

TESIS

IDENTIFIKASI CENGKIH UNTUK MEMBEDAKAN PUING RANTING DAN DAUN DENGAN DATA AUGMENTASI MENGGUNAKAN FASTER R-CNN

IDENTIFICATION OF CLOVES TO DISTINGUISH TWIG AND LEAF DEBRIS WITH DATA AUGMENTATION USING FASTER R-CNN

AULIA DARNILASARI

D082201014



PROGRAM STUDI MAGISTER TEKNIK INFORMATIKA

DEPARTEMEN TEKNIK INFORMATIKA

FAKULTAS TEKNIK

UNIVERSITAS HASANUDDIN

GOWA

2024



PENGAJUAN TESIS

IDENTIFIKASI CENGKIH UNTUK MEMBEDAKAN PUING RANTING DAN DAUN DENGAN DATA AUGMENTASI MENGGUNAKAN FASTER R-CNN

Tesis

Sebagai Salah Satu Syarat untuk Mencapai Gelar Magister Program Studi Teknik
Informatika

AULIA DARNILASARI

D082201014

Kepada

**FAKULTAS TEKNIK
UNIVERSITAS HASANUDDIN**

GOWA

2023



TESIS

IDENTIFIKASI CENGKIH UNTUK MEMBEDAKAN PUING RANTING DAN DAUN DENGAN DATA AUGMENTASI MENGUNAKAN FASTER R-CNN

AULIA DARNILASARI
D082201014

Telah dipertahankan di hadapan Panitia Ujian Tesis yang dibentuk dalam rangka penyelesaian studi pada Program Magister Teknik Informatika Fakultas Teknik Universitas Hasanuddin
Pada tanggal 15 Februari 202
dan dinyatakan telah memenuhi syarat kelulusan

Menyetujui,

Pembimbing Utama



Prof. Dr. Ir. Indrabayu., ST, MT, M. Bus.Sys., IPM, ASEAN.Eng.
NIP. 19750716 200012 2 002

Pembimbing Pendamping



Prof. Dr.Eng. Intan Sari Areni, S.T., M.T.
NIP. 19750203 200012 2 002

Dekan Fakultas Teknik
Universitas Hasanuddin



Ketua Program Studi
S2 Teknik Informatika



nmad Isran Ramli, M.T. IPM., ASEAN.Eng.
6 200012 1 002

Dr. Ir. Zahir Zainuddin, M.Sc.
NIP. 19640427 198910 1 002

PERNYATAAN KEASLIAN TESIS DAN KELIMPAHAN HAK CIPTA


Yang bertanda tangan dibawah ini :

Nama : Aulia Darnilasari
 Nomor Mahasiswa : D082201014
 Program Studi : S2 Teknik Informatika

Dengan ini menyatakan bahwa, tesis berjudul “identifikasi cengkih untuk membedakan puing ranting dan daun dengan data augmentasi menggunakan faster r-cnn” adalah karya saya dengan arahan dari komisi pembimbing (Prof. Dr. Ir. Indrabayu, ST., MT., M.Bus.Sys., IPM, ASEAN. Eng. dan Ibu Prof. Dr. Eng. Intan Sari Areni, ST., M.T.). Karya ilmiah ini belum diajukan dan tidak sedang diajukan dalam bentuk apa pun kepada perguruan tinggi mana pun. Sumber informasi yang berasal atau dikutip dari karya yang ditermpkan maupun tidak ditermpkan dari penulis lain telah disebutkan dalam teks dan dicantumkan dalam Daftar Pustaka tesis ini. Sebagian dari isi tesis ini telah dipublikasikan di Jurnal (The International Conference on Computer System, *Information Technology, and Electrical Engineering (COSITE)*) sebagai artikel dengan judul “*Implementation of Faster R-CNN with Colour and Blur Augmentation For Differentiate Cengkihs From Debris*”.

Dengan ini saya limpahkan hak cipta dari karya tulis saya berupa tesis ini kepada Universitas Hasanuddin.

Gowa, 15 Februari 2024

Yang Menyatakan

 Aulia Darnilasari



KATA PENGANTAR

Puji dan syukur penulis panjatkan kepada Allah Subhanahu wa ta'ala, karena berkat rahmat dan karunia-Nya sehingga tesis yang berjudul “IDENTIFIKASI CENGKIH UNTUK MEMBEDAKAN PUNG RANTING DAN DAUN DENGAN DATA AUGMENTASI MENGGUNAKAN FASTER R-CNN” ini dapat diselesaikan sebagai salah satu syarat dalam menyelesaikan jenjang Strata-2 pada Departemen Teknik Informatika Fakultas Teknik Universitas Hasanuddin.

Penulis menyadari bahwa dalam penyusunan dan penulisan laporan tesis ini tidak lepas dari bantuan, bimbingan serta dukungan dari berbagai pihak, dari masa perkuliahan sampai dengan masa penyusunan tesis. Oleh karena itu, penulis dengan senang hati menyampaikan terima kasih kepada:

1. Allah Subhanahu wa ta'ala, Tuhan Yang Maha Esa atas semua berkat, karunia, serta pertolongan-Nya yang tiada batas, yang diberikan kepada penulis di setiap langkah dalam pembuatan program hingga penulisan laporan tesis ini;
2. Kedua Orang tua penulis, Bapak Darwis dan Ibu Murni yang selalu menjadi motivasi terbesar dalam penyelesaian perkuliahan ini yang tidak pernah putus memberikan dukungan, doa, dan semangat serta selalu sabar dalam mendidik penulis sejak kecil;
3. Adik saya yang dengan sangat sabar menemani dan memberikan semangat kepada penulis selama penyusunan tesis;
4. Bapak Prof. Dr. Ir. Indrabayu, ST., MT., M.Bus.Sys., IPM, ASEAN. Eng. Sebagai pembimbing I dan Ibu Prof. Dr. Eng. Intan Sari Areni, ST., M.T. Sebagai pembimbing II yang telah memberikan waktu, tenaga, pikiran, dukungan moril maupun materiil serta perhatian yang luar biasa untuk mengarahkan penulis dalam penyusunan tesis.
5. Ibu Dr. Ir. Ingrid Nurtanio, M.T., Bapak Dr. Ir. Amil Ahmad Ilham, S.T., M.IT. dan Bapak Prof. Dr. Ir. Andani, MT. selaku dosen penguji yang telah memberikan kritik dan saran yang membangun sehingga laporan tesis ini jadi lebih baik.



6. Bapak Prof. Dr. Ir. Indrabayu, S.T., M.T., M.Bus.Sys., IPM, ASEAN. Selaku Ketua Departemen Teknik Informatika Fakultas Teknik Universitas Hasanuddin yang telah memberikan motivasi, bimbingan, dan semangatnya selama masa perkuliahan penulis.
7. Bapak Dr. Ir. Zahir Zainuddin, M.Sc. Selaku Ketua Program Studi Magister Teknik Informatika Fakultas Teknik Universitas Hasanuddin yang telah memberikan motivasi, bimbingan, dan semangatnya selama masa perkuliahan penulis.
8. Bapak Irwan S.T., La Ode Muh. Armadi S. Kom., Andi Anzanul Zikra S. Kom., Herlina Anwar S.T. Selaku partner penelitian yang telah menjadi teman diskusi dan membantu dalam penelitian ini.
9. Teman-teman Magister Teknik Informatika atas dukungan dan semangat yang diberikan selama ini.
10. Ibu Yuanita S.Kom., M.Pd. serta segenap Staf Program Studi Magister Teknik Informatika yang telah banyak membantu penulis selama pengurusan administrasi.

Akhir kata, penulis berharap semoga Allah SWT. Senantiasa berkenan membalas segala kebaikan dari semua pihak yang telah banyak membantu. Semoga Tesis ini dapat memberikan manfaat bagi pengembangan ilmu. Aamiin ya Rabbal Alamin.

Gowa, 15 Februari 2024

Aulia Darnilasari



ABSTRAK

AULIA DARNILASARI. *Identifikasi Cengkih untuk Membedakan Puing Ranting dan Daun dengan Data Augmentasi Menggunakan Faster R-CNN.* (Dibimbing oleh **Indrabayu** dan **Intan Sari Areni**).

Latar Belakang Penelitian ini memfokuskan pada pengembangan model deteksi objek dengan pendekatan *computer vision*, dengan tujuan mengatasi permasalahan kompleks terkait pemisahan antara cengkih dan puing (ranting dan daun). Metode yang digunakan dalam penelitian ini melibatkan pengembangan sistem deteksi objek cengkih dari puing dengan memanfaatkan algoritma Faster R-CNN, dengan model arsitektur ResNet50. Penelitian ini menggunakan video yang diambil menggunakan *belt conveyor* dengan tingkat kecepatan (18,11 21,13 24,15 27,11 30,19 33,21 36,23 39,25 42,27 45,29 rpm (*revolution per minute*)), dan tingkat kepadatan objek yang berbeda yakni sedikit, sedang, dan padat sebagai. Selanjutnya, penelitian ini melibatkan penerapan augmentasi data warna (*brightness contrast*) dan blur (*median blur and motion blur*), untuk meningkatkan kemampuan model dalam mengatasi variasi citra dan memungkinkan daya adaptasi lebih tinggi dalam proses pengenalan objek. Jumlah data yang digunakan pada penelitian ini menggunakan data latih 350 citra yang sebelum diaugmentasi dan 1050 citra setelah diaugmentasi. Pada proses pelatihan, menggunakan *epoch* sebanyak 100, menggunakan batch size sebanyak 16, jumlah class sebanyak 4 dan Resnet50. Hasil terbaik diperoleh berdasarkan nilai rata-rata *mAP* 0,99 dengan menggunakan augmentasi dan ambang batas 0,5 (*mAP_0.5*). Berdasarkan uji coba model terbaik maka diperoleh akurasi tertinggi sebesar 97% pada kecepatan 18,11 rpm kepadatan sedikit dengan menggunakan augmentasi dan akurasi terburuk sebesar 0,44% terjadi pada tingkat kepadatan padat dengan kecepatan 45,29 rpm tanpa augmentasi.

Kata Kunci: Cengkih, *Computer Vision*, Faster R-CNN, ResNet50, Augmentasi.



ABSTRACT

AULIA DARNILASARI. *identification of cloves to distinguish twig and leaf debris with data augmentation using faster r-cnn. (Supervised by **Indrabayu** and **Intan Sari Areni**).*

Background This research focuses on the development of an object detection model with a computer vision approach, with the aim of overcoming complex problems related to the separation between Cengkihs and debris (twigs and leaves). The method used in this research involves the development of a Cengkih object detection system from debris by utilizing the Faster R-CNN algorithm, with the ResNet50 architecture model. This research uses videos captured using a conveyor belt with speed levels of (18,11 21,13 24,15 27,11 30,19 33,21 36,23 39,25 42,27 45,29 rpm (revolution per minute)), and different object density levels of little, medium, and dense as. Furthermore, this research involves the application of color (brightness contrast) and blur (median blur and motion blur) data augmentation, to improve the model's ability to cope with image variations and enable higher adaptability in the object recognition process. The amount of data used in this study uses training data of 350 images before augmentation and 1050 images after augmentation. In the training process, using an epoch of 100 and a batch size of 16, the best results are obtained based on the average value of mAP 0.99 by using augmentation and a threshold of 0.5 (mAP_0.5). Based on the best model trial, the highest accuracy of 97% was obtained at a speed of 18,11 rpm with a small density using augmentation and the worst accuracy of 0.44% occurred at a speed of 45,29 rpm using augmentation.

