

## BAB II

### TINJAUAN PUSTAKA

#### 2.1. Penelitian Terdahulu

Berikut merupakan beberapa penelitian terdahulu terkait perancangan sistem klasifikasi buah:

##### 2.1.1 *Automatic Fruits Classification System Based on Deep Neural Network*[8]

Penelitian yang berjudul “*Automatic Fruits Classification System Based on Deep Neural Network*” dilakukan oleh Khadija Munir, Arif Iqbal Umar, and Waqas Yousaf. Penelitian ini melakukan perancangan terhadap sistem klasifikasi buah menggunakan arsitektur *Deep Neural Network* ResNet50 dengan tujuan untuk memberikan teknik yang efisien dan akurat dalam melakukan klasifikasi buah, guna meningkatkan efisiensi dari sistem *robot-based farming*. Model menggunakan model ResNet50 yang di train menggunakan 2 public dataset berbeda, yakni dataset FRUIT-360 dengan 660 gambar dan dataset FIDS-30 dengan 38038 gambar. Kedua dataset kemudian digunakan untuk proses training dengan porsi 10 hingga 80%. Hasil dari model kemudian diukur berdasarkan nilai accuracy, precision, recall dan F1-score. Sistem mampu melampaui nilai akurasi *state of the art* yang menggunakan model Faster R-CNN dengan 60% training data dataset FIDS-30 dan 10% training data dataset Fruit-360 dengan model CNN.

Berdasarkan penelitian diatas, terdapat beberapa poin penting yang penulis ambil yakni :

- Arsitektur ResNet50 mampu memberikan akurasi yang mumpuni walau menggunakan jumlah data yang lebih sedikit.

- Penelitian melakukan pengukuran tingkatan keberhasilan dari sistem klasifikasi melalui perbandingan nilai Accuracy, Precision, Recall dan khususnya F1-Score.

### 2.1.2 *Identification of Ripe and Unripe Citrus Fruits Using Artificial Neural Network* [9]

Penelitian yang berjudul “*Identification of Ripe and Unripe Citrus Fruits Using Artificial Neural Network*” dilakukan oleh Rex Fiona, Shreya Thomas, Isabel Maria J, dan Hannah B. Penelitian ini melakukan survey terhadap klasifikasi tingkat kematangan pada buah, serta deteksi penyakit pada tumbuhan. Berdasarkan hasil survey yang dilakukan, penulis menentukan untuk mengimplementasikan system identifikasi kematangan pada buah jeruk menggunakan sebuah *artificial neural network* yang mendeteksi buah-buahan yang berdasarkan warna RGB yang ada. Penelitian menggunakan 350 gambar RGB buah jeruk mentah, matang dan busuk. Gambar kemudian melalui tahap segmentasi dimana gambar digital diubah menjadi objek melalui metode *watershed*. Kemudian dilakukan proses *feature extraction* berdasarkan nilai RGB yang ada pada object. Berdasarkan Teknik yang dirancang dan diimplementasikan berhasil menghasilkan tingkat akurasi sebesar 90%.

Beberapa poin penting yang diperoleh dari penelitian ini adalah sebagai berikut:

- Identifikasi kematangan pada buah jeruk dapat dilakukan berdasarkan tingkatan nilai RGB suatu gambar jeruk.
- Kematangan buah jeruk dapat diklasifikasikan menjadi tiga kelas berdasarkan warnanya, yakni mentah, matang dan busuk.

