

Komparatif Studi Model Deep Learning Untuk Deteksi Karies Gigi

Yefta Tanuwijaya¹, Theresia Herlina Rochadiani²

yefta.tanuwijaya@student.pradita.ac.id¹, theresia.herlina@pradita.ac.id²

^{1,2} Universitas Pradita

Informasi Artikel	Abstrak
Diterima : 25 Apr 2025 Direvisi : 30 Apr 2025 Disetujui : 30 Apr 2025	Karies gigi merupakan sebuah penyakit gigi yang dianggap sebagai masalah kesehatan masyarakat global dan diperlukan pendeteksi yang terjangkau untuk daerah-daerah terpencil. Penelitian ini menyajikan komparasi terhadap hasil evaluasi model <i>deep learning</i> untuk mendeteksi karies gigi dari tingkat awal hingga rampant dengan menggunakan model YOLOv11, Faster R-CNN dan RetinaNet. Dataset berisi 1.036 gambar dengan yang terbagi dalam 4 kelas (gigi sehat, karies awal, karies sedang dan karies rampant). Hasilnya YOLOv11 menghasilkan <i>mean average precision</i> (mAP) tertinggi sebesar 79.2%. Selain itu, skor <i>precision</i> (70,9%), <i>recall</i> (76,6%) dan <i>f1 score</i> (73,6%) yang seimbang, <i>average precision</i> (AP) per kelas yang tinggi (gigi sehat: 85,5%, karies awal: 66,9%, karies rampant: 91,6% dan karies sedang: 72,6%), waktu inferensi secepat 5.6 ms per gambar dan ukuran model sekecil 5 MB nya juga diungguli oleh YOLOv11 yang cocok untuk diimplementasikan ke berbagai macam perangkat untuk mendukung tenaga medis dalam mendeteksi karies gigi di daerah terpencil.
Keywords	Abstract
Dental caries, Object detection, YOLOv11, Faster R-CNN, RetinaNet	<i>Dental caries is a dental disease that is considered a global public health problem and requires detection that is friendly to remote areas. This study presents a comparison of the evaluation results of deep learning models for detecting dental caries from early to extensive levels using YOLOv11, Faster R-CNN and RetinaNet models. The dataset contains 1,036 images divided into 4 classes (healthy teeth, early caries, moderate caries and extensive caries). As a result, YOLOv11 produced the highest mean average precision (mAP) of 79.2%. In addition, balanced precision (70.9%), recall (76.6%) and f1 score (73.6%), high average precision (AP) per class (healthy teeth: 85.5%, early caries: 66.9%, extensive caries: 91.6% and moderate caries: 72.6%), a 5.6 ms inference time and 5 MB model size are featured by YOLOv11 which is suitable to be implemented into various devices to support medical personnel in detecting dental caries in remote areas.</i>

A. Pendahuluan

Kesehatan gigi dan mulut merupakan bagian penting dari kesehatan tubuh secara keseluruhan. Karies gigi merupakan sebuah penyakit pada gigi yang dianggap sebagai masalah kesehatan masyarakat global yang signifikan [1]. Namun mendeteksi karies gigi sejak dini sebelum memburuk untuk mencegah karies gigi masih menjadi tantangan. Berdasarkan Survei Kesehatan Indonesia (SKI) pada tahun 2023 di Indonesia, anak-anak di umur 5-9 tahun sebanyak 49,9% memiliki permasalahan gigi berlubang, rusak atau sakit dan masalah gigi tersebut banyak juga ditemukan di pedesaan dengan angka 46,2% dari jumlah responden sebanyak 344.735. Angka yang cukup tinggi ini tidak didukung dengan tenaga medis yang memadai, baru 66,1% dari jumlah responden sebanyak 17.928 dari warga pedesaan yang menerima perawatan dari tenaga medis gigi [2].

