

DETEKSI PENYAKIT GIGI PADA CITRA DENTAL OPG X-RAYS MENGUNAKAN ARSITEKTUR EFFICIENTDET

Jesen Ong, Muhammad Rizky Pribadi

Informatika, Universitas Multi Data Palembang

Jalan Rajawali No.14 Palembang, Indonesia

jesenong_2226250084@mhs.mdp.ac.id

ABSTRAK

Penelitian ini memanfaatkan deep learning untuk membantu diagnosis penyakit gigi dari citra radiografi panoramik Orthopantomogram (OPG) mengingat tingginya prevalensi masalah gigi dan mulut serta rendahnya akses perawatan (WHO, 2022; Riskesdas, 2018; Survei Kesehatan Indonesia, 2023). Analisis OPG memiliki kompleksitas visual seperti distorsi, tumpang tindih struktur, variasi kontras, serta objek patologis berukuran kecil yang menyulitkan interpretasi secara konsisten. Penelitian ini bertujuan membandingkan kinerja EfficientDet-D2, EfficientDet-D3, dan EfficientDet-D4 dalam mendeteksi lima kelas penyakit, yaitu Caries, Infection, Impacted teeth, Fracture, dan Broken crown. Dataset publik Rahman dkk. (2024) diolah melalui Roboflow dan dibagi menjadi 134 citra latih (449 anotasi), 13 citra validasi (49 anotasi), dan 12 citra uji (28 anotasi). Ukuran input disesuaikan per varian (D2: 768, D3: 896, D4: 1024) dan model diinisialisasi menggunakan pretrained weights COCO. Evaluasi menggunakan mAP50. EfficientDet-D4 memperoleh mAP50 tertinggi pada validasi sebesar 0,800, sedangkan mAP50 terbaik pada data uji dicapai EfficientDet-D2 sebesar 0,714, diikuti EfficientDet-D4 sebesar 0,701 dan EfficientDet-D3 sebesar 0,622.

Kata kunci : *deep learning, deteksi objek, EfficientDet, mAP50, OPG, penyakit gigi*

1. PENDAHULUAN

Kesehatan merupakan salah satu faktor penting dalam menunjang kualitas hidup manusia. Di antara berbagai aspek kesehatan, kesehatan gigi dan mulut sering kali kurang diperhatikan, padahal berbagai penyakit seperti karies, gigi impaksi, infeksi, kerusakan mahkota maupun akar gigi, hingga fraktur dapat menimbulkan komplikasi serius jika tidak ditangani. WHO tahun 2022 melaporkan bahwa lebih dari 3,5 miliar orang mengalami penyakit gigi dan mulut, namun hanya sebagian kecil yang memperoleh penanganan medis. Data Riskesdas 2018 dan Survei Kesehatan Indonesia 2023 menunjukkan kondisi serupa di Indonesia, di mana prevalensi keluhan gigi dan mulut mencapai lebih dari 56 persen, tetapi kurang dari 11 persen yang mendapatkan perawatan tenaga medis. Kondisi ini menggambarkan adanya kebutuhan akan solusi diagnostik yang lebih cepat dan akurat agar penanganan dapat dilakukan lebih dini. Radiografi panoramik atau Orthopantomogram (OPG) merupakan salah satu alat diagnostik yang banyak digunakan untuk pemeriksaan awal kondisi gigi, karena mampu menampilkan gambaran menyeluruh struktur rahang dan gigi dalam satu citra. Namun, interpretasi citra OPG masih sangat bergantung pada keahlian dokter, sehingga rawan perbedaan interpretasi dan berpotensi menimbulkan keterlambatan diagnosis. Secara teknis, citra OPG memiliki tantangan seperti distorsi kurvatur rahang, overlap struktur gigi, perbedaan ketebalan jaringan, kualitas kontras yang bervariasi, serta ukuran objek patologis yang sering kali kecil, misalnya caries dan fraktur. Kompleksitas visual tersebut membuat metode manual maupun model deteksi objek yang kurang sensitif terhadap variasi skala sulit bekerja secara

konsisten, terutama ketika target berukuran kecil dan berada pada area dengan detail yang saling tumpang tindih. Penerapan AI pada radiograf panoramik juga semakin berkembang untuk membantu alur diagnosis dan deteksi berbagai kondisi dental, sehingga memperkuat relevansi penggunaan pendekatan otomatis berbasis deep learning pada citra OPG [1]. Seiring perkembangan teknologi, kecerdasan buatan dan deep learning mulai dimanfaatkan dalam analisis citra medis, dan Convolutional Neural Networks telah menunjukkan hasil yang menjanjikan. Mahesh dkk. [2] menggunakan EfficientNetB7 pada klasifikasi kanker payudara dan mencapai akurasi 98,29 persen. Huang dan Liu [3] menggunakan EfficientDet-D7 untuk pelacakan objek robot dan memperoleh akurasi 99,62 persen. Cao dkk. [4] menerapkan EfficientDet-D3 untuk deteksi malai gandum dan mencapai akurasi 95,30 persen. Dalam konteks medis, Karno dkk. [5] menggunakan EfficientNet-B7 untuk deteksi COVID-19, sedangkan Khushi dkk. [6] menunjukkan bahwa EfficientNet-B7 unggul dalam klasifikasi tumor otak. Hasil-hasil tersebut menegaskan bahwa keluarga arsitektur EfficientNet dan EfficientDet memiliki potensi kuat untuk ekstraksi fitur dan penerapan pada skenario yang menuntut ketelitian tinggi, termasuk pada citra medis yang memiliki variasi visual kompleks.