### 2.1.3 *Study on an Automatic Sorting System for Date Fruits* [10]

Penelitian yang berjudul “*Study on an Automatic Sorting System for Date Fruits*” dilakukan oleh Razieh Purdarbani et al. Penelitian ini melakukan perancangan sistem sortir online berbasis *machine vision* yang ditujukan untuk melakukan penyortiran terhadap buah kurma (*date fruit*) berdasarkan tingkat kematangan buah yang terbagi menjadi 4 tingkatan yakni, Kimri (mentah), Khalal (berubah warna), Rotab (Setengah matang), dan Tamar (Matang). Sistem terdiri dari unit *conveyor*, unit penerangan, unit penangkapan gambar dan unit sortasi. Sistem akan melakukan deteksi menggunakan algoritma *Taxonomy Classification*, dimana sistem melakukan observasi dan analisis terhadap perbedaan dan kesamaan fitur-fitur fisik dan mekanis dari sampel yang ada. Buah akan melewati *conveyor belt* dimana terdapat sebuah kamera yang menangkap gambar dari buah. Setelah gambar diproses, buah kemudian akan diarahkan ke *port* yang sesuai dengan karakteristik dari buah tersebut menggunakan *step-motor* dan juga *actuator*. Sistem deteksi dirancang menggunakan 50 sampel buah acak yang digunakan untuk *feature extraction* dimana nilai RGB gambar akan diambil. Nilai RGB ini akan digunakan oleh system untuk memilah buah yang melalui *conveyor belt*. Sistem yang telah dirancang menghasilkan tingkat akurasi 100% untuk tahapan Tamar, 97% untuk tahapan rotab, dan 99.66% pada tahapan Khalal.

Beberapa poin yang dapat diambil dari penelitian diatas adalah sebagai berikut :

- Penggunaan *Taxonomy Classification* dimana sistem melakukan pembelajaran terhadap fitur-fitur dari buah sampel yang digunakan.
- Sistem mengimplementasikan sistem sortir secara menyeluruh, dimana sistem juga dilengkapi dengan *conveyor belt*, motor dan *actuator* sebagai *feeder* dan *sorting system* .

#### 2.1.4 *Research on classification and recognition of fruit and vegetable based on lightweight ResNet-50* [11]

Penelitian yang berjudul “*Research on classification and recognition of fruit and vegetable based on lightweight ResNet-50*” dilakukan oleh Xin Hong, LiFeng Qian, et al. Penelitian ini melakukan pengembangan terhadap sistem klasifikasi buah dan sayur menggunakan arsitektur ResNet50. Dilakukan modifikasi pada model ResNet50 dimana diintegrasikan sebuah *deep separable convolution module* pada *residual module* yang mampu membuat model lebih ringan selagi memberikan peningkatan pada efisiensi model. Dilakukan juga fine-tuning dan optimasi untuk meningkatkan nilai akurasi dari model. Penelitian menghasilkan peningkatan pada kecepatan deteksi sebesar 19.19% selagi menurunkan file size dari model sebesar 57.8%

Berdasarkan penelitian diatas dapat diambil beberapa poin penting yakni:

- ResNet50 dapat digunakan sebagai metode klasifikasi yang ringan dan efektif dengan modifikasi lebih lanjut.

#### 2.1.5 *Ensemble of multi-task deep convolutional neural networks using transfer learning for fruit freshness classification* [12]

Penelitian berjudul “*Ensemble of multi-task deep convolutional neural networks using transfer learning for fruit freshness classification*” dilakukan oleh Jaeyong Kang dan Jeonghwan Gwak. Penelitian ini melakukan perancangan model Deep Convolutional Neural Network yang terdiri dari gabungan *bottleneck features* dari arsitektur ResNet-50 dan ResNet-101 yang kemudian digunakan untuk mengklasifikasikan jenis dan tingkat kesegaran dari buah. Digunakan juga metode Transfer Learning guna meningkatkan efektivitas model walau menggunakan data training yang sedikit. Model kemudian di evaluasi menggunakan gabungan data yang diambil dari dataset dan gambar di internet untuk merepresentasikan jenis dan tingkat kesegaran

dari kategori buah yang ada. Model menghasilkan nilai akurasi di 98.50% dalam klasifikasi tingkat kesegaran, dan 97.43% dalam klasifikasi jenis buah.

Beberapa poin penting yang dapat diambil berdasarkan penelitian diatas adalah :

- Metode Transfer Learning mampu meningkatkan efektivitas dari model walau menggunakan jumlah data training yang lebih sedikit.