Kesehatan gigi yang buruk dapat menyebabkan kualitas hidup yang negatif dan meningkatkan resiko terkena penyakit-penyakit kronis. Seperti contohnya, rasa tidak nyaman yang terjadi akibat gigi yang terinfeksi dapat mempengaruhi asupan makanan dan juga nutrisi. Selain itu, bakteri yang berhubungan dengan karang gigi kronis telah dikaitkan dengan diabetes dan penyakit kardiovaskular. Tidak hanya secara kesehatan, tetapi kesehatan gigi yang buruk dapat mempengaruhi kesehatan mental, seperti malu dalam bersenyum, berbicara atau/dan makan [3][4].

Minimnya literasi yang dimiliki orang tua terhadap kesehatan gigi anak, juga pelayanan kesehatan yang sulit diakses pada daerah-daerah terpencil berpengaruh dalam mendiagnosa dan memberikan perawatan yang tepat pada kesehatan gigi anak. Hal ini dapat memperburuk kondisi kesehatan secara umum serta meningkatkan biaya pengobatan di kemudian hari. Karies yang lama didiamkan dan tidak dirawat atau dicegah akan mengakibatkan terkikisnya gigi sehingga terbentuknya lubang pada gigi atau biasa yang dikenal sebagai gigi berlubang [5].

Ada berbagai macam cara untuk mendeteksi karies gigi, seperti *visual inspection*, *radiograf bitewing*, *digital imaging fiberoptic transillumination*, teknik *fluorescence-based*, dan juga *cone-beam computed tomography* (CBCT). Salah satu cara yang paling umum digunakan oleh para tenaga medis dalam mendeteksi karies gigi adalah dengan cara *visual inspection* dan *radiograf bitewing*. Namun cara-cara tersebut memiliki limitasi seperti diperlukannya biaya tambahan untuk perangkat yang digunakan [6] atau perlunya foto gigi yang dimana perlu biaya sebelum bisa ditindak lebih lanjut.

Dalam beberapa tahun terakhir, kemajuan teknologi khususnya di *artificial intelligence* dan *machine learning* telah membuka peluang baru dalam mendukung bidang kesehatan, termasuk dalam deteksi penyakit melalui radiograf, fotograf, atau pindaian tiga dimensi yang akurat dan konsisten [6].

Salah satu cabang *machine learning*, yaitu *computer vision* merupakan cabang yang akan dimanfaatkan untuk mendeteksi penyakit melalui *object detection*. Sehingga dibutuhkan sebuah model untuk menjalankan tugas tersebut dan untuk menciptakan sebuah model *machine learning* yang dapat digunakan untuk mendeteksi karies gigi dibutuhkan sebuah dataset yang akan digunakan oleh arsitektur untuk melatih model tersebut sehingga model dapat mendeteksi dengan akurat.

Deep learning menjadi pendekatan yang banyak digunakan karena kelebihanannya yang dapat mengekstraksi fitur secara otomatis melalui arsitektur

jaringan saraf tiruan yang kompleks. Model-modelnya antara lain, seperti Faster R-CNN, RetinaNet, dan YOLO, banyak digunakan untuk melakukan tugas-tugas objek deteksi, terutama dalam bidang kesehatan.

Pada tahun 2024, dilakukan sebuah penelitian menggunakan internal dataset yang digunakan oleh pengembang aplikasi pada penelitian sebelumnya untuk mendeteksi karies gigi anak kecil, dengan model berbasis *artificial intelligence* mendapatkan akurasi yang tinggi di angka 97.2%. Angka ini hasilnya tidak jauh beda dari hasil yang dicapai oleh pengembang aplikasi. Sehingga diusulkan untuk penelitian menggunakan sampel gambar dari dataset yang berbeda untuk pengembangan modelnya [7].

