

## Klasifikasi Penyakit Periodontal Pada Citra Panoramik Gigi Menggunakan Deep Learning Berbasis ResNet50

Dodi Syaripudin, Encep Yayat, Jayadi Jayadi, Agung Rachmat Raharja

Fakultas Kesehatan dan Teknik, Universitas Bandung, Indonesia

Email: dodisyaripudin@bandunguniversity.ac.id; encepuyayat@bandunguniversity.ac.id;

jayadi@bandunguniversity.ac.id; agungmat@bandunguniversity.ac.id.

Diterima:  
2 Februari 2025

Diterima Setelah Revisi:  
19 Februari 2025

Dipublikasikan:  
27 Februari 2025

### Abstrak

Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model klasifikasi berbasis *deep learning* untuk mendeteksi penyakit periodontal dan non-periodontal dari citra *rontgen* panoramik gigi. Dataset yang digunakan terdiri dari citra panoramik yang diolah melalui proses augmentasi data untuk meningkatkan keragaman, kemudian dibagi menjadi subset pelatihan, validasi, dan pengujian guna memastikan kemampuan generalisasi model. Model *transfer learning* dengan arsitektur ResNet50 diterapkan untuk memanfaatkan kemampuan ekstraksi fitur yang optimal dari data citra medis. Hasil evaluasi menunjukkan bahwa model memiliki akurasi keseluruhan sebesar 56%, dengan precision untuk kelas penyakit-non-periodontal sebesar 0.53 dan recall mencapai 1.00, menunjukkan bahwa model mampu mengenali seluruh kasus penyakit-non-periodontal tetapi masih kesulitan mendeteksi penyakit periodontal. Sebaliknya, kelas penyakit-periodontal memiliki precision 1.00 tetapi recall hanya 0.12, yang mengindikasikan bahwa model sering gagal mengenali sebagian besar sampel penyakit periodontal. Analisis lebih lanjut menggunakan confusion matrix menunjukkan adanya bias model terhadap kelas non-periodontal, yang mengarah pada tingginya jumlah *false negative* dalam klasifikasi penyakit periodontal. Beberapa langkah seperti penyeimbangan dataset, *fine-tuning* model, serta augmentasi data tambahan direkomendasikan untuk meningkatkan generalisasi dan akurasi prediksi. Dengan validasi lebih mendalam, model ini diharapkan dapat menjadi alat yang efisien dan akurat untuk mendukung analisis klinis dalam diagnosis penyakit periodontal.

**Kata kunci:** Penyakit Periodontal, *ResNet50*, Klasifikasi Gambar

### ABSTRACT

*This study aims to develop and evaluate a deep learning-based classification model to detect periodontal and non-periodontal diseases from panoramic X-ray images. The dataset used consists of panoramic images processed through data augmentation to enhance diversity, then split into training, validation, and testing subsets to ensure the model's generalization capability. A transfer learning approach utilizing the ResNet50 architecture was implemented to leverage its optimal feature extraction capabilities for medical image analysis. Evaluation results indicate that the model achieved an overall accuracy of 56%, with precision for the non-periodontal disease class at 0.53 and recall reaching 1.00, signifying that the model correctly identified all non-periodontal cases but struggled to detect periodontal disease. Conversely, the periodontal disease class attained precision of 1.00 but recall of only 0.12, indicating that the model frequently failed to recognize most periodontal disease samples. Further analysis using*

*the confusion matrix revealed a bias toward the non-periodontal class, leading to a high number of false negatives in periodontal disease classification. Several improvements, including dataset balancing, fine-tuning the model, and additional data augmentation, are recommended to enhance generalization and predictive accuracy. With more in-depth validation, this model is expected to become an efficient and accurate tool to support clinical analysis in diagnosing periodontal disease.*

**Keywords:** *Periodontal Disease, ResNet50, Image Classification*

## 1 PENDAHULUAN

Penyakit periodontal, seperti kalkulus (karang gigi) dan gingivitis, merupakan masalah kesehatan gigi yang umum di masyarakat. Kalkulus adalah deposit keras yang terbentuk di permukaan gigi akibat mineralisasi plak, yang dapat menyebabkan peradangan gusi. Gingivitis, peradangan pada gusi, merupakan tahap awal penyakit periodontal yang dapat berkembang menjadi periodontitis jika tidak ditangani. Periodontitis adalah penyakit inflamasi pada jaringan pendukung gigi yang ditandai dengan kerusakan struktur seperti gingiva, ligamen periodontal, sementum, dan tulang alveolar (Dwisatya Ramadhani et al., 2022). Deteksi dini terhadap kalkulus dan gingivitis sangat penting untuk mencegah perkembangan penyakit periodontal yang lebih serius. Kalkulus dapat menjadi faktor predisposisi akumulasi plak yang sulit dibersihkan, sehingga meningkatkan risiko peradangan gusi. Oleh karena itu, menjaga kebersihan mulut dan melakukan pemeriksaan gigi secara rutin adalah langkah penting dalam pencegahan penyakit periodontal (Pranata, 2019). Selain itu, faktor-faktor seperti kebiasaan merokok, penyakit sistemik seperti diabetes, dan penggunaan gigi tiruan yang tidak tepat dapat meningkatkan risiko terjadinya penyakit periodontal. Oleh karena itu, penting untuk memperhatikan faktor-faktor tersebut dalam upaya pencegahan dan penanganan penyakit periodontal (J. D. Manson & B. M. Eley, 2023).

