

Klasifikasi Buah-Buahan dengan Metode ResNet-RS

Fruit Classification With ResNet-RS

1st Dewa Made Aditya Wirasakananda
Fakultas Informatika
Universitas Telkom
Bandung, Indonesia
dewamadeaditya@student.telkomuniversity.ac.id

2nd Ema Rachmawati
Fakultas Informatika
Universitas Telkom
Bandung, Indonesia
emarachmawati@telkomuniversity.ac.id

3rd Gamma Kosala
Fakultas Informatika
Universitas Telkom
Bandung, Indonesia
gammakosala@telkomuniversity.ac.id

Abstrak—Buah-buahan merupakan salah satu makanan yang dikonsumsi oleh masyarakat di dunia. Dengan adanya berbagai jenis buah-buahan yang tersedia di dunia, buah-buahan tersebut mempunyai karakteristik bentuk dan warna yang berbeda-beda. Oleh karena itu perlunya dilakukan klasifikasi sebagai cara untuk mengidentifikasi buah-buahan secara cepat, dengan menerapkan teknik computer vision yang menggunakan metode ResNet-RS. Metode ini digunakan karena ResNet-RS merupakan metode yang mempunyai peningkatan terhadap ResNet yang diperkenalkan pada 2015. Untuk klasifikasi buah-buahan dengan menggunakan metode ResNet-RS mendapatkan hasil yaitu 97.29% akurasi, 97.29% F1-Score, 97.28% recall, dan 97.31% precision. Terdapat selisih 4.07% dalam akurasi terhadap model ResNet dengan dataset yang sama.

Kata kunci—buah-buahan, ResNet-RS, klasifikasi

Abstract—Fruits are one of the foods consumed by people in the world. With the existence of various types of fruits available in the world, these fruits have different shape and color characteristics. Therefore, it is necessary to classify as a way to identify fruits quickly, by applying computer vision techniques using the ResNet-RS method. This method is used because ResNet-RS is a method that has improvements to ResNet introduced in 2015. For the classification of fruits using the ResNet-RS method, the results were 97.29% accuracy, 97.29% F1-Score, 97.28% recall, and 97.31% precision. There is a 4.07% difference in accuracy with the ResNet model with the same dataset.

Keywords—fruits, ResNet-RS, classification

I. PENDAHULUAN

Untuk menjalankan kehidupan sehari-hari, manusia membutuhkan makanan agar tetap beraktivitas, salah satunya adalah buah-buahan. Buah-buahan adalah salah satu makanan yang mengandung vitamin dan mineral yang dibutuhkan tubuh manusia, oleh karena itu buah-buahan banyak dibutuhkan oleh masyarakat di seluruh dunia baik itu buah lokal dan buah import. Untuk mempermudah mengetahui jenis buah-buahan yang tersedia bagi masyarakat, perlunya dilakukan klasifikasi.

Perlunya dilakukan klasifikasi karena banyaknya jenis buah-buahan, sehingga cara ini diperlukan untuk mempercepat sorting dalam proses identifikasi buah-buahan tersebut, contoh yang dapat diambil adalah buah apel, buah

ini mempunyai banyak varian jenis seperti warna, dan bentuk. Dalam sekilas terlihat buah ini mudah untuk dikenali, tetapi jika dilihat lebih teliti beberapa dari jenis apel tersebut berbeda, hal yang juga dapat dimanfaatkan dari klasifikasi adalah berkurangnya biaya dan waktu dalam melakukan sorting dan meningkatkan produktivitas.

Untuk menyelesaikan permasalahan, maka dibangun sebuah sistem yang melakukan klasifikasi terhadap 131 kelas pada berbagai jenis buah-buahan, dengan menggunakan metode Convolutional Neural Network (CNN) dengan arsitektur ResNet-RS. ResNet-RS ini merupakan cara baru dari klasifikasi yang merupakan peningkatan dari ResNet dari 2015. Hasil performa dari ResNet-RS adalah 82,2% dalam Top-1 ImageNet, performa tersebut diraih dengan memodifikasi metode training dari arsitektur ResNet, dengan memodifikasi architecture maka ResNet-RS dalam mencapai performa 83,4% dalam Top-1 ImageNet (Bello dkk., 2021).

Penelitian ini akan menjawab pertanyaan dari permasalahan mengenai bagaimana membangun sebuah sistem yang melakukan klasifikasi citra buah-buahan dengan menggunakan ResNet-RS. Adapun untuk ruang lingkup dari batasan masalah yaitu untuk dataset yang dipakai adalah dataset fruit-360 [11]. Pada dataset sudah disediakan split training set, dan test set. Jumlah kelas citra pada dataset fruit-360 [11] berjumlah 131 kelas. Metode yang digunakan adalah ResNet-RS.

Berdasarkan masalah yang dijelaskan pada latar belakang maka tujuan diadakannya penelitian ini adalah membangun sistem klasifikasi terhadap buah-buahan dengan menggunakan metode Resnet-RS.

