

# Analisa Performa Convolutional Neural Network dalam Klasifikasi Citra Apel dengan Data Augmentasi

Dzalfa Tsalsabila Rhamadiyanti\*, Kusriani

Magister Teknik Informatika, Universitas Amikom Yogyakarta, Yogyakarta, Indonesia

Email: <sup>1</sup>\*dzalfats@students.amikom.ac.id, <sup>2</sup>kusriani@amikom.ac.id

Email Penulis Korespondensi: dzalfats@students.amikom.ac.id

**Abstrak**—Augmentasi adalah proses pembuatan sampel baru dari dataset asli dengan menerapkan transformasi acak kecil pada dataset asli, tetapi tetap mempertahankan labelnya. Penelitian ini menerapkan Data Augmentasi pada model *Convolutional Neural Network* untuk klasifikasi citra apel. Citra apel yang digunakan adalah apel *Braeburn* yang memiliki warna kulit oranye hingga merah dengan latar belakang kuning, apel *Crimson Snow* yang berkulit merah, dan apel *pink lady* dengan warna kulit merah muda yang cerah serta memiliki rona kuning dan hijau. Citra apel yang digunakan berjumlah 675 gambar terbagi menjadi 3 kelas yang masing-masing berjumlah 225 gambar. Terdapat 4 teknik augmentasi yang diterapkan yaitu *flipping*, *cropping*, *rotation*, dan *noise injection*. Penelitian ini melakukan 6 skenario yaitu tanpa augmentasi, dengan menerapkan masing-masing teknik augmentasi secara terpisah dan kombinasi antara dua teknik augmentasi yang menghasilkan nilai akurasi tertinggi. Dari keenam skenario tersebut didapatkan bahwa teknik augmentasi yang menghasilkan nilai akurasi terbaik adalah *noise injection* yaitu sebesar 98,82% lalu diikuti oleh *flipping* dengan akurasi sebesar 72,78%, selanjutnya *rotation* dengan nilai akurasi sebesar 68,64% dan teknik augmentasi yang menghasilkan nilai akurasi terendah adalah *cropping* yaitu 67,46%. Kedua teknik augmentasi terbaik yaitu *noise injection* dan *flipping* dikombinasikan dan menghasilkan nilai akurasi sebesar 84,02%. Nilai akurasi yang didapatkan oleh kombinasi ini tidak maksimal dikarenakan efek dari *noise injection* yang bisa saja terhapus oleh perubahan orientasi yang konsisten dari *flipping*. Sehingga menyebabkan model kesulitan dalam mempelajari fitur-fitur yang konsisten. Penelitian selanjutnya diharapkan dapat memaksimalkan efektivitas teknik augmentasi dengan memilih teknik augmentasi yang saling melengkapi dan sesuai dengan karakteristik dari data yang diolah.

**Kata Kunci:** Augmentasi; Convolutional Neural Network; Cropping; Flipping; Noise Injection; Rotation

**Abstract**—Augmentation is creating new samples from an original dataset by applying small random transformations to the original dataset but retaining its labels. This research applies Data Augmentation to the Convolutional Neural Network model for apple image classification. The apple images used are Braeburn apples which have orange to red skin with a yellow background, Crimson Snow apples which have red skin, and Pink Lady apples with bright pink skin and yellow and green hues. There are 675 apple images used, divided into three classes, each with 225 photos. Four augmentation techniques are applied, namely flipping, cropping, rotation, and noise injection. This research carried out six scenarios, namely without augmentation, using each augmentation technique separately and combining two augmentation techniques, which produced the highest accuracy values. From the six scenarios, it was found that the augmentation technique that produced the best accuracy value was noise injection, namely 98.82%, followed by flipping with an accuracy of 72.78%, then rotation with an accuracy value of 68.64% and an augmentation technique that produced an accuracy value. The lowest is cropping, namely 67.46%. The two best augmentation techniques, noise injection, and flipping, were combined and produced an accuracy value of 84.02%. The accuracy value obtained by this combination could be more optimal due to the effect of noise injection, which can erase consistent changes in orientation from flipping. This needs to be improved so that the model can learn consistent features. It is hoped that future research can maximize the effectiveness of augmentation techniques by choosing augmentation techniques that complement each other and suit the characteristics of the data being processed.

**Keywords:** Augmentation; Convolutional Neural Network; Cropping; Flipping; Noise Injection; Rotation

## 1. PENDAHULUAN

Apel adalah salah satu buah yang berasal dari Asia Tengah, apel dapat beradaptasi dengan baik karena mampu tumbuh di iklim tropis dan merupakan salah satu buah terkenal di Jepang dan China [1], [2]. Apel dikenal sebagai buah dengan jenis yang beragam, dimana masing-masing jenis Apel menyuguhkan karakteristik unik yang menciptakan rasa yang berbeda bagi konsumen. Berbagai varietas apel dapat ditemui di seluruh dunia, seperti apel *pink lady* yang memiliki kulit berwarna merah pseudo pink, apel *crimson snow* yang ditandai dengan kulit berwarna merah tua, apel *braeburn* yang menunjukkan variasi warna kulit dari oranye hingga merah, bahkan di atas lapisan kuning, serta apel *rome beauty* yang mengkilap dengan warna merahnya yang mencolok [3]. Selain itu, terdapat berbagai jenis apel lain yang dapat ditemui dengan karakteristik yang unik.

Membedakan jenis apel hanya dari warna kulitnya seringkali menjadi tugas yang sulit dan membingungkan bagi manusia. Sebagai contoh, apel *braeburn* dan *crimson snow* memiliki warna kemerahan yang mirip, sementara tekstur dan rasa keduanya dapat berbeda secara signifikan. Hal ini menciptakan tantangan bagi konsumen yang hanya mengandalkan mata untuk membuat keputusan pembelian yang tepat. Pengembangan sistem pengenalan citra pada buah apel dapat membantu mengatasi kesulitan ini, memastikan bahwa konsumen dapat dengan mudah dan akurat mengidentifikasi jenis apel yang sesuai dengan preferensi mereka.

