

# KLASIKASI CITRA PADA PENYAKIT KANKER MULUT MENGGUNAKAN ARSITEKTUR DENSENET201 MENGGUNAKAN OPTIMASI ADAM DAN SGD

Muhammad Fauzan Novriandy, Basuki Rahmat, Achmad Junaidi  
Teknik Informatika, Universitas Pembangunan Nasional Veteran Jawa Timur  
Jalan Raya Karanglo km 2 Malang, Indonesia  
20081010255@student.upnjatim.ac.id

## ABSTRAK

Kanker mulut merupakan salah satu kanker terbanyak yang terjadi di dunia dan tercatat menempati urutan keenam pada kategori kanker yang sering terjadi serta kanker yang paling banyak menyebabkan kematian. Klasifikasi penyakit kanker mulut menggunakan 5.000 data gambar untuk 2 kelas yaitu Normal dan Oral Squamous Cell Carcinoma (OSCC). Peneliti menggunakan arsitektur Densenet201 dengan optimizer Adam dan SGD untuk melakukan klasifikasi pada dataset yang terbatas. Hasil Penelitian menggunakan Densenet201 memiliki hasil akurasi lebih baik apabila menggunakan Optimasi SGD, Akuisisi Data 80 % dan 20 %, menggunakan Batch Size 32 dengan akurasi sebesar 0.96 daripada Optimasi Adam dengan akurasi tertinggi pada penerapan model Densenet201 menggunakan Optimasi Adam pada Akuisisi Data 70 % dan 30 %, dan Batch Size 64 dengan memperoleh akurasi sebesar 0.86. Pada pelatihan dan pengujian dengan data uji/validasi, model Densenet201 menggunakan Optimasi SGD pada akuisisi data 80 % dan 20 %, menggunakan Batch Size 32 mencapai hasil klasifikasi gambar terbaik. Kelas normal berhasil diklasifikasikan dengan benar sebanyak 338 gambar, sedangkan terdapat 22 gambar yang salah diklasifikasikan. Untuk kelas OSCC, terdapat 334 gambar yang diklasifikasikan dengan benar dan hanya 6 gambar yang salah diklasifikasikan.

**Kata kunci :** *Transfer Learning, Densenet201, Adam, SGD, Kanker Mulut*

## 1. PENDAHULUAN

Kanker adalah sekelompok besar penyakit yang hampir semua organ atau jaringan tubuh ketika sel-sel abnormal tumbuh tak terkendali, melampaui batas dan biasanya menyerang bagian tubuh yang berdekatan dan menyebar ke organ lain [1]. Kanker rongga mulut merupakan salah satu kanker terbanyak yang terjadi di dunia dan tercatat menempati urutan keenam pada kategori kanker yang paling sering terjadi serta kanker yang paling banyak menyebabkan kematian. Di wilayah Indonesia, persentase kanker mulut sebesar 42% dari seluruh kanker pada manusia dan 1,01% terjadi pada kanker lidah. Persentase terjadinya kanker mulut di area sekitar rongga mulut bervariasi antara area satu dengan lainnya, yaitu sekitar 30%-40% terjadi pada bibir bawah, 25% di lidah, dan pada dasar mulut sekitar 20% [2].

Pencegahan yang dilakukan untuk mengetahui gejala kanker mulut selain dengan proses medis dapat diupayakan melalui pemanfaatan teknologi. Sebagai contoh ialah penggunaan image processing atau pengolahan citra digital untuk mengidentifikasi kanker pada mulut. Metode CNN atau *Convolutional Neural Network* telah menjadi salah satu metode untuk masalah klasifikasi gambar dalam beberapa tahun terakhir [3]. Hal ini terutama dikarenakan arsitektur model berlapis-lapis digunakan untuk mengekstraksi dan mempelajari fitur-fitur kompleks dari data.

CNN sendiri memiliki beragam model arsitektur seperti contohnya Densenet201, maka dari itu arsitektur model berlapis-lapis yang membantu dalam mengekstraksi dan mempelajari fitur-fitur kompleks yang terkait dengan tugas langsung dari data. Namun, pendekatan ini memerlukan sejumlah besar data agar

dapat memberikan hasil yang menjanjikan. Untuk mengatasi masalah ini, diperkenalkan model terlatih dengan konsep *transfer learning*. *Transfer learning* dicapai dengan mempertimbangkan kerangka jaringan dalam bersama dengan bobot yang telah dilatih sebelumnya pada kumpulan data besar dan kemudian mengadaptasi bobot pada tugas target dengan kumpulan data berukuran terbatas.

Penunjang kinerja pengolahan citra dapat diterapkan Optimasi Algoritma, Algoritma optimasi seperti SGD (*Stochastic Gradient Descent*) dan Adam (*Adaptive Moment Estimation*), sering digunakan dalam model pembelajaran mesin untuk mempercepat konvergensi (proses di mana model mencapai titik di mana peningkatan lebih lanjut dalam pelatihan tidak signifikan) dan mencapai hasil yang lebih baik, seperti meningkatkan akurasi atau mengurangi fungsi kerugian model.