Permasalahan yang dihadapi pada domain kedokteran gigi adalah bahwa penelitian terdahulu memang telah menunjukkan potensi penggunaan object detection, tetapi performa yang dicapai masih belum sepenuhnya memenuhi kebutuhan penerapan klinis. Razaghi dkk. [7] menggunakan YOLOv8 untuk deteksi penyakit gigi pada citra BiteWing dan OPG, namun nilai mAP yang diperoleh hanya 71,6 persen

meskipun nilai precision dan recall mencapai 90 persen. El Bagoury dkk. [8] menggunakan YOLOv5 pada citra OPG dan memperoleh mAP@0.5 sebesar 0,61 serta mAP@[0.5–0.95] sebesar 0,28. Thanathornwong dan Suebnukarn [9] menerapkan Faster-RCNN dan mendapatkan precision 0,81 dengan recall 0,80, sedangkan Wang dkk. [10] memodifikasi YOLOv8 sehingga mAP meningkat menjadi 86,7 persen, namun peningkatan tersebut masih belum mencapai akurasi ideal untuk digunakan dalam sistem klinis. Selain itu, studi pada radiograf panoramik juga menunjukkan bahwa pendekatan object detection seperti Faster R-CNN, YOLO, dan SSD telah banyak digunakan dan dibandingkan performanya pada konteks panoramik X-ray, sehingga menguatkan bahwa paradigma deteksi objek relevan untuk citra dental panoramik [11]. Dengan mempertimbangan hasil penelitian-penelitian tersebut, dapat disimpulkan bahwa masih terdapat celah riset berupa performa mAP yang belum optimal serta keterbatasan dalam menangani kompleksitas visual OPG secara menyeluruh, terutama pada target berukuran kecil dan variasi tampilan anatomis yang tinggi. Oleh karena itu, masih diperlukan arsitektur deteksi modern yang lebih adaptif serta mampu memadukan fitur multi-resolusi secara efektif agar deteksi lebih konsisten.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan membandingkan kinerja EfficientDet-D2, EfficientDet-D3, dan EfficientDet-D4 dalam mendeteksi lima kelas penyakit gigi pada citra OPG, yaitu 0 = Caries, 1 = Infection, 2 = Impacted teeth, 3 = Fracture, dan 4 = Broken crown. Tujuan perbandingan antar varian ini adalah memperoleh gambaran yang jelas mengenai pengaruh peningkatan skala model terhadap performa deteksi, sehingga dapat ditentukan varian yang paling sesuai untuk karakteristik citra OPG pada penelitian ini.

Rencana penyelesaian masalah dilakukan dengan memanfaatkan arsitektur EfficientDet yang menggabungkan EfficientNet sebagai feature extractor dan BiFPN untuk fusi fitur multi-skala. BiFPN memungkinkan weighted bidirectional feature fusion sehingga informasi dari berbagai resolusi dapat digabungkan secara lebih optimal untuk meningkatkan sensitivitas terhadap variasi skala objek. Menurut Tan dkk. [12], EfficientDet mengusulkan BiFPN dan compound scaling untuk meningkatkan akurasi sekaligus efisiensi pada deteksi objek. Selain itu, Yilmaz dan Navruz [13] menegaskan bahwa EfficientDet memberikan trade-off akurasi dan kecepatan yang baik dibanding YOLO, SSD, dan arsitektur lain. Dukungan tambahan dari Huang dan Liu [3] pada EfficientDet-D7 menunjukkan bahwa kerangka EfficientDet dapat mencapai performa tinggi pada tugas visual yang menuntut ketelitian, namun penelitian ini tidak berfokus pada varian terbesar tersebut. Secara spesifik, penelitian ini mengevaluasi EfficientDet-D2, EfficientDet-D3, dan EfficientDet-D4 untuk melihat dampak peningkatan skala model secara bertahap melalui konsep compound scaling

[12]. Fokus pada D2 hingga D4 dipilih agar studi tetap realistis dari sisi efisiensi komputasi sekaligus memungkinkan analisis komparatif yang jelas terhadap pengaruh kapasitas model terhadap kinerja deteksi pada citra OPG. Dengan demikian, penelitian ini diharapkan dapat meningkatkan konsistensi deteksi pada citra OPG dan berkontribusi pada pengembangan sistem Computer-Aided Diagnosis yang lebih akurat dan aplikatif dalam praktik klinis kedokteran gigi.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Berbagai penelitian menunjukkan bahwa pendekatan deep learning efektif untuk tugas klasifikasi maupun deteksi objek pada citra, baik pada domain umum maupun medis. Cao dkk. [4] menerapkan EfficientDet-D3 untuk identifikasi dan perhitungan jumlah maloklusi secara otomatis dan memperoleh akurasi perhitungan sebesar 95,30 persen, serta waktu deteksi yang cepat. Temuan tersebut menunjukkan bahwa varian EfficientDet tingkat menengah dapat memberikan performa deteksi yang kompetitif dan efisien, sehingga relevan dijadikan rujukan dalam penelitian yang berfokus pada varian EfficientDet-D2, EfficientDet-D3, dan EfficientDet-D4.