Selain itu, terdapat sebuah penelitian yang mendeteksi karies gigi dengan menggunakan *deep learning*. Dalam penelitiannya, penulis menggunakan 4 *deep learning* arsitektur dengan hasil tertinggi dicapai oleh arsitektur VGG16 dengan skor *precision* di angka 95% dan 100%, juga skor *recall*nya di angka 97% dan 99% pada non-karies dan karies secara berurutan, namun peneliti mengusulkan untuk menggunakan data yang lebih luas lagi dari berbagai sumber daripada menggunakan data dari 1 institusi tertentu, selain itu juga training dilakukan pada model secara langsung dengan arsitektur yang berbeda untuk dapat melihat performa yang berbeda [8].

Sedangkan dari penelitian dari Anil, et. al. mengulas berbagai macam metode untuk mendeteksi karies gigi, salah satunya menggunakan algoritma *machine learning* yaitu *support vector machines* (SVM), namun SVM memiliki keterbatasan yaitu perlunya dataset yang banyak dan beragam untuk dapat menghasilkan akurasi yang sesuai dengan harapan, sehingga untuk menggunakan metode ini perlu biaya yang mahal dan memakan banyak waktu [6].


Sehingga penelitian ini diusulkan memanfaatkan model *deep learning* untuk dapat mendeteksi dini karies gigi yang tidak hanya khusus anak kecil, tetapi juga dapat mendeteksi karies gigi pada orang dewasa dengan menggunakan metode *visual inspection* sebagai salah satu metode yang paling umum digunakan oleh tenaga medis dan dapat mendapatkan hasil tanpa perlunya biaya tambahan apapun seperti melakukan foto gigi.

Dengan memanfaatkan *deep learning* untuk mendeteksi karies gigi, diharapkan kesehatan gigi pada anak-anak, maupun orang dewasa sekalipun meningkat secara keseluruhan, memudahkan masyarakat dalam mendeteksi karies gigi yang dapat dilakukan dari rumah sekalipun dan model dapat digunakan oleh pihak kesehatan untuk meningkatkan kesehatan gigi dengan lebih efektif di masa yang akan datang.

B. Metode Penelitian

Penelitian ini menggunakan tiga model *deep learning* yang digunakan untuk mendeteksi karies gigi, yaitu YOLOv11, RetinaNet, dan Faster R-CNN. Ketiga model ini akan dikomparasikan untuk menentukan model yang tepat dalam mendeteksi karies gigi. Seperti yang terlihat pada gambar 1, penelitian akan dimulai dengan *data acquisition*, dilanjutkan dengan *data preprocessing*, dan melakukan *data splitting* dengan *stratified k-fold cross validation*, selanjutnya dilakukan *feature extraction* untuk mengambil fitur penting dari gambar yang akan digunakan untuk proses


deteksi objek. Dari data-data yang sudah didapat maka digunakan oleh model untuk melatih model *deep learning* yang performanya akan dievaluasi berdasarkan metrik.



Gambar 1. Desain Penelitian

1. Data Acquisition

Pengumpulan data yang dilakukan dengan cara mengunduh dataset yang telah dipublikasikan di internet [9]. Dataset yang berasal dari internet cenderung memiliki variasi yang lebih beragam, sehingga dapat memperkuat model. Dataset yang didapat sudah termasuk dengan label di dalamnya. Jumlah gambar yang didapat sebanyak 1.242 gambar dengan sampel gambar gigi sehat pada bagian kiri dan gigi karies pada bagian kanan seperti yang terlihat pada gambar 2.




Gambar 2. Sampel Gambar Gigi

2. Data Cleaning dan Data Annotation

Dataset akan melalui proses pembersihan untuk menghapus gambar yang kurang relevan dengan penelitian. Setelah dibersihkan, dataset diberi label berdasarkan 4 kelas yang sesuai dengan konten dari gambar sehingga 1 gambar dapat memiliki 1 atau lebih kelas seperti yang terlihat pada gambar 3. Jumlah anotasi setiap kelas berada pada tabel 1.

