

# Optimasi Image Classification Pada Burung Kenari Dengan Menggunakan Data Augmentasi dan Convolutional Neural Network

Gusniar Alfian Noor<sup>\*1</sup>, Dadang Iskandar Mulyana<sup>2</sup>, Faisal Akbar<sup>3</sup>

<sup>1,2,3</sup>Teknik Informatika, Sekolah Tinggi Ilmu Komputer Cipta Karya Informatika,

E-mail: <sup>\*1</sup>alfiangusniar13@gmail.com, <sup>2</sup>mahvin2012@gmail.com, <sup>3</sup> akb.faisal02@gmail.com

## Abstrak

Burung kenari atau dalam Bahasa latin (*Serinus canaria*) merupakan salah satu burung hias dimana anda dapat mendengar kicauan yang sangat bagus dan menarik. Kepulauan Canary pertama kali ditemukan di Kepulauan Canary pada abad ke-15 oleh seorang navigator Prancis bernama Jean de Berthand. Burung yang ditemukan memiliki bulu dan warna yang sangat indah, serta suara yang sangat merdu. Namun perlu diingat bahwa ada beberapa jenis dan jenis burung kenari, tergantung dari bentuk, warna dan asalnya. Dalam hal ini peneliti menggunakan Convolutional Neural Network (CNN) untuk mengoptimalkan klasifikasi gambar kenari. Convolutional Neural Network (CNN) adalah jenis jaringan saraf yang biasa digunakan untuk data gambar. Tujuan dari penelitian ialah untuk mengoptimalkan citra burung kenari untuk mengklasifikasikan data berlabel menggunakan metode Supervised Learning, salah satu metode pembelajaran mesin di mana sistem sudah mengenali atau memiliki hasil yang diharapkan pengguna. Singkatnya, metode pembelajaran ini bekerja dengan menggunakan kembali data dan mengeluarkan hasil yang dimasukkan oleh pengguna atau dibuat oleh sistem sebelumnya. Implementasi pengenalan citra burung kenari dilakukan dengan menggunakan 2 model pengujian yaitu model Sequential dan model on top VGG16 yang berjalan pada data augmentasi. Data pengujian pada penelitian ini adalah 1.275 citra data latih dan 30 citra data uji yang menghasilkan nilai evaluasi dengan nilai akurasi 98,40% dan nilai loss 0,092 pada model Sequential dan nilai akurasi 98,15% dan nilai loss 0,032 pada model on top VGG16.

**Kata Kunci** : Image Classification, Burung Kenari, Data Augmentasi, Convolutional Neural Network

## 1. PENDAHULUAN

Di Indonesia sudah sejak lama masyarakatnya gemar memelihara burung kenari (*Serinus canaria*) karena kombinasi warnanya yang banyak, variasi dan kicauan.[1] Penampilan Jenis burung kenari ini karena ini Burung kenari mudah dikembangbiakkan dan dipelihara, selalu ada inovatif baru untuk dapatkan lebih banyak warna baru, peternak kenari yang menarik cenderung menyilangkan burung kenari polos berbagai warna untuk mendapatkan warna tak terbatas. Misalnya, warna bulu kuning polos putih lapisan mendapat warna campuran kuning dan putih dari kuning putih. Dan burung warna bulu campur koleksi yang menarik. [2] Dalam perkembangan teknologi yang semakin pesat saat ini, terutama dibidang computer vision dalam beberapa tahun ini dengan penerapan jaringan saraf convolutional menunjukkan bahwa kinerja yang canggih dengan tingkat akurasi yang tinggi, dalam penemuan objek.[3]

Klasifikasi adalah proses menemukan model yang dapat membagi data berdasarkan kelas, dan dibagi menjadi dua fase, yaitu dengan fase pelatihan (pembelajaran) dan pengujian (testing), yang menentukan cara mengenali kategori data.[4]

Deep learning memiliki kemampuan yang sangat baik dalam computer vision dengan kapabilitasnya yang signifikan dalam memodelkan berbagai data kompleks seperti data gambar.

Salah satu metode Deep learning pada saat ini memiliki hasil paling bagus dalam pengenalan citra adalah Convolutional Neural Network (CNN). Hal itu disebabkan karena metode CNN berusaha meniru sistem pengenalan citra pada visual cortex manusia sehingga memiliki kemampuan mengolah informasi citra. [5] Oleh karena itu, penulis akan memberikan contoh mengenai pengenalan objek pada gambar.



Gambar 1. Burung Kenari

Convolutional Neural Network (CNN) dapat digunakan karena bisa menangani masalah yang cukup kompleks tersebut dan memiliki kinerja yang baik dari hasil penelitian terkait.[6] Convolutional Neural Network (CNN) merupakan variasi dari jaringan saraf tiruan yang memiliki bobot dan beberapa lapisan tersembunyi yang disusun menjadi arsitektur.[7] Convolutional Neural Network (CNN) dapat digunakan dalam proses klasifikasi data. Hal ini ditandai dengan metode pembelajaran yang diawasi. Pembelajaran terbimbing berfungsi agar data yang akan dilatih sudah ada dan variabel yang akan dibidik sudah ada. Tujuan yang dicapai Metode ini terdiri dari pengelompokan data ke dalam data yang sudah ada. CNN banyak digunakan untuk mendeteksi objek atau adegan dan melakukan deteksi objek dan segmentasi.[8]

Berdasarkan penulisan diatas, maka penulis bertujuan untuk membuat Optimasi Image Classification pada burung Kenari Dengan Menggunakan Data Augmentasi. Adapun metode yang digunakan pada sistem tahap pengenalan karakter plat nomor kendaraan ini adalah metode Convolutional Neural Network (CNN).

