



DETEKSI PENYAKIT GIGI DAN MULUT MENGGUNAKAN ALGORITMA *INCEPTION-V3* DETECTION OF DENTAL AND ORAL DISEASES USING *INCEPTION-V3*

Dloifur Rohman Al Ghifari^{1*}, Ema Utami², Dhani Ariatmanto³

Universitas Amikom Yogyakarta, Indonesia^{1,2,3}

E-mail: dloifurrohman@students.amikom.ac.id

Article Info	Abstrak
Submitted: 07-04-2025	Kesehatan gigi dan mulut sangat penting bagi kesejahteraan umum, namun banyak orang mengabaikan pengobatan karena kurangnya kesadaran atau tantangan diagnostik. Metode diagnostik tradisional sering kali kurang akurat dan efisien. Penelitian ini bertujuan mengembangkan sistem otomatis untuk mengklasifikasikan penyakit gigi dan mulut menggunakan algoritma <i>deep learning Inception-V3</i> guna meningkatkan akurasi diagnostik. Penelitian menggunakan dataset 8.776 citra oral yang diseimbangkan dengan SMOTE dan diproses dengan teknik augmentasi. <i>Inception-V3</i> dilatih dan dibandingkan dengan CNN, VGG-16, ResNet50, serta model <i>machine learning</i> tradisional. Model <i>Inception-V3</i> mencapai akurasi 94%, mengungguli model lain (CNN: 81%, VGG-16: 88.7%, ResNet50: 76.25%) dan menunjukkan stabilitas tanpa <i>overfitting</i> . Studi ini menegaskan potensi <i>Inception-V3</i> dalam analisis gambar medis, menawarkan alat diagnostik yang andal untuk deteksi dini penyakit gigi dan mulut, sehingga dapat meningkatkan hasil layanan kesehatan. Kata Kunci: klasifikasi, penyakit gigi dan mulut, CNN, Inception-v3.
Final Revised: 21-04-2025	
Accepted: 22-04-2025	
Published: 23-04-2025	

Abstract

Dental and oral health are crucial for overall well-being, yet many individuals neglect treatment due to a lack of awareness or diagnostic challenges. Traditional diagnostic methods often struggle with accuracy and efficiency. This study aims to develop an automated system for classifying dental and oral diseases using the Inception-V3 deep learning algorithm to improve diagnostic accuracy. The research utilized a dataset of 8,776 oral images, balanced using SMOTE, and preprocessed with augmentation techniques. Inception-V3 was trained and compared against CNN, VGG-16, ResNet50, and traditional machine learning models. The proposed Inception-V3 model achieved 94% accuracy, outperforming other models (CNN: 81%, VGG-16: 88.7%, ResNet50: 76.25%) and demonstrating stability without overfitting. This study highlights the potential of Inception-V3 in medical image analysis, offering a reliable tool for early and accurate diagnosis of dental diseases, which can enhance healthcare outcomes.

Keywords: *classification, dental and oral diseases, CNN, Inception-v3.*

Corresponding Author: Dloifur Rohman Al Ghifari

Email: dloifurrohman@students.amikom.ac.id

This article is licensed under



PENDAHULUAN

Kesehatan merupakan suatu hal yang sangat penting dalam kehidupan sehari-hari. Dengan memiliki badan yang sehat dapat meningkatkan kehidupan sehari-hari lebih optimal. Selain Kesehatan tubuh, Kesehatan mulut dan gigi tidak kalah penting, karena mulut dan gigi yang tidak sehat dapat mempengaruhi kondisi tubuh secara keseluruhan. Mulut merupakan gerbang masuk seluruh makanan yang dibutuhkan tubuh dan gigi merupakan alat mengunyah agar proses pencernaan makanan dalam perut berjalan baik. Sedangkan penyakit mulut dan gigi merupakan kondisi yang mempengaruhi struktur dan fungsi kerja gigi. Mulut dan gigi yang tidak sehat akan menimbulkan dampak negatif dan mengganggu kegiatan sehari-hari.

Menurut Hasil Riset Dasar Kesehatan (RISKESDAS) 2018, sebanyak 57,6% Masyarakat Indonesia mengalami masalah mulut dan gigi, serta 93% anak Indonesia mengalami karies gigi dan 87% orang yang memiliki penyakit mulut dan gigi tidak berobat ke dokter, mereka berusaha untuk mengobatinya secara mandiri (Nia, Afdillah. Fachruddin, 2023). Berdasarkan data tersebut kesadaran akan Kesehatan gigi dan mulut masih tergolong rendah karena kurangnya sosialisasi dan pengetahuan tentang penyakit mulut dan gigi. Padahal apabila dibiarkan penyakit pada gigi dan mulut akan dapat menyebabkan penyakit berbahaya lainnya (Muhammad Ifan Rifani Ihsan et al., 2022)(Jaiswal & Bhirud, 2021). Selain itu dalam mendiagnosis jenis penyakit mulut dan gigi tidak mudah karena memiliki gejala yang hampir sama dan jika pengobatannya tidak benar dapat menyebabkan proses penyembuhan yang lama. Sehingga perlu adanya sistem yang dapat mendeteksi penyakit pada mulut dan gigi menggunakan sebuah citra.