Pada penelitian klasifikasi berbasis CNN non EfficientNet-B7, Maylianti dkk. [14] membandingkan EfficientNet-B0 dan ResNet-50 untuk mendeteksi penyakit pada buah kakao dan melaporkan akurasi yang sama tinggi, yaitu 96 persen, dengan perbedaan karakteristik pada metrik precision dan recall. Rasjid dan Akbar [15] menerapkan arsitektur VGG16 untuk klasifikasi penyakit gigi seperti karies, periodontitis, dan gingivitis, namun hasil akurasi validasi yang diperoleh masih 77 persen sehingga menunjukkan perlunya pengembangan lebih lanjut. Lavenia dkk. [16] menggunakan CNN untuk klasifikasi pulpitis pada citra radiografi periapikal, dengan hasil akurasi tertinggi 98,75 persen melalui pengaturan optimizer dan jumlah epoch. Syaripudin dkk. [17] memanfaatkan ResNet50 untuk klasifikasi penyakit periodontal pada citra panoramik, tetapi hasilnya menunjukkan performa yang belum stabil dengan akurasi keseluruhan 56 persen dan kecenderungan bias antar kelas. Rangkaian penelitian tersebut mengindikasikan bahwa meskipun klasifikasi berbasis CNN telah banyak digunakan pada citra dental, performa dapat bervariasi tergantung karakteristik data dan konfigurasi model.

Pada pendekatan object detection untuk citra dental, Razaghi dkk. [7] menggunakan YOLOv8 untuk mendeteksi penyakit gigi pada citra BiteWing dan OPG dan memperoleh nilai mAP 71,6 persen dengan precision dan recall sebesar 90 persen. El Bagoury dkk. [8] menerapkan YOLOv5 pada citra OPG dan memperoleh mAP@0.5 sebesar 0,61 serta mAP@[0.5–0.95] sebesar 0,28, yang menunjukkan bahwa tantangan deteksi pada citra panoramik masih cukup besar. Selain itu, Thanathornwong dan

Suebnuarn [9] menggunakan Faster-RCNN dan melaporkan precision 0,81 serta recall 0,80. Hasil tersebut memperlihatkan bahwa metode deteksi objek pada citra dental telah menunjukkan potensi, namun performanya masih belum sepenuhnya optimal untuk kebutuhan klinis.

Secara keseluruhan, tinjauan penelitian terdahulu menunjukkan bahwa deteksi objek pada citra OPG masih menghadapi tantangan performa, sementara penggunaan EfficientDet varian menengah seperti D3 telah terbukti efektif pada berbagai tugas deteksi di domain lain. Oleh karena itu, penelitian ini berfokus pada evaluasi komparatif EfficientDet-D2, EfficientDet-D3, dan EfficientDet-D4 untuk mendeteksi lima kelas penyakit gigi pada citra OPG, sebagai upaya mengisi celah penelitian yang masih terbatas pada studi deteksi penyakit gigi menggunakan varian EfficientDet tersebut.

2.2. Radiografi Panoramik (OPG)

Radiografi panoramik, dikenal juga sebagai orthopantomography atau panoramic radiography, merupakan pemeriksaan radiografi ekstraoral yang menghasilkan satu citra dua dimensi dengan cakupan luas, meliputi lengkung gigi rahang atas-bawah beserta struktur maksilofasial penting di sekitarnya. Karena cakupannya yang komprehensif, radiografi panoramik sering digunakan sebagai pemeriksaan skrining di kedokteran gigi dan menjadi salah satu modalitas yang paling sering diresepkan untuk evaluasi umum kondisi gigi dan rahang [18].

Secara klinis, OPG bermanfaat karena dapat memberikan overview anatomi gigi dan tulang rahang dalam satu pengambilan, dengan biaya relatif rendah serta paparan radiasi yang umumnya lebih rendah dibanding pemeriksaan radiografi tertentu yang lebih detail [18].

Meski demikian, sebagai citra proyeksi 2D dengan cakupan luas, OPG juga memiliki karakteristik yang perlu diperhatikan untuk analisis: detail objek kecil bisa tampak samar, sebagian struktur dapat saling tumpang tindih, serta kualitas kontras dapat bervariasi antar pasien maupun antar perangkat. Variasi ini menjadi alasan mengapa analisis otomatis berbasis computer vision dan deep learning pada OPG perlu mempertimbangkan ketahanan model terhadap perubahan kualitas dan skala objek [19].

