

Pengembangan Model CNN ResNet-18 untuk Klasifikasi Kondisi Gigi Berbasis Citra RGB sebagai Solusi Diagnostik Digital

Gabriel Mediose Alfranda Sihotang¹, Julian Supardi^{*2}

^{1,2}Magister Ilmu Komputer, Fakultas Ilmu Komputer, Universitas Sriwijaya, Indonesia
Email: ¹gabrielmediose88@gmail.com, ²dprmlab2020@gmail.com

Abstrak

Penelitian ini menggunakan model CNN ResNet-18 untuk klasifikasi kondisi gigi berbasis citra RGB dengan empat kategori: *Calculus*, *Caries*, *Gingivitis*, dan *Tooth Discoloration*. Data diambil dari dataset Oral Diseases. Teknik preprocessing mencakup Resize, Center Crop, dan Normalization. Model dilatih menggunakan optimizer Adam dengan learning rate 0.001 dan 50 epoch. Tujuan penelitian menggunakan Residual Network-18 untuk melakukan klasifikasi kondisi gigi *Gingivitis*, *Calculus*, *Karies*, dan *Tooth Discoloration* yang menggunakan data dari dataset Oral Diseases. Tahapan *preprocessing* mencakup *Resize*, *Center Crop*, *Random Resized Crop*, *Random Horizontal Flip*, *Random Rotation*, *ToTensor*, dan *Normalization*. Model dilatih dengan *Hyperparameter optimizer Adam*, *Learning Rate 0.0001*, *Epochs 50*, dan *Batch Size 16*. Hasil evaluasi model mencatat bahwa model mendapatkan performa akurasi tinggi pada kelas *Caries* 97% dan kelas *Tooth Discoloration* 96%. Namun performa akurasi yang lebih rendah pada kelas *Gingivitis* 88% dan kelas *Calculus* 78%. Penelitian ini memberikan kontribusi pada efisiensi diagnostik gigi dengan mengurangi ketergantungan pada X-Ray.

Kata kunci: CNN, Diagnostik Digital, Klasifikasi Gigi, ResNet-18

Development of CNN ResNet-18 Model for RGB Image-Based Dental Condition Classification as a Digital Diagnostic Solution

Abstract

This study used the CNN ResNet-18 model for the classification of dental conditions based on RGB images with four categories: *Calculus*, *Caries*, *Gingivitis*, and *Tooth Discoloration*. Data were taken from the Oral Diseases dataset. Preprocessing techniques include *Resize*, *Center Crop*, and *Normalization*. The model was trained using Adam's optimizer with a learning rate of 0.001 and 50 epochs. The purpose of the study was to use Residual Network-18 to classify the condition of *Gingivitis*, *Calculus*, *Cares*, and *Tooth Discoloration* using data from the Oral Diseases dataset. The preprocessing stages include *Resize*, *Center Crop*, *Random Resized Crop*, *Random Horizontal Flip*, *Random Rotation*, *ToTensor*, and *Normalization*. The model was trained with Adam Hyperparameter optimizer, *Learning Rate 0.0001*, *Epochs 50*, and *Batch Size 16*. The results of the model evaluation noted that the model obtained high accuracy performance in the *Caries* class of 97% and the *Tooth Discoloration* class of 96%. However, the accuracy performance was lower in the *Gingivitis* class of 88% and the *Calculus* class of 78%. This research contributes to the efficiency of dental diagnostics by reducing the dependence on X-Ray.

Keywords: CNN, Dental Classification, Digital Diagnostics, ResNet-18

1. PENDAHULUAN

Kondisi Gigi seperti *Calculus*, *Caries*, *Gingivitis*, dan *Tooth Discoloration* adalah masalah kesehatan gigi yang sering dijumpai dengan prevelensi tinggi pada kalangan masyarakat. Hal ini disebabkan oleh kurangnya kesadaran atau pengetahuan bagaimana perawatan gigi yang baik[1]. *Calculus* disebabkan oleh lapisan kotoran yang menempel dan tidak dibersihkan pada gigi sehingga menyebabkan penumpukan plak[2]. *Caries* merupakan kondisi gigi paling umum dengan prevalensi 80% terjadi di Indonesia terutama terjadi pada anak-anak dan juga bisa terjadi pada orang dewasa[3]. *Caries* disebabkan oleh plak yang telah lama menempel pada gigi, kemudian merusak enamel gigi[4]. *Gingivitis* adalah peradangan pada gusi yang disebabkan oleh penumpukan plak, namun menyebabkan peradangan dan pendarahan gusi[5]. *Tooth Discoloration* atau perubahan warna gigi akibat

konsumsi makanan atau minuman yang mengandung pewarna, penggunaan obat-obatan dan kebiasaan merokok[6].

Untuk mengetahui kondisi gigi secara detail maka, dibutuhkan teknologi Dental X-Ray yang digunakan dalam kedokteran gigi dalam mendiagnosis berbagai kondisi gigi. Akan tetapi Namun penggunaan alat ini masih mengalami banyak kekurangan, salah satunya resiko misdiagnosis melalui proses *screening* atau keterbatasan interpretasi gambar X-Ray[7]. Penelitian Danial et al [8], juga mengatakan bahwa pada saat pembacaan gambar X-Ray, para medis mengalami misdiagnosis atau kekeliruan oleh tingkat pengetahuan terutama kasus gigi pasien yang kompleks[9]. Selain itu kekurangan lainnya pada masalah biaya pemeriksaan yang mahal serta proses administrasi yang lamban. Hal inilah yang menjadi hambatan pasien dalam memeriksa kesehatan gigi serta perawatan[8]. Alat X-Ray ini juga memiliki resiko paparan radiasi dengan dosis tinggi dan berpotensi menurunkan kesehatan tubuh seseorang dalam jangka panjang, diantaranya penyakit kanker [10], [11].


Untuk mempermudah pihak medis terutama dokter gigi dalam pembacaan hasil X-ray maka diperlukan suatu algoritma yaitu penerapan Deep Learning dengan menggunakan CNN. Deep Learning merupakan cabang machine learning yang memiliki konsep seperti jaringan saraf manusia dengan lapisan neuron yang terhubung, salah satunya adalah *Convolutional Neural Network* (CNN) yang dirancang khusus dalam pemrosesan data berbentuk gambar dan efektif dalam tugas klasifikasi gambar, termasuk untuk diagnosis kondisi gigi [12], [13].

