

RESEARCH ARTICLE

Klasifikasi Penyakit Periodontal Pada Citra Gigi Berwarna Menggunakan Arsitektur Berbasis *Convolutional Neural Network*

Thomhert Suprpto Siadari and Yuli Sun Hariyani

Fakultas Teknik Elektro, Universitas Telkom, Bandung, 40257, Jawa Barat, Indonesia
*Corresponding author: thomhert@telkomuniversity.ac.id

Abstrak

Periodontal disease is a one of dental health problems that can lead to tooth loss if not correctly treated. Early detection and accurate diagnosis are crucial to mitigating the impact of periodontal disease. This paper investigates the performance of two Convolutional Neural Network (CNN) models, ResNet-50 and EfficientNet-B3, in classifying periodontal disease using color dental images. Experimental results show that EfficientNet-B3 achieves higher classification accuracy of 84.09%, while ResNet-50 achieves an accuracy of 75%. The precision of the EfficientNet-B3 model is 80% compared to 66.67% for the ResNet model. The recall of the EfficientNet-B3 model is 75%, while ResNet is 62.5%. The F1-score of EfficientNet-B3 is 77.42%, whereas ResNet is 64.52%. These results indicate the superiority of EfficientNet-B3 in classifying periodontal disease using color dental images. The advantage of the EfficientNet-B3 model demonstrates its significant potential in enhancing the accuracy and efficiency of automated periodontal disease diagnosis. The use of CNN models enables faster and more accurate diagnostic processes. Further development could improve the accuracy and reliability of AI-based diagnostic systems in the field of dentistry, which ultimately can reduce the workload of dental health professionals and improve clinical outcomes for patients.

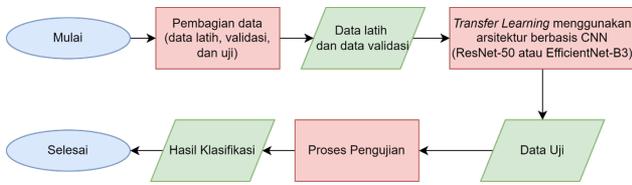
Key words: *Convolutional Neural Network, Classification, Periodontal Disease, Color Image.*

Pendahuluan

Penyakit periodontal adalah salah satu masalah kesehatan gigi dan mulut yang paling umum terjadi. Penyakit ini menyerang jaringan pendukung gigi, termasuk gusi, tulang alveolar, ligamen periodontal, dan sementum, yang dapat menyebabkan kehilangan gigi jika tidak ditangani dengan baik [1]. Penyakit ini tidak hanya berdampak pada kesehatan mulut tetapi juga memiliki kaitan dengan kondisi sistemik seperti penyakit kardiovaskular, diabetes, dan komplikasi kehamilan [2]. Oleh karena itu, deteksi dini dan diagnosis yang akurat sangat penting untuk mengurangi dampak lebih lanjut dari penyakit ini serta mencegah komplikasi yang lebih serius. Seiring dengan kemajuan teknologi dalam bidang kecerdasan buatan atau *Artificial Intelligence (AI)*, penggunaan model *deep learning*, khususnya *Convolutional Neural Networks (CNN)*, menunjukkan potensi besar dalam berbagai aplikasi medis [3]. CNN merupakan jenis jaringan saraf tiruan yang dirancang untuk mengenali pola visual secara otomatis melalui lapisan konvolusi dengan mengekstrak fitur-fitur penting dari citra *input* [4]. CNN sudah digunakan secara luas dalam berbagai tugas pengenalan pola dan klasifikasi citra medis, seperti deteksi kanker, identifikasi penyakit mata, dan analisis citra radiologi [5], [6], [7], [8], [9], [10]. Pencitraan medis dalam bidang kedokteran gigi mengalami perkembangan yang pesat, salah satunya dengan penggunaan citra gigi berwarna. Citra gigi berwarna memberikan informasi visual yang lebih kaya dibandingkan citra

hitam-putih layaknya citra x-ray, sehingga dapat meningkatkan akurasi diagnosis [11]. Penggunaan citra gigi berwarna dalam diagnosis penyakit periodontal dapat membantu dalam identifikasi tanda-tanda klinis yang mungkin lebih sulit terlihat pada citra hitam putih konvensional [6]. Namun, analisis manual dari citra ini memerlukan keahlian khusus dan waktu yang lama.

Kesalahan dalam interpretasi dapat menyebabkan diagnosis menjadi tidak akurat dan pengobatan yang tidak tepat [12]. Dalam beberapa tahun terakhir, beberapa penelitian menunjukkan bahwa model CNN dapat mencapai akurasi yang tinggi dalam klasifikasi citra medis dan mampu menyaingi kinerja para ahli dalam beberapa kasus [3], [13]. Sebagai contoh, model CNN telah berhasil digunakan untuk mendeteksi karies gigi, memprediksi kerusakan tulang, dan mendiagnosis berbagai kondisi oral lainnya [14], [15], [16], [17]. Dengan demikian, pengembangan sistem otomatis untuk klasifikasi penyakit periodontal berbasis CNN menggunakan citra gigi berwarna dapat memberikan solusi yang efisien dan akurat. Penelitian ini membandingkan performansi dari dua model CNN yang populer, yaitu ResNet-50 dan *EfficientNet-B3*, dalam hal klasifikasi penyakit periodontal menggunakan citra gigi berwarna. ResNet-50 dikenal karena kemampuannya dalam mengatasi masalah degradasi pada jaringan yang sangat dalam melalui penggunaan *residual learning* [18]. Sedangkan model *EfficientNet-B3* merupakan model yang dioptimalkan untuk efisiensi dengan menggunakan teknik *scaling* yang menggabungkan sisi kedalaman,