## 2. METODE PENELITIAN

### 2.1. Tahapan Penelitian

Tahapan ini akan membahas beberapa metode rancangan. “Optimasi Image Classification Pada Burung Kenari Dengan Menggunakan Data Augmentasi dan Convolutional Neural Network”.

dimana peneliti akan mengenalisa beberapa metode algoritma CNN.

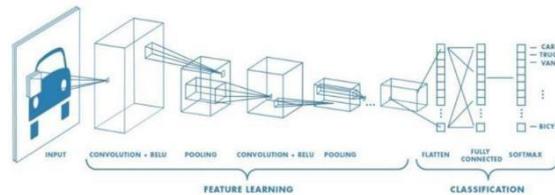
Convolutional Neural Network (CNN) adalah evolusi dari Multilayer Perceptron (MLP) yang dirancang untuk memproses data dua dimensi. Karena kedalaman jaringan, CNN diklasifikasikan sebagai jenis jaringan saraf dalam dan banyak diterapkan pada data gambar. Untuk klasifikasi citra, MLP tidak menyimpan informasi spasial dari data citra, menganggap setiap piksel sebagai fitur independen, dan menghasilkan hasil yang buruk, yang tidak sesuai.[5]

Gambar digital HSV mendefinisikan warna dalam hal rona (warna sebenarnya), saturasi (kemurnian warna), dan nilai (kecerahan warna). Keunggulan HSV adalah adanya dalam warna, dan sama dengan hingga yang dirasakan oleh indera manusia. Warna terdiri dari model, tetapi 444 lain seperti RGB adalah hasil dari campuran dari primer.[9] Selain itu, penelitian ini dapat merumuskan masalah, merumuskan asumsi awal, mengidentifikasi variabel, mengklasifikasikan data, menginterpretasikan data, merumuskan model, menghubungkan data, dan menarik kesimpulan.[10]

Baru-baru ini, pengenalan gambar yang lebih luas, pengenalan objek menggunakan Convolutional Neural Network (CNN), telah membuat perkembangan yang luar biasa. Sejak dilaporkan dalam objek ImageNet, akurasi dan peningkatan CNN merupakan tantangan untuk klasifikasi setiap tahun.[11]

Struktur CNN memiliki kemiripan dengan jaringan syaraf tiruan. Klasifikasi gambar CNN menerima masukan atau masukan gambar yang diproses dan masuk dalam kategori tertentu. Perbedaan antara CNN dan ANN terletak pada arsitektur tambahan CNN, yang dioptimalkan untuk karakteristik gambar input.[12] CNN memiliki beberapa komponen utama, antara lain:

1. Convolution Layer
2. Pooling Layer
3. Rectified Linear Unit (ReLU)
4. Fully Connected Layer
5. Dropout
6. Softmax Activation



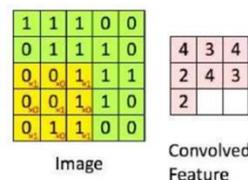
Gambar 2. Proses Convolutional Neural Network[12]

1. Convolutional Layer

Convolutional Neural Networks merupakan suatu varian dari neural network pada deep learning yang dibuat melalui proses peningkatan Multi Layer Perceptron dan banyak dipakai dalam aplikasi computer vision seperti klasifikasi citra, deteksi objek dan pengenalan wajah.[13] Hasil dari convolution layer adalah citra baru yang menunjukkan fitur dari citra masukan. Setiap citra yang menjadi masukan, menggunakan filter convolution layer dalam proses tersebut. Convolutional layer terdiri dari neuron yang tersusun sedemikian rupa sehingga membentuk sebuah filter dengan panjang dan tinggi (pixel). Sebagai contoh, layer pertama pada feature extraction layer adalah convolutional layer dengan ukuran 6x6x3. Panjang 6pixel, tinggi 6 pixel, dan tebal/jumlah 3 buah sesuai dengan channel dari gambar tersebut. Ketiga filter ini akan digeser keseluruhan bagian dari gambar. Setiap pergeseran akan dilakukan operasi “dot” antara input dan nilai dari filter tersebut sehingga menghasilkan sebuah output atau biasa disebut sebagai activation map atau feature map.[12] Dalam persamaan matematika dari operasi konvolusi bisa dilihat pada persamaan berikut [14]:

$$s(t) = (x \times y)(t) \quad (1)$$

Dengan s(t) adalah fungsi konvolusi, x merupakan input, dan w adalah filter.



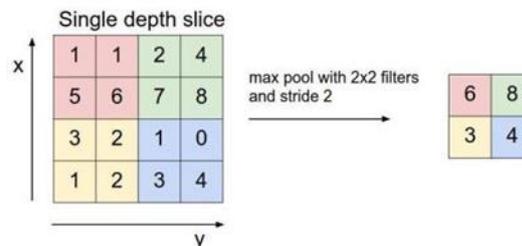
Gambar 3. Operasi Konvolusi[12]

Seluruh kotak hijau adalah gambar yang dapat dilipat. Kernel bergerak dari sudut kiri atas ke sudut kanan bawah. Seperti yang kita lihat hasil melipat gambar dari gambar di sebelah kanan. Tujuannya adalah untuk menggulung data gambar. Yaitu, mengekstraksi fitur dari gambar input. Konvolusi menghasilkan transformasi linier dari data input sesuai dengan informasi spasial dalam data.

