

# Klasifikasi Citra Kesegaran Daging Sapi Menggunakan CNN ResNet-50V2

1<sup>st</sup> Muhammad Gibran Ramadhan  
Fakultas Teknik Elektro  
Universitas Telkom  
Bandung, Indonesia  
mgibranram@gmail.com

2<sup>nd</sup> R. Yunendah Nur Fu'adah  
Fakultas Teknik Elektro  
Universitas Telkom  
Bandung, Indonesia  
yunendah.staff@telkomuniversity.ac.id

3<sup>rd</sup> Sofiah Saidah  
Fakultas Teknik Elektro  
Universitas Telkom  
Bandung, Indonesia  
sofiasaidahsfi@telkomuniversity.ac.id

**Abstrak** — Daging sapi adalah jenis bahan makanan hewani yang didapatkan dari ternak sapi. Daging sapi tergolong dalam jenis daging merah yang memiliki kandungan protein sebagai sumber nutrisi. Penentuan daging sapi yang segar seringkali sulit dilakukan dengan cara tradisional, seperti pengamatan langsung terhadap warna, tekstur, dan bau yang bersifat subjektif, sehingga menjadi tantangan bagi sebagian masyarakat di Indonesia. Kesalahan dalam penentuan tersebut dapat berpotensi menimbulkan risiko kesehatan bagi konsumen serta kerugian finansial bagi pihak penjual maupun pembeli. Permasalahan ini dapat diatasi dengan penerapan teknologi *deep learning* menggunakan *Convolutional Neural Network* (CNN) yang dapat melakukan klasifikasi citra daging sapi secara lebih objektif. Tugas akhir ini akan dibangun sistem klasifikasi kesegaran daging sapi yang terdiri dari dua kelas, yaitu segar dan tidak segar. Sistem tersebut menggunakan *Convolutional Neural Network* (CNN) ResNet-50V2. Dataset yang digunakan pada sistem ini dikumpulkan dari situs web Kaggle yang berisi 3268 citra yang terbagi merata antara kelas segar dan tidak segar, masing-masing sebesar 50%. Citra dataset tersebut disimpan dalam format .jpg. Informasi ini dimanfaatkan untuk proses pelatihan dan pengujian sistem dengan hasil terbaik. Pada penelitian ini, hasil pengujian sistem yang telah dilakukan menggunakan beberapa parameter diperoleh hasil terbaik menggunakan Adam optimizer, batch size sebesar 16, learning rate sebesar 0,01, dan epoch sebesar 20. Berdasarkan hasil parameter tersebut, diperoleh metrik dengan akurasi sebesar 99,39%, presisi sebesar 99,40%, recall sebesar 99,39%, dan f1-score sebesar 99,39%.

**Kata kunci**—Daging Sapi, Deep Learning, Convolutional Neural Network (CNN), ResNet-50V2

## I. PENDAHULUAN

Daging sapi merupakan salah satu bahan pangan yang berasal dari hewan ternak sapi yang banyak dikonsumsi masyarakat Indonesia karena rasanya yang lezat dan memiliki kandungan gizi terutama sebagai sumber protein hewani. Permintaan masyarakat Indonesia terhadap daging sapi terus meningkat seiring dengan pertumbuhan penduduk serta peningkatan kesadaran pentingnya gizi protein. Hal tersebut menjadikan kualitas kesegaran daging sapi menjadi faktor penting yang harus diperhatikan untuk menjaga kesehatan dan kepuasan konsumen. Kesulitan dalam menentukan kualitas kesegaran daging sapi secara akurat menggunakan metode tradisional seperti pengamatan subjektif langsung dari orang terhadap warna, tekstur, atau bau yang masih menjadi masalah bagi sebagian masyarakat Indonesia. Ketidakakuratan dalam metode tradisional tersebut dapat menyebabkan kesalahan pemilihan daging sapi yang berakibat pada risiko gangguan kesehatan konsumen serta kerugian ekonomi bagi penjual atau pembeli. Masalah tersebut bisa diatasi menggunakan teknologi *deep learning* menggunakan *Convolutional Neural Network* (CNN) yang mampu melakukan klasifikasi citra daging sapi secara objektif.

