

KLASIFIKASI CITRA PENYAKIT KANKER MULUT MENGGUNAKAN ARSITEKTUR RESNET50 OPTIMASI ADAM DAN SGD

Muhammad Fauzan Novriandy^{1*}, Basuki Rahmat², Achmad Junaidi³

^{1,2,3}Universitas Pembangunan Nasional “Veteran” Jawa Timur, Jl. Rungkut Madya No.1, Gn. Anyar, Surabaya

Received: 2 Juli 2024

Accepted: 31 Juli 2024

Published: 7 Agustus 2024

Keywords:

Transfer Learning, Resnet50, Adam, SGD, Oral Cancer.

Correspondent Email:

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 Resnet50 dengan optimizer Adam dan SGD untuk melakukan klasifikasi pada dataset yang terbatas. Hasil Penelitian menggunakan model Resnet50 memiliki hasil akurasi lebih baik apabila menggunakan Optimasi SGD, Akuisisi Data 80 % dan 20 %, menggunakan Batch Size 32 dengan akurasi sebesar 0.95 daripada Optimasi Adam dengan akurasi tertinggi pada penerapan model Resnet50 menggunakan Optimasi Adam pada akuisisi data 70 % dan 30 % menggunakan Batch Size 32 dengan memperoleh akurasi sebesar 0.84. Pada pelatihan dan pengujian dengan data uji/validasi, model Resnet50 menggunakan Optimasi SGD, pada Akuisisi Data 70 % dan 30 %, dan menggunakan Batch Size 32. mencapai hasil klasifikasi gambar terbaik. Kelas normal berhasil diklasifikasikan dengan benar sebanyak 470 gambar, sedangkan terdapat 26 gambar yang salah diklasifikasikan. Untuk kelas OSCC, terdapat 473 gambar yang diklasifikasikan dengan benar dan hanya 37 gambar yang salah diklasifikasikan.

Abstract. Oral cancer is one of the most common cancers worldwide, ranking sixth in terms of prevalence and being one of the leading causes of cancer-related deaths. The classification of oral cancer involves using 5,000 image data for two classes: Normal and Oral Squamous Cell Carcinoma (OSCC). The researchers used the Resnet50 architecture with Adam and SGD optimizers to classify a limited dataset. The study results indicated that the Resnet50 model achieved better accuracy when using the SGD optimizer, with data acquisition of 80% and 20%, and a batch size of 32, yielding an accuracy of 0.95, compared to the Adam optimizer, which achieved its highest accuracy of 0.84 with the Resnet50 model using a data acquisition of 70% and 30% and a batch size of 32. In training and testing with test/validation data, the Resnet50 model using the SGD optimizer, with data acquisition of 70% and 30%, and a batch size of 32, achieved the best image classification results. The normal class was correctly classified in 470 images, with 26 images misclassified. For the OSCC class, 473 images were correctly classified, with only 37 images misclassified.

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 Resnet50, 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. *Resnet50*

ResNet50 adalah salah satu arsitektur jaringan saraf konvolusional (CNN) yang sangat populer dan efektif dalam memecahkan masalah klasifikasi gambar. Dikembangkan oleh Microsoft Research pada tahun 2015, ResNet50 terkenal karena mengatasi masalah pelatihan yang dalam deep training dengan mengenalkan blok residual.

Resnet50 adalah salah satu varian ResNet yang memiliki 50 layer. ResNet- 50 melewati 3 layer dan terdapat 1 X 1 convolution layer [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].

