

Sistem Grading Kualitas Telur Ayam Konsumsi berdasarkan Citra Kerabang Menggunakan *Convolutional Neural Network*

Fatra Nonggala Putra⁽¹⁾, Lestariningsih⁽²⁾, Vion Age Tricahyo⁽³⁾, Febbi Senna Lestari⁽⁴⁾

^{1,3,4}Program Studi Ilmu Komputer, Universitas Nahdlatul Ulama Blitar

²Program Studi Peternakan Universitas Nahdlatul Ulama Blitar
Jl. Masjid No. 22 Kota Blitar, Indonesia

Email: ¹fatranp@unublitar.ac.id

Tersedia Online di

<http://www.jurnal.unublitar.ac.id/index.php/briliant>

Sejarah Artikel

Diterima 5 Agustus 2024
Direvisi 4 September 2024
Disetujui 9 September 2024
Dipublikasikan 31 Agustus 2024

Keywords:

CNN; Classification; Grading; Egg

Kata Kunci:

CNN; Grading; Klasifikasi; Telur ayam konsumsi

Corresponding Author:

Name:
Fatra Nonggala Putra
Email:
fatranp@unublitar.ac.id

Abstract: *Chicken egg grading is identifying and grouping or classifying chicken eggs for consumption based on specific criteria. In SNI 3926:2008, the grade/class of consumption eggs is divided into 3 (three): Grades I, II, and III. Eggs with grade I have a higher selling value than grade II. Likewise, grade II eggs have a higher selling value than grade III. With these criteria, it is necessary to carry out a grading process that is still carried out by manual observation, so it requires extra time and energy with less uniform results because it depends on the individual observing. Based on these problems, it is necessary to have an egg quality grading system based on shell images that can identify egg quality according to its grade. In the study, there are several stages of research, namely: 1) Literature Study, 2) Data Collection, 3) System Design, 4) System Testing, 5) Results Analysis, and 6) Publication and Reporting. The CNN algorithm is used to classify based on shell images. The study's results showed that the performance of the CNN model had an accuracy value of 92.19%, precision of 92.78%, recall of 92.62%, and f1-score of 92.42%. This shows that the CNN model can well classify the quality of chicken eggs for consumption based on shell images.*

Abstrak: Grading telur ayam merupakan proses identifikasi dan pengelompokan atau klasifikasi telur ayam konsumsi berdasarkan kriteria tertentu. Dalam SNI 3926:2008, grade/kelas telur konsumsi dibagi menjadi 3 (tiga) yaitu telur Grade I, II, dan III. Telur dengan grade I memiliki nilai jual yang lebih tinggi daripada grade II, demikian juga telur grade II memiliki nilai jual lebih tinggi daripada grade III. Dengan adanya kriteria tersebut, perlu dilakukan proses grading yang biasanya masih dikerjakan dengan pengamatan secara kasap mata sehingga memerlukan waktu dan tenaga ekstra lebih dengan hasil yang kurang seragam karena bergantung kepada individu

yang mengamati. Berdasarkan permasalahan tersebut, perlu adanya sistem grading kualitas telur berdasar citra kerabang yang mampu mengidentifikasi kualitas telur sesuai gradenya. Pada penelitian terdapat beberapa tahapan penelitian yaitu; 1) Studi Pustaka, 2) Pengumpulan Data, 3) Perancangan Sistem, 4) Ujicoba Sistem, 5) Analisa Hasil, dan 6) Publikasi dan Pelaporan. Algoritma CNN digunakan untuk melakukan klasifikasi berdasarkan citra kerabang. Hasil penelitian menunjukkan bahwa performa model CNN memiliki nilai akurasi 92,19%, presisi 92,78%, recall 92,62%, dan f1-score 92,42%. Hal ini menunjukkan bahwa model CNN yang dibangun mampu melakukan klasifikasi kualitas telur ayam konsumsi berdasar citra kerabang dengan baik.