Dalam praktik klinis, diagnosis penyakit gigi sering kali bergantung pada evaluasi visual dan radiografi oleh dokter gigi. Evaluasi ini bersifat subjektif dan dapat bervariasi tergantung pada pengalaman dan keahlian masing-masing dokter. Untuk mengatasi tantangan ini, teknologi otomasi berbasis kecerdasan buatan (*Artificial Intelligence* atau AI) telah diperkenalkan dalam bidang kedokteran gigi guna meningkatkan akurasi diagnosis, mengurangi subjektivitas, dan mempercepat proses evaluasi. Salah satu pendekatan AI yang menjanjikan adalah penggunaan *Convolutional Neural Networks* (CNN), sebuah algoritma *deep learning* yang dirancang khusus untuk memproses dan menganalisis data berbasis gambar, seperti foto klinis atau radiografi (Danial & Setiawati, 2024).

Convolutional Neural Networks (CNN) telah membuktikan efektivitasnya dalam berbagai aplikasi medis, termasuk klasifikasi gambar radiologi, pendeteksian lesi kanker, dan identifikasi penyakit mata. Dalam konteks kedokteran gigi, CNN digunakan untuk menganalisis citra digital, baik dalam format foto intraoral maupun radiografi, guna mendeteksi dan mengklasifikasikan berbagai kondisi gigi dan mulut. Misalnya, penelitian oleh (Schwendicke et al., 2020) menunjukkan bahwa CNN dapat digunakan untuk mendeteksi karies dengan tingkat akurasi yang tinggi (Shaikh et al., 2022). Selain itu, CNN memiliki kemampuan untuk mengenali pola-pola kompleks dalam gambar, termasuk struktur gigi dan jaringan periodontal, yang sulit diidentifikasi dengan mata manusia (Agrawal & Nihade, 2022).

Penerapan Convolutional Neural Networks (CNN) dalam otomatisasi deteksi kalkulus dan gingivitis menawarkan beberapa keunggulan. Pertama, CNN dapat memproses sejumlah besar data gambar dengan cepat, meningkatkan efisiensi waktu diagnosis (Li et al., 2021). Kedua, model ini dapat dilatih untuk mengenali berbagai tingkat keparahan penyakit, memberikan diagnosis yang lebih detail. Ketiga, penerapan CNN dapat membantu mengurangi beban kerja dokter gigi, terutama di wilayah

dengan kekurangan tenaga profesional. Dengan integrasi sistem berbasis CNN, klinik gigi dapat memberikan layanan diagnostik yang lebih baik dan lebih cepat kepada pasien (Kabir et al., 2021)

ResNet50 adalah salah satu varian dari arsitektur Residual Network (ResNet) yang memiliki 50 lapisan dalam (deep layers) (Suprihanto et al., 2022). Arsitektur ini dirancang untuk tugas pengenalan dan klasifikasi gambar dengan memanfaatkan konsep residual learning (Ryandra, 2022), yang diperkenalkan oleh He et al. dalam paper "Deep Residual Learning for Image Recognition" (2015). ResNet50 menjadi pilihan populer dalam deep learning karena kemampuannya yang unggul dalam mengekstraksi fitur dari data gambar tanpa mengalami masalah degradasi performa, bahkan pada jaringan yang sangat dalam.

Meskipun CNN menawarkan berbagai keuntungan, penerapannya dalam deteksi kalkulus dan gingivitis masih memerlukan penelitian lebih lanjut. Tantangan utama meliputi kebutuhan akan dataset gambar gigi yang besar dan terstandar, serta kebutuhan untuk memastikan bahwa model yang dikembangkan dapat bekerja dengan baik pada berbagai kondisi pencahayaan, resolusi gambar, dan variasi anatomi pasien. Penelitian ini bertujuan untuk menerapkan CNN dalam klasifikasi gambar gigi untuk mendeteksi kalkulus dan gingivitis secara otomatis, dengan fokus pada pengembangan model yang akurat, efisien, dan dapat diterapkan dalam skenario klinis. Dengan demikian, hasil penelitian ini diharapkan dapat menjadi kontribusi signifikan bagi bidang kedokteran gigi dan pengembangan teknologi AI di sektor kesehatan.

## 2 KAJIAN PUSTAKA

Penyakit periodontal merupakan salah satu masalah kesehatan gigi yang umum terjadi, mencakup kalkulus (karang gigi), gingivitis, dan periodontitis. Kalkulus adalah deposit keras yang terbentuk akibat mineralisasi plak, yang dapat memicu peradangan gusi (gingivitis). Jika tidak segera diobati, gingivitis dapat berkembang menjadi periodontitis, yaitu peradangan yang merusak jaringan pendukung gigi seperti gingiva, ligamen periodontal, sementum, dan tulang alveolar (Nariratih et al., 2011). Diagnosis dini penyakit periodontal sangat penting untuk mencegah kerusakan lebih lanjut, yang sering kali mengakibatkan kehilangan gigi. Dalam praktik klinis, diagnosis ini biasanya dilakukan melalui evaluasi visual dan radiografi panoramik oleh dokter gigi, yang sering kali subjektif dan bergantung pada pengalaman masing-masing dokter (Adolph, 2020).