ResNet-18 merupakan salah satu model *Convolutional Neural Network* (CNN) dirancang untuk mengatasi vanishing gradients pada jaringan deep learning. ResNet-18 memiliki ciri khas menggunakan residual blocks untuk memfasilitasi kompleksitas pembelajaran agar lebih baik saat proses pelatihan model. Studi yang dilakukan oleh Lee et al[14], mengatakan ResNet-18 bisa mencapai tingkat akurasi lebih dari 98% untuk klasifikasi kondisi gigi dari radiograf dibandingkan menggunakan arsitektur AlexNet dan VGG. Selain itu penelitian Mishra et al [15] menyebutkan integrasi data augmentasi bisa meningkatkan kinerja ResNet-18 untuk klasifikasi citra gigi. Kemudian interpretabilitas prediksi ResNet-18 mendapatkan keuntungan signifikan dengan teknik Grad-Cam dalam melakukan visualisasi area prediksi gambar sehingga dapat membangun kepercayaan dokter untuk diagnostik secara efektif[16].

Ditinjau dari uraian permasalahan di atas, penelitian ingin mencoba membuat suatu pengembangan *deep learning* berbasis CNN menggunakan arsitektur ResNet-18 untuk klasifikasi kondisi gigi *Gingivitis*, *Calculus*, *Karies*, dan *Tooth Discoloration* dengan harapan model yang diusulkan dalam melakukan pelatihan data dapat memperoleh hasil klasifikasi dengan tingkat akurasi yang baik, dan dapat menjadi bahan pertimbangan medis dan ketepatan diagnosis kondisi gigi.

2. METODE PENELITIAN

Proses klasifikasi kondisi gigi, ada beberapa tahapan metode penelitian agar berjalan terstruktur mengikuti alur, berikut adalah tahapan penelitian yang diperlihatkan pada Gambar 1 :




Gambar 1. Tahapan Penelitian

2.1. Pengumpulan Data

Data yang dikumpulkan untuk penelitian klasifikasi kondisi gigi menggunakan data sekunder yang didapatkan dari website kaggle dengan nama ‘*Oral Diseases*’, terdiri dari kumpulan gambar kondisi gigi format RGB dengan kualitas yang cukup bagus. Namun penelitian ini hanya memakai kondisi gigi *Calculus*, *Caries*, *Gingivitis*, dan *Tooth Discoloration* dengan total keseluruhan berjumlah 4.735 data. Data sekunder yang telah di kumpulkan dibagi menggunakan teknik split validation dengan membagi secara acak menjadi sub-folder *data training*, *data validation*, dan *data testing* sesuai dengan kebutuhan penelitian agar dapat diproses ke tahapan selanjutnya.

2.2. Preprocessing Data

Data yang telah dikumpulkan sebelumnya perlu dilakukan *preprocessing* dengan mengubah atau memodifikasi gambar. *Preprocessing* Data mencakup *Resize*, *Center Crop*, *Random Resized Crop*, *Random Horizontal Flip*, *Random Rotation*, *To Tensor*, *Normalize*. Tahapan *preprocessing* bertujuan untuk memastikan konsistensi dan optimalisasi gambar sebelum pelatihan model[17]. Berikut adalah tahapan *preprocessing* dapat dilihat pada Gambar 2.

Gambar 2. Tahapan *Preprocessing* Data

Tahapan pertama *Resize* adalah melakukan pengukuran dimensi gambar agar model memproses gambar dengan ukuran yang sama[18]. Tahapan kedua adalah *Center Crop* berfokus pada bagian gambar relevan dengan membuang area tertentu yang tidak diperlukan[19]. Tahapan ketiga adalah *Random Resized Crop* untuk memotong gambar secara acak dengan ukuran yang berbeda agar model mempelajari variasi perspektif gambar[20]. Tahapan keempat *Random Horizontal Flip* digunakan untuk membalik gambar secara acak agar model bisa mengenali pola dengan orientasi yang berbeda[21]. Tahapan kelima *Random Rotation* digunakan untuk memutar gambar secara acak agar model mampu mengenali berbagai macam sudut pandang[22]. Tahapan keenam adalah konversi gambar menjadi format *ToTensor* agar mendapatkan efisiensi pemrosesan di GPU selama masa pelatihan model[23]. Tahapan ketujuh *Normalization* digunakan untuk memastikan rentang nilai piksel gambar ke skala yang sama serta berguna untuk mempercepat konvergensi serta stabilitas selama masa pelatihan[24].

2.3. Perancangan Model

Model CNN yang diusulkan untuk klasifikasi kondisi gigi *Calculus*, *Caries*, *Gingivitis*, dan *Tooth Discoloration* adalah *Residual Network-18 (ResNet-18)*. Selama proses pelatihan menggunakan model ini akan memasuki beberapa tahapan sampai pada hasil keluaran dari model ini. Berikut adalah usulan tahapan model CNN arsitektur *Residual Network-18 (ResNet-18)* dapat dilihat pada tabel 3.


Tabel 1. Usulan parameter model arsitektur *Residual Network-18 (ResNet-18)*

Layer (type)	Output Shape
Conv2d	[-1, 64, 64, 64]
BatchNorm2d	[-1, 64, 64, 64]
ReLU	[-1, 64, 64, 64]
MaxPool2d	[-1, 64, 32, 32]
Conv2d	[-1, 64, 32, 32]
BatchNorm2d	[-1, 64, 32, 32]
ReLU	[-1, 64, 32, 32]
Conv2d	[-1, 64, 32, 32]
BatchNorm2d	[-1, 64, 32, 32]
ReLU	[-1, 64, 32, 32]
BasicBlock	[-1, 64, 32, 32]
Conv2d	[-1, 128, 16, 16]
BatchNorm2d	[-1, 128, 16, 16]
ReLU	[-1, 128, 16, 16]
Conv2d	[-1, 128, 16, 16]
BatchNorm2d	[-1, 128, 16, 16]
ReLU	[-1, 128, 16, 16]
BasicBlock	[-1, 128, 16, 16]
Conv2d	[-1, 256, 8, 8]
BatchNorm2d	[-1, 256, 8, 8]
ReLU	[-1, 256, 8, 8]
Conv2d	[-1, 256, 8, 8]
BatchNorm2d	[-1, 256, 8, 8]
ReLU	[-1, 256, 8, 8]
BasicBlock	[-1, 256, 8, 8]
Conv2d	[-1, 512, 4, 4]
BatchNorm2d	[-1, 512, 4, 4]
ReLU	[-1, 512, 4, 4]
Conv2d	[-1, 512, 4, 4]