## 2. TINJAUAN PUSTAKA

### 2.1. Kanker Mulut

Kanker mulut merupakan salah satu jenis kanker yang tumbuh dan berkembang di sekitar mulut sampai rongga mulut atau orofaring namun kebanyakan kanker ini belum terdiagnosis sampai kanker telah menyebar ke kelenjar getah bening di leher dan rahang. Oleh karena itu, apabila kanker ini terlambat ditemukan maka 25 % penyakit kanker mulut bersifat fatal [4].

Resiko terjadinya kanker mulut meningkat diakibatkan oleh tembakau dan alkohol, dan faktor lain seperti selaput lendir yang mengalami rangsangan kronis disebabkan kurangnya kebersihan mulut dan longgarnya gigi palsu, dan lain sebagainya.

## 2.2. Citra Digital

Citra yang dapat diolah oleh komputer secara langsung merupakan citra digital, nilai-nilai real ataupun kompleks yang direpresentasikan dengan deretan bit tertentu merupakan isi dari sebuah citra digital. Intensitas atau tingkat keabuan dari citra dapat disimpulkan sebagai fungsi  $(x, y)$  dan memiliki ukuran  $M$  merupakan baris,  $N$  merupakan kolom,  $x$  merupakan koordinat spasial, dan  $f$  dititik koordinat  $(x, y)$ . Disimpulkan bahwa citra tersebut adalah citra digital. Jika nilai  $(x, y)$  dan nilai amplitudo  $f$  secara keseluruhan finite dan memiliki nilai diskrit [5].

## 2.3. Machine Learning

Proses pembelajaran *Machine Learning* dimulai dengan mengobservasi data, pengalaman langsung, dan arahan hingga mengerti pola dari data supaya dapat membuat keputusan yang lebih baik di masa yang akan datang sesuai dengan data yang diberikan. *Machine Learning* dapat disebut sebagai pemrograman dengan data. Tujuan utama dari *Machine Learning* adalah komputer mampu belajar dengan sendiri tanpa bantuan dari manusia dan penyesuaian tindakan [6].

## 2.4. Deep Learning

Pada dasarnya, *deep learning* bekerja dengan cara menyajikan model komputasi yang dapat mengenali pola yang lebih kompleks dan abstrak. Ini memungkinkan *deep learning* untuk menyelesaikan tugas-tugas seperti pengenalan wajah, penerjemahan bahasa, pengenalan suara, dan banyak lagi. *Deep learning* telah menunjukkan hasil yang mengesankan dalam sejumlah aplikasi, terutama ketika memiliki volume data yang besar untuk dilatih [7].

## 2.5. Convolutional Neural Network

CNN merupakan salah satu jenis metode dari *Deep Neural Network*. Prinsip kerja metode CNN ini mirip dengan metode MLP, namun pada metode CNN setiap neuron disajikan dalam bentuk dua dimensi, yang tidak sama dengan metode MLP, dimana setiap neuron hanya memiliki satu dimensi [8].

## 2.6. Densenet201

Dense Convolutional Network (DenseNet) merupakan salah satu model arsitektur *Deep Learning* yang menghubungkan setiap layer beserta feature-maps ke seluruh layer berikutnya. Layer berikutnya akan menerima input feature-maps dari seluruh layer sebelumnya. DenseNet menghubungkan setiap lapisan/blok ke setiap lapisan/blok lainnya dengan cara umpan maju. Sedangkan jaringan konvolusional tradisional dengan  $L$  lapisan memiliki koneksi  $L - 1$  antara setiap lapisan dan lapisan berikutnya jaringan memiliki koneksi langsung  $L(L + 1)/2$ . DenseNet memiliki beberapa keunggulan menarik antara lain meringankan masalah gradien-gradien, memperkuat penyebaran fitur, mendorong penggunaan kembali fitur, dan secara substansial mengurangi jumlah parameter [9].

## 2.7. Optimasi Adam

Adam pertama kali diperkenalkan pada makalah ICLR pada tahun 2015 oleh Diederik Kingma [10]. Algoritma optimasi ini memiliki kelebihan dimana sangat efisien secara komputasi dan dalam prosesnya membutuhkan sedikit memori. Adam atau *Adaptive Moment Estimation* merupakan algoritma pengembangan dari Adagrad dimana cara kerjanya mirip kombinasi antara RMSProp dan Momentum, disebut adaptive karena mirip RMSProp dimana learning rate berubah sepanjang training, dan moment estimation karena menggunakan estimasi momen pada matematika.

## 2.8. Optimasi SGD

SGD atau *Stochastic Gradient Descent* biasa merupakan algoritma optimasi yang mencari suatu bobot baru dengan metode pengambilan salah satu data dari semua data training, sesudah itu SGD melakukan analisa dari setiap data yang diambil. Memakai SGD dapat mengurangi penggunaan memori yang diperlukan disaat pemrosesan bobot baru dan dalam sehingga proses pembelajaran model lebih cepat, akan tetapi dalam proses pembelajaran model akan sering terjadi fluktuasi yang cukup tinggi [11].