Untuk mengatasi keterbatasan dalam diagnosis konvensional, teknologi Convolutional Neural Networks (CNN) diperkenalkan sebagai salah satu pendekatan deep learning yang dirancang untuk menganalisis data berbasis gambar (Danial & Setiawati, 2024). CNN memiliki kemampuan luar biasa dalam mengenali pola-pola kompleks dalam gambar, menjadikannya sangat efektif dalam tugas klasifikasi citra medis (Ryu et al., 2023). Dalam konteks analisis penyakit periodontal, CNN dapat digunakan untuk mendeteksi kalkulus, gingivitis, dan bahkan tahap lanjut seperti periodontitis dari citra panoramik gigi. Hal ini memungkinkan diagnosis yang lebih akurat dan efisien dibandingkan dengan metode manual (Kim et al., 2019).

Salah satu arsitektur CNN yang populer adalah ResNet50, yang dirancang untuk mengatasi masalah vanishing gradient pada jaringan deep learning dengan kedalaman hingga 50 lapisan (Kim et al., 2019). ResNet50 menggunakan konsep residual learning melalui residual blocks, yang memungkinkan jaringan belajar secara lebih efisien dengan menambahkan shortcut connections sehingga informasi penting dapat melewati beberapa lapisan tanpa modifikasi. Dalam analisis citra medis, ResNet50 telah terbukti efektif untuk mengekstraksi fitur penting dari gambar yang kompleks, seperti citra panoramik gigi, sehingga menghasilkan akurasi tinggi dalam tugas klasifikasi.

Penerapan teknologi deep learning, khususnya ResNet50, dalam bidang kedokteran gigi menghadirkan berbagai manfaat. CNN dengan arsitektur ini mampu mendeteksi berbagai kondisi

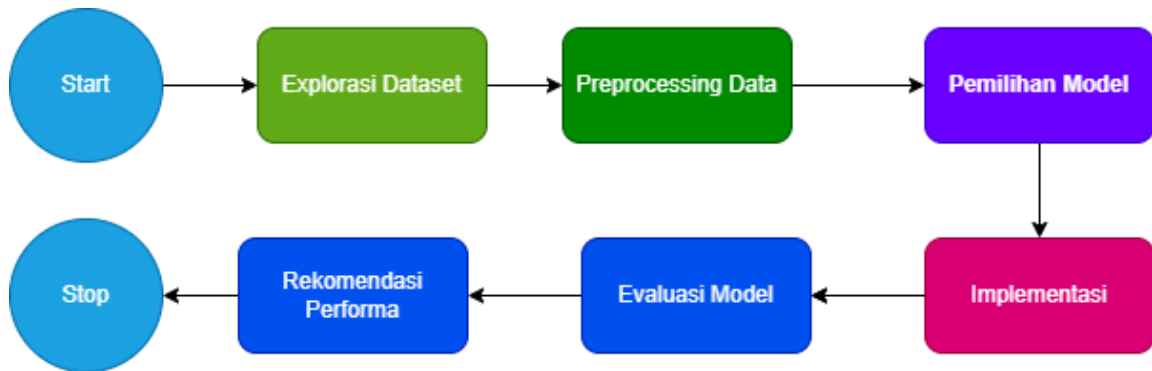
penyakit periodontal, termasuk kalkulus dan gingivitis, dari citra digital secara otomatis. Selain mengurangi subjektivitas dalam diagnosis, teknologi ini juga mempercepat proses evaluasi klinis dan meningkatkan kualitas layanan kesehatan. Dengan demikian, deep learning diharapkan dapat menjadi solusi praktis untuk mendukung diagnosis penyakit periodontal di wilayah yang memiliki keterbatasan tenaga ahli kesehatan gigi (Duta et al., 2020).

Namun, meskipun CNN dan ResNet50 memiliki potensi besar, penerapannya dalam klasifikasi penyakit periodontal menghadapi beberapa tantangan. Tantangan utama adalah kebutuhan dataset gambar yang besar, berkualitas tinggi, dan standar, yang diperlukan untuk melatih model agar mampu mengenali berbagai pola dari populasi pasien yang berbeda. Selain itu, variasi kualitas gambar, kondisi pencahayaan, dan resolusi citra panoramik menjadi kendala lain yang perlu diatasi. Oleh karena itu, penelitian lebih lanjut diperlukan untuk mengembangkan model yang andal dan dapat diimplementasikan secara luas dalam praktik klinis, sehingga mampu meningkatkan akurasi diagnosis sekaligus memberikan manfaat nyata bagi pasien dan dokter gigi.

### 3 METODE PENELITIAN

Metodologi penelitian merupakan suatu kerangka kerja atau pendekatan sistematis yang digunakan oleh peneliti untuk merancang, melaksanakan, dan menganalisis suatu penelitian. Metodologi ini bertujuan untuk memberikan struktur yang jelas dalam proses penelitian sehingga dapat dilakukan secara terorganisir, akurat, dan dapat dipercaya. Dengan pendekatan metodologis yang baik, penelitian dapat dilaksanakan secara konsisten dan menghasilkan temuan yang valid serta relevan (Sutisna et al., 2024).