PENDAHULUAN

Jawa Timur merupakan penghasil telur terbesar di Indonesia khususnya kabupaten Blitar menjadi daerah dengan tingkat produksi telur terbanyak berdasarkan data Badan Pusat Statistik (BPS) sejak tahun 2016 hingga tahun 2022. Produksi telur yang melimpah tersebut perlu untuk dijaga mutunya (Lestariningsih et al., 2020). Pengaturan mutu ini menjadi perhatian karena mengingat telur yang berkualitas maka memberikan dampak signifikan terhadap kualitas gizi Masyarakat yang mengkonsumsinya. Pentingnya menjaga mutu telur konsumsi sangat penting untuk meningkatkan nilai jual telur dan agar produk mampu bersaing di pasar (Rusmanah et al., 2019). Pengaturan akan mutu telur konsumsi tercantum pada SNI 3926:2008 yaitu standar nasional dari jenis telur konsumsi (BPS Provinsi Jawa Timur, 2020). Pada SNI ini telah dijelaskan jika terdapat 3 (tiga) *grade*/kelas telur konsumsi yaitu telur *Grade I*, *II*, dan *III*. Telur dengan *grade I* memiliki nilai jual yang lebih tinggi daripada *grade II*, demikian juga telur *grade II* memiliki nilai jual lebih tinggi daripada *grade III*. Guna mengklasifikasikan telur sesuai SNI, maka diperlukan proses *grading*.

Pada saat ini, proses *grading* telur masih dikerjakan secara manual. Hal ini memberikan dampak kepada waktu dan tenaga ekstra lebih banyak sedangkan hasil yang didapatkan kurang seragam. Individu yang melakukan proses *grading* menjadi salah satu faktor munculnya peluang keberagaman yang lebih tinggi dan cenderung subjektif (Adi, 2023). Selain itu, proses *grading* manual juga mengharuskan dilakukan pencatatan jumlah telur dan *grade* yang dimiliki secara manual. Hal tersebut juga didukung dengan hasil wawancara terhadap salah satu pemilik peternakan ayam petelur di Kabupaten Blitar, dirumuskan 2 (dua) permasalahan yang menjadi dasar penelitian ini, yaitu; 1) Proses *grading* telur yang masih manual di beberapa peternakan ayam petelur yang ada di Blitar, 2) proses pencatatan jumlah dari telur sesuai *grade* yang masih menggunakan cara manual.

Dengan perkembangan teknologi, kini telah hadir sistem komputerisasi yang mampu melakukan pengidentifikasian secara lebih objektif dan efisien. Sistem ini menggunakan berbagai sensor dan algoritma untuk menganalisis berbagai karakteristik telur, seperti ukuran, bentuk, dan warna cangkang. Prinsip dari sistem komputerisasi ini yakni terdiri dari akuisisi data (sistem pencitraan dan sensor fisik), pre-processing (segmentasi gambar dan augmentasi data), ekstraksi fitur (fitur geometri, tekstur dan warna), klasifikasi dan output seperti klasifikasi *grade* dan visualisasi hasil. Beberapa penelitian mengungkapkan jika CNN sudah banyak sekali diintegrasikan dengan mutu produk peternakan seperti daging mendapatkan hasil pengklasifikasian citra dengan tingkat akurasi yang sangat tinggi (Sulistia & Vatesia, 2024). Pendekatan teknologi Deep Learning yaitu algoritma klasifikasi Convolutional Neural Network (CNN) (Bagas Valentino, 2023; Bila et al., 2021; Ekamila et al., 2023). CNN bertugas untuk mengidentifikasi objek citra telur berdasarkan data citra kerabang telur ayam konsumsi. *Grading* atau klasifikasi kualitas telur merupakan hal penting dalam proses ekonomi jual-beli telur ayam konsumsi untuk memastikan kualitas dari tiap butir telur sesuai *grade* ketentuan SNI 3926:2008. Hal tersebut jika diintegrasikan dalam menjamin mutu produk peternakan maka sangat bermanfaat sekali. Apalagi hal tersebut ditunjang dengan data atau sistem recording yang sudah terintegrasi dalam suatu sistem. Dikemukakan juga jika smart *grading* yang diterapkan pada bidang peternakan sangat membantu proses recording secara otomatis melalui sistem (Lestariningsih et al., 2023) dan (Putra et al., 2023).