Pada saat ini teknologi komputasi telah mengalami perkembangan yang sangat pesat, sehingga saat ini komputer mampu melakukan pengenalan secara otomatis suatu *object* dari suatu *citra* (Putra et al., 2022). Pengolahan citra ini dapat dijadikan salah satu Solusi dalam mengenali, mengidentifikasi dan mengklasifikasi penyakit mulut dan gigi. Dalam melakukan pengklasifikasian atau deteksi penyakit pada mulut dan gigi dapat menggunakan metode *data minning*. *Data minning* merupakan teknologi pencarian informasi pada data besar yang dapat mempercepat pengenalan dan pengelompokan jenis berdasarkan label dengan menggunakan metode yang ada pada *data mining*. Penelitian sebelumnya terkait deteksi penyakit mulut dan gigi, dengan menggunakan algoritma *restNet50* untuk memprediksi penyakit gigi karies berdasarkan citra *panoramic radiograph* gigi dan menghasilkan akurasi yang baik sebesar 92% (Oztekin et al., 2023). Penelitian lainnya dengan menggunakan citra *panoramic radiograph* gigi untuk mendeteksi penyakit mulut menggunakan algoritma SVM (*Support Vektor Machine*) dan menghasilkan akurasi yang cukup baik sebesar 66,61% dan algoritma SVR (*Support Vektor Regression*) sebesar 70,81% (Jaiswal & Bhirud, 2021).

Deep learning merupakan metode pembelajaran terbaru dan memiliki daya komputasi yang handal dalam mengolah data yang besar. Penggunaan *Deep learning* dalam mengklasifikasi atau mendiasnotik berdasarkan gambar terbukti handal (Khalid et al., 2021). Salah satu algoritma *Deep learning* yang sering digunakan dalam pemrosesan gambar medis yaitu *Convolutional Neural Network* (CNN), karena mampu menangani tugas-tugas seperti identifikasi gambar, segmentasi dan klasifikasi dengan akurasi yang tinggi (Almalki et al., 2022). CNN digunakan untuk medeteksi penyakit covid-19 berdasarkan CT-Scan data pasien (Arivoli et al., 2022) dan deteksi penyakit daun padi berdasarkan citra daun (Hairani & Widiyaningtyas, 2024), keduanya mendapatkan akurasi yang tinggi mencapai 99%. Pada penelitian lainnya yang dilakukan oleh (Mujahid et al., 2022), pada penelitian tersebut menggunakan algoritma CNN model Inception-V3

untuk mendeteksi penyakit pneumonia dari citra X-ray dan menghasilkan akurasi yang baik sebesar 99%.

Penelitian terkait lainnya, melakukan klasifikasi kerusakan gigi menjadi tiga klas cavity, filling dan implant, berdasarkan gambar *panoramic radiograph* gigi menggunakan algoritma NASNet Model menghasilkan akurasi yang cukup tinggi sebesar 96% (Al-Ghamdi et al., 2022). Penelitian lainnya CNN digunakan untuk mendiagnosis penyakit periodontal gigi berdasarkan citra *panoramic radiographs* gigi dan menghasilkan akurasi tertinggi mencapai 82% (Lee et al., 2018) . Sedangkan dalam mendeteksi penyakit cavity gigi berdasarkan citra gigi, algoritma CNN dapat menghasilkan akurasi sebesar 71% (Sonavane et al., 2021). Penelitian lainnya dilakukan oleh (Jusman et al., 2021), melakukan perbandingan model algoritma SVM dengan model Algoritma K-NN untuk klasifikasi level penyakit gigi karies berdasarkan citra *radiographic* gigi. Penelitian menghasilkan model Algoritma gaussian-SVM mendapat akurasi tertinggi 95.7%, sedikit lebih baik dari model algoritma Fine-KNN sebesar 94,9%. Sedangkan waktu komputasinya K-NN mendapat waktu tercepat dari SVM untuk semua jenis model algoritmanya..

Berdasarkan permasalahan yang telah diuraikan dan beberapa penelitian yang telah dipaparkan, maka penelitian ini mengusulkan metode CNN model inception V3 untuk klasifikasi penyakit mulut dan gigi berdasarkan citra gigi. Pada proses klasifikasi akan terlebih dahulu dilakukan penyeimbangan dataset menggunakan algoritma SMOTE agar dapat meningkatkan akurasi (Kaope & Pristyanto, 2023).

Pada penelitian ini dilakukan pengklasifikasian penyakit gigi dan mulut berdasarkan citra gigi dan mulut menggunakan algoritma *deep learning Inception-V3*. Kebaruan penelitian ini terletak pada penggunaan algoritma *Inception-V3* untuk mengklasifikasikan penyakit gigi dan mulut dari citra oral dengan akurasi mencapai 94%, mengungguli model *deep learning* lainnya seperti CNN (81%), VGG-16 (88.7%), dan ResNet50 (76.25%). Berbeda dengan penelitian sebelumnya yang berfokus pada penyakit tertentu atau menggunakan arsitektur yang kurang efisien, penelitian ini memanfaatkan kemampuan ekstraksi fitur canggih *Inception-V3* dan menerapkan SMOTE untuk menyeimbangkan dataset, mengatasi masalah ketidakseimbangan kelas [15][18]. Selain itu, studi ini membandingkan metode yang diusulkan dengan algoritma *machine learning* tradisional (misalnya, KNN, SVM) dan arsitektur CNN lainnya, menunjukkan kinerja superior dalam akurasi dan stabilitas selama pelatihan dan validasi.