#### 2.1.6 *Fruit Sorting Based on Machine Vision Technique* [13]

Penelitian yang berjudul “*Fruit Sorting Based on Machine vision Technique*” dilakukan oleh Mohd Safirin Karis, Wira Hidayat Mohd Saad, et al. Penelitian ini melakukan penelitian terkait teknik yang digunakan untuk melakukan pembedaan tipe apel berdasarkan ukuran. Penelitian menggunakan algoritma *image processing* yang di desain untuk melakukan klasifikasi terhadap apel berdasarkan informasi dari suatu gambar. Penelitian juga mengimplementasikan beberapa teknik *image processing* seperti *image enhancement*, *morphological*, *image segmentation* dan *HSV image conversion*, yang digunakan untuk membedakan apel berdasarkan ukurannya masing-masing. Pada tahap pengujian, terdapat beberapa permasalahan yang muncul akibat dari kesalahan teknis pada gambar seperti keberadaan bayangan dan cerminan pada objek. Untuk mengatasi permasalahan tersebut, digunakan beberapa metode konversi HSV lain untuk meningkatkan performa dari klasifikasi buah. Berdasarkan hasil percobaan, sistem mampu melakukan klasifikasi terhadap apel melalui ukurannya. Selain itu, intensitas cahaya juga memiliki pengaruh tinggi pada proses *image processing*.

Beberapa poin penting yang dapat diambil dari penelitian diatas adalah :


- Klasifikasi pada buah tidak hanya dapat dilakukan berdasarkan warna atau karakteristik RGB buah, tetapi juga dapat diklasifikasikan berdasarkan bentuknya
- Bayangan dan cerminan pada buah yang diklasifikasi dapat memunculkan permasalahan dalam proses klasifikasi.

## 2.2. Tinjauan Teori

### 2.2.1 *Kematangan Buah Jeruk*

Secara umum, kematangan pada buah jeruk dapat ditentukan oleh 2 hal, yakni warna buah serta kepadatan buah. Tingkat kematangan buah jeruk dapat dibagi menjadi 3 tingkatan, yakni Belum Matang, Matang, dan Busuk [14].

Contoh Jeruk Belum Matang



Gambar 2.1 Contoh Jeruk Belum Matang

Buah jeruk yang belum matang memiliki warna kehijauan hingga hijau kekuning-kuningan yang dapat dilihat pada gambar 2.1. Jeruk yang belum matang juga memiliki tekstur yang lebih padat dibandingkan buah jeruk yang matang.

Contoh Jeruk Matang



Gambar 2.2 Contoh Jeruk Matang

Buah jeruk matang memiliki warna hijau kekuning-kuningan hingga oranye atau kuning serta tekstur yang tidak terlalu keras seperti pada gambar 2.2.[15]



*Gambar 2.3 Contoh Jeruk Busuk*

Buah jeruk yang busuk dapat dilihat dari warnanya yang hijau busuk hingga kecoklat-coklatan di bagian-bagian tertentu hingga keseluruhan jeruk yang dapat dilihat pada gambar 2.3. Selain itu, buah jeruk busuk juga lembek dan berair dibandingkan jeruk biasanya. Indikasi lain dari buah jeruk yang busuk adalah adanya bercak putih di permukaan jeruk yang menandakan keberadaan jamur pada jeruk.

### **2.2.2 *Artificial Intelligence* dan *Machine Learning***

*Artificial Intelligence* atau AI merupakan kemampuan yang dimiliki oleh mesin yang dapat meniru kecerdasan alami makhluk hidup. Suatu algoritma AI mampu melakukan beberapa aktivitas seperti pembelajaran, penyelesaian permasalahan, pemahaman logis, layaknya suatu makhluk hidup.[16]

*Machine Learning* merupakan salah satu bagian dari AI yang menitik beratkan pada aspek pembelajaran dimana suatu algoritma memiliki kemampuan untuk belajar dan menganalisa input dan output serta memahami pola yang ada. Algoritma juga mampu melakukan pengulangan untuk memberikan output yang efisien dan akurat [17]

*Deep learning* merupakan perkembangan lanjutan dari *Machine Learning* dimana digunakan sebuah *neural network* berlapis yang

mensimulasikan cara kerja dari otak manusia yang mampu belajar dan menganalisa data dalam jumlah besar.[18]

### **2.2.3 Computer Vision [19]**

Computer Vision atau CV, merupakan sebuah subkategori bidang AI dimana komputer dapat memahami dan memproses suatu objek melalui media gambar atau video, layaknya sistem penglihatan manusia.