2.3. Dental Disease

Penyakit gigi atau dental disease mencakup berbagai kondisi patologis yang dapat diamati melalui pemeriksaan klinis maupun radiograf. Dalam penelitian ini, kategori yang dibahas meliputi caries, infection, impacted teeth, fracture, dan broken crown. Setiap kondisi memiliki karakteristik klinis dan tampilan radiograf yang berbeda, sehingga pemahaman konsep dasar ini penting sebagai landasan dalam proses deteksi pada citra OPG.

Caries merupakan kerusakan jaringan keras gigi akibat demineralisasi enamel dan dentin oleh asam

yang dihasilkan aktivitas bakteri. Pada citra radiograf, *caries* umumnya tampak sebagai area radiolusens atau lebih gelap pada permukaan gigi maupun bagian internal gigi, bergantung pada lokasi dan tingkat keparahannya. Impacted teeth adalah kondisi ketika gigi gagal erupsi secara normal, kondisi ini sering terjadi pada gigi molar ketiga atau wisdom teeth, penyebabnya dapat berupa keterbatasan ruang maupun posisi pertumbuhan gigi yang miring. Pada radiograf, kondisi ini terlihat sebagai gigi yang terperangkap di bawah jaringan gingiva atau berada pada posisi yang tidak semestinya.

Infection seperti abses dapat terlihat pada radiograf sebagai area radiolusens di sekitar akar gigi yang mengindikasikan peradangan, kerusakan jaringan periapikal, atau resorpsi tulang. Jika tidak ditangani, infeksi berpotensi berkembang dan menyebar ke jaringan sekitarnya. Sementara itu, fracture menggambarkan retakan atau patahan gigi yang dapat terjadi akibat trauma maupun tekanan oklusal berlebih. Pemeriksaan radiografi membantu mengidentifikasi lokasi fraktur dan memperkirakan tingkat keparahan sebagai dasar penentuan rencana perawatan. Adapun broken crown menunjukkan kerusakan berat pada mahkota gigi hingga sebagian struktur gigi hilang, kondisi ini sering berkaitan dengan fraktur atau caries yang luas, sehingga umumnya membutuhkan penanganan restoratif yang kompleks atau tindakan pencabutan [20].

2.4. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan arsitektur jaringan saraf yang dirancang khusus untuk data citra, dengan kemampuan mengekstraksi fitur spasial melalui operasi konvolusi. CNN mempelajari representasi fitur secara bertingkat: lapisan awal cenderung menangkap pola sederhana seperti tepi dan tekstur, sedangkan lapisan lebih dalam memodelkan pola yang lebih kompleks dan lebih dekat dengan konsep objek. Karakter ini membuat CNN menjadi fondasi utama berbagai metode deep learning pada pengolahan citra, termasuk citra medis.

Pada analisis radiograf gigi, CNN umum digunakan sebagai feature extractor baik untuk tugas klasifikasi (misalnya mengidentifikasi ada/tidaknya kelainan) maupun deteksi (menentukan lokasi kelainan). Survei di bidang radiograf gigi menunjukkan bahwa pendekatan deep learning berbasis CNN menjadi kerangka dominan karena kemampuannya menangani variasi visual citra dental dan belajar langsung dari data tanpa rekayasa fitur manual yang rumit [21].

2.5. EfficientDet


EfficientDet merupakan keluarga arsitektur deteksi objek (object detection) yang dirancang untuk mencapai keseimbangan antara akurasi dan efisiensi komputasi. Secara umum, sistem deteksi objek bertujuan memprediksi bounding box (lokasi) dan kelas objek pada citra. Dalam desain EfficientDet,

deteksi dilakukan dengan pendekatan one-stage detector yang memproduksi prediksi lokasi dan kelas secara langsung dengan arsitektur yang dioptimalkan agar efisien pada berbagai keterbatasan sumber daya [12].

Konsep penting pada EfficientDet adalah pemanfaatan representasi fitur multi-skala untuk mengakomodasi variasi ukuran objek serta mekanisme fusi fitur yang efektif. EfficientDet memperkenalkan fusi fitur bidirectional berbobot (weighted bidirectional feature fusion) melalui BiFPN untuk memperkaya informasi dari beberapa level resolusi, sehingga objek kecil maupun besar tetap memiliki peluang terdeteksi dengan baik. Selain itu, EfficientDet menggunakan strategi compound scaling untuk menskalakan komponen jaringan secara terkoordinasi sehingga efisiensi dan akurasi dapat ditingkatkan secara sistematis [12]. Secara praktis, karakter multi-skala dan fusi fitur ini relevan untuk citra OPG yang memuat objek dengan ukuran bervariasi dan detail kelainan yang bisa sangat kecil

3. METODE PENELITIAN

Dalam pelaksanaan penelitian ini, dilakukan perancangan metode secara sistematis untuk memastikan setiap tahap berjalan dengan terarah dan menghasilkan model deteksi yang optimal. Metodologi ini mencakup serangkaian langkah mulai dari studi literatur hingga pengujian hasil model. Tahapan metodologi penelitian secara umum dapat dilihat pada Gambar 1, yang menggambarkan alur penelitian dari awal hingga tahap pengujian.