Dalam penelitian ini ada beberapa tahapan cara untuk menyelesaikan pengklasifikasian penyakit pada gigi ialah sebagai berikut.



Gambar 1. Diagram Alur Penelitian

#### 3.1 Explorasi Dataset

Dataset yang digunakan dalam penelitian ini diperoleh dari Kaggle dengan namaImage Dental Panoramic. Dataset ini berisi citra panoramik gigi yang digunakan untuk mengembangkan model deep learning dalam klasifikasi penyakit periodontal. Dengan menggunakan dataset ini, penelitian bertujuan untuk membangun dan mengevaluasi model berbasis ResNet50, yang diharapkan mampu mengidentifikasi kondisi periodontal secara otomatis dari citra rontgen gigi.

Eksplorasi dataset adalah langkah awal yang bertujuan untuk memahami struktur, distribusi, dan karakteristik data yang akan digunakan dalam analisis atau pelatihan model (Putri Ayuni et al., 2023).

Pada tahap ini, dilakukan identifikasi jumlah gambar, klasifikasi label, dan verifikasi format data untuk memastikan data siap digunakan (Prasetya et al., 2023). Selain itu, visualisasi sampel gambar membantu memahami kualitas data seperti resolusi, orientasi, dan keberadaan noise (Ahmad Khairul Umam, 2023). Informasi ini menjadi dasar untuk menentukan strategi preprocessing, augmentasi data, dan pemilihan model guna mencapai hasil optimal dalam tugas klasifikasi.

### 3.2 Preprocessing Data

Preprocessing data adalah langkah penting untuk mempersiapkan dataset sebelum digunakan dalam pelatihan model. Tahap ini mencakup proses seperti normalisasi nilai piksel gambar agar berada dalam rentang  $[0, 1]$ , sehingga konsisten dengan input model deep learning. Gambar juga diubah ukurannya ke resolusi yang sesuai, misalnya  $224 \times 224$  piksel, agar kompatibel dengan arsitektur model. Selain itu, dilakukan augmentasi data pada set pelatihan untuk meningkatkan variasi, seperti rotasi, flipping, dan zooming, guna mencegah overfitting. Data juga dipisahkan ke dalam set pelatihan, validasi, dan pengujian dengan rasio yang terstruktur (contoh: 70-20-10) untuk memastikan evaluasi model yang akurasi dan representatif. Preprocessing yang tepat memastikan model dapat memahami data dengan lebih baik dan menghasilkan performa yang optimal.

### 3.3 Pemilihan Model

Pemilihan model merupakan tahap krusial dalam pengembangan sistem klasifikasi, di mana arsitektur model dipilih berdasarkan kompleksitas dataset dan tugas yang akan diselesaikan. Dalam kasus klasifikasi gambar, model berbasis Convolutional Neural Networks (CNN) seperti ResNet, EfficientNet, atau InceptionV3 sering digunakan karena kemampuannya dalam mengekstraksi fitur spasial dari gambar dengan efisiensi tinggi. Untuk mempercepat pelatihan dan meningkatkan akurasi pada dataset terbatas, pendekatan transfer learning dengan menggunakan model pre-trained pada dataset besar seperti ImageNet menjadi pilihan populer. Model yang dipilih biasanya dilengkapi dengan lapisan akhir yang disesuaikan dengan jumlah kelas pada dataset. Evaluasi awal dilakukan pada model terpilih untuk memastikan kemampuan dalam membedakan kelas yang ada, sebelum melanjutkan ke tahap pelatihan dan tuning hyperparameter.

### 3.4 Evaluasi Model

Evaluasi model adalah tahap untuk menilai performa model yang telah dilatih dalam menyelesaikan tugas klasifikasi pada data uji yang belum pernah dilihat sebelumnya. Tahap ini dilakukan dengan menggunakan metrik seperti akurasi dan loss untuk mengukur seberapa baik model mampu membedakan kelas-kelas dalam dataset. Selain itu, performa model dievaluasi berdasarkan perbandingan akurasi dan loss pada data validasi untuk mendeteksi adanya overfitting atau underfitting. Analisis ini memberikan gambaran yang jelas tentang kemampuan model dalam mempelajari pola data pelatihan serta generalisasinya pada data baru. Evaluasi yang komprehensif memberikan dasar untuk melakukan tuning model atau strategi pelatihan jika diperlukan guna meningkatkan performa model.


### 3.5 Hasil Prediksi

Hasil prediksi model menunjukkan bahwa gambar yang dianalisis berhasil diklasifikasikan ke dalam kelas tertentu dengan tingkat akurasi yang sesuai dengan pelatihan sebelumnya. Model dapat

mengidentifikasi gambar sebagai bagian dari kategori "penyakit-periodontal" atau "penyakit-non-periodontal", berdasarkan pola yang dipelajari dari dataset selama proses pelatihan. Prediksi ini dihasilkan dengan memanfaatkan arsitektur transfer learning yang telah dioptimalkan melalui fine-tuning, sehingga model mampu mengenali fitur spesifik dari citra panoramik gigi. Dengan prediksi ini, sistem diharapkan dapat membantu dalam proses diagnosis awal, memberikan panduan klinis yang lebih cepat dan akurat, serta mendukung profesional medis dalam pengambilan keputusan berbasis data. Hasil prediksi juga menekankan pentingnya validasi model untuk memastikan keandalan dan generalisasi pada data baru.