Keywords: *Cloves, Computer Vision, Faster R-CNN, ResNet50, Augmentation.*



HALAMAN DAFTAR ISI

TESIS	ii
PENGAJUAN TESIS.....	ii
PERNYATAAN KEASLIAN TESIS DAN KELIMPAHAN HAK CIPTA ..	iv
KATA PENGANTAR.....	v
ABSTRAK	vii
ABSTRACT	viii
HALAMAN DAFTAR ISI.....	ix
DAFTAR TABEL.....	xi
DAFTAR GAMBAR.....	xvii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Tujuan Penelitian	4
1.4 Manfaat Penelitian	4
1.5 Ruang Lingkup Penelitian.....	5
BAB II TINJAUAN PUSTAKA.....	6
2.1 Landasan Teori.....	6
2.1.1 Pengertian Cengkih (<i>Cengkih</i>)	6
2.1.2 Pengolahan Bunga Cengkih	6
2.1.3 Tingkat Pemasaran Cengkih	7
2.1.4 <i>Artificial Intelligence (AI)</i>	8
2.1.5 <i>Computer Vision</i>	9
2.1.6 <i>Augmentasi (Augmentation)</i>	12
2.1.7 <i>Bounding Box</i> (Kotak Pembatas)	14
2.1.8 <i>Convolutional Neural Network (CNN)</i>	15
2.1.9 <i>Faster R-CNN</i>	16
2.1.10 <i>Residual Network</i>	18
2.1.11 Google Collaboratory	20
2.1.12 Jupyter Notebook	21
2.1.13 Evaluasi Sistem	22
2.2 Metode Penyelesaian Masalah	25
2.2.1 <i>State of the art</i> penelitian	25
Kerangka Pikir	30
METODOLOGI PENELITIAN	33
Tahap Studi Literatur	33



3.2	Tahapan penelitian	33
3.3	Waktu dan lokasi penelitian	35
3.4	Teknik Pengambilan Data	35
3.5	Analisis Kebutuhan	44
3.6	Rancangan Sistem	44
3.7	Evaluasi Sistem	55
BAB IV HASIL DAN PEMBAHASAN.....		56
4.1	Hasil training model dan Evaluasi Sistem	56
4.2	Hasil Pengujian Skenario	62
BAB V PENUTUP.....		201
5.1	Kesimpulan	201
5.2	Saran.....	201
DAFTAR PUSTAKA.....		202
LAMPIRAN.....		205



DAFTAR TABEL

Tabel 1. Fungsi Matrik Evaluasi	24
Tabel 2. <i>State of the art</i>	25
Tabel 3. Sampel data kelas Cengkih dan Puing Tanpa Augmentasi	37
Tabel 4. Sampel data kelas Cengkih dan Puing Menggunakan Augmentasi	39
Tabel 5. Perhitungan Kecepatan <i>Belt Conveyor</i> Berdasarkan Waktu	41
Tabel 6. Kategori Skenario Jumlah <i>Class</i> Berdasarkan Tingkat Kepadatan	43
Tabel 7. Sampel Skenario Pengambilan Data	43
Tabel 8. Hasil Training tanpa <i>color and blur augmentations</i>	56
Tabel 9. Hasil Training menggunakan <i>color and blur</i> augmentasi	59
Tabel 10. Hasil Deteksi Tanpa Augmentasi	63
Tabel 11. Hasil Deteksi Dengan Augmentasi	64
Tabel 12. Contoh Hasil Skenario 1 Kepadatan Sedikit	65
Tabel 13. Nilai <i>Confusion Matrix</i> cengkih Skenario 1 Kepadatan Sedikit	66
Tabel 14. Hasil <i>Confusion Matrix</i> cengkih Skenario 1 Kepadatan Sedikit	66
Tabel 15. Nilai <i>Confusion Matrix</i> ranting Skenario 1 Kepadatan Sedikit	67
Tabel 16. Hasil <i>Confusion Matrix</i> ranting Skenario 1 Kepadatan Sedikit	67
Tabel 17. Nilai <i>Confusion Matrix</i> cengkih Skenario 1 Kepadatan Sedikit	68
Tabel 18. Hasil <i>Confusion Matrix</i> cengkih Skenario 1 Kepadatan Sedikit	68
Tabel 19. Contoh Hasil Skenario 1 Kepadatan Sedang	69
Tabel 20. Nilai <i>Confusion Matrix</i> cengkih Skenario 1 Kepadatan Sedang	70
Tabel 21. Hasil <i>Confusion Matrix</i> cengkih Skenario 1 Kepadatan Sedang	71
Tabel 22. Nilai <i>Confusion Matrix</i> ranting Skenario 1 Kepadatan Sedang	71
Tabel 23. Hasil <i>Confusion Matrix</i> ranting Skenario 1 Kepadatan Sedang	72
Tabel 24. Nilai <i>Confusion Matrix</i> daun Skenario 1 Kepadatan Sedang	72
Tabel 25. Hasil <i>Confusion Matrix</i> daun Skenario 1 Kepadatan Sedang	73
Tabel 26. Contoh Hasil Skenario 1 kepadatan padat	73
Tabel 27. Nilai <i>Confusion Matrix</i> cengkih Skenario 1 Kepadatan Padat	76
Tabel 28. Hasil <i>Confusion Matrix</i> cengkih Skenario 1 Kepadatan Padat	76
Tabel 29. Nilai <i>Confusion Matrix</i> ranting Skenario 1 Kepadatan Padat	77
Tabel 30. Hasil <i>Confusion Matrix</i> ranting Skenario 1 Kepadatan Padat	77
Tabel 31. Nilai <i>Confusion Matrix</i> daun Skenario 1 Kepadatan Padat	78
Tabel 32. Hasil <i>Confusion Matrix</i> ranting Skenario 1 Kepadatan Padat	78
Tabel 33. Contoh Hasil Skenario 2 Kepadatan Sedikit	79
Tabel 34. Nilai <i>Confusion Matrix</i> cengkih Skenario 2 Kepadatan Sedikit	80
Tabel 35. Hasil <i>Confusion Matrix</i> cengkih Skenario 2 Kepadatan Sedikit	80
Nilai <i>Confusion Matrix</i> ranting Skenario 2 Kepadatan Sedikit	81
Hasil <i>Confusion Matrix</i> ranting Skenario 2 Kepadatan Sedikit	81
Nilai <i>Confusion Matrix</i> daun Skenario 2 Kepadatan Sedikit	82
Hasil <i>Confusion Matrix</i> daun Skenario 2 Kepadatan Sedikit	82



Tabel 40. Contoh Hasil Skenario 2 Kepadatan Sedang	83
Tabel 41. Nilai <i>Confusion Matrix</i> cengkih Skenario 2 Kepadatan Sedang.....	84
Tabel 42. Hasil <i>Confusion Matrix</i> cengkih Skenario 2 Kepadatan Sedang	85
Tabel 43. Nilai <i>Confusion Matrix</i> ranting Skenario 2 Kepadatan Sedang.....	85
Tabel 44. Hasil <i>Confusion Matrix</i> cengkih Skenario 2 Kepadatan Sedang	86
Tabel 45. Nilai <i>Confusion Matrix</i> cengkih Skenario 2 Kepadatan Sedang.....	86
Tabel 46. Hasil <i>Confusion Matrix</i> cengkih Skenario 2 Kepadatan Sedang	86
Tabel 47. Contoh Hasil Skenario 2 Kepadatan Padat	87
Tabel 48. Nilai <i>Confusion Matrix</i> cengkih Skenario 2 Kepadatan Padat	89
Tabel 49. Hasil <i>Confusion Matrix</i> cengkih Skenario 2 Kepadatan Padat.....	89
Tabel 50. Nilai <i>Confusion Matrix</i> ranting Skenario 2 Kepadatan Padat.....	90
Tabel 51. Hasil <i>Confusion Matrix</i> ranting Skenario 2 Kepadatan Padat	90
Tabel 52. Nilai <i>Confusion Matrix</i> daun Skenario 2 Kepadatan Padat	91
Tabel 53. Hasil <i>Confusion Matrix</i> daun Skenario 2 Kepadatan Padat.....	91
Tabel 54. Contoh Hasil Skenario 3 Kepadatan Sedikit.....	92
Tabel 55. Nilai <i>Confusion Matrix</i> cengkih Skenario 3 Kepadatan Sedikit.....	93
Tabel 56. Hasil <i>Confusion Matrix</i> cengkih Skenario 3 Kepadatan Sedikit	93
Tabel 57. Nilai <i>Confusion Matrix</i> ranting Skenario 3 Kepadatan Sedikit	94
Tabel 58. Hasil <i>Confusion Matrix</i> ranting Skenario 3 Kepadatan Sedikit.....	94
Tabel 59. Nilai <i>Confusion Matrix</i> daun Skenario 3 Kepadatan Sedikit.....	95
Tabel 60. Hasil <i>Confusion Matrix</i> Skenario 3 Kepadatan Sedikit.....	95
Tabel 61. Contoh Hasil Skenario 3 Kepadatan Sedang	96
Tabel 62. Nilai <i>Confusion Matrix</i> cengkih Skenario 3 Kepadatan Sedang	98
Tabel 63. Hasil <i>Confusion Matrix</i> cengkih Skenario 3 Kepadatan Sedang.....	98
Tabel 64. Nilai <i>Confusion Matrix</i> ranting Skenario 3 Kepadatan Sedang.....	99
Tabel 65. Hasil <i>Confusion Matrix</i> cengkih Skenario 3 Kepadatan Sedang.....	99
Tabel 66. Nilai <i>Confusion Matrix</i> daun Skenario 3 Kepadatan Sedang	99
Tabel 67. Hasil <i>Confusion Matrix</i> daun Skenario 3 Kepadatan Sedang.....	100
Tabel 68. Contoh Hasil Skenario 3 Kepadatan Padat	100
Tabel 69. Nilai <i>Confusion Matrix</i> Skenario 3 Kepadatan Padat.....	103
Tabel 70. Hasil <i>Confusion Matrix</i> Skenario 3 Kepadatan Padat.....	103
Tabel 71. Nilai <i>Confusion Matrix</i> ranting Skenario 3 Kepadatan Padat.....	104
Tabel 72. Hasil <i>Confusion Matrix</i> Skenario 3 Kepadatan Padat.....	104
Tabel 73. Nilai <i>Confusion Matrix</i> daun Skenario 3 Kepadatan Padat	104
Tabel 74. Hasil <i>Confusion Matrix</i> daun Skenario 3 Kepadatan Padat.....	105
Tabel 75. Contoh Hasil Skenario 4 Kepadatan Sedikit.....	105
Tabel 76. Nilai <i>Confusion Matrix</i> cengkih Skenario 4 Kepadatan Sedikit.....	106
Tabel 77. Hasil <i>Confusion Matrix</i> cengkih Skenario 4 Kepadatan Sedikit	107
Nilai <i>Confusion Matrix</i> ranting Skenario 4 Kepadatan Sedikit	107
Hasil <i>Confusion Matrix</i> cengkih Skenario 4 Kepadatan Sedikit	107
Nilai <i>Confusion Matrix</i> daun Skenario 4 Kepadatan Sedikit.....	108
Hasil <i>Confusion Matrix</i> daun Skenario 4 Kepadatan Sedikit	108



Tabel 82. Contoh Hasil Skenario 4 Kepadatan Sedang	109
Tabel 83. Nilai <i>Confusion Matrix</i> cengkih Skenario 4 Kepdatan Sedang	110
Tabel 84. Hasil <i>Confusion Matrix</i> cengkih Skenario 4 Kepdatan Sedang	111
Tabel 85. Nilai <i>Confusion Matrix</i> ranting Skenario 4 Kepdatan Sedang	111
Tabel 86. Hasil <i>Confusion Matrix</i> ranting Skenario 4 Kepdatan Sedang	111
Tabel 87. Nilai <i>Confusion Matrix</i> daun Skenario 4 Kepdatan Sedang	112
Tabel 88. Hasil <i>Confusion Matrix</i> daun Skenario 4 Kepadatan Sedang	112
Tabel 89. Contoh Hasil Skenario 4 Kepadatan Padat	113
Tabel 90. Nilai <i>Confusion Matrix</i> cengkih Skenario 4 Kepdatan Padat	115
Tabel 91. Hasil <i>Confusion Matrix</i> cengkih Skenario 4 Kepdatan Padat	115
Tabel 92. Nilai <i>Confusion Matrix</i> ranting Skenario 4 Kepdatan Padat	116
Tabel 93. Hasil <i>Confusion Matrix</i> ranting Skenario 4 Kepdatan Padat	116
Tabel 94. Nilai <i>Confusion Matrix</i> daun Skenario 4 Kepadatan Padat	117
Tabel 95. Hasil <i>Confusion Matrix</i> daun Skenario 4 Kepadatan Padat	117
Tabel 96. Contoh Hasil Skenario 5 Kepadatan Sedikit	117
Tabel 97. Nilai <i>Confusion Matrix</i> cengkih Skenario 5 Kepdatan Sedikit	118
Tabel 98. Hasil <i>Confusion Matrix</i> cengkih Skenario 5 Kepdatan Sedikit	119
Tabel 99. Nilai <i>Confusion Matrix</i> ranting Skenario 5 Kepdatan Sedikit	119
Tabel 100. Hasil <i>Confusion Matrix</i> ranting Skenario 5 Kepdatan Sedikit	119
Tabel 101. Nilai <i>Confusion Matrix</i> daun Skenario 5 Kepdatan Sedikit	120
Tabel 102. Hasil <i>Confusion Matrix</i> daun Skenario 5 Kepdatan Sedikit	120
Tabel 103. Contoh Hasil Skenario 5 Kepadatan Sedang	121
Tabel 104. Nilai <i>Confusion Matrix</i> cengkih Skenario 5 Kepdatan Sedang	122
Tabel 105. Hasil <i>Confusion Matrix</i> cengkih Skenario 5 Kepdatan Sedang	122
Tabel 106. Nilai <i>Confusion Matrix</i> ranting Skenario 5 Kepdatan Sedang	123
Tabel 107. Hasil <i>Confusion Matrix</i> ranting Skenario 5 Kepdatan Sedang	123
Tabel 108. Nilai <i>Confusion Matrix</i> daun Skenario 5 Kepdatan Sedang	124
Tabel 109. Hasil <i>Confusion Matrix</i> daun Skenario 5 Kepadatan Sedang	124
Tabel 110. Contoh Hasil Skenario 5 Kepadatan Padat	124
Tabel 111. Nilai <i>Confusion Matrix</i> cengkih Skenario 5 Kepdatan Padat	127
Tabel 112. Hasil <i>Confusion Matrix</i> cengkih Skenario 5 Kepdatan Padat	127
Tabel 113. Nilai <i>Confusion Matrix</i> ranting Skenario 5 Kepdatan Padat	128
Tabel 114. Hasil <i>Confusion Matrix</i> ranting Skenario 5 Kepdatan Padat	128
Tabel 115. Nilai <i>Confusion Matrix</i> daun Skenario 5 Kepdatan Padat	129
Tabel 116. Hasil <i>Confusion Matrix</i> daun Skenario 5 Kepdatan Padat	129
Tabel 117. Contoh Hasil Skenario 6 Kepadatan Sedikit	129
Tabel 118. Nilai <i>Confusion Matrix</i> cengkih Skenario 6 Kepdatan Sedikit	130
Tabel 119. Hasil <i>Confusion Matrix</i> cengkih Skenario 6 Kepdatan Sedikit	131
). Nilai <i>Confusion Matrix</i> ranting Skenario 6 Kepdatan Sedikit	131
1. Hasil <i>Confusion Matrix</i> ranting Skenario 6 Kepdatan Sedikit	131
2. Nilai <i>Confusion Matrix</i> daun Skenario 6 Kepdatan Sedikit	132
3. Hasil <i>Confusion Matrix</i> daun Skenario 6 Kepdatan Sedikit	132