Gambar 1. Diagram alir penelitian yang terdiri dari pembagian data, proses *transfer learning* menggunakan jaringan arsitektur berbasis CNN yaitu ResNet-50 atau EfficientNet-B3. Model yang dilatih lalu diuji dengan data uji dan diukur hasil performansinya.

lebar, dan resolusi jaringan [19]. Kedua model ini dipilih karena performansinya terbukti unggul dan popularitasnya dalam berbagai aplikasi klasifikasi citra medis. Salah satu tantangan utama dalam penerapan CNN untuk klasifikasi penyakit periodontal adalah variabilitas tinggi dalam citra gigi berwarna. Citra ini dapat dipengaruhi oleh berbagai faktor seperti pencahayaan, posisi gigi, dan kondisi oral lainnya [20]. Oleh karena itu, diperlukan pendekatan yang robust dan adaptif untuk mengatasi tantangan ini.

Dalam penelitian ini, dikembangkan model CNN yang mampu mengklasifikasikan penyakit periodontal pada citra gigi berwarna dengan akurasi relatif tinggi. Model dievaluasi dengan menggunakan metrik performa seperti akurasi, *precision*, *recall*, dan *F1-score* untuk memberikan gambaran yang komprehensif tentang kinerja model [13], [20]. Hasil penelitian ini diharapkan dapat memberikan kontribusi dalam meningkatkan kualitas diagnosis dan perawatan penyakit periodontal. Dengan menggunakan model CNN yang tepat, proses diagnosis dapat dilakukan lebih cepat dan akurat, mengurangi beban kerja tenaga medis gigi, dan memungkinkan deteksi dini yang lebih efektif. Selain itu, temuan penelitian ini juga membuka peluang untuk pengembangan lebih lanjut guna meningkatkan kinerja dan keandalan sistem diagnostik AI di masa depan. Jurnal ini disusun dalam beberapa bagian. Bagian pertama adalah Pendahuluan, yang memberikan latar belakang masalah dan tujuan penelitian. Bagian kedua adalah Metode Penelitian, yang menjelaskan prosedur pengumpulan data, arsitektur model CNN yang digunakan, dan metode evaluasi. Bagian ketiga adalah Pembahasan, yang membahas hasil eksperimen dan analisis dari penelitian ini. Bagian keempat adalah Kesimpulan, yang merangkum hasil penelitian dan memberikan rekomendasi untuk penelitian lebih lanjut.

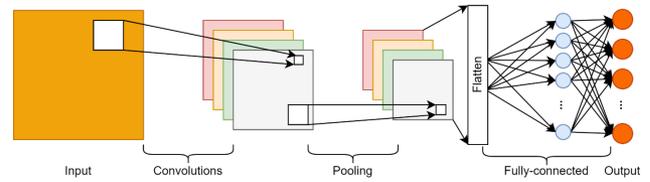
Metodologi Penelitian

Tahap Penelitian

Penelitian dalam jurnal ini secara umum menggunakan diagram alir yang tertera pada gambar 1. Langkah pertama adalah pengumpulan dataset dari penelitian [21]. Setelah melakukan pengumpulan data, data dibagi menjadi tiga bagian yaitu data latih, data validasi, dan data uji. Data latih digunakan untuk proses latih dengan metode *transfer learning* sampai model mendapatkan performansi terbaik pada data validasi. Setelah mendapatkan model baru yang sudah dilatih lalu dilanjutkan pengujian dengan data uji. Hasil pengujian diukur dengan menggunakan beberapa matriks uji kinerja seperti akurasi, *precision*, *recall*, dan *F1-score*.

Pengumpulan Data

Tahap pengumpulan data merupakan langkah penting dalam pengembangan model *deep learning*. Proses ini melibatkan pengumpulan dan penyusunan dataset yang berkualitas dan representatif dari domain masalah yang akan diselesaikan. Dataset dapat dikumpulkan dari berbagai sumber seperti basis data publik, *sensor*, *web scraping*, atau bahkan melalui eksperimen dan survei. Setelah data terkumpul, langkah selanjutnya adalah preprocessing yang mencakup pembersihan



Gambar 2. Contoh arsitektur jaringan Convolution Neural Network.

data dari kesalahan atau inkonsistensi, normalisasi, dan transformasi untuk memastikan bahwa data siap digunakan dalam pelatihan model. Kualitas data yang baik akan mempengaruhi kinerja model secara keseluruhan. Pada penelitian ini digunakan data yang bersumber dari [21] yang diambil dari internet dan sudah dilakukan seleksi di mana semua gambar adalah gambar gigi yang dengan posisi mulut terbuka. Data yang terkumpul dari sumber [21] adalah 82 gambar gigi normal dan 138 gambar gigi dengan penyakit periodontitis.