Berbagai penelitian klasifikasi kesegaran citra daging sapi menggunakan *Convolutional Neural Network* (CNN) telah dilakukan, diantaranya penelitian dari Dodi Efendi dkk. dengan judul “Penerapan Algoritma Convolutional Neural Network Arsitektur ResNet-50 untuk Klasifikasi Citra Daging Sapi dan Babi” dengan akurasi tes tertinggi sebesar 97,83%, presisi sebesar 97%, recall sebesar 97%, dan f1-score sebesar 97% menggunakan optimizer adam, batch size 32, learning rate 0,01, dan epoch 50 [1]. Penelitian selanjutnya dari Cakra dkk. dengan judul “Klasifikasi Tingkat Kesegaran Daging Sapi di Pasar Mandonga Kota Kendari Menggunakan Arsitektur Deep Learning VGG-16” dengan akurasi tertinggi sebesar 99,33% menggunakan optimizer adam, batch size 32, learning rate 0,001, dan epoch 20 [2]. Penelitian selanjutnya dari Charisa Nur Sahera dengan judul “Optimasi Penerapan Algoritma Convolutional Neural Network dalam Klasifikasi Tingkat Kesegaran Daging Sapi” dengan akurasi tertinggi sebesar 98.50% menggunakan ResNet-50 dengan optimizer adam, learning rate 0,01 dan epoch 10 [3].

## II. KAJIAN TEORI


Menyajikan dan menjelaskan teori-teori yang berkaitan dengan variabel-variabel penelitian.

### A. Daging Sapi

Daging sapi merupakan bahan pangan hewani yang berasal dari hewan ternak sapi. Daging sapi termasuk ke dalam kategori daging merah yang berperan sebagai sumber pangan kaya protein. Tingkat kesegaran daging sapi menjadi faktor penentu kualitas daging untuk dikonsumsi. Daging sapi yang segar umumnya memiliki warna merah dengan serat yang halus, kandungan lemak yang berwarna kekuningan, dan mengeluarkan aroma amis yang khas namun tidak menyengat. Sementara daging sapi yang sudah tidak segar umumnya memiliki warna lebih pucat, kadar air lebih banyak, dan mengeluarkan aroma amis yang tidak sedap [6].

### B. Pengolahan citra digital

Pengolahan citra digital adalah metode yang digunakan untuk melakukan serangkaian operasi pada citra digital dengan tujuan meningkatkan kualitas visual citra digital atau memperoleh sejumlah informasi bermanfaat yang terkandung di dalamnya [4]. Citra digital merupakan data dalam bentuk representasi dua dimensi dimana elemen terkecilnya dinamakan piksel. Masing-masing piksel memiliki koordinat (x,y) dan nilai intensitas I(x,y). Informasi warna pada setiap citra digital diperoleh dari intensitas cahaya yang telah ditangkap oleh sensor berbentuk grid di dalam kamera. Hasil yang diperoleh dari pemindaian kamera adalah citra digital dengan format warna RGB (*Red*, *Green*, *Blue*), sehingga setiap piksel mewakili tiga komponen intensitas yaitu *I Red*, *I Green*, dan *I Blue*. Ketiga komponen tersebut membentuk susunan *array* dua dimensi seperti pada gambar 1(B) [5].




GAMBAR 1 Array Dua Dimensi Pada Citra (B)

### C. Deep Learning

*Deep learning* merupakan teknik dalam pembelajaran mesin yang memanfaatkan jaringan saraf tiruan berlapis-lapis untuk mempelajari pola data atau menyelesaikan tugas prediksi seperti pada bidang *computer vision*, *speech recognition*, dan *natural language processing* [4]. Prinsip kerja *deep learning* didasarkan seperti yang terjadi pada proses pengiriman sinyal antar neuron di otak manusia yang kemudian memungkinkan sistem pembelajaran secara bertingkat hingga membentuk pemahaman yang mendalam [7].