## 2.9. Flatten

Sebelum dimasukkan ke dalam *layer fully connected*, setiap neuron dalam *convolutional layer* harus diubah menjadi data satu dimensi terlebih dahulu. Hasil dari proses feature extraction dengan *convolutional* dan *pooling layer* menghasilkan *feature map* dalam bentuk *array* multidimensi. Oleh karena itu, *feature map* harus diflatten atau di-reshape menjadi sebuah vektor agar bisa digunakan sebagai input oleh *layer fully connected* [12].

## 2.10. Sigmoid

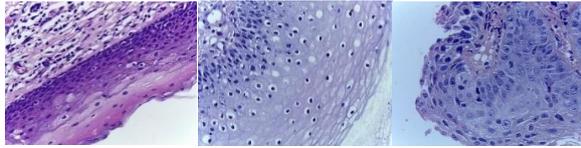
Fungsi sigmoid menghasilkan output dalam rentang 0 hingga 1, yang berguna dalam konteks di mana model perlu memberikan output yang terbatas, seperti probabilitas [13]. Ketika digunakan dalam lapisan output untuk masalah klasifikasi biner, output dari fungsi sigmoid dapat diartikan sebagai probabilitas kelas positif. Ini memudahkan interpretasi hasil model.

## 3. METODE PENELITIAN

Pada bagian ini memuat metode yang digunakan pada pembuatan skripsi.

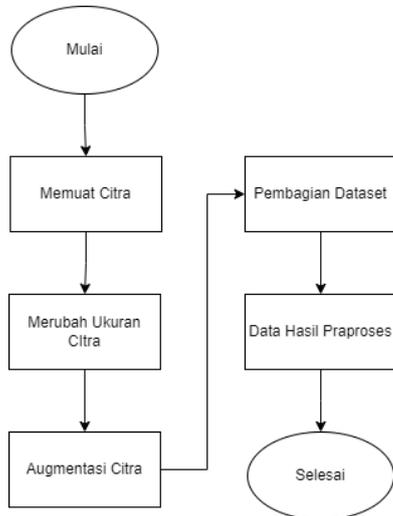
### 3.1. Pengumpulan Data

Dataset ini berisi tentang gambar histopatologi yang dapat terjadi pada kanker mulut. Data tersebut bersifat publik dan terdiri dari dua jenis data, yaitu mulut yang sehat atau normal sebanyak 2.500 data gambar, dan mulut yang terkena kanker atau abnormal atau ganas sebanyak 2.500 data gambar, dengan total keseluruhan sebanyak 5.000 data gambar. Sampel data ini digunakan dalam penelitian sebagai contoh:



Gambar 1. Gambar sampel dataset kanker mulut

3.2. Praproses Data

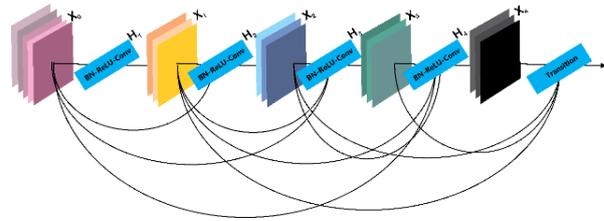


Gambar 2. Gambar alur praproses data

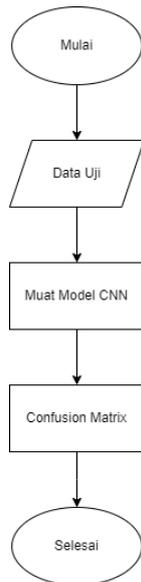
Praproses yang terdiri dari tiga langkah seperti yang terlihat pada Gambar 2. Pertama, penulis akan mengubah ukuran citra menjadi 224x224. Kemudian, proses selanjutnya yaitu melakukan augmentasi citra dikarenakan pelatihan dataset yang terbatas dan menghindari overfitting pada model, dan selanjutnya akan melakukan pembagian dataset menjadi tiga subset utama yaitu data pelatihan (*training data*), data validasi (*validation data*), dan data pengujian (*test data*).

3.3. Perancangan Arsitektur

DenseNet-201 yang merupakan Jaringan Saraf Konvolusional (Convolutional Neural Network/CNN) dengan 201 lapisan yang terhubung secara padat dan dirancang untuk memfasilitasi tugas pengenalan gambar dan klasifikasi dalam ranah deep learning. Pengembangan DenseNet dilakukan oleh Gao Huang, Zhuang Liu, dan Kilian Q. Weinberger, sebagai lanjutan dari konsep-konsep yang mendasari arsitektur sebelumnya seperti ResNet (Residual Network). DenseNet memanfaatkan lapisan transisi untuk mengurangi dimensi data spasial di antara Dense Blocks, yang dicapai melalui penerapan konvolusi 1x1 dan operasi pooling. Pada Gambar berikut menjelaskan lapisan transisi dari DenseNet.