METODE PENELITIAN


Peneliti melakukan beberapa tahap diantaranya pengumpulan data, penyeimbangan dataset, *preprocessing*, ekstraksi fitur, pelatihan model dan evaluasi hasil. Metode penelitian secara jelas dapat dilihat pada Gambar 1.



Gambar 1. Metode Penelitian

Dataset

Dataset yang digunakan diambil dari hasil didapatkan melalui repository public *Kaggle*. Dataset yang akan digunakan pada penelitian berjumlah 8776 citra gigi dan akan dikelompokkan menjadi 4 klas, yaitu *caries*, *hypodontia*, *gingivitis* dan *Mouth Ulcer*. Dataset *caries* berjumlah 2560, *Hypodontia* berjumlah 1246,gingivitis berjumlah 2344 data dan mouth ulcer berjumlah 2626 data. Contoh dataset dapat dilihat pada Gambar 2.



Gambar 2. Dataset Penyakit Gigi dan Mulut

Preprocessing

Tahap *preprocessing* dapat mengurangi *overfitting* dan meningkatkan kualitas citra sehingga kinerja model algoritma dapat meningkat (Sun et al., 2022). Pada tahap *preprocessing* dibagi menjadi 2 proses yaitu data augmentasi dan data *splitting*. Data augmentasi diperlukan untuk menambahkan varaitif data sehingga data meningkat kinerja CNN dalam mengenali penyakit mulut dan gigi (Kushartanto et al., 2024). Proses Data augmentasi menggunakan beberapa teknik agar data hasil augmentasi tidak 100% mirip dengan data asli. Teknik augmentasi yang digunakan adalah *Resize* menjadi ukuran 200x200 untuk menyamakan ukuran tiap dataset agar dapat mengurangi waktu komputasi, perubahan citra *Rescale*, *Zoom*, *Rotation*, dan *Flip Horizontal*. Proses data *splitting* yaitu pembagian dataset menjadi data training dan data *testing* dengan rasio pembagian 80% untuk *data training* dan 20% untuk *data testing*.

Synthetic Minority Over-sampling Technique (SMOTE)

Pada penelitian ini untuk mengatasi ketidakseimbangan dataset, kami menggunakan metode SMOTE. Penyeimbangan dataset perlu dilakukan agar hasil pelatihan model tidak cenderung condong ke kelas yang banyak datanya. Cara kerja SMOTE dengan cara membuat data buatan yang nanti akan ditambahkan ke data minoritas (Ustyannie & Suprpto, 2020). Data sintetis ditentukan berdasarkan tetangga terdekatnya. Data baru yang dihasilkan oleh metode SMOTE menggunakan persamaan 1.

$$X_{syn} = x_i + rand(0,1) \times (x_{knn} - x_i) \quad (1)$$

Dimana, X_{syn} adalah sampel sintetis baru dari proses SMOTE, x_i sampel yang akan disintesis dari sampel minoritas, $rand(0, 1)$ adalah nilai acak dari nol hingga satu dan x_{knn} Jumlah sampel tetangga akan digunakan untuk mensintesis sampel baru dari sampel kelas minoritas.

Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan algoritma *deep learning* yang banyak digunakan untuk memproses data yang besar. Serta mempunyai potensi dan kinerja yang handal untuk penerapan kategorisasi gambar, pengenalan objek, dan pemeriksaan gambar medis (Thakur & Kumar, 2021). Arsitektur CNN sama dengan ANN terdiri dari neuron yang mempunyai fungsi bobot, bias dan aktivasi. Namun CNN membagi arsitektur tersebut menjadi 2 bagian yaitu *Feature Extraction Layer* dan *Fully Connected Layer* atau klasifikasi layer. (Ramdhani et al., 2020). Sehingga dalam CNN tidak perlu proses Ekstraksi fitur dan segmentasi secara manual. *Feature Extraction Layer* ini merupakan proses mengubah data menjadi bentuk angka yang merepresentasikan data yang terdiri dari *Convolutional Layer* dan *Pooling Layer*. Sedangkan *Fully Connected Layer* memiliki beberapa *hidden layer*, *activation function*, *output layer*, dan *loss function*. Ilustrasi dari Arsitektur CNN lebih jelasnya dapat dilihat pada Gambar 3.