Bobot pada layer ini menunjukkan convolutional kernel yang digunakan, sehingga Anda dapat melatih convolutional kernel berdasarkan input ke CNN.[12]

## 2. Pooling Layer

Pooling layer yang terdapat pada CNN menggunakan fungsi fitur map atau activation map sebagai masukan dan diteruskan untuk diolah dengan berbagai jenis operasi statistik berdasarkan nilai piksel terdekat. Keuntungan dari pooling layer yaitu dapat secara bertahap mengurangi ukuran volume output pada fitur map yang dapat berguna untuk mengendalikan overfitting.[15] Pada umumnya ada dua pooling yang bisa digunakan yaitu max pooling dan average pooling.[16] Dimasukkan di antara lapisan konvolusi berkelanjutan dari arsitektur model CNN, lapisan penyatuan secara bertahap dapat mengurangi ukuran volume keluaran peta fitur untuk mengurangi jumlah parameter dan perhitungan dalam jaringan dan mengontrol overfitting. Hal terpenting saat membuat model CNN adalah memilih banyak jenis pooling layer. Dalam hal ini, ada manfaat untuk kinerja model.[17] Lapisan penyatuan bekerja dengan larik peta fitur apa pun dan mengurangi ukurannya. Bentuk penyatuan lapisan yang paling umum adalah dengan menggunakan filter 2x2. Filter ini diterapkan dalam dua langkah dan bekerja pada setiap irisan input. Bentuk seperti itu menyusutkan peta fitur menjadi 75% dari ukuran aslinya. Pada dasarnya, pooling layer terdiri dari filter ukuran dan kenaikan tertentu yang menyapu seluruh area peta fitur. Pooling yang umum digunakan adalah maximum pooling dan average pooling. Misalnya, jika Anda menggunakan penyatuan maksimum 2x2 dengan 2 langkah, setiap pergeseran filter memilih nilai maksimum dalam ruang piksel 2x2, dan penyatuan rata-rata memilih nilai rata-rata.[12]



Gambar 4. Max Pooling

Tujuan penggunaan pooling layer adalah untuk memperkecil dimensi dari peta fitur (downsampling). Ini mempercepat perhitungan dengan mengurangi parameter yang perlu diperbarui dan harus mengatasinya. [12]

## 3. Rectified Linear Unit (ReLU)

Rectified Linear Unit (ReLU) adalah fungsi aktivasi linear yang digunakan dalam CNN. Activation function mempunyai tugas di dalam menentukan apakah neuron harus aktif atau tidak berdasarkan nilai bobot yang dimasukan.[18] Dalam Persamaan matematika dari fungsi aktivasi ReLU bisa kita lihat pada persamaan berikut ini :[14]

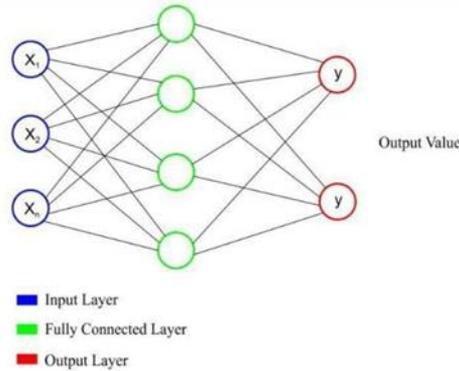
$$relu(x) = \max(0, x) \quad (2)$$

Dengan  $relu(x)$  merupakan fungsi ReLU dari nilai  $x$ ,  $x$  adalah input, dan  $\max(0, x)$  ialah fungsi nilai max dari 0 dan  $x$ .

## 4. Fully Connected Layer

Feature map Karena hasil ekstraksi ciri masih berupa larik multidimensi, maka peta ciri harus “diratakan” atau diubah menjadi vektor agar dapat digunakan sebagai masukan dari bidang yang terhubung penuh.

Lapisan Fully-connected Merupakan lapisan dimana semua neuron aktif pada lapisan sebelumnya terhubung dengan neuron pada lapisan berikutnya, mirip dengan jaringan syaraf tiruan. Sebelum terhubung ke semua neuron di lapisan FullyConnected, setiap aktivitas di lapisan sebelumnya harus dikonversi ke data 1D. Lapisan Fully-Connected Ini biasanya digunakan dalam metode Multilayer Perceptron dan dimaksudkan untuk memproses data sehingga dapat diklasifikasikan. Perbedaan antara lapisan Fully Connected dan lapisan konvolusi reguler adalah bahwa neuron di lapisan konvolusi hanya terhubung ke area input tertentu. Lapisan FullyConnected memiliki neuron yang terhubung sepenuhnya. Namun, kedua lapisan tersebut tetap mengoperasikan produk dot, sehingga fungsinya tidak jauh berbeda.[12]

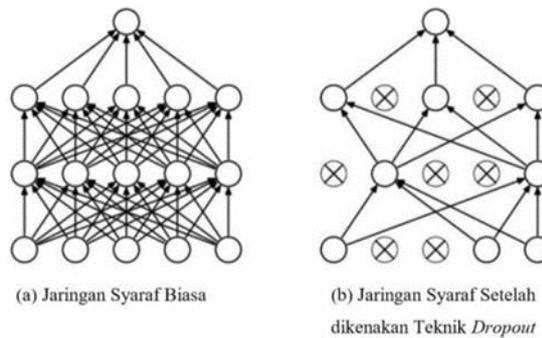


Gambar 5. Fully Connected Layer

5. Dropout

Dropout Adalah pilihan acak dari beberapa neuron. Digunakan selama pelatihan. Neuron ini dihancurkan hampir secara acak. Ini berarti bahwa kontribusi neuron yang ditinggalkan dihentikan sementara jaringan dan bobot baru tidak diterapkan ke neuron selama backpropagation.