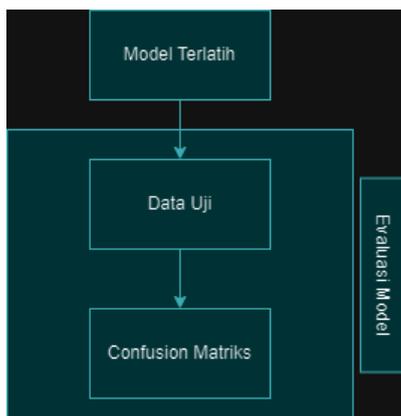
### 3.5. Pengujian Model



Gambar 5. Gambar alur pengujian model

Model diuji dengan menggunakan 3500 citra dari data uji pada skenario pengujian akuisisi data 70% dan 30%, kemudian menggunakan 4000 citra dari data uji pada skenario pengujian akuisisi data 80% dan 20 % yang telah melalui proses prapemrosesan. Setelah proses pengujian, nilai prediksi akan dibandingkan dengan nilai label asli pada data uji untuk menghitung jumlah prediksi yang benar. Selanjutnya, *Confusion matrix* dapat digunakan untuk mengevaluasi kinerja model.

### 3.6. Evaluasi Model



Gambar 6. Gambar alur evaluasi model

Dalam konteks penelitian ini, evaluasi dilakukan dengan menggunakan model yang telah di-*train* pada data uji. Pendekatan yang umum digunakan untuk evaluasi performa model adalah dengan memanfaatkan metode *confusion matrix*. *Confusion*

*matrix* memungkinkan kita untuk mengukur kinerja model secara lebih rinci. Dari *confusion matrix*, kita dapat menghitung berbagai metrik evaluasi seperti akurasi, presisi, recall, dan f1 score. Akurasi menunjukkan seberapa tepat model dalam mengklasifikasikan keseluruhan data uji. Presisi memberikan gambaran tentang proporsi dari kelas positif yang secara tepat diklasifikasikan oleh model. *Recall*, atau juga dikenal sebagai *sensitivity*, mengukur kemampuan model dalam menemukan kembali semua contoh positif. F1 score adalah rata-rata harmonis dari *presisi* dan *recall*.

## 4. HASIL DAN PEMBAHASAN

Adapun hasil dan pembahasan yang akan dijelaskan menjadi beberapa sub bab.

### 4.1. Persiapan Dataset

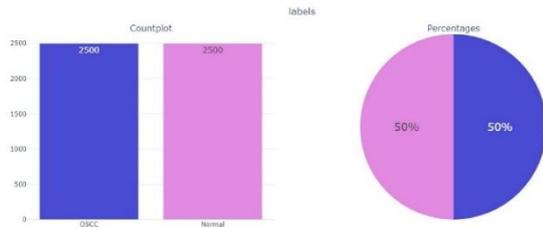
Data yang akan digunakan dalam penelitian ini berasal dari Website yaitu Mendeley Data, dimana website ini menawarkan penyimpanan berbagi data penelitian. Data tersebut merupakan data publik yang terdiri dari dua jenis, yaitu gambar histopatologi mulut yang sehat dan mulut yang terkena kanker atau abnormal. Setiap kelas terdiri dari 2500 data, sehingga totalnya terdapat 5000 gambar yang akan digunakan dalam penelitian ini. Data tersebut akan digunakan untuk pengujian dalam penelitian ini.

### 4.2. Menyiapkan Data dan Label

	filepaths	labels
0	/content/drive/MyDrive/Dataset Histopathologic...	OSCC
1	/content/drive/MyDrive/Dataset Histopathologic...	OSCC
2	/content/drive/MyDrive/Dataset Histopathologic...	OSCC
3	/content/drive/MyDrive/Dataset Histopathologic...	OSCC
4	/content/drive/MyDrive/Dataset Histopathologic...	OSCC
...	...	...
4995	/content/drive/MyDrive/Dataset Histopathologic...	Normal
4996	/content/drive/MyDrive/Dataset Histopathologic...	Normal
4997	/content/drive/MyDrive/Dataset Histopathologic...	Normal
4998	/content/drive/MyDrive/Dataset Histopathologic...	Normal
4999	/content/drive/MyDrive/Dataset Histopathologic...	Normal
5000 rows x 2 columns		

Gambar 7. Gambar alur evaluasi model

Data penelitian ini terdiri dan 5000 data yang terbagi dalam dua folder yang sekaligus menggambar dua kelas. Klasifikasi pada penyakit kanker mulut ini mencakup dua kondisi yaitu Normal dan Oral Squamous Cell Carcinoma (OSCC), Setiap folder berisi data yang representatif untuk masing-masing kondisi, sehingga memungkinkan analisis yang lebih rinci dan akurat dalam penelitian ini.



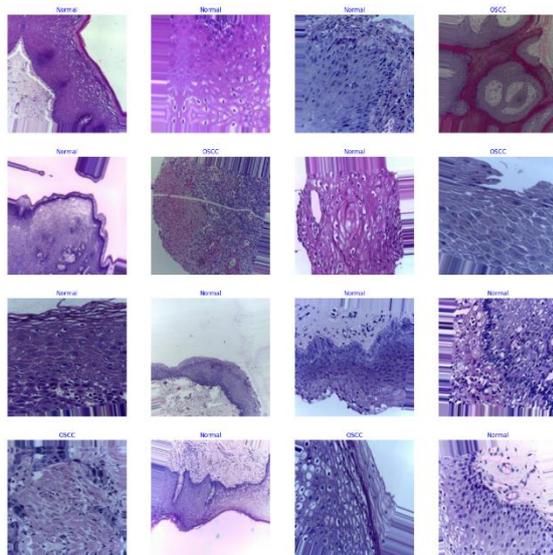
Gambar 8. Gambar alur evaluasi model

Diagram pada Gambar 8. ini memberikan gambaran visual yang jelas mengenai sebaran data pada masing-masing kelas, menyajikan perbandingan jumlah sampel yang terdapat dalam setiap kategori secara grafis.