### D. Convolutional Neural Network (CNN)


*Convolutional Neural Network* (CNN) adalah salah satu metode *deep learning* yang menggunakan operasi konvolusi secara linear yang sering dimanfaatkan untuk melakukan berbagai tugas seperti deteksi maupun klasifikasi objek dalam sebuah citra digital [8]. CNN mulai diperkenalkan pertama kali pada tahun 1998 dan telah mengalami perkembangan yang pesat hingga sekarang [4]. Arsitektur CNN secara umum mencakup dua tahap utama yaitu *feature learning* dan *classification*. Pada tahap *feature learning*, citra input dilakukan proses ekstraksi ciri yang penting melalui proses pada beberapa lapisan tersembunyi, seperti *convolutional layer*, *ReLU*, dan *pooling layer*. Setelah didapatkan fitur ekstraksi pada proses *feature learning*, kemudian dilanjutkan ke tahap *classification* yang dimana hasil ekstraksi diubah ke bentuk vektor melalui proses *flatten layer*, *fully connected layer*, dan fungsi sigmoid atau softmax yang kemudian dapat menghasilkan output berupa prediksi kelas dari citra input yang telah diproses [9].



GAMBAR 2 Arsitektur CNN (D)

### E. Convolutional Layer

*Convolutional layer* merupakan lapisan arsitektur CNN yang melakukan proses operasi konvolusi. Proses konvolusi dalam lapisan ini dilakukan dengan cara mengubah nilai piksel berdasarkan nilai-nilai piksel sekitarnya [4]. Ilustrasi perhitungan konvolusi pada citra ditunjukkan pada gambar 3(E).



GAMBAR 3 Perhitungan Konvolusi Pada Citra (E)


### F. Rectified Linear Unit (ReLU)

Aktivasi ReLU digunakan untuk menambahkan elemen nonlinearitas pada jaringan saraf sehingga dapat meningkatkan kemampuan model dalam mengenali pola yang kompleks. ReLU memungkinkan *feature map* menyajikan citra lebih akurat sesuai karakteristik visualnya dengan cara mengubah nilai negatif pada piksel menjadi nol [10]. Proses ReLU menggunakan persamaan dibawah ini:

$$f(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (1)$$

#### G. Pooling Layer

*Pooling layer* adalah lapisan setelah lapisan *convolutional* dalam arsitektur CNN. Lapisan ini mengambil hasil dari *convolutional layer* dan disederhanakan menjadi kumpulan nilai baru yang mewakili informasi penting dari setiap *feature map*. Ada dua jenis teknik *pooling* yang sering digunakan yaitu *max pooling* dan *average pooling*. *Average pooling* mencari nilai rata-rata dari area piksel tertentu pada citra, sedangkan *max pooling* mencari nilai yang terbesar dari area piksel tertentu pada citra [7]. Ilustrasi proses *pooling layer* ditunjukkan pada gambar 4(G).



GAMBAR 4 Perhitungan Pooling Layer (G)

#### H. Fully Connected Layer

*Fully connected layer* adalah lapisan akhir pada struktur CNN yang memiliki hubungan dengan seluruh output dari lapisan sebelumnya. Lapisan ini berfungsi memproses hasil olahan citra agar dapat diklasifikasikan. Pada lapisan ini dilakukan proses *flatten* untuk mengubah *feature map* menjadi vektor satu dimensi. Proses tersebut dilakukan karena output dari lapisan sebelumnya masih berupa *feature map* yang tidak bisa dipakai langsung sebagai input *fully connected layer* [8].


#### I. Fungsi Sigmoid

Sigmoid merupakan salah satu fungsi aktivasi dalam jaringan saraf tiruan. Sigmoid digunakan untuk mengubah output menjadi bernilai nol sampai satu, sehingga bisa digunakan untuk menentukan hasil probabilitas antara dua kelas. Persamaan fungsi sigmoid adalah sebagai berikut:

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (2)$$

#### J. Residual Network (ResNet)


ResNet merupakan salah satu arsitektur CNN yang diciptakan untuk mengatasi permasalahan arsitektur CNN yang lain berupa penurunan performa sistem yang menyebabkan kesalahan saat proses pelatihan maupun pengujian data menjadi lebih besar. ResNet menggunakan metode *skip connection* untuk mengatasi permasalahan tersebut [8]. Mekanisme ini memungkinkan input  $x$  melewati satu atau beberapa lapisan tanpa melalui proses pembobotan seperti yang ditunjukkan pada gambar 5.