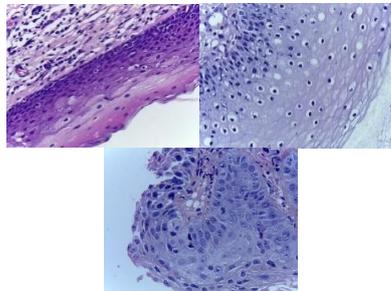
2.10. *Sigmoid*

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

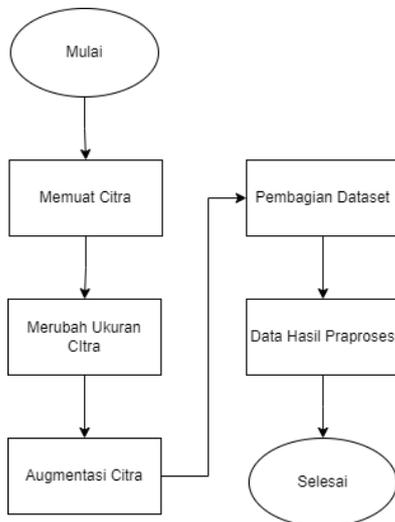
3.1. *Pengumpulan Data*

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.



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

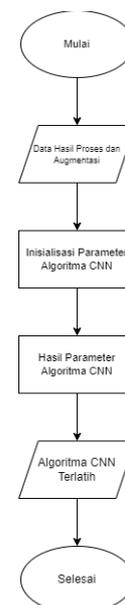
Pembangunan arsitektur Convolutional Neural Network (CNN) dimulai dengan pemilihan arsitektur dasar yang sesuai dengan karakteristik dataset dan masalah yang ingin diselesaikan.



Gambar 3. Gambar arsitektur Resnet

Arsitektur ResNet memperkenalkan konsep "skip connections" atau "residual connections" yang dirancang untuk mengatasi permasalahan degradasi performa yang sering timbul ketika mendesain jaringan dengan kedalaman yang lebih besar. Resnet50 terbentuk dari serangkaian blok dasar yang terdiri dari serangkaian lapisan konvolusi yang disusun secara berurutan. Blok dasar ini dapat mencakup dua atau tiga lapisan konvolusi, bergantung pada pengaturan khusus dari blok tersebut. ResNet-50 memanfaatkan blok bottleneck, yang terdiri dari tiga lapisan konvolusi, yakni konvolusi 1x1, konvolusi 3x3, dan konvolusi 1x1. Konsep ini memiliki manfaat mengurangi jumlah parameter dan beban komputasi tanpa mengurangi ekspresivitas representasi.

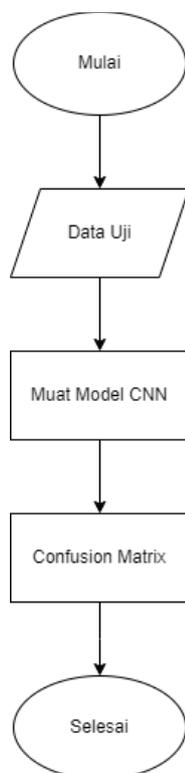
3.4. Pelatihan Model



Gambar 4. Gambar alur pelatihan model

Setelah merencanakan struktur model dan mengatur hyperparameter untuk model ResNet50, langkah selanjutnya adalah menjalankan proses pelatihan pada dataset. Proses pelatihan ini menerapkan epoch 30 dan menyesuaikan *batch size* pada skema pengujian yang akan dilakukan. Pelatihan ini dilakukan menggunakan Google Colaboratory, dengan memanfaatkan akselerator GPU yang tersedia di platform tersebut untuk mempercepat waktu pelatihan dataset.

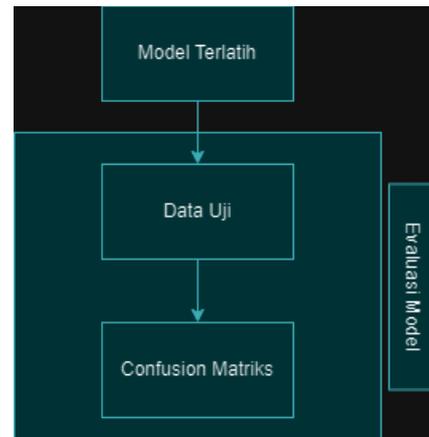
3.5. Pengujian Model



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

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.