Pengenalan citra merupakan bidang yang berkembang pesat dalam dunia *computer vision* dan *machine learning*. Pengenalan citra sering dilakukan dengan berbagai macam algoritma machine learning seperti *K-Nearest Neighbors (KNN)*, *Support Vector Machine (SVM)*, dan *Convolutional Neural Network (CNN)*. *Convolutional Neural Network* menjadi salah satu algoritma yang paling penting di bidang *machine learning*. CNN telah mencapai prestasi yang mengesankan di berbagai bidang seperti *computer vision* [4].

CNN sering menghadapi masalah ketika proses training sedang berlangsung. Masalah ini biasa disebut dengan *overfitting*, dimana model dapat mempelajari data *training* dengan baik tetapi tidak bekerja dengan baik pada data baru atau data testing [5]. Selain *overfitting*, ada juga yang disebut sebagai *underfitting*, dimana model sudah tidak mampu lagi dalam menangkap variasi data. Salah satu teknik yang dapat mengatasi kedua masalah ini adalah data augmentasi.

Data Augmentasi adalah metode yang efektif untuk mengurangi *overfitting* pada model CNN yang disebabkan oleh data sampel yang terbatas. Teknik ini bekerja dengan memperkirakan ruang probabilitas data dengan memanipulasi sampel input [6]. Data augmentasi bermanfaat untuk membangun model *Deep Learning* yang baik, dimana error validasi harus terus berkurang seiring dengan error training. Terdapat banyak jenis data augmentasi, seperti *flipping* yaitu melakukan *flip* horizontal atau vertical pada gambar, *rotation* yaitu memutar gambar ke kanan atau kiri pada sumbu 1 dan 359, *Noise Injection* yaitu menyuntikkan matriks nilai acak yang biasanya diambil dari distribusi *Gaussian* dan juga *Cropping* yaitu memotong bagian tengah setiap gambar [7]. Data augmentasi biasa digunakan untuk meningkatkan nilai akurasi dari program yang dirancang.

Terdapat beberapa penelitian yang telah dilakukan untuk klasifikasi dengan *machine learning* dan data augmentasi. Rangkuman mengenai penelitian tersebut dapat dilihat di bawah ini.

Penelitian Phiphiphatphaisit & Surinta [8], dengan menerapkan berbagai teknik data augmentasi dan menggabungkannya dengan proses *cropping* sebelum training model dengan menggunakan arsitektur *MobileNet*, dapat meningkatkan nilai akurasi sekitar 5%, sehingga model yang dibangun lebih unggul daripada arsitektur-arsitektur lain. Maka dari itu penelitian ini dapat dilanjutkan dengan menerapkan arsitektur *MobileNet* dengan jumlah dataset yang sama dengan *state-of-the-art* lain. Secara umum, penelitian ini meningkatkan pemahaman tentang penggunaan teknik augmentasi data yang kompleks dalam konteks arsitektur *MobileNet*.

Menurut penelitian Satila Passa, dkk [9], data augmentasi berhasil meningkatkan nilai presisi arsitektur *YOLOv8* dari 92,6% (tanpa augmentasi) menjadi 94,2. Hal ini menunjukkan bahwa kombinasi antara arsitektur *YOLOv8* dan teknik augmentasi data dapat meningkatkan kinerja arsitektur itu sendiri, serta meningkatkan kemampuannya dalam mengatasi variasi tumor yang beragam dan kondisi pengambilan gambar yang beragam.

Penelitian Dewantara, dkk [10], dengan menerapkan 2 tahap augmentasi pada dataset yang digunakan untuk training menggunakan arsitektur *ResNet* dengan *transfer learning*, dapat meningkatkan nilai akurasi. Dengan hanya menerapkan tahap augmentasi pertama yaitu *Geometric Transformation* (GT) seperti *flipping*, *rotation*, *translation*, dan *scaling* memberikan nilai akurasi tertinggi sebesar 99,19% pada epoch ke-15. Sedangkan dengan menerapkan tahap augmentasi pertama dan kedua yaitu *Distortion Injection* (DI) seperti *Brightness*, *Random Eraser*, dan *Noise Injection* memberikan nilai akurasi tertinggi pada epoch ke-5 yaitu 99,07%. Hal ini membuktikan bahwa penerapan data augmentasi secara bertahap dapat meningkatkan ukuran dataset dan nilai akurasi klasifikasi.

Penelitian Chun, dkk [11], yang berfokus terhadap evaluasi efektivitas kombinasi teknik augmentasi yang diterapkan terhadap beberapa arsitektur CNN, membuktikan bahwa arsitektur *ResNet50* dapat mencapai nilai akurasi terbaik jika dikombinasikan dengan teknik data augmentasi dan *transfer learning*. Hal ini terbukti dengan adanya penelitian selanjutnya dari Poojary, dkk [12], yang membuktikan bahwa arsitektur *ResNet50* dikombinasikan dengan data augmentasi dapat mendapatkan nilai akurasi yang lebih tinggi daripada arsitektur lain.