Pada bagian selanjutnya akan terbagi 4 bagian. Bagian pertama menjelaskan tentang studi terkait yang menjadi pendukung penelitian ini. Bagian kedua akan menjelaskan tentang bagaimana sistem yang dibangun pada penelitian. Bagian ketiga akan menjelaskan tentang evaluasi sistem yang dibangun dan bagian terakhir akan menjelaskan kesimpulan dari penelitian ini.

II. KAJIAN TEORI

Dalam melakukan penulisan ini sudah terdapat beberapa penelitian yang berkaitan dengan permasalahan

dari latar belakang yang sudah dijelaskan, berikut penelitian yang berhubungan dengan latar belakang.

Penelitian telah dilakukan oleh Zhang dkk., 2014 terkait klasifikasi buah-buahan dengan menggunakan computer vision dan Feedforward Neural Network (FNN), dalam penelitian ini dataset diperoleh dengan menggunakan kamera digital dan mempersiapkan dataset untuk dipakai. Setelah dataset siap dipakai maka selanjutnya mengambil fitur-fitur pada citra dan dikirim ke FNN. Setelah fitur dikirim maka akan dilakukan proses training oleh algoritma FSCABC, penelitian ini juga menggunakan K-fold cross validation untuk meningkatkan kemampuan dari FNN. Hasil yang didapatkan dalam penelitian ini adalah dari 1653 citra berwarna dan 18 kategori kelas mendapatkan skor akurasi klasifikasi yaitu 89.1%. Skor ini lebih tinggi jika dibandingkan dengan menggunakan algoritma Genetic Algorithm dengan skor akurasi klasifikasi 84.8%. Karena hasil ini penelitian mengambil kesimpulan bahwa algoritma FSCACB dengan FNN efektif dalam klasifikasi buah-buahan.

Penelitian telah dilakukan oleh Kausar dkk., 2018 terkait klasifikasi buah-buahan dengan Pure-CNN. Dalam penelitian ini percobaan dilakukan dengan menggunakan Pure Convolutional Neural Network (PCNN), dengan penggunaan parameter yang minimum. PCNN mempunyai 7 convolutional layer, untuk mengurangi overfitting maka PCNN menggunakan Global Average Pooling (GAP), dataset yang digunakan dalam penelitian ini adalah fruit-360 yang terdiri atas 55244 citra buah-buahan berwarna dengan jumlah kelas 81. Hasil yang didapatkan dari penelitian ini adalah skor akurasi dari PCNN dengan dataset fruit-360 adalah 98.88%.

Penelitian yang telah dilakukan oleh Munir dkk., 2020 terkait klasifikasi buah-buahan berdasarkan Deep Neural Network, penelitian ini bertujuan untuk mencari skor akurasi dalam klasifikasi untuk pertanian, penanam, dan penghasilan buah secara otomatis oleh mesin robot. Penelitian ini menggunakan ResNet-50 karena diperlukannya sebagai transfer learning. Hasil yang didapatkan dalam penelitian ini dengan pendekatan hanya 10% training dibandingkan dengan penelitian yang sudah ada mengacu kepada F1 Score mendapatkan hasil dari 0.838 ke 0.894 dan 0.955.


Penelitian yang telah dilakukan oleh Duong dkk., 2020 terkait klasifikasi buah-buahan dengan menggunakan EfficientNet dan MixNet, penelitian ini bertujuan karena masih banyaknya pendekatan yang memakan waktu banyak dalam waktu training / testing atau banyaknya False Positive (FP). EfficientNet dan MixNet dianggap sebagai solusi yang praktis, karena dapat mengenai buah secara akurat dan cepat, kedua sistem di atas juga dapat diluncurkan dengan perangkat yang tidak banyak mempunyai komputasi. Dataset yang digunakan dalam penelitian ini adalah fruit-360, yang pada saat July 2019 mempunyai 96 kelas dan terdiri atas 65,326 citra yang sudah terbagi menjadi dua untuk data training dan testing. Hasil yang didapatkan dari penelitian ini adalah, semua versi dari EfficientNet dan MixNet memperoleh hasil akurasi lebih dari 99%, hasil ini

dibandingkan dengan menggunakan ConvNet dengan hasil akurasi paling optimal adalah 94.52%.

Penelitian yang telah dilakukan oleh Siddiqi, 2019 terkait efektivitas klasifikasi buah-buahan dengan menggunakan transfer learning, untuk model yang digunakan Inception v3 dan VGG16. Pada penelitian ini dataset yang digunakan adalah fruit-360 yang berisi 72 kelas dan citra sebanyak 48,249. Penelitian ini bertujuan untuk membuktikan bahwa, transfer learning dapat meningkatkan hasil akurasi dari klasifikasi buah. Hasil yang didapatkan dari penelitian ini pada VGG16 menggunakan fine tuning memperoleh skor akurasi 99.27%, untuk model Inception v3 dengan menggunakan transfer learning juga memberikan hasil akurasi yang sangat bagus.

III. METODE


Pada Gambar 3.1 merupakan sistem klasifikasi buah-buahan dengan ResNet-RS yang akan dibangun dengan menggunakan bahasa pemrograman Python. Proses dimulai dari pengumpulan dataset yang terdiri dari data latih dan data uji, langkah selanjutnya adalah melatih model ResNet-RS hingga mendapatkan hasil yang memuaskan.