Gambar 3. Arsitektur CNN

Lapisan pertama yaitu lapisan input digunakan untuk membaca data. Lapisan *convolution* adalah lapisan yang paling penting karena sebagai proses ekstraksi fitur, dimana didalamnya terdapat proses pembelajaran fitur untuk kategorisasi citra. Filter atau kernel digunakan menentukan karakteristik dari matrik nilai atau bobot. Pada lapisan convolution untuk mendeteksi fitur dilakukan antara filter dan citra. Dimana untuk menghitung matriks input f (gambar) dan filter k dapat menggunakan persamaan 2.

$$F(i, j) = (f * k)(i, j) = \sum_m \sum_n k(m, n), f(i - m, j - n) \quad (2)$$

Ketika sebuah fitur terdeteksi di bagian tertentu dari gambar, nilai hasil operasi konvolusi pada area tersebut akan lebih tinggi. Sebaliknya, jika fitur tersebut tidak ada, hasil konvolusinya akan lebih rendah (Quoc et al., 2024). Dalam penelitian ini, digunakan tiga lapisan konvolusi dengan jumlah filter masing-masing 64, 32, dan 16 untuk klasifikasi biner, serta empat lapisan konvolusi dengan filter masing-masing 16, 32, 64, dan 128 untuk klasifikasi ganda. Kedua jenis klasifikasi ini menggunakan ukuran filter

3x3. Lapisan-lapisan tersebut terutama berfungsi untuk membentuk peta fitur. Output dari setiap lapisan dimasukkan ke dalam fungsi aktivasi *non-linier* untuk menambah non-linieritas pada persamaan. Berbagai fungsi *non-linier* seperti *sigmoid*, *Rectified Linear Unit* (ReLU), fungsi tanjung hiperbolik (*tanh*), dan lainnya dapat digunakan sebagai fungsi aktivasi, namun kami memilih Leaky ReLU karena dianggap paling sesuai untuk model ini. Persamaan ReLU dapat dilihat pada Persamaan (3).

$$f(x) = \begin{cases} 0 & \text{for } x \leq 0 \\ 1 & \text{for } x \geq 0 \end{cases} \quad (3)$$

Lapisan berikutnya disebut lapisan *pooling layer*. Lapisan ini bertugas agar peta fitur memiliki ukuran yang seminimal mungkin. *Pooling layer* terbagi menjadi beberapa bentuk yaitu *average pooling*, *maximum pooling* dan *sum pooling*. *Maximum pooling* kami gunakan untuk penelitian ini agar dapat mengekstrak fitur yang penting dan menangkap fitur lokal dengan lebih baik. Lapisan terakhir yaitu *Fully connected layer* yang berfungsi untuk proses klasifikasi. Dalam lapisan tersebut terdapat *neuron* atau simpul yang saling terhubung dengan *neuron* yang lain pada lapisan berikutnya. Hasil dari ekstraksi fitur akan diubah menjadi bentuk *vector* satu dimensi terlebih dahulu sebelum masuk pada lapisan ini. Pengklasifikasian pada lapisan ini menggunakan pengklasifikasian *sigmoid* dan *softmax*. Persamaan *sigmoid* dan *softmax* dapat dilihat pada persamaan 4 dan 5.

$$\text{Sigmoid}(x) = \frac{1}{1+e^{-x}} \quad (4)$$

$$\text{Softmax}(x_i) = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}} \quad (5)$$

Dalam penelitian ini juga kami menggunakan lapisan dropout untuk mengatasi permasalahan *overfitting* dan *divergensi*.

Inception-V3

Pada algoritma CNN terdapat beberapa model arsitektur, salah satunya adalah *Inception-V3*. Model arsitektur *Inception-V3* sering digunakan dalam pengklasifikasian dan pengenalan gambar. Model ini merupakan perkembangan dari model *GoogLeNet*. *Inception-V3* mempunyai keunggulan dalam efisiensinya dan kinerja klasifikasi gambar yang kuat, *Inception-V3* menangkap beragam fitur (Kiflie et al., 2024). Model ini walaupun memiliki layer sebanyak 42 layer tetapi dapat secara efisien mempertahankan kinerja yang baik dengan mengurangi parameter dan filter konvolusinya (Ahmed et al., 2023). Model ini menggabungkan konvolusi dengan berbagai ukuran, seperti 1x1, 3x3, dan 5x5. *Inception V3* juga menggunakan fitur faktorisasi yang signifikan, yang membagi lapisan konvolusi 5x5 menjadi dua lapisan 3x3. Sambil meningkatkan akurasi, metode pengurangan parameter ini membantu mencegah *overfitting* (Thangaraj et al., 2023).

Evaluasi Hasil

Untuk menghitung kinerja model yang sudah dibuat, evaluasi hasil digunakan; dalam penelitian ini, evaluasi akan menggunakan *confusion matrix* untuk menghitung rasio prediksi benar dan salah. Matriks ini memberikan detail mendalam tentang klasifikasi aktual dibandingkan dengan klasifikasi yang diprediksi yang dibuat oleh model, yang memungkinkan analisis menyeluruh atas keakuratannya.