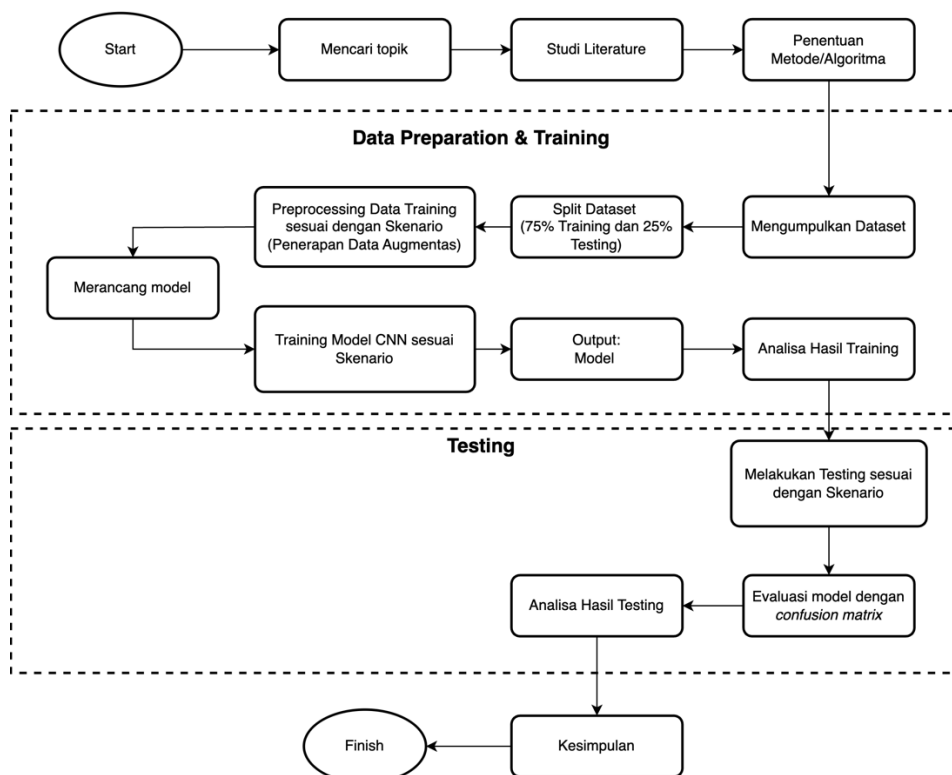
Penelitian terkait ketahanan algoritma CNN pernah dilakukan oleh Rhamadiyanti & Suyanto [3]. Penelitian ini melakukan proses training dengan menambahkan *noise* sebesar 10% hingga 50% pada dataset. Hal ini menyebabkan penurunan nilai akurasi yang signifikan seiring dengan penambahan *noise* tersebut. Dari hal ini dapat disimpulkan bahwa nilai akurasi dapat menurun dikarenakan dataset yang berjumlah terbatas sehingga model CNN kesulitan dalam mencocokkan tekstur yang tertutupi bintik-bintik *noise* yang ditambahkan pada proses preprocessing.

Paper ini akan menggunakan 3 kelas dataset yaitu apel *braeburn*, apel *crimson snow*, dan apel *pink lady*. Dataset ini dipilih untuk melihat variasi klasifikasi antara jenis apel yang berbeda berdasarkan karakteristik visual masing-masing. Tujuan utama paper ini adalah untuk mengevaluasi dan menganalisis efek dari penggunaan teknik data augmentasi dalam meningkatkan performa klasifikasi citra dengan menggunakan algoritma *Convolutional Neural Network*. Data augmentasi akan diterapkan pada dataset untuk menciptakan variasi tambahan dalam data latih yang bertujuan untuk meningkatkan kemampuan model dalam mengenali membedakan antara ketiga jenis apel tersebut. Dengan menggunakan CNN, penelitian ini akan mengukur sejauh mana teknik augmentasi data dapat meningkatkan akurasi dan efisiensi model klasifikasi citra. Hasil dari penelitian ini diharapkan dapat memberikan wawasan yang lebih mendalam mengenai efektivitas augmentasi data dalam konteks klasifikasi citra dengan menggunakan algoritma *Convolutional Neural Network*.

## 2. METODOLOGI PENELITIAN

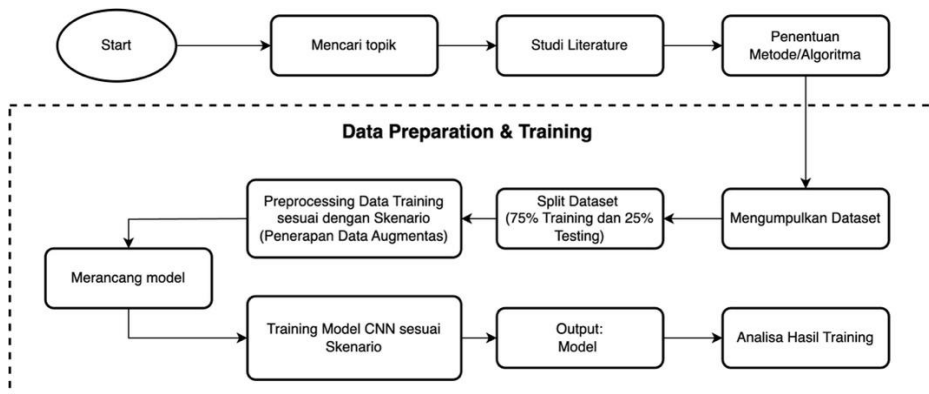
### 2.1 Alur Penelitian

Keseluruhan alur penelitian yang dilakukan dapat dilihat pada Gambar 1.