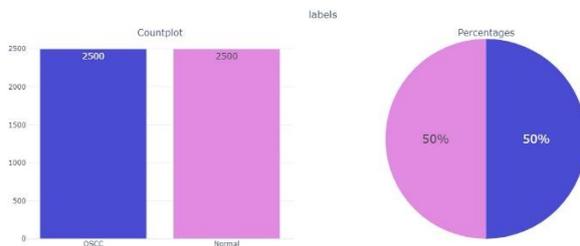
4.2. Menyiapkan Data dan Label

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

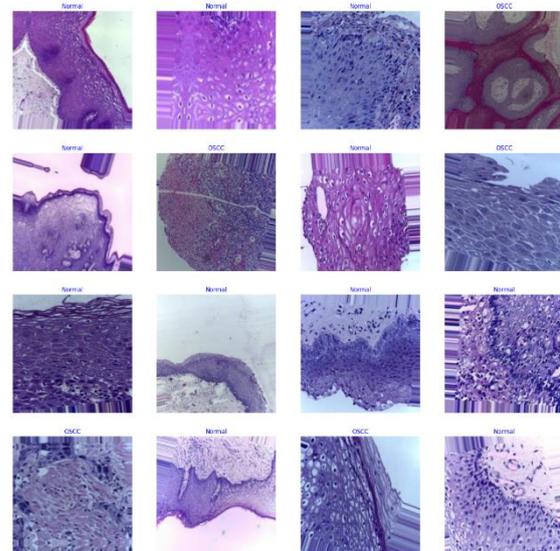
4.3. Praproses Data

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.

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.



Gambar 9. Gambar output augmentasi data

4.4. Implementasi Model Resnet50

Layer (type)	Output Shape	Param #
resnet50 (Functional)	(None, 2048)	23587712
batch_normalization (Batch Normalization)	(None, 2048)	8192
dense (Dense)	(None, 256)	524544
dropout (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 2)	514

Total params: 24120962 (92.01 MB)
 Trainable params: 24063746 (91.80 MB)
 Non-trainable params: 57216 (223.50 KB)

Gambar 10. Gambar struktur model Resnet50 optimasi Adam

Model Resnet50 dengan optimasi Adam memiliki total 24,120,962 parameter, dengan 24,063,746 parameter yang dapat diubah (trainable params) dan 57,216 parameter yang tidak dapat diubah (non-trainable params) terkait dengan lapisan Normalisasi Batch (*Batch Normalization*). Parameter yang dapat diubah terutama berupa bobot dan bias dalam lapisan Dense dan Dropout yang terletak setelah model ResNet50. Bobot dan bias ini akan disesuaikan selama pelatihan untuk mempelajari fitur-fitur spesifik dari data yang dimiliki agar model dapat melakukan klasifikasi yang sesuai dengan dataset yang digunakan.

Layer (type)	Output Shape	Param #
resnet50 (Functional)	(None, 2048)	23587712
batch_normalization (Batch Normalization)	(None, 2048)	8192
dense (Dense)	(None, 256)	524544
dropout (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 2)	514

Total params: 24120962 (92.01 MB)
 Trainable params: 24063746 (91.80 MB)
 Non-trainable params: 57216 (223.50 KB)

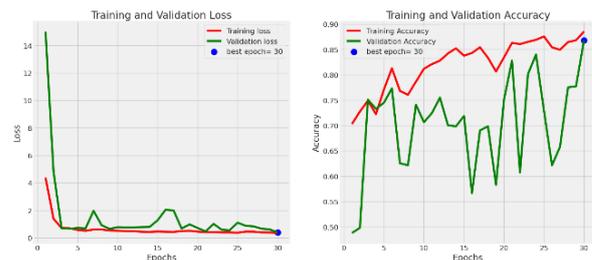
Gambar 11. Gambar struktur model Resnet50 optimasi SGD

Total parameter sebesar 24,120,962. Lapisan Normalisasi Batch (*Batch Normalization*) memiliki 8,192 parameter tidak dapat diubah, sedangkan lapisan Dense memiliki 524,544 parameter untuk lapisan pertama dan 514 parameter untuk lapisan kedua. Jumlah parameter yang dapat diubah adalah 24,063,746, termasuk bobot dan bias dalam lapisan Dense dan Normalisasi Batch.