Pembagian Data Latih dan Data Uji

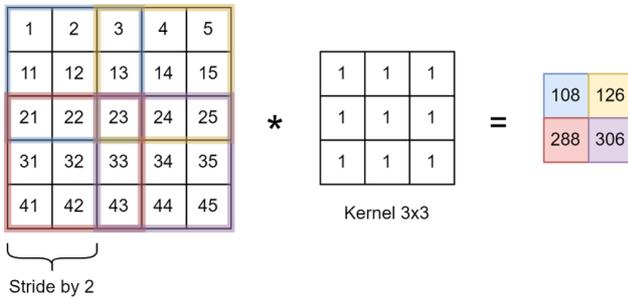
Secara umum pembagian data menjadi dua bagian yaitu data latih dan data uji. Untuk data latih dilakukan pembagian menjadi dua yaitu data latih sebenarnya dan data validasi. Pembagian data latih, validasi, dan uji merupakan langkah krusial dalam pengembangan model pembelajaran mesin untuk memastikan performansi model yang baik dan dapat diandalkan. Data Latih (*training data*) digunakan untuk melatih model. Tujuannya untuk menemukan pola atau hubungan dalam data yang dapat digunakan untuk membuat prediksi. Model belajar dari data ini dengan menyesuaikan bobot dan parameter model untuk meminimalisir kesalahan prediksi. Biasanya, data latih mencakup sekitar 60-80% dari total data yang tersedia. Data Validasi (*validation data*) digunakan untuk mengevaluasi model selama proses latih (*training*). Ini membantu dalam pemilihan model dan pengaturan parameter (*tuning*) untuk menghindari *overfitting*. Model dievaluasi dengan menggunakan data validasi setelah pelatihan pada data latih selesai baik secara bertahap (*batch*) atau keseluruhan. Hasil evaluasi tiap iterasi digunakan untuk melakukan penyesuaian pada model. Biasanya model terbaik diambil dari model dengan performansi terbaik dari hasil evaluasi dengan menggunakan data validasi.

Proporsi data validasi umumnya sekitar 10-20% dari total data dan tidak digunakan untuk melatih model, hanya digunakan untuk validasi dalam proses latih. Artinya model tidak secara langsung melihat data validasi ketika proses latih. Data Uji (*test data*) digunakan untuk mengevaluasi performansi akhir model setelah proses pelatihan dan validasi selesai. Proses ini memberikan gambaran bagaimana model bekerja pada data yang belum pernah dilihat sebelumnya. Model yang sudah dilatih dievaluasi pada data uji untuk menentukan akurasi, *precision*, *recall*, dan *F1-score*. Data uji biasanya mencakup sekitar 10-20% dari total data dan harus benar-benar terpisah dari proses pelatihan dan validasi. Pada penelitian ini, digunakan ratio pembagian data latih, data validasi dan data uji yaitu 60% data latih, 20% data validasi dan 20% data uji.

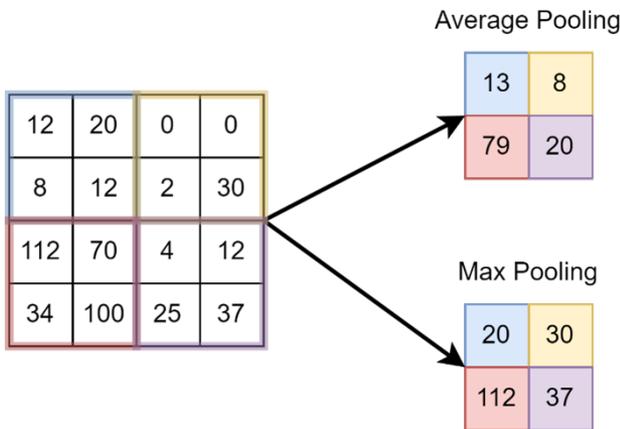
Pemodelan

1. Convolutional Neural Network

Convolutional Neural Networks (CNNs), atau Jaringan Syaraf Konvolusional, adalah jenis arsitektur jaringan saraf tiruan yang banyak digunakan dalam pengolahan citra dan video seperti pengenalan gambar, dekeksi objek, dan segmentasi objek. Gambar 2 mendeskripsikan jaringan CNN Secara umum. CNN memanfaatkan operasi konvolusi untuk menangkap fitur spasial dan pola



Gambar 3. Lapisan Konvolusi.



Gambar 4. Lapisan Pooling.

dalam data. Secara umum penjelasan CNN adalah sebagai berikut:

- Lapisan Konvolusi

Lapisan ini melakukan operasi konvolusi pada *input* untuk mengekstrak fitur-fitur lokal. *Filter* atau *kernel* dengan ukuran kecil (3x3 atau 5x5) diterapkan pada seluruh citra *input*. Setiap *filter* bergeser di seluruh citra, dan pada setiap posisi, elemen-elemen dalam *filter* dikalikan dengan nilai piksel yang sesuai dalam citra, dan hasilnya dijumlahkan untuk menghasilkan satu nilai dalam fitur *map*. Setiap *filter* menghasilkan fitur *map* (*feature map*) yang mendeteksi fitur spesifik, seperti tepi, tekstur, atau pola tertentu. Proses konvolusi diperlihatkan pada gambar 3.

- Lapisan Aktivasi

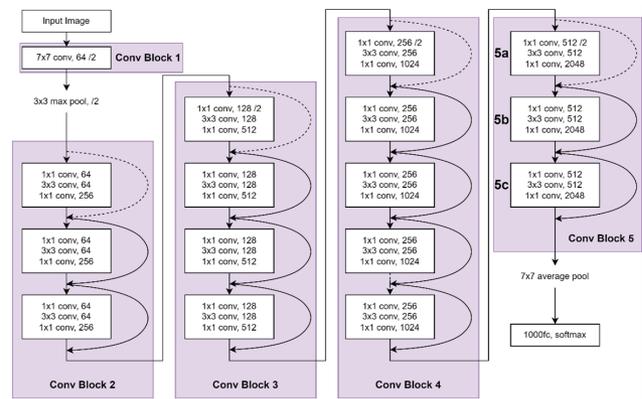
Setelah konvolusi, lapisan aktivasi diterapkan untuk memperkenalkan *non-linearitas* ke dalam model. Fungsi aktivasi yang umum digunakan adalah *Rectified Linear Unit* (ReLU).