Gambar 1. Tahapan Metodologi Penelitian

3.1. Studi Literatur

Tahapan awal penelitian diawali dengan melakukan studi literatur terhadap berbagai sumber ilmiah seperti jurnal, buku, dan publikasi akademik yang berkaitan dengan bidang computer vision, deep learning, dan analisis citra medis. Studi ini bertujuan untuk memahami teori dasar mengenai Convolutional Neural Networks (CNN), arsitektur EfficientNet, serta mekanisme kerja EfficientDet, termasuk penerapan object detection dalam domain medis. Selain itu, studi literatur juga mencakup penelitian terdahulu mengenai metode dan objek terkait.

3.2. Pengumpulan Dataset

Pada tahap ini digunakan dataset publik yang bersumber dari penelitian Rahman dkk. (2024) yang tersedia di platform Mendeley Data. Dataset tersebut berisi citra radiografi panoramik gigi atau Orthopantomography (OPG) yang pada publikasinya mencakup enam kelas, yaitu *Healthy Teeth*, *Caries*, *Impacted Teeth*, *Infection*, *Fractured Teeth*, dan *Broken-down Crown/Root (BDC/BDR)*. Namun, dalam penelitian ini kelas *Healthy Teeth* tidak digunakan, karena fokus penelitian diarahkan pada deteksi dan lokalisasi area patologis, sehingga proses pemodelan difokuskan pada lima kelas penyakit gigi, yaitu *Caries*, *Infection*, *Impacted Teeth*, *Fracture*, dan *Broken crown* (Rahman dkk., 2024).

Selanjutnya, dataset diunggah dan diolah menggunakan Roboflow untuk memudahkan manajemen data, penyesuaian label kelas, serta penyiapan format anotasi yang sesuai untuk pelatihan model deteksi objek. Tahap ini juga mencakup pengaturan struktur data dan pembagian dataset ke subset pelatihan, validasi, dan pengujian sesuai kebutuhan eksperimen. Sampel data terdapat pada Gambar 2.



Gambar 2. Sampel Data

3.3. Perancangan

Tahap perancangan dilakukan untuk menyusun rancangan eksperimen deteksi penyakit gigi pada citra OPG menggunakan arsitektur EfficientDet secara terstruktur. Perancangan ini mencakup pengaturan pembagian dataset, penentuan varian model yang digunakan, penyesuaian ukuran input citra, serta strategi inisialisasi bobot model agar proses pelatihan berjalan lebih stabil dan hasil deteksi dapat dibandingkan secara adil antar varian.

Pada rancangan pembagian dataset, data dipisahkan menjadi tiga subset, yaitu data latih, validasi, dan uji, sehingga proses pelatihan, pemantauan performa selama pelatihan, serta evaluasi akhir dilakukan pada data yang berbeda. Dataset yang digunakan terdiri dari 134 citra latih dengan 449 anotasi, 13 citra validasi dengan 49 anotasi, serta 12 citra uji dengan 28 anotasi. Pembagian ini ditetapkan untuk memastikan model belajar dari data latih, sementara performa dipantau pada data validasi dan dinilai secara final menggunakan data uji.

Selanjutnya, penelitian ini menggunakan tiga varian EfficientDet, yaitu EfficientDet-D2,

EfficientDet-D3, dan EfficientDet-D4. Untuk menyesuaikan karakteristik tiap varian dan mendukung deteksi objek pada berbagai skala, dilakukan penetapan resolusi input citra yang berbeda pada masing-masing model melalui proses resize. Ukuran input yang digunakan adalah 768 untuk EfficientDet-D2, 896 untuk EfficientDet-D3, dan 1024 untuk EfficientDet-D4. Pengaturan ini bertujuan untuk menjaga kesesuaian antara kapasitas model dan detail informasi visual yang diproses, sekaligus memungkinkan analisis komparatif terkait pengaruh peningkatan skala model dan resolusi input terhadap kualitas deteksi pada citra OPG.

Selain itu, untuk meningkatkan efektivitas pelatihan, setiap varian model diinisialisasi menggunakan bobot prelatih dari dataset COCO. Penggunaan pretrained weights dipilih karena bobot prelatih telah mempelajari fitur visual umum sehingga dapat membantu mempercepat konvergensi dan meningkatkan stabilitas pelatihan ketika diaplikasikan pada dataset OPG, terutama pada tahap awal pembelajaran parameter model.

3.4. Implementasi

Pada tahap ini dilakukan implementasi sistem deteksi penyakit gigi berbasis EfficientDet yang telah dirancang sebelumnya. Implementasi dilakukan menggunakan bahasa pemrograman Python dengan memanfaatkan framework dan pustaka deep learning untuk melatih model deteksi objek. Penelitian ini mengimplementasikan tiga varian model, yaitu EfficientDet-D2, EfficientDet-D3, dan EfficientDet-D4, yang masing-masing dilatih menggunakan ukuran input citra sesuai rancangan, yaitu 768 untuk EfficientDet-D2, 896 untuk EfficientDet-D3, dan 1024 untuk EfficientDet-D4. Setiap model diinisialisasi menggunakan pretrained weights dari dataset COCO untuk membantu mempercepat proses pelatihan serta meningkatkan stabilitas pembelajaran, karena model tidak memulai pelatihan dari kondisi bobot acak.