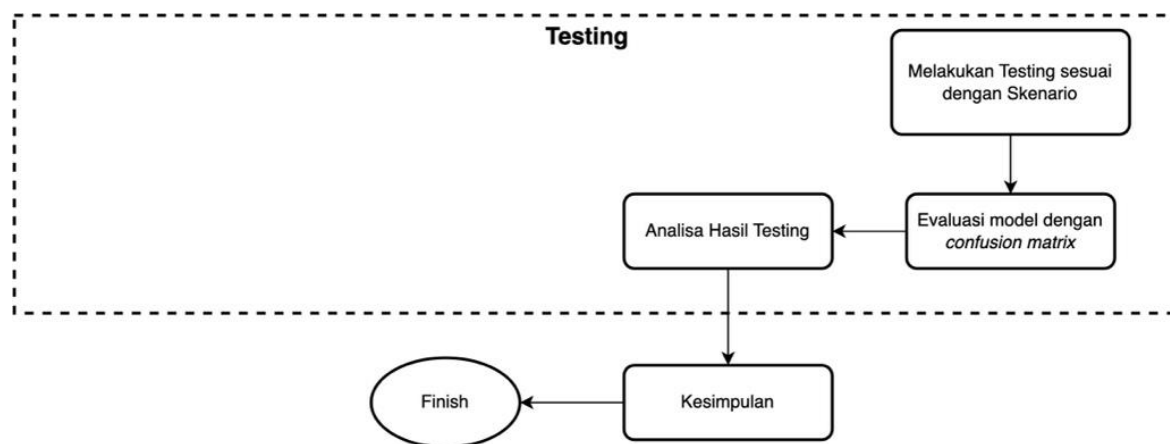
Gambar 1. Alur Penelitian

Penelitian ini melakukan beberapa rangkaian, terdiri dari dua rangkaian besar yaitu data preparation serta training dan testing. Pada tahap awal, dilakukan studi literatur untuk mencari pengetahuan dan konsep yang relevan dalam bidang klasifikasi citra. Studi literatur ini penting untuk memahami perkembangan terbaru dan menemukan solusi yang telah diuji dalam penelitian sebelumnya. Setelah mendapatkan pengetahuan serta konsep terkait dengan klasifikasi citra, akan dilakukan pencarian metode atau algoritma yang cocok dengan tujuan penelitian. Penentuan algoritma yang tepat sangat penting karena akan mempengaruhi hasil akhir dari klasifikasi citra yang dilakukan. Setelah menentukan algoritma yang akan digunakan, selanjutnya adalah tahap pengumpulan dataset yang dibutuhkan. Dataset yang digunakan pada penelitian ini adalah dataset public yang dapat ditemukan di website Kaggle yang bernama Fruit-360 [13]. Dataset ini dipilih karena memiliki variasi citra yang cukup untuk melatih model dan mencakup berbagai jenis buah, termasuk apel yang menjadi fokus penelitian. Dataset akan dijelaskan lebih lanjut pada bagian 2.2. Langkah selanjutnya adalah melakukan preprocessing data. Preprocessing adalah proses menyiapkan data mentah untuk diproses lebih lanjut. Hal ini mencakup penghapusan data yang tidak dibutuhkan, mengubah ukuran data, dan menerapkan teknik augmentasi data untuk mempermudah proses klasifikasi [14]. Teknik augmentasi seperti flipping, cropping, rotation, dan noise injection digunakan untuk memperkaya variasi data latih, sehingga model dapat belajar dari lebih banyak contoh dan meningkatkan akurasi. Setelah preprocessing dilakukan, tahap selanjutnya adalah merancang model CNN untuk melakukan proses training sesuai dengan skenario yang diajukan. Model CNN dirancang dengan berbagai layer yang telah disesuaikan untuk mengoptimalkan pengenalan pola pada dataset apel. Output dari langkah ini berupa akurasi dari model yang telah dilatih. Dari output tersebut akan dilakukan analisa terkait pengaruh penerapan data augmentasi terhadap data yang digunakan. Analisa ini bertujuan untuk mengevaluasi seberapa efektif teknik augmentasi dalam meningkatkan kinerja model pada tugas klasifikasi citra apel. Rangkaian besar pertama dapat dilihat pada Gambar 2.



Gambar 2. Rangkaian Data Preparation & Training


Setelah *training* dilakukan dan model telah didapatkan, rangkaian selanjutnya dapat dilihat pada Gambar 3 yaitu Rangkaian *testing*. Proses *testing* ini penting untuk mengetahui seberapa baik model yang telah dilatih dapat menggeneralisasi data yang belum pernah dilihat sebelumnya. Proses *testing* akan dilakukan sejumlah skenario yang diajukan, yang mencakup berbagai teknik augmentasi. Setelah *testing* selesai, akan dilakukan proses evaluasi dengan menggunakan metode *confusion matrix*. *Confusion matrix* adalah salah satu metode evaluasi performa model yang telah dibuat yang biasa digunakan pada model klasifikasi multi-kelas dengan label tunggal [15], yang memberikan gambaran detail tentang prediksi yang benar dan salah untuk setiap kelas. Dengan menggunakan *confusion matrix*, dapat dilihat secara jelas bagaimana model melakukan prediksi pada setiap kelas, termasuk identifikasi kesalahan yang sering terjadi. Langkah terakhir adalah melakukan analisa dari hasil *testing* tersebut. Analisa ini mencakup perbandingan kinerja model berdasarkan berbagai metrik evaluasi seperti akurasi, presisi, *recall*, dan *F1-score*. Proses *testing* akan menentukan skenario terbaik dari beberapa skenario yang diajukan pada penelitian ini, membantu untuk mengidentifikasi teknik augmentasi yang memberikan hasil paling optimal. Evaluasi yang komprehensif ini memastikan bahwa model yang dihasilkan tidak hanya memiliki akurasi tinggi, tetapi juga konsisten dan dapat diandalkan untuk tugas klasifikasi citra apel dalam berbagai kondisi. Hasil analisa ini akan memberikan wawasan berharga tentang efektivitas teknik augmentasi dan konfigurasi model dalam meningkatkan kinerja klasifikasi citra.



Gambar 3. Rangkaian Testing

## 2.2 Dataset

Dataset yang digunakan pada penelitian ini adalah citra apel yang dibagi menjadi tiga kelas sesuai dengan warna kulitnya yang mirip, yaitu apel *Braeburn*, apel *Crimson Snow*, dan apel *Pink Lady*. Apel *Braeburn* memiliki karakteristik warna kulit yang bervariasi dari merah hingga kuning-oranye, seperti yang dapat dilihat pada Gambar 2 (a). Apel *Crimson Snow*, di sisi lain, menampilkan kulit merah cerah yang terkadang disertai dengan semburat putih, terlihat pada Gambar 2 (b). Sementara itu, apel *Pink Lady* memiliki kulit merah muda dengan *undertone* hijau atau kuning, seperti yang ditunjukkan pada Gambar 2 (c). Dataset ini merupakan bagian dari dataset yang lebih luas bernama "*Fruit 360*" yang diunggah oleh Mihai Oltean di website Kaggle [13]. Setiap gambar dalam dataset telah dilabeli dengan benar, sehingga memudahkan proses *training* dan evaluasi model.