Dropout merupakan proses mencegah overfitting dan mempercepat proses belajar. Ini mengacu pada penghapusan neuron dalam bentuk lapisan tersembunyi dan terlihat di jaringan. Menghapus neuron berarti menghapusnya sementara dari jaringan yang ada. Neuron yang akan dihapus dipilih secara acak. Setiap neuron diberi peluang antara nol dan satu.



Gambar 6. Contoh Implementasi Dropout

Pada gambar 6 jaringan syaraf (a) merupakan jaringan syaraf biasa dengan dua lapisan tersembunyi. Sedangkan pada bagian (b) jaringan syaraf sudah diaplikasikan teknik regularisasi dropout dimana ada beberapa neuron aktivasi yang tidak dipakai lagi. Ini adalah salah satu teknik sangat mudah diimplementasikan pada model CNN dan berdampak pada performa model melatih serta mengurangi overfitting.[12]

$$zr = \sum_{c=1}^J xcWcr + br \quad (3)$$

Dengan r ialah 1,2,3,...,R, R merupakan jumlah neuron yang keluar, J merupakan jumlah neuron yang masuk, zr adalah output pada neuron ke-r, xc merupakan input pada neuron ke-c, Wcr merupakan bobot antara neuron input ke-c menuju neuron output ke-r, dan br merupakan bias untuk neuron output ke-r.

#### 6. Softmax Activation

Softmax Activation adalah bentuk lain dari regresi logistik yang bekerja dalam proses klasifikasi tiga kelas atau lebih. Softmax digunakan untuk mengubah output dari lapisan terakhir menjadi distribusi probabilitas dasarnya.

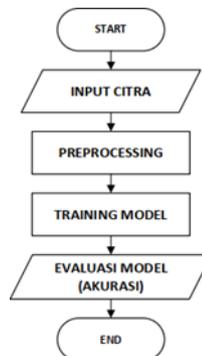
Di bawah ini adalah persamaan aktivasi softmax [19]:

$$fi(\vec{x}) = \frac{e^{xi}}{\sum_{j=1}^k e^{xj}} \quad (4)$$

Persamaan diatas ini terdapat notasi fi yang merupakan hasil fungsi setiap bagian ke-i pada keluaran kelas vektor. Sedangkan x merupakan vektor yang memiliki nilai dari hasil fully connected layer terakhir. Softmax dapat menghitung probabilitas dari semua kelas kemudian akan diambil vektor yang bernilai riil dan diubah kedalam nilai dengan rentang nol sampai dengan satu yang jika dijumlahkan semuanya akan bernilai satu [19].

## 2.2. Metode Penyelesaian Masalah

Dalam penelitian ini penulis menggunakan metode Convolutional Neural Network merupakan salah satu metode dari machine learning yang merupakan pengembangan dari Multi Layer Perceptron (MLP) untuk merancang dan mengolah atau membuat data dari dua dimensi. CNN juga merupakan salah satu jenis metode dari Deep Neural Network yang dikarenakan didalamnya memiliki tingkat jaringan dan mempunyai banyak penerapan yang dilakukan di dalam citra. Metode CNN terdiri dari dua metode yaitu klasifikasi yang menggunakan feedward dan tahap pembelajarannya menggunakan Framework Keras pada Google Collaboratory dan back-end Tensor Flow. Gambaran umum yang dilakukan dalam proses penelitian ini dijelaskan pada Gambar 7 berikut :



Gambar 7. Kerangka uji

Pada gambar 7 diatas merupakan tahapan awal yang dilakukan untuk input citra berupa dataset yang sudah dipersiapkan sebelumnya dan 2 bagian yaitu data train dan data test. Data gambar dalam penelitian ini diunduh dari web dengan menggunakan Data augmentasi, yang memiliki berbagai ukuran. Sejalan dengan itu, preprocessing gambar dilakukan agar mendapatkan gambar siap pakai untuk kemudian ditangani lebih lanjut, baik untuk kebutuhan ekstraksi maupun kebutuhan klasifikasi data.

Proses tersebut dilakukan menggunakan beberapa langkah preprocessing data augmentasi yang dapat dilakukan dalam klasifikasi menggunakan metode CNN.

Preprocessing merupakan tahapan yang dilakukan sebelum melatih atau menguji model dengan melakukan resizing, konversi citra RGB, dan ekstraksi fitur VGG16. Mengubah ukuran mengubah ukuran gambar yang digunakan untuk menyesuaikan gambar untuk pelatihan atau pengujian. Konversi gambar RGB mengubah gambar berwarna menjadi skala abu-abu. Ekstraksi ciri merupakan teknik pengenalan objek yang mengkaji karakteristik khusus suatu objek dengan tujuan melakukan perhitungan dan perbandingan untuk mengetahui karakteristik objek tersebut dan mengklasifikasikan gambar.