Sementara itu, parameter tidak dapat diubah adalah 57,216, terkait dengan lapisan Normalisasi Batch. Lapisan ekstraksi fitur tidak dapat diubah dan menggunakan bobot yang sudah ada dari pelatihan awal model ResNet50 pada dataset ImageNet.

4.5. Pelatihan Model

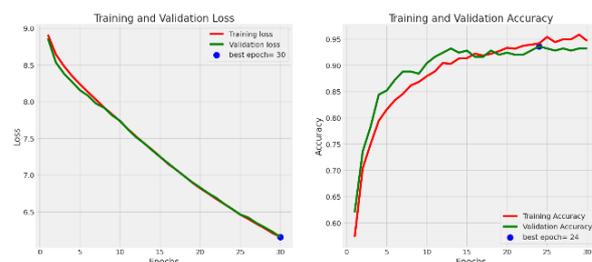
1. Hasil Pelatihan Resnet50 Menggunakan Optimasi Adam.



Gambar 12. Gambar visualisasi skenario pengujian 1

Pada akhir proses pelatihan, didapatkan hasil akurasi pelatihan sebesar 0,885 dan akurasi validasi sebesar 0,868. Kemudian mendapat nilai 0,349 pada nilai fungsi kerugian (loss) dan 0,392 nilai fungsi kerugian pada akhir validasi model pada akhir pelatihan model skenario pengujian ini.

2. Hasil Pelatihan Resnet50 Menggunakan Optimasi SGD.

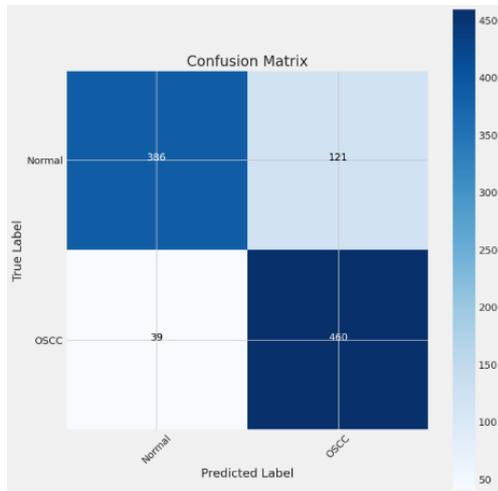


Gambar 13. Gambar visualisasi skenario pengujian 2

Pada akhir proses pelatihan, didapatkan hasil akurasi pelatihan sebesar 0,946 dan akurasi validasi sebesar 0,932. Kemudian mendapat nilai 6,158 pada nilai fungsi kerugian (loss) dan 6,156 nilai fungsi kerugian pada akhir validasi model pada akhir pelatihan model skenario pengujian ini.

4.6. Pelatihan Model

1. Hasil Pengujian dan Evaluasi Resnet50 Menggunakan Optimasi Adam.



Gambar 14. Gambar confusion matrix skenario 1

Berdasarkan gambar confusion matrix yang diberikan, terdapat 160 data yang salah klasifikasinya dan 596 data merupakan data yang benar terklasifikasi. Nilai True Positive (TP) untuk kelas “Normal” adalah 136, False Positive (FP) adalah 39, False Negative (FN) untuk kelas “OSCC” adalah 121, dan True Negative (TN) untuk kelas “OSCC” adalah 460.

	precision	recall	f1-score	support
Normal	0.91	0.76	0.83	507
OSCC	0.79	0.92	0.85	499
accuracy			0.84	1006
macro avg	0.85	0.84	0.84	1006
weighted avg	0.85	0.84	0.84	1006