GAMBAR 3.1
SISTEM KLASIFIKASI BUAH-BUAHAN DENGAN RESNET-RS

A. Deep Residual Network (ResNet)


Deep Residual Network atau ResNet adalah sebuah neural network yang diperkenalkan pada 2015 yang bertujuan untuk menyelesaikan masalah akurasi ketika layer pada neural network biasa memasuki arah yang lebih dalam terjadi training error dan test error.




GAMBAR 3.1
TRAINING ERROR (KIRI) DAN TEST ERROR (KANAN) PADA CIFAR-10

DENGAN 20 LAYER DAN 56 LAYER (K. HE DKK., 2016)

Dari permasalahan di atas maka dibentuk sebuah neural network yang bernama 'Deep Residual Network' yang bekerja dengan memindahkan weight ke weight layer yang lebih dalam untuk mengurangi degradation pada gradient atau memberikan sebuah jalan bagi data untuk mencapai bagian selanjutnya dari neural networks dengan melewati beberapa layer, konsep tersebut diberi nama 'Skip Connection', gambar 3.2 akan menunjukkan konsep tersebut (He dkk., 2016). Pada gambar 3.3 akan menunjukkan arsitektur dari Resnet 50 yang menunjukkan struktur pada downsampling yang bekerja dengan membagi menjadi dua jalur yang akan dilewati oleh citra, jalur residual bisa menggunakan path a yaitu melakukan identity mapping dengan tidak ada penambahan entries pada parameter atau path b yaitu melewati 1x1 convolutional dengan parameter stride yang sama.



GAMBAR 3.2
RESIDUAL LEARNING: A BUILDING BLOCK



GAMBAR 3.3
ARSITEKTUR DARI RESNET-50 (T. HE DKK., 2018)

B. ResNet-RS

ResNet-RS adalah sebuah peningkatan dari ResNet yang diperkenalkan pada Bello dkk., 2021, peningkatan yang dilakukan oleh ResNet-RS adalah meraih skor akurasi 82.2% pada top-1 ImageNet, skor tersebut merupakan kenaikan sebesar 3.2% daripada ResNet yang mempunyai skor akurasi 79%, hal itu diraih dengan melakukan peningkatan dari training method, ketika dilakukan peningkatan lebih lanjut pada kedua arsitektur yaitu ResNet

D dan Squeeze and Excitation meraih skor akurasi 83.4% yang merupakan kenaikan yang lebih tinggi. Dengan menggunakan Training Method dan Regularization Method yang baru.

ResNet-RS melakukan beberapa perubahan yaitu, metode training berubah dengan menerapkan metode SGDR (Stochastic Gradient Descent with Warm Restart) sebuah algoritma optimasi yang mencari parameter dari model yang terbaik agar cocok pada predicted dan actual output dari model, penggunaan optimasi SGDR mendapatkan penambahan akurasi untuk ResNet-RS. Perubahan selanjutnya dalam ResNet-RS adalah metode Regularization yaitu dengan menerapkan EMA of weights, Label Smoothing, Stochastic Depth, RandAugment, dan Decrease weight decay mendapatkan kenaikan akurasi lebih tinggi.

Dari kedua perubahan pada Training Method dan Regularization Method yang diterapkan pada ResNet-RS memberikan peningkatan dalam skor akurasi top-1 sebesar 82.2%, untuk meningkatkan skor akurasi lebih tinggi, pada ResNet-RS dilakukan perubahan kecil mengenai arsitektur yang digunakan. Arsitektur yang diperkenalkan adalah modifikasi dari ResNet-D dan Squeeze-And-Excitation (SE) untuk peningkatan akurasi pada setiap perubahan dapat dilihat pada gambar 3.3. Salah satu perubahan arsitektur dengan menggunakan ResNet-D (T. He dkk., 2018) yaitu, ukuran convolution yaitu 7x7 diganti menjadi ukuran yang lebih kecil yaitu 3x3 seperti yang pertama kali diperkenalkan pada Inception v3. Dengan perubahan yang telah dilakukan pada ResNet-RS maka arsitektur terbaru seperti tabel 3.2, selain perbedaan dari modifikasi ResNet-D, ResNet-RS masih bekerja selayaknya ResNet original yaitu tetap menggunakan skip connection tetapi perbedaan dari ResNet-D dengan Resnet yaitu penambahan pada downsampling block sebelum 1x1 convolution menjadi 2x2 average pool dengan $s = 2$, seperti yang di ilustrasikan pada gambar 2.5. (Bello dkk., 2021)


TABLE 3.1
PERUBAHAN PADA RESNET-RS WARNA UNGU MERPAKAN PERUBAHAN PADA TRAINING METHOD, WARNA HIJAU MERUPAKAN PERUBAHAN PADA REGULARIZATION METHOD DAN WARNA KUNING MERUPAKAN PERUBAHAN PADA ARCHITECTURAL IMPROVEMENT (BELLO DKK., 2021)