Selama proses pelatihan, dilakukan pemantauan terhadap nilai loss function dan performa deteksi pada data validasi untuk memastikan model mengalami peningkatan kinerja secara bertahap. Metrik evaluasi yang dipantau mencakup mean Average Precision (mAP) pada data validasi, sehingga proses pemilihan model dapat dilakukan secara objektif. Setelah pelatihan selesai, model dengan performa terbaik berdasarkan nilai mAP tertinggi disimpan dan digunakan pada tahap pengujian untuk memperoleh hasil evaluasi akhir.

Hasil implementasi model menghasilkan prediksi berupa bounding box dan label kelas pada citra radiografi panoramik gigi (OPG). Keluaran sistem difokuskan pada lima kelas penyakit gigi yang digunakan dalam penelitian ini, yaitu Caries, Infection, Impacted teeth, Fracture, dan Broken crown. Prediksi ini kemudian digunakan sebagai dasar untuk analisis kinerja model, baik secara keseluruhan maupun

berdasarkan masing-masing kelas pada tahap pengujian.

3.5. Pengujian

Tahap pengujian dilakukan untuk mengevaluasi performa model EfficientDet dalam mendeteksi penyakit gigi pada citra Dental OPG X-rays. Pengujian dilakukan pada data uji untuk mengukur kemampuan model dalam melakukan deteksi secara akurat terhadap kelas-kelas penyakit gigi yang digunakan dalam penelitian ini. Model yang diuji meliputi EfficientDet-D2, EfficientDet-D3, dan EfficientDet-D4, sehingga hasil pengujian juga digunakan untuk membandingkan kinerja antar varian model.

Evaluasi performa dilakukan menggunakan metrik Mean Average Precision pada ambang Intersection over Union (IoU) 0.50 atau mAP@0.50 (mAP50). IoU 0.50 digunakan untuk menentukan apakah sebuah prediksi dianggap benar, yaitu ketika area tumpang tindih antara bounding box prediksi dan bounding box ground truth mencapai minimal 50 persen. Metrik mAP50 menghitung nilai Average Precision (AP) untuk setiap kelas berdasarkan hubungan precision dan recall pada ambang IoU 0.50, kemudian dirata-ratakan untuk seluruh kelas objek (Akbari dkk., 2023). Semakin tinggi nilai mAP50 yang dihasilkan, semakin baik kemampuan model dalam mendeteksi dan mengklasifikasikan objek penyakit gigi. Perhitungan mAP dinyatakan pada Persamaan (2), yaitu rata-rata nilai AP dari seluruh kelas.

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \quad (2)$$

4. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil evaluasi kinerja tiga varian EfficientDet yang digunakan dalam penelitian, yaitu EfficientDet-D2, EfficientDet-D3, dan EfficientDet-D4. Evaluasi dilakukan menggunakan metrik mAP50 pada data validasi dan data uji. Metrik mAP50 digunakan untuk merepresentasikan kemampuan model dalam mendeteksi serta mengklasifikasikan objek penyakit gigi secara tepat pada ambang Intersection over Union (IoU) sebesar 0.50. Perbandingan nilai mAP50 pada data validasi dan data uji antar varian EfficientDet disajikan pada Tabel 1.

Tabel 1. Hasil mAP50 pada data validasi dan data uji

Varian model	mAP50 Validasi	mAP50 Uji
EfficientDet-D2	0.754	0.714
EfficientDet-D3	0.595	0.622
EfficientDet-D4	0.800	0.701

Berdasarkan Tabel 1, EfficientDet-D4 memperoleh nilai mAP50 tertinggi pada data validasi, yaitu sebesar 0.800, diikuti oleh EfficientDet-D2 dengan nilai 0.754 dan EfficientDet-D3 dengan nilai 0.595. Pada data uji, performa terbaik justru ditunjukkan oleh EfficientDet-D2 dengan nilai mAP50

sebesar 0.714, kemudian EfficientDet-D4 sebesar 0.701, dan EfficientDet-D3 sebesar 0.622. Perbedaan ini menunjukkan bahwa peningkatan kapasitas model tidak selalu menghasilkan peningkatan performa yang konsisten pada data yang tidak dilihat selama pelatihan.

EfficientDet-D3 menunjukkan performa terendah baik pada data validasi maupun data uji. Hal ini mengindikasikan bahwa konfigurasi D3 pada penelitian ini belum mampu mengekstraksi fitur yang cukup representatif untuk membedakan lima kelas penyakit gigi pada citra OPG secara optimal. Salah satu kemungkinan penyebabnya adalah keterbatasan kapasitas model dalam menangani kompleksitas visual OPG, khususnya pada objek berukuran kecil dan area yang memiliki overlap struktur gigi.