Gambar 4. Citra apel (a) Braeburn, (b) Crimson Snow, (c) Pink Lady

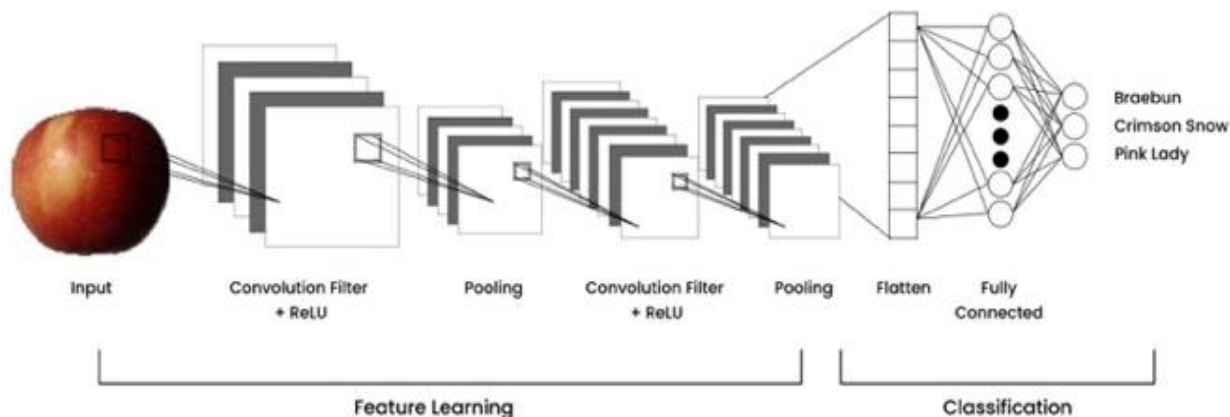
Kelas apel yang digunakan pada penelitian ini adalah apel *Braeburn* yang merupakan salah satu varietas apel komersial terpenting yang berasal dari Selandia Baru dengan warna kulit dari oranye hingga merah dengan latar belakang kuning [16], apel *crimson snow* yang berasal dari Australia yang memiliki warna kulit merah, serta apel *pink lady* yang berasal dari Australia Barat dengan warna kulit merah muda yang cerah serta memiliki rona kuning dan hijau. Total dataset yang digunakan pada penelitian ini sebanyak 675 gambar, yang mencakup ketiga jenis apel tersebut. Dataset ini kemudian akan dibagi menjadi data *training* sebesar 75% dan data *testing* sebesar 25%. Detail distribusi dataset per kelas dapat dilihat pada Tabel 1, yang menunjukkan jumlah gambar dari setiap jenis apel dalam set *training* dan *testing*. Pembagian dataset ini dirancang untuk memastikan bahwa setiap kelas terwakili dengan baik dalam proses *training* dan *testing*, memungkinkan model untuk mempelajari fitur-fitur spesifik dari masing-masing jenis apel dan mengklasifikasikannya dengan akurasi tinggi.

Tabel 1. Detail Dataset

Kelas	Train	Test	Total
Braeburn	168	57	225
Crimson Snow	168	57	225
Pink Lady	168	57	225
<b>Total</b>	<b>504</b>	<b>171</b>	<b>675</b>

### 2.3 Convolutional Neural Network

Pada penelitian ini, klasifikasi akan dilakukan dengan menggunakan algoritma *Convolutional Neural Network (CNN)*. Model akan dilatih untuk mengklasifikasikan 3 tipe apel yaitu apel *Braeburn*, apel *Crimson Snow*, dan apel *Pink Lady*. Pada penelitian ini, model CNN yang digunakan adalah model yang dikembangkan secara mandiri untuk tujuan klasifikasi citra. Model CNN ini terdiri dari 3 *convolution layers* yang bekerja mengambil inputan sampel dan mengekstraksi fitur-fitur menggunakan serangkaian filter yang dipelajari [17], yang digunakan untuk mengekstraksi fitur dari data citra untuk menghasilkan output berupa *feature map*, serta 3 *pooling layer* yang bertujuan untuk mereduksi dimensi data hasil *convolution* [18]. Selain itu, CNN menggunakan *hidden layer* yang dikenal sebagai *fully connected layer* yang menghubungkan hasil-hasil ekstraksi fitur ke dalam proses akhir klasifikasi yang menghasilkan output yang memprediksi kelas dari dataset yang diberikan [19]. Pada tahap akhir, fungsi aktivasi softmax digunakan untuk menghasilkan probabilitas dari setiap kelas, sehingga model dapat menentukan kelas mana yang paling mungkin untuk setiap gambar [20]. Arsitektur model CNN dapat dilihat pada Gambar 5.



Gambar 5. Arsitektur CNN

Dalam penelitian ini, model CNN dikonfigurasi dengan *convolution layers* yang terdiri dari 32, 64, dan 128 unit masing-masing dengan ukuran kernel 3x3 dan fungsi aktivasi ReLU untuk mengaktifkan pembelajaran non-linear dalam jaringan. Lalu diterapkan *max pooling* dengan ukuran pool 2x2 setelah masing-masing *convolution layers* untuk mempertahankan fitur penting sembari mengurangi komputasi yang diperlukan. *Layer dense* pertama memiliki 8 node yang diikuti oleh lapisan dropout dengan dropout rate sebesar 0,5 untuk mencegah overfitting. *Layer dense* terakhir memiliki 3 node yang diaktifkan dengan *softmax activation* untuk menghasilkan probabilitas kelas output dari dataset yang terdiri dari 3 kelas. Konfigurasi ini dirancang untuk mengoptimalkan pengenalan pola gambar dalam kelas dataset yang kompleks. Kesimpulan model CNN yang digunakan dapat dilihat pada Gambar 6.