GAMBAR 5 Ilustrasi Residual Network (J)

#### K. Residual Network 50 Version 2 (ResNet-50V2)

ResNet-50V2 merupakan salah satu arsitektur CNN yang dikembangkan pada tahun 2016. Angka 50 dalam ResNet-50V2 adalah jumlah lapisan yang terdapat dalam model ini. ResNet-50 V2 dibuat sebagai penyempurnaan dari model sebelumnya, yaitu ResNet-50 [12]. Perbedaan utama ResNet-50 V2 dengan ResNet-50 adalah pada residual *block* ResNet-50 V2 menggunakan *pre-activation* sedangkan ResNet-50 menggunakan *post-activation*, sehingga ResNet-50 V2 dapat mempermudah aliran antar lapisan yaitu memungkinkan untuk kembali ke lapisan sebelumnya karena struktur lapisan yang seragam. Selain itu, ResNet-50 V2 menggunakan *batch normalization* serta fungsi aktivasi ReLU pada input sebelum dilakukan operasi konvolusi. Sementara itu pada ResNet-50, langkah tersebut diterapkan setelah operasi konvolusi. Ilustrasi pada gambar 6(K) menunjukkan perbedaan antara ResNet-50 V2 dan ResNet-50 [12].




GAMBAR 6 Perbedaan ResNet-V1 dan ResNet-V2 (K)

### III. METODE

#### A. Desain Sistem

Pada Tugas Akhir ini, sistem yang akan dirancang adalah klasifikasi tingkat kesegaran daging sapi menggunakan model *Convolutional Neural Network* (CNN) dengan arsitektur ResNet-50V2. Gambaran umum desain sistem yang dirancang dapat dilihat pada gambar 7(A).



GAMBAR 7 Desain Sistem  
(A)

#### B. Dataset

Dataset yang digunakan adalah citra daging sapi yang diperoleh dari situs web [www.kaggle.com](http://www.kaggle.com) dengan judul “LOCBEEF: Beef Quality Image Dataset”. Dataset tersebut berisi 3268 citra yang dikumpulkan dari pukul 07:00 hingga 22:00. Dataset dibagi menjadi dua kategori yaitu data *train* atau latih dan data *test* atau uji. Setiap kategori terdiri dari dua kelas, yaitu segar dan tidak segar. Data latih berisi 2228 citra, masing-masing kelas yaitu segar dan tidak segar berisi 1114 citra. Sedangkan data uji berisi 980 citra, masing-masing kelas yaitu segar dan tidak segar berisi 490 citra. Resolusi citra dalam dataset tersebut beragam, yaitu 176 x 144 piksel, 320 x 240 piksel, 640 x 480 piksel, 720 x 480 piksel, 720 x 720 piksel, 1280 x 720 piksel, 1920 x 1080 piksel, 2560 x 1920 piksel, 3120 x 3120 piksel, 3264 x 2248 piksel, dan 4160 x 3120 piksel. Pada Tugas Akhir ini, total dataset yang berjumlah 3268 citra diubah menjadi kategori data latih sebanyak 80%, data validasi 10%, dan data uji 10%. Setiap kategori tetap terdiri dari dua kelas yaitu daging sapi segar dan daging sapi tidak segar. Gambar adalah masing-masing satu contoh citra daging sapi yang diambil dari dataset dengan dua kelas klasifikasi yaitu segar dan tidak segar.



(a) segar

(b) tidak segar

GAMBAR 8  
(B)

#### C. Pre-Processing

*Pre-processing* adalah proses yang dilakukan sebelum citra diolah ke dalam model sistem dengan tujuan untuk meningkatkan mutu citra serta menyamakan karakteristik citra. Dengan demikian, sistem dapat bekerja lebih optimal. Pada Tugas Akhir ini, *pre-processing* yang dilakukan adalah *resizing* citra. *Resizing* citra bertujuan untuk menyamakan ukuran piksel citra. Ukuran citra yang kurang optimal seperti terlalu besar dapat memperlambat proses pengolahan dalam sistem. Sementara itu, jika ukuran citra terlalu kecil akan menjadi kurang optimal.