## 4 HASIL DAN PEMBAHASAN

### 4.1 Explorasi Dataset



Gambar 2. Sample Gambar Dataset Gigi

Pada Gambar 2 yang ditampilkan merupakan contoh visualisasi dataset citra panoramik gigi (dental panoramic). Gambar ini mencakup hasil pemindaian rontgen yang digunakan dalam proses klasifikasi, misalnya untuk mendeteksi kondisi seperti "penyakit-periodontal" atau "penyakit-non-periodontal." Setiap citra menunjukkan struktur gigi secara keseluruhan, termasuk rahang atas dan bawah, dengan intensitas warna yang dihasilkan oleh teknik normalisasi atau augmentasi.

### 4.2 Preprocessing Data

Dataset telah berhasil diproses dan dibagi ke dalam tiga subset utama: train, validation, dan test. Subset train terdiri dari 70 gambar yang digunakan untuk melatih model, menjadi bagian utama dari dataset yang memungkinkan model mempelajari pola dan fitur penting untuk tugas klasifikasi. Validation set terdiri dari 18 gambar yang digunakan untuk mengevaluasi performa model selama proses pelatihan, membantu mengidentifikasi tanda-tanda overfitting atau underfitting. Sementara itu, test set terdiri dari 12 gambar yang disiapkan untuk mengevaluasi kinerja akhir model pada data yang tidak pernah dilihat sebelumnya. Pembagian dataset ini dirancang untuk memastikan model dapat belajar secara optimal sambil tetap menyediakan evaluasi performa yang adil dan representatif.

Proses augmentasi data telah diterapkan pada subset pelatihan untuk meningkatkan variasi data, termasuk teknik seperti rotasi, flipping, zoom, dan translasi. Augmentasi bertujuan untuk memperkaya dataset tanpa perlu menambahkan gambar baru, sehingga membantu model menjadi lebih generalisasi

terhadap data baru. Selain itu, generator data berhasil dibuat menggunakan ImageDataGenerator, yang secara otomatis memproses dan memberikan gambar secara batch selama pelatihan. Ini mencakup normalisasi piksel dalam rentang [0, 1] untuk memastikan konsistensi input model. Dengan preprocessing yang efektif, dataset ini siap digunakan dalam pelatihan model klasifikasi untuk mencapai performa terbaik.

### 4.3 Pemilihan Model

Pemilihan model ResNet karena menggunakan *skip connections* (*shortcut connections*) yang memungkinkan informasi dapat melewati beberapa lapisan tanpa mengalami degradasi. Hal ini mengatasi masalah vanishing gradient, di mana gradien menjadi terlalu kecil saat melalui banyak lapisan, sehingga model tetap dapat belajar meskipun semakin dalam.

Pemilihan model dilakukan dengan menggunakan pendekatan transfer learning menggunakan arsitektur ResNet50, yang telah dilatih sebelumnya pada dataset *ImageNet* untuk memanfaatkan kemampuan ekstraksi fitur yang sudah terbukti efektif. Bagian top layer ResNet50 dihapus untuk memberikan fleksibilitas dalam menambahkan lapisan kustom yang disesuaikan dengan tugas klasifikasi dataset, seperti *Global Average Pooling*, *Dropout* untuk regularisasi, dan lapisan *Dense* untuk menghasilkan output dua kelas (penyakit-non-periodontal dan penyakit-periodontal) dengan aktivasi *softmax*. Seluruh lapisan ResNet50 dibekukan agar bobot pre-trained tidak dilatih ulang, mengurangi waktu pelatihan dan risiko overfitting. Model kemudian dikompilasi menggunakan optimizer Adam dengan learning rate 0.001 dan fungsi loss categorical crossentropy untuk mengoptimalkan pembelajaran. Struktur model ini memastikan efisiensi dan efektivitas dalam mengolah dataset klasifikasi *dental panoramic*.