Penelitian penting dilakukan karena dapat memberikan manfaat yang banyak dalam bidang peternakan. Manfaat dari sistem komputerisasi ini adalah objektivitas secara otomatis dan mengurangi bias manusia, efisiensi menghasilkan proses klasifikasi menjadi cepat dan akurat, konsistensi dengan kriteria penilaian yang sama diterapkan pada setiap telur serta menghasilkan data yang lebih akurat untuk pengendalian kualitas produksi. Jika diterapkan dalam industri maka hasil penelitian ini memberikan manfaat pada kegiatan *sorting* telur, *control* kualitas dan riset guna pengembangan model prediksi kualitas telur berdasarkan faktor-faktor tertentu.

METODE

Bagian ini menyajikan secara ringkas dan jelas tentang bagaimana prosedur penelitian dilakukan. Uraian disajikan dalam beberapa paragraf tanpa subbagian atau dipilah-pilah dalam subsubbagian. Isinya, menyangkut teknik pengumpulan data, subjek/populasi/sampel, instrumen pengumpulan data, sumber data, dan teknik analisis data. Kutipan ahli tentang metode penelitian diperbolehkan untuk ditulis namun sedikit saja, agar menghindari penggunaan tabel, dan lebih mengutamakan penulisan dalam bentuk deskriptif.

Populasi dalam penelitian ini adalah data citra telur ayam. Data citra didapatkan melalui pemotretan secara langsung terhadap telur ayam yang telah dikategorikan ke dalam tiga grade, yaitu grade 1, grade 2, dan grade 3. Grade 1 terdiri dari 23 telur, grade 2 terdiri dari 21 telur, dan grade 3 terdiri dari 20 telur. Setiap telur dipotret sebanyak lima kali dengan menampilkan permukaan cangkang telur yang berbeda. Oleh karena itu, jumlah data yang dijadikan sampel pada penelitian ini adalah 320 data citra telur ayam yang terdiri dari 115 citra telur ayam Grade 1, 105 citra telur ayam Grade 2, dan 100 citra telur ayam Grade 3. Citra yang digunakan merupakan citra RGB (Red, Green, Blue) dengan format file *.jpg. Sampling data dilakukan secara acak untuk membagi data menjadi data latih dan data uji dengan rasio 80:20, yaitu 80% data latih dan 20% data uji. Jumlah data latih dan data uji adalah sebagai berikut.

Tabel 1. Jumlah Data Uji dan Data Latih


	Data Latih	Data Uji	Jumlah
Grade 1	92 data	23 data	115 data
Grade 2	84 data	21 data	105 data
Grade 3	80 data	20 data	100 data
Total	256 data	64 data	320 data

Pembuatan model dalam penelitian ini memiliki beberapa tahapan sebagai berikut.

Preprocessing Data


Dalam penelitian ini, tahapan preprocessing data citra yang dilakukan adalah sebagai berikut.

- Cropping*, yaitu memotong bagian citra untuk memperoleh citra dengan ukuran lebih kecil dan lebih terkonsentrasi pada bagian yang ditentukan (Amelia et al., 2016). Pada penelitian ini, *cropping* dilakukan pada citra masukan untuk mengurangi objek yang tidak dibutuhkan dan menyeragamkan ukurannya menjadi persegi.



Gambar 1. Hasil Foto Telur Konsumsi

- Resize*, yaitu mengubah ukuran citra sesuai kebutuhan (Lorentius et al., 2019). Pada penelitian ini, citra masukan diubah ukurannya menjadi 512×512 piksel agar proses klasifikasi tidak terlalu berat.




