		36	96,12

15	82,14	35	89,19
14	80,91	34	86,36
13	80,15	33	92,52
12	87,96	32	78,33
11	88,39	31	77,05
21	90,65	41	83,05
22	93,40	42	76,61
23	80,91	43	84,75
24	84,91	44	88,99
25	87,04	45	83,48
26	94,23	46	99,01
27	96,12	47	93,27
28	92,31	48	95,15

Tabel 2. Rincian nilai akurasi tiap gigi

Adanya 401 FP yang ditemukan dalam penelitian ini tentu memiliki dampak langsung terhadap nilai akurasi. Hasil deteksi dinyatakan FP apabila model berhasil membentuk *bounding box* pada gigi tetapi salah dalam mengklasifikasikan kelas gigi tersebut seperti yang terdapat pada Gambar 3a; terbentuk *double bounding box* dengan salah satu *bounding box* yang dibentuk salah dalam mengklasifikasikan kelas gigi terkait seperti pada Gambar 3b; model berhasil membentuk *bounding box* pada suatu gigi tetapi mengklasifikasikan kelas ganda pada gigi tersebut seperti pada Gambar 3c; terdapat *bounding box* yang mencakup dua gigi sekaligus dan mengklasifikasikan kelas ganda pada dua gigi tersebut seperti pada Gambar 3d; terdapat *bounding box* dengan klasifikasi yang tepat tetapi *bounding box* tidak tepat berada pada batas marginal objek gigi yang bersangkutan seperti pada Gambar 3e; atau adanya bagian *edentulous* yang terdeteksi sebagai gigi seperti pada 3f. Distribusi persentase bentuk-bentuk FP tersebut dapat dilihat pada Tabel 3. Dari tabel tersebut, didapatkan bahwa bentuk FP terbanyak adalah terjadinya *double bounding box*, yaitu sebesar 70,82% serta terbanyak kedua adalah terjadinya salah klasifikasi yaitu sebesar 12,97%.





Gambar 3. Contoh gambaran *false positive* (FP) : (a) Tampak hasil *bounding box* dengan kelas gigi 36 dan 37 pada gigi 47 dan 48; (b) Tampak *double bounding box* dengan kelas gigi 11 dan 12 pada gigi 11; (c) Tampak *bounding box* dengan kelas ganda gigi 21 dan 22 pada gigi 21; (d) Tampak *bounding box* dengan kelas ganda gigi 23 dan 24 yang mencakup gigi 23 dan 24 sekaligus; (e) Tampak *bounding box* kelas gigi 23 yang tidak tepat pada batas marginal gigi 23; (f) Tampak *bounding box* yang mendeteksi edentulous gigi 36.

Bentuk	Jumlah	Persentase
Misklasifikasi	52	12,97%
<i>Double bounding box</i>	284	70,82%
Klasifikasi ganda pada satu gigi	48	11,97%
Klasifikasi dua gigi digabung	10	2,49%
<i>Bounding box</i> tidak tepat pada batas marginal gigi	5	1,25%
<i>Edentulous</i> terdeteksi sebagai gigi	2	0,50%

Table 3. Distribusi persentase bentuk FP

REFERENSI

1. White, S.C. and Pharoah MJ. Oral Radiology (Principle and Interpretation). Vol. 53, Journal of Chemical Information and Modeling. 2013.
2. Ruth MSMA, Sosiawan A. *Peran Panoramik Radiografik di Bidang Odontology Forensik*. Surabaya: Anugrah Imprenta,; 2021.
3. Baksi BG, Alpöz E, Soğur E, Mert A. Perception of anatomical structures in digitally filtered and conventional panoramic radiographs: A clinical evaluation. *Dentomaxillofacial Radiology*. 2010;39(7).