Pada Proses klasifikasi citra burung kenari dilakukan menggunakan 2 model yang berbeda. Pengujian pertama dilakukan dengan model Sequential yaitu membuat sebuah model pengujian yang sederhana dengan menentukan parameter secara acak guna untuk mendapatkan nilai akurasi yang maksimal. Kedua pengujian ini dilakukan model on top VGG16 dengan melakukan feature extraction VGG16 terlebih dahulu sebelum pengujian dilakukan. sering digunakan model ini dalam penelitian - penelitian sebelumnya karena memiliki akurasi yang cukup baik. Dengan mengevaluasi disetiap pengujian model sebelumnya,

maka akan didapat nilai accuracy dan nilai loss yang diperoleh dari setiap model pengujian. Dari sini kita dapat melihat kemungkinan kegagalan objek citra yang dibaca dalam proses klasifikasi. Dalam proses ini evaluasi juga akan didapatkan nilai akurasi final yang didapat dari keseluruhan model pengujian.

### 2.2.1. Dataset

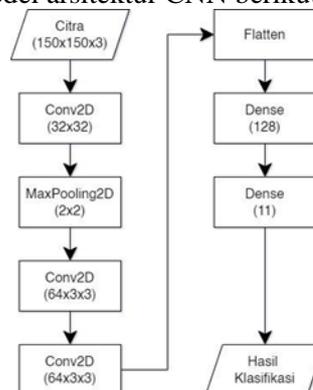
Dataset pengujian yang digunakan adalah data train dan 255 citra pada data test dengan 50 data test citra yang diambil menggunakan metode scraping dari berbagai sumber di internet yaitu google image dan situs: [https://www.kaggle.com/batoulmerhi/bird-speciesclassificationdenganmengunduh\(download\) gambar terkait dengan objek dalam penelitian ini](https://www.kaggle.com/batoulmerhi/bird-speciesclassificationdenganmengunduh(download) gambar terkait dengan objek dalam penelitian ini).

Tabel 1. Variabel Penelitian

Variabel	Train	test	Defenisi Variabel
Burung Kenari	255	50	Citra Berupa Gambar Burung Kenari 

### 2.2.2. Rancangan Pengujian

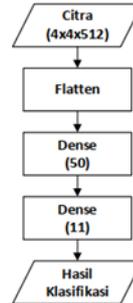
Penelitian ini digunakan 2 model arsitektur CNN berikut.



Gambar 8. Model sequential

Pada gambar 8 diatas merupakan flow model pengujian sequential. gambar diatas citra yang dimasukan berukuran 150x150x3 piksel dan dilakukan konversi ke grayscale kemudian dilakukan konvolusi menggunakan dua layer konvolusi jumlah filter masing-masing 32 dan 64 berukuran 3x3. Pada pooling layer menggunakan operasi max pooling dengan pooling max berukuran 2x2 nantinya setiap ukuran citra dibagi dua saat melewati proses ini. Proses flatten dapat digunakan

untuk merubah format citra 2d ke 1d dengan nilai yang sudah ditentukan 150x150x3 piksel. Kemudian kita gunakan dua dense layer, dengan layer pertama berfungsi sebagai activation ReLu (rectified linear unit) berukuran 128 neuron dan layer kedua Softmax sejumlah 5 neuron sesuai dengan jumlah kelas data yang diambil dari dataset.



Gambar 9. Model On Top VGG16

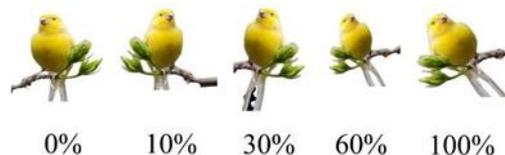
Diatas gambar 9 merupakan model ke 2 yang dalam proses klasifikasi dengan memanfaatkan salah satu feature extraction dari VGG16 dan pelatihan pada ImageNet. Setelah itu mendapat ekstraksi fitur dari VGG16 tahap pertama citra yang masukan berukuran 4x4x512 piksel. Selanjutnya akan melakukan proses flatten dari citra yang di input tersebut. Kemudian dua dense layer, dengan layer pertama sebagai activation ReLu (rectified linear unit) berukuran 50 neuron dan layer kedua Softmax sejumlah 5 neuron.

pustaka dilakukan dengan menggunakan penomoran sesuai urutan munculnya pustaka tersebut, misal sitasi buku [1], sitasi jurnal ilmiah [2]. Sitasi kepustakaan harus ada dalam Daftar Pustaka dan Daftar Pustaka harus ada sitasinya dalam naskah. Pustaka yang disitasi pertama kali pada naskah, harus ada pada daftar pustaka nomor satu, pustaka yang disitasi kedua yang muncul dalam naskah muncul sebagai daftar pustaka urutan kedua, berikut seterusnya.

### 3. HASIL DAN PEMBAHASAN

#### 3.1. Data Augmentasi

Dalam penelitian ini digunakan hasil gambar dari berbagai sumber di internet. Namun hasil yang diperoleh menunjukkan bahwa jumlah dataset yang terkumpul masih belum terlalu banyak. Oleh karena itu, untuk meningkatkan variasi citra, perlu diterapkan ekstensi data untuk mendapatkan dataset yang diinginkan. Sebelum diperbesar, gambar yang dihasilkan dipotong menjadi beberapa bagian. Bagian tersebut kemudian diskalakan menjadi 255 x 255 dan mengalami tiga jenis ekspansi data: rotasi acak, flip horizontal, dan noise acak. Proses ini akan menghasilkan kumpulan data yang diperluas secara acak pada 50:50 pada kumpulan data yang tidak diperluas. Pembahasan



Gambar 10. Hasil Augmentasi

Berdasarkan gambar 10 hasil augmentasi bisa diketahui bahwa hasil penerapan augmentasi adalah random rotation dan flip.