Gambar 2. Hasil Resize Dataset

- c. Augmentasi data, yaitu teknik memodifikasi data citra yang sudah ada dengan cara mengubah posisi dan bentuknya tanpa menghilangkan esensi data (Mubarok, 2019). Tahapan ini dilakukan untuk memperbanyak jumlah data latih karena jumlah dataset terbatas dan kurang beragam agar performa model dapat meningkat. Pada penelitian ini, augmentasi data yang dilakukan pada dataset adalah *rescale*, *rotation range*, *height shift range*, *width shift range*, *flip*, dan *fill mode*. *Rescale* diterapkan pada seluruh dataset mencakup data latih dan data uji, sedangkan augmentasi data lainnya hanya diterapkan pada data latih. Tahapan augmentasi data yang dilakukan dalam penelitian ini, antara lain:

- 1) *Rescale*, yaitu menormalisasi citra atau memperkecil nilai pada pemodelan dengan cara membagi piksel dari 0-255 dengan piksel terbesar atau 255 sehingga menghasilkan nilai piksel dengan rentang 0-1 (D & Kusumaningtyas, 2022). Pada penelitian ini, nilai *rescale* adalah $1./255$.
- 2) *Rotation range*, yaitu memutar citra secara acak sesuai dengan rentang nilai rotasi yang digunakan (D & Kusumaningtyas, 2022). Pada penelitian ini, nilai *rotation range* adalah 20 yang menunjukkan rentang rotasi $\pm 20^\circ$. Artinya, citra dapat dirotasi hingga 20° searah jarum jam dan 20° berlawanan arah jarum jam.
- 3) *Height shift range*, yaitu menggeser citra secara vertikal (Idrus, 2022). Pada penelitian ini, nilai *height shift range* adalah 0,1 yang menunjukkan rentang pergeseran $\pm 10\%$ dari tinggi citra.
- 4) *Width shift range*, yaitu menggeser citra secara horizontal (Idrus, 2022). Pada penelitian ini, nilai *width shift range* adalah 0,1 yang menunjukkan rentang pergeseran $\pm 10\%$ dari lebar citra.
- 5) *Flip*, yaitu membalik citra secara horizontal atau vertikal (Mubarok, 2019). Pada penelitian ini, *flip* dilakukan secara horizontal.
- 6) *Fill mode*, yaitu mengisi piksel citra yang kosong akibat pergeseran atau rotasi citra dengan mode tertentu (D & Kusumaningtyas, 2022). Pada penelitian ini, *fill mode* yang digunakan adalah *constant*.

Augmentasi data dilakukan dengan “*ImageDataGenerator()*” dari Keras. Dalam penerapannya, “*ImageDataGenerator()*” melakukan augmentasi data pada citra secara acak dengan mengkombinasikan jenis augmentasi yang telah ditentukan, baik sebagian maupun keseluruhan dengan contoh hasil sebagai berikut.



Gambar 3. Ilustrasi Dataset

Pembangunan Model CNN

Arsitektur model Convolutional Neural Network disusun oleh peneliti dengan susunan lapisan yang ditunjukkan oleh tabel berikut.

Tabel 2. Arsitektur Model Convolutional Neural Network

Nama Lapisan	Ukuran
Convolution Layer (Conv2D)	32 filter ukuran 3×3 dan aktivasi ReLu
Pooling (Maxpooling)	Filter 2×2
Convolution Layer (Conv2D)	32 filter ukuran 3×3 dan aktivasi ReLu
Pooling (Maxpooling)	Filter 2×2
Convolution Layer (Conv2D)	64 filter ukuran 3×3 dan aktivasi ReLu
Pooling (Maxpooling)	Filter 2×2
Convolution Layer (Conv2D)	64 filter ukuran 3×3 dan aktivasi ReLu
Pooling (Maxpooling)	Filter 2×2
Dropout	0,2
Flatten	-
Dense	64 neuron dan aktivasi ReLu
Dense	32 neuron dan aktivasi ReLu
Dense	3 neuron dan aktivasi Softmax

Berdasarkan susunan lapisan tersebut, model Convolutional Neural Network memiliki empat lapisan konvolusi dengan ukuran filter 3×3 (Firdaus, 2021). Jumlah filter dalam lapisan ini adalah 32 dan 64 yang disusun dari jumlah filter terkecil ke terbesar. Susunan jumlah filter ini bertujuan agar filter yang lebih besar dapat mengekstraksi fitur citra dari konvolusi sebelumnya yang lebih kecil. Dalam susunan lapisan tersebut, nilai *Stride* tidak ditentukan sehingga digunakan nilai *Stride* standar yaitu 1 agar filter bergerak satu langkah atau piksel saat melakukan operasi konvolusi. Setiap kali menyelesaikan satu lapisan konvolusi, dilakukan *Pooling* dengan metode *Maxpooling* berukuran 2×2. Setelah itu, proses dilanjutkan dengan *Dropout* 0,2, *Flatten*, lalu *Fully Connected Layer*. *Fully Connected Layer* terdiri dari tiga lapisan *Dense* dengan jumlah neuron 64, 32, dan 3. Aktivasi ReLu digunakan pada setiap *Convolution Layer* dan dua *Dense* pertama, sedangkan aktivasi Softmax digunakan pada *Dense* terakhir karena klasifikasi terdiri dari tiga kelas.