Penjelasan tabel 3 merangkum parameter arsitektur model ResNet-18 saat melakukan proses pelatihan model. Proses dimulai dengan layer Conv2D untuk mengekstraksi fitur dari inputan gambar kondisi gigi seperti tepi dan tekstur gambar. Lapisan BatchNorm2d berfungsi untuk menjaga kestabilan distribusi output dan mempercepat pelatihan model, sementara fungsi ReLU untuk mengubah nilai negatif menjadi nol, dan nilai positif tetap dipertahankan, hal ini agar model dapat menangkap pola yang tidak dapat ditangani oleh transformasi linear, sehingga dapat meningkatkan kemampuan memahami data kompleks. Blok Residual atau Basic Block berfungsi untuk melakukan lompatan antar lapisan agar dapat mempertahankan informasi dari proses pelatihan sebelumnya. Jumlah filter akan bertambah seiring pelatihan dari 64 hingga 512 pada dimensi gambar sehingga menjadi lebih kompleks untuk pembelajaran fitur.

2.4. Model Arsitektur *Residual Network* -18

Algoritma pada penelitian klasifikasi kondisi gigi menggunakan model CNN dengan arsitektur *Residual Network-18* yang diusulkan. Arsitektur ini memiliki ciri khas pada *residual block* dalam model. Dalam proses pelatihan model, gambar kondisi gigi akan melewati beberapa tahapan proses agar mendapatkan hasil keluaran berupa kondisi gigi. Berikut adalah gambar 3 untuk tahapan arsitektur *Residual Network* -18



Gambar 3. Ilustrasi Arsitektur *Residual Network*-18

Pada gambar 3. Ilustrasi proses secara garis besar dimulai dari input gambar kondisi gigi misalnya *Tooth Discoloration* dengan ukuran citra 128x128 piksel, setelah itu melewati lapisan blok konvolusi dengan filter 64, 128, 256, 512. Lapisan *MaxPooling* berfungsi untuk mereduksi dimensi gambar serta mengurangi ukuran gambar. *Residual Connections* terhubung di setiap lapisan berfungsi membantu dalam mengatasi masalah *vanishing gradients* selama proses pelatihan. Setelah itu *Average Pooling* akan menghitung rata-rata dari keseluruhan pooling, hal ini akan membantu mengurangi parameter serta mencegah overfitting. Lapisan *Fully Connected Layer* menghubungkan neuron agar memberikan hasil keluaran prediksi kondisi gigi, misalnya adalah *Tooth Discoloration*.

2.5. Pelatihan Model

Pelatihan model akan menggunakan data training untuk mengenali pola dan fitur. Model akan memproses citra RGB kondisi gigi dengan cara ekstraksi fitur melalui lapisan konvolusi, kemudian pada akhirnya menciptakan hasil prediksi. Terdapat proses *Forward Propagation* yaitu input akan bergerak melalui jaringan untuk menghasilkan output, selanjutnya *Backward Propagation* akan menghitung *loss* selisih antara hasil prediksi. Proses ini juga akan mengirimkan gradien balik ke jaringan untuk pembaharuan bobot agar hasil prediksi dapat mengalami peningkatan. *Hyperparameter* dalam pelatihan model juga perlu ditambahkan dengan memberi *Optimizer*, *Epoch*, *Learning rate*, dan *Batch Size* agar selama masa pelatihan model menghasilkan performa optimal dan mencapai hasil terbaik untuk klasifikasi kondisi gigi. Berikut adalah *Hyperparameter* dalam pelatihan model dapat dilihat pada Tabel 4.

Tabel 2. Hyperparameter Pelatihan Model

Hyperparameter	Value
<i>Optimizer</i>	Adam
<i>Epochs</i>	50
<i>Learning rate</i>	0.001
<i>Batch size</i>	16

2.6. Evaluasi Model

Pada proses tahapan evaluasi model akan diuji menggunakan data testing yang terpisah agar memberikan kesan objektif terkait kemampuan model pada saat generalisasi data baru kemudian hasil dari pengujian akan dilakukan analisis berdasarkan metrik yang relevan dengan tugas klasifikasi. Metrik-metrik yang akan digunakan untuk mengevaluasi model klasifikasi kondisi gigi menggunakan *confussion matrix* meliputi Akurasi, Presisi, Recall, dan F1-Score. Akurasi digunakan untuk melihat hasil kinerja model klasifikasi dengan menghitung jumlah prediksi benar dan total keseluruhan sampel prediksi[25]. Presisi mengukur prediksi positif yang benar bahwa model memprediksi kondisi gigi dengan kemungkinan prediksi itu benar, sedangkan Recall untuk mengukur seberapa baik model memberikan prediksi positif yang benar dari semua kelas[26]. Fi-Score bertujuan untuk melihat keseimbangan hasil antara Presisi dan Recall[27]. Hal ini memberikan perspektif sejauh mana model membuat prediksi dalam berbagai kondisi gigi. Untuk menghitung metrik dapat dilakukan dengan persamaan dengan rumus sebagai berikut[28][29].

Keterangan:

TP = Data positif yang terklasifikasi benar

TN = Data negatif yang terklasifikasi benar

FP = Data positif yang terklasifikasi salah

FN = Data negatif yang terklasifikasi salah

$$\text{Akurasi} = \frac{\text{Jumlah Prediksi Benar}}{\text{Total Jumlah Sampel}} \quad (1)$$

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

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

$$f1 \text{ Score} = 2 \cdot \frac{\text{Presisi} * \text{Recall}}{\text{Presisi} + \text{Recall}} \quad (4)$$

3. HASIL

3.1. Pengumpulan Data

Total keseluruhan berjumlah 4.735 Data terdiri dari kondisi gigi *Calculus*, *Caries*, *Gingivitis*, dan *Tooth Discoloration*. Setiap kelas memiliki data dengan jumlah yang berbeda. Kemudian menggunakan *split validation* dengan membagi data *training* 72%, *validation* 18%, dan *testing* 10%. Berikut adalah Tabel 1 jumlah keseluruhan data serta pembagian data yang dikumpulkan dan Tabel 2. untuk sampel gambar kondisi gigi.