- Lapisan Pooling

Lapisan ini mengurangi dimensi spasial dari fitur *map*, mengurangi jumlah parameter dan komputasi dalam jaringan, serta membantu dalam pengenalan fitur invarian skala. Beberapa jenis operasi *pooling* adalah *Max Pooling* di mana mengambil nilai maksimum dalam jendela dan *Average Pooling* di mana mengambil rata-rata nilai dalam jendela seperti terlihat di gambar 4.

- Lapisan Fully Connected

Lapisan ini menghubungkan setiap neuron di lapisan sebelumnya dengan setiap neuron di lapisan saat ini, di mana



Gambar 5. Jaringan ResNet-50 .

cara kerjanya adalah serupa dengan jaringan saraf tiruan tradisional. Biasanya digunakan untuk menggabungkan fitur yang diekstraksi dan membuat keputusan paling akhir.

2. ResNet-50

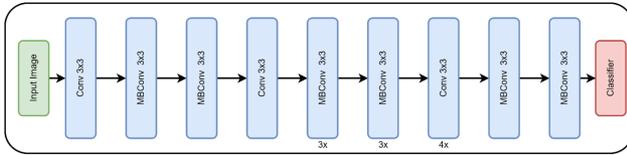
ResNet adalah salah satu model jaringan saraf konvolusional yang terkenal dan banyak digunakan dalam berbagai tugas pengenalan gambar. ResNet-50 adalah bagian dari keluarga Residual Networks (ResNets) [18]. ResNet-50 terdiri dari 50 lapisan (*layers*), yang membuatnya jauh lebih dalam dibandingkan model CNN tradisional. Model ini terdiri dari beberapa blok residual yang masing-masing terdiri dari beberapa lapisan konvolusional. Blok residual adalah inti dari ResNet. Setiap blok residual memiliki koneksi identitas (*identity connections*) yang melewati *input* secara langsung ke *output*.

Ini membantu mengatasi masalah *vanishing gradient* (gradien menghilang) yang sering terjadi pada jaringan yang sangat dalam. ResNet-50 dimulai dengan satu lapisan konvolusional, diikuti dengan *batch normalization* dan *ReLU activation*. Setelah itu, terdapat serangkaian blok residual, yang terdiri dari lapisan konvolusional dengan *kernel* 1x1, 3x3, dan 1x1, di mana lapisan pertama dan terakhir biasanya mengurangi dan meningkatkan dimensi, sementara lapisan tengah mempertahankan dimensi. Model ini menggunakan *pooling layer* (lapisan *pooling*) dan *fully connected layer* (lapisan sepenuhnya terhubung) di akhir untuk menghasilkan *output* akhir. Gambar 5 mendeskripsikan jaringan ResNet-50 secara umum.

3. EfficientNet

EfficientNet-B3 adalah salah satu model dari keluarga EfficientNet yang dirancang untuk mencapai keseimbangan antara akurasi dan efisiensi komputasi dalam tugas-tugas *computer vision*, seperti pengenalan gambar [19]. Model ini menggunakan pendekatan baru yang disebut *Compound Scaling* untuk mengoptimalkan arsitektur model dengan memperhatikan tiga dimensi skala utama: *depth* (kedalaman), *width* (lebar), dan *resolution* (resolusi). EfficientNet-B3 adalah versi dengan skala yang lebih besar dibandingkan dengan model dasar EfficientNet-B0. Model ini memiliki 24 lapisan, 48 *channels* pada lapisan pertama, dan resolusi gambar *input* sebesar 300x300 piksel.

EfficientNet-B3 dirancang untuk memberikan kinerja yang unggul dengan penggunaan sumber daya yang lebih efisien. Dibandingkan dengan model konvensional seperti *InceptionNet*, EfficientNet-B3 dapat mencapai akurasi yang lebih tinggi dengan jumlah parameter dan FLOPS (*Floating Point Operations Per Second*) yang lebih rendah. Model ini sering digunakan dalam berbagai aplikasi *computer vision*, seperti pengenalan gambar untuk



Gambar 6. Jaringan EfficientNet-B3.

mengenali objek dalam gambar, deteksi objek untuk menemukan dan mengklasifikasikan objek dalam gambar, serta segmentasi gambar untuk memisahkan objek atau area tertentu dalam gambar. Kelebihan utama dari EfficientNet-B3 meliputi efisiensi melalui penggunaan *compound scaling*, kinerja tinggi dengan akurasi yang sangat baik dalam berbagai tugas *computer vision*, dan fleksibilitas yang memungkinkan penyesuaian dengan berbagai kebutuhan aplikasi melalui pengaturan skala *depth*, *width*, dan *resolution*. Gambar 6 menjelaskan bagaimana jaringan EfficientNet-B3.