#### D. Pelatihan Model

Model ResNet-50V2 terdiri dari 50 lapisan. Jumlah lapisan pada arsitektur ini berdampak pada durasi pelatihan dataset. Semakin banyak jumlah lapisan yang digunakan, maka waktu yang dibutuhkan untuk melatih dataset juga semakin lama. Pada pelatihan model ResNet-50 V2, diawali dengan input citra dari dataset daging sapi yang telah melewati *pre-processing* diproses melalui beberapa lapisan konvolusi dilengkapi fungsi aktivasi ReLU, kemudian dilakukan operasi *pooling* untuk memperkecil dimensi *feature map* serta melakukan ekstraksi fitur-fitur penting secara bertahap. Hasil dari ekstraksi fitur-fitur tersebut kemudian dilakukan *flatten* dan diteruskan menuju lapisan *fully connected*, kemudian diproses oleh fungsi sigmoid pada tahap klasifikasi untuk menghasilkan prediksi kelas, yaitu daging sapi segar dan tidak segar. ResNet-50V2 menggunakan urutan dari *batch normalization*, dilanjutkan ReLU, kemudian dilakukan konvolusi. Berbeda dengan ResNet-50V2 yang berawal dari konvolusi, dilanjutkan *batch normalization*, kemudian dilakukan aktivasi ReLU. Modifikasi pada ResNet-50V2 tersebut membuarkan model dapat mempercepat proses konvergensi, sehingga pelatihan model lebih optimal.

#### E. Performansi Sistem

Sistem CNN ResNet-50V2 yang telah dibangun akan dievaluasi berdasarkan performansi sistem sebagai hasil kinerja dari sistem apakah sistem tersebut sudah sesuai dengan apa yang diharapkan serta untuk mengetahui kelebihan serta kekurangan sistem tersebut.

#### F. Confusion Matrix

*Confusion matrix* adalah salah satu teknik yang dipakai untuk menilai akurasi suatu sistem. Pada setiap elemen dalam

*confusion matrix* menunjukkan hasil prediksi model yang dikategorikan sebagai benar (*true*) dan salah (*false*).

|                  |              | Actual Values                                         |                                                      |
|------------------|--------------|-------------------------------------------------------|------------------------------------------------------|
|                  |              | 1 (Positive)                                          | 0 (Negative)                                         |
| Predicted Values | 1 (Positive) | <b>TP</b><br>(True Positive)                          | <b>FP</b><br>(False Positive)<br><i>Type I Error</i> |
|                  | 0 (Negative) | <b>FN</b><br>(False Negative)<br><i>Type II Error</i> | <b>TN</b><br>(True Negative)                         |

GAMBAR 8  
(F)

1. *True Positive* (TP) merupakan kondisi ketika model memprediksi suatu nilai sebagai positif dan prediksi tersebut hasilnya benar.
2. *True Negative* (TN) merupakan kondisi ketika model memprediksi suatu nilai sebagai negatif dan prediksi tersebut hasilnya benar.
3. *False Positive* (FP) merupakan kondisi ketika model memprediksi suatu nilai sebagai positif dan prediksi tersebut hasilnya salah.
4. *False Negative* (FN) merupakan kondisi ketika model memprediksi suatu nilai sebagai negatif dan prediksi tersebut hasilnya salah.