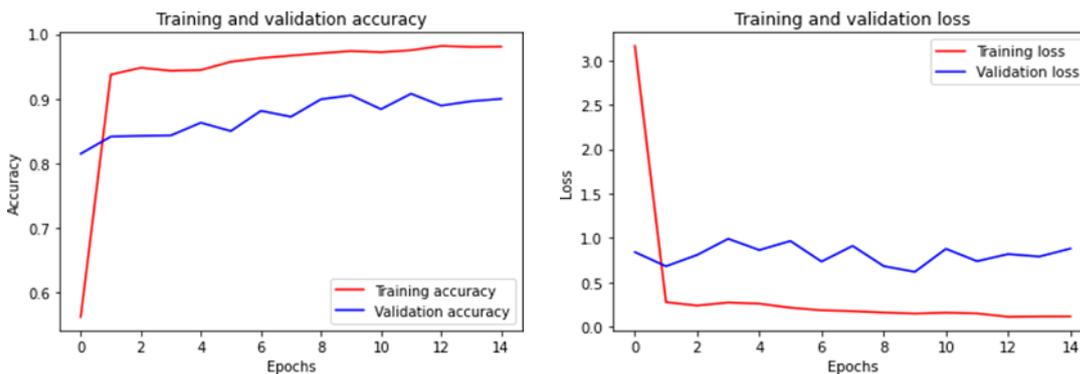
### 3.2. Model Sequential

Tabel 2. Hasil Fit Model Sequential

Epoch	Data Train		Data Validation	
	Loss	Accuracy	Loss	Accuracy
1	3.1655	0.5622	0.8397	0.8148
2	0.2748	0.9373	0.6801	0.8412
3	0.2364	0.9479	0.8076	0.8425
4	0.2707	0.9432	0.9899	0.8431
5	0.2579	0.9444	0.8627	0.8628
6	0.2118	0.9572	0.9653	0.8498
7	0.1833	0.9629	0.7329	0.8812
8	0.1730	0.9667	0.9096	0.8720
9	0.1575	0.9704	0.6815	0.8991
10	0.1461	0.9738	<b>0.6166</b>	0.9052
11	0.1558	0.9720	0.8771	0.8837
12	0.1475	0.9750	0.7368	<b>0.9077</b>
13	<b>0.1100</b>	<b>0.9816</b>	0.8172	0.8892
14	0.1139	0.9802	0.7893	0.8960
15	0.1146	0.9806	0.8789	0.8997

Tabel 2 merupakan hasil pelatihan dari data train/latih dan data validasi dengan menggunakan epoch sebanyak 15 kali. Dapat dilihat bahwa iterasi mendapatkan nilai accuracy dan nilai loss dari data train dan data validasi. Nilai accuracy merupakan nilai yang dapat dipakai sebagai acuan dalam mengetahui tingkat kesuksesan/kelayakan model yang sebelumnya dibuat dan nilai loss merupakan ukuran dari kegagalan/kesalahan yang dibuat networks yang bertujuan untuk meminimalisirnya.

Pada data train diperoleh nilai akurasi tertinggi sebesar 0.9816 pada epoch ke-13, sedangkan nilai loss terendah 0.1100 di epoch ke-13, kemudian pada data validasi diperoleh nilai akurasi tertinggi sebesar 0.9077 pada epoch ke-12 sedangkan nilai loss terendah 0.6166 di epoch ke-10. Dari hasil pelatihan data train dan data validasi tersebut bisa kita visualisasikan kedalam plot/grafik berikut ini :



Gambar 11. Plot Accuracy vs Loss Model Sequential

Gambar 11 diatas diketahui bahwa relasi antara nilai accuracy dan nilai loss pada data train dan data validasi dengan jumlah epoch/iterasi. Korelasi/hubungan terjadi pada nilai akurasi menunjukan bahwa korelasi positif yang memiliki hubungan satu arah dengan ketentuan semakin banyak jumlah epoch yang dilakukan maka nilai accuracy data train dan data validation semakin tinggi.

Sebaliknya sesuai dengan nilai accuracy, hubungan antara jumlah epoch dengan nilai loss merupakan korelasi negatif dimana banyaknya jumlah epoch yang akan digunakan mempengaruhi nilai loss yang dihasilkan pada pelatihan data semakin kecil. Mengingat hasil ini, kita dapat menyimpulkan bahwa meningkatkan jumlah epoch dalam proses pelatihan dapat mencapai pengurangan kerugian yang diharapkan. Dari hasil pelatihan model sequential diatas menghasilkan nilai evaluasi kinerja yang dihasilkan dari data test dengan nilai akurasi sebesar 98,40% dan nilai loss sebesar 0,092.