Ada beberapa model evaluasi yang akan dihasilkan dari *confusion matrix*, yaitu *accuracy* adalah proporsi prediksi yang benar (baik positif maupun negatif) dari semua prediksi yang dibuat dengan menggunakan persamaan 6. *Precision* (juga dikenal sebagai Nilai Prediktif Positif), mengukur proporsi kejadian yang diprediksi dengan benar sebagai

positif dari semua kejadian yang diprediksi, perhitungannya menggunakan persamaan 7. *Recall* adalah ukuran seberapa besar jumlah kejadian positif yang diprediksi dengan benar dibandingkan dengan semua kejadian positif yang sebenarnya, perhitungannya menggunakan persamaan 8. Dan yang terakhir *F1-Score* adalah rata-rata antara *Precision* dan *Recall*, yang memberikan satu metrik untuk menyeimbangkan kedua metrik tersebut (Ameslek et al., 2024), perhitungan *F1-score* menggunakan persamaan 9.

$$Accuracy = \frac{TP+TN}{TP+FP+FN+TN} \quad (6)$$

$$Precision = \frac{TP}{TP+FP} \quad (7)$$

$$Recall = \frac{TP}{TP+FN} \quad (8)$$

$$F1 \text{ score} = \frac{2 \times Precision \times Recall}{Precision+recall} \quad (9)$$

HASIL DAN PEMBAHASAN

Komputer dengan RAM 16 GB, VGA Nvidia GTX, dan *processor core i5* digunakan untuk menjalankan seluruh eksperimen penelitian. Selain itu, untuk menjalankannya, aplikasi jupyter *notebook* dengan Bahasa pemrograman *Python* versi 3.9.7, Selama proses pelatihan model, dataset dibagi menjadi dua: 80% sebagai data pelatihan dan 20% sebagai data pengujian, kemudian *data training* akan dibagi menjadi 80% *data training* dan 20% *data validation*. Dalam prosesnya pelatihannya dilakukan penyeimbangan dataset menggunakan algoritma SMOTE karena agar hasil akurasi yang didapatkan baik. Jumlah dataset yang digunakan pada data training sebanyak 2100 pada klas *mouth ulcer*, 2048 data pada klas *caries*, 1875 pada klas *gingivitis* dan 997 pada klas *hypodontia*. Setelah dilakukan penyeimbangan data data set menggunakan SMOTE menghasilkan data sebanyak 2100 data pada setiap kelas, lebih jelasnya dapat dilihat pada Tabel 1.

Tabel 1. Jumlah Dataset Sebelum Dan Sesudah Smote

Nama Klas	Tanpa SMOTE	SMOTE
<i>Mouth Ulcer</i>	2100	2100
<i>Caries</i>	2048	2100
<i>Gingivitis</i>	1875	2100
<i>Hypodontia</i>	997	2100

Selain itu, penelitian ini membandingkan berbagai teknik pengajaran mesin dengan metode yang disarankan. metode machine learning yang menjadi pembanding sebagai contoh, seperti KNN, *Multinomial Naive Bayes* (Multinomial NB), *Logistic Regression*, dan *Linear Support Vector Classifier* (*Linear SVC*). Pada pemodelan menggunakan algoritma *machine learning*, proses ekstraksi fiturnya menggunakan algoritma GLCM (*Grey Level Co-Occurrence*). Berdasarkan Tabel 2, dapat di lihat bahwa metode KNN menghasilkan akurasi sebesar 63%, *Multinomial Naive Bayes* (Multinomial NB) menghasilkan akurasi sebesar 54%, *logistic regression* sebesar 61% dan *Linear Suppor Vektor Clasifier* sebesar 65%.

Tabel 2. Perbandingan Algoritma Lainnya

Algoritma	Accuracy
KNN	0.63
Multinomial NB	0.54
Logistic Regression	0.61
Linear SVC	0.65

Kemudian dilakukan pelatihan dengan metode usulan, dengan menggunakan algoritma CNN model architecture *Inception-V3*. Pada penelitian ini juga akan dilakukan perbandingan dengan algoritma CNN standart dan model architecture lainnya yaitu *ResNet50*. Sebelum masuk pada proses pelatihan model, terlebih dahulu menentukan parameter dari *inception-V3* yang sangat penting karena dapat mempengaruhi hasil akurasi. Parameter *inception-V3* yang digunakan dalam penelitian ini dapat dilihat pada Tabel 3.


Tabel 3. Parameter *Inception-V3*

Nama Parameter	Nilai Parameter
<i>Activation</i>	<i>Softmax</i>
<i>Optimizer</i>	<i>Adam</i>
<i>Learning Rate</i>	0.1
<i>Batch Size</i>	64
<i>Loss Function</i>	<i>Sparse Categorical Cross-Entropy</i>
<i>Dropout</i>	0.5
<i>Epochs</i>	15