Model: "sequential\_8"

Layer (type)	Output Shape	Param #
conv2d_24 (Conv2D)	(None, 148, 148, 32)	896
activation_40 (Activation)	(None, 148, 148, 32)	0
max_pooling2d_24 (MaxPooling2D)	(None, 74, 74, 32)	0
conv2d_25 (Conv2D)	(None, 72, 72, 64)	18496
activation_41 (Activation)	(None, 72, 72, 64)	0
max_pooling2d_25 (MaxPooling2D)	(None, 36, 36, 64)	0
conv2d_26 (Conv2D)	(None, 34, 34, 128)	73856
activation_42 (Activation)	(None, 34, 34, 128)	0
max_pooling2d_26 (MaxPooling2D)	(None, 17, 17, 128)	0
flatten_8 (Flatten)	(None, 36992)	0
dense_16 (Dense)	(None, 8)	295944
activation_43 (Activation)	(None, 8)	0
dropout_8 (Dropout)	(None, 8)	0
dense_17 (Dense)	(None, 3)	27
activation_44 (Activation)	(None, 3)	0

=====  
 Total params: 389219 (1.48 MB)  
 Trainable params: 389219 (1.48 MB)  
 Non-trainable params: 0 (0.00 Byte)

Gambar 6. Model CNN

## 2.4 Data Augmentasi

Penelitian ini menggunakan 4 teknik augmentasi yang yaitu *flipping*, *rotation*, *cropping*, dan *noise injection*. Data Augmentasi adalah metode yang efektif untuk mengurangi overfitting pada model CNN yang disebabkan oleh data sampel yang terbatas. Teknik ini bekerja dengan memperkirakan ruang probabilitas data dengan memanipulasi sampel input [6]. Penelitian ini menerapkan empat teknik augmentasi untuk meningkatkan performa model klasifikasi citra apel, yaitu *flipping*, *rotation*, *cropping*, dan *noise injection*.

*Flipping* adalah teknik augmentasi yang membalikkan gambar secara horizontal dan vertikal, sehingga menghasilkan variasi orientasi gambar yang dapat membantu model belajar untuk mengenali objek dari sudut pandang yang berbeda. Teknik ini meningkatkan keberagaman data pelatihan dengan menciptakan versi gambar yang berbeda, namun tetap mempertahankan label yang sama. Ilustrasi *flipping* dapat dilihat pada Gambar 7 (a) sebelum *flipping*; (b) setelah *flipping*.



Gambar 7. Flipping

*Rotation* melibatkan pemutaran gambar pada sumbu tertentu, memungkinkan model untuk mengatasi variasi sudut pandang dan orientasi objek dalam gambar. Ini membantu model menjadi lebih *robust* terhadap perubahan posisi objek dalam citra. Ilustrasi *rotation* dapat dilihat pada Gambar 8 (a) sebelum *rotation*; (b) setelah *rotation*.



Gambar 8. Rotation

*Cropping* dilakukan dengan memotong bagian tengah gambar atau area tertentu, yang bertujuan untuk mensimulasikan variasi dalam komposisi gambar dan memastikan model dapat mengenali objek meskipun hanya sebagian dari gambar yang terlihat. Ilustrasi *cropping* dapat dilihat pada Gambar 9 (a) sebelum *cropping*; (b) setelah *cropping*.



Gambar 9. Cropping

*Noise Injection* adalah teknik yang menambahkan gangguan pada gambar untuk mensimulasikan kondisi nyata yang mungkin mengganggu kualitas gambar. Pada penelitian ini, *Gaussian blur* digunakan dengan tingkat 10% untuk menambahkan efek kabur pada gambar, yang bertujuan untuk meningkatkan ketahanan model terhadap *noise* dan variasi visual yang tidak terduga. Ilustrasi *noise injection* dapat dilihat pada Gambar 10 (a) sebelum *noise injection*; (b) setelah *noise injection*.



Gambar 10. Noise Injection

Setiap teknik augmentasi ini dirancang untuk memperluas dataset dengan variasi yang relevan, sehingga model dapat dilatih untuk mengenali objek dengan lebih baik dalam berbagai kondisi dan meningkatkan akurasi klasifikasi pada data yang belum terlihat sebelumnya. Proses augmentasi dilakukan dengan menggunakan ImageDataGenerator dari library keras.

### 3. HASIL DAN PEMBAHASAN

Pada penelitian ini, algoritma *Convolutional Neural Network* (CNN) diterapkan untuk klasifikasi citra apel dengan menggunakan teknik data augmentasi. Dataset apel terdiri dari tiga kelas yaitu *Braeburn*, *Crimson Snow*, dan *Pink Lady*, yang dibagi dengan rasio 75% untuk data *training* dan 25% untuk data *testing*. Data melalui tahap *pre-processing* termasuk normalisasi data dan pengubahan ukuran data menjadi 150x150. Teknik data augmentasi yang digunakan mencakup *flipping*, *cropping*, *rotation*, dan *noise injection gaussian blur* sebesar 10%. Penelitian ini melakukan enam skenario eksperimen yaitu tanpa menerapkan data augmentasi, menerapkan teknik augmentasi *flipping*, menerapkan teknik augmentasi *cropping*, menerapkan teknik augmentasi *rotation*, menerapkan teknik augmentasi *noise injection*, dan mengkombinasikan dua skenario teknik augmentasi yang menghasilkan nilai akurasi terbesar yaitu *flipping dan noise injection*.

Model CNN yang digunakan dikonfigurasi dengan convolution layers yang terdiri dari 32, 64, dan 128 unit masing-masing dengan ukuran kernel 3x3 dan fungsi aktivasi ReLU untuk mengaktifkan pembelajaran non-linear dalam jaringan. Setelah masing-masing convolution layer, diterapkan max pooling dengan ukuran pool 2x2 untuk mempertahankan fitur penting sembari mengurangi komputasi yang diperlukan. Layer dense pertama memiliki 8 node yang diikuti oleh lapisan dropout dengan dropout rate sebesar 0,5 untuk mencegah overfitting. Layer dense terakhir memiliki 3 node yang diaktifkan dengan softmax activation untuk menghasilkan probabilitas kelas output dari dataset yang terdiri dari 3 kelas. Konfigurasi ini dirancang untuk mengoptimalkan pengenalan pola gambar dalam kelas dataset yang kompleks.

Hasil evaluasi menunjukkan bahwa teknik augmentasi data berhasil meningkatkan akurasi model secara signifikan. Teknik Noise Injection menghasilkan akurasi tertinggi sebesar 98,82%, sementara teknik Cropping memberikan akurasi terendah sebesar 67,46%. Hasil evaluasi yang lebih detail dapat dilihat pada Bagian 3.2.