Tabel 3. Keseluruhan data dan pembagian data

Kondisi Gigi	Training	Validation	Testing
<i>Calculus</i>	932	234	130
<i>Caries</i>	1713	429	238
<i>Gingivitis</i>	788	198	110
<i>Tooth Discoloration</i>	1320	330	184

Tabel 4. Visualisasi Kondisi Gigi



3.2. Preprocessing Data

Data yang telah dikumpulkan masuk ke dalam tahapan *preprocessing* dengan menggunakan teknik augmentasi *Rezize*, *Center Crop*, *Random Rezize Crop*, *Random Horizontal Flip*, *Random Rotation*, *ToTensor*,

Normalization. Berikut adalah sampel dari kondisi gigi untuk memperlihatkan visualisasi hasil *preprocessing* data yang dapat dilihat pada Gambar 3.

```
image_size = 128
train_transforms = transforms.Compose([
    transforms.Resize(image_size),
    transforms.CenterCrop(image_size),
    transforms.RandomResizedCrop(image_size, scale=(0.8, 1.0)),
    transforms.RandomHorizontalFlip(),
    transforms.RandomRotation(10),
    transforms.ToTensor(),
    transforms.Normalize([0.485, 0.456, 0.406], [0.229, 0.224, 0.225]),
```




Gambar 4. Hasil *Preprocessing* Data Kondisi Gigi *Calculus*, *Caries*, *Gingivitis*, dan *Tooth Discoloration*

Pada Gambar 3. memperlihatkan sampel tahapan *preprocessing*. Untuk hasil *Rezize* mengubah dimensi gambar menjadi 128x128 piksel, *Center Crop* memotong gambar ke bagian tengah dengan ukuran 128x128 piksel, *Random Resized Crop* mengubah dimensi gambar secara acak menjadi 128x128 piksel dengan skala pemotongan diatur sebesar 80% sampai 100% dari dimensi citra. *Random Horizontal Flip* membalik gambar sehingga menciptakan variasi gambar. *Random Rotation* memutar gambar secara acak hingga 10 derajat. *ToTensor* mengkonversikan gambar ke format PyTorch agar gambar diubah menjadi rentang [0,1]. *Normalization* melakukan penormalan dimensi warna RGB dari [0.485, 0.456, 0.406] menjadi [0.229, 0.224, 0.225] agar membantu penyelarasan model yang dilatih.

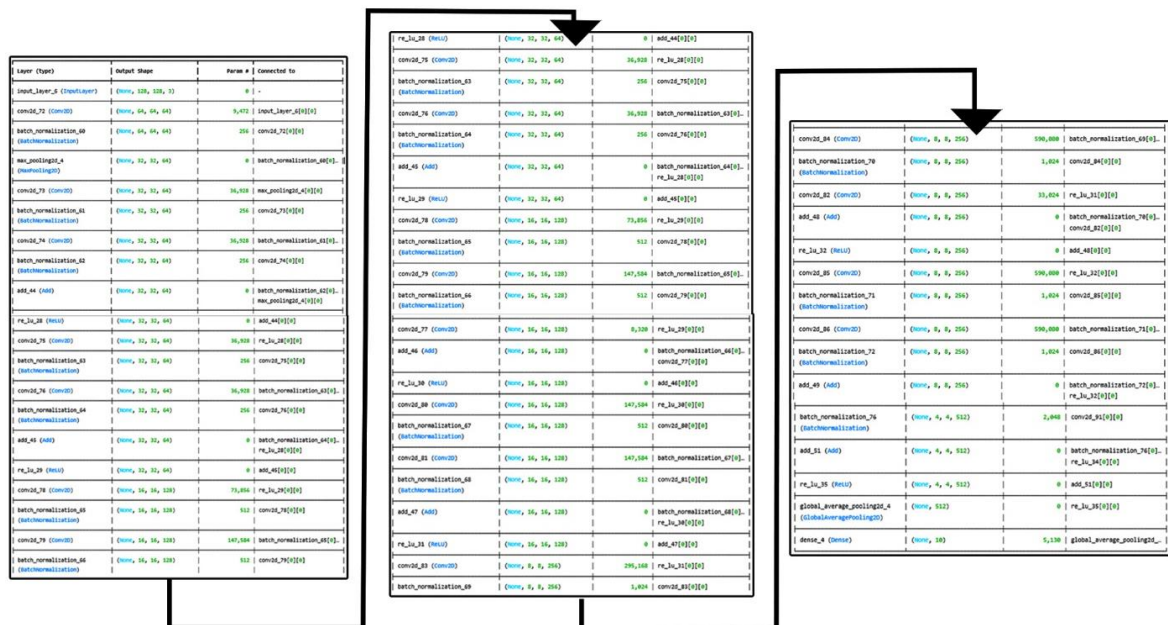
3.3. Model Arsitektur *Residual Network -18*

Model yang dipakai untuk klasifikasi kondisi gigi *Calculus*, *Caries*, *Gingivitis*, dan *Tooth Discoloration* adalah *Residual Network-18*. Model ini dimulai dari input layer sebagai data masukan kondisi gigi, dimensi input sebesar 128x128 piksel dengan dimensi warna RGB (*Red*, *Green*, *Blue*). Lapisan Konvolusi akan melakukan ekstraksi fitur dari gambar, ini melibatkan kernel matriks, representasi gambar yang dihasilkan. *Batch Normalization* akan menormalkan hasil dari lapisan sebelumnya agar distribusi berada pada rentang [0,1] dan bisa mempercepat kinerja serta kestabilan model dengan pengurangan *vanishing gradients*. *ReLU (Rectified Linear Unit)* diberikan untuk memberikan fungsi nonlinearitas dalam jaringan neuron, sehingga model mempelajari secara kompleks dalam data. *MaxPooling2D* atau *Down-Sampling* digunakan untuk mengurangi dimensi fitur dan mempertahankan fitur yang lebih relevan. Ciri khas *Residual Networks -18* adalah *Residual Blocks* yang bertujuan menambahkan hasil keluaran dari satu lapisan ke lapisan lainnya, hal ini mempermudah pelatihan model klasifikasi kondisi gigi. Lapisan *Flatten* akan melakukan konversi matriks 2D menjadi vektor 1D agar dapat di proses oleh *Fully Connected*. *Dense Layer* atau *Fully Connected* akan memberikan neuron berdasarkan keputusan dari fitur yang telah diekstraksi, dan menciptakan klasifikasi kondisi gigi. Berikut adalah Gambar 4. Model *CNN Residual Network -18* dapat dilihat dibawah ini.