Transfer Learning

Transfer learning adalah teknik di mana model yang sudah dilatih sebelumnya pada suatu tugas dengan dataset tertentu digunakan sebagai model awal untuk pelatihan pada tugas yang berbeda. Model *pre-trained* dilatih pada dataset yang sangat besar, seperti *ImageNet*, yang berisi jutaan gambar dengan ribuan kategori. Dengan menggunakan model *pre-trained*, kita dapat memanfaatkan pengetahuan yang telah dipelajari oleh model tersebut dan mengaplikasikannya pada tugas baru yang memiliki data lebih sedikit. Sehingga tidak hanya menghemat waktu dan komputasi, tetapi juga sering kali menghasilkan performansi yang lebih baik dibandingkan melatih model dari awal (*scratch*). Ada berbagai tipe dalam *transfer learning*, misalnya lapisan awal dari model *pre-trained* dibekukan (*freeze*) karena lapisan ini telah belajar fitur-fitur dasar yang dapat diterapkan secara umum, misalnya tepi, tekstur, dan bentuk. Lapisan-lapisan yang lebih atas kemudian diadaptasi atau dilatih ulang pada dataset baru yang spesifik untuk menyesuaikan dengan tugas yang ditargetkan. Misalnya, dalam klasifikasi penyakit periodontal dari gambar medis, model seperti ResNet-50 atau EfficientNet-B3 yang telah dilatih pada *ImageNet* dapat digunakan sebagai dasar, dan lapisan-lapisan atasnya dilatih ulang dengan gambar medis untuk mendeteksi tanda-tanda spesifik dari penyakit tersebut.

Uji Kinerja

Dalam penelitian ini, beberapa metrik uji kinerja digunakan untuk menilai seberapa baik model bekerja. Berikut adalah penjelasan mengenai metrik-metrik tersebut beserta formulanya:

- Akurasi (*Accuracy*)

Akurasi adalah rasio dari jumlah prediksi yang benar terhadap total jumlah prediksi. Ini memberikan gambaran umum tentang seberapa sering model membuat prediksi yang benar.

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

di mana TP = True Positive, TN = True Negative, FP = False Positive, dan FN = False Negative.

- Precision

Precision adalah rasio dari jumlah prediksi positif yang benar (TP) terhadap total jumlah prediksi positif. *Precision* mengukur keakuratan hasil prediksi kelas positif dari model.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2)$$

- Recall (Sensitivitas)

Table 1. Jumlah Data Dan Pembagian Data

Nama	Total	Penyakit Periodontal	Normal
Data latih	132	82	50
Data validasi	44	28	16
Data uji	44	28	16



Gambar 7. Gigi dengan penyakit periodontal (kiri) dan gigi normal (kanan) [21].

Recall adalah rasio dari jumlah prediksi positif yang benar (TP) terhadap total jumlah data positif aktual. *Recall* mengukur kemampuan model untuk dapat memprediksi semua kasus positif.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3)$$

- F1-Score

F-Score adalah metrik yang menggabungkan *precision* dan *recall* sehingga dapat memberikan gambaran terkait keseimbangan antara *precision* dan *recall* dari model yang dihasilkan

$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

Metrik-metrik ini digunakan untuk memberikan pandangan yang lebih komprehensif tentang performansi model, terutama dalam konteks klasifikasi yang tidak seimbang di mana satu kelas lebih dominan daripada kelas lainnya. Memahami dan menginterpretasikan metrik-metrik ini membantu dalam memilih model terbaik dan mengidentifikasi bagian yang perlu ditingkatkan kemampuannya.

Gambar visualisasi dari gigi yang memiliki penyakit periodontal dan gigi normal dapat dilihat pada gambar 7.

Pelatihan Model

Pelatihan model dilakukan dengan beberapa langkah dan *hyperparameter* harus diatur dengan benar untuk memastikan model terlatih dengan optimal. *Library* yang digunakan dalam penelitian ini mencakup *library python* seperti *pytorch*, *torchvision*, *timm*, *numpy*, dan *pandas*. Instalasi paket *library* dilakukan dengan menggunakan *pip* dan *requirements.txt* yang berisi daftar paket dengan versi minimum yang diperlukan. *Hyperparameter* adalah parameter yang konfigurasinya ditentukan sebelum proses pelatihan model dimulai. *Hyperparameter* yang diberikan mencakup berbagai aspek dari data, model, pelatihan, dan optimasi. Berikut adalah penjelasan lengkap mengenai setiap bagian *hyperparameter* yang digunakan yang dapat dilihat pada tabel 2.

Hasil dan Pembahasan

Dataset

Dataset diperoleh dari [21] di mana penelitian ini membahas terkait klasifikasi penyakit periodontal pada citra gigi berwarna. Adapun pembagian dataset latih, validasi, dan uji adalah sebagai berikut:

Table 2. Hyperparameter

Nama	Deskripsi	Nilai
Jumlah GPU	Jumlah GPU yang digunakan	1
Jumlah kelas	Jumlah kelas untuk klasifikasi.	Binary
Ukuran <i>input</i>	Ukuran <i>input</i> gambar.	224x224
Jumlah channel gambar	Jumlah channel pada gambar (misalnya, 3 untuk RGB).	33
Strategi <i>sampling</i>	Tingkat peluruhan bobot <i>sampling</i> jika menggunakan strategi <i>progressively balanced</i> .	<i>progressively balanced</i>
<i>Data augmentation</i>	Augmentasi data yang digunakan	horizontal flip, color distortion, vertical flip, rotasi, tranlasi
Jaringan <i>pretrained</i>	<i>Backend</i> untuk pembangun jaringan (misalnya, timm). Memuat bobot dari model yang sudah dilatih sebelumnya.	ResNet-50 atau EfficientNet-B3 Ya
<i>epochs</i>	Jumlah <i>epoch</i> untuk pelatihan.	50
Ukuran <i>batch</i>	Ukuran <i>batch</i> untuk pelatihan.	8
Uji kinerja	Uji kinerja yang digunakan	Akurasi, Presisi, <i>Recall</i> , F1-Score
<i>optimizer</i>	<i>Optimizer</i> dalam proses latih	Adam
<i>learning rate</i>	<i>Learning rate</i> untuk prose latih	0.001
<i>scheduler</i>	Scheduler untuk <i>learning rate</i> (misalnya, <i>cosine</i>).	<i>Cosine</i>