Improvement	Top-1	Δ
ResNet-200	79.0	—
+ Cosine LR Decay	79.3	+0.3
+ Increase training epochs	78.8 †	-0.5
+ EMA of weights	79.1	+0.3
+ Label Smoothing	80.4	+1.3
+ Stochastic Depth	80.6	+0.2
+ RandAugment	81.0	+0.4
+ Dropout on FC	80.7 ‡	-0.3
+ Decrease weight decay	82.2	+1.5
+ Squeeze-and-Excitation	82.9	+0.7
+ ResNet-D	83.4	+0.5

TABLE 3.2
ARSITEKTUR RESNET-RS DENGAN MODIFIKASI RESNET-D DAN SQUEEZE AND EXCITATION. UKURAN OUTPUT

DIASUMSIKAN DENGAN INPUTAN GAMBAR 224X224.
LAMBANG X MENUNJUKKAN BANYAKNYA BLOCK YANG
DIULANG DALAM ARSITEKTUR RESNET-101 (BELLO DKK.,
2021)

Block Group	Output Size	Convolutional Layout
Stem	112x112	$\begin{bmatrix} 3 \times 3, 64, s2 \\ 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 1$
c2	56x56	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 1$
c3	28x28	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 1$
c4	14x14	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 1$
c5	7x7	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 1$
	1x1	$\begin{bmatrix} Avg Pool \\ Dropout \\ 1000 - d FC \end{bmatrix} \times 1$



GAMBAR 3.4
PERUBAHAN PADA RESNET-D DI DALAM DOWNSAMPLING
BLOCK YAITU DENGAN MENAMBAHKAN 2X2 STRIDE = 2
SEBELUM CONV 1X1 AGAR MENGHINDARI PENGAMBILAN
FEATURE MAPS
YANG TIDAK LENGKAP (T. HE DKK., 2018)

C. Dataset

Pada penelitian ini, untuk klasifikasi akan menggunakan dataset berupa citra dari buah-buahan dengan format jpg. Dataset ini memiliki 131 kelas dan mempunyai 90.483 citra dengan 67.692 citra untuk training dan 22.688 citra untuk test. Untuk setiap kelas yang ada pada dataset memiliki citra yang berada pada kisaran jumlah antara 400-500 citra, berikut adalah nama kelas dalam dataset Fruit 360 berikut:

TABLE 3.3
LIST KELAS YANG ADA DI DALAM DATASET FRUIT 360

Kelas Dataset Fruit 360			
Apple Braeburn	Apple Crimson Snow	Apple Golden 1	Apple Golden 2
Apple Golden 3	Apple Granny Smith	Apple Pink Lady	Apple Red 1
Apple Red 2	Apple Red 3	Apple Red Delicious	Apple Red Yellow 1
Apple Red Yellow 2	Apricot	Avocado	Avocado ripe
Banana	Banana Lady Finger	Banana Red	Beetroot
Blueberry	Cactus fruit	Cantaloupe 1	Cantaloupe 2
Carambula	Cauliflower	Cherry 1	Cherry 2
Cherry Rainier	Cherry Wax Black	Cherry Wax Red	Cherry Wax Yellow
Chestnut	Clementine	Cocos	Corn

Corn Husk	Cucumber Ripe	Cucumber Ripe 2	Dates
Eggplant	Fig	Ginger Root	Granadilla
Grape Blue	Grape Pink	Grape White	Grape White 2
Grape White 3	Grape White 4	Grapefruit Pink	Grapefruit White
Guava	Hazelnut	Huckleberry	Kaki
Kiwi	Kohlrabi	Kumquats	Lemon
Lemon Meyer	Limes	Lychee	Mandarine
Mango	Mango Red	Mangostan	Maracuja
Melon Piel de Sapo	Mulberry	Nectarine	Nectarine Flat
Nut Forest	Nut Pecan	Onion Red	Onion Red Peeled
Onion White	Orange	Papaya	Passion Fruit
Peach	Peach 2	Peach Flat	Pear
Pear 2	Pear Abate	Pear Forelle	Pear Kaiser
Pear Monster	Pear Red	Pear Stone	Pear Williams
Pepino	Pepper Green	Pepper Orange	Pepper Red
Pepper Yellow	Physalis	Physalis with Husk	Pineapple
Pineapple Mini	Pitahaya Red	Plum	Plum 2
Plum 3	Pomegranate	Pomelo Sweetie	Potato Red
Potato Red Washed	Potato Sweet	Potato White	Quince
Rambutan	Raspberry	Redcurrant	Salak
Strawberry	Strawberry Wedge	Tamarillo	Tangelo
Tomato 1	Tomato 2	Tomato 3	Tomato 4
Tomato Cherry Red	Tomato Heart	Tomato Maroon	Tomato Yellow
Tomato not Ripened	Walnut	Watermelon	

Dataset dapat diunduh pada kaggle dengan nama Fruit 360 (Mureşan & Oltean, 2018) .
<https://www.kaggle.com/moltean/fruits>



GAMBAR 3.5
 BEBERAPA CONTOH GAMBAR DARI DATASET FRUIT 360

Pada proses ini dilakukan pembangunan model dan melatih dengan menggunakan dataset yang sudah dipersiapkan. Pada penelitian ini kedua model menggunakan pre trained model dengan weights yaitu imagenet. Pada penelitian ini menggunakan Adam


Optimizer dan categorical_crossentropy sebagai loss function, alasan dari penggunaan dari Adam Optimizer karena mempunyai kemampuan untuk mempunyai komputasi yang cepat dan hanya membutuhkan sedikit parameter.