Gambar 5. Model CNN Residual Network – 18

Pada Gambar 5. Adalah detail parameter arsitektur *Residual Network-18* yang telah diusulkan untuk klasifikasi kondisi gigi. Model ini menggunakan berbagai lapisan dan terhubung ke masing-masing lapisan lainnya untuk proses dan klasifikasi gambar.




Gambar 6. Detail Model CNN Residual Network – 18.

3.4. Pelatihan Model

Pelatihan model dengan menggunakan *Hyperparameter* melibatkan dengan ukuran Batch sebesar 16 yang berarti akan memproses 16 gambar per-iterasi dan mempengaruhi performa pelatihan. *Epochs* yang digunakan adalah 50 mengindikasikan model dilatih selama 50 siklus pada konvergensi. *Optimizer Adam* untuk optimasi momentum dan rata-rata gradien dalam mempercepat proses pelatihan serta. Learning rate ditentukan sebesar 0.001 adalah standar minimum digunakan untuk keseimbangan proses pelatihan cepat dan stabil.

```
batch_size = 16
num_epochs = 50
criterion = nn.CrossEntropyLoss()
optimizer = optim.Adam(model.parameters(), lr=0.001)
```


Pada Gambar 6. mendapatkan hasil akurasi yang cukup baik sebesar 92% pada *Epoch 50*, kemudian *Train Loss* sebesar 0.0914 menunjukkan bahwa model berhasil melakukan pengurangan kesalahan pada data pelatihan. *Val Loss* sebesar 0.1770 menunjukkan terjadi kesalahan pada data validasi setelah pelatihan. Nilai tinggi dibandingkan dengan *Train Loss* mengindikasikan ada perbedaan antar performa model pada data pelatihan dan data validasi. Secara keseluruhan, pelatihan ini tetap menandakan bahwa model *Residual Networks -18* memiliki kemampuan dalam mengenali dan mengklasifikasikan gambar sesuai kelas kondisi gigi.



Gambar 7. Hasil Pelatihan Model


3.5. Evaluasi Model

Setelah mendapatkan hasil dari pelatihan model menggunakan *Hyperparameter* yang telah ditentukan sebelumnya, setelah itu melakukan pengujian data dengan menggunakan data *testing* untuk uji identifikasi citra agar dapat mengetahui hasil evaluasi prediksi kondisi gigi *Calculus*, *Caries*, *Gingivitis*, dan *Tooth Discoloration*. Hasil pengujian data dapat dilihat pada gambar 9. Sebagai berikut.

Gambar 8. Hasil prediksi kondisi gigi *Calculus*, *Caries*, *Gingivitis*, dan *Tooth Discoloration*.

Pada Gambar 9. hasil pengujian data kondisi gigi ditampilkan beberapa sampel untuk melihat gambar citra. Visualisasi dibantu dengan menggunakan *Grad-Cam* untuk klasifikasi kondisi gigi dan membantu memberi area fokus model dalam membuat prediksi. Kelas *Calculus* memberikan sebagian prediksi benar pada fokus area, namun terjadi kesalahan prediksi ketika model memprediksi sebagai *Gingivitis*, ditunjukkan pada *Grad-Cam* meluas ke area gusi gigi sehingga menyebabkan kesalahan prediksi karena ada tumpang tindih antara *Calculus* dan *Gingivitis*. Kelas *Caries* memberikan performa model yang sangat baik dalam memprediksi *Caries*. Semua prediksi ditampilkan dengan benar. Hasil yang konsisten menunjukkan tingkat akurasi yang tinggi untuk kelas *Caries*. Kelas *Gingivitis* menunjukkan beberapa kesalahan prediksi menjasi *Calculus* atau *Tooth Discoloration*. *Grad-Cam* memberikan fokus model namun mencakup area gusi dan plak gigi sehingga menyebabkan kebingungan model. Kelas *Tooth Discoloration* menunjukkan performa mode yang baik pada prediksi yang sebagian besar benar. *Grad-Cam* menunjukkan fokus model pada area gigi yang mengalami perubahan warna.

Kemudian *Confusion matrix* dari prediksi model pada empat kelas kondisi gigi. Setiap baris matriks mewakili label yang benar ditandai pada *True Labels* dan setiap kolom mewakili label prediksi atau disebut *Predicted Label*. Berikut merupakan gambar 8. Hasil dari *Confusion Matrix* untuk model *Residual Network-18* yang dapat dilihat pada Gambar 8.



Gambar 9. Confusion Matrix Residual Network -18

Pada Gambar 8. dijelaskan pada *True Labels* (0) dengan kelas kondisi gigi *Calculus* menunjukkan bahwa 116 prediksi yang benar untuk kelas *Calculus*, kemudian 14 kasus yang salah prediksi diperhatikan pada *Predicted Labels* terdiri dari 2 kasus diprediksi sebagai *Caries*, 11 kasus diprediksi sebagai *Gingivitis*, dan 1 kasus diprediksi sebagai *Tooth Discoloration*.

Pada *True Labels* (1) dengan kelas kondisi gigi *Caries* menunjukkan bahwa 233 prediksi yang benar untuk kelas *Caries*, kemudian 3 prediksi salah diperhatikan pada *Predicted Labels* terdiri dari 5 salah prediksi sebagai *Tooth Discoloration*. Model ini memiliki performa yang baik dalam mendeteksi *Caries* sehingga memiliki tingkat kesalahan yang minimal.