Setelah semua pengaturan dan *hyperparameter* diatur, berikut adalah langkah-langkah umum untuk melatih model *deep learning*:

1. Load Dataset: dataset diambil menggunakan *torchvision.datasets* dan transformasi data diterapkan menggunakan *torchvision.transforms* untuk normalisasi dan augmentasi.
2. Persiapan dataloader: *dataLoader* digunakan untuk memuat data dalam *batch* selama proses pelatihan.
3. Inisialisasi model: model *deep learning* diinisialisasi menggunakan *library* *timm.create_model* dengan konfigurasi yang diatur, termasuk apakah menggunakan model *pre-trained* atau tidak.
4. Menetapkan *loss function* dan optimzer: *Loss function* yang digunakan dalam kasus ini adalah *Binary Cross-Entropy* dan optimizer Adam diatur sesuai dengan konfigurasi.
5. Jumlah *epoch*: model dilatih melalui beberapa *epoch*, di mana pada setiap *epoch* mencakup:
 6. Data diproses dalam *batch*.
 7. Proses Prediksi dilakukan menggunakan model yang dilatih dalam *batch* tersebut.
 8. *Loss* dihitung menggunakan *loss function*.
 9. Gradien dihitung dan dilakukan perubahan parameter menggunakan optimizer.
10. *Scheduler learning rate* digunakan untuk memperbaharui proses latih.
11. Evaluasi: Pada interval yang telah ditentukan, model menggunakan data validasi untuk menghitung metrik kinerja seperti akurasi, *precision*, *recall*, dan F1-score.
12. *Checkpointing*: Model disimpan secara berkala untuk memastikan bahwa model terbaik dapat disimpan dengan baik.

Hasil Pengujian

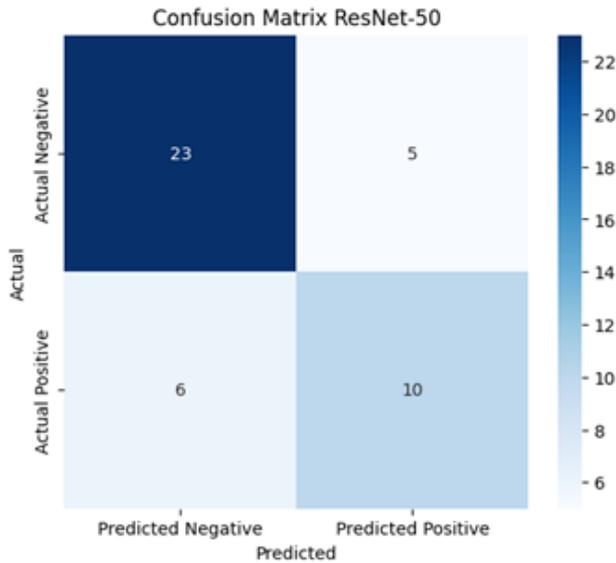
Berdasarkan hasil evaluasi performansi model *deep learning* EfficientNet-B3 dan ResNet pada table 2, EfficientNet-B3 menunjukkan performansi yang lebih unggul dibandingkan ResNet di semua metrik evaluasi yang

Table 3. Hasil Pengujian Untuk Masing-Masing Uji Kinerja

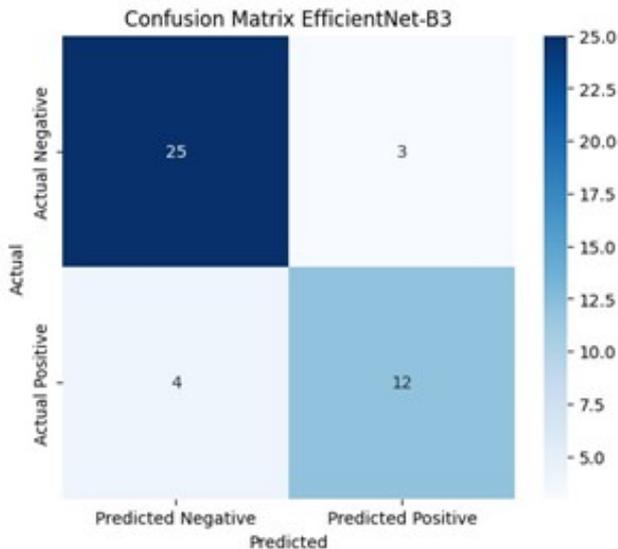
Nama	EfficientNet-B3	ResNet-50
Akurasi	84.09%	75%
<i>Precision</i>	80%	66.67%
<i>Recall</i>	75%	62.5%
F1-score	77.42%	64.52%