Gambar 15. Gambar classification report skenario 1

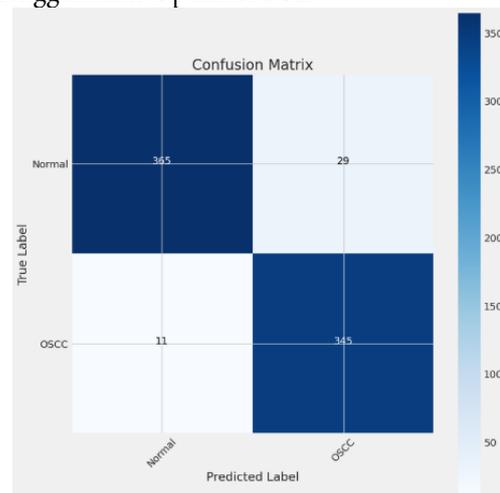
Pada Gambar menunjukkan laporan untuk kelas Normal, model menunjukkan Precision sebesar 0.91, yang berarti ketika model memprediksi kelas Normal, 91% dari prediksi tersebut adalah benar. Recall yang didapat adalah 0.76, menandakan bahwa dari semua kasus Normal yang sebenarnya, model berhasil mengidentifikasi 76% dari mereka dengan benar. F1-Score yang diperoleh adalah 0.83, yang merupakan rata-rata harmonik dari precision dan recall, memberikan gambaran umum tentang akurasi dan kelengkapan model. Jumlah sampel yang sebenarnya adalah

Normal, yang ditunjukkan oleh Support, adalah 507.

Sementara itu, untuk kelas OSCC, Precision yang didapat adalah 0.79, menunjukkan bahwa ketika model memprediksi kelas OSCC, 79% dari prediksi tersebut adalah benar. Recall yang didapat adalah 0.92, menandakan bahwa dari semua kasus OSCC yang sebenarnya, model berhasil mengidentifikasi 92% dari mereka dengan benar. F1-Score yang diperoleh adalah 0.85, yang menunjukkan keseimbangan yang lebih baik antara precision dan recall untuk kelas OSCC dibandingkan dengan kelas Normal. Jumlah sampel yang sebenarnya adalah OSCC, yang ditunjukkan oleh Support, adalah 499.

Secara keseluruhan, model memiliki Accuracy sebesar 0.84, yang menunjukkan bahwa model benar dalam memprediksi 84% dari waktu. Macro Average memberikan rata-rata untuk precision (0.85), recall (0.84), dan f1-score (0.84) tanpa mempertimbangkan distribusi kelas. Sedangkan Weighted Average memberikan rata-rata untuk precision (0.85), recall (0.84), dan f1-score (0.84) dengan mempertimbangkan dukungan atau jumlah sampel untuk setiap kelas.

2. Hasil Pengujian dan Evaluasi Resnet50 Menggunakan Optimasi SGD



Gambar 16. Gambar confusion matrix skenario 2

Berdasarkan gambar 4.35 terdapat 40 data yang salah klasifikasinya dan 710 data merupakan data yang benar terklasifikasi. Nilai True Positive (TP) untuk kelas “Normal” adalah 365, False Positive (FP) adalah 11, False

Negative (FN) untuk kelas “OSCC” adalah 29, dan True Negative (TN) untuk kelas “OSCC” adalah 345.

	precision	recall	f1-score	support
Normal	0.97	0.93	0.95	394
OSCC	0.92	0.97	0.95	356
accuracy			0.95	750
macro avg	0.95	0.95	0.95	750
weighted avg	0.95	0.95	0.95	750

Gambar 17. Gambar classification report skenario 3

Berdasarkan gambar menunjukkan untuk kelas Normal, model menunjukkan Precision sebesar 0.97, yang berarti ketika model memprediksi kelas Normal, 97% dari prediksi tersebut adalah benar. Recall yang didapat adalah 0.93, menandakan bahwa dari semua kasus Normal yang sebenarnya, model berhasil mengidentifikasi 93% dari mereka dengan benar. F1-Score yang diperoleh adalah 0.95, yang merupakan rata-rata harmonik dari precision dan recall, memberikan gambaran umum tentang akurasi dan kelengkapan model dalam memprediksi kelas ini dengan baik sekali karena nilai F1-Score sangat tinggi mendekati sempurna yaitu satu atau seratus persen. Jumlah sampel yang sebenarnya adalah Normal ditunjukkan oleh Support adalah sebanyak jumlah sampelnya yaitu ada 394.