#### 3.1 Hasil Perbandingan Teknik Augmentasi

Pada penelitian ini dilakukan 6 skenario *training* yaitu tanpa augmentasi, menerapkan masing-masing augmentasi (*flipping*, *cropping*, *rotation*, *noise injection*) dan menggabungkan dua teknik augmentasi yang menghasilkan nilai akurasi

terbaik. Pada Tabel 2, dapat dilihat bahwa penerapan teknik augmentasi pada model CNN dapat bekerja dengan baik. Hal ini dibuktikan dengan peningkatan nilai akurasi ketika model menerapkan teknik augmentasi. Selain nilai akurasi, didapatkan juga matriks evaluasi lainnya seperti presisi, *recall*, dan *F1-Score*. Nilai-nilai ini didapatkan dari *confusion matrix*, yang merupakan teknik evaluasi yang menunjukkan jumlah prediksi benar dan salah yang dilakukan oleh model untuk setiap kelas. Nilai akurasi diperoleh dari perbandingan antara jumlah prediksi benar dengan total jumlah prediksi, sementara presisi mengukur ketepatan prediksi yang sesuai, *recall* mengukur kemampuan model dalam menemukan semua sampel yang sesuai, dan *F1-Score* merupakan rata-rata dari presisi dan *recall*. Dengan menggunakan keempat metrik ini, evaluasi kinerja model menjadi lebih komprehensif dan dapat menunjukkan efektivitas teknik augmentasi yang diterapkan.

Tabel 2. Hasil Penelitian

Teknik Augmentasi	Akurasi	Presisi	Recall	F1-Score
Tanpa Augmentasi	66,27	49,39	66,67	55,01
<i>Flipping</i>	72,78	84,51	73,10	67,36
<i>Cropping</i>	67,46	78,23	68,86	60,76
<i>Rotation</i>	68,64	50,89	66,67	56,34
<i>Noise Injection</i>	98,82	98,81	98,74	98,80
<i>Noise Injection + Flipping</i>	84,02	87,57	83,02	81,72

### 3.2 Evaluasi Teknik Augmentasi

Dari skenario penerapan 4 teknik augmentasi yang diterapkan secara mandiri, skenario *Noise injection* menghasilkan nilai akurasi terbaik yaitu 98,82%, hal ini karena *noise injection* cenderung mempertahankan fitur utama dari gambar asli tanpa mengubah struktur dari gambar tersebut. Teknik ini juga lebih konsisten dalam mempertahankan relevansi fitur penting dalam gambar. Sedangkan untuk teknik augmentasi yang mendapatkan nilai terkecil adalah *cropping* yaitu 67,46%, nilai ini hanya berbeda 1,19% dari akurasi skenario tanpa augmentasi yaitu 66,27%. *Cropping* menghasilkan nilai terendah dikarenakan ketika prosesnya, *cropping* bisa saja mengurangi informasi penting dari gambar yang mengakibatkan hilangnya detail atau fitur yang relevan untuk klasifikasi. Hal ini membuat model sulit dalam mengenali objek dengan akurat dan kesulitan dalam mempelajari variasi yang diperlukan. *Flipping* menjadi teknik augmentasi yang memiliki nilai akurasi tertinggi kedua yaitu 72,78% diikuti oleh *rotation* di tempat ketiga dengan akurasi sebesar 68,64%. *Flipping* baik horizontal atau vertical mencerminkan perubahan yang simetris dan lebih sering ditemui dalam dataset sehingga memungkinkan model untuk belajar dengan lebih baik terhadap variasi tersebut. Sedangkan *rotation* dapat memberikan kompleksitas geometris yang lebih besar, terutama jika sudut rotasi yang diberikan tidak selalu konsisten atau relevan dengan gambar aslinya. Hal ini dapat membuat model sulit untuk mengenali pola serta menghadapi resiko *overfitting* pada variasi yang tidak relevan. Perbedaan citra setelah diterapkan teknik augmentasi *flipping* dan *noise injection* dapat dilihat pada gambar 11.



Gambar 11. Perbandingan Citra

Setelah mendapatkan hasil dari ke-4 teknik augmentasi yang diterapkan secara mandiri, dilakukan lagi skenario dengan menerapkan 2 teknik augmentasi dengan nilai tertinggi yaitu *Noise Injection* dan *Flipping*. Nilai akurasi untuk skenario ini adalah 84,02% yang mana lebih kecil daripada skenario *noise injection* dan lebih besar dari skenario *flipping*. Hal ini karena *noise injection* secara khusus menambahkan variasi dalam bentuk noise pada gambar yang dapat membantu model untuk lebih tahan terhadap gangguan, di sisi lain *flipping* mengubah orientasi gambar secara simetris yang menciptakan variasi dalam presentasi visual dari data yang ada. Kedua teknik augmentasi ini tidak selalu bekerja secara sinergis dalam meningkatkan akurasi model. Penerapan teknik augmentasi *noise injection* lebih efektif dalam memperbaiki akurasi karena lebih fokus terhadap variasi dalam konten gambar, sedangkan *flipping* memperkenalkan kompleksitas tambahan yang tidak selalu meningkatkan performa model secara konsisten.

## 4. KESIMPULAN

Dalam penelitian ini, klasifikasi apel telah dilakukan menggunakan *Convolutional Neural Network* dan data augmentasi, dengan menerapkan enam skenario berbeda. Hasilnya menunjukkan bahwa penerapan augmentasi pada algoritma

*Convolutional Neural Network* membantu model bekerja lebih baik, yang dibuktikan dengan peningkatan signifikan dalam nilai akurasi. Dari empat teknik augmentasi yang diterapkan, *noise injection* terbukti menjadi teknik augmentasi terbaik dengan menghasilkan nilai akurasi tertinggi sebesar 98,82%, sementara teknik *cropping* mendapatkan nilai akurasi terendah sebesar 67,46%. Kombinasi antara *noise injection* dan *flipping* tidak selalu memberikan hasil yang optimal, karena efek dari *noise injection* dapat terhapus oleh perubahan orientasi yang konsisten dari *flipping*, yang menyebabkan model kesulitan dalam mempelajari fitur-fitur yang konsisten. Untuk penelitian selanjutnya, disarankan agar efektivitas augmentasi dimaksimalkan dengan memilih teknik augmentasi yang saling melengkapi dan sesuai dengan karakteristik spesifik dari data yang diolah, sehingga performa klasifikasi dapat ditingkatkan lebih lanjut.