Pada *True Labels* (2) dengan kelas kondisi gigi *Gingivitis* menunjukkan bahwa 78 prediksi yang benar untuk kelas *Gingivitis*, kemudian 32 kasus yang salah prediksi diperhatikan pada *Predicted Labels* terdiri dari 31 kasus diprediksi sebagai *Calculus*, dan 1 kasus diprediksi sebagai *Tooth Discoloration*. Model cenderung kesulitan dalam mendeteksi *Gingivitis*, dengan banyak kasus salah sebagai *Calculus*.

Pada *True Labels* (3) dengan kelas kondisi gigi *Tooth Discoloration* menunjukkan bahwa 179 prediksi yang benar untuk kelas *Tooth Discoloration*, kemudian 5 kasus yang salah prediksi diperhatikan pada *Predicted Labels* terdiri dari 1 kasus diprediksi sebagai *Calculus*, 4 kasus diprediksi sebagai *Caries*. Model menunjukkan performa yang baik dan kesalahan yang minimal.

Setelah mendapatkan hasil pengujian model pada Gambar 8. maka selanjutnya melakukan perhitungan metrik Akurasi, Presisi, Recall, dan F1-Score dengan menggunakan rumus persamaan metrik yang dijelaskan sebelumnya pada sub-bab 2.6. Berikut adalah perhitungan metrik dari hasil Confusion Matrix sebagai berikut:

a. Akurasi

$$Akurasi_{Total} = \frac{116+233+78+179}{116+2+11+1+0+233+0+5+31+0+78+1+1+4+0+179} = \frac{606}{661} = 0.9166 \text{ atau } 91.7\%$$

b. Presisi

$$Presisi_{Calculus} = \frac{116}{116+2+31+1} = \frac{116}{150} = 0.773$$

$$Presisi_{Caries} = \frac{233}{233+2+4} = \frac{233}{239} = 0.975$$

$$Presisi_{Gingivitis} = \frac{78}{78+11} = \frac{78}{89} = 0.876$$

$$Presisi_{Tooth\ Discoloration} = \frac{179}{179+1+5} = \frac{179}{185} = 0.968$$

c. Recall

$$Recall_{Calculus} = \frac{116}{116+2+11+1} = \frac{116}{130} = 0.892$$

$$Recall_{Caries} = \frac{233}{233+5} = \frac{233}{238} = 0.979$$

$$Recall_{Gingivitis} = \frac{78}{78+31+1} = \frac{78}{110} = 0.710$$

$$Recall_{Tooth\ Discoloration} = \frac{179}{179+1+4} = \frac{179}{184} = 0.973$$

d. F1 -Score

$$f1\ Score_{Calculus} = 2 \cdot \frac{0.773 \cdot 0.892}{0.773 + 0.892} = 0.829$$

$$f1\ Score_{Caries} = 2 \cdot \frac{0.975 \cdot 0.979}{0.975 + 0.979} = 0.977$$

$$f1\ Score_{Gingivitis} = 2 \cdot \frac{0.876 \cdot 0.709}{0.876 + 0.709} = 0.784$$

$$f1\ Score_{Tooth\ Discoloration} = 2 \cdot \frac{0.968 \cdot 0.973}{0.968 + 0.973} = 0.970$$

Tabel 5. Hasil Confusion Matrix

Kondisi Gigi	Akurasi	Presisi	Recall	F1-Score
<i>Calculus</i>	0.78	0.78	0.89	0.83
<i>Caries</i>	0.97	0.97	0.98	0.98
<i>Gingivitis</i>	0.88	0.88	0.71	0.78
<i>Tooth Discoloration</i>	0.96	0.96	0.97	0.97

Tabel 5. Menunjukkan hasil evaluasi dari pelatihan model dengan empat metrik utama Akurasi, Presisi, Recall, dan F1-Score untuk empat kondisi gigi yang diuji, yaitu *Calculus*, *Caries*, *Gingivitis*, dan *Tooth Discoloration*.

Calculus mendapatkan akurasi 78%, dengan presisi 78%, recall 89%, dan F1-Score 83%. Meskipun relatif rendah pada akurasi dan presisi dengan kondisi gigi lainnya, namun hasil recall yang cukup tinggi mampu mendeteksi sebagian kasus *Calculus* dengan baik.

Caries menunjukkan akurasi 97%, presisi 97%, recall 98%, dan F1-Score 98%, hal ini menunjukkan model sangat baik dalam identifikasi dan klasifikasi *Caries*.

Gingivitis menunjukkan akurasi 88%, presisi 88%, recall 71%, dan F1-Score 78%, meskipun akurasi dan presisi mendapatkan nilai yang tinggi, namun nilai recall yang rendah menunjukkan bahwa model terdapat kegagalan deteksi yang mengarah pada penurunan F1-Score.

Tooth Discoloration memiliki akurasi 96%, presisi 97%, dan F1-Score 97%, menunjukkan bahwa model hampir mendekati sempurna seperti kondisi gigi *Caries* dalam klasifikasi atau hampir tanpa kesalahan dalam identifikasi maupun prediksi.

Secara keseluruhan, model mampu menunjukkan performa terbaik dalam mengklasifikasikan kondisi gigi. *Caries* dan *Tooth Discoloration* mendapatkan performansi yang sangat tinggi, sementara *Gingivitis* mendapatkan performa yang kurang optimal dalam recall. *Calculus* menunjukkan kinerja yang cukup baik meskipun masih ada ruang perbaikan pada akurasi dan presisi.

4. DISKUSI

Penelitian ini menggunakan model arsitektur ResNet-18 dalam klasifikasi kondisi gigi berbasis citra RGB, dengan tingkat performa akurasi tinggi pada *Caries* 97% dan *Tooth Discoloration* 96%. Sedangkan, tingkat performa akurasi cenderung rendah untuk *Calculus* 78%, dan *Gingivitis* 88%. Secara keseluruhan, model mendapatkan akurasi sebesar 91.7% mengindikasikan efektivitas model pada klasifikasi gambar RGB, meskipun terdapat kelemahan pada pola yang kompleks atau tumpang tindih. Perbandingan dengan penelitian Lee et al [14], menggunakan citra radiograf panoramik serta mendapatkan akurasi sebesar 98% keseluruhan data, hasil ini lebih tinggi, karena citra radiograf cenderung memberikan data lebih struktur dan seragam dibandingkan RGB yang memiliki variasi gambar, pencahayaan, perspektif pengambilan gambar, dan kualitas gambar sehingga mempengaruhi performa model.