diukur, yakni akurasi, F1-score, *precision*, dan *recall*. Detail dari *confusion matrix* untuk model EfficientNet-B3 dapat dilihat pada gambar, sedangkan *confusion matrix* untuk model ResNet-50 dapat dilihat pada gambar. Akurasi EfficientNet-B3 3 mencapai 84.09%, sedangkan ResNet hanya mencapai 75%. Ini menunjukkan bahwa secara keseluruhan, EfficientNet-B3 lebih sering membuat prediksi yang benar dibandingkan ResNet. Akurasi yang lebih tinggi ini mencerminkan kemampuan model untuk memberikan hasil yang lebih handal dan tepat dalam mengklasifikasikan gambar yang diberikan. *Precision* dari model EfficientNet-B3 adalah 80% dibandingkan dengan 66.67% pada ResNet. *Precision* mengukur seberapa banyak dari prediksi positif yang benar-benar positif. Nilai *precision* 3 yang lebih tinggi pada EfficientNet-B3 menunjukkan bahwa model ini lebih akurat dalam memprediksi kelas positif. Ini berarti ketika EfficientNet-B3 mengklasifikasikan sebuah gambar sebagai positif, kemungkinan besar prediksi tersebut benar. Hasil Pengujian dapat dilihat pada tabel 3.

Recall dari model EfficientNet-B3 adalah 75%, sementara ResNet adalah 62.5%. *Recall* mengukur seberapa baik model dapat mendeteksi semua contoh positif yang ada dari dataset. Nilai *recall* yang lebih tinggi pada EfficientNet-B3 menunjukkan bahwa model ini lebih baik dalam mendeteksi semua kasus positif dan mengurangi jumlah *false negatives*. Ini sangat penting untuk memprediksi di mana kegagalan mendeteksi contoh positif bisa berakibat fatal. F1-score dari EfficientNet-B3 adalah 77.42%, sedangkan ResNet adalah 64.52%.



Gambar 8. Confusion matrix untuk model ResNet-50.



Gambar 9. Confusion matrix untuk model EfficientNet-B3.

F1-score adalah rata-rata perbandingan dari *precision* dan *recall*, memberikan keseimbangan antara kemampuan model untuk memprediksi kelas positif dengan benar (*precision*) dan mendeteksi semua instance positif yang ada (*recall*). F1-score yang lebih tinggi pada EfficientNet-B3 menunjukkan bahwa model ini memiliki keseimbangan yang lebih baik antara *precision* dan *recall*, yang sangat penting dalam aplikasi nyata di mana baik *false positives* maupun *false negatives* harus minimal.

Analisis

Dari dua hasil pemodelan dengan menggunakan EfficientNet-B3 dan ResNet-50 juga dapat dibandingkan dengan penelitian Sebelumnya [21]. Di mana penelitian tersebut menggunakan arsitektur Parallel 1D CNN dengan akurasi 74.54%. Dibandingkan dengan hasil model ResNet-50, akurasi yang kami dapatkan lebih tinggi 0.46 poin. Namun

hasil EfficientNet-B3 terlihat signifikan yaitu 84.09% akurasi. Dari hasil pengujian, ada beberapa faktor yang mungkin menjelaskan keunggulan EfficientNet-B3 dibandingkan ResNet-50. Pertama, arsitektur model EfficientNet-B3 menggunakan teknik *compound scaling*, yang mengoptimalkan skala kedalaman, lebar, dan resolusi gambar secara bersamaan. Hal ini memungkinkan model untuk mencapai akurasi yang lebih baik. Di sisi lain, meskipun ResNet-50 menggunakan pendekatan residual *learning* yang efektif untuk mengatasi masalah *vanishing gradient*, arsitektur ini tidak seefisien EfficientNet-B3 dalam memanfaatkan kompleksitas model terhadap ukuran dataset tertentu. Dalam hal ini ukuran dataset yang relatif sedikit. Kedua, ukuran dan kompleksitas model EfficientNet-B3 memungkinkan EfficientNet-B3 untuk menghasilkan representasi fitur yang lebih detail dan lebih akurat, sementara ResNet-50 mungkin memerlukan lebih banyak *tuning* dan sumber daya komputasi untuk mencapai performansi yang setara dalam penelitian ini.

Ketiga, penggunaan bobot *pre-trained* dari dataset besar seperti ImageNet bisa jadi lebih efektif pada EfficientNet-B3. Efisiensi arsitektur EfficientNet-B3 memungkinkan *transfer learning* yang lebih efektif, menghasilkan generalisasi yang lebih baik pada dataset penyakit periodontal. Keempat, pengaturan data augmentation dan regularisasi yang lebih optimal pada EfficientNet-B3 dapat membantu model ini menghindari *overfitting* dan meningkatkan kemampuan generalisasi. Data *augmentation* yang baik dapat membantu model belajar fitur yang lebih kuat dan representatif dari data asli, sementara regularisasi yang baik dapat mencegah model menjadi terlalu kompleks dan *overfitting* pada data latih. Secara keseluruhan, hasil evaluasi ini menunjukkan bahwa EfficientNet-B3 adalah pilihan yang lebih baik untuk melakukan klasifikasi penyakit periodontal berbasis citra gigi berwarna. Model ini mampu memberikan prediksi yang lebih akurat dan andal dibandingkan ResNet-50, menjadikannya lebih sesuai untuk aplikasi praktis yang membutuhkan keandalan tinggi. Hasil penelitian dengan menggunakan Eff.