HASIL DAN PEMBAHASAN

Pada penelitian ini, proses klasifikasi dilakukan dengan model Convolutional Neural Network yang telah dibangun. Model dilengkapi dengan optimasi Adam untuk mengoptimalkan kinerja model pelatihan. Nilai batch size yang digunakan adalah 8 sehingga setiap epoch memiliki 32 steps per epoch ($256 / 8 = 32$) dan 8 validation steps ($64 / 8 = 8$). Sementara itu, nilai epoch ditentukan sebesar 100 yang menerapkan early stopping, yaitu teknik yang digunakan untuk menghentikan proses pelatihan ketika model sudah mencapai kondisi tertentu. Dalam pembuatan model ini, proses pelatihan akan berhenti ketika nilai val_accuracy sudah tidak mengalami peningkatan setelah 5 iterasi dari val_accuracy tertinggi.

Lapisan Konvolusi Pertama

Lapisan konvolusi pertama dengan jumlah filter 32 melakukan ekstraksi fitur dari citra masukan sehingga menghasilkan *feature map* yang berisi fitur unik dari citra asli. *Feature map* selanjutnya diaktivasi dengan ReLu untuk mempertahankan nilai positif dan mengubah nilai negatif menjadi nol. *Feature map* hasil konvolusi memiliki ukuran yang lebih kecil daripada citra masukan karena pengaruh ukuran filter yang digunakan. Ukuran *feature map* hasil konvolusi dapat dihitung menggunakan rumus pada Persamaan (1) dimana pada konvolusi pertama menjadi $(512 - 3) + 1 = 510$ sehingga *feature map* berukuran 510×510 piksel. Sementara itu, jumlah parameter pada lapisan konvolusi dapat dihitung dengan rumus pada Persamaan (2) dimana pada konvolusi pertama menjadi $((3 \times 3 \times 3) + 1) \times 32 = 896$ parameter.

$$Uk\ hasil\ konv = (uk\ masukan - uk\ filter) + 1 \dots \dots \dots (1)$$

$$Jml\ param\ konv = ((uk\ filter \times uk\ filter \times jml\ channel) + 1) \times jml\ filter \dots \dots \dots (2)$$

Setelah diaktivasi, proses dilanjutkan ke operasi *Maxpooling* untuk mengurangi ukuran piksel pada *feature map*. *Maxpooling* 2×2 menunjukkan bahwa akan diambil satu nilai piksel terbesar dari setiap empat nilai piksel yang berdekatan pada *feature map* untuk mempertahankan informasi penting dalam citra. Oleh karena itu, *feature map* hasil *Maxpooling* memiliki ukuran piksel 50% dari ukuran sebelumnya. Pada *Maxpooling* pertama, ukuran *feature map* menjadi 255×255 piksel.

Lapisan Konvolusi Kedua

Konvolusi kedua dilakukan dengan filter berjumlah 32 sehingga memiliki parameter sebanyak $((3 \times 3 \times 32) + 1) \times 32 = 9.248$ parameter. *Feature map* hasil konvolusi kedua memiliki ukuran $(255 - 3) + 1 = 253$ atau 253×253 piksel. Setelah diaktivasi dengan ReLu, *feature map* mengalami *Maxpooling* kedua sehingga ukurannya menjadi 126×126 piksel.