**4.3. Praproses Data**

Setelah memuat dataset melalui google drive kemudian tahapan praproses akan dilakukan, dimana tahapan pertama yang akan dilakukan yaitu melakukan pembagian dataset, dimana pada proses skema pengajuan penelitian ini terdapat 2 skema untuk melakukan Akuisisi Data, yaitu 80% untuk data training dan 20 % untuk validasi data dan yang kedua 70% untuk data training dan 30% untuk validasi data. Pada skenario akuisisi data 80% dan 20% terbagi menjadi 4.000 train data, 250 validation data, dan 750 test data. Kemudian pada skenario akuisisi data 70% dan 30% terbagi menjadi 3.500 train data, 494 validation data, dan 1.006 test data.

Pada penelitian ini menggunakan batch size 32 dan 64. Kemudian, ukuran gambar diatur menjadi (224, 224) dengan 3 saluran warna RGB. Selanjutnya, untuk pengujian model, batch size diatur agar tidak melebihi 80 dan memastikan bahwa jumlah langkah (steps) sesuai dengan panjang data test yang telah ditentukan sebelumnya.



Gambar 9. Gambar output augmentasi data

Kemudian demi mendapatkan pada penelitian ini untuk mendapatkan preprocessing data yang optimal digunakan augmentasi data. Proses augmentasi data dimulai dengan mempersiapkan generator data untuk pelatihan, validasi, dan pengujian dalam pembelajaran mesin berbasis gambar. kemudian menampilkan beberapa contoh gambar output dari hasil augmentasi data, pada kode ini menggunakan iterasi sebanyak 16 kali (sesuai dengan jumlah subplot yang ingin ditampilkan), gambar juga dinormalisasikan dengan membaginya dengan 255.

**4.4. Implementasi Model Densenet201**

Layer (type)	Output Shape	Param #
densenet201 (Functional)	(None, 1920)	18321984
batch_normalization (Batch Normalization)	(None, 1920)	7680
dense (Dense)	(None, 256)	491776
dropout (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 2)	514

=====  
 Total params: 18821954 (71.80 MB)  
 Trainable params: 18589058 (70.91 MB)  
 Non-trainable params: 232896 (909.75 KB)  
 =====

Gambar 10. Gambar struktur model Densenet201 optimasi Adam

Pada lapisan ekstraksi fitur (densenet201 (Functional)), terdapat 18,321,984 parameter yang tidak dapat diubah. Bobot jaringan tidak akan diperbarui karena model akan menggunakan bobot yang telah dipelajari saat Arsitektur DenseNet201 dilatih pada dataset ImageNet. Dengan demikian, jaringan telah terisi dengan fitur umum yang berguna untuk klasifikasi gambar.

Pada lapisan Normalisasi Batch (batch\_normalization (Batch Normalization)), terdapat 7,680 parameter yang tidak dapat diubah. Parameter ini terkait dengan normalisasi batch pada model DenseNet201 yang telah dilatih sebelumnya.

Pada lapisan Fully Connected Layer, terdapat 491,776 parameter yang dilatih untuk klasifikasi sesuai dengan dataset yang digunakan. Bobot dan bias dalam lapisan Fully Connected Layer ini akan disesuaikan selama pelatihan untuk mempelajari fitur-fitur spesifik dari data yang dimiliki, sehingga model dapat melakukan klasifikasi yang sesuai dengan dataset yang digunakan. Total parameter yang dapat diubah (trainable params) adalah 18,589,058. Sedangkan total parameter yang tidak dapat diubah (non-trainable params) adalah 232,896.

Layer (type)	Output Shape	Param #
densenet201 (Functional)	(None, 1920)	18321984
batch_normalization (Batch Normalization)	(None, 1920)	7680
dense (Dense)	(None, 256)	491776
dropout (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 2)	514

=====  
 Total params: 18821954 (71.80 MB)  
 Trainable params: 18589058 (70.91 MB)  
 Non-trainable params: 232896 (909.75 KB)

Gambar 11. Gambar struktur model Densenet201 optimasi SGD

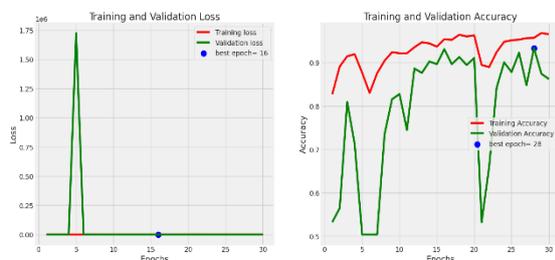
Pada bagian Functional (densenet201 (Functional)), terdapat 18,321,984 parameter yang tidak dapat diubah. Bobot jaringan tidak akan diperbarui karena model akan menggunakan bobot yang telah dipelajari saat Arsitektur DenseNet201 dilatih pada dataset ImageNet. Dengan demikian, jaringan telah terisi dengan fitur umum yang berguna untuk klasifikasi gambar.