Tabel 124. Contoh Hasil Skenario 6 Kepadatan Sedang	133
Tabel 125. Nilai <i>Confusion Matrix</i> cengkih Skenario 6 Kepadatan Sedang	134
Tabel 126. Hasil <i>Confusion Matrix</i> cengkih Skenario 6 Kepadatan Sedang	135
Tabel 127. Nilai <i>Confusion Matrix</i> ranting Skenario 6 Kepadatan Sedang.....	135
Tabel 128. Hasil <i>Confusion Matrix</i> ranting Skenario 6 Kepadatan Sedang	135
Tabel 129. Nilai <i>Confusion Matrix</i> daun Skenario 6 Kepadatan Sedang	136
Tabel 130. Hasil <i>Confusion Matrix</i> daun Skenario 6 Kepadatan Sedang.....	136
Tabel 131. Contoh Hasil Skenario 6 Kepadatan padat	137
Tabel 132. Nilai <i>Confusion Matrix</i> cengkih Skenario 6 Kepadatan Padat	139
Tabel 133. Hasil <i>Confusion Matrix</i> cengkih Skenario 6 Kepadatan Padat.....	139
Tabel 134. Nilai <i>Confusion Matrix</i> ranting Skenario 6 Kepadatan Padat.....	139
Tabel 135. Hasil <i>Confusion Matrix</i> ranting Skenario 6 Kepadatan Padat	140
Tabel 136. Nilai <i>Confusion Matrix</i> daun Skenario 6 Kepadatan Padat	140
Tabel 137. Hasil <i>Confusion Matrix</i> daun Skenario 6 Kepadatan Padat.....	140
Tabel 138. Contoh Hasil Skenario 7 Kepadatan Sedikit.....	141
Tabel 139. Nilai <i>Confusion Matrix</i> cengkih Skenario 7 Kepadatan Sedikit.....	142
Tabel 140. Hasil <i>Confusion Matrix</i> cengkih Skenario 7 Kepadatan Sedikit.....	142
Tabel 141. Nilai <i>Confusion Matrix</i> ranting Skenario 7 Kepadatan Sedikit	143
Tabel 142. Hasil <i>Confusion Matrix</i> ranting Skenario 7 Kepadatan Sedikit.....	143
Tabel 143. Nilai <i>Confusion Matrix</i> daun Skenario 7 Kepadatan Sedikit.....	144
Tabel 144. Hasil <i>Confusion Matrix</i> daun Skenario 7 Kepadatan Sedikit	144
Tabel 145. Contoh Hasil Skenario 7 Kepadatan Sedang	145
Tabel 146. Nilai <i>Confusion Matrix</i> cengkih Skenario 7 Kepadatan Sedang.....	146
Tabel 147. Hasil <i>Confusion Matrix</i> cengkih Skenario 7 Kepadatan Sedang	147
Tabel 148. Nilai <i>Confusion Matrix</i> ranting Skenario 7 Kepadatan Sedang.....	147
Tabel 149. Hasil <i>Confusion Matrix</i> ranting Skenario 7 Kepadatan Sedang	147
Tabel 150. Nilai <i>Confusion Matrix</i> daun Skenario 7 Kepadatan Sedang	148
Tabel 151. Hasil <i>Confusion Matrix</i> daun Skenario 7 Kepadatan Sedang.....	148
Tabel 152. Contoh Hasil Skenario 7 Kepadatan Padat	149
Tabel 153. Nilai <i>Confusion Matrix</i> cengkih Skenario 7 Kepadatan Padat	151
Tabel 154. Hasil <i>Confusion Matrix</i> cengkih Skenario 7 Kepadatan Padat.....	151
Tabel 155. Nilai <i>Confusion Matrix</i> ranting Skenario 7 Kepadatan Padat.....	152
Tabel 156. Hasil <i>Confusion Matrix</i> ranting Skenario 7 Kepadatan Padat	152
Tabel 157. Nilai <i>Confusion Matrix</i> daun Skenario 7 Kepadatan Padat	153
Tabel 158. Hasil <i>Confusion Matrix</i> daun Skenario 7 Kepadatan Padat.....	153
Tabel 159. Contoh Hasil Skenario 8 Kepadatan Sedikit.....	154
Tabel 160. Nilai <i>Confusion Matrix</i> cengkih Skenario 8 Kepadatan Sedikit.....	155
Tabel 161. Hasil <i>Confusion Matrix</i> cengkih Skenario 8 Kepadatan Sedikit.....	155
2. Nilai <i>Confusion Matrix</i> ranting Skenario 8 Kepadatan Sedikit	156
3. Hasil <i>Confusion Matrix</i> ranting Skenario 8 Kepadatan Sedikit.....	156
4. Nilai <i>Confusion Matrix</i> daun Skenario 8 Kepadatan Sedikit.....	157
5. Hasil <i>Confusion Matrix</i> daun Skenario 8 Kepadatan Sedikit	157



Tabel 166. Contoh Hasil Skenario 8 Kepadatan Sedang	158
Tabel 167. Nilai <i>Confusion Matrix</i> cengkih Skenario 8 Kepadatan Sedang.....	159
Tabel 168. Hasil <i>Confusion Matrix</i> cengkih Skenario 8 Kepadatan Sedang	160
Tabel 169. Nilai <i>Confusion Matrix</i> ranting Skenario 8 Kepadatan Sedang.....	160
Tabel 170. Hasil <i>Confusion Matrix</i> ranting Skenario 8 Kepadatan Sedang	160
Tabel 171. Nilai <i>Confusion Matrix</i> daun Skenario 8 Kepadatan Sedang	161
Tabel 172. Hasil <i>Confusion Matrix</i> daun Skenario 8 Kepadatan Sedang.....	161
Tabel 173. Contoh Hasil Skenario 8 Kepadatan Padat	162
Tabel 174. Nilai <i>Confusion Matrix</i> cengkih Skenario 8 Kepadatan Padat	164
Tabel 175. Hasil <i>Confusion Matrix</i> cengkih Skenario 8 Kepadatan Padat.....	164
Tabel 176. Nilai <i>Confusion Matrix</i> ranting Skenario 8 Kepadatan Padat.....	165
Tabel 177. Hasil <i>Confusion Matrix</i> ranting Skenario 8 Kepadatan Padat	165
Tabel 178. Nilai <i>Confusion Matrix</i> daun Skenario 8 Kepadatan Padat	166
Tabel 179. Hasil <i>Confusion Matrix</i> daun Skenario 8 Kepadatan Padat.....	166
Tabel 180. Contoh Hasil Skenario 9 Kepadatan Sedikit.....	166
Tabel 181. Nilai <i>Confusion Matrix</i> cengkih Skenario 9 Kepadatan Sedikit.....	168
Tabel 182. Hasil <i>Confusion Matrix</i> cengkih Skenario 9 Kepadatan Sedikit.....	168
Tabel 183. Nilai <i>Confusion Matrix</i> ranting Skenario 9 Kepadatan Sedikit	169
Tabel 184. Hasil <i>Confusion Matrix</i> ranting Skenario 9 Kepadatan Sedikit.....	169
Tabel 185. Nilai <i>Confusion Matrix</i> daun Skenario 9 Kepadatan Sedikit.....	169
Tabel 186. Hasil <i>Confusion Matrix</i> daun Skenario 9 Kepadatan Sedikit	170
Tabel 187. Contoh Hasil Skenario 9 Kepadatan Sedang	170
Tabel 188. Nilai <i>Confusion Matrix</i> cengkih Skenario 9 Kepadatan Sedang.....	172
Tabel 189. Hasil <i>Confusion Matrix</i> cengkih Skenario 9 Kepadatan Sedang	172
Tabel 190. Nilai <i>Confusion Matrix</i> ranting Skenario 9 Kepadatan Sedang.....	173
Tabel 191. Hasil <i>Confusion Matrix</i> ranting Skenario 9 Kepadatan Sedang	173
Tabel 192. Nilai <i>Confusion Matrix</i> daun Skenario 9 Kepadatan Sedang	174
Tabel 193. Hasil <i>Confusion Matrix</i> daun Skenario 9 Kepadatan Sedang.....	174
Tabel 194. Contoh Hasil Skenario 9 Kepadatan Padat	174
Tabel 195. Nilai <i>Confusion Matrix</i> cengkih Skenario 9 Kepadatan Padat	177
Tabel 196. Hasil <i>Confusion Matrix</i> cengkih Skenario 9 Kepadatan Padat.....	177
Tabel 197. Nilai <i>Confusion Matrix</i> ranting Skenario 9 Kepadatan Padat.....	178
Tabel 198. Hasil <i>Confusion Matrix</i> ranting Skenario 9 Kepadatan Padat	178
Tabel 199. Nilai <i>Confusion Matrix</i> daun Skenario 9 Kepadatan Padat	178
Tabel 200. Hasil <i>Confusion Matrix</i> daun Skenario 9 Kepadatan Padat.....	179
Tabel 201. Contoh Hasil Skenario 10 Kepadatan Sedikit.....	179
Tabel 202. Nilai <i>Confusion Matrix</i> cengkih Skenario 10 Kepadatan Sedikit.....	180
Tabel 203. Hasil <i>Confusion Matrix</i> cengkih Skenario 10 Kepadatan Sedikit.....	181
4. Nilai <i>Confusion Matrix</i> ranting Skenario 10 Kepadatan Sedikit	181
5. Hasil <i>Confusion Matrix</i> ranting Skenario 10 Kepadatan Sedikit.....	181
3. Nilai <i>Confusion Matrix</i> daun Skenario 10 Kepadatan Sedikit.....	182
7. Hasil <i>Confusion Matrix</i> daun Skenario 10 Kepadatan Sedikit	182



Tabel 208. Contoh Hasil Skenario 10 Kepadatan Sedang	183
Tabel 209. Nilai <i>Confusion Matrix</i> cengkih Skenario 10 Kepadatan Sedang.....	184
Tabel 210. Hasil <i>Confusion Matrix</i> cengkih Skenario 10 Kepadatan Sedang	185
Tabel 211. Nilai <i>Confusion Matrix</i> ranting Skenario 10 Kepadatan Sedang.....	185
Tabel 212. Hasil <i>Confusion Matrix</i> ranting Skenario 10 Kepadatan Sedang	185
Tabel 213. Nilai <i>Confusion Matrix</i> daun Skenario 10 Kepadatan Sedang	186
Tabel 214. Hasil <i>Confusion Matrix</i> daun Skenario 10 Kepadatan Sedang.....	186
Tabel 215. Contoh Hasil Skenario 10 Kepadatan Padat	187
Tabel 216. Nilai <i>Confusion Matrix</i> cengkih Skenario 10 Kepadatan Padat	189
Tabel 217. Hasil <i>Confusion Matrix</i> cengkih Skenario 10 Kepadatan Padat.....	189
Tabel 218. Nilai <i>Confusion Matrix</i> ranting Skenario 10 Kepadatan Padat.....	190
Tabel 219. Hasil <i>Confusion Matrix</i> ranting Skenario 10 Kepadatan Padat	190
Tabel 220. Nilai <i>Confusion Matrix</i> daun Skenario 10 Kepadatan Padat	191
Tabel 221. Hasil <i>Confusion Matrix</i> daun Skenario 10 Kepadatan Padat.....	191
Tabel 222. Perbandingan Hasil Skenario Pada Kelas Cengkih.....	192
Tabel 223. Perbandingan Hasil Skenario Pada Kelas Ranting	193
Tabel 224. Perbandingan Hasil Skenario Pada Kelas Daun	194
Tabel 225. Grafik Perbandingan Akurasi Kelas Cengkih Hasil Kecepatan 60,70, 80, 90, 100, 110, 120, 130,140,45,29 rpm ketika tanpa augmentasi	196
Tabel 226. Grafik Perbandingan Akurasi Kelas Ranting Hasil Kecepatan 60,70, 80, 90, 100, 110, 120, 130,140,45,29 rpm ketika tanpa augmentasi.	197
Tabel 227. Grafik Perbandingan Akurasi Kelas Daun Hasil Kecepatan 60,70, 80, 90, 100, 110, 120, 130,140,45,29 rpm ketika tanpa augmentasi.	198