Sementara itu, untuk kelas OSCC, Precision yang didapat adalah sebesar 0.92, menunjukkan bahwa ketika model memprediksi kelas OSCC, 92% dari prediksi tersebut adalah benar. Recall yang didapat adalah 0.97, menandakan bahwa dari semua kasus OSCC yang sebenarnya, model berhasil mengidentifikasi 97% dari mereka dengan benar. F1-Score yang diperoleh adalah 0.95, yang menunjukkan keseimbangan yang lebih baik antara precision dan recall untuk kelas OSCC dibandingkan dengan kelas Normal. Jumlah sampel yang sebenarnya adalah OSCC, yang ditunjukkan oleh Support, adalah 356.

Secara keseluruhan, model memiliki Accuracy sebesar 0.95, yang menunjukkan bahwa model benar dalam memprediksi 95% dari waktu. Macro Average dan Weighted Average memberikan rata-rata untuk precision, recall, dan f1-score yang sama yaitu 0.95, dengan mempertimbangkan dukungan atau

jumlah sampel untuk setiap kelas. Ini menunjukkan performa yang sangat baik dari model dalam klasifikasi 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.	Resnet50 Optimasi Adam, Akuisisi Data 80 % dan 20 %, dan Batch Size 32	6.663 detik	79,68 %	83,2 %	79,33 %
2.	Resnet50 Optimasi Adam, Akuisisi Data 80 % dan 20 %, dan Batch Size 64	7.681 detik	62,96 %	61,19 %	60,79 %
3.	Resnet50 Optimasi Adam, Akuisisi Data 70 % dan 30 %, dan Batch Size 32	6.272 detik	86,34 %	86,84 %	84,09 %
4.	Resnet50 Optimasi Adam, Akuisisi Data 70 % dan 30 %, dan Batch Size 64	8.645 detik	48,94 %	50,40 %	50,49 %
5.	Resnet50 Optimasi SGD, Akuisisi Data 80 % dan 20 %, dan Batch Size 32	5.284 detik	95,93 %	93,19 %	94,66 %
6.	Resnet50 Optimasi SGD, Akuisisi Data 80 % dan 20 %, dan Batch Size 64	4.815 detik	94,06 %	92 %	90,39 %
7.	Resnet50 Optimasi SGD, Akuisisi Data 70 %	3.593 detik	96,17 %	92,71 %	93,73 %

	dan 30 %, dan Batch Size 32				
8.	Resnet50 Optimasi SGD, Akuisisi Data 70 % dan 30 %, dan Batch Size 64	4.563 detik	95,02 %	92,30 %	92,44 %

Pada tabel diatas akurasi dataset terbaik secara keseluruhan diperoleh nomor 7 dengan menggunakan Resnet50 Optimasi SGD, Akuisisi Data 70 % dan 30 %, dan Batch Size 32. Dengan masing-masing perolehan pada data train, validation, dan test yaitu dengan capaian 95,93 %, 93,19 %, dan 94,66 %.

Berdasarkan proses pelatihan keseluruhan yang menggunakan epoch 30 dalam semua skenario pengujian, waktu keseluruhan yang dibutuhkan paling banyak terdapat pada skenario pengujian menggunakan Resnet50 Optimasi Adam, Akuisisi Data 70 % dan 30 %, dan Batch Size 64 dengan waktu yang dibutuhkan yaitu 8.645 detik.