Kesimpulan

Jurnal ini fokus pada penggunaan CNN yakni membandingkan performansi dua model CNNs yaitu ResNet-50 dan EfficientNet-B3 untuk tugas klasifikasi penyakit periodontal menggunakan citra gigi berwarna. Dari eksperimen yang dilakukan, hasil menunjukkan bahwa model EfficientNet-B3 memiliki akurasi klasifikasi yang lebih tinggi, yaitu sebesar 84.09%, dibandingkan dengan ResNet-50 yang hanya mencapai akurasi sebesar 75%. *Precision* dari model EfficientNet-B3 adalah 80% dibandingkan dengan 66.67% pada ResNet. *Recall* dari model EfficientNet-B3 adalah 75%, sementara ResNet adalah 62.5%. F1-score dari EfficientNet-B3 adalah 77.42%, sedangkan ResNet adalah 64.52%. Keunggulan dari metrik uji kinerja EfficientNet-B3 ini membuktikan adanya potensi besar dalam meningkatkan efisiensi diagnosis otomatis penyakit periodontal berbasis CNNs. Penggunaan model CNN memungkinkan proses diagnosis dilakukan lebih cepat dan akurat, sehingga dapat mengurangi beban kerja tenaga medis gigi dan memungkinkan deteksi dini yang lebih efektif. Penelitian ini memberikan kontribusi dalam upaya pengembangan sistem diagnosis berbasis AI di bidang kedokteran gigi, yang pada akhirnya dapat meningkatkan kualitas perawatan dan hasil klinis bagi pasien.

Daftar Pustaka

1. Newman MG, Takei H, Klokkevold PR, Carranza FA. Newman and Carranza's Clinical Periodontology: Newman and Carranza's Clinical Periodontology E-Book. Elsevier Health Sciences; 2018.
2. Nazir MA. Prevalence of periodontal disease, its association with systemic diseases and prevention. International Journal of Health

- Sciences (Qassim). 2017;11(2):72-80.
3. Litjens G, et al. A survey on deep learning in medical image analysis. *Medical Image Analysis*. 2017 Dec;42:60-88.
 4. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015 May;521(7553):436-44.
 5. Esteva A, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*. 2017 Feb;542(7639):115-8.
 6. Rajpurkar P, et al.. CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning; 2017. ArXiv preprint arXiv:1711.05225.
 7. Alyoubi WL, Shalash WM, Abulkhair MF. Diabetic retinopathy detection through deep learning techniques: A review. *Informatics in Medicine Unlocked*. 2020;20:100377.
 8. Li Q, Cai W, Wang X, Zhou Y, Feng DD, Chen M. Medical image classification with convolutional neural network. In: 2014 13th International Conference on Control Automation Robotics & Vision (ICARCV); 2014. p. 844-8.
 9. Ibrokhimov B, Hur C, Kim H, Kang S. An Optimized Deep Belief Network Model for Accurate Breast Cancer Classification. *IEIE Transactions on Smart Processing & Computing*. 2020;9(4):266-73.
 10. Vankdothu R, Hameed MA, Fatima H. A Brain Tumor Identification and Classification Using Deep Learning based on CNN-LSTM Method. *Computers and Electrical Engineering*. 2022 Jul;101:107960.
 11. Mallya S, Lam E. *White and Pharoah's Oral Radiology E-book: Principles and Interpretation: Second South Asia Edition E-Book*. Elsevier, India; 2019.
 12. Abiodun Ol, et al. Comprehensive Review of Artificial Neural Network Applications to Pattern Recognition. *IEEE Access*. 2019;7:158820-46.
 13. Anwar SM, Majid M, Qayyum A, Awais M, Alnowami M, Khan MK. Medical Image Analysis using Convolutional Neural Networks: A Review. *Journal of Medical Systems*. 2018 Nov;42(11):226.
 14. Lee JG, et al. Deep Learning in Medical Imaging: General Overview. *Korean Journal of Radiology*. 2017;18(4):570.
 15. Yin J, Ngiam KY, Teo HH. Role of Artificial Intelligence Applications in Real-Life Clinical Practice: Systematic Review. *Journal of Medical Internet Research*. 2021 Apr;23(4):e25759.
 16. Warin K, Limprasert W, Suebnukarn S, Jinaporntham S, Jantana P. Performance of deep convolutional neural network for classification and detection of oral potentially malignant disorders in photographic images. *International Journal of Oral and Maxillofacial Surgery*. 2022 May;51(5):699-704.
 17. Anantharaman R, Velazquez M, Lee Y. Utilizing Mask R-CNN for Detection and Segmentation of Oral Diseases. In: 2018 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). IEEE; 2018. p. 2197-204.
 18. He K, Zhang X, Ren S, Sun J. Deep Residual Learning for Image Recognition; 2015. [Online]. Available: <http://image-net.org/challenges/LSVRC/2015/>.
 19. Tan M, Le Q. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. In: Chaudhuri K, Salakhutdinov R, editors. Proceedings of the 36th International Conference on Machine Learning. vol. 97 of Proceedings of Machine Learning Research. PMLR; 2019. p. 6105-14. [Online]. Available: <https://proceedings.mlr.press/v97/tan19a.html>.
 20. Voulodimos A, Doulamis N, Doulamis A, Protopapadakis E. Deep Learning for Computer Vision: A Brief Review. *Computational Intelligence and Neuroscience*. 2018;2018:1-13.
 21. Park S, et al. Periodontal Disease Classification with Color Teeth Images Using Convolutional Neural Networks. *Electronics (Basel)*. 2023 Mar;12(7):1518.