EfficientDet-D4 menampilkan performa yang sangat baik pada data validasi, namun mengalami penurunan pada data uji. Penurunan ini menunjukkan bahwa meskipun model dengan kapasitas lebih besar mampu mempelajari pola yang lebih kompleks pada data latih dan validasi, model tersebut menjadi lebih sensitif terhadap variasi data uji yang tidak pernah dilihat sebelumnya. Dengan kata lain, peningkatan skala model berpotensi meningkatkan kemampuan fitting terhadap data latih, namun tidak selalu diikuti oleh peningkatan kemampuan generalisasi.

Sebaliknya, EfficientDet-D2 menunjukkan performa yang relatif stabil, karena meskipun nilai mAP50 pada data validasi berada di bawah D4, model ini justru menghasilkan nilai tertinggi pada data uji. Hal ini mengindikasikan bahwa varian dengan kompleksitas yang lebih ringan mampu menjaga keseimbangan antara kemampuan mempelajari pola data dan kemampuan melakukan generalisasi terhadap data baru. Pada konteks citra OPG yang memiliki variasi visual tinggi dan jumlah data relatif terbatas, kondisi ini menjadi sangat penting agar model tidak hanya bekerja baik pada data latih, tetapi juga pada skenario nyata di lapangan.

Perbandingan antara hasil validasi dan hasil uji memperlihatkan pola yang berbeda pada masing-masing varian. EfficientDet-D2 mengalami penurunan moderat dari 0.754 menjadi 0.714, EfficientDet-D4 mengalami penurunan yang lebih besar dari 0.800 menjadi 0.701, sedangkan EfficientDet-D3 justru mengalami peningkatan dari 0.595 menjadi 0.622. Pola ini menegaskan bahwa evaluasi berbasis data validasi saja belum cukup untuk menentukan varian terbaik, karena tujuan utama penelitian adalah memperoleh performa yang stabil pada data uji sebagai representasi kemampuan generalisasi.

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa pemilihan varian EfficientDet perlu mempertimbangkan keseimbangan antara kapasitas model dan kemampuan generalisasi. Dalam konteks penelitian ini, EfficientDet-D2 dapat dinyatakan sebagai varian paling unggul berdasarkan performa pada data uji, sementara EfficientDet-D4 tetap menunjukkan potensi tinggi namun masih

memerlukan perhatian lebih pada aspek generalisasi sebelum diterapkan pada sistem Computer-Aided Diagnosis di lingkungan klinis.

5. KESIMPULAN DAN SARAN

Kesimpulan dari penelitian ini menunjukkan bahwa arsitektur EfficientDet mampu digunakan untuk mendeteksi penyakit gigi pada citra Dental OPG X-rays dengan performa yang cukup baik berdasarkan metrik mAP50, di mana EfficientDet-D4 memperoleh nilai tertinggi pada data validasi sebesar 0.800, sedangkan performa terbaik pada data uji dicapai oleh EfficientDet-D2 dengan mAP50 sebesar 0.714, diikuti EfficientDet-D4 sebesar 0.701 dan EfficientDet-D3 sebesar 0.622, sehingga dapat disimpulkan bahwa peningkatan skala model tidak selalu menghasilkan peningkatan performa yang konsisten pada data yang berbeda dan pemilihan varian perlu mempertimbangkan keseimbangan antara kapasitas model dan kemampuan generalisasi; untuk penelitian selanjutnya disarankan melakukan eksperimen menggunakan varian EfficientDet yang lebih tinggi serta memperbanyak jumlah dan variasi data agar model dapat mempelajari fitur yang lebih beragam dan berpotensi meningkatkan performa deteksi pada kondisi klinis yang lebih luas.

DAFTAR PUSTAKA

- [1] S. Mureşanu *et al.*, "Automating Dental Condition Detection on Panoramic Radiographs: Challenges, Pitfalls, and Opportunities," *Diagnostics*, vol. 14, no. 20, p. 2336, Oct. 2024, doi: 10.3390/diagnostics14202336.
- [2] T. R. Mahesh, S. B. Khan, K. K. Mishra, S. Alzahrani, and M. Alojail, "Enhancing diagnostic precision in breast cancer classification through EfficientNetB7 using advanced image augmentation and interpretation techniques," *Int J Imaging Syst Technol*, vol. 35, no. 1, Jan. 2025, doi: 10.1002/ima.70000.
- [3] Z. Huang and X. Liu, "Robot target tracking technology based on Efficient Detection D7 with gabor filter," in *2024 4th International Conference on Mobile Networks and Wireless Communications (ICMNWC)*, IEEE, Dec. 2024, pp. 1–5. doi: 10.1109/ICMNWC63764.2024.10871991.
- [4] L. Cao, X. Zhang, J. Pu, S. Xu, X. Cai, and Z. Li, "The field wheat count based on the Efficientdet algorithm," in *2020 IEEE 3rd International Conference on Information Systems and Computer Aided Education (ICISCAE)*, IEEE, Sep. 2020, pp. 557–561. doi: 10.1109/ICISCAE51034.2020.9236918.
- [5] A. S. B. Karno, D. Arif, and I. S. K. Wardhana, "Deteksi covid-19 image chest X-Ray dengan Convolutional Neural Network Efficient Net-B7," in *Seminar Nasional Teknologi Informasi dan Komunikasi STI&K (SeNTIK)*, Sep. 2021, pp. 23–28.