Langkah awal yaitu memilih depth yang dipakai untuk menentukan block configuration, untuk penelitian ini menggunakan depth 50 dengan alasan ukuran dari input size citra, terlihat pada tabel 3.4 menunjukan block configuration. Input gambar masuk ke dalam block stem dengan input size 100x100 dan mendapatkan output size 50x50 hal itu karena pada stem block terdapat stride 2 sehingga input dibagi menjadi menjadi 2, setelah itu proses berlanjut kepada block c2 dengan pengulangan block sebanyak 3 kali dan mendapatkan output size 25x25, setelah itu memasuki block c3 dengan pengulangan block sebanyak 4 kali dan mendapatkan output size 13x13, block selanjutnya yaitu c4 dengan pengulangan block sebanyak 6

kali dan mengeluarkan output 7x7, selanjutnya memasuki block c5 dengan pengulangan 3 kali dan mengeluarkan output 4x4, terakhir citra akan memasuki avg pool, dropout dan fc.

TABLE 3.4
BLOCK CONFIGURATION UNTUK DEPTH SEMUA RESNET
YANG DIPAKAI DI DALAM RESNET-RS, PADA BLOCK C3 DAN
C4 MEMPUNYAI DEPTH SCALING YANG LEBIH BESAR UNTUK
MEMBATASI OVERFITTING (BELLO DKK., 2021).

Model	Depth	Block Configuration
ResNet	50	[3-4-6-3]
ResNet	101	[3-4-23-3]
ResNet	152	[3-8-36-3]
ResNet	200	[3-24-36-3]
ResNet	270	[4-29-53-4]
ResNet	350	[4-36-72-4]
ResNet	420	[4-44-87-4]



GAMBAR 3.6

ARSITEKTUR RESNET-RS 50 DENGAN INPUT SIZE 100X100, SIMBOL X DI DALAM GAMBAR MEREPRESENTASIKAN BERAPA BANYAK BLOCK DIULANG DI DALAM RESNET-RS 50

Untuk melakukan evaluasi pada eksperimen, akan dilakukan perbandingan dengan menggunakan model Resnet, alasan dari perbandingan yaitu untuk melihat apakah model yang dipakai sesuai dengan klaim yaitu lebih baik dari model pendahulunya yaitu Resnet. Hasil yang akan dibandingkan yaitu akurasi, F1-Score, precision, recall,

waktu testing, dan hasil dari confusion matrix . Ilustrasi dari penggunaan struktur matriks terdapat pada tabel 3.3.

TABLE 3.5
ILUSTRASI DARI CONFUSION MATRIX

Actual Class	Predicted Class	
	Positive	Negative
Positive	True Positive (TP)	False Positive (FP)
Negative	False Negative (FN)	True Negative (TN)

Nilai pada True Positive (TP) dan True Negative (TN) adalah nilai yang memprediksi banyaknya kelas yang diperkirakan benar. False Negative (FN) dan False Positive (FP) adalah nilai yang memprediksi jumlah kelas di kelas yang salah. Dari confusion matrix dapat dihitung nilai akurasi dengan rumus di bawah ini

$$accuracy = \frac{(TP + TN)}{(TP + FP + FN + TN)}$$

Precision adalah perbandingan antara True Positive (TP) dengan banyaknya data yang diprediksi positif dari model, berikut rumus untuk menghitung precision.

$$Precision = \frac{TP}{(TP + FP)}$$

Recall adalah perbandingan antara True Positive (TP) dengan banyaknya data yang sebenarnya positif dari model, berikut rumus untuk menghitung Recall.

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

F1-Score adalah rata rata yang didapatkan dari Recall dan Precision untuk mendapatkan nilai dari False Positive (FP) dan False Negative (FN) , berikut rumus untuk menghitung F1-Score.

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


IV. HASIL DAN PEMBAHASAN

Bagian evaluasi akan menjelaskan tentang hasil pengujian dan analisis hasil pengujian. Hasil pengujian berisi tentang hasil yang didapat selama pengujian berlangsung sedangkan analisis hasil pengujian berisi tentang kondisi-kondisi yang mempengaruhi hasil.