#### G. Akurasi

Akurasi adalah tingkat keakuratan keseluruhan sistem yang telah dibangun, yaitu untuk prediksi nilai positif maupun negatif. Persamaan untuk menghitung akurasi adalah sebagai berikut:

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

#### H. Presisi

Presisi adalah tingkat keauratan pada nilai positif dalam sistem, yaitu banyaknya prediksi nilai positif yang terbukti benar. Persamaan untuk menghitung presisi adalah sebagai berikut:

$$Presisi = \frac{TP}{TP+FP} \quad (4)$$

#### I. Recall

*Recall* adalah tingkat kemampuan sistem dalam menemukan kembali data yang relevan. Persamaan untuk menghitung recall adalah sebagai berikut:

$$Recall = \frac{TP}{TP+FN} \quad (5)$$

#### J. F1-Score

*F1-score* adalah hasil rata-rata dari presisi dan *recall* untuk menilai kinerja sistem secara seimbang. Persamaan untuk menghitung *F1-score* adalah sebagai berikut:

$$F1 - Score = \frac{2 \times Recall \times Precision}{Recall + Precision} \quad (6)$$

#### K. Loss

*Loss* adalah parameter yang digunakan sebagai evaluasi kinerja sistem setelah proses prediksi dilakukan. Terdapat berbagai jenis fungsi *loss*, namun pada penelitian ini digunakan *binary cross entropy* untuk dua kategori klasifikasi. Persamaan untuk menghitung *loss* adalah sebagai berikut:

$$Binary Cross Entropy Loss = -p \ln q - (1 - p) \ln(1 - q) \quad (7)$$

#### Keterangan:

p = Hasil prediksi berupa ya atau tidak (1 atau 0)  
q = Nilai *loss*

#### L. Parameter Performansi

Parameter performansi merupakan suatu indikator yang digunakan untuk mengevaluasi tingkat keberhasilan sebuah sistem dalam mencapai target yang sudah ditentukan. Beberapa parameter performansi pada Tugas Akhir ini adalah *optimizer*, *batch size*, *learning rate*, dan *epoch*.

#### M. Optimizer

*Optimizer* adalah metode yang digunakan untuk menyesuaikan bobot dan *learning rate* dengan tujuan mengurangi nilai *loss*. *Optimizer* yang dipakai dalam penelitian ini adalah *adam optimizer*.

#### N. Batch Size

*Batch size* adalah jumlah data sampel yang diproses dalam satu kali iterasi. Pada penelitian ini, *batch size* yang digunakan adalah 8, 16, dan 32.

#### O. Learning Rate

*Learning rate* adalah parameter dalam proses pelatihan yang digunakan untuk menghitung perubahan bobot. Nilai *learning rate* berada dalam rentang nol hingga satu. Semakin tinggi nilai *learning rate*, maka proses pelatihan semakin cepat, namun akurasi jaringan cenderung menurun. Sebaliknya, semakin rendah nilai *learning rate*, maka akurasi jaringan cenderung meningkat tetapi waktu pelatihan menjadi lebih lama. Pada penelitian ini, *learning rate* yang digunakan adalah 0,01, 0,001, dan 0,0001.

#### P. Epoch

*Epoch* adalah satu putaran dalam pelatihan di mana seluruh data *training* diproses oleh model sebanyak satu kali. Pada penelitian ini, *epoch* yang digunakan adalah 10, 20, dan 30.

#### IV. HASIL DAN PEMBAHASAN

##### A. Skenario Pengujian

Parameter yang diuji secara berurutan dalam skenario ini meliputi *batch size*, *learning rate*, dan *epoch* menggunakan parameter *optimizer* tetap yaitu *adam optimizer*. Pengujian dilakukan untuk mencari parameter-parameter terbaik yang berpengaruh terhadap hasil performa sistem.

##### B. Hasil Pengujian


Hasil pengujian sistem dilihat pada *confusion matrix* serta beberapa nilai metrik yaitu presisi, *recall*, *f1-score*, akurasi, dan *loss*.

##### C. Pengujian Parameter Batch Size

Pengujian diawali dengan skenario untuk mencari nilai *batch size* terbaik diantara 8, 16, dan 32 dengan kombinasi nilai *learning rate* 0,0001 dan *epoch* 20.

| Batch Size | Presisi | Recall | F1-Score | Akurasi | Loss   |
|------------|---------|--------|----------|---------|--------|
| 8          | 98.79   | 98.78  | 98.78    | 98.78   | 0.0256 |
| 16         | 99.1    | 99.09  | 99.09    | 99.09   | 0.0287 |
| 32         | 99.1    | 99.09  | 99.09    | 99.09   | 0.0325 |