Berdasarkan hasil pelatihan model yang telah dilakukan dan dengan menggunakan parameter yang sama, di dapatkan hasil metode usulan memiliki akurasi yang lebih baik dari metode CNN standar dan *ReNet50*. Dapat dilihat pada Tabel 4, algoritma CNN dengan model architecture *Inception-V3* menghasilkan akurasi sebesar 94% lebih baik sedikit dari model architecture *ResNet-50* yang menghasilkan akurasi sebesar 93%. Model architecture *inception-V3* juga terbukti dapat meningkatkan akurasi model algoritma CNN yang menghasilkan akurasi 81%. Dapat dilihat juga pada grafik gambar 4 dan Gambar 5, hasil pelatihan model *inception-V3* memiliki akurasi pada tahap pelatihan dan pengujian yang sama sebesar 94% dan stabil naik terus, serta *training loss* dan *validation loss* yang dihasilkan tidak terlalu tinggi perbedaannya yaitu sebesar 0,17 dan 0,18 menggambarkan bahwa metode usulan *inception-V3* tidak terjadi *overfitting*. Sedangkan CNN Akurasi pelatihan sebesar 81% dan akurasi pengujian sebesar 80% serta cenderung naik turun pada setiap *epochs*-nya. *Validation loss* yang dihasilkan lebih besar dari pada *training loss* yaitu secara berturut-turut sebesar 0.57 dan 0.49. Pada penelitian ini juga dilakukan evaluasi hasil menggunakan *confusion matrix*. Hasil *confusion matrix* pada metode CNN *precision* sebesar 82%, *recall* dan *F-1 score* sama 81%, lebih jelasnya dapat dilihat pada Gambar 6. Sedangkan pada metode usulan *inception-V3* menghasilkan nilai *precision*, *recall* dan *F-1 score* sama besarnya yaitu 94%, lebih jelasnya dapat dilihat pada Gambar 7.

Tabel 4. Hasil pengujian CNN dan Inception-V3

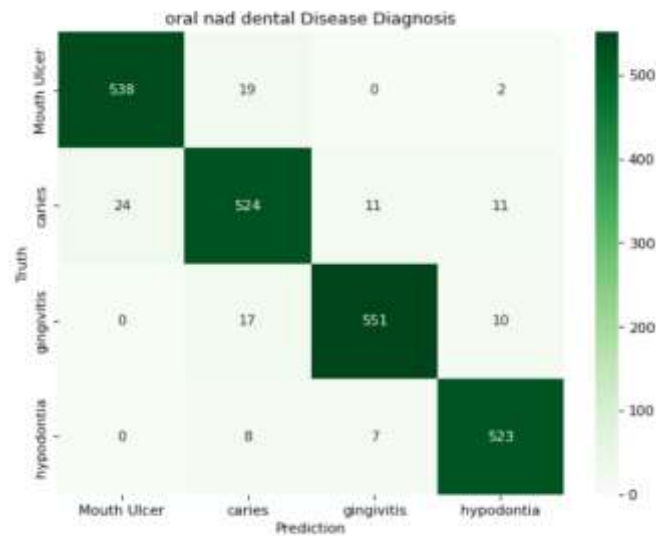
Algoritma	Training Akurasi	Training Loss	Validasi on Akurasi	Validasi on loss	Precisi on	Recall	F-1 score
CNN	81.3%	0.57	80.4%	0.49	82%	81%	81%
Inception-V3	94.2%	0.17	94.17%	0.18	94%	94%	94%



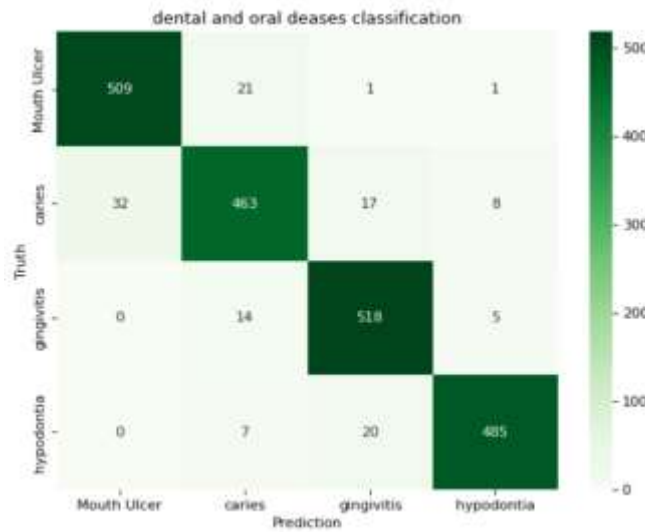
Gambar 4. Grafik Hasil Pelatihan Model Inception-V3



Gambar 5. Grafik Hasil Pelatihan Model CNN



Gambar 6. Confusion Matrix CNN




Gambar 7. Confusion Matrix Inception-V3


Pada penelitian ini juga dilakukan perbandingan dengan model *architecture* yang lain yaitu dengan VGG-16 dan *ResNet50*. Berdasarkan eksperimen yang dilakukan, Model VGG-16 menghasilkan *training* akurasi lebih tinggi dari model *ResNet50* dan *inception-V3* dengan nilai sebesar 98%. Tetapi *validation* akurasi tidak lebih besar dari model *inception-V3*. Lebih jelasnya dapat dilihat pada Tabel 5. Berdasarkan grafik hasil pelatihan model VGG-16 pada Gambar 8 dapat dilihat bahwa terjadi *overfitting* pada model tersebut karena *training* akurasi dan *validation* akurasi terdapat perbedaan nilai yang cukup besar, serta nilai *loss* pada saat pelatihan terus menurun berbanding terbalik dengan *nilai loss validation* yang semakin bertambah. Pada tabel 6 dapat dilihat hasil pengujian dengan menggunakan data testing, *inception-V3* menghasilkan Akurasi terbaik dengan akurasi sebesar 93.8%.