Pada lapisan Normalisasi Batch (batch\_normalization (Batch Normalization)), terdapat 7,680 parameter yang tidak dapat diubah. Parameter ini terkait dengan normalisasi batch pada model DenseNet201 yang telah dilatih sebelumnya.

Pada lapisan Fully Connected Layer, terdapat 491,776 parameter yang dilatih untuk klasifikasi sesuai dengan dataset yang digunakan. Bobot dan bias dalam lapisan Fully Connected Layer ini akan disesuaikan selama pelatihan untuk mempelajari fitur-fitur spesifik dari data yang dimiliki, sehingga model dapat melakukan klasifikasi yang sesuai dengan dataset yang digunakan. Total parameter dalam model ini adalah 18,821,954, dengan 18,589,058 parameter yang dapat diubah (trainable params) dan 232,896 parameter yang tidak dapat diubah (non-trainable params).

**4.5. Pelatihan Model**

1. Hasil Pelatihan Densenet201 Menggunakan Optimasi Adam.

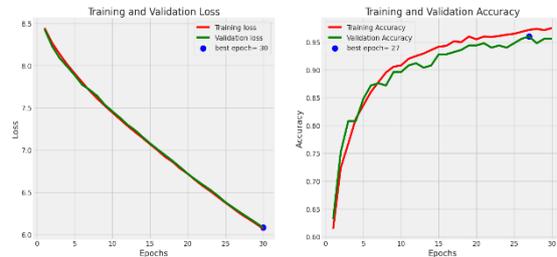


Gambar 12. Gambar visualisasi skenario pengujian 4

Pada akhir proses pelatihan, didapatkan hasil akurasi pelatihan sebesar 0,965 dan akurasi validasi

sebesar 0,862. Kemudian mendapat nilai 0,162 pada nilai fungsi kerugian (loss) dan 0,595 nilai fungsi kerugian pada akhir validasi model pada akhir pelatihan model skenario pengujian ini.

2. Hasil Pelatihan Densenet201 Menggunakan Optimasi SGD.

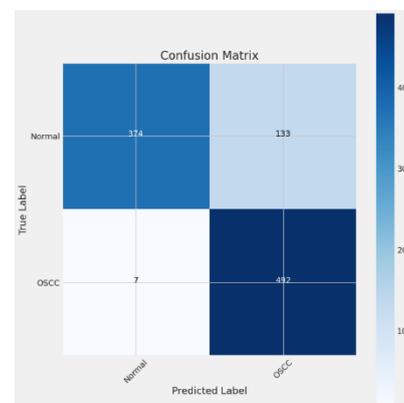


Gambar 13. Gambar visualisasi skenario pengujian 5

Pada akhir proses pelatihan, didapatkan hasil akurasi pelatihan sebesar 0,975 dan akurasi validasi sebesar 0,956. Kemudian mendapat nilai 6,067 pada nilai fungsi kerugian (loss) dan 6,081 nilai fungsi kerugian pada akhir validasi model pada akhir pelatihan model skenario pengujian ini.

**4.6. Pengujian dan Evaluasi Model**

1. Hasil Pengujian dan Evaluasi Densenet201 Menggunakan Optimasi Adam.



Gambar 14. Gambar confusion matrix skenario 4

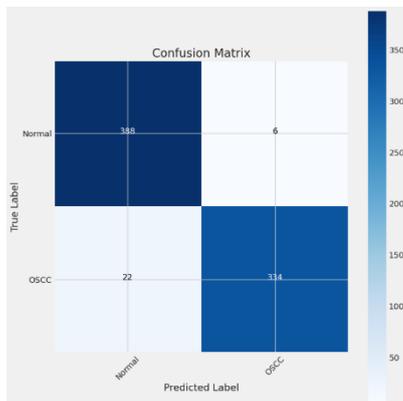
Berdasarkan matriks kebingungan, dari total data yang diuji, 866 data diklasifikasikan dengan benar dan 140 data salah klasifikasinya. True Positive (TP) untuk kelas "Normal" adalah 374, False Positive (FP) adalah 7, False Negative (FN) untuk kelas "OSCC" adalah 133, dan True Negative (TN) untuk kelas "OSCC" adalah 492, menunjukkan performa algoritma klasifikasi dalam membedakan antara kelas "Normal" dan "OSCC".

Normal	0.98	0.74	0.84	507
OSCC	0.79	0.99	0.88	499
accuracy			0.86	1006
macro avg	0.88	0.86	0.86	1006
weighted avg	0.89	0.86	0.86	1006

Gambar 15. Gambar classification report skenario 4

Pada gambar dijelaskan bahwa untuk kelas "Normal," model memiliki precision 0.98, recall 0.74, dan F1-score 0.84 dengan 507 sampel. Untuk kelas "OSCC," model menunjukkan precision 0.79, recall 0.99, dan F1-score 0.88 dengan 499 sampel. Secara keseluruhan, model memiliki akurasi 0.87. Macro average untuk precision, recall, dan F1-score masing-masing adalah 0.87, 0.86, dan 0.86, sedangkan weighted average juga menunjukkan nilai yang sama, mempertimbangkan jumlah sampel untuk setiap kelas.