Tabel 1. Kelas Karies Gigi

No	Kelas	Jumlah Label
1	Gigi Sehat	3,649
2	Karies Awal	3,330
3	Karies Sedang	2,685
4	Karies Rampan	2,774

**Gambar 3.** Sampel Gambar yang Dianotasi

Jumlah label pada masing-masing kelas tidak memiliki perbedaan yang cukup signifikan. Untuk dapat mengatasi ketidakseimbangan jumlah label kelas, dilakukan teknik undersampling, yaitu mengurangi jumlah label pada dataset. Sehingga kelas gigi sehat, karies awal, dan karies rampan akan melakukan pengurangan sampai kurang lebih sejumlah 2.600, mengikuti jumlah label pada karies sedang.

3. Data Preprocessing

Data selanjutnya melalui *preprocessing* dengan di-*resize* menjadi 640x640 pixels, teknik ini cukup populer karena dapat menurunkan komputasi dan memenuhi persyaratan input model, dimana *input* memiliki ukuran gambar yang sama. Selain itu juga, kontras gambar ditingkatkan untuk menajamkan gambar agar model dapat lebih jelas mendeteksi saat proses *training* model [10] seperti yang terlihat pada gambar 4.

**Gambar 4.** Sampel Gambar yang Melalui *Preprocessing*

4. Data Splitting


Data splitting dilakukan dengan menggunakan metode *stratified k-fold cross validation* untuk memastikan setiap fold memiliki jumlah distribusi kelas yang sama seperti dataset yang asli [11]. Metode ini sangat penting untuk menangani masalah dataset yang tidak seimbang. Dalam *stratified k-fold* dengan 5 fold, maka data akan dibagi menjadi 5 subset yang memiliki proporsi kelas yang seimbang.

5. Model Deep Learning

Salah satu subbidang dari machine learning (ML) disebut deep learning (DL). Kemampuan DL untuk mengekstrak fitur tingkat tinggi dari data input mentah adalah salah satu keunggulan utamanya [12]. Setelah mendapatkan dataset dari proses-proses yang telah dilakukan, ResNet50 akan dimanfaatkan untuk *feature extraction* yang akan digunakan oleh setiap model *deep learning* untuk melakukan tugas *object detection* yaitu Faster R-CNN, RetinaNet, dan YOLOv11.

a. Faster R-CNN


Sebelum adanya Faster R-CNN, algoritma ini dimulai dari R-CNN, yaitu algoritma satu tahap yang mengubah object detection menjadi masalah regresi. Semua algoritma dua tahap selanjutnya dipengaruhi oleh R-CNN, yang juga membantu algoritma deteksi objek berbasis CNN secara progresif mendapatkan daya tarik. Selanjutnya dibentuk Fast R-CNN berdasarkan R-CNN, yang menyederhanakan lapisan spatial pyramid pooling (SPP) ke lapisan pengumpulan *region of interest* (ROI) berdasarkan SPP-Net, dan menguraikan keluaran lapisan yang terhubung penuh menjadi (SVD) untuk memperoleh dua vektor keluaran: skor klasifikasi *softmax* dan regresi jendela dari persegi panjang pembatas *bounding box*. Perbaikan metode ini menggabungkan masalah klasifikasi dengan masalah regresi kotak pembatas. Selanjutnya dibentuk Faster R-CNN, dengan menggunakan Fast R-CNN untuk menggantikan algoritma *selective search* yang ada di Fast R-CNN yang memakan waktu dan tidak efisien. RPN dapat menggunakan jaringan saraf untuk mempelajari strateginya sendiri dalam menghasilkan proposal wilayah dan memanfaatkan peta fitur sepenuhnya [13]. Seperti yang terlihat pada gambar 5, dalam arsitektur Faster R-CNN, *convolutional layer* adalah jaringan saraf *convolutional* dan berfungsi sebagai blok ekstraksi fiturnya [14].



Gambar 5. Arsitektur Faster R-CNN

b. RetinaNet


Tiga komponen utama dalam RetinaNet adalah *backbone network* untuk *feature extraction*, *feature pyramid networks* (FPN) dan subjaringan klasifikasi dan regresi. Seperti yang pada gambar 6 untuk mendapatkan hasil deteksi, karakteristik gambar pertama-tama diambil oleh backbone, yang kemudian disusun ulang dalam FPN, dan kemudian diberikan ke subjaringan klasifikasi dan regresi [15].