Salah satu contoh pengimplementasian teknologi CV adalah pada algoritma *self driving cars*, dimana mobil dapat mengidentifikasi dan mengklasifikasikan berbagai macam objek yang ada melalui sebuah kamera dan mampu melakukan tindakan tertentu, berdasarkan data yang diperoleh.

### **2.2.4 Convolutional Neural Network [20]**

Convolutional Neural Network merupakan salah satu bentuk algoritma Deep Learning yang menggunakan suatu gambar sebagai input dan melakukan klasifikasi terhadap beragam aspek atau objek pada gambar berdasarkan bobot atau bias yang dimiliki agar dapat dibedakan dari satu sama lain.


Convolutional Neural Network memiliki arsitektur yang mirip dengan pola neuron pada otak manusia. Beberapa contoh perkembangan dari arsitektur CNN adalah seperti AlexNet, VGGNet dan ResNet.

### **2.2.5 ResNet50 [21]**

ResNet50 atau Residual Network 50 merupakan CNN yang dikembangkan dari model VGGNet untuk mengatasi berbagai masalah umum dari *deep CNN* seperti *vanishing gradient* dimana karakteristik yang telah dipelajari menjadi hilang setelah sekian *layer* pelatihan, dan ResNet mampu memberikan peningkatan performa dengan



menggunakan *flops* yang lebih sedikit. Untuk versi ResNet yang digunakan memiliki 50 *layers* seperti terlihat pada gambar 2.4



Gambar 2.4 ResNet50 Model Architecture

ResNet mempunyai fitur *skip connection* untuk mengatasi *vanishing gradient*, *skip connection* bekerja dengan melewati *layer* tertentu namun tetap menjaga nilai *gradient* yang didapatkan.

### 2.2.6 Dataset, Image Preprocessing dan Data Augmentation

Dataset merupakan suatu koleksi data yang saling berhubungan antara satu sama lain, dan dapat diakses secara individu atau bersamaan [22]. Algoritma *Deep Learning* melakukan pembelajaran dan analisis melalui dataset yang digunakan sebagai input.

Sebelum dataset dapat diinput ke suatu model, perlu dilakukan persiapan akan gambar menjadi suatu format yang sudah ditentukan. Hal ini dilakukan untuk mengurangi kecacatan dan ketidakakuratan model. Tahapan persiapan dataset ini disebut sebagai *Image Preprocessing*. Beberapa contoh langkah Image Preprocessing adalah *resizing*, *orienting* dan *color correction*

Selain itu, suatu dataset juga dapat melalui proses *Data Augmentation*, dimana dataset yang sudah ada di augmentasi sehingga mampu memperbanyak jumlah data unik dari suatu dataset. *Data Augmentation* membantu dalam mengeneralisir data dan memungkinkan model untuk mempelajari informasi yang lebih luas. *Data Augmentation* juga mencegah terjadinya *overfitting* pada saat *training model* dilakukan. Beberapa contoh dari *Data Augmentation* adalah *rotation*, *flipping*, *cropping*, dan penambahan *noise*. [23]

### 2.2.7 *Classification* [24]

*Classification* merupakan suatu tugas algoritma *machine learning* dimana suatu gambar atau video diklasifikasikan berdasarkan aspek-aspek tertentu. *Classification* dilakukan Ketika data terdiri dari dua atau lebih kelas dengan masing-masing label yang memungkinkan sistem untuk mempelajari karakteristik dari masing masing kelas.

Proses pembelajaran ini memungkinkan sistem untuk melakukan evaluasi terhadap karakteristik data baru dan menggolongkan data sesuai dengan label data yang dipelajari

### 2.2.8 *Accuracy, Precision, Recall, F1-Score*

Salah satu metode evaluasi performa model adalah nilai *Accuracy*, yang mengukur tingkat akurasi yang dihasilkan berdasarkan prediksi benar yang dilakukan oleh model terhadap keseluruhan proses prediksi. Hal tersebut dilakukan dengan membagi seluruh prediksi benar dengan total jumlah prediksi.