2. Hasil Pengujian dan Evaluasi Densenet201 Menggunakan Optimasi SGD.



Gambar 16. Gambar confusion matrix skenario 5

Berdasarkan matriks kebingungan, dari 750 data yang diuji oleh model klasifikasi, 672 data diklasifikasikan dengan benar dan 28 data salah klasifikasinya. Untuk kelas "Normal," terdapat 338 True Positives (TP) dan 22 False Positives (FP). Untuk kelas "OSCC," terdapat 334 True Negatives (TN) dan 6 False Negatives (FN).

	precision	recall	f1-score	support
Normal	0.95	0.98	0.97	394
OSCC	0.98	0.94	0.96	356
accuracy			0.96	750
macro avg	0.96	0.96	0.96	750
weighted avg	0.96	0.96	0.96	750

Gambar 17. Gambar classification report skenario 5

Model klasifikasi menunjukkan kinerja yang sangat baik dalam mengidentifikasi kelas "Normal" dan "OSCC". Untuk kelas "Normal", precision adalah 0.95, recall 0.98, dan F1-score 0.97 dengan 394 sampel. Untuk kelas "OSCC", precision adalah 0.98, recall 0.94, dan F1-score 0.96 dengan 356 sampel. Secara keseluruhan, model memiliki akurasi 0.96, dengan macro average dan weighted average untuk precision, recall, dan F1-score juga sebesar 0.96, menunjukkan performa model yang sangat baik dalam mengidentifikasi kedua kelas tersebut.

4.7. Pembahasan Pelatihan

Tabel 1. Hasil Pelatihan Model

No.	Skenario Pengujian	Waktu	Hasil Akurasi Dataset		
			Train Data	Val Data	Test Data
1.	Densenet201 Optimasi Adam, Akuisisi Data 80 % dan 20 %, dan Batch Size 32	6.109 detik	86,87 %	86 %	86,26 %
2.	Densenet201 Optimasi Adam, Akuisisi Data 80 % dan 20 %, dan Batch Size 64	6.325 detik	80,62 %	80 %	78,53 %
3.	Densenet201 Optimasi Adam, Akuisisi Data 70 % dan 30 %, dan Batch Size 32	7.171 detik	85,17 %	87,44 %	86,28 %
4.	Densenet201 Optimasi Adam, Akuisisi Data 70 % dan 30 %, dan Batch Size 64	5.627 detik	90,28 %	86,23 %	86,08 %
5.	Densenet201 Optimasi SGD, Akuisisi Data 80 % dan 20 %, dan Batch Size 32	14.355 detik	99,68 %	95,59 %	96,26 %
6.	Densenet201 Optimasi SGD, Akuisisi Data 80 % dan 20 %, dan Batch Size 64	4.073 detik	96,09 %	93,19 %	94,53 %
7.	Densenet201 Optimasi SGD, Akuisisi Data 70 % dan 30 %, dan Batch Size 32	3.653 detik	98,31 %	95,14 %	96,22 %
8.	Densenet201 Optimasi SGD, Akuisisi Data 70 % dan 30 %, dan Batch Size 64	3.589 detik	95,2 %	92,1 %	93,14 %

Pada tabel diatas akurasi dataset terbaik secara keseluruhan diperoleh nomor 5 dengan menggunakan Densenet201 Optimasi SGD, Akuisisi Data 80 % dan 20 %, dan Batch Size 32. Dengan masing-masing perolehan pada data train, validation, dan test yaitu 99,68 %, 95,59 %, dan 96,26 %.

Berdasarkan proses pelatihan keseluruhan yang menggunakan epoch 30 dalam semua skenario pengujian, waktu keseluruhan yang dibutuhkan paling banyak terdapat pada skenario pengujian menggunakan Densenet201 Optimasi SGD, Akuisisi Data 80 % dan 20 %, dan Batch Size 32 dengan waktu yang dibutuhkan yaitu 14.355 detik.

**4.8. Pembahasan Pengujian dan Evaluasi**

Tabel 2. Hasil Pengujian dan Evaluasi Model

No.	Skenario Pengujian	Akurasi	Rata-Rata		
			Presisi	Recall	F1-Score
1.	Densenet201 Optimasi Adam, Akuisisi Data 80 % dan 20 %, dan Batch Size 32	0,86	0,86	0,86	0,86
2.	Densenet201 Optimasi Adam, Akuisisi Data 80 % dan 20 %, dan Batch Size 64	0,79	0,80	0,79	0,78
3.	Densenet201 Optimasi Adam, Akuisisi Data 70 % dan 30 %, dan Batch Size 32	0,86	0,87	0,86	0,86
4.	Densenet201 Optimasi Adam, Akuisisi Data 70 % dan 30 %, dan Batch Size 64	0,86	0,89	0,86	0,86
5.	Densenet201 Optimasi SGD, Akuisisi Data 80 % dan 20 %, dan Batch Size 32	0,96	0,96	0,96	0,96
6.	Densenet201 Optimasi SGD, Akuisisi Data 80 % dan 20 %, dan Batch Size 64	0,95	0,95	0,95	0,95
7.	Densenet201 Optimasi SGD, Akuisisi Data 70 % dan 30 %, dan Batch Size 32	0,96	0,96	0,96	0,96
8.	Densenet201 Optimasi SGD, Akuisisi Data 70 % dan 30 %, dan Batch Size 64	0,93	0,93	0,93	0,93