TABEL 1 Metrik Hasil Uji Batch Size (C)




GAMBAR 9 Confusion Matrix Hasil Uji Batch Size (C)

##### D. Pengujian Parameter Learning Rate

Pengujian ini dilakukan dengan skenario untuk mencari nilai *learning rate* terbaik diantara 0,0001, 0,001, dan 0,01 dengan kombinasi nilai parameter terbaik dari pengujian sebelumnya yaitu *batch size* 16 dan *epoch* 20.

| Learning Rate | Presisi | Recall | F1-Score | Akurasi | Loss   |
|---------------|---------|--------|----------|---------|--------|
| 0.0001        | 99.1    | 99.09  | 99.09    | 99.09   | 0.0287 |
| 0.001         | 98.52   | 98.48  | 98.48    | 98.48   | 0.0684 |
| 0.01          | 99.4    | 99.39  | 99.39    | 99.39   | 0.0285 |

TABEL 2 Metrik Hasil Uji Learning Rate (D)




GAMBAR 10 Confusion Matrix Hasil Uji Learning Rate (D)

##### E. Pengujian Parameter Epoch

Pengujian ini dilakukan dengan skenario untuk mencari nilai *epoch* terbaik diantara 10, 20, dan 30 dengan kombinasi nilai parameter terbaik dari pengujian sebelumnya yaitu *batch size* 16 dan *learning rate* 0,01.

| Epoch | Presisi | Recall | F1-Score | Akurasi | Loss   |
|-------|---------|--------|----------|---------|--------|
| 10    | 97.62   | 97.56  | 97.56    | 97.56   | 0.0518 |
| 20    | 99.4    | 99.39  | 99.39    | 99.39   | 0.0285 |
| 30    | 99.09   | 99.08  | 99.09    | 99.09   | 0.0231 |

TABEL 3 Metrik Hasil Uji Epoch (E)



GAMBAR 10 Confusion Matrix Hasil Uji Learning Rate (E)


##### F. Analisis Hasil Pengujian

Setelah melakukan pengujian pada berbagai parameter, penulis mendapatkan hasil pengujian parameter terbaik yang terlihat pada tabel 4(F).

|                      |      |
|----------------------|------|
| <i>Batch Size</i>    | 16   |
| <i>Learning Rate</i> | 0,01 |
| <i>Epoch</i>         | 20   |

TABEL 4 Nilai Parameter Terbaik Hasil Uji (F)

Hasil pengujian pada penelitian ini yang menggunakan adam *optimizer* dengan nilai parameter *batch size*, *learning rate*, dan *epoch* terbaik seperti terlihat pada tabel 4(D) adalah dengan nilai presisi 99,4 %, *recall* 99,39%, *f1-score* 99,39%, akurasi 99,39%, dan *loss* 0,0285. Adapun grafik hasil pengujian terbaik dapat dilihat pada gambar 11(D).



GAMBAR 11 Grafik Hasil Akurasi dan Loss Terbaik (F)

Hasil pengujian diatas tidak mengalami *overfitting* karena *gap* atau jarak antara *loss* dan *validation* sepanjang *epoch* tergolong kecil, sehingga performa model stabil. Berdasarkan keseluruhan hasil pengujian, metrik yang paling dibutuhkan adalah presisi karena memuat nilai positif atau kelas segar. Nilai positif pada penelitian ini adalah data yang paling penting untuk dicari hasilnya.

## V. KESIMPULAN

Tugas Akhir ini telah berhasil dibangun sistem klasifikasi daging sapi menggunakan *Convolutional Neural Network* (CNN) ResNet-50V2. Sistem dapat bekerja paling optimal menggunakan parameter adam *optimizer* dengan *batch size* 16, *learning rate* 0,01, dan *epoch* 20. Metrik hasil uji tertinggi adalah dengan presisi 99,4 %, *recall* 99,39%, *f1-score* 99,39%, akurasi 99,39%, dan *loss* 0,0285.