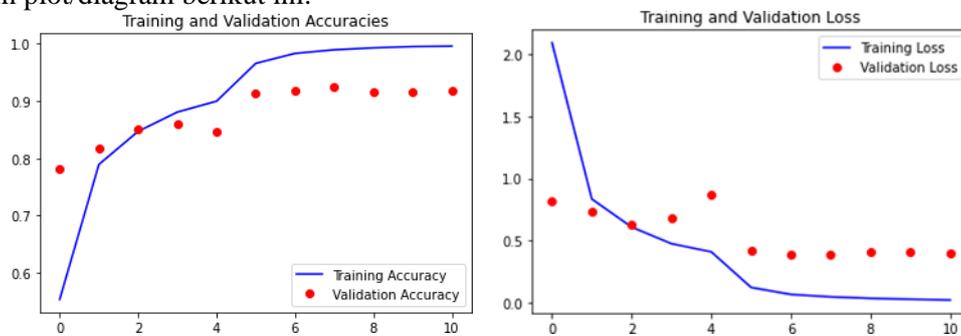
### 3.3. Model on top VGG16

Tabel 3. Hasil Fit Model on top VGG16

Epoch	Data Train		Data Validation	
	Loss	Accuracy	Loss	Accuracy
1	2.0951	0.5530	0.8177	0.7809
2	<b>0.8334</b>	0.7891	0.7373	0.8178
3	0.6070	0.8470	0.6322	0.8505
4	0.4731	0.8807	0.6766	0.8597
5	0.4073	0.8998	0.8661	0.8468
6	0.1202	0.9659	0.4155	0.9126
7	0.0635	0.9833	0.3907	0.9188
8	0.0441	0.9896	0.3879	0.9237
9	0.0323	0.9930	0.4021	0.9169
10	0.0245	0.9953	0.4021	0.9169
11	0.0189	0.9960	0.3972	0.9188

Tabel 3 diatas bisa kita dilihat hasil pengujian model kedua yaitu model on top VGG16 dengan jumlah epoch sebanyak 11 kali.

Dan data tersebut pada pengujian data train menghasilkan nilai akurasi tertinggi sebesar 0.9960 pada epoch ke-11 sedangkan nilai loss terendah 0.8334 di epoch ke-2, selanjutnya pada data validasi diperoleh nilai akurasi tertinggi sebesar 0.9237 pada epoch ke-8 sedangkan nilai loss terendah 0.8661 di epoch ke-5. Hasil data pengujian dari tabel diatas dapat kita visualisasikan kedalam plot/diagram berikut ini.



Gambar 12. Plot Accuracy vs Loss Model on top VGG16

Pada Gambar 12 di atas, terdapat hubungan antara nilai accuracy dan nilai loss data train validasi data dari jumlah iterasi model kedua.

Dapat melihat bahwa model kedua ini memiliki korelasi Nilai accuracy dalam arah yang sama dengan data bandingkan dengan data pelatihan/train atau validasi ada korelasi negatif dengan nilai loss. dari model on top VGG16 dalam pelatihan model teratas evaluasi kinerja yang dihasilkan oleh data pengujian nilai accuracy adalah 98,15% adalah nilai loss 0,032.

### 3.4. Evaluasi

Dapat dievaluasi dari hasil kedua model pengujian yaitu dengan model Sequential dan model on top VGG16 yang sudah dilatih menggunakan data train sebanyak 1.275 citra dan diperoleh nilai evaluasi yang dihasilkan dari data test sebanyak 30 citra dengan melakukan

pengujian sebanyak 15 kali untuk model sequential dan 11 kali model on top VGG16 , batch size=129, validation split=0.2 didapat nilai accuracy dan nilai loss sebagai berikut ini :

Tabel 4. Evaluasi Nilai Accuracy dan Nilai Loss

Model Sequential		Model On Top VGG16	
Accuracy	Loss	Accuracy	Loss
98,40%	0,092	98,15%	0,032

#### 4. KESIMPULAN

Setelah melakukan penelitian ini dan hasil dari penerapan implementasi metode Convolutional Neural Network (CNN), proses klasifikasi burung kenari , memiliki kesimpulan bahwa untuk dapat melewati proses preprocessing dengan baik ukuran citra dapat diubah dimensinya menjadi 150x150x3 piksel dan dikonversi warna citranya menjadi grayscale pada model Sequential, kemudian menggunakan feature extraction VGG16 yang dilatih di data augmentasi dengan ukuran dimensi 4x4x512 piksel pada on top VGG16. Akurasi yang dihasilkan akan semakin baik apabila digunakan data train yang semakin banyak.

Hal tersebut dibuktikan dengan pengujian pada jumlah data training sebanyak 80% dan data validasi sebanyak 20% pada setiap model pengujian. Dengan melakukan evaluasi pengujian model Sequential dengan epoch sebanyak 15 kali dan model on top VGG16 dengan epoch sebanyak 10 kali, batch size=129, dan validation split=0,2 (80% training dan 20% validasi) diperoleh nilai accuracy dan nilai loss model berdasarkan data test sebesar 98,40% nilai accuracy dan 0,092 nilai loss pada model Sequential serta 98,15% nilai accuracy dan 0,032 nilai loss pada model on top VGG16.

#### DAFTAR PUSTAKA

- [1] A. M. Akhrom, I. Soedarmanto, Y. Yanuartono, T. Susmiati, A. Nururrozi, and S. Raharjo, "PENENTUAN JENIS KELAMIN BURUNG KENARI (<em>Serinus canaria</em>) BERDASARKAN GEN <em>Chromodomain Helicase DNA-Binding 1 (CHD1)</em>," J. Bioteknol. Biosains Indones., vol. 7, no. 1, pp. 1–8, 2020, doi: 10.29122/jbbi.v7i1.3178.
- [2] Mudawamah, Armada, Puspitarini, and O. Rahayu, "Perbandingan Ukuran Tubuh Pada Berbagai Warna Bulu Dan Nukleotida Gen Tyrosinase (TYR) Burung Kenari (Serinus canaria) Dan Burung Merpati (Columba livia domestica)," J. Rekasatwa Peternak., vol. 01, no. 01, pp. 71–76, 2019, [Online]. Available: <http://kelincikenari.com/wp-content/uploads/2019/03/armada2166-5739-1- PB.pdf>.
- [3] V. M. P. Salawazo, D. P. J. Gea, R. F. Gea, and F. Azmi, "Implementasi Metode Convolutional Neural Network ( CNN ) Pada Penegagalan Objek Video CCTV," J. Mantik Penusa, vol. 3, no. 1, pp. 74–79, 2019.
- [4] M. Resa, A. Yudianto, and H. Al Fatta, "Analisis Pengaruh Tingkat Akurasi Klasifikasi Citra Wayang dengan Algoritma Convolutional Neural Network," J. Teknol. Inf., vol. 4, no. 2, pp. 182–190, 2020.