Penelitian Mishra et al [15], menjelaskan bahwa augmentasi data mempengaruhi kinerja ResNet-18 dalam distribusi data yang tidak seimbang. Dalam penelitian ini teknik augmentasi mencakup *Resize*, *Center Crop*, *Random Resized Crop*, *Random Horizontal Flip*, *Random Rotation*, *To Tensor*, *Normalize* sudah diterapkan, namun ketidakseimbangan distribusi data masih mempengaruhi performa model, terutama pada kelas *Calculus* dan *Gingivitis*.

Hasil prediksi ditunjukkan menggunakan visualisasi *Grad-Cam* area fokus model dan visualisasi terbaik pada kelas *Caries* dan *Tooth Discoloration*. Menurut penelitian Liu et al [16] menjelaskan bahwa visualisasi *Grad-Cam* tidak hanya membantu interpretasi model namun juga dapat menjadi alat pertimbangan medis dalam membantu pemeriksaan penunjang serta meningkatkan kepercayaan untuk diagnosa klinis. Namun dalam penelitian ini terdapat ambiguitas prediksi pada kelas *Calculus* dan *Gingivitis*, karena fokus melebar sampai ke area gusi sehingga menyebabkan kesalahan prediksi. Hal ini perlu ada peningkatan strategi pelatihan dalam memisahkan fitur yang tumpang tindih.

Dampak pada praktik medis menjadi sorotan penting seperti pengurangan resiko terpapar radiasi jangka panjang. Penelitian Kumar et al [7] menyoroti bahwa penggunaan berbasis RGB adalah alternatif yang sangat aman, terutama pada kalangan anak-anak dan wanita hamil. Efisiensi diagnostik menggunakan citra RGB lebih mudah dijangkau dan hemat biaya dibandingkan X-Ray karena membuka peluang implementasi di klinik dengan sumber daya terbatas sehingga menawarkan pendekatan praktis dalam diagnosa klinis tanpa alat mahal.

5. KESIMPULAN

Penelitian ini menyimpulkan bahwa potensi besar menggunakan model ResNet-18 dalam mendukung diagnosa digital berbasis citra RGB untuk klasifikasi kondisi gigi. Berikut poin-poin utama:

1. Model aritektur ResNet-18 bisa mendapatkan akurasi tinggi pada klasifikasi kondisi gigi, dengan hasil terbaik pada kelas *Caries* 97% dan *Tooth Discoloration* 96%, meskipun terdapat performa cenderung rendah pada kelas *Calculus* 78% dan *Gingivitis* 88%.
2. Model ini memberikan pendekatan praktis untuk mengurangi paparan radiasi serta memberikan peluang pada diagnosa klinis yang lebih aman dan terjangkau di lingkungan medis.
3. Teknik Grad-Cam memberikan keunggulan tidak hanya pada interpretasi model namun juga meningkatkan tingkat kepercayaan serta penunjang pemeriksaan medis.

Pada penelitian ini juga memiliki implikasi secara luas, seperti keamanan pasien lebih baik agar mengurangi resiko paparan radiasi, terutama untuk pasien anak-anak, wanita hami, atau kondisi kesehatan tertentu. Kemudian ketersediaan diagnosa yang terjangkau dengan model berbasis citra RGB dapat diimplementasikan pada klinik kecil, daerah terpencil, atau sumber daya terbatas. Visualisasi *Grab-Cam* berdampak positif untuk tingkat kepercayaan serta efisiensi diagnosa digital hal ini memungkinkan para dokter bisa lebih fokus pada perawatan pasien dan tugas lainnya.

Rekomendasi penelitian lanjutan bisa dilakukan dengan menggabungkan beberapa model CNN agar meningkatkan akurasi serta perbandingan model. Kemudian segmentasi bisa ditambahkan lebih banyak agar dapat meningkatkan akurasi pada kelas dengan tumpang tindih fitur. Optimalisasi *Hyperparameter* juga penting seperti penyesuaian *Epoch*, *Optimizer*, *Learning Rate*, dan *Batch Size* agar mencapai performa yang diinginkan. Kemudian studi interdisipliner melibatkan praktisi medis untuk kolaborasi integrasi model pada alur kerja klinis dan pengujian langsung di lapangan.

DAFTAR PUSTAKA

- [1] A. M. Puspitasari, D. E. Ratnawati, and A. W. Widodo, "Klasifikasi Penyakit Gigi Dan Mulut Menggunakan Metode Support Vector Machine," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 2, pp. 802–810, 2018, Accessed: May 16, 2024. [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/967>.
- [2] W. Y. Prihandini and A. Faizah, "Perawatan Kuretase Gingiva Pada Gigi Kaninus Kanan Rahang Atas," *Jikg (Jurnal Ilmu Kedokt. Gigi)*, 2022, doi: 10.23917/jikg.v5i1.19355.
- [3] I. Mayerd, "Deteksi Dini Karies Gigi Dengan Metode Fluoresen Optik Pada Saliva," *J. Tek. Its*, 2023, doi: 10.12962/j23373539.v12i3.118633.
- [4] L. T. Marthinu and M. Bidjuni, "Penyakit Karies Gigi Pada Personil Detasemen Gegana Satuan Brimob Polda Sulawesi Utara Tahun 2019," *Jigim (Jurnal Ilm. Gigi Dan Mulut)*, 2020, doi: 10.47718/jgm.v3i2.1436.
- [5] A. Fansurna, "Pengaruh Perilaku Merokok Terhadap Kejadian Penyakit Periodontal Di Puskesmas Cempaka Kota Banjarbaru," *An-Nadaa J. Kesehat. Masy.*, 2023, doi: 10.31602/ann.v10i1.10182.
- [6] M. H. Habibillah, "Rancang Bangun Sistem Pakar Diagnosis Penyakit Gigi Pada Manusia Berbasis Android," *Simpatik J. Sist. Inf. Dan Inform.*, 2021, doi: 10.31294/simpatik.v1i2.867.
- [7] A. Kumar, H. S. Bhadauria, and A. Singh, "Descriptive Analysis of Dental X-Ray Images Using Various Practical Methods: A Review," *Peerj Comput. Sci.*, 2021, doi: 10.7717/peerj-cs.620.
- [8] P. A. Oakley and D. E. Harrison, "X-Ray Hesitancy: Patients' Radiophobic Concerns Over Medical X-Rays," *Dose-Response*, 2020, doi: 10.1177/1559325820959542.
- [9] H. Danial and D. Setiawati, "Convolutional Neural Network (Cnn) Based On Artificial Intelligence In Periodontal Diseases Diagnosis," vol. 20, no. 1, 2024, doi: 10.46862/interdental.v20i1.8641.
- [10] N. K. Chowdhury, M. A. Kabir, M. M. Rahman, and N. Rezoana, "ECOVNet: An Ensemble of Deep Convolutional Neural Networks Based on EfficientNet to Detect COVID-19 From Chest X-rays," 2020, doi: 10.7717/peerj-cs.551.