Lapisan Konvolusi Ketiga

Proses dilanjutkan ke lapisan konvolusi ketiga dengan filter berjumlah 64 sehingga memiliki parameter sebanyak $((3 \times 3 \times 32) + 1) \times 64 = 18.496$ parameter. *Feature map* hasil konvolusi ketiga memiliki ukuran $(126 - 3) + 1 = 124$ atau 124×124 piksel. Setelah mengalami aktivasi ReLu, *feature map* mengalami *Maxpooling* ketiga sehingga ukurannya menjadi 62×62 piksel.

Lapisan Konvolusi Keempat

Konvolusi keempat atau terakhir dilakukan dengan filter berjumlah 64 sehingga memiliki parameter sebanyak $((3 \times 3 \times 64) + 1) \times 64 = 36.928$ parameter. *Feature map* hasil konvolusi keempat memiliki ukuran $(62 - 3) + 1 = 60$ atau 60×60 piksel. Setelah mengalami aktivasi ReLu, *feature map* mengalami *Maxpooling* keempat sehingga ukurannya menjadi 30×30 piksel.

Dropout

Setelah menyelesaikan empat kali konvolusi, proses dilanjutkan ke tahap *Dropout* untuk membuang beberapa neuron secara acak. Tahapan ini dilakukan untuk mengurangi ketergantungan antarneuron akibat kompleksitas *Hidden Layer* yang dapat menimbulkan *overfitting*. Nilai 0,2 pada *Dropout* menunjukkan bahwa 20% neuron akan dibuang secara acak pada setiap iterasi pelatihan.

Flatten

Sebelum menuju *Dense Layer (Fully Connected Layer)*, *feature map* yang berupa *array* multidimensi melalui tahapan *Flatten* untuk mentransformasinya menjadi *array* atau vektor satu dimensi. Tahapan ini diperlukan karena *Fully Connected Layer* hanya dapat memproses *array* satu dimensi. Ukuran vektor satu dimensi dapat dihitung dengan rumus pada Persamaan (3) dimana $(30 \times 30 \times 64) = 57.600$.

$$Uk \text{ vektor} = (p \text{ feature map} \times \ell \text{ feature map} \times \text{jml filter}) \dots\dots\dots(3)$$

Lapisan Dense Pertama

Fully Connected Layer merupakan lapisan akhir dari model CNN yang melakukan klasifikasi citra. Vektor satu dimensi menjadi masukan dari *Dense Layer* pertama yang memiliki 64 neuron. Setiap neuron pada lapisan tersebut terhubung dengan seluruh neuron pada data masukan agar model dapat mempelajari pola-pola yang kompleks. Setiap neuron selanjutnya diaktivasi dengan ReLu sehingga menghasilkan vektor berdimensi 64. Jumlah parameter pada lapisan ini dapat dihitung dengan Persamaan (4) dimana $(57.600 \times 64) + 64 = 3.686.464$ parameter.

$$\text{Jml param dense layer 1} = (\text{jml keluaran sebelumnya} \times \text{jml neuron}) + \text{jml neuron} \dots\dots(4)$$

$$\text{Jml param dense layer 2} = (\text{jml neuron sebelumnya} \times \text{jml neuron}) + \text{jml neuron} \dots\dots(5)$$

Lapisan Dense Kedua

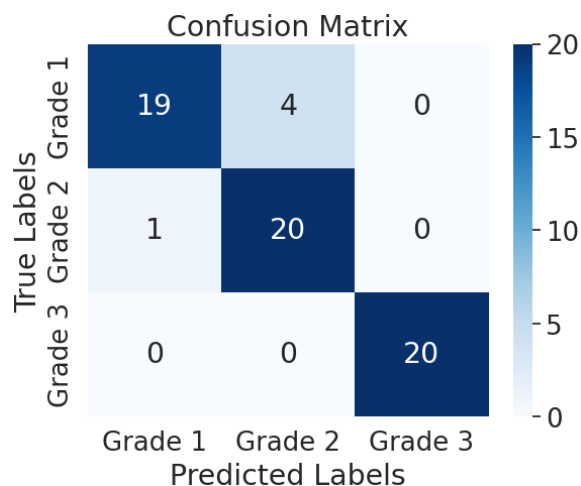
Setelah itu, vektor menjadi masukan untuk *Dense Layer* kedua yang memiliki 32 neuron dan diaktivasi dengan ReLu. Jumlah parameter lapisan ini dapat dihitung dengan rumus pada Persamaan (5) dimana $(64 \times 32) + 32 = 2.080$ parameter.

