

Pengembangan Model CNN ResNet-18 untuk Klasifik...

By: JULIAN Supardi

As of: Mar 11, 2025 9:55:19 PM
5,246 words - 49 matches - 32 sources

Similarity Index

14%

Mode: Similarity Report ▾

paper text:

DOI: <https://doi.org/10.52436/1.jpti> .568 Vol . 4, No . 12, Desember 2024, Hal . 747-758 p-ISSN: 2775-4227 e-ISSN: 2775-4219

6

Pengembangan Model CNN ResNet-18 untuk Klasifikasi Kondisi Gigi Berbasis Citra RGB sebagai Solusi Diagnostik Digital Gabriel Mediose Alfranda Sihotang1, Julian Supardi

4

*2 1,2Magister

Ilmu Komputer, Fakultas Ilmu Komputer, Universitas Sriwijaya, Indonesia Email: 1gabrielmediose88@gmail.com

21

, 2dprmlab2020@gmail.com Abstrak Penelitian ini menggunakan

model CNN ResNet-18 untuk klasifikasi kondisi gigi berbasis citra RGB

4

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

26

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

24

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

12

50 epochs.

The purpose of the study was to use Residual Network-18 to classify the

22

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

20

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 prevalensi 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

14

[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**

15

pendarahan gusi[5]. Tooth Discoloration atau perubahan warna gigi akibat 747 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**

25

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 interapretabilitas prediksi ResNet-18 mendapatkan keuntungan signifikan dengan teknik Grad-Cam dalam melakukan visualisasi area prediksi gambar sehingga dapat membangun kepercayaan dokter untukagnostik 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**

19

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 dikumpulkan 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

17

Data Tahapan pertama Rezize 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 Rezize 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 To Tensor agar mendapatkan efisiensi pemrosesan di GPU selama masa pelatihan model[23]. Tahapan ketujuh Normalization digunakan untuk memastikan rentang nilai piksel gambar ke skala ayng 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

18

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, 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] Conv2d [- 1, 128, 16, 16]
BatchNorm2d [- 1, 128, 16, 16] ReLU [- 1, 128, 16, 16] BasicBlock [- 1, 128, 16, 16] Conv2d [-1

1

256, 8, 8] BatchNorm2d [-1, 256, 8, 8] ReLU [-1, 256, 8, 8] Conv2d [-1, 256, 8, 8] BatchNorm2d [-1, 256, 8, 8] Conv2d [- 1, 256, 8, 8] BatchNorm2d [- 1, 256, 8, 8] ReLU [- 1
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

1

] 749 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 tektur 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 infomasi 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, 255, 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

8

Hyperparameter Value

Optimizer Adam Epochs 50 Learning rate 0.001

29

Batch size 16 2.6. Evaluasi

Model Pada proses tahapan evaluasi **model** akan **diuji menggunakan data testing yang**

23

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**

31

klasifikasi kondisi gigi menggunakan confussion matrix meliputi

Akurasi, Presisi, Recall, dan F1-Score . Akurasi **digunakan** untuk **melihat**

5

hasil

kinerja model klasifikasi dengan menghitung **jumlah prediksi benar dan**

5

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 terkласifikasi benar TN = Data negatif yang terkласifikasi benar FP = Data positif yang terkласifikasi salah FN = Data negatif yang terklasifikasi salah

7

$Akkurasi = \frac{TP + TN}{TP + TN + FP + FN}$ (1) $Rakir = \frac{TP}{TP + FN}$ (2) $Recall = \frac{TP}{TP + FN}$ (3) $F1 Score = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall}$ (4) $Precision = \frac{TP}{TP + FP}$ (5) 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 Calculus 932 234 130 Caries 1713 429 238 Gingivitis 788 198 110 Tooth Discoloration 1320 330 184 Tabel 4. Visualisasi Kondisi Gigi Calculus Caries Gingivitis Tooth Discoloration 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, 751 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
```

13

```
.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
```

11

]), 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 memotor 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
```