4. Leite AF, Gerven A van, Willems H, Beznik T, Lahoud P, Gaêta-Araujo H, et al. Artificial intelligence-driven novel tool for tooth detection and segmentation on panoramic radiographs. *Clin Oral Investig*. 2021;25(4).
5. Lin PL, Huang PY, Huang PW, Hsu HC, Chen CC. Teeth segmentation of dental periapical radiographs based on local singularity analysis. *Comput Methods Programs Biomed*. 2014;113(2).
6. Jiang F, Jiang Y, Zhi H, Dong Y, Li H, Ma S, et al. Artificial intelligence in healthcare: Past, present and future. Vol. 2, *Stroke and Vascular Neurology*. 2017.
7. Yu D, Hinton G, Morgan N, Chien JT, Sagayama S. Introduction to the special section on deep learning for speech and language processing. Vol. 20, *IEEE Transactions on Audio, Speech and Language Processing*. 2012.
8. Singh SP, Kumar A, Darbari H, Singh L, Rastogi A, Jain S. Machine translation using deep learning: An overview. In: 2017 International Conference on Computer, Communications and Electronics, *COMPTELIX 2017*. 2017.
9. Cao C, Liu F, Tan H, Song D, Shu W, Li W, et al. Deep Learning and Its Applications in Biomedicine. Vol. 16, *Genomics, Proteomics and Bioinformatics*. 2018.
10. Lee H, Park M, Kim J. Cephalometric landmark detection in dental x-ray images using convolutional neural networks. In: *Medical Imaging 2017: Computer-Aided Diagnosis*. 2017.
11. Wang Y, Zheng J. Real-time face detection based on YOLO. In: 1st IEEE International Conference on Knowledge Innovation and Invention, *ICKII 2018*. 2018.
12. Miki Y, Muramatsu C, Hayashi T, Zhou X, Hara T, Katsumata A, et al. Classification of teeth in cone-beam CT using deep convolutional neural network. *Comput Biol Med*. 2017;80.
13. Tuzoff D v., Tuzova LN, Bornstein MM, Krasnov AS, Kharchenko MA, Nikolenko SI, et al. Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofacial Radiology*. 2019;48(4).
14. Oktay AB. Tooth detection with Convolutional Neural Networks. In: 2017 Medical Technologies National Conference, *TIPTEKNO 2017*. 2017.

15. Chen H, Zhang K, Lyu P, Li H, Zhang L, Wu J, et al. A deep learning approach to automatic teeth detection and numbering based on object detection in dental periapical films. *Sci Rep.* 2019;9(1).
16. Redmon J, Divvala S, Girshick R, Farhadi A. You only look once: Unified, real-time object detection. In: *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition.* 2016.
17. Bochkovskiy A, Wang CY, Liao HYM. YOLOv4: Optimal Speed and Accuracy of Object Detection. 2020 Apr 22; Available from: <http://arxiv.org/abs/2004.10934>
18. Jiang L, Chen D, Cao Z, Wu F, Zhu H, Zhu F. A Two-Stage Deep Learning Architecture for Radiographic Assessment of Periodontal Bone Loss. 2021; Available from: <https://doi.org/10.21203/rs.3.rs-885130/v1>
19. Zhu T, Chen D, Wu F, Zhu F, Zhu H. Artificial intelligence model to detect real contact relationship between mandibular third molars and inferior alveolar nerve based on panoramic radiographs. *Diagnostics.* 2021;11(9).
20. Son DM, Yoon YA, Kwon HJ, An CH, Lee SH. Automatic detection of mandibular fractures in panoramic radiographs using deep learning. *Diagnostics.* 2021;11(6).
21. Leatherman G. Two- digit system of designating teeth—FDI submission. *Aust Dent J.* 1971;16(6).
22. Yasa Y, Çelik Ö, Bayrakdar IS, Pekince A, Orhan K, Akarsu S, et al. An artificial intelligence proposal to automatic teeth detection and numbering in dental bite-wing radiographs. *Acta Odontol Scand.* 2021;79(4).
23. Putra RH, Doi C, Yoda N, Astuti ER, Sasaki K. Current applications and development of artificial intelligence for digital dental radiography. Vol. 51, *Dentomaxillofacial Radiology.* 2022.
24. Gerhardt M do N, Fontenele RC, Leite AF, Lahoud P, van Gerven A, Willems H, et al. Automated detection and labelling of teeth and small edentulous regions on cone-beam computed tomography using convolutional neural networks. *J Dent.* 2022 Jul 1;122.