Lapisan Dense Ketiga

Selanjutnya, vektor menjadi masukan untuk *Dense Layer* ketiga yang memiliki 3 neuron dan diaktivasi dengan Softmax. Aktivasi Softmax dipilih agar keluaran dari lapisan ini yang menjadi hasil prediksi berupa nilai 0, 1, dan 2. Nilai prediksi tersebut disesuaikan dengan kasus awal yang berupa *multiclass classification* atau klasifikasi dengan lebih dari dua kelas. Jumlah parameter lapisan ini adalah $(32 \times 3) + 3 = 99$. Dengan demikian, jumlah total parameter yang dapat dilatih pada model ini adalah 3.754.211 parameter.

Evaluasi

Tahap evaluasi dalam penelitian ini dilakukan dengan metode *confusion matrix*, serta akurasi, presisi, *recall*, dan *f1-score* (Pratama Adi et al., 2023) dengan hasil evaluasi sebagai berikut.



Gambar 4. Hasil *Confusion Matrix*

Berdasarkan *confusion matrix* tersebut, terdapat 4 citra Grade 1 yang terprediksi secara salah sebagai Grade 2 dan 1 citra Grade 2 yang terprediksi secara salah sebagai Grade 1. Sementara itu, citra lainnya terprediksi secara benar sesuai kelasnya.

	precision	recall	f1-score	support
Grade 1	0.9500	0.8261	0.8837	23
Grade 2	0.8333	0.9524	0.8889	21
Grade 3	1.0000	1.0000	1.0000	20
accuracy			0.9219	64
macro avg	0.9278	0.9262	0.9242	64
weighted avg	0.9273	0.9219	0.9218	64

Nilai akurasi, presisi, *recall*, dan *f1-score* dapat dilihat dari *Classification Report*. Berdasarkan hasil tersebut dalam bentuk persentase, model memiliki akurasi 92,19%, presisi 92,78%, *recall* 92,62%, dan *f1-score* 92,42%.

SIMPULAN

Implementasi algoritma Convolutional Neural Network untuk klasifikasi atau grading telur ayam konsumsi dilakukan dengan 320 data citra RGB dari telur konsumsi berukuran 512×512 piksel dengan rasio data latih dan data uji sebesar 80:20 yang diproses melalui empat lapisan konvolusi dengan ukuran filter 3×3, jumlah filter 32 dan 64, Maxpooling 2×2, Dropout 0,2, Flatten, lapisan Fully Connected dengan jumlah filter 64, 32, dan 3, serta aktivasi ReLu berdasarkan batch size dan epoch. Hasil percobaan menunjukkan bahwa batch size berukuran 8 dan nilai epoch 32 menghasilkan nilai akurasi 92,19%, presisi 92,78%, recall 92,62%, dan f1-score 92,42%. Hasil ini menunjukkan bahwa model CNN yang dibangun mampu melakukan grading/klasifikasi telur ayam konsumsi berdasarkan citra kerabang dengan baik.

DAFTAR RUJUKAN

- Adi F. (2023). Klasifikasi Ukuran dan Kualitas Telur Ayam Menggunakan Algoritma Convolutional Neural Network. *e-Proceeding of Engineering*, 10(1), 473-480.
- Amelia, I., Hermana, A. N., & Pramana, A. (2016). Verifikasi Tanda Tangan Dengan Edge Detection Dan Metode Learning Vector Quantization. *MIND Journal*, 1(1), 49–56. <https://doi.org/10.26760/mindjournal.v1i1.49>
- Bagas Valentino, S. (2023). Klasifikasi Kualitas Daging Marmer Berdasarkan Citra Warna Daging Menggunakan Metode Convolutional Neural Network. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(1), 125–129. <https://doi.org/10.36040/jati.v7i1.6128>