30

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)
```

16

) 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 mengindikasi 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

10

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 menjadi 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**

5

yang dijelaskan sebelumnya pada sub-bab 2.6. Berikut adalah perhitungan metrik dari hasil Confusion Matrix sebagai berikut: a. Akurasi $AkrrariRkrak = \frac{116+2+11+1+0+121336++023+35++7381++107+978+1+1+4+0+179}{606} = 0.9166$ arar 91.7% b. Presisi $PreririBakcrkrr = \frac{116+121+631+1}{111560} = 0.773 = PreririBaricr = \frac{233}{233+2+4} = 0.975$ 239 PreririFikgiririr = $\frac{787+811}{7889} = 0.876 = PreririRkkrrh Birckkkrarikk = \frac{1791+791+5}{117895} = 0.968$ c. Recall $RecakkBakcrkrr = \frac{116+121+611+1}{111360} = 0.892 = RecakkBaricr = \frac{233}{233+5} = 0.979$ 238 RecakkFikgiririr = $\frac{78+7381+1}{17180} = 0.710 = RecakkRkkrrh Birckkkrarikk = \frac{1791+791+4}{117894} = 0.973$ d. F1 -Score $e0 ScnreCalcrIrr = 0.00..000000+0.00.000000 = 0.000 e0 ScnreCareer = 0.00.000000+0.00.000000 = 0.000 e0 ScnreGeneererer = 0.00..000000+0.00.000000 = 0.000 e0 ScnreSnnre Cercnlrnarenn = 0.00..000000+0.00.000000 = 0.000$ Tabel 5. Hasil Confusion Matrix Kondisi Gigi Calculus Caries Gingivitis Tooth Discoloration Akurasi Presisi

Recall	F1-Score	0.78	0.78	0	.89	0	.83	0	.97	0	.97	0	.98	0	.98	0	.88	0	.88	0	.71	0	.78	0	.96	0	.96	0
--------	----------	------	------	---	-----	---	-----	---	-----	---	-----	---	-----	---	-----	---	-----	---	-----	---	-----	---	-----	---	-----	---	-----	---

9

.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 dengang kondisi gigi lainnya, namun hasil recall yang cukup tinggi mampu mendeteksi sebagian kasus Calculus dengan baik. Caries menunjukkan

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 perfomansi 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% mengindikasi 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, Cemter 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,

. 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 hamil, 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] [3] [4] 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.
- [5] I. Mayerd, "Deteksi Dini Karies Gigi Dengan Metode Fluoresen Optik Pada Saliva," *J. Tek. Its*, 2023, doi: 10.12962/j23373539.v12i3.118633.
- [6] L. T. Marthinu and M. Biduni, "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.
- [7] [8] [9] [10] 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.
- [11] 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.
- [12] A. Kumar, H. S. Bhaduria, 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.
- [13] P. A. Oakley and D. E. Harrison, "X-Ray Hesitancy: Patients' Radiophobic Concerns Over Medical X- Rays," *Dose-Response*, 2020, doi: 10.1177/1559325820959542.
- [14] 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.
- [15] 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.
- [16] [17] 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.
- [18] 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.
- [19] 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.
- [20] 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.
- [21] [22] 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.
- [23] 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.
- [24] H. Mohammad-Rahimi et al., "Deep Learning in Periodontology and Oral Implantology: A scoping Review," *J. Periodontal Res.*, 2022, doi: 10.1111/jre.13037.
- [25] 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] [22] 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. 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] [26] [27] [28] [29] 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. 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. V. Artanti, "Klasifikasi Cardiovascular Diseases Menggunakan Algoritma K-Nearest Neighbors (KNN)," Techno Com, 2024, doi: 10.62411/tc.v23i2.10061. E. Lestari, "Prediksi Keganasan Kanker Payudara Dengan Pendekatan Machine Learning," Jati (Jurnal Mhs. Tek. Inform., 2023, doi: 10.36040/jati.v7i3.6963. 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..

Jurnal Pendidikan dan Teknologi Indonesia (JPTI)

2

)

Jurnal Pendidikan dan Teknologi Indonesia (JPTI) p-ISSN: 2775-4227 e-ISSN: 2775-4219 Jurnal Pendidikan dan

2

Teknologi Indonesia (JPTI) p-ISSN: 2775-4227 e-ISSN: 2775-4219

3

Jurnal Pendidikan dan Teknologi Indonesia (JPTI) p-ISSN: 2775-4227 e-ISSN: 2775-4219 Jurnal Pendidikan dan

2

Jurnal Pendidikan dan Teknologi Indonesia (JPTI) p-ISSN: 2775-4227 e-ISSN: 2775-4219 Jurnal Pendidikan dan

2