DAFTAR GAMBAR

Gambar 1. Cengkih Kering	6
Gambar 2. Jenis Objek Penelitian ini (a) cengkih, (b) ranting, dan (c) daun.....	7
Gambar 3. Hubungan Antara <i>AI</i> , <i>ML</i> , dan <i>DL</i>	8
Gambar 4. Cara Kerja <i>ML</i> dan <i>DL</i>	9
Gambar 5. Sistem penglihatan manusia	10
Gambar 6. Sistem penglihatan komputer	10
Gambar 7. Ilustrasi median blur.....	13
Gambar 8. Contoh efek blur gerakan cepat.....	13
Gambar 9. Contoh Hasil Kecerahan Kontras: (a) Citra original; (b) Citra hasil kecerahan kontras	14
Gambar 10. Contoh hasil <i>bounding box</i>	14
Gambar 11. Arsitektur CNN	15
Gambar 12. Diagram Prinsip RPN.....	17
Gambar 13. Faster R-CNN <i>basic operation process</i>	18
Gambar 14. <i>ResNet50 Architecture</i>	19
Gambar 15. Bagian <i>Residual Block</i> (a) Blok Regular dan (b) Blok <i>Residual</i>	19
Gambar 16. Tampilan <i>Google Collab</i>	21
Gambar 17. <i>User Interface IDE Jupyter Notebook</i>	21
Gambar 18. <i>Confusion matrix</i>	24
Gambar 19. Kerangka Pikir.....	30
Gambar 20. Tahapan Penelitian	33
Gambar 21. Lokasi Pengambilan Data Petani Cengkih	35
Gambar 22. Teknik Pengambilan Data <i>pada Belt conveyor</i>	36
Gambar 23. Ilustrasi Pengambilan Data Ketika Sampai Kepemilahan.....	36
Gambar 24. Jenis <i>class</i> pada penelitian ini (a) cengkih, (b) ranting (c) daun.....	37
Gambar 25. Kode mengubah kecepatan rpm pada <i>belt conveyor</i>	42
Gambar 26. Diagram Blok Sistem	45
Gambar 27. Contoh hasil perbandingan (a) Sebelum proses <i>orientation image and resize image</i> , (b) Setelah proses <i>orientation image and resize image</i>	47
Gambar 28. Ilustrasi hasil augmentasi <i>median blur, motion blur and brightness contrast</i>	48
Gambar 29. <i>Flowchart</i> Anotasi dan <i>Labelling</i>	49
Gambar 30. Anotasi menggunakan roboflow	49
Gambar 31. Informasi dataset anotasi situs roboflow tanpa augmentasi	50
Gambar 32. Informasi dataset anotasi situs roboflow menggunakan augmentasi	50
Gambar 33. Model Faster R-CNN	50
34. <i>Backbone ResNet50</i>	52
35. Hasil perbandingan training tanpa dan menggunakan augmentasi	61
36. Contoh hasil deteksi sistem skenario 1 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi.....	65



Gambar 37. Contoh hasil perhitungan pengujian cengkih skenario 1 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	66
Gambar 38. Contoh hasil perhitungan pengujian ranting skenario 1 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi.	67
Gambar 39. Contoh hasil perhitungan pengujian daun skenario 1 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	68
Gambar 40. Contoh hasil deteksi sistem skenario 18,11 rpm kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.	70
Gambar 41. Contoh hasil perhitungan pengujian cengkih skenario 1 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	70
Gambar 42. Contoh hasil perhitungan pengujian ranting skenario 1 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	71
Gambar 43. Contoh hasil perhitungan pengujian daun skenario 1 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	72
Gambar 44. Contoh hasil deteksi sistem skenario 1 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.	75
Gambar 45. Contoh hasil perhitungan pengujian cengkih skenario 1 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi	76
Gambar 46. Contoh hasil perhitungan pengujian ranting skenario 1 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.	77
Gambar 47. Contoh hasil perhitungan pengujian daun skenario 1 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.....	78
Gambar 48. Contoh hasil deteksi sistem skenario 2 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi.....	79
Gambar 49. Contoh hasil perhitungan pengujian cengkih skenario 2 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	80
Gambar 50. Contoh hasil perhitungan pengujian ranting skenario 2 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi.	81
Gambar 51. Contoh hasil perhitungan pengujian daun skenario 2 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	82
Gambar 52. Contoh hasil deteksi sistem skenario 2 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	84
Gambar 53. Contoh hasil perhitungan pengujian cengkih skenario 2 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	84
Gambar 54. Contoh hasil perhitungan pengujian ranting skenario 2 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	85
Gambar 55. Contoh hasil perhitungan pengujian daun skenario 2 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	86
56. Contoh hasil deteksi sistem skenario 2 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.....	88
57. Contoh hasil perhitungan pengujian cengkih 21,13 rpm kepadatan t, (a) tanpa augmentasi (b) menggunakan augmentasi	89



Gambar 58. Contoh hasil perhitungan pengujian ranting 21,13 rpm kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.	90
Gambar 59. Contoh hasil perhitungan pengujian daun 21,13 rpm kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.....	91
Gambar 60. Contoh hasil deteksi sistem skenario 3 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi.....	92
Gambar 61. Contoh hasil perhitungan pengujian cengkih skenario 3 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	93
Gambar 62. Contoh hasil perhitungan pengujian ranting skenario 3 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi.	94
Gambar 63. Contoh hasil perhitungan pengujian daun skenario 3 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	95
Gambar 64. Contoh hasil deteksi sistem skenario 3 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	97
Gambar 65. Contoh hasil perhitungan cengkih pengujian 3 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi	97
Gambar 66. Contoh hasil perhitungan ranting pengujian 3 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.	98
Gambar 67. Contoh hasil perhitungan daun pengujian 3 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi	99
Gambar 68. Contoh hasil deteksi sistem skenario 3 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.....	102
Gambar 69. Contoh hasil perhitungan pengujian skenario 3 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi	102
Gambar 70. Contoh hasil perhitungan pengujian ranting skenario 3 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.	103
Gambar 71. Contoh hasil perhitungan pengujian daun skenario 3 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.....	104
Gambar 72. Contoh hasil deteksi sistem skenario 27,11 rpm kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi.	106
Gambar 73. Contoh hasil perhitungan pengujian cengkih skenario 4 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	106
Gambar 74. Contoh hasil perhitungan pengujian ranting skenario 4 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi.	107
Gambar 75. Contoh hasil perhitungan pengujian daun skenario 4 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	108
Gambar 76. Contoh hasil deteksi sistem skenario 4 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	110
77. Contoh hasil perhitungan pengujian cengkih skenario 4 kepadatan ng, (a) tanpa augmentasi (b) menggunakan augmentasi.....	110
78. Contoh hasil perhitungan pengujian ranting skenario 4 kepadatan ng, (a) tanpa augmentasi (b) menggunakan augmentasi.....	111



Gambar 79. Contoh hasil perhitungan pengujian daun skenario 4 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	112
Gambar 80. Contoh hasil deteksi sistem skenario 4 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.....	114
Gambar 81. Contoh hasil perhitungan cengkih pengujian skenario 4 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi	115
Gambar 82. Contoh hasil perhitungan ranting pengujian skenario 4 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.	116
Gambar 83. Contoh hasil perhitungan daun pengujian skenario 4 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.....	116
Gambar 84. Contoh hasil deteksi sistem skenario 5 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi.....	118
Gambar 85. Contoh hasil perhitungan pengujian cengkih skenario 5 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	118
Gambar 86. Contoh hasil perhitungan pengujian ranting skenario 5 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi.	119
Gambar 87. Contoh hasil perhitungan pengujian daun skenario 5 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	120
Gambar 88. Contoh hasil deteksi sistem skenario 5 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	121
Gambar 89. Contoh hasil perhitungan cengkih pengujian 5 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi	122
Gambar 90. Contoh hasil perhitungan ranting pengujian 5 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.	123
Gambar 91. Contoh hasil perhitungan daun pengujian 5 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi	124
Gambar 92. Contoh hasil deteksi sistem skenario 5 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.....	126
Gambar 93. Contoh hasil perhitungan cengkih pengujian 5 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi	127
Gambar 94. Contoh hasil perhitungan ranting pengujian 5 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.	128
Gambar 95. Contoh hasil perhitungan daun pengujian 5 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.....	129
Gambar 96. Contoh hasil deteksi sistem skenario 33,21 rpm kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi.	130
Gambar 97. Contoh hasil perhitungan cengkih pengujian skenario 6 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	130
Gambar 98. Contoh hasil perhitungan ranting pengujian skenario 6 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	131
Gambar 99. Contoh hasil perhitungan daun pengujian skenario 6 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	132



Gambar 100. Contoh hasil deteksi sistem skenario 6 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	134
Gambar 101. Contoh hasil perhitungan pengujian cengkih skenario 6 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	134
Gambar 102. Contoh hasil perhitungan pengujian ranting skenario 6 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	135
Gambar 103. Contoh hasil perhitungan pengujian daun skenario 6 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	136
Gambar 104. Contoh hasil deteksi sistem skenario 6 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.....	138
Gambar 105. Contoh hasil perhitungan pengujian cengkih skenario 6 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi	138
Gambar 106. Contoh hasil perhitungan pengujian ranting skenario 6 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.	139
Gambar 107. Contoh hasil perhitungan pengujian daun skenario 6 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi	140
Gambar 108. Contoh hasil deteksi sistem skenario 7 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi.....	141
Gambar 109. Contoh hasil perhitungan pengujian cengkih skenario 7 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	142
Gambar 110. Contoh hasil perhitungan pengujian ranting skenario 7 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi.	143
Gambar 111. Contoh hasil perhitungan pengujian daun skenario 7 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	144
Gambar 112. Contoh hasil deteksi sistem skenario 7 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	146
Gambar 113. Contoh hasil perhitungan pengujian cengkih skenario 7 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	146
Gambar 114. Contoh hasil perhitungan pengujian ranting skenario 7 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	147
Gambar 115. Contoh hasil perhitungan pengujian daun skenario 7 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	148
Gambar 116. Contoh hasil deteksi sistem skenario 7 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	150
Gambar 117. Contoh hasil perhitungan pengujian cengkih 36,23 rpm kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi	151
Gambar 118. Contoh hasil perhitungan pengujian ranting 36,23 rpm kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.	152
Gambar 119. Contoh hasil perhitungan pengujian daun 36,23 rpm kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi	153
Gambar 120. Contoh hasil deteksi sistem skenario 8 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi.....	154



Gambar 121. Contoh hasil perhitungan pengujian cengkih skenario 8 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	155
Gambar 122. Contoh hasil perhitungan pengujian ranting skenario 8 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	156
Gambar 123. Contoh hasil perhitungan pengujian daun skenario 8 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	157
Gambar 124. Contoh hasil deteksi sistem skenario 8 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	159
Gambar 125. Contoh hasil perhitungan pengujian cengkih skenario 8 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	159
Gambar 126. Contoh hasil perhitungan pengujian ranting skenario 8 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	160
Gambar 127. Contoh hasil perhitungan pengujian daun skenario 8 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	161
Gambar 128. Contoh hasil deteksi sistem skenario 8 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.....	163
Gambar 129. Contoh hasil perhitungan pengujian cengkih skenario 8 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi	164
Gambar 130. Contoh hasil perhitungan pengujian ranting skenario 8 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.	164
Gambar 131. Contoh hasil perhitungan pengujian daun skenario 8 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi	165
Gambar 132. Contoh hasil deteksi sistem skenario 9 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi.....	167
Gambar 133. Contoh hasil perhitungan pengujian cengkih skenario 9 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	167
Gambar 134. Contoh hasil perhitungan pengujian ranting skenario 9 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	168
Gambar 135. Contoh hasil perhitungan pengujian daun skenario 9 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	169
Gambar 136. Contoh hasil deteksi sistem skenario 9 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	171
Gambar 137. Contoh hasil perhitungan pengujian cengkih skenario 9 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	171
Gambar 138. Contoh hasil perhitungan pengujian ranting skenario 9 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	172
Gambar 139. Contoh hasil perhitungan pengujian daun skenario 9 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	173
l40. Contoh hasil deteksi sistem skenario 9 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.....	176
l41. Contoh hasil perhitungan pengujian cengkih skenario 9 kepadatan t, (a) tanpa augmentasi (b) menggunakan augmentasi	176