## REFERENCES

- [1] A. Sucipto, A. K. Zyen, B. B. Wahono, T. Tamrin, H. Mulyo, and R. R. Ali, "Linear Discriminant Analysis for Apples Fruit Variety Based on Color Feature Extraction," *2021 Int. Semin. Appl. Technol. Inf. Commun.*, pp. 184–189, 2021, doi: 10.1109/iSemantic52711.2021.9573200.
- [2] A. Matsui, M. Inuma, and L. Meng, "Deep Learning Based Real-time Visual Inspection for Harvesting Apples," *2022 Int. Conf. Adv. Mechatron. Syst.*, pp. 76–80, 2022, doi: 10.1109/ICAMEchS57222.2022.10003376.
- [3] D. T. Rhamadiyanti and S. Suyanto, "Robustness of Convolutional Neural Network in Classifying Apple Images," *Proc. - 2021 Int. Semin. Intell. Technol. Its Appl. Intell. Syst. New Norm. Era, ISITIA 2021*, pp. 226–231, 2021, doi: 10.1109/ISITIA52817.2021.9502258.
- [4] Z. Li, F. Liu, W. Yang, S. Peng, and J. Zhou, "A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects," *IEEE Trans. Neural Networks Learn. Syst.*, vol. 33, no. 12, pp. 6999–7019, 2022, doi: 10.1109/TNNLS.2021.3084827.
- [5] C. F. G. Dos Santos and J. P. Papa, "Avoiding Overfitting: A Survey on Regularization Methods for Convolutional Neural Networks," *ACM Comput. Surv.*, vol. 54, no. 10s, 2022, doi: 10.1145/3510413.
- [6] Q. Zheng, M. Yang, X. Tian, N. Jiang, and D. Wang, "A full stage data augmentation method in deep convolutional neural network for natural image classification," *Discret. Dyn. Nat. Soc.*, vol. 2020, no. 1, 2020, doi: 10.1155/2020/4706576.
- [7] C. Shorten and T. M. Khoshgofaar, "A survey on Image Data Augmentation for Deep Learning," *J. Big Data*, vol. 6, no. 1, 2019, doi: 10.1186/s40537-019-0197-0.
- [8] S. Phiphiphatphaisit and O. Surinta, "Food Image Classification with Improved MobileNet Architecture and Data Augmentation," *ICISS '20 Proc. 3rd Int. Conf. Inf. Sci. Syst.*, pp. 51–56, 2020, doi: 10.1145/3388176.3388179.
- [9] R. Satila Passa, S. Nurmaini, and D. P. Rini, "YOLOv8 Based on Data Augmentation for MRI Brain Tumor Detection," *Sci. J. Informatics*, vol. 10, no. 3, p. 363, 2023, doi: 10.15294/sji.v10i3.45361.
- [10] D. S. Dewantara, R. Hidayat, H. Susanto, and A. M. Arymurthy, "CNN with multi stage image data augmentation methods for indonesia rare and protected orchids classification," *2020 Int. Conf. Comput. Sci. Its Appl. Agric.*, 2020, doi: 10.1109/ICOSICA49951.2020.9243174.
- [11] T. H. Chun, U. R. Hashim, S. Ahmad, L. Salahuddin, N. H. Choon, and K. Kanchymalay, "Efficacy of the Image Augmentation Method using CNN Transfer Learning in Identification of Timber Defect," *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, no. 5, pp. 107–114, 2022, doi: 10.14569/IJACSA.2022.0130514.
- [12] R. Poojary, R. Raina, and A. K. Mondal, "Effect of data-augmentation on fine-tuned cnn model performance," *IAES Int. J. Artif. Intell.*, vol. 10, no. 1, pp. 84–92, 2021, doi: 10.11591/ijai.v10.i1.pp84-92.
- [13] H. Mureşan and M. Oltean, "Fruit recognition from images using deep learning," *Acta Univ. Sapientiae, Inform.*, vol. 10, no. 1, pp. 26–42, 2021, doi: 10.48550/arXiv.1712.00580.
- [14] L. Fitriani, D. Tresnawati, and M. B. Sukriyansah, "Image Classification On Garutan Batik Using Convolutional Neural Network with Data Augmentation," *JUITA J. Inform.*, vol. 11, no. 1, p. 107, 2023, doi: 10.30595/juita.v11i1.16166.
- [15] D. Krstinić, M. Braović, L. Šerić, and D. Božić-Štulić, "Multi-label Classifier Performance Evaluation with Confusion Matrix," *Conf. Int. Conf. Soft Comput. Artif. Intell. Mach. Learn. (SAIM 2020)*, vol. 10, pp. 01–14, 2020, doi: 10.5121/csit.2020.100801.
- [16] D. Mandal, U. Wermund, L. Phavaphutanon, and R. Cronje, *Temperate Fruits: Production, Processing, and Marketing*. 2021. doi: 10.1201/9781003045861.
- [17] S. Ghosal and K. Sarkar, "Rice Leaf Diseases Classification Using CNN with Transfer Learning," *2020 IEEE Calcutta Conf.*, pp. 230–236, 2020, doi: 10.1109/CALCON49167.2020.9106423.
- [18] L. Alzubaidi *et al.*, *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions*, vol. 8, no. 1. Springer International Publishing, 2021. doi: 10.1186/s40537-021-00444-8.
- [19] A. G. Alharbi and M. Arif, "Detection and classification of apple diseases using convolutional neural networks," *2020 2nd Int. Conf. Comput. Inf. Sci.*, pp. 1–5, 2020, doi: 10.1109/ICCIS49240.2020.9257640.
- [20] K. Z. Thet, K. K. Htwe, and M. M. Thein, "Grape Leaf Diseases Classification using Convolutional Neural Network," *2020 Int. Conf. Adv. Inf. Technol.*, pp. 147–152, 2020, doi: 10.1109/ICAIT51105.2020.9261801.