- [6] H. M. T. Khushi, T. Masood, A. Jaffar, M. Rashid, and S. Akram, "Improved multiclass brain tumor detection via customized pretrained EfficientNetB7 model," *IEEE Access*, vol. 11, pp. 117210–117230, 2023, doi: 10.1109/ACCESS.2023.3325883.
- [7] M. Razaghi, H. E. Komleh, F. Dehghani, and Z. Shahidi, "Innovative diagnosis of dental diseases using YOLO V8 deep learning model," in *2024 13th Iranian/3rd International Machine Vision and Image Processing Conference (MVIP)*, IEEE, Mar. 2024, pp. 1–5. doi: 10.1109/MVIP62238.2024.10491172.
- [8] M. El Bagoury *et al.*, "Dental disease detection based on CNN for panoramic dental radiographs," in *2023 Eleventh International Conference on Intelligent Computing and Information Systems (ICICIS)*, IEEE, Nov. 2023, pp. 530–535. doi: 10.1109/ICICIS58388.2023.10391205.
- [9] B. Thanathornwong and S. Suebnukarn, "Automatic detection of periodontal compromised teeth in digital panoramic radiographs using faster regional convolutional neural networks," *Imaging Sci Dent*, vol. 50, no. 2, p. 169, 2020, doi: 10.5624/isd.2020.50.2.169.
- [10] Q. Wang, X. Zhu, Z. Sun, B. Zhang, J. Yu, and S. Qian, "Optimized Yolov8 feature fusion algorithm for dental disease detection," *Comput Biol Med*, vol. 187, p. 109778, Mar. 2025, doi: 10.1016/j.compbiomed.2025.109778.
- [11] 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.
- [12] M. Tan, R. Pang, and Q. V. Le, "EfficientDet: Scalable and Efficient Object Detection," in *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, Jun. 2020, pp. 10778–10787. doi: 10.1109/CVPR42600.2020.01079.
- [13] E. N. Yilmaz and T. S. Navruz, "Real-time object detection: A comparative analysis of YOLO, SSD, and EfficientDet algorithms," in *2025 7th International Congress on Human-Computer Interaction, Optimization and Robotic Applications (ICHORA)*, IEEE, May 2025, pp. 1–9. doi: 10.1109/ICHORA65333.2025.11017287.
- [14] N. P. Maylianti, I. G. N. L. Wijayakusuma, and I. P. C. Arta Wiguna, "Comparison of EfficientNet-B0 and ResNet-50 for detecting diseases in cocoa fruit," *Journal of Applied Informatics and Computing*, vol. 9, no. 1, pp. 115–120, Jan. 2025, doi: 10.30871/jaic.v9i1.8868.
- [15] A. A. Rasjid and F. A. Akbar, "Penerapan deep learning arsitektur VGG16 untuk klasifikasi penyakit gigi," in *Seminar Nasional Informatika Bela Negara (SANTIKA)*, 2023, pp. 160–162.
- [16] F. Lavenia, C. M. Sidik Ramdani, and I. Hoerons, "Klasifikasi penyakit pulpitis pada citra radiografi periapikal menggunakan metode Convolutional Neural Network (CNN)," *Media Jurnal Informatika*, vol. 16, no. 1, p. 61, Jun. 2024, doi: 10.35194/mji.v16i1.4098.
- [17] D. Syaripudin, E. Yayat, J. Jayadi, and A. R. Raharja, "Klasifikasi penyakit periodontal pada citra panoramik gigi menggunakan deep learning berbasis ResNet50," *SisInfo*, vol. 7, no. 1, pp. 50–61, Feb. 2025, doi: 10.37278/sisinfo.v7i1.1063.
- [18] R. Izzetti, M. Nisi, G. Aringhieri, L. Crocetti, F. Graziani, and C. Nardi, "Basic Knowledge and New Advances in Panoramic Radiography Imaging Techniques: A Narrative Review on What Dentists and Radiologists Should Know," *Applied Sciences*, vol. 11, no. 17, p. 7858, Aug. 2021, doi: 10.3390/app11177858.
- [19] N. Anbiaee and P. Pahlavanzadeh, "Evaluation of Panoramic Radiography Diagnostic Accuracy in the Assessment of Interdental Alveolar Bone Loss Using CBCT," *Clin Exp Dent Res*, vol. 10, no. 6, Dec. 2024, doi: 10.1002/cre2.70042.
- [20] R. B. Rahman, S. A. Tanim, N. Alfaz, T. E. Shrestha, M. S. U. Miah, and M. F. Mridha, "A comprehensive dental dataset of six classes for deep learning based object detection study," *Data Brief*, vol. 57, p. 110970, Dec. 2024, doi: 10.1016/j.dib.2024.110970.
- [21] S. Bhat, G. K. Birajdar, and M. D. Patil, "A comprehensive survey of deep learning algorithms and applications in dental radiograph analysis," *Healthcare Analytics*, vol. 4, p. 100282, Dec. 2023, doi: 10.1016/j.health.2023.100282.