Tabel 5. Hasil Pengujian Model Architecture CNN


Algoritma	Training Akurasi	Training Loss	Validati on Akurasi	Validati on loss	Precisi on	Recall	F-1 score
VGG-16	98.8%	0.02	88.9%	0.56	89%	89%	89%
Renet50	86,2%	0,51	77,8	0,67	83%	76%	76%
Inception-V3	94.2%	0.17	94.17%	0.18	94%	94%	94%




Gambar 8. Grafik Hasil Pelatihan Model VGG-16



Gambar 9. Grafik Hasil Pelatihan Model Resnet50



Gambar 10. Confusion Matrix VGG-16



Gambar 11. Confusion Matrix Resnet50

Tabel 6. Hasil Pengujian menggunakan Data testing

Algoritma	CNN	VGG-16	ResNet50	Inception-V3
Akurasi	81,34%	88,7%	76,25%	93.8%

KESIMPULAN

Berdasarkan hasil pengujian yang telah dilakukan, metode usulan *inception-V3* telah berhasil dan dapat menghasilkan akurasi yang baik dalam kasus klasifikasi penyakit mulut dan gigi. Algoritma *deep learning* juga terbukti lebih baik dari algoritma *machine learning* seperti KNN, *Multinomial Naive Bayes* (Multinomial NB), *Logistic Regression* dan *Linear Support Vector Classifier* (Linear SVC) dalam pengklasifikasiannya dengan menggunakan ekstraksi fitur GLCM (*Grey Co-Occurrence Matrix*). Metode usulan juga menghasilkan akurasi yang lebih baik dari algoritma *deep learning* lainnya seperti CNN, VGG-16 dan *ResNet50*. Pada metode usulan *inception-V3* tidak terjadi *overfitting* karena hasil training akurasi dan validation akurasi tidak jauh berbeda dan cenderung sama dan terus naik tiap epoch-nya, serta nilai *loss* pada tahap pelatihan dan pengujian yang cenderung sama-sama stabil terus turun tiap epoch-nya. Saran untuk penelitian yang berikutnya dapat melakukan pengujian pada parameter *inception-V3* dan jumlah *epoch* yang digunakan, agar dapat menghasilkan hasil akurasi yang lebih baik dengan waktu dan biaya komputasi yang lebih cepat.

DAFTAR PUSTAKA

- Ahmed, M., Afreen, N., Ahmed, M., Sameer, M., & Ahamed, J. (2023). An inception V3 approach for malware classification using machine learning and transfer learning. *International Journal of Intelligent Networks*, 4(September 2022), 11–18. <https://doi.org/10.1016/j.ijin.2022.11.005>
- Al-Ghamdi, A. S. A. M., Ragab, M., Alghamdi, S. A., Asseri, A. H., Mansour, R. F., & Koundal, D. (2022). Detection of Dental Diseases through X-Ray Images Using Neural Search Architecture Network. *Computational Intelligence and Neuroscience*, 2022. <https://doi.org/10.1155/2022/3500552>
- Almalki, Y. E., Din, A. I., Ramzan, M., Irfan, M., Aamir, K. M., Almalki, A., Alotaibi, S., Alaglan, G., Alshamrani, H. A., & Rahman, S. (2022). Deep Learning Models for Classification of Dental Diseases Using Orthopantomography X-ray OPG Images. *Sensors*, 22(19). <https://doi.org/10.3390/s22197370>
- Ameslek, O., Zahir, H., Latifi, H., & Bachaoui, E. M. (2024). Combining OBIA, CNN, and UAV imagery for automated detection and mapping of individual olive trees. *Smart Agricultural Technology*, 9(July), 100546. <https://doi.org/10.1016/j.atech.2024.100546>
- Arivoli, A., Golwala, D., & Reddy, R. (2022). CoviExpert: COVID-19 detection from chest X-ray using CNN. *Measurement: Sensors*, 23(July), 100392. <https://doi.org/10.1016/j.measen.2022.100392>
- Hairani, H., & Widiyaningtyas, T. (2024). Augmented Rice Plant Disease Detection with Convolutional Neural Networks. *INTENSIF: Jurnal Ilmiah Penelitian Dan Penerapan Teknologi Sistem Informasi*, 8(1), 27–39. <https://doi.org/10.29407/intensif.v8i1.21168>
- Jaiswal, P., & Bhirud, S. (2021). Classification and Prediction of Oral Diseases in Dentistry using an Insight from Panoramic Radiographs and Questionnaire. *2021 5th International Conference on Information Systems and Computer Networks, ISCON 2021, October 2021*. <https://doi.org/10.1109/ISCON52037.2021.9702402>
- Jusman, Y., Anam, M. K., Puspita, S., Saleh, E., Kanafiah, S. N. A. M., & Tamarena, R. I. (2021). Comparison of Dental Caries Level Images Classification Performance using KNN and SVM Methods. *Proceedings of the 2021 IEEE International Conference on Signal and Image Processing Applications, ICSIPA 2021*, 167–172.