Gambar 6. Arsitektur RetinaNet

c. You Only Look Once (YOLO)

Arsitektur YOLO terdiri dari tiga komponen fundamental. Pertama, *backbone* bertindak sebagai pengekstrak fitur utama, mengubah data gambar yang belum diproses menjadi peta fitur multi-skala menggunakan jaringan saraf *convolutional*. Kedua, dengan menggunakan lapisan khusus untuk menggabungkan dan meningkatkan representasi fitur pada berbagai skala, komponen leher berfungsi sebagai tahap pemrosesan perantara. Ketiga, komponen kepala berfungsi sebagai mekanisme prediksi, menggunakan peta fitur yang telah ditingkatkan untuk menghasilkan output akhir untuk klasifikasi dan lokalisasi objek. Pada gambar 7 terdapat 3 kunci dari arsitektur YOLOv11, C3K2 yang mengindikasikan ukuran kernal yang lebih kecil sehingga berkontribusi untuk proses yang lebih cepat dan mempertahankan performanya, C2PSA yang meningkatkan perhatian spasial dalam peta fitur. Model ini lebih mampu berkonsentrasi pada area yang signifikan pada gambar karena mekanisme perhatian spasial ini. Blok C2PSA memungkinkan YOLOv11 untuk fokus pada wilayah tertentu yang diminati dengan menggabungkan informasi secara spasial, yang dapat meningkatkan akurasi deteksi untuk objek dengan ukuran dan lokasi yang berbeda [16].



Gambar 7. Arsitektur YOLOv11**6. Pengujian Metode dan Evaluasi Hasil**

Masing-masing model akan menghasilkan hasil *precision*, *recall*, *f1 score* dan metrik evaluasi lainnya *mean average precision* (mAP) yang akan digunakan untuk dijadikan sebagai bahan perbandingan antara masing-masing model *object detection* [17]. *Precision* adalah metrik yang menunjukkan kemungkinan bahwa data memang positif. *Sensitivity*, nama lain dari *recall*, adalah metrik yang digunakan untuk mengevaluasi kapasitas tes dalam mendeteksi hasil positif yang sebenarnya. Hal ini dihitung dengan membagi jumlah total kejadian positif yang sebenarnya dengan jumlah prediksi positif yang benar. Dengan menghitung rata-rata, akurasi dan *sensitivity/recall* digabungkan untuk mendapatkan *f1 score* [18]. mAP merupakan sebuah metrik yang digunakan untuk menilai performa *precision-recall* dari model *object detection*. Untuk menghitung mAP, terlebih dahulu menghitung *average precision* (AP) dari setiap kategorinya [19].

$$Precision = \frac{TP}{TP+FP} \quad (1)$$

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

$$F1\ Score = \frac{TP}{TP + \frac{1}{2}(FP+FN)} \quad (3)$$

$$AP = \sum_n (R_n - R_{n-1}) P_n \quad (4)$$


$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (5)$$

Dimana P_n dan R_n adalah *precision* dan *recall* pada ambang batas ke- n . N adalah jumlah kelas, dalam hal ini, satu kelas untuk deteksi karies gigi.

C. Hasil dan Pembahasan

Dalam penelitian ini, perangkat yang digunakan untuk melatih model *deep learning* Faster R-CNN, RetinaNet, dan YOLOv11 adalah sebuah laptop yang dilengkapi dengan OS Windows 11, AMD Ryzen 7 5800H, RAM sebesar 16 gb dan kartu grafis NVIDIA RTX 3050 Ti. Implementasi model *deep learning* menggunakan framework PyTorch untuk YOLOv11 dan Detectron2 untuk Faster R-CNN dan RetinaNet.