A. Hasil Pengujian


Pengujian klasifikasi buah-buahan mempunyai 131 kelas dengan total 90.483 citra yang dibagi ke dalam dua dataset yaitu 67.692 citra pada data training dan 22.688 citra pada data testing. Hal yang diperhatikan dalam pengujian tugas akhir ini adalah perbandingan antara kedua model yaitu Resnet-RS dan Resnet. Tujuan dari perbandingan untuk menentukan model yang terbaik untuk melakukan klasifikasi terhadap dataset buah buahan. Hasil akhir yang didapatkan dalam klasifikasi dengan menggunakan dataset Fruit-360, model Resnet-RS memberikan performa lebih baik dibandingkan dengan Resnet. Kedua model menggunakan parameter yang sama yaitu, input size 100x100 pixel, Batch size 8, dan Epoch yaitu 25. Kedua model juga memberikan hasil yaitu waktu testing sebagai perbandingan, waktu testing dilakukan dengan menampung semua data testing di dalam variabel setelah itu variabel akan melakukan prediksi terhadap model yang telah di training, proses ini dilakukan sebanyak lima kali dan akan diambil waktu terbaik. Kedua model menggunakan optimizer yaitu Adam Optimizer, alasan dari penggunaan optimizer untuk memberikan waktu komputasi yang lebih cepat tetapi memerlukan parameter yang sedikit untuk tuning, selain dari optimizer kedua model juga menggunakan dropout sebesar 85%, berdasarkan beberapa percobaan yang dilakukan kedua model memberikan hasil yang overfitting di beberapa kelas sehingga diperlukannya dropout sebagai pencegah terjadinya overfitting.

Hasil yang didapatkan dari ResNet-RS dengan akurasi 97.29% dan waktu testing yang didapatkan yaitu 26.9 detik, tabel 4.1 memberikan hasil yang lebih detail. Pada gambar 4.1 kiri diberikan grafik training pada model Resnet-RS terlihat pada training accuracy mendapatkan penurunan pada beberapa epoch, hal yang sama juga terjadi pada training loss pada gambar 4.2 kiri. Untuk hasil dari confusion matrix pada tabel 4.2 dan tabel 4.3 menunjukkan bahwa terdapat 34 kelas yang mendapatkan hasil False Positive dan 26 kelas yang mendapatkan hasil False Negative (FN), salah satu dari kelas yang salah melakukan prediksi terlihat pada gambar 4.2 yaitu Apple Red 2 dan Apple Braeburn.



GAMBAR 4.1

GRAFIK AKURASI TRAINING DAN TESTING RESNET-RS (KIRI) DAN GRAFIK AKURASI TRAINING DAN TESTING RESNET (KANAN)



GAMBAR 4.2

GRAFIK LOSS TRAINING DAN TESTING RESNET-RS (KIRI) DAN GRAFIK AKURASI LOSS DAN TESTING RESNET (KANAN)



GAMBAR 4.3

GAMBAR BUAH APPLE RED 2 DARI TRAINING (KIRI) DAN BUAH APPLE BRAEBURN DARI TESTING (KANAN), GAMBAR MERUPAKAN HASIL DARI KLASIFIKASI YANG SALAH OLEH MODEL RESNET-RS

ditunjukkan pada gambar 4.4 yaitu antara kelas Apple Yellow 1 dan Cantaloupe.



GAMBAR 4.4


GAMBAR BUAH APPLE RED YELLOW 1 DARI TRAINING (KIRI) DAN BUAH CANTALOUPE DARI TESTING (KANAN), GAMBAR MERUPAKAN HASIL KLASIFIKASI YANG SALAH OLEH MODEL RESNET

50

Selanjutnya untuk perbandingan yaitu model ResNet, mendapatkan hasil akurasi 93.22% dan waktu testing 22.6, tabel 4.1 memberikan hasil yang lebih detail. Pada gambar 4.1 kanan diberikan grafik training dari Resnet terlihat pada testing accuracy pada beberapa epoch dan pada gambar 4.2 kanan testing loss mendapat kenaikan loss yang sangat tinggi pada beberapa epoch diikuti dengan penurunan pada epoch selanjutnya. Untuk hasil dari confusion matrix pada tabel 4.3 dan tabel 4.4 menunjukkan bahwa terdapat 46 kelas yang mendapatkan hasil False Postive dan 45 kelas yang mendapatkan hasil False Negative (FN), salah satu kelas yang salah melakukan prediksi seperti yang

Berdasarkan hasil yang diberikan pada confusion matrix, beberapa kelas dari kedua model memiliki kesalahan dalam melakukan prediksi seperti yang ditunjukkan pada gambar 4.5 pada kelas Corn dan Peach.

Pada gambar 4.6 kedua model melakukan klasifikasi yang benar.



GAMBAR 4.5

GAMBAR BUAH CORN DARI TRAINING (KIRI) DAN BUAH PEACH 2 DARI TESTING (KANAN), KEDUA MODEL SALAH SALAM MELAKUKAN PREDIKSI KLASIFIKASI BERDASARKAN DARI CONFUSION MATRIX.