Gambar 142. Contoh hasil perhitungan pengujian ranting skenario 9 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.	177
Gambar 143. Contoh hasil perhitungan pengujian daun skenario 9 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi	178
Gambar 144. Contoh hasil deteksi sistem skenario 10 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi.....	180
Gambar 145. Contoh hasil perhitungan pengujian cengkih skenario 10 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	180
Gambar 146. Contoh hasil perhitungan pengujian ranting skenario 10 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi.	181
Gambar 147. Contoh hasil perhitungan pengujian daun skenario 10 kepadatan sedikit, (a) tanpa augmentasi (b) menggunakan augmentasi	182
Gambar 148. Contoh hasil deteksi sistem skenario 45,29 rpm kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	184
Gambar 149. Contoh hasil perhitungan pengujian cengkih skenario 10 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	184
Gambar 150. Contoh hasil perhitungan pengujian ranting skenario 10 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	185
Gambar 151. Contoh hasil perhitungan pengujian daun skenario 10 kepadatan sedang, (a) tanpa augmentasi (b) menggunakan augmentasi.....	186
Gambar 152. Contoh hasil deteksi sistem skenario 10 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.....	188
Gambar 153. Contoh hasil perhitungan pengujian cengkih skenario 10 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi	189
Gambar 154. Contoh hasil perhitungan pengujian ranting skenario 10 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi.	190
Gambar 155. Contoh hasil perhitungan pengujian daun skenario 10 kepadatan padat, (a) tanpa augmentasi (b) menggunakan augmentasi	191



BAB I

PENDAHULUAN

1.1 Latar Belakang

Syzygium aromaticum, syn. *Eugenia aromaticum* atau biasa dikenal dengan cengkih merupakan salah satu komoditas unggulan Indonesia yang memiliki peran penting dalam ekonomi negara (Malahika et al., 2018). Saat ini Indonesia merupakan negara produsen, sekaligus konsumen cengkih terbesar di dunia (“Produksi Cengkeh Indonesia Terbesar di Dunia | Databoks.” 2020). Salah satu agribisnis hilir tani wilayah penghasil cengkih terdapat di jalan poros Bone-Sinjai tepatnya Desa Teko, Tanete Riaattang Kec. Cina Kab.Bone Sulawesi Selatan, Indonesia. Usaha agribisnis hilir yang dapat dilakukan salah satunya meliputi peningkatan mutu bunga cengkih kering melalui perbaikan penanganan pascapanen (perontokan, sortasi basah untuk memisahkan bunga dan tangkai bunga dan kotoran, pengeringan bunga dan tangkai bunga, pengemasan dan penyimpanan) (“Tanaman Cengkih (*Syzygium aromaticum*) | Dinas Pertanian.” 2018).

Namun, hasil dari wawancara yang dilakukan peneliti dengan beberapa petani cengkih yang ada di Kab. Bone mengatakan, bahwa masalah yang sering dihadapi oleh petani cengkih adalah kesulitan dalam memisahkan cengkih dengan puing (ranting dan daun) setelah proses pengeringan terkadang masih ada puing (ranting dan daun) pada saat dilakukan penimbangan. Hal ini menyebabkan adanya penambahan berat pada saat masuk ke dalam proses penimbangan cengkih, oleh karena itu diperlukan sebuah deteksi objek yang dapat mengklasifikasikan cengkih dari puing (ranting dan daun).

Klasifikasi cengkih dan puing (ranting dan daun) dapat dilakukan menggunakan berbagai teknologi, salah satunya adalah pengolahan citra. Pengolahan citra adalah salah satu cara yang efektif untuk mendeteksi cengkih dan puing (ranting dan daun) dalam gambar (Pesik et al., 2018).



Computer vision dapat membantu mengisolasi cengkih dan puing (ranting dan daun) dari latar belakang, sehingga memungkinkan penggunaan teknik klasifikasi yang lebih mudah. Beberapa teknik pengolahan citra yang umum digunakan

dalam deteksi cengkih meliputi segmentasi citra, ekstraksi fitur, dan pengklasifikasian. Pada dasarnya, *computer vision* bekerja dengan memanfaatkan data video dan gambar yang telah diproses untuk menghasilkan informasi yang dibutuhkan (Putra, 2010). Hal ini memungkinkan juga diterapkan pada industri pertanian seperti untuk pengenalan buah, pemetaan, klasifikasi kematangan buah, dan pembuatan sistem untuk melakukan sorting buah dan sampah.

Adapun beberapa penelitian terkait mengenai cengkih telah dilakukan oleh beberapa peneliti, salah satunya adalah klasifikasi kualitas bunga cengkih kering berdasarkan ukuran dan warna menggunakan metode GLCM (*Gray Level Co-Occurrence Matrix*) dengan 32 sampel memberikan akurasi 92,50% (Yaspin et al., 2020). Penelitian selanjutnya tentang klasifikasi kualitas bunga cengkih kering dengan menggunakan metode *Deep learning* dan algoritma *Convolutional Neural Network* (CNN). Penelitian ini menghasilkan akurasi akhir sebesar 87,75%. Namun, penelitian sebelumnya hanya melakukan deteksi *single detection* dan tidak melakukan pengolahan data secara *real-time* (Prayogi et al., 2021).

Selanjutnya, telah dilakukan penelitian mengenai cara memisahkan buah-buahan berdasarkan tingkat kematangan dengan menggunakan algoritma *Support Vector Machine* (SVM). Salah satu contoh penelitian ini adalah tentang penggunaan SVM untuk mengklasifikasikan kematangan stroberi berdasarkan warna kulitnya. Salah satu kontribusi utama dari penelitian tersebut adalah pembuatan prototype alat yang dapat menyortir stroberi matang dan tidak matang secara otomatis secara *real-time* hingga memperoleh akurasi 85,64%. Namun, pada penelitian ini tidak terdapat perbandingan kecepatan yang di implementasikan pada alat penyortir buah stroberi (Indrabayu et al., 2019).

Penelitian tentang deteksi kematangan buah secara *real-time* menggunakan Model Jaringan Saraf *Deep Neural Network Faster R-CNN*. Tujuan dari penelitian ini adalah untuk mengembangkan model deteksi objek yang dapat secara akurat, mendeteksi buah-buahan yang telah matang secara *real-time* menggunakan algoritma *deep learning* *Faster R-CNN* dengan arsitektur VCG16, ResNet50 dan V2 untuk pengembangan model deteksi buah. Nilai presisi rata-rata deteksi buah yang dihasilkan adalah 0,87. Namun, penelitian ini memiliki



kelemahan, seperti kurangnya penjelasan yang rinci tentang arsitektur model yang digunakan (C et al., 2022).

Untuk itu dibutuhkan arsitektur model yang dapat menjadi landasan dalam mendeteksi cengkih dan puing (daun dan ranting). Penelitian tersebut membahas tentang Deteksi Otomatis Tomat Matang Tunggal pada Tanaman Menggabungkan Faster R-CNN dan Set Fuzzy intuitionistic. Hasil *root mean square error* (RMSE) masing-masing adalah 0,26% dan 1,18%. Hasil penelitian menunjukkan bahwa pengklasifikasi Faster R-CNN yang lebih cepat dapat secara akurat dan cepat melokalisasi calon daerah tomat matang. Namun, dalam penelitian ini tidak dibahas mengenai perbaikan citra untuk meningkatkan hasil selama proses pelatihan data (Hu et al., 2019).

Penelitian selanjutnya, Peningkatan Presisi Deteksi Kecambah Air Berbasis Mask R-CNN dengan Data *Augmentation*. Penelitian ini bertujuan untuk meningkatkan akurasi identifikasi tunas air dengan mengaplikasikan teknik augmentasi data, suatu metode yang bertujuan untuk memperluas variasi dalam data latihan yang digunakan. Pada tahap pengujian, model dengan tingkat pembelajaran 0,01 dan augmentasi data telah menghasilkan F1 skor sebesar 0,96 pada ambang batas 0,80. Hasil ini menunjukkan bahwa pendekatan yang diusulkan berhasil meningkatkan presisi deteksi kecambah air secara signifikan (Areni et al., 2023).

Sebelumnya, beberapa penelitian yang berkaitan dengan cengkih telah dilakukan. Namun, belum ada solusi yang ditemukan untuk mengatasi pemisahan cengkih kering dari puing (daun dan ranting). Dalam pemilahan antara cengkih dan puing (ranting serta daun) menggunakan sistem *belt conveyor* dengan kecepatan tinggi, ditemui kesulitan dalam memproses citra yang terdistorsi, terutama terkait citra yang bergerak dan kabur. Oleh karena itu, studi ini bertujuan untuk mengembangkan suatu model yang mampu mendeteksi dan mengklasifikasikan cengkih dan puing (ranting serta daun) dalam masalah citra yang muncul pada *belt conveyor*.



Salah satu tujuan utama dari penelitian ini adalah mendeteksi dan klasifikasi cengkih dan puing (ranting dan daun). Pendekatan yang diambil dengan memanfaatkan Faster R-CNN yang telah terbukti memiliki kinerja yang unggul dalam

mendeteksi objek dalam citra (Hu et al., 2019). Penelitian ini juga akan mempertimbangkan penggunaan teknik augmentasi data untuk meningkatkan kehandalan model dalam mendeteksi dan mengklasifikasi (Areni et al., 2023). Dengan demikian, penelitian ini diharapkan dapat memberikan solusi terhadap permasalahan yang dihadapi dalam proses identifikasi antara cengkih dan puing (ranting serta daun) pada sistem belt conveyor (Indrabayu et al., 2019).

1.2 Rumusan Masalah

Berdasarkan latar belakang masalah, rumusan masalah pada penelitian ini adalah:

1. Bagaimana sistem dapat mendeteksi dan mengklasifikasi cengkih serta puing (ranting dan daun) melalui pendekatan computer vision, dengan penekanan pada peningkatan kualitas deteksi dan klasifikasi objek dalam berbagai skenario pengujian menggunakan teknik augmentasi data?
2. Bagaimana unjuk kerja sistem dalam mendeteksi dan mengklasifikasi cengkeh dan puing (ranting dan daun)?

1.3 Tujuan Penelitian

Tujuan penelitian ini adalah:

1. Membuat sistem yang dapat mendeteksi dan mengklasifikasi cengkih serta puing (ranting dan daun) melalui pendekatan computer vision, dengan penekanan pada peningkatan kualitas deteksi dan klasifikasi objek dalam berbagai skenario pengujian menggunakan teknik augmentasi data.
2. Mengetahui unjuk kerja sistem dalam mendeteksi dan mengklasifikasi objek cengkih dan puing (ranting dan daun).

1.4 Manfaat Penelitian

yang dapat diperoleh dari penelitian ini adalah sebagai berikut:



1. Bagi peneliti, pengaplikasian dari sejumlah konsep dan pengetahuan yang berguna untuk menambah pengetahuan ataupun kemampuan/skill mengenai proses pengenalan pola untuk mendeteksi dan mengklasifikasi jenis cengkih dan puing (daun dan ranting).
2. Bagi pemerintah khususnya pada agribisnis, dapat digunakan sebagai prototype alat yang membantu proses pemilahan cengkih dan puing (daun dan ranting) secara otomatis.
3. Bagi institusi Pendidikan Magister Teknik Informatika, dapat digunakan sebagai referensi ilmiah dalam penelitian untuk pengembangan *system* untuk mendeteksi dan mengklasifikasi dengan objek atau kasus yang berbeda.

1.5 Ruang Lingkup Penelitian

Adapun ruang lingkup pada penelitian ini adalah:

1. Sampel yang digunakan adalah cengkih dan puing (daun dan ranting).
2. Kelas yang dideteksi hanya cengkih kering, daun kering dan ranting kering.
3. Lokasi pengambilan cengkih dilakukan di usaha dagang Karya Tani di daerah Kab.Bone.
4. Pengambilan data menggunakan *belt conveyor* dengan kecepatan (18,11 21,13 24,15 27,11 30,19 33,21 36,23 39,25 42,27 45,29 rpm) dan tingkat kepadatan sedikit, sedang, padat.
5. Kamera yang digunakan Logitech dengan resolusi 1080p/30 atau 60 fps (maksimal 1920 x 1080 piksel).
6. Untuk mengatasi perbedaan kontras selama proses pengambilan data, digunakan penerangan tambahan dalam bentuk lampu LED yang diposisikan di dalam kotak pengambilan gambar yang terletak pada belt conveyor.



BAB II

TINJAUAN PUSTAKA

2.1 Landasan Teori

2.1.1 Pengertian Cengkih (*Cengkih*)

Syzygium aromaticum, syn. *Eugenia aromaticum* atau biasa dikenal dengan cengkih merupakan tanaman rempah asli bumi Nusantara Indonesia yang tergolong ke dalam jenis tanaman tropis yang hasil panennya bisa dirasakan setelah tanaman berumur 4-5 tahun (Yaspin et al., 2020). Bunga cengkih merupakan bagian yang sering digunakan dan dikeringkan oleh petani hingga warnanya menjadi kecokelatan. Setelah proses tersebut, petani menyortir bunga cengkih kering berdasarkan kualitasnya dengan menggunakan penilaian visual sesuai ukuran dan warnanya (“Tanaman cengkih (*Syzygium aromaticum*) | Dinas Pertanian.” 2018). Contoh cengkih kering dapat dilihat pada Gambar1 berikut.



Gambar 1.Cengkih Kering


2.1.2 Pengolahan Bunga Cengkih

Pengolahan cengkih pasca panen yaitu cengkih dijemur di bawah sinar matahari hingga mengalami penyusutan dan perubahan warna menjadi cokelat kemudian petani menyortir cengkih yang berkualitas baik berdasarkan ukuran dari petani tersebut sehingga hasil klasifikasi penilaian mutu cengkih berbeda-beda tergantung pada penilaian masing-masing petani (Pesik et al., 2018).