-
- [11] L. A. Villamizar-Martinez and J. Losey, "Assessment of the Occupational Radiation Dose From a Handheld Portable X-Ray Unit During Full-Mouth Intraoral Dental Radiographs in the Dog and the Cat – A Pilot Study," *J. Vet. Dent.*, 2023, doi: 10.1177/08987564231175596.
- [12] N. Hilmi, "Implementasi HE, AHE, Dan CLAHE Pada Metode Convolutional Neural Network Untuk Identifikasi Citra X-Ray Paru-Paru Normal Atau Terinfeksi Covid19," *Edu Komputika J.*, 2023, doi: 10.15294/edukomputika.v10i1.57237.
- [13] L. Hakim, Z. Sari, and H. Handhajani, "Klasifikasi Citra Pigmen Kanker Kulit Menggunakan Convolutional Neural Network," *J. Resti (Rekayasa Sist. Dan Teknol. Informasi)*, 2021, doi: 10.29207/resti.v5i2.3001.
- [14] K. Lee, S. Jung, J. Ryu, S. Shin, and J. Choi, "Evaluation of transfer learning with deep convolutional neural networks for screening osteoporosis in dental panoramic radiographs," *J. Clin. Med.*, vol. 9, no. 2, p. 392, 2020, doi: 10.3390/jcm9020392.
- [15] A. Mishra, "Classification of pneumonia and COVID-19 using convolutional neural network," *Int. J. Heal. Sci. Pharm.*, pp. 65–88, 2023, doi: 10.47992/ijhsp.2581.6411.0110.
- [16] S. Liu *et al.*, "Predicting microvascular invasion in hepatocellular carcinoma: a deep learning model validated across hospitals," *Cancer Imaging*, vol. 21, no. 1, 2021, doi: 10.1186/s40644-021-00425-3.
- [17] H. Mohammad-Rahimi *et al.*, "Deep Learning in Periodontology and Oral Implantology: A scoping Review," *J. Periodontal Res.*, 2022, doi: 10.1111/jre.13037.
- [18] S. Sivasundaram and C. R. Pandian, "Performance Analysis of Classification and Segmentation of Cysts in Panoramic Dental Images Using Convolutional Neural Network Architecture," *Int. J. Imaging Syst. Technol.*, 2021, doi: 10.1002/ima.22625.
- [19] J.-H. Lee, "Identification of Dental Implant Systems From Low-Quality and Distorted Dental Radiographs Using AI Trained on a Large Multi-Center Dataset," *Sci. Rep.*, 2024, doi: 10.1038/s41598-024-63422-z.
- [20] J.-Y. Cha, H. Yoon, I. Yeo, K.-H. Huh, and J. Han, "Panoptic Segmentation on Panoramic Radiographs: Deep Learning-Based Segmentation of Various Structures Including Maxillary Sinus and Mandibular Canal," *J. Clin. Med.*, 2021, doi: 10.3390/jcm10122577.
- [21] P. Sonavane, "A Survey on Airport Detection on Remote Sensing Images Using Deep Convolutional Neural Network," *Int. J. Res. Appl. Sci. Eng. Technol.*, 2019, doi: 10.22214/ijraset.2019.6070.
- [22] Z. Xiao-yi, C. Luo, B. Qiao, N. Jin, Y. Zhao, and H. Zhang, "A Deep Learning Model Using Convolutional Neural Networks for Caries Detection and Recognition With Endoscopes," *Ann. Transl. Med.*, 2022, doi: 10.21037/atm-22-5816.
- [23] C. Kim, H.-G. Jeong, W. Park, and D. Kim, "Tooth-Related Disease Detection System Based on Panoramic Images and Optimization Through Automation: Development Study," *Jmir Med. Informatics*, 2022, doi: 10.2196/38640.
- [24] E. Y. Park, H. Cho, S. Kang, S. Jeong, and E.-K. Kim, "Caries Detection With Tooth Surface Segmentation on Intraoral Photographic Images Using Deep Learning," *BMC Oral Health*, 2022, doi: 10.1186/s12903-022-02589-1.
- [25] M. F. Naufal, "Analisis Perbandingan Algoritma SVM, KNN, Dan CNN Untuk Klasifikasi Citra Cuaca," *J. Teknol. Inf. Dan Ilmu Komput.*, 2021, doi: 10.25126/jtiik.2021824553.
- [26] H. Hidayat, "Klasifikasi Penyakit Jantung Menggunakan Random Forest Clasifier," *J. Siskom-Kb (Sistem Komput. Dan Kecerdasan Buatan)*, 2023, doi: 10.47970/siskom-kb.v7i1.464.
- [27] V. Artanti, "Klasifikasi Cardiovascular Diseases Menggunakan Algoritma K-Nearest Neighbors (KNN)," *Techno Com*, 2024, doi: 10.62411/tc.v23i2.10061.
- [28] E. Lestari, "Prediksi Keganasan Kanker Payudara Dengan Pendekatan Machine Learning," *Jati (Jurnal Mhs. Tek. Inform.)*, 2023, doi: 10.36040/jati.v7i3.6963.
- [29] S. Lasniari, J. Jasril, S. Sanjaya, F. Yanto, and M. Affandes, "Klasifikasi Citra Daging Babi dan Daging Sapi Menggunakan Deep Learning Arsitektur ResNet-50 dengan Augmentasi Citra," *J. Sist. Komput. dan Inform.*, vol. 3, no. 4, p. 450, 2022, doi: 10.30865/json.v3i4.4167..