## REFERENSI

- [1]D. Efendi, J. Jasril, S. Sanjaya, F. Syafria, dan E. Budianita, "Penerapan algoritma Convolutional Neural Network arsitektur ResNet-50 untuk klasifikasi citra daging sapi dan babi," J. Riset Komput. (JURIKOM), vol. 9, no. 3, p. 607, Jun. 2022,doi: 10.30865/jurikom.v9i3.4176.[Online]. Tersedia:https://ejurnal.stmikbudidarma.ac.id/index.php/jurikom/article/view/4176.
- [2]C. Cakra, S. Samsuddin, dan F. Kahar, "Klasifikasi tingkat kesegaran daging sapi di Pasar Mandonga Kota Kendari menggunakan arsitektur deep learning VGG-16," J. Sist. Inform. dan Tek. Komput., vol. 9,no. 2,hlm. 293–298,Okt. 2024,

doi: 10.51876/simtek.v9i2.1333.:contentReference oaicite:0}{index=0}.

- [3]C. N. Sahera, Y. Rahmawati, dan R. Dijaya, "Optimasi penerapan algoritma Convolution Neural Network dalam klasifikasi tingkat kesegaran daging sapi," J. Tek. Inform. Komput., vol. 7, no. 1, Jun. 2024, doi: 10.37600/tekinkom.v7i1.1122.
- [4]A. Arnita, F. Marpaung, F. Aulia, N. Suryani, dan R. C. Nabila, Computer Vision dan Pengolahan Citra Digital. Surabaya, Indonesia: Pustaka Aksara, 2022. ISBN: 978-623-8230-27-3.
- [5]H. Fitriyah dan R. C. Wihandika, Dasar-Dasar Pengolahan Citra Digital, 1st ed. Malang, Indonesia: Universitas Brawijaya Press, Oct. 2021. [Online]. Tersedia:https://books.google.co.id/books?id=LoNT EAAQBAJ.
- [6]D. M. A. N. Ichsan dan M. Malabay, "Perancangan dan implementasi virtual tour sebagai media promosi inovatif pada Fakultas Ilmu Komputer," IKRA-ITH Informatika, vol. 8, no. 3, pp. 1–8, Nov. 2024.[Online].Tersedia:https://journals.upi-yai.ac.id/index.php/ikraithinformatika/issue/view/153.
- [7]G.M. Kurnia, N. Ibrahim, dan S. Saidah, "ANALISIS DAN KLASIFIKASI PENYAKIT TANAMAN DAUN KENTANG DENGAN MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN) ARSITEKTUR RESNET,"e-Proceeding Telkom University.
- [8]R. A. Shafa, M. Rita, dan S. Saidah, "Klasifikasi penyakit pneumonia berbasis citra X-ray dengan arsitektur ResNet-50," e-Proceeding Appl. Sci., Telkom Univ.
- [9]G. A. Lestary, N. Ibrahim, dan K. Saleh, "Classification level of maturity of the tea leaves using the convolutional neural network method with ResNet architecture," e-Proceeding Telkom University.
- [10]D. Ilhamdi, N. Fuadah, dan S. Saidah, "Brain Tumor Classification Based on MRI Image Processing using Convolutional Neural Network (CNN) with ResNet Architecture," dalam Proc. 2023 3rd Int. Conf. on Artificial Intelligence, Robotics, and Signal Processing (AIRO SIP), Kuala Lumpur, Malaysia,Aug.2023,doi:10.1109/AIRO SIP58759.2023.10873939.
- [11]C. Cahyaningtyas, M. K. Mira, M. K. Candra Gudianto, M. K. Maya Sari, dan M. K. Noviyanti P., Computer Vision untuk Pemula: Deteksi dan Analisis Ekspresi Wajah dengan CNN. Jakarta, Indonesia: Uwais Inspirasi Indonesia, Jun. 2025.[Online].Tersedia:https://books.google.co.id/books?id=WTJoEQAAQBAJ.
- [12]T. A. Hartanto, "Perbandingan pre-trained CNN model pada klasifikasi penyakit retina mata," Skripsi, Program Studi Informatika, Fakultas Teknik dan Informatika, Universitas Multimedia Nusantara, Tangerang, 2022.