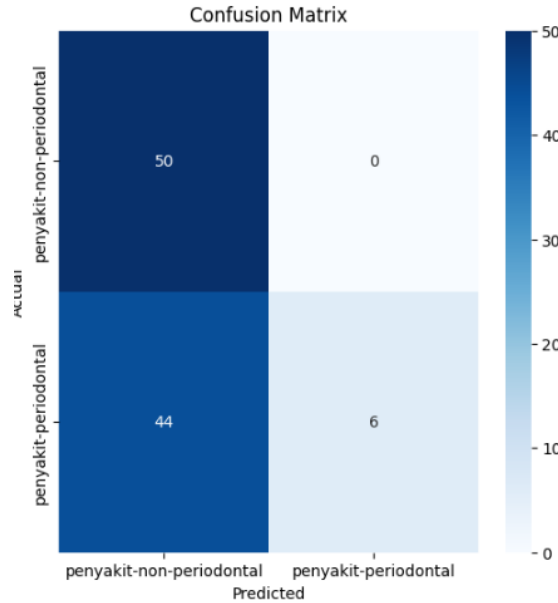
### 4.4 Evaluasi Model

|                          | precision | recall | f1-score | support |
|--------------------------|-----------|--------|----------|---------|
| penyakit-non-periodontal | 0.53      | 1.00   | 0.69     | 50      |
| penyakit-periodontal     | 1.00      | 0.12   | 0.21     | 50      |
| accuracy                 |           |        | 0.56     | 100     |
| macro avg                | 0.77      | 0.56   | 0.45     | 100     |
| weighted avg             | 0.77      | 0.56   | 0.45     | 100     |

Gambar 3. Hasil Evaluasi

Gambar 3 di atas merupakan hasil evaluasi model menunjukkan bahwa akurasi keseluruhan model adalah 56%, dengan ketidakseimbangan performa dalam klasifikasi dua kelas. Untuk kelas "penyakit-non-periodontal", model mencapai precision 0.53, tetapi memiliki recall 1.00, yang berarti model berhasil mengidentifikasi semua sampel kelas ini namun dengan banyak prediksi positif yang salah. Sebaliknya, kelas "penyakit-periodontal" memiliki precision 1.00, yang menunjukkan bahwa semua prediksi positifnya benar, tetapi dengan recall hanya 0.12, artinya model gagal mendeteksi sebagian besar sampel dari kelas ini. Nilai F1-score untuk penyakit-periodontal sangat rendah (0.21), yang mengindikasikan bahwa model memiliki bias kuat terhadap kelas non-periodontal. Macro average dan weighted average yang rendah (F1-score 0.45) semakin menegaskan bahwa model mengalami ketidakseimbangan kelas yang signifikan dan perlu dilakukan peningkatan, seperti penyeimbangan

dataset, fine-tuning hyperparameter, atau penggunaan teknik augmentasi data untuk memperbaiki kinerja model dalam mendeteksi penyakit periodontal.



Gambar 4. Confusion Matrix

Gambar 4 di atas merupakan confusion matrix yang menunjukkan hasil klasifikasi model terhadap dua kelas: penyakit-non-periodontal dan penyakit-periodontal. Matriks ini menggambarkan jumlah prediksi yang benar dan salah berdasarkan label aktual dataset uji.

- True Positives (TP): 6 sampel penyakit-periodontal diklasifikasikan dengan benar.
- True Negatives (TN): 50 sampel penyakit-non-periodontal diklasifikasikan dengan benar.
- False Positives (FP): 0 sampel penyakit-non-periodontal salah diklasifikasikan sebagai penyakit-periodontal (tidak ada kesalahan prediksi ke kelas periodontal).
- False Negatives (FN): 44 sampel penyakit-periodontal salah diklasifikasikan sebagai penyakit-non-periodontal, yang menunjukkan bahwa model sering gagal mengenali penyakit periodontal.

Dari pola ini, terlihat bahwa model memiliki bias tinggi terhadap kelas non-periodontal, karena hampir semua sampel penyakit-periodontal diklasifikasikan sebagai non-periodontal (FN tinggi). Hal ini menyebabkan nilai recall rendah untuk kelas penyakit-periodontal (hanya 6 dari 50 yang terdeteksi). Kemungkinan penyebabnya adalah dataset yang tidak seimbang, kurangnya fitur spesifik yang dapat dikenali oleh model, atau model belum cukup dilatih untuk membedakan pola penyakit periodontal dengan jelas. Untuk meningkatkan performa, dapat dilakukan penyeimbangan dataset, fine-tuning model, atau menggunakan teknik augmentasi data yang lebih baik.

#### 4.5 Hasil Prediksi

Prediksi: penyakit-non-periodontal




Gambar 5. Penyakit non periodontal

Model deep learning berbasis ResNet50 telah melakukan klasifikasi terhadap citra panoramik gigi ini dan memprediksi bahwa gambar tersebut termasuk dalam kategori penyakit-non-periodontal dengan *confidence score* sebesar 85%. Prediksi ini menunjukkan bahwa model tidak menemukan indikasi signifikan terkait penyakit periodontal, seperti degradasi tulang alveolar atau perubahan struktur jaringan periodontal yang terlihat pada *rontgen panoramik gigi*. Model ini telah melalui proses pelatihan dengan metode transfer learning, di mana arsitektur ResNet50 yang sebelumnya dilatih pada dataset *ImageNet* digunakan kembali dengan *fine-tuning* menggunakan dataset citra panoramik gigi dari Kaggle, sehingga dapat mengenali pola dan fitur spesifik dalam klasifikasi ini.