YOLOv11, Faster R-CNN dan RetinaNet menggunakan konfigurasi *batch size* sebesar 4 dan *learning rate* sekecil 0.001. YOLOv11 dilatih dengan 25 epoch, Faster R-CNN dan RetinaNet dilatih dengan 10.350 iterasi yang ekuivalen atau setara dengan 25 epoch. Pada Gambar 8, 9, dan 10 terlihat hasil prediksi yang dilakukan oleh masing-masing model yaitu RetinaNet, Faster R-CNN, dan YOLOv11 secara berurutan.



Gambar 8. Hasil Prediksi dari RetinaNet



Gambar 9. Hasil Prediksi dari Faster R-CNN



Gambar 10. Hasil Prediksi dari YOLOv11

Hasil komparasi dari evaluasi model YOLOv11, RetinaNet, dan Faster R-CNN untuk mendeteksi karies gigi. Pada Tabel 2, terlihat hasil sudah diringkas dan dianalisis. Dataset yang digunakan dipastikan tidak memiliki bias terhadap suatu model dalam proses penelitian. Gambar yang digunakan sebanyak 1.036 dengan jumlah kelas sebanyak kurang lebih masing-masingnya 2.000 dalam setiap fold.

Tabel 2. Ringkasan Hasil Model

Metrik	Faster R-CNN	RetinaNet	YOLOv11
Precision	61,0%	65,7%	70,9%
Recall	85,5%	96,9%	76,6%
F1 Score	71,2%	78,3%	73,6%
mAP	66,0%	65,7%	79,2%
AP Gigi Sehat	39,7%	41,3%	85,5%
AP Karies Awal	35,6%	37,4%	66,9%
AP Karies Rampan	51,4%	53,7%	91,6%
AP Karies Sedang	47,2%	45,3%	72,6%
Inference Time	92,1 ms	81,7 ms	5,6 ms
Model Size	322 MB	283 MB	5 MB

YOLOv11 menunjukkan hasil mean average precision (mAP) yang tinggi lebih daripada Faster R-CNN dan RetinaNet sebesar 79,2% dan average precision dari masing-masing kelas nya, seperti gigi sehat (85,5%), karies awal (66,9%), karies rampan (91,6%), dan karies sedang (72,6%) juga lebih tinggi. Inference yang cepat, secepat 5,6 ms dan ukuran model yang hanya 5 MB sangat cocok digunakan untuk aplikasi-aplikasi yang membutuhkan deteksi secara real-time dan dapat diaplikasikan di perangkat dengan sistem kecil sekalipun.

Sebagai perbandingan, Faster R-CNN (66,0%) memiliki mAP kedua tertinggi dengan perbedaan hanya 0.3% dengan RetinaNet (65,7%). Namun, 3 AP dari masing-masing kelas yang dihasilkan oleh Faster R-CNN (gigi sehat: 39,7%, karies

awal: 35,6%, karies rampan: 51,4%, dan karies sedang: 47,2%) lebih rendah daripada RetinaNet (gigi sehat: 41,3%, karies awal: 37,4%, karies rampan: 53,7%, dan karies sedang: 45,3%), yaitu gigi sehat, karies awal, dan karies rampan. Namun, Faster R-CNN dan RetinaNet memiliki inference time (Faster R-CNN: 92,1 ms dan RetinaNet: 81,7%) dan ukuran model yang besar (Faster R-CNN: 322 MB dan RetinaNet: 283 MB) sehingga perangkat yang dapat menggunakan kedua model ini sangat terbatas dan memakan waktu yang cukup lama untuk mendeteksi.