Proses pengolahan bunga cengkih sampai mendapatkan bunga cengkih yang kering melalui beberapa tahap, yaitu: panen, perontokan (pemisahan gagang dan bunga), pemeraman, pengeringan dan sortasi. Bunga cengkih dipanen pada waktu beberapa bunga dalam satu rangkaian bunga sudah berwarna kemerah-merahan. Sesudah panen dilakukan pemisahan bunga dengan tangkainya yang biasa dilakukan dengan tangan (secara manual) (Nurdjannah, 2004).

Dari hasil pemisahan gagang (ranting) dan bunga terkadang hasilnya masih tercampur dengan gagang (ranting) dan daun, sehingga pada saat proses penjemuran terkadang dari beberapa daun dan ranting ikut pada proses penjemuran. Cengkih kering yang dijual ke pengepul masih dalam tercampur dengan puing (ranting dan daun) seperti pada Gambar 2 berikut.



Gambar 2. Jenis Objek Penelitian ini (a) cengkih, (b) ranting, dan (c) daun

2.1.3 Tingkat Pemasaran Cengkih

Indonesia adalah produsen dan konsumen cengkih *Syzigium aromaticum* terbesar dunia, Pada tahun 2016, total produksi cengkih dunia sekitar 180,49 ton dan sekitar 139,52 ton atau 77,30% dari jumlah tersebut berasal dari Indonesia (BPS, 2019). Di Indonesia, produsen cengkih terbesar berada di Pulau Sulawesi kemudian diikuti oleh Kepulauan Maluku. Sekitar 60% produksi cengkih Indonesia berasal dari Pulau Sulawesi (Tulungen, 2019).

Harga cengkih di Sulawesi bervariasi menurut musim, pada musim panen raya tahun 2016 harga per kg Rp 40.000 dan pada musim bukan panen raya, tahun 2018 harga per kg Rp 150.000-175.000 per kg. Fluktuasi harga cengkih dapat dengan penganekaragam pemanfaatan cengkih dan produk turunannya. bervariasi pemanfaatan cengkih, maka semakin banyak pula permintaan




akan cengkih. Akibatnya harga cengkih akan semakin baik, yang pada gilirannya akan menguntungkan petani (Tulungen, 2019).

Usaha agribisnis hilir yang dapat dilakukan salah satunya meliputi peningkatan mutu bunga cengkih kering melalui perbaikan penanganan pascapanen (perontokan, sortasi basah untuk memisahkan bunga dan tangkai bunga dan kotoran, pengeringan bunga dan tangkai bunga, pengemasan dan penyimpanan) (“Tanaman Cengkih (*Syzigium aromaticum*) | Dinas Pertanian,” 2018).

2.1.4 Artificial Intelligence (AI)

Artificial Intelligence (AI), atau dalam bahasa Indonesia dikenal dengan Kecerdasan Buatan adalah cabang ilmu komputer yang berfokus pada pembuatan dan penerapan perangkat lunak dan algoritma yang dapat melakukan tugas-tugas yang biasanya memerlukan intervensi dan kecerdasan manusia. AI adalah topik yang mencakup bidang ilmu *Machine Learning* (ML) dan *Deep Learning* (DL). Skema hubungan antara AI ML dan DL dapat dilihat pada gambar 3.



Gambar 3. Hubungan Antara AI, ML, dan DL (Elgendy, 2020)


Machine Learning (ML) adalah bagian dari AI yang menggunakan metode statistik, dengan metode tersebut memungkinkan mesin (komputer) untuk mengambil keputusan berdasarkan data. Algoritma *machine learning* dirancang

at belajar dan kemampuannya meningkat seiring waktu ketika terdapat 1, tanpa diprogram secara eksplisit (Seema Singh, 2018) (Priyanto llah, 2021). Contoh penerapan *machine learning* adalah sebuah sistem



yang dapat mendeteksi penyakit jantung berdasarkan rekaman elektrokardiogram (EKG).

Deep Learning (DL) adalah jenis dari *machine learning* yang terinspirasi oleh fungsi sel otak manusia yang disebut neuron, dari inspirasi itulah terdapat konsep yang dinamakan *Neural network (NN)*. Namun pada *Deep learning neural network*-nya lebih dari dua lapisan. Selain itu terdapat beberapa hal yang menjadi evolusi *neural network* pada *deep learning* lebih banyak neuron dari jaringan sebelumnya, cara yang lebih kompleks untuk menghubungkan lapisan/neuron dan ekstraksi fitur otomatis (Vinet and Zhedanov, 2011). Belum ada panduan yang betul-betul solid dalam menentukan jumlah *hidden layer* pada sebuah arsitektur model *deep learning* (Priyanto Hidayatullah, 2021). Terdapat perbedaan antara algoritma *machine learning* tradisional dengan algoritma *deep learning* pada *computer vision*. Pada algoritma *machine learning* tradisional dilakukan ekstraksi fitur yang menghasilkan vektor fitur, setelah itu diklasifikasikan menggunakan algoritma *machine learning*. Sedangkan pada *deep learning*, ekstraksi fitur dan klasifikasi dilakukan oleh *neural network*. Ilustrasi cara kerja *DL* dan *ML* dapat dilihat pada Gambar 4.



Gambar 4. Cara Kerja *ML* dan *DL* (Elgendy, 2020).


2.1.5 Computer Vision

Computer vision adalah sebuah sub bidang dari *Artificial Intelligence (AI)* yang fokus dengan persepsi visual. Bagi manusia persepsi visual pada dasarnya dilakukan mengamati pola dan objek melalui penglihatan atau input visual (Elgendy, 2020). Contohnya memperhatikan lingkungan sekitar saat mengemudi, di harus dengan memahami objek apa saja yang ada. Jika terdapat objek




seperti pejalan kaki atau kendaraan lain pada jarak yang dekat, maka pengemudi tersebut harus mengambil tindakan diantara-Nya adalah mengerem kendaraannya.

Secara sederhana sistem penglihatan manusia terdiri dari sensor atau mata untuk menangkap citra dan otak untuk memproses serta menafsirkan citra. Sistem penglihatan manusia diilustrasikan pada Gambar 5.



Gambar 5. Sistem penglihatan manusia (Elgendy, 2020).

Sistem penglihatan komputer juga hampir sama dengan sistem penglihatan manusia. Komputer membutuhkan dua komponen utama untuk melihat layaknya manusia yaitu yaitu *sensing device* untuk meniru fungsi mata dan *interpreting device* untuk meniru fungsi otak. Sistem penglihatan komputer seperti pada Gambar 6.



Gambar 6. Sistem penglihatan komputer (Elgendy, 2020)

Sensing device merupakan perangkat penginderaan komputer, perangkat tersebut dipilih sesuai dengan apa yang akan dilihat. Contohnya kamera, radar, sinar-X, dan *CT scan*. *Interpreting device* merupakan program yang diterapkan komputer untuk memproses dan menafsirkan Citra. Para ilmuwan si oleh cara kerja otak manusia dan mencoba merekayasa sistem saraf membangun otak buatan yang dikenal dengan *artificial neural network* (Elgendy, 2020).



Terdapat beberapa tugas yang sering dilakukan oleh *computer vision* diantaranya:

a. Klasifikasi Gambar (*Image classification*)

Klasifikasi Gambar adalah penentuan kategori sebuah citra berdasarkan objek yang terkandung di dalamnya. Masukan dari klasifikasi gambar adalah citra dengan satu objek. Sedangkan outputnya adalah hasil klasifikasi objek atau objek apa yang ada pada citra input dengan nilai probabilitasnya (Hidayatullah, 2021).

Terdapat beberapa algoritma yang dapat digunakan untuk melakukan klasifikasi gambar:

- *Convolutional Neural Network (CNN)*
- *Local Binary Pattern (LBP) + Support Vector Machine (SVM)*
- *Histogram of Oriented Gradients (HOG) + Support Vector Machine (SVM)*
- *Histogram of Oriented Gradients (HOG) + K Nearest Neighbours (KNN)*

b. Deteksi Objek (*Object Detection*)

Deteksi Objek menggabungkan klasifikasi dan lokalisasi, pada deteksi objek dapat mendeteksi banyak objek pada suatu citra atau video. Tujuan utama deteksi objek adalah memprediksi lokasi objek dengan *bounding box* atau kotak pembatas dan melakukan klasifikasi objek yang ada pada setiap *bounding box*. Input pada deteksi objek adalah citra yang mengandung satu atau lebih objek, outputnya adalah hasil prediksi lokasi Objek dengan *bounding box* dan klasifikasi objek setiap *bounding box* (Elgendy, 2020). Terdapat beberapa model deteksi objek yang memiliki kinerja yang sangat bagus. Model tersebut antara lain:

- *You On/y Look Once (YOLO)*
- *EfficientDet*
- *Single Shot Mu/tiBox Detector (SSD)*

aster Region Based Convo/utiona/ Neural Network (Faster- RCNN)



2.1.6 Augmentasi (*Augmentation*)


Augmentasi (*augmentation*) dalam konteks pengolahan citra merujuk pada teknik atau proses untuk membuat variasi atau modifikasi pada dataset gambar yang ada. Tujuannya adalah untuk meningkatkan jumlah dan keanekaragaman data pelatihan yang tersedia, sehingga memperkaya variasi pola dan fitur yang dapat dipelajari oleh model. Augmentasi digunakan untuk mengatasi masalah kurangnya data pelatihan yang mencukupi atau ketidakseimbangan dalam distribusi kelas (Sanjaya and Ayub, 2020).

Dengan melakukan augmentasi pada dataset gambar, dapat memperluas variasi kondisi pencahayaan, rotasi, pergeseran, zoom, refleksi, dan transformasi lainnya yang mungkin terjadi pada gambar dalam situasi dunia nyata. Hal ini membantu model untuk belajar secara lebih umum dan meningkatkan kemampuannya dalam mengenali objek cengkih dan puing (ranting dan daun) atau pola dalam berbagai kondisi (Sanjaya and Ayub, 2020). Berikut augmentasi yang digunakan pada penelitian ini adalah augmentasi warna (*brightness contrash*) dan augmentasi blur (*median blur* dan *motion blur*).

(a) *Median Blur*

Median blur digunakan sebagai teknik pemulusan (*smoothing*) untuk menghilangkan noise atau detail kecil dalam gambar. Pada setiap piksel, median blur menggantikan nilai piksel tersebut dengan nilai median dari piksel-piksel di sekitarnya. Metode ini efektif dalam mengurangi noise tanpa merusak kontur atau detail yang lebih besar dalam gambar (Saifullah et al., 2017).





Gambar 7. Ilustrasi median blur

(b) *Motion Blur*

Motion blur adalah efek visual yang muncul ketika objek bergerak cepat saat gambar diambil atau ketika kamera bergerak selama pengambilan gambar. Namun, *motion blur* juga dapat diterapkan secara sengaja pada gambar untuk menciptakan efek artistik atau memperhalus detail dalam gambar. Gambar 8 memperlihatkan efek blur yang menimbulkan sensasi gerakan cepat.




Gambar 8. Contoh efek blur gerakan cepat (Gunawan and Kalalembang, n.d.2010.)



tness and Contrast

rightness and contrast mengacu pada pengaturan tingkat kecerahan dan daan antara nilai piksel dalam gambar. *Brightness* mengontrol seberapa


terang atau gelap keseluruhan gambar, sedangkan *contrast* mengontrol perbedaan relatif antara tingkat kecerahan piksel yang berdekatan. Pengaturan kecerahan dan kontras digunakan untuk mengontrol tampilan visual gambar dan dapat mempengaruhi tingkat detail, kedalaman warna, dan tingkat kontras antara objek dalam gambar (Sugiarti, 2018). Gambar 9 memperlihatkan contoh hasil kecerahan kontras.



Gambar 9. Contoh Hasil Kecerahan Kontras: (a) Citra original; (b) Citra hasil kecerahan kontras (Wakhidah, 2011).

2.1.7 *Bounding Box* (Kotak Pembatas)

Dalam pendeteksian objek, untuk menggambarkan lokasi spasial suatu objek biasanya menggunakan *bounding box*. *Bounding Box* berbentuk persegi panjang, yang ditentukan oleh koordinat x dan y dari sudut kiri atas persegi panjang dan koordinat sudut kanan bawah tersebut. Representasi *bounding box* yang umum digunakan lainnya adalah koordinat sumbu (x, y) dari pusat *bounding box*, dan lebar dan tinggi kotak (Zhang, 2022). Contoh hasil *bounding box* pada cengkih dapat dilihat pada Gambar 10.




Gambar 10. Contoh hasil *bounding box*.