GAMBAR 4.6

GAMBAR BUAH LEMON MEYER (KIRI) DAN BUAH COCOS (KANAN), KEDUA MODEL BENAR DALAM MELAKUKAN PREDIKSI KLASIFIKASI BERDASARKAN DARI CONFUSION MATRIX

TABLE 4.1
HASIL PENGUJIAN

Model	Precision	Recall	F1 Score	Akurasi	Waktu Testing
Resnet-RS50	97.31%	97.28%	97.29%	97.29%	26.9 detik per loop
Resnet 50	93.28%	93.21%	93.22%	93.22%	22.1s per loop

TABLE 4.2
HASIL KELAS DAN JUMLAH CITRA FALSE POSITIVE (FP) BERDASARKAN CONFUSION MATRIX RESNET-RS

Kelas Buah	Jumlah Citra False Positive
Apple Braeburn	106
Apple Crimson Snow	43
Apple Golden 2	2
Apple Golden 3	2
Apple Granny Smith	1
Banana Lady Finger	31
Beetroot	1
Cactus fruit	1
Cherry 2	39
Chestnut	5
Cocos	2

Dates	10
Ginger Root	16
Granadilla	1
Grape White	7
Grape White 2	31
Hazelnut	10
Kiwi	2
Kohlrabi	34
Nut Pecan	12
Onion Red	50
Onion Red Peeled	63
Onion White	6
Passion Fruit	2
Peach 2	12
Pear Abate	5
Pear Stone	1
Pepino	3
Pepper Green	28
Physalis with Husk	18
Pitahaya Red	68
Potato Red	2

TABLE 4.3
HASIL KELAS DAN JUMLAH CITRA FALSE NEGATIVE (FN) BERDASARKAN CONFUSION MATRIX RESNET-RS

Kelas Buah	Jumlah Citra False Negative
Apple Golden 3	1
Apple Red 2	45
Apple Red Delicious	52
Apple Red Yellow 1	5
Banana	2
Banana Red	2
Beetroot	21
Blueberry	5
Carambula	21
Cherry Rainier	39
Chestnut	8
Clementine	1
Corn	36
Corn Husk	42
Eggplant	31
Fig	66
Ginger Root	1
Maracuja	10
Nectarine	11
Pear Monster	3
Pear Red	43
Pepino	39
Physalis with Husk	1
Potato Red Washed	10
Raspberry	67
Tomato not Ripened	28

TABLE 4.4
HASIL KELAS DAN JUMLAH CITRA FALSE POSITIVE (FP) BERDASARKAN CONFUSION MATRIX RESNET

Kelas Buah	Jumlah Citra False Positive
Apple Golden 1	2
Apple Golden 2	87
Apple Granny Smith	113
Apple Red 2	12
Apple Red Delicious	17
Banana	107
Banana Lady Finger	48
Banana Red	12
Blueberry	2
Cherry 2	4
Cherry Rainier	12
Chestnut	4
Corn Husk	20
Eggplant	9
Fig	1
Granadilla	45

Grape Pink	65
Grape White	13
Grape White 2	24
Grape White 3	29
Grape White 4	9
Grapefruit White	17
Mango	157
Mulberry	35
Nectarine	12
Nut Pecan	4
Peach 2	20
Peach Flat	22
Pear 2	113
Pear Abate	9
Pear Forelle	8
Pear Monster	25
Pear Stone	37
Pear Williams	7
Physalis with Husk	67
Pineapple	12
Plum 3	18
Potato Red	89
Potato Red Washed	138
Potato Sweet	3
Potato White	24
Salak	8
Tangelo	6
Tomato 2	7
Tomato Heart	13
Tomato not Ripened	52

Pear Williams	35
Pepper Red	13
Physalis with Husk	77
Potato Sweet	75
Rambutan	24
Strawberry Wedge	23
Walnut	17

TABLE 4.5

HASIL KELAS DAN JUMLAH CITRA FALSE NEGATIVE (FN)
BERDASARKAN CONFUSION MATRIX RESNET

Kelas Buah	Jumlah Citra False Negative
Apple Braeburn	12
Apple Golden 1	83
Apple Golden 3	81
Apple Pink Lady	8
Apple Red 1	52
Apple Red Yellow 1	35
Apple Red Yellow 2	14
Banana	10
Banana Red	8
Beetroot	26
Cactus fruit	71
Cantaloupe 2	101
Carambola	21
Cherry Rainier	4
Cocos	8
Corn	65
Corn Husk	13
Eggplant	59
Ginger Root	31
Grapefruit Pink	2
Guava	1
Kiwi	13
Kohlrabi	5
Kumquats	45
Lemon	5
Limes	36
Mandarine	5
Maracuja	28
Melon Piel de Sapo	146
Nut Forest	1
Nut Pecan	1
Onion Red	149
Onion White	38
Peach	26
Pear	32
Pear Abate	12
Pear Monster	16
Pear Stone	4