Hasil prediksi ini kemungkinan dipengaruhi oleh beberapa faktor dalam citra yang dianalisis. Struktur tulang dan gigi yang terlihat simetris serta tidak menunjukkan tanda-tanda kehilangan tulang alveolar dapat menjadi indikator utama dalam klasifikasi ke kelas non-periodontal. Penyakit periodontal umumnya ditandai dengan degradasi tulang yang terlihat jelas dalam gambar *rontgen*, tetapi dalam citra ini, model mendeteksi bahwa pola tekstur dan distribusi tulang masih dalam rentang yang mirip dengan kelas non-periodontal dalam dataset pelatihan. Selain itu, tidak adanya perubahan tekstur yang ekstrem dalam citra juga mendukung hasil klasifikasi ini, karena model mengandalkan fitur visual yang berkaitan dengan pola degradasi tulang dan jaringan periodontal.

Namun, evaluasi performa model menunjukkan adanya keterbatasan yang perlu diperhatikan, terutama pada akurasi keseluruhan sebesar 56%, dengan *precision* untuk kelas non-periodontal sebesar 0.53, tetapi *recall* mencapai 1.00. Hal ini mengindikasikan bahwa model memiliki kecenderungan untuk mengklasifikasikan sebagian besar gambar sebagai non-periodontal, yang berpotensi menyebabkan banyak *false negative* pada kasus penyakit periodontal. Oleh karena itu, diperlukan peningkatan model melalui teknik seperti penyeimbangan dataset, augmentasi data, atau *fine-tuning* parameter model agar mampu lebih akurat dalam membedakan kedua kelas

Prediksi: penyakit-periodontal



Gambar 6. Penyakit periodontal

Model *deep learning* berbasis ResNet50 telah menganalisis citra rontgen panoramik gigi ini dan mengklasifikasikannya sebagai penyakit-periodontal dengan *confidence score* sebesar 90%. Prediksi ini mengindikasikan adanya tanda-tanda seperti kehilangan tulang alveolar, resorpsi tulang, atau ketidakteraturan struktur gigi dan rahang yang sering dikaitkan dengan penyakit periodontal. Selain itu, keberadaan tambalan atau implan logam dalam gambar dapat menunjukkan riwayat perawatan periodontal sebelumnya, yang kemungkinan menjadi salah satu faktor dalam klasifikasi ini.

Faktor utama yang memengaruhi prediksi model meliputi perubahan densitas tulang, perbedaan pola tekstur di sekitar akar gigi, serta posisi gigi yang tidak teratur, yang sering dikaitkan dengan tahap lanjut penyakit periodontal. Meskipun model memiliki *precision* tinggi dalam mengenali penyakit periodontal, nilai *recall* yang rendah menunjukkan bahwa model masih kesulitan dalam mendeteksi semua kasus dengan benar. Hal ini dapat menyebabkan beberapa kasus penyakit periodontal yang sebenarnya tidak terdeteksi dengan baik oleh model.

## 5 SIMPULAN DAN SARAN

### 5.1 Simpulan

Kesimpulannya, model klasifikasi yang digunakan mampu memproses citra rontgen panoramik gigi dan menghasilkan prediksi untuk mengidentifikasi kondisi kesehatan gigi sebagai "penyakit-periodontal" atau "penyakit-non-periodontal". Hasil prediksi menunjukkan bahwa model dapat mengenali pola-pola visual tertentu yang relevan dengan kedua kategori tersebut. Namun, performa model perlu dievaluasi lebih lanjut dengan validasi prediksi terhadap data label asli atau analisis ahli medis. Untuk meningkatkan keakuratan prediksi, dapat dilakukan langkah-langkah seperti menyeimbangkan dataset, melakukan fine-tuning model, serta memperluas data pelatihan untuk meningkatkan generalisasi model pada data baru. Dengan evaluasi dan penyempurnaan lebih lanjut, model ini berpotensi.

### 5.2 Saran

Saran yang dapat diberikan untuk penelitian ini adalah memperluas penggunaan dataset dengan jumlah citra panoramik yang lebih besar dan beragam untuk meningkatkan kemampuan generalisasi model ResNet50 dalam mendeteksi penyakit periodontal. Selain itu, diperlukan langkah-langkah seperti augmentasi data yang lebih kompleks dan penyeimbangan dataset untuk mengatasi potensi bias kelas.