2.1.8 Convolutional Neural Network (CNN)

Convolutional Neural Networks (CNN) merupakan bagian dari *deep learning* dan merupakan salah satu jenis arsitektur jaringan saraf yang secara luas diaplikasikan untuk tugas-tugas deteksi dan pengenalan gambar. Keunikan CNN terletak pada kemampuannya untuk mengidentifikasi dependensi spasial dan temporal dalam gambar, sehingga memungkinkan pemahaman yang lebih mendalam tentang konten gambar. Seperti halnya dengan *Artificial Neural Networks* (ANN), CNN juga terdiri dari beberapa komponen kunci seperti input, bobot (*weight*), bias, dan fungsi aktivasi. Namun, struktur CNN menawarkan fitur unik dalam bentuk arsitektur yang secara khusus dirancang untuk menangani data berdimensi tinggi, seperti gambar (Elgendy, 2020).

Arsitektur CNN umumnya dapat dibagi menjadi dua bagian utama: ekstraksi fitur dan klasifikasi. Bagian ekstraksi fitur terdiri dari lapisan konvolusional dan pooling yang bertujuan untuk mengidentifikasi dan memahami fitur penting dalam data. Setelah fitur-fitur ini diekstraksi, kemudian diteruskan ke bagian klasifikasi yang biasanya terdiri dari lapisan penuh (*fully connected layers*) untuk pengambilan keputusan. Secara keseluruhan, CNN menyediakan kerangka kerja yang kuat dan fleksibel untuk mengolah data berdimensi tinggi, dengan fitur-fitur uniknya yang memungkinkan pemahaman yang lebih baik tentang gambar dan memfasilitasi aplikasi lanjutan dalam bidang pengenalan pola dan analisis gambar. Skema arsitektur CNN dapat dilihat pada gambar 11.



Gambar 11. Arsitektur CNN (Elgendy, 2020)



2.1.9 Faster R-CNN

Agar lebih akurat dalam pendeteksian objek, model Fast R-CNN biasanya harus menghasilkan banyak proposal wilayah dalam pencarian selektif. Untuk mengurangi proposal wilayah tanpa kehilangan akurasi, Faster R-CNN mengusulkan untuk menggantikan pencarian selektif dengan *Region Proposal Network* (Ren et al., 2017).

Dibandingkan dengan Fast R-CNN, Faster R-CNN hanya mengubah metode proposal wilayah dari pencarian selektif ke *Region Proposal Network* (RPN). Sisa model tetap tidak berubah. RPN bekerja dalam langkah-langkah berikut:


1. Menggunakan *convolutional layer* 3×3 dengan padding 1 untuk mengubah output CNN menjadi output baru dengan c channel. Dengan cara ini, setiap unit di sepanjang dimensi spasial peta fitur yang diekstraksi CNN mendapatkan vektor fitur baru dengan panjang c .
2. Berpusat pada setiap piksel peta fitur, buat beberapa *anchor boxes* dengan skala dan rasio aspek yang berbeda dan beri label.
3. Menggunakan vektor fitur panjang- c di tengah setiap *anchor boxes*, prediksi kelas biner (latar belakang atau objek) dan *bounding box* untuk *anchor boxes*.
4. Mempertimbangkan *bounding box* yang diprediksi yang kelas prediksinya adalah objek, menghapus hasil yang tumpang tindih menggunakan penekanan non-maksimum. *Bounding box* prediksi yang tersisa untuk objek adalah proposal wilayah yang diperlukan oleh *pooling layer* wilayah yang diminati.

Perlu dicatat bahwa, sebagai bagian dari model Faster R-CNN, RPN dilatih bersama dengan model lainnya. Dengan kata lain, fungsi tujuan dari Faster R-CNN tidak hanya mencakup prediksi kelas dan *bounding box* dalam deteksi objek, tetapi juga prediksi kelas biner dan *bounding box* dari *anchor boxes* di RPN.

Sebagai hasil dari pelatihan *end-to-end*, jaringan proposal region mempelajari cara ilkan proposal region berkualitas tinggi, agar tetap akurat dalam sian objek dengan pengurangan jumlah proposal region yang dipelajari (Zhang, 2022).



Faster R-CNN menyediakan metode konfigurasi VGG16, ResNet_v1 dan model pra-pelatihan lainnya. Pertama, peta fitur dihasilkan oleh ekstraksi fitur dari gambar dalam kumpulan data, kemudian ditransfer ke RPN untuk diproses. Proses utama adalah: menghasilkan *anchor*, klasifikasi *softmax*, *bounding box regression*, dan menghasilkan proposal. Pada peta fitur, setiap piksel dapat dianggap sebagai 20 *anchor*. RPN menghasilkan beberapa *anchor box* untuk setiap titik *anchor* dengan menyesuaikan koefisien. Area kandidat ini diubah menjadi fitur yang terhubung penuh dengan konvolusi, dan pemetaan dari fitur ke lapisan klasifikasi dan lapisan regresi diwujudkan dengan menggunakan kernel konvolusi $2 \times k$ dan $4 \times k$. Pada lapisan klasifikasi, klasifikasi *softmax* digunakan untuk menentukan apakah area kandidat termasuk dalam latar depan (yaitu target); di lapisan regresi, *regresi bbox* digunakan untuk memodifikasi area kandidat, sehingga lebih dekat ke area nyata yang telah ditetapkan (yaitu kotak yang ditandai selama *preprocessing*). Kemudian, lapisan proposal akan menyesuaikan titik *anchor* sesuai dengan hasil regresi, dan memilih beberapa kandidat area dengan skor prospek tinggi sebagai proposal. Prinsip RPN ditunjukkan pada Gambar 12.




Gambar 12. Diagram Prinsip RPN (Kong et al., 2020)

Setelah itu, ROI *pooling layer* akan mengumpulkan proposal dan peta fitur untuk menghasilkan peta fitur proposal. Peta fitur proposal keluaran dihitung apisan koneksi penuh dan klasifikasi *softmax* untuk menentukan kategori ng dimiliki setiap proposal, keluaran vektor probabilitas *cls_prob*, dan tkan posisi *offset bbox_pred* dari setiap 21 proposal dengan *regresi bbox*



untuk mengekstrak bingkai deteksi target yang lebih akurat. Parameter keluaran seperti *cls_prob* dan *bbox_pred* akan digunakan untuk mengoptimalkan model data keluaran pelatihan CNN dan meningkatkan kinerja deteksi Faster R-CNN. Proses operasi dasar Faster R-CNN ditunjukkan pada Gambar 13.




Gambar 13. Faster R-CNN *basic operation process* (Kong et al., 2020)

2.1.10 Residual Network


Operasi yang paling penting di CNN adalah *Convolutional Layer*, *Convolutional Layer* merupakan blok inti dari *Convolutional Neural Network* yang melakukan sebagian besar komputasi berat. Salah satu contoh model *Convolutional Layer* yang cukup populer adalah ResNet, ResNet50 adalah Jaringan Residual yang berisi 50 layer. Seperti VGG, ukuran lapisan konvolusi adalah filter 3×3 , ukuran input model ini ditetapkan sebagai 224×224 . Beberapa desain sederhana seperti untuk lapisan yang memiliki jumlah filter yang sama memiliki keluaran yang sama, jumlah filter menjadi dua kali lipat jika ukuran keluaran yang terbelit dibelah dua sehingga kompleksitas waktu per lapisan 22 dipertahankan. Model diakhiri dengan *pooling layer* rata-rata dan 1000-way *fullyconnected layer* dengan *softmax*, model ini memiliki lebih sedikit filter dan kompleksitas yang lebih rendah daripada jaring VGG dan ada varian lain seperti ResNet101 dan ResNet152 (Bendjillali et al., 2020). Gambar 14 menunjukkan lapisan konfigurasi jaringan ResNet50.





Gambar 14. *ResNet50 Architecture* (Zhang, 2022)

Inti dari *Residual Network* (*ResNet*) adalah gagasan bahwa, setiap lapisan tambahan harus lebih mudah memuat fungsi identitas sebagai salah satu elemennya. Pertimbangan ini agak mendalam tetapi mengarah pada solusi yang sangat sederhana. *Residual Block* diilustrasikan pada Gambar 15.



Gambar 15. Bagian *Residual Block* (a) Blok Regular dan (b) Blok *Residual* (Zhang, 2022)



ti yang digambarkan pada Gambar 14, nilai input dinyatakan dengan x .
14 (a), bagian dalam kotak garis putus-putus harus langsung mempelajari
1 $f(x)$. Di sebelah kanan, bagian dalam kotak garis putus-putus perlu

mempelajari pemetaan residual $f(x) - x$, yang merupakan cara blok residual mendapatkan namanya. Jika pemetaan identitas $f(x) = x$ adalah pemetaan dasar yang diinginkan, pemetaan residual lebih mudah dipelajari hanya perlu mendorong bobot dan bias lapisan bobot atas (misalnya, *fully connected layer* dan *convolutional layer*) di dalam kotak garis putus-putus menjadi nol. Gambar 14 (b) mengilustrasikan blok *residual ResNet*, dimana garis padat yang membawa input lapisan x ke operator tambahan disebut sambungan residual (atau sambungan pintasan) (Zhang, 2022).


Dengan blok residual, input dapat menyebar lebih cepat melalui koneksi residual di seluruh lapisan. 24 *ResNet* mengikuti desain lapisan konvolusi 3×3 penuh VGG. Blok residual memiliki dua lapisan konvolusi 3×3 dengan jumlah saluran keluaran yang sama, setiap lapisan konvolusi diikuti oleh lapisan sedangisasi batch dan fungsi aktivasi ReLU. Kemudian melewati dua operasi konvolusi dan menambahkan input langsung sebelum fungsi aktivasi ReLU terakhir. Jenis desain ini mensyaratkan bahwa output dari dua lapisan konvolusi harus memiliki bentuk yang sama dengan input, sehingga dapat dijumlahkan (Zhang, 2022).

2.1.11 Google Collaboratory

Fitur unik dari *Google Collab* adalah kemampuan untuk berbagi dan kolaborasi dengan mudah. Pengguna dapat dengan mudah berbagi *notebook* mereka dengan tim maupun teman, sehingga memungkinkan kolaborasi dalam pengembangan kode dan analisis data secara *real-time*. *Google Collab* juga terintegrasi dengan *Google Drive*, sehingga pengguna dapat menyimpan dan mengelola file dan proyeknya dengan mudah dalam penyimpanan *cloud Google Drive*. Dengan fitur-fitur yang dimilikinya, *Google Collab* memberikan fleksibilitas, kemudahan, aksesibilitas dalam mengolah data, melakukan eksperimen, dan mengembangkan aplikasi *Machine Learning* dalam lingkungan yang ramah pengguna dan berbasis cloud. Gambar 16 menampilkan user *interface*

le Collab.






Gambar 16. Tampilan *Google Collab*

2.1.12 Jupyter Notebook

Jupyter Notebook adalah sebuah IDE (*Integrated Development Environment*) yang digunakan untuk menulis, menjalankan, dan membagikan kode secara interaktif. IDE ini memungkinkan pengguna untuk menggabungkan teks, kode, visualisasi, dan dokumentasi dalam satu dokumen yang disebut sebagai *notebook* (Randles *et al.*, 2017). Gambar 17 menampilkan *user interface* dari *Jupyter Notebook*.



Gambar 17. User Interface IDE *Jupyter Notebook*



Optimized using
trial version
www.balesio.com

Jupyter Notebook merupakan aplikasi bawaan yang tersedia di platform

a. Anaconda sendiri adalah sebuah platform yang bersifat *open source*

yang digunakan untuk pengembangan dan pemrograman menggunakan bahasa Python dan R. Tujuan utama dari Anaconda adalah untuk menyediakan pengelolaan paket Python yang mudah dan efisien di sistem pengguna (Anaconda Inc., 2021). Dengan menggunakan Anaconda, pengguna dapat menginstal dan mengelola paket-paket Python dengan mudah, termasuk paket-paket yang sering digunakan dalam pengembangan *machine learning* maupun *deep learning*. Anaconda menyediakan lingkungan virtual yang terisolasi yang memungkinkan pengguna untuk menginstal paket-paket Python yang spesifik dan menjaga kestabilan dan keseragaman lingkungan pengembangan mereka. Salah satu komponen utama dari Anaconda adalah *Jupyter Notebook*. *Jupyter Notebook* berfungsi sebagai antarmuka pengguna yang memungkinkan pengguna untuk membuat dan menjalankan kode Python secara interaktif melalui halaman web. Dalam *Jupyter Notebook*, pengguna dapat menulis dan menjalankan kode Python dalam sel-sel yang terpisah, serta menyertakan teks, visualisasi, dan dokumentasi dalam satu dokumen yang lengkap.

2.1.13 Evaluasi Sistem

Penelitian ini mengevaluasi sistem menggunakan dua teknik evaluasi: *mAP* (*mean Average Precision*) dan *confusion matrix*. *mAP* umumnya digunakan dalam mendeteksi objek, di mana sistem atau model harus mengidentifikasi objek dalam gambar dan menentukan seberapa baik deteksi tersebut. Hasil evaluasi dengan *mAP* akan memberikan skor yang mencerminkan seberapa baik model melakukan deteksi objek pada berbagai kelas (Bhatti et al., 2020).