B. Analisis Hasil Pengujian

Berdasarkan hasil pada tabel 4.1 dapat terlihat bahwa ada perbedaan 4.07% dari akurasi, hal ini karena resnet-rs mempunyai modifikasi dari arsitektur yaitu Resnet D dan Squeeze and Excitation. Pada gambar 4.3, gambar 4.4, dan gambar 4.5 kedua model terlihat melakukan kesalahan klasifikasi karena terdapat kesamaan warna tekstur ataupun bentuk pada kedua citra. Kedua model mempunyai parameter yang berbeda, pada Resnet-RS jumlah parameter yaitu 33,696,288 dengan waktu testing 26,9 detik dan pada Resnet jumlah parameter 27,880,451 dengan waktu testing 22,5 detik. Kedua model menggunakan parameter yang sedikit berbeda, selain dari perbedaan dari arsitektur yang digunakan ResNet-RS menggunakan pooling max yang berfungsi untuk mengambil value maximum dari feature map dan menggunakannya untuk membuat downsampled feature map hal ini biasanya terjadi setelah convolutional layer. Parameter adalah sebuah konfigurasi variabel yang memberikan isi dari model, parameter dibutuhkan oleh model untuk membuat prediksi dari dataset yang diberikan, parameter juga mendefinisikan skill yang diberikan oleh model untuk menyelesaikan permasalahan yang diselesaikan oleh model. Dengan perubahan dari total parameter yang dimiliki kedua model maka layer yang dipakai berbeda Resnet-RS memiliki layer yang lebih banyak dibandingkan Resnet.

V. KESIMPULAN

Berdasarkan pengujian yang dilakukan pada penelitian tugas akhir Klasifikasi Buah Buahan dengan Metode Resnet RS, mendapatkan akurasi sebesar 97.29% dan waktu komputasi 26.9 s jika dibandingkan dengan model Resnet 50 yang memperoleh akurasi 93.22% dan waktu testing 22.1 s. Terdapat selisih 4.07% dalam akurasi dan 4.8 s dalam waktu testing, sehingga beberapa improvisasi dan perubahan dari arsitektur yang dilakukan pada Resnet RS terhadap Resnet terbukti memberikan peningkatan akurasi, precision, recall, dan F1 Score. Namun tidak dapat diabaikan kekurangan yang dimiliki oleh Resnet-RS adalah waktu testing yang lebih lambat dibandingkan dengan Resnet yang disebabkan oleh bertambahnya layer yang digunakan.

Saran dari pengembangan penelitian ini adalah menambahkan kelas citra yang belum termasuk di dataset agar bisa melakukan identifikasi terhadap citra buah yang belum dikenali. Untuk pengembangan model bisa menggunakan scaling strategies dan training strategies sesuai dengan saran dari pengembangan model.

REFERENSI

- [1] Bello, I., Fedus, W., Du, X., Cubuk, E. D., Srinivas, A., Lin, T.-Y., Shlens, J., & Zoph, B. (2021). Revisiting ResNets: Improved Training and Scaling Strategies. <https://arxiv.org/abs/2103.07579>
- [2] Chauhan, R., Ghanshala, K. K., & Joshi, R. C. (2018). Convolutional Neural Network (CNN) for Image Detection and Recognition. ICSCCC 2018 - 1st International Conference on Secure Cyber Computing and Communications, 278–282. <https://doi.org/10.1109/ICSCCC.2018.8703316>
- [3] Duong, L. T., Nguyen, P. T., di Sipio, C., & di Ruscio, D. (2020). Automated fruit recognition using EfficientNet and MixNet. Computers and Electronics in Agriculture, 171, 105326. <https://doi.org/10.1016/J.COMPAG.2020.105326>
- [4] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition (hlm. 770–778). <http://image-net.org/challenges/LSVRC/2015/>
- [5] He, T., Zhang, Z., Zhang, H., Zhang, Z., Xie, J., & Li, M. (2018). Bag of Tricks for Image Classification with Convolutional Neural Networks. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2019-June, 558–567. <https://doi.org/10.48550/arxiv.1812.01187>
- [6] Kausar, A., Sharif, M., Park, J., & Shin, D. R. (2018). Pure-CNN: A framework for fruit images classification. Proceedings - 2018 International Conference on Computational Science and Computational Intelligence, CSCI 2018, 404–408. <https://doi.org/10.1109/CSCI46756.2018.00082>
- [7] Khaing, Z. M., Naung, Y., & Htut, P. H. (2018). Development of control system for fruit classification based on convolutional neural network. Proceedings of the 2018 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering, ElConRus 2018, 2018-January, 1805–1807. <https://doi.org/10.1109/EICONRUS.2018.8317456>
- [8] Munir, K., Umar, A. I., & Yousaf, W. (2020). Automatic Fruits Classification System Based on Deep Neural Network. NUST Journal of Engineering Sciences, 13(1), 37–44. <https://doi.org/10.24949/NJES.V13I1.501>
- [9] Mureşan, H., & Oltean, M. (2018). Fruit recognition from images using deep learning. Acta Universitatis Sapientiae, Informatica, 10(1), 26–42. <https://doi.org/10.2478/AUSI-2018-0002>
- [10] Siddiqi, R. (2019). Effectiveness of transfer learning and fine tuning in automated fruit image classification. PervasiveHealth: Pervasive Computing Technologies for Healthcare, 91–100. <https://doi.org/10.1145/3342999.3343002>
- [11] Zhang, Y., Wang, S., Ji, G., & Phillips, P. (2014). Fruit classification using computer vision and feedforward neural network. Journal of Food Engineering, 143, 167–177. <https://doi.org/10.1016/J.JFOODENG.2014.07.001>