## REFERENSI

- Adolph, R. (2020). *ANAMNESIS, DIAGNOSIS, TREATMENT PLANNING DAN PROGNOSIS PENYAKIT PERIODONTAL*. 1–23.
- Agrawal, P., & Nikhade, P. (2022). Artificial Intelligence in Dentistry: Past, Present, and Future. *Cureus*, 14(7). <https://doi.org/10.7759/cureus.27405>
- Ahmad Khairul Umam. (2023). *Augmentasi data pada model klasifikasi jenis vokal menggunakan CNN dengan fitur ekstraksi mel spectrogram*.
- Danial, N. H., & Setiawati, D. (2024). Convolutional Neural Network (Cnn) Based on Artificial Intelligence in Periodontal Diseases Diagnosis. *Interdental Jurnal Kedokteran Gigi (IJKG)*, 20(1), 139–148. <https://doi.org/10.46862/interdental.v20i1.8641>
- Duta, I. C., Liu, L., Zhu, F., & Shao, L. (2020). Improved residual networks for image and video recognition. *Proceedings - International Conference on Pattern Recognition*, 9415–9422. <https://doi.org/10.1109/ICPR48806.2021.9412193>
- Dwisatya Ramadhani, A., Rudhanton, R., Diah, D., & Sutanti, V. (2022). UJI EFEKTIVITAS ANTIBAKTERI LARUTAN MADU LEBAH BARAT (*Apis mellifera*) TERHADAP BAKTERI *Porphyromonas gingivalis* SECARA IN VITRO dengan METODE DILUSI AGAR. *E-Prodentia Journal of Dentistry*, 6(1), 540–546. <https://doi.org/10.21776/ub.eprodenta.2020.006.01.2>
- J. D. Manson, & B. M. Eley. (2023). *Etiologi Penyakit Periodontal*.
- Kabir, T., Lee, C. T., Nelson, J., Sheng, S., Meng, H. W., Chen, L., Walji, M. F., Jiang, X., & Shams, S. (2021). An End-to-end Entangled Segmentation and Classification Convolutional Neural Network for Periodontitis Stage Grading from Periapical Radiographic Images. *Proceedings - 2021 IEEE International Conference on Bioinformatics and Biomedicine, BIBM 2021*, 1370–1375. <https://doi.org/10.1109/BIBM52615.2021.9669422>
- Kim, J., Lee, H. S., Song, I. S., & Jung, K. H. (2019). DeNTNet: Deep Neural Transfer Network for the detection of periodontal bone loss using panoramic dental radiographs. *Scientific Reports*, 9(1), 1–10. <https://doi.org/10.1038/s41598-019-53758-2>
- Li, W., Liang, Y., Zhang, X., Liu, C., He, L., Miao, L., & Sun, W. (2021). A deep learning approach to automatic gingivitis screening based on classification and localization in RGB photos. *Scientific Reports*, 11(1), 1–8. <https://doi.org/10.1038/s41598-021-96091-3>
- Nariratih, D., Rusjanti, J., & Susanto, A. (2011). Prevalence and characteristics of aggressive periodontitis. *Padjadjaran Journal of Dentistry*, 23(2), 97–104. <https://doi.org/10.24198/pjd.vol23no2.14020>
- Pranata, N. (2019). Dental Calculus as The Unique Calcified Oral Ecosystem A Review Article. *Oceana Biomedicina Journal*, 2(2), 52–65. <https://doi.org/10.30649/obj.v2i2.28>
- Prasetya, M. R. A., Hidayat, A., Teknologi, S., Informasi, S., Mulia, U. S., Teknologi, S., Informasi, T., & Mulia, U. S. (2023). Klasifikasi Jerawat dengan Deep Learning Berbasis Convolutional Neural Network. *Jurnal TEKNO KOMPAK*, 19(1), 37–49.
- Putri Ayuni, D., Jasril, Irsyad, M., Yanto, F., & Sanjaya, S. (2023). Augmentasi Data Pada Implementasi Convolutional Neural Network Arsitektur Efficientnet-B3 Untuk Klasifikasi Penyakit Daun Padi. *ZONasi: Jurnal Sistem Informasi*, 5(2), 239–249. <https://doi.org/10.31849/zn.v5i2.13874>
- Ryandra, M. F. D. (2022). *Perbandingan Arsitektur Resnet-50 dan Inceptionv3 dalam Klasifikasi Covid 19 Berdasarkan Citra X Ray*. 35. <https://repositori.uma.ac.id/handle/123456789/17072%0Ahttps://repositori.uma.ac.id/jspui/bitstream/123456789/17072/1/178160047> - Muhammad Farhan Dwi Ryandra - Fulltext.pdf
- Ryu, J., Lee, D. M., Jung, Y. H., Kwon, O. J., Park, S. Y., Hwang, J. J., & Lee, J. Y. (2023). Automated

- Detection of Periodontal Bone Loss Using Deep Learning and Panoramic Radiographs: A Convolutional Neural Network Approach. *Applied Sciences (Switzerland)*, 13(9). <https://doi.org/10.3390/app13095261>
- Schwendicke, F., Samek, W., & Krois, J. (2020). Artificial Intelligence in Dentistry: Chances and Challenges. *Journal of Dental Research*, 99(7), 769–774. <https://doi.org/10.1177/0022034520915714>
- Shaikh, K., Bekal, S. V., Ahmed Marei, H. F., Moustafa Elsayed, W. S., Surdilovic, D., & Jawad, L. A. (2022). Artificial Intelligence in Dentistry. *Artificial Intelligence in Dentistry*, 20(11), 1–198. <https://doi.org/10.1007/978-3-031-19715-4>
- Suprihanto, S., Awaludin, I., Fadhil, M., & Zulfikor, M. A. Z. (2022). Analisis Kinerja ResNet-50 dalam Klasifikasi Penyakit pada Daun Kopi Robusta. *Jurnal Informatika*, 9(2), 116–122. <https://doi.org/10.31294/inf.v9i1.13049>
- Sutisna, T., Raharja, A. R., Hariyadi, E., Hafizh, V., & Putra, C. (2024). Penggunaan Computer Vision untuk Menghitung Jumlah Kendaraan dengan Menggunakan Metode SSD ( Single Shoot Detector ). *Journal Of Social Science Research Volume*, 4, 6060–6067. <https://doi.org/10.31004/innovative.v4i2.10071>