$$Accuracy = \frac{Jumlah\ Prediksi\ Benar}{Total\ Prediksi}$$

Dengan tingginya nilai *Accuracy* yang diberikan oleh model, maka model juga semakin akurat dalam melakukan prediksi terhadap data yang digunakan. Namun dengan tingginya akurasi model, belum menjamin kebenaran atau presisi model dalam melakukan. Oleh karena itu diperlukan penilaian jenis *Precision* yang menghitung rasio jumlah prediksi positif yang benar (*True Positive*) dibandingkan dengan jumlah total prediksi positif (*True Positive+False Positive*).

$$Precision = \frac{True\ Positive}{True\ Positive + False\ Positive}$$

Recall merupakan penilaian performa suatu model yang menghitung rasio jumlah prediksi positif yang benar (*True Positive*) dibandingkan dengan jumlah total kejadian positif (*True Positive+False Negative*). [25]

$$Recall = \frac{True\ Positive}{True\ Positive + False\ Negative}$$

F1-Score digunakan untuk mengevaluasi performa oleh suatu model klasifikasi dimana dilakukan perhitungan antara nilai precision dan recall yang memberikan nilai *harmonic mean* untuk performa model.

$$F1\ Score = 2 * \frac{Precision * Recall}{Precision + Recall}$$

### 2.2.9 Confusion Matrix [26]

True Label	Mango	10	3	2
	Apple	4	7	4
	Orange	0	0	15
		Mango	Apple	Orange
		Predicted Label		

Gambar 2.5 Contoh Confusion Matrix

Confusion Matrix merupakan metode untuk evaluasi hasil yang didapatkan penelitian dengan memetakan hasil prediksi dengan nilai asli dari suatu kelas. Untuk penelitian ini, Confusion Matrix yang digunakan berukuran 3x3 seperti pada gambar 2.5. Hal tersebut dikarenakan penulis memiliki tiga jenis kelas yang ingin diklasifikasikan yakni jeruk matang, jeruk belum matang, dan jeruk busuk. Metode ini juga digunakan oleh penulis karena menghasilkan

nilai *recall* dan *precision* yang nantinya merupakan variabel yang digunakan untuk mencari *F-1 Score*.

#### **2.2.10 Receiver Operating Characteristic (ROC) [27]**

ROC adalah kurva yang menunjukkan nilai prediksi pada threshold klasifikasi berbeda dalam penelitian, ROC memplot dua parameter yakni True Positive Rate (TPR) terhadap False Positive Rate (FPR), pada nilai threshold yang berbeda dan memisahkan sinyal dari noise.

Jika diturunkan batas threshold klasifikasi, lebih banyak objek yang diklasifikasikan sebagai positif, yang meningkatkan TPR dan FPR. Dari kurva ini, nilai penting yang didapatkan adalah AUC (Area Under Curve ROC), yang mengukur area dua dimensi yang terletak di bawah kurva ROC dari titik (0,0) hingga titik (1,1). AUC mengukur kemampuan classifier untuk dapat membedakan antar kelas. Hal ini digunakan sebagai ringkasan kurva ROC. Semakin tinggi nilai AUC maka semakin baik pula model dalam membedakan kelas positif dan negatif. AUC memberikan gambaran kinerja model di semua batas klasifikasi yang memungkinkan.

Terdapat dua metode penilaian ROC/AUC terhadap model multiclass, yakni One vs One (OVO) dan One vs Rest (OVR) [28]. metode One vs One atau OVO, melakukan penilaian AUC antara satu kelas yang dianggap sebagai nilai positive dengan satu kelas lainnya yang dianggap sebagai nilai negative. Sedangkan metode One vs Rest (OVR) melakukan perhitungan nilai AUC antara satu kelas positive dengan gabungan kelas-kelas lainnya yang dijadikan sebagai negative. Keseluruhan nilai AUC OVO atau OVR yang didapatkan kemudian dapat dirata-ratakan guna mendapatkan nilai akhir kinerja model.

### 2.2.11 Roboflow [29]

Roboflow merupakan *website* yang menyediakan kemudahan dalam melakukan *machine learning* terutama untuk *image processing*, Roboflow menyediakan fitur premium berupa augmentasi dataset untuk langsung di-*training* ke berbagai model *CNN* populer.

Untuk penelitian ini, penulis memanfaatkan fitur gratis dari Roboflow yakni kemudahan untuk mengatur versi dataset serta melakukan augmentasi pada dataset menggunakan algoritma yang disediakan oleh Roboflow.