Pada penelitian serupa sebelumnya, karies gigi dibagi menjadi empat kelas, yaitu kelas suara atau *no surface change*, kelas awal atau *visually non-cavitated*, kelas sedang dan kelas rampan. Penelitian dilakukan dengan membandingkan dua klasifikasi, yang pertama antara gigi non-karies (gabungan antara kelas suara dan kelas awal) dan karies (gabungan antara kelas sedang dan rampan), juga membandingkan kelas suara dan kelas awal. Empat model digunakan untuk mendeteksi karies gigi, yaitu YOLOv3, Faster R-CNN, RetinaNet, dan SSD. Dalam evaluasi model klasifikasi pertama, skor *precision* tertinggi diraih oleh SSD dengan 97.1% dan terendah oleh YOLOv3 dengan 65,3%, namun kedua model mendapatkan skor *precision* rendah saat evaluasi model klasifikasi kedua, yaitu 0% dan 49.7% secara berurutan, tertinggi diraih oleh Faster R-CNN sebesar 61,5% [14]. Secara data menunjukkan bahwa model kurang baik dalam mendeteksi kelas suara dan kelas awal.

Lain halnya, YOLOv11 dalam penelitian ini menunjukkan skor *precision* tertinggi sebesar 70,9% dalam mendeteksi semua kelas pada karies gigi. Walaupun *recall* lebih rendah dari model yang lain hanya sebesar 76,6% dan *f1 score* sebesar (73,6%), evaluasi yang seimbang dari YOLOv11 dapat memberikan prediksi yang cenderung lebih pasti dan cepat. Jika dibandingkan dengan RetinaNet yang hasil *precision* (65,7%) yang rendah dan *recall* (96,9%) yang tinggi dan *f1 score* sebesar 78,3% akan cenderung menghasilkan deteksi banyak objek sekaligus, tetapi akan terjadi salah prediksi.

D. Simpulan

Penelitian ini membandingkan YOLOv11, Faster R-CNN dan RetinaNet untuk mendeteksi karies gigi dari tingkat awal hingga rampan. Ketiga model dapat mendeteksi karies gigi dengan menampilkan *bounding box* pada gigi dan memprediksi tingkat karies gigi. YOLOv11 mengungguli dengan mAP 12,1% lebih tinggi dari Faster R-CNN dan 12.4% lebih tinggi dari RetinaNet, dan AP per kelas yang lebih tinggi. Selain itu, dapat mendeteksi 15 kali lebih cepat dan ukuran yang 47 kali lebih kecil dari model-model yang dibandingkan, sehingga dapat diaplikasikan ke berbagai perangkat dan digunakan untuk mendeteksi karies dengan *real-time*. Berdasarkan hasil skor *precision*, *recall*, dan *f1 score* yang diperoleh YOLOv11, model tersebut cocok untuk deteksi yang cepat dengan hasil yang lebih pasti. Namun jika tujuan dari pendeteksi ini adalah mendeteksi karies gigi dengan banyak dalam satu waktu dan tidak masalah dengan prediksi yang terkadang salah, dapat memilih model RetinaNet.

Pada penelitian selanjutnya diharapkan dapat berfokus untuk mengintegrasikan model ke sebuah aplikasi *mobile* untuk dapat membantu tenaga medis dalam mendeteksi karies gigi pada daerah-daerah yang terpencil.