- Bila, S., Fitrianto, A., & Sartono, B. (2021). Image Classification of Beef and Pork Using Convolutional Neural Network in Keras Framework. *International Journal of Science, Engineering and Information Technology*, 5(02), 245–248. <https://doi.org/10.21107/ijseit.v5i02.9864>
- BPS Provinsi Jawa Timur. (2020). *Indikator Pertanian Provinsi Jawa Timur 2020*.
- D, W. M. P., & Kusumaningtyas, A. P. (2022). Analisis Pengaruh Data Augmentasi Pada Klasifikasi Bumbu Dapur Menggunakan Convolutional Neural Network. *Jurnal Media Informatika Budidarma*, 6(4), 2022–2031. <https://doi.org/10.30865/mib.v6i4.4201>
- Ekamila, T., Rahayu, F., Zuchriadi, A., & Octa Indarso, A. (2023). Penerapan Deep Learning Untuk Klasifikasi Kesegaran Daging Sapi Berbasis Mobile Apps. *Edu Komputika Journal*, 10(1), 10–16. <https://doi.org/10.15294/edukomputika.v10i1.68478>
- Firdaus, M. R. (2021). Penerapan Algoritma Convolutional Neural Network dalam Klasifikasi Telur Ayam Fertile dan Infertile Berdasarkan Hasil Candling. *Jurnal Informatika Universitas Pamulang*, 5(4), 563. <https://doi.org/10.32493/informatika.v5i4.8556>
- Idrus, T. (2022). *Identifikasi Penyakit Pada Tanaman Apel Menggunakan Convolutional Neural Network Berbasis Citra Daun*. Universitas Islam Negeri Maulana Malik Ibrahim.
- Lestariningsih, L., Nada, M. S., Yasin, M. Y., Ropida, S., & Abidin, M. K. (2020). Peranan Nomor Kontrol Veteriner Terhadap Jaminan Mutu Keamanan Produk Hasil Peternakan. *Briliant: Jurnal Riset Dan Konseptual*, 5(1), 180–188. <https://doi.org/10.28926/briliant.v5i1.437>
- Lestariningsih, L., Putra, F. N., & Mashudi, M. (2023). Optimalisasi Tingkat pengetahuan peternak Puyuh terhadap Penyuluhan Mesin Tetas Puyuh dan smart Recording Berbasis IoT. *JPPNU (Jurnal Pengabdian Dan Pemberdayaan Nusantara)*, 5(2), 173–180.
- Lorentius, C. A., Adipranata, R., & Tjondrowiguno, A. (2019). Pengenalan Aksara Jawa dengan Menggunakan Metode Convolutional Neural Network. *Jurnal INFRA*, 7(1), 221–227.
- Mubarok, H. (2019). *Identifikasi Ekspresi Wajah Berbasis Citra Menggunakan Algoritma Convolutional Neural Network (CNN)*. Universitas Islam Negeri Maulana Malik Ibrahim.
- Pratama Adi, M. F., Prasasti, A. L., & Paryasto, M. W. (2023). *Klasifikasi Ukuran dan Kualitas Telur Ayam Menggunakan Algoritma Convolutional Neural Network Classification of Chicken Egg Quality and Size Using the Convolutional Neural Network Algorithm*. 10(1), 1–8.
- Putra, F. N., Lestariningsih, L., & Tricahyo, V. A. (2023). Optimalisasi Peningkatan Tingkat Pengetahuan Peternak Itik dengan Mengembangkan Smart grading Berbasis IoT dan Edukasi Budidaya Itik. *JPPNu (Jurnal Pengabdian Dan Pemberdayaan Nusantara)*, 5(2), 275–284.
- Rusmanah, E., Wibowo Irawan, A., & Andria, F. (2019). Implementasi Digital Marketing Guna Peningkatan Peluang Pasar Produksi Hasil Ternak Puyuh Masyarakat Desa Galuga. *Jurnal ABM Mengabdi*, 6(1), 15–25. www.slideshare.net/wearesocialsg/digital-in-2018-southeast-asia
- Sulistia, F. Y., & Vatesia, A. (2024). PENERAPAN DEEP LEARNING MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) UNTUK KLASIFIKASI DAGING AYAM MENGGUNAKAN ARSITEKTUR RESNET-50. *Journal of Information Technology and Computer Science (INTECOMS)*, 7(3), 685–691.