Pada penelitian model Densenet201 terdapat skenario yang memiliki hasil baik, yaitu pada skenario pengujian menggunakan Densenet201 Optimasi SGD, Akuisisi Data 80 % dan 20 % dengan Batch Size 32 dan dimana skenario tersebut mendapatkan akurasi sebesar 0,96. Begitu juga pada 3 metrik yang lain yaitu Precision, Recall, dan F1-Score mendapatkan nilai paling tinggi dibandingkan penggunaan model Densenet201 yang lainnya dengan masing-masing mendapatkan nilai 0,96, 0,96 dan 0,96.

efektif dan mengurangi kebutuhan augmentasi data. Pemilihan model arsitektur harus disesuaikan dengan kompleksitas masalah dan jumlah dataset, serta menjelajahi variasi arsitektur model CNN lainnya untuk meningkatkan kinerja model. Selain itu, membuat model CNN berdasarkan arsitektur Densenet dan Resnet dengan jumlah lapisan dan parameter yang lebih sederhana namun memiliki kinerja klasifikasi yang lebih baik dalam hal akurasi juga direkomendasikan.

**5. KESIMPULAN DAN SARAN**

Pengklasifikasian penyakit kanker mulut menggunakan Arsitektur Densenet201 dapat dilakukan dengan metode Transfer Learning menggunakan bobot ImageNet. Model Densenet201 yang menggunakan optimasi SGD, akuisisi data 80% dan 20%, serta batch size 32 menghasilkan kinerja terbaik, dengan akurasi 99,68% pada data pelatihan, 95,59% pada data validasi, dan 96,26% pada data uji. Penelitian menunjukkan bahwa model Densenet201 dengan konfigurasi tersebut memiliki akurasi 0,96, lebih baik daripada penggunaan optimasi Adam dengan akurasi 0,86. Pada pelatihan dan pengujian, model ini berhasil mengklasifikasikan 338 gambar kelas normal dengan benar dan 22 gambar salah, serta 334 gambar kelas OSCC dengan benar dan hanya 6 gambar yang salah.

Untuk penelitian selanjutnya, disarankan memastikan dataset dalam jumlah besar dan distribusi data yang merata pada setiap kelas untuk memudahkan model dalam mengidentifikasi antar kelas secara

**DAFTAR PUSTAKA**

[1] World Health Organization. (2010). *World health statistics 2010*. World Health Organization.

[2] Adityawan, F., Dentawan, F., & Pritama, A. S. (2023). *Kanker Mulut*. UGM PRESS

[3] Sardogan, M., Tuncer, A., & Ozen, Y. (2018). *Plant Leaf Disease Detection and Classification ased on CNN with LVQ Algorithm*.

[4] Fajrin, M., & Fatimah, D. D. S. (2015). Perancangan Sistem Pakar Diagnosis Penyakit Kanker Mulut. *Jurnal Algoritma*, 12(2), 192-198.

[5] Putra, D. (2010). *Pengolahan Citra Digital*. Yogyakarta: CV ANDI OFFSET.

[6] Futoma, Joseph, Morgan Simons, Trishan Panch, Finale Doshi-Velez, and Leo Anthony Celi. (2020). "The Myth of Generalisability in Clinical Research and Machine Learning in Health Care." *The Lancet Digital Health* 2(9):e489–92. doi: 10.1016/S2589-7500(20)30186-2.

- 
- [7] Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
- [8] Salawazo, V. M. P., Gea, D. P. J., Gea, R. F., & Azmi, F. (2019). Implementasi metode convolutional neural network (cnn) pada peneganalan objek video cctv. *Jurnal Mantik Penusa*, 3(1.1).
- [9] Miranda, N. D., Novamizanti, L., & Rizal, S. (2020). Convolutional Neural Network pada klasifikasi sidik jari menggunakan RESNET-50. *Jurnal Teknik Informatika (Jutif)*, 1(2), 61-68.
- [10] Kingma, D. P., & Ba, J. (2017). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- [11] Ruder, S. (2016). *An overview of gradient descent optimization algorithms*. 1–14. <http://arxiv.org/abs/1609.04747>
- [12] Yudianto, M. R. A., Kusriani, K., & Al Fatta, H. (2020). Analisis Pengaruh Tingkat Akurasi Klasifikasi Citra Wayang dengan Algoritma Convolutional Neural Network. (*JurTI*) *Jurnal Teknologi Informasi*, 4(2), 182-191.
- [13] Bengio, Y., Lecun, Y., & Hinton, G. (2021). Deep learning for AI. *Communications of the ACM*, 64(7), 58-65.