E. Referensi

- [1] K. Tzimas, M. Antoniadou, T. Varzakas, and C. Voidarou, "Plant-Derived Compounds: A Promising Tool for Dental Caries Prevention," Jun. 01, 2024, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/cimb46060315.
- [2] B. K. P. K. Kemenkes, "Survei Kesehatan Indonesia 2023 Dalam Angka," 2023.
- [3] P. Romandini, C. Marruganti, W. G. Romandini, M. Sanz, S. Grandini, and M. Romandini, "Are periodontitis and dental caries associated? A systematic review with meta-analyses," Feb. 01, 2024, *John Wiley and Sons Inc.* doi: 10.1111/jcpe.13910.
- [4] S. A. B. Rad, M. E. Oliveira, A. Maklennan, P. Castiglia, and G. Campus, "Higher prevalence of dental caries and periodontal problems among refugees: A scoping review," 2023, *University of Edinburgh*. doi: 10.7189/JOGH.13.04111.
- [5] M. Sarvarbek, "TYPES OF CARIES," in *Conference On The Role And Importance Of Science In The Modern World*, 2024, pp. 400–401.
- [6] S. Anil, P. Porwal, and A. Porwal, "Transforming Dental Caries Diagnosis Through Artificial Intelligence-Based Techniques," *Cureus*, Jul. 2023, doi: 10.7759/cureus.41694.
- [7] J. Schwarzmaier *et al.*, "Validation of an Artificial Intelligence-Based Model for Early Childhood Caries Detection in Dental Photographs," *J Clin Med*, vol. 13, no. 17, p. 5215, Sep. 2024, doi: 10.3390/jcm13175215.
- [8] F. Khan, M. Raza, N. Ullah, K. Khisrow, I. Ali, and A. Jamil, "Dental caries and non caries detection using deep learning," *Int J Health Sci (Qassim)*, vol. 7, no. S1, pp. 790–804, May 2023, doi: 10.53730/ijhs.v7ns1.14277.
- [9] C. Geass, "Final Fronts + Crowns Dataset," Jun. 2024, *Roboflow*. [Online]. Available: <https://universe.roboflow.com/code-geass/final-fronts-crowns>
- [10] H. Liu, X. Ma, Y. Yu, L. Wang, and L. Hao, "Application of Deep Learning-Based Object Detection Techniques in Fish Aquaculture: A Review," *J Mar Sci Eng*, vol. 11, no. 4, Apr. 2023, doi: 10.3390/jmse11040867.
- [11] S. Prusty, S. Patnaik, and S. K. Dash, "SKCV: Stratified K-fold cross-validation on ML classifiers for predicting cervical cancer," *Frontiers in Nanotechnology*, vol. 4, Aug. 2022, doi: 10.3389/fnano.2022.972421.
- [12] K. Choudhary *et al.*, "Recent advances and applications of deep learning methods in materials science," *NPJ Comput Mater*, vol. 8, no. 1, Dec. 2022, doi: 10.1038/s41524-022-00734-6.
- [13] W. Li, "Analysis of Object Detection Performance Based on Faster R-CNN," in *Journal of Physics: Conference Series*, IOP Publishing Ltd, Mar. 2021. doi: 10.1088/1742-6596/1827/1/012085.
- [14] M. T. G. Thanh, N. Van Toan, V. T. N. Ngoc, N. T. Tra, C. N. Giap, and D. M. Nguyen, "Deep Learning Application in Dental Caries Detection Using Intraoral Photos Taken by Smartphones," *Applied Sciences (Switzerland)*, vol. 12, no. 11, Jun. 2022, doi: 10.3390/app12115504.
- [15] L. Zhang *et al.*, "Vehicle Object Detection Based on Improved RetinaNet," in *Journal of Physics: Conference Series*, IOP Publishing Ltd, Feb. 2021. doi: 10.1088/1742-6596/1757/1/012070.

- [16] R. Khanam and M. Hussain, "YOLOv11: An Overview of the Key Architectural Enhancements," Oct. 2024, [Online]. Available: <http://arxiv.org/abs/2410.17725>
- [17] B. Mirzaei, H. Nezamabadi-pour, A. Raoof, and R. Derakhshani, "Small Object Detection and Tracking: A Comprehensive Review," *Sensors*, vol. 23, no. 15, Aug. 2023, doi: 10.3390/s23156887.
- [18] S. A. Hasanah, A. A. Pravitasari, A. S. Abdullah, I. N. Yulita, and M. H. Asnawi, "A Deep Learning Review of ResNet Architecture for Lung Disease Identification in CXR Image," *Applied Sciences (Switzerland)*, vol. 13, no. 24, Dec. 2023, doi: 10.3390/app132413111.
- [19] P. Vilcapoma *et al.*, "Comparison of Faster R-CNN, YOLO, and SSD for Third Molar Angle Detection in Dental Panoramic X-rays," *Sensors*, vol. 24, no. 18, p. 6053, Sep. 2024, doi: 10.3390/s24186053.