4.8. Pembahasan Pengujian dan Evaluasi

Tabel 2. Hasil Pengujian dan Evaluasi Model

No.	Skenario Pengujian	Akurasi	Rata-Rata		
			Precisi	Recall	F1-Score
1.	Resnet50 Optimasi Adam, Akuisisi Data 80 % dan 20 %, dan Batch Size 32	0,79	0,82	0,79	0,79
2.	Resnet50 Optimasi Adam, Akuisisi Data 80 % dan 20 %, dan Batch Size 64	0,61	0,68	0,61	0,58
3.	Resnet50 Optimasi Adam, Akuisisi Data 70 % dan 30 %, dan Batch Size 32	0,84	0,85	0,84	0,84
4.	Resnet50 Optimasi Adam, Akuisisi Data 70 % dan 30 %, dan Batch Size 64	0,50	0,56	0,50	0,37

5.	Resnet50 Optimasi SGD, Akuisisi Data 80 % dan 20 %, dan Batch Size 32	0,95	0,95	0,95	0,95
6.	Resnet50 Optimasi SGD, Akuisisi Data 80 % dan 20 %, dan Batch Size 64	0,90	0,91	0,90	0,90
7.	Resnet50 Optimasi SGD, Akuisisi Data 70 % dan 30 %, dan Batch Size 32	0,94	0,94	0,94	0,94
8.	Resnet50 Optimasi SGD, Akuisisi Data 70 % dan 30 %, dan Batch Size 64	0,92	0,92	0,92	0,92

Pada penelitian model Resnet50 terdapat skenario yang memiliki hasil baik, yaitu pada skenario pengujian menggunakan Resnet50 dengan Optimasi SGD, Akuisisi Data 80 % dan 20 %, dan Batch Size 32 dimana mendapatkan hasil yang cukup baik yaitu 0.95. Begitu juga pada 3 metrik yang lain yaitu Precision, Recall, dan F1-Score mendapatkan nilai paling tinggi dibandingkan penggunaan model Resnet50 yang lainnya dengan masing-masing mendapatkan nilai 0.95, 0.95 dan 0.95.

5. KESIMPULAN

- a. Pengklasifikasikan penyakit kanker mulut dengan Arsitektur Resnet50 dapat menggunakan metode Tranfer Learning dengan menggunakan bobot ImageNet.
- b. Model Resnet50 menggunakan Optimasi SGD, pada Akuisisi Data 70 % dan 30 %, dan menggunakan Batch Size 32. menghasilkan kinerja terbaik dalam evaluasi terhadap data pelatihan, validasi, dan uji. Hasil evaluasi tersebut menunjukkan tingkat akurasi sebesar 95,93% untuk data pelatihan, 93,19% untuk data validasi, dan 94,66% untuk data uji.

- c. Hasil Penelitian menggunakan model Resnet50 memiliki hasil akurasi lebih baik apabila menggunakan Optimasi SGD, Akuisisi Data 80 % dan 20 %, menggunakan Batch Size 32 dengan akurasi sebesar 0.95 daripada Optimasi Adam dengan akurasi tertinggi pada penerapan model Resnet50 menggunakan Optimasi Adam pada akuisisi data 70 % dan 30 % menggunakan Batch Size 32 dengan memperoleh akurasi sebesar 0.84.
- d. Pada pelatihan dan pengujian dengan data uji/validasi, model Resnet50 menggunakan Optimasi SGD, pada Akuisisi Data 70 % dan 30 %, dan menggunakan Batch Size 32. mencapai hasil klasifikasi gambar terbaik. Kelas normal berhasil diklasifikasikan dengan benar sebanyak 470 gambar, sedangkan terdapat 26 gambar yang salah diklasifikasikan. Untuk kelas OSCC, terdapat 473 gambar yang diklasifikasikan dengan benar dan hanya 37 gambar yang salah diklasifikasikan.

- [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.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada pihak-pihak terkait yang telah memberi dukungan terhadap penelitian ini.

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.