- [5] W. S. Eka Putra, "Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101," *J. Tek. ITS*, vol. 5, no. 1, 2016, doi: 10.12962/j23373539.v5i1.15696.
- [6] S. E. Limantoro, Y. Kristian, and D. D. Purwanto, "Pemanfaatan Deep Learning pada Video Dash Cam untuk Deteksi Pengendara Sepeda Motor," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 7, no. 2, pp. 3–9, 2018, doi: 10.22146/jnteti.v7i2.419.
- [7] N. Hanum Harani, C. Prianto, and M. Hasanah, "Deteksi Objek Dan Pengenalan Karakter Plat Nomor Kendaraan Indonesia Menggunakan Metode Convolutional Neural Network (CNN) Berbasis Python," *J. Tek. Inform.*, vol. 11, no. 3, pp. 47–53, 2019.
- [8] H. Shim et al., "IMPLEMENTASI CONVOLUTION NEURAL NETWORK (CNN) UNTUK KLASIFIKASI JAMUR KONSUMSI DI INDONESIA MENGGUNAKAN KERAS," *Adv. Opt. Mater.*, vol. 10, no. 1, pp. 1–9, 2018, [Online]. Available: <https://doi.org/10.1103/PhysRevB.101.089902><http://dx.doi.org/10.1016/j.nantod.2015.04.009><http://dx.doi.org/10.1038/s41467-018-05514-9><http://dx.doi.org/10.1038/s41467-019-13856-1><http://dx.doi.org/10.1038/s41467-020-14365-2><http://dx.doi.org/10.1038/s41467-020-14365-2>
- [9] J. F. Fauzi, H. Tolle, and R. K. Dewi, "Tampilan Implementasi Metode RGB To HSV pada Aplikasi Pengenalan Mata Uang Kertas Berbasis Android untuk Tuna Netra," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 6, pp. 2319–2325, 2018, [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/1594/577>.
- [10] I. Yusuf and S. W. Widyaningsih, "Implementasi Pembelajaran Fisika Berbasis Laboratorium Virtual terhadap Keterampilan Proses Sains dan Persepsi Mahasiswa," *Berk. Ilm. Pendidik. Fis.*, vol. 6, no. 1, p. 18, 2018, doi: 10.20527/bipf.v6i1.4378.
- [11] H. Fonda, "Klasifikasi Batik Riau Dengan Menggunakan Convolutional Neural Networks (Cnn)," *J. Ilmu Komput.*, vol. 9, no. 1, pp. 7–10, 2020, doi: 10.33060/jik/2020/vol9.iss1.144.
- [12] A. Peryanto, A. Yudhana, and R. Umar, "Rancang Bangun Klasifikasi Citra Dengan Teknologi Deep Learning Berbasis Metode Convolutional Neural Network," *Format J. Ilm. Tek. Inform.*, vol. 8, no. 2, p. 138, 2020, doi: 10.22441/format.2019.v8.i2.007.
- [13] S. Riyadi and D. I. Mulyana, "Optimasi Image Classification pada Wayang Kulit Dengan Convolutional Neural Network," pp. 1–8, 1850.
- [14] F. C. Kartika Wisnudhanti, "Metode Convolutional Neural Network Dalam Klasifikasi Citra Tiga Tokoh Wayang Pandawa," vol. 7, no. 2018, pp. 1–5, 2020.
- [15] S. Ilahiyah and A. Nilogiri, "Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network," *JUSTINDO (Jurnal Sist. dan Teknol. Inf. Indones.)*, vol. 3, no. 2, pp. 49–56, 2018.

- [16] F. I. Kurniadi, "Klasifikasi Topeng Cirebon menggunakan Metode Convolutional Neural Network," *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 8, no. 1, pp. 163–169, 2021, doi: 10.35957/jatisi.v8i1.568.
- [17] C. Y. Lee, P. W. Gallagher, and Z. Tu, "Generalizing pooling functions in convolutional neural networks: Mixed, gated, and tree," *Proc. 19th Int. Conf. Artif. Intell. Stat. AISTATS 2016*, vol. 51, pp. 464–472, 2016.
- [18] D. C. Khrisne and T. Hendrawati, "Indonesian Alphabet Speech Recognition for Early Literacy using Convolutional Neural Network Approach," *J. Electr. Electron. Informatics*, vol. 4, no. 1, p. 34, 2020, doi: 10.24843/jeei.2020.v04.i01.p06.
- [19] M. A. Hanin, R. Patmasari, and R. Y. Nur, "Sistem Klasifikasi Penyakit Kulit Menggunakan Convolutional Neural Network ( Cnn ) Skin Disease Classification System Using Convolutional Neural Network ( Cnn )," *e- Proceeding Eng.*, vol. 8, no. 1, pp. 273–281, 2021.