<https://doi.org/10.1109/ICSIPA52582.2021.9576774>

- Kaope, C., & Pristyanto, Y. (2023). The Effect of Class Imbalance Handling on Datasets Toward Classification Algorithm Performance. *MATRIK : Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer*, 22(2), 227–238. <https://doi.org/10.30812/matrik.v22i2.2515>
- Khalid, M., Niazi, K., Parwani, A. V, & Gurcan, M. (2021). Digital Pathology and Artificial Intelligence. *Lancet Oncology*, 20(5). [https://doi.org/10.1016/S1470-2045\(19\)30154-8](https://doi.org/10.1016/S1470-2045(19)30154-8). Digital
- Kiflie, M. A., Sharma, D. P., & Haile, M. A. (2024). Deep learning for Ethiopian indigenous medicinal plant species identification and classification. *Journal of Ayurveda and Integrative Medicine*, 15(6), 100987. <https://doi.org/10.1016/j.jaim.2024.100987>
- Kushartanto, A. I., Fauziah, F., & Aldisa, R. T. (2024). Comparison of CNN and SVM Methods on Web-based Skin Disease Classification Process. *Sinkron*, 8(2), 778–788. <https://doi.org/10.33395/sinkron.v8i2.13349>
- Lee, J. H., Kim, D. H., Jeong, S. N., & Choi, S. H. (2018). Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. *Journal of Periodontal and Implant Science*, 48(2), 114–123. <https://doi.org/10.5051/jpis.2018.48.2.114>
- Muhammad Ifan Rifani Ihsan, Agustine, Lady, Rizka Dahlia, & Ahmad Fachrurozi. (2022). Sistem Pakar Diagnosa Penyakit Pada Gigi Berbasis Web Dengan Penalaran Forward Chaining. *Elkom : Jurnal Elektronika Dan Komputer*, 15(2), 403–411. <https://doi.org/10.51903/elkom.v15i2.921>
- Mujahid, M., Rustam, F., Álvarez, R., Luis Vidal Mazón, J., Díez, I. de la T., & Ashraf, I. (2022). Pneumonia Classification from X-ray Images with Inception-V3 and Convolutional Neural Network. *Diagnostics*, 12(5), 1280. <https://doi.org/10.3390/diagnostics12051280>
- Nia, Afdillah. Fachruddin, A. N. (2023). Survey Dan Pemeriksaan Kesehatan Gigi Dalam Upaya Peningkatan Derajat Kesehatan Gigi dan Mulut. *Jurnal Abdi Dan ...*, 01(2), 26–31.
- Oztekin, F., Katar, O., Sadak, F., Yildirim, M., Cakar, H., Aydogan, M., Ozpolat, Z., Talo Yildirim, T., Yildirim, O., Faust, O., & Acharya, U. R. (2023). An Explainable Deep Learning Model to Prediction Dental Caries Using Panoramic Radiograph Images. *Diagnostics*, 13(2). <https://doi.org/10.3390/diagnostics13020226>
- Putra, I. P., Rusbandi, R., & Alamsyah, D. (2022). Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network. *Jurnal Algoritme*, 2(2), 102–112. <https://doi.org/10.35957/algoritme.v2i2.2360>
- Quoc, N., Trong, N., & Hoai, V. (2024). Fault classification and localization in power transmission line based on machine learning and combined CNN-LSTM models. *Energy Reports*, 12(November), 5610–5622. <https://doi.org/10.1016/j.egy.2024.11.061>
- Ramdhani, M. A., Ramdhani, M. A., Maylawati, D. S. adillah, & Mantoro, T. (2020). Indonesian news classification using convolutional neural network. *Indonesian Journal of Electrical Engineering and Computer Science*, 19(2), 1000–1009. <https://doi.org/10.11591/ijeecs.v19.i2.pp1000-1009>
- Sonavane, A., Yadav, R., & Khamparia, A. (2021). Dental cavity classification of using convolutional neural network. *IOP Conference Series: Materials Science and Engineering*, 1022(1). <https://doi.org/10.1088/1757-899X/1022/1/012116>

- Sun, X., Li, G., Qu, P., Xie, X., Pan, X., & Zhang, W. (2022). Research on plant disease identification based on CNN. *Cognitive Robotics*, 2(May), 155–163. <https://doi.org/10.1016/j.cogr.2022.07.001>
- Thakur, S., & Kumar, A. (2021). X-ray and CT-scan-based automated detection and classification of covid-19 using convolutional neural networks (CNN). *Biomedical Signal Processing and Control*, 69(March), 102920. <https://doi.org/10.1016/j.bspc.2021.102920>
- Thangaraj, R., P, P., Ramakrishnan, J., R, N., & Eswaran, S. (2023). A deep convolution neural network for automated COVID-19 disease detection using chest X-ray images. *Healthcare Analytics*, 4(April), 100278. <https://doi.org/10.1016/j.health.2023.100278>
- Ustyannie, W., & Suprpto, S. (2020). Oversampling Method To Handling Imbalanced Datasets Problem In Binary Logistic Regression Algorithm. *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, 14(1), 1. <https://doi.org/10.22146/ijccs.37415>