Teknologi Indonesia (JPTI) p-ISSN: 2775-4227 e-ISSN: 2775-4219

3

Jurnal Pendidikan dan Teknologi Indonesia (JPTI) p-ISSN: 2775-4227 e-ISSN: 2775-4219 Jurnal Pendidikan dan

2

Teknologi Indonesia (JPTI) p-ISSN: 2775-4227 e-ISSN: 2775-4219

3

Jurnal Pendidikan dan Teknologi Indonesia (JPTI) p-ISSN: 2775-4227 e-ISSN: 2775-4219 Jurnal Pendidikan dan

2

Teknologi Indonesia (JPTI) p-ISSN: 2775-4227 e-ISSN: 2775-4219

2

Jurnal Pendidikan dan Teknologi Indonesia (JPTI) p-ISSN: 2775-4227 e-ISSN: 2775-4219 748 750 752 753 754 755 756 757 758

sources:

1

139 words / 3% - Crossref

[Farzaneh Jafari, Anup Basu. "Two-dimensional Parallel Spatio-Temporal Pyramid Pooling for Hand Gesture Recognition", IEEE Access, 2023](#)

- 2 92 words / 2% - Internet
[Lestari, Ayuni, Situmorang, Valencia Tara, Tahdid, Tahdid, Ridwan, K.A, Manggala, Agus. "Analisa Efisiensi Termal Water Tube Boiler Berdasarkan Rasio Udara Bahan Bakar LPG Untuk Memproduksi Saturated dan Superheated Steam", Infinite Corporation, 2021](#)
- 3 44 words / 1% - Internet from 26-Jul-2021 12:00AM
[jpti.journals.id](#)
- 4 40 words / 1% - Internet from 16-Jan-2025 12:00AM
[jpti.journals.id](#)
- 5 24 words / 1% - Internet from 25-Oct-2023 12:00AM
[ojs.unud.ac.id](#)
- 6 19 words / < 1% match - Internet
[Mufidah, Ulfa Miftakhul, Widiastuti, Sripit, Riana, Desy Dwi. "Pengembangan Cerita Bergambar Bahasa Jawa \(Cergam Baja\) Untuk Siswa Sekolah Dasar", Infinite Corporation, 2021](#)
- 7 22 words / < 1% match - Internet
[Rozzi Zaputra,-. "DEEP LEARNING UNTUK KLASIFIKASI B-ACUTE LYMPHOBLASTIC LEUKEMIA CELL MENGGUNAKAN ARSITEKTUR DENSENET121", 2023](#)
- 8 16 words / < 1% match - Internet from 18-Jul-2023 12:00AM
[repository.uin-suska.ac.id](#)
- 9 20 words / < 1% match - Internet from 18-Jan-2023 12:00AM
[core.ac.uk](#)
- 10 9 words / < 1% match - Internet from 13-Sep-2021 12:00AM
[core.ac.uk](#)
- 11 21 words / < 1% match - Internet from 14-Apr-2023 12:00AM
[vimsky.com](#)
- 12 12 words / < 1% match - Crossref

13 12 words / < 1% match - Internet from 09-Jan-2024 12:00AM
[neptune.ai](#)

14 11 words / < 1% match - Internet from 07-Jan-2020 12:00AM
[berkahbaitulherbal.wordpress.com](#)

15 11 words / < 1% match - Internet from 08-Jul-2017 12:00AM
[reridamaria.blogspot.com.br](#)

16 11 words / < 1% match - Internet from 02-Jul-2024 12:00AM
[www.geeksforgeeks.org](#)

17 11 words / < 1% match - Internet from 14-Jun-2022 12:00AM
[www.researchgate.net](#)

18 10 words / < 1% match - Crossref
[Zeyu Cao, Xiaorun Li, Yueming Feng, Shuhan Chen, Chaoqun Xia, Liaoying Zhao. "ContrastNet: Unsupervised feature learning by autoencoder and prototypical contrastive learning for hyperspectral imagery classification", Neurocomputing, 2021](#)

19 10 words / < 1% match - Internet from 12-Oct-2023 12:00AM
[jurnal.murnisadar.ac.id](#)

20 10 words / < 1% match - Internet from 03-Mar-2025 12:00AM
[scholar.archive.org](#)

21 10 words / < 1% match - Internet
[Falah, Miftahul, Rini, Dian Palupi, Pahendra, Iwan. "Memprediksi Penyakit Kanker Payudara dan Liver menggunakan Algoritma Backpropagation", Annual Research Seminar \(ARS\), 2020](#)

22 10 words / < 1% match - Internet from 18-Feb-2024 12:00AM
[www.grafati.com](#)

- 23 9 words / < 1% match - Crossref
[Muhammad Fajri Ramadhan, Dewi Lestari, Ulfa Khaira. "Prediksi Harga Bitcoin Menggunakan Metode Long Short Term Memory", Jurnal Pepadun, 2024](#)
-
- 24 9 words / < 1% match - Internet from 08-Jul-2024 12:00AM
[repository.telkomuniversity.ac.id](#)
-
- 25 8 words / < 1% match - Internet from 16-Nov-2020 12:00AM
[dspace.uii.ac.id](#)
-
- 26 8 words / < 1% match - Internet from 06-Jul-2024 12:00AM
[ejournal.polbeng.ac.id](#)
-
- 27 8 words / < 1% match - Internet from 20-Nov-2017 12:00AM
[jurnal.uhamka.ac.id](#)
-
- 28 8 words / < 1% match - Internet from 18-Aug-2017 12:00AM
[karyatulisilmiah.com](#)
-
- 29 8 words / < 1% match - Internet from 07-Jan-2020 12:00AM
[upcommons.upc.edu](#)
-
- 30 7 words / < 1% match - Crossref
[Davito Rasendriya Rizqullah Putra, Reyhan Adi Saputra. "IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK \(CNN\) UNTUK MENDETEKSI PENGGUNAAN MASKER PADA GAMBAR", Jurnal Informatika dan Teknik Elektro Terapan, 2023](#)
-
- 31 6 words / < 1% match - Crossref
[Zahra Azhari, Lusiana Efrizoni, Wirta Agustin, Rini Yanti. "Opinion Mining menggunakan Algoritma Deep Learning untuk Menganalisis Penggunaan Aplikasi Jamsostek Mobile", The Indonesian Journal of Computer Science, 2023](#)
-
- 32 6 words / < 1% match - Internet
[Yuniar, Seananda Firly. "Kajian Kondisi Lamun Terkait Dengan Kelimpahan Gastropoda Untuk Menunjang Restorasi Lamun Di Pulau Pramuka, Taman Nasional Kepulauan Seribu, DKI Jakarta", 2017](#)