Confusion matrix adalah matriks yang menunjukkan klasifikasi prediksi dan aktual, sebuah matriks konfusi berukuran $l \times l$, di mana l adalah jumlah nilai label atau kelas yang berbeda (Kohavi & Provost, 1998). Dalam *multi-class confusion matrix*, kelas-kelas dicantumkan dalam urutan yang sama dalam baris seperti pada kolom Gambar 16. Oleh karena itu elemen yang diklasifikasikan dengan benar (*True Positive*) terletak pada diagonal utama dari kiri atas ke kanan bawah dan di titik pertemuan antara prediksi dan aktual (Grandini et al., 2020).



Evaluasi model Faster R-CNN dapat dilihat dari nilai loss yang dicapai, semakin rendah nilai loss, semakin baik modelnya (Bhatti *et al.*, 2020). Rumus loss function dapat ditulis sebagai berikut:

$$Loss = Lcls + Lbox + Lmask \quad (1)$$

Keterangan:

Fungsi loss dalam Faster R-CNN terdiri dari tiga bagian, yaitu:

$Lcls$ (*loss clasification*) : nilai loss dari hasil training berfokus pada klasifikasi yang diprediksi

$Lbox$ (*loss bounding box*) : nilai loss regresi dari bounding boxe prediksi), dan

$Lmask$ (*loss masking*) : nilai loss dari masker yang diprediksi)

Metrik mAP digunakan untuk membandingkan jumlah objek sebenarnya dan objek yang terdeteksi dengan benar (Bhatti *et al.*, 2020).

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (2)$$

Keterangan:

N : adalah jumlah kelas atau kategori yang diuji.

AP_i : adalah *Average Precision* untuk kelas atau kategori ke- i

Average Precision (AP) untuk setiap kelas dihitung sebagai area di bawah kurva *Precision-Recall* ($P-R$ curve). $P-R$ curve menunjukkan hubungan antara presisi dan *recall* pada berbagai nilai ambang batas (*threshold*) pada hasil prediksi model.

Akurasi adalah salah satu metrik yang paling populer dalam klasifikasi *multi class*. Rumus Akurasi mempertimbangkan jumlah elemen *True Positive* dan *True Negative* pada pembilang dan jumlah semua entri *confusion matrix* pada penyebut. Penting juga memahami *False Positive* (prediksi salah positif) dan *False Negative* (prediksi salah negatif) yang memberikan informasi lebih dalam tentang performa model.

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$



asi mengembalikan ukuran keseluruhan tentang seberapa banyak model iksi dengan benar pada seluruh kumpulan data (Grandini *et al.*, 2020).

Dalam menentukan nilai sel pada *confusion matrix* nilai TP, FP, FN, dan TN berbeda untuk setiap kelas. Gambar 18 merupakan cara dalam menentukan nilai pada *confusion matrix*.

		Actual Values	
		1 (Positive)	0 (Negative)
Predicted Values	1 (Positive)	TP (True Positive)	FP (False Positive) <i>Type I Error</i>
	0 (Negative)	FN (False Negative) <i>Type II Error</i>	TN (True Negative)

Gambar 18. *Confusion matrix*

Di dalam *confusion matrix*, terdapat empat kemungkinan hasil prediksi:

- *True Positive* (TP): Jumlah sampel yang benar diprediksi sebagai positif.
- *True Negative* (TN): Jumlah sampel yang benar diprediksi sebagai negatif.
- *False Positive* (FP): Jumlah sampel yang salah diprediksi sebagai positif (*False Alarm*).
- *False Negative* (FN): Jumlah sampel yang salah diprediksi sebagai negatif (*Missed Detection*).

Tabel 1. Fungsi Matrik Evaluasi

No	Metrik Evaluasi	Fungsi
1	<i>Loss</i>	Menghitung hasil deteksi kelas objek, ketepatan prediksi <i>bounding box</i> , dan akurasi saat pelatihan dalam 1 iterasi.
2	<i>mAP</i>	Kualitas dan kelengkapan deteksi objek pada berbagai kelas pada seluruh objek cengkih dan puing (ranting dan daun)
3	Akurasi	Mengukur sejauh mana model benar secara keseluruhan



2.2 Metode Penyelesaian Masalah

2.2.1 *State of the art* penelitian

Tabel 2. *State of the art*

Peneliti	Judul	Objek Permasalahan	Metode Penyelesaian dan Hasil
(Prayogi et al., 2021)	<i>Image classification of different cengkih (Syzygium aromaticum) quality using deep learning method with convolutional neural network algorithm</i>	Objek: Cengkih Permasalahan: • mengklasifikasikan kualitas bunga cengkih kering	• metode deep learning dengan algoritma <i>Convolutional Neural Network</i> (CNN), • Melakukan analisis <i>sensitivitas hiperparameter</i> CNN untuk mendapatkan model terbaik untuk proses klasifikasi kualitas cengkih. • Akurasi: 87%
(Indrabayu et al., 2019)	<i>Strawberry Ripeness Classification System Based On Skin Tone Color using Multi-Class Support Vector Machine</i>	Objek: Stroberi Permasalahan: mengidentifikasi tingkat kematangan stroberi berdasarkan warna kulitnya	• <i>Hue, Saturation, dan Value</i> (HSV) • <i>Radial Basis Function</i> (RBF) • <i>multi-class support vector machine</i> (SVM) • Akurasi: 85,64%
9)	<i>Automatic detection of single ripe tomato on plant combining Faster R-CNN</i>	Objek: Tomat Permasalahan: mendeteksi tomat matang yang cepat dan akurat pada tanaman	• (KNN) • <i>support vector machine</i> (SVM) untuk klasifikasi



Peneliti	Judul	Objek Permasalahan	Metode Penyelesaian dan Hasil
	<i>and intuitionistic fuzzy set</i>		• <i>Machine Vision System (MVS)</i> untuk penghitung buah otomatis • Akurasi: 88%
(Ramos et al., 2017)	<i>automatic fruit count on coffe branches using computer vision</i>	Objek: Buah Kopi Permasalahan: Bagaimana menghitung buah kopi	• Canny edge detektor untuk segmentasi • <i>Bayes classifier</i> (KNN), <i>support vector machine</i> (SVM) untuk deteksi • <i>Machine Vision System (MVS)</i> untuk penghitung buah otomatis • Akurasi: 88%
(Areni et al., 2023)	<i>Increasing Precision of Water Sprout Detection based on Mask R-CNN with Data Augmentation</i>	Objek: Tanaman Kakao Permasalahan: mendeteksi kecambah air pada tanaman kakao	• Mask R-CNN • Teknik Augmentasi, yaitu (<i>flip horizontal</i>, blur menggunakan <i>Gaussian blur</i>, modifikasi kontras menggunakan kontras linier, perubahan saturasi warna, memotong sisi gambar secara acak sebanyak 50 piksel, dan memutar gambar). • Akurasi: Hasil yang diperoleh menunjukkan bahwa model yang dilatih dengan <i>learning rate</i> 0,01 dengan augmentasi data dapat mendeteksi objek lebih baik dibandingkan model lainnya



Peneliti	Judul	Objek Permasalahan	Metode Penyelesaian dan Hasil
(C et al., 2022)	<i>Real-time Riped Fruit Detection using Faster R-CNN Deep Neural Network Models</i>	Objek: Buah (Tomat, apel, pisang, kiwi, stroberi dan jeruk) Permasalahan: mengembangkan sistem deteksi buah yang matang	dengan F1 score 0,96 pada threshold 0,80. - Membandingkan arsitektur pada Algoritma Faster R-CNN yaitu (Resnet50, VGG-16 dan InceptionV2) untuk deteksi buah yang matang. - Akurasi: Hasil dari penelitian ini menunjukkan bahwa arsitektur Resnet50 lebih cepat dan memperoleh akurasi yang baik dalam mendeteksi buah yaitu 94,19%.
(Xu et al., 2020)	<i>Fast Method of Detecting Tomatoes in a Complex Scene for Picking Robots</i>	Objek: Robot pemetik buah dan sayuran (tomat) Permasalahan: Bagaimana mendeteksi tomat dengan masalah (cahaya latar, sinar matahari langsung, buah dan cabang yang tumpang tindih, daun yang menghalangi, dll.)	- YOLOv3 - Akurasi: 91,92%
(Jia et al., 2022)	<i>A fast and efficient green apple object detection model based on Foveabox</i>	Objek: Apel Hijau Permasalahan: Mendeteksi apel hijau	<i>Fast optimized Foveabox detection model</i> (Fast-FDM) untuk mendeteksi apel hijau - Teknik Augmentasi (<i>Brightness contrast and flip</i>) Untuk



Peneliti	Judul	Objek Permasalahan	Metode Penyelesaian dan Hasil
			meningkatkan kemampuan model dalam mengenali objek secara umum dan dalam berbagai kondisi, dataset citra diperkaya dengan variasi kecerahan, kontras, dan flip. • Akurasi : hasil dari penelitian ini menunjukkan bahwa model deteksi objek berbasis <i>Foveabox</i> berhasil mendeteksi objek apel hijau dengan tingkat akurasi yang baik
(Apolo-Apolo et al., 2020)	<i>Deep learning techniques for estimation of the yield and size of citrus fruits using a UAV</i>	Objek: Jeruk Permasalahan: mendeteksi, menghitung, dan memperkirakan ukuran buah jeruk pada masing-masing pohon	• <i>Faster R-CNN</i> • UAV (drone) : untuk memperkirakan hasil panen dan ukuran buah jeruk berdasarkan citra yang diambil. • <i>Gaussian smoothing</i> dan <i>filter median blur</i> untuk menghilangkan <i>noise</i> pada gambar. • Akurasi: hasil dari penelitian ini menunjukkan bahwa model mampu deteksi dengan baik




Peneliti	Judul	Objek Permasalahan	Metode Penyelesaian dan Hasil
	<i>Kiwifruit detection in field images using Faster R-CNN with VGG16</i>	Objek: Buah Kiwi Permasalahan: mendeteksi buah kiwi	• R-CNN (<i>Region-based Convolutional Neural Network</i>) dengan arsitektur VGG16 untuk deteksi objek pada gambar buah kiwi. • Augmentasi <i>Motion Blur</i> untuk membuat sistem deteksi buah kiwi tidak terpengaruh oleh blur disebabkan oleh kamera terpasang saat mengambil gambar. • Akurasi: 87,61%



2.3 Kerangka Pikir

Tujuan kerangka pikir adalah untuk mengetahui posisi dan keunikan penelitian yang akan dilaksanakan. Kerangka pikir dapat dilihat pada Gambar 19.



Gambar 19. Kerangka Pikir

Tahapan kerangka pikir penelitian diuraikan sebagai berikut.

Pertama, pada latar belakang penelitian (*background*). Difokuskan pada konteks permasalahan yang dihadapi oleh komunitas petani cengkih yakni kesulitan dalam memisahkan cengkih dari puing (ranting dan daun) setelah proses pengeringan terkadang masih ada puing (ranting dan daun) pada saat dilakukan penimbangan. Hal ini menyebabkan adanya penambahan berat pada saat masuk ke



proses penimbangan cengkih, oleh karena itu diperlukan sebuah sistem untuk pemisahan cengkih dari puing (ranting dan daun). Dalam penelitian ini antara cengkih dan puing (ranting serta daun) menggunakan sistem *belt*

conveyor dengan kecepatan tinggi, ditemui kesulitan dalam memproses citra yang terdistorsi, terutama terkait citra yang bergerak dan kabur. Oleh karena itu, studi ini bertujuan untuk mengembangkan suatu model yang mampu mendeteksi dan mengklasifikasikan cengkih dan puing (ranting serta daun) dalam masalah citra yang muncul pada *belt conveyor*.

Kedua, sebagai respons terhadap konteks permasalahan yang telah diuraikan, beberapa pendekatan eksisting telah diimplementasikan. Pendekatan-pendekatan tersebut meliputi tahapan-tahapan sebagai berikut; pertama, melakukan wawancara dengan sejumlah petani cengkih, kedua, melaksanakan proses pengambilan cengkih dan puing (ranting dan daun) dari petani cengkih yang bersangkutan, dan ketiga, melanjutkan dengan pengambilan dataset melalui penerapan *belt conveyor*.

Ketiga, hasil yang dihasilkan dari proses akuisisi dataset mengalami penyempurnaan dalam tahap *pra-pemrosesan*. Tahap ini meliputi dua prosedur utama, yaitu penyesuaian orientasi citra (*orientation image*) dan penyesuaian dimensi citra (*resize image*), yang memiliki tujuan dalam memperbaiki integritas data dengan mengoreksi rotasi gambar. Kemudian dilakukan penerapan teknik augmentasi warna, yang melibatkan peningkatan kontras kecerahan (*brightness contrast*) serta penggunaan teknik augmentasi blur, yang meliputi efek blur pergerakan (*motion blur*) dan efek blur median (*median blur*) yang bertujuan untuk meningkatkan keanekaragaman dan kualitas dataset. Dari hasil teknik augmentasi kemudian dilanjutkan pelabelan data (anotasi) yang bertujuan untuk memberikan pembelajaran mesin, terutama dalam tugas-tugas seperti pengenalan objek, klasifikasi gambar, deteksi objek. Dengan memberikan label pada objek, fitur, atau area tertentu dalam gambar, model pembelajaran mesin dapat dilatih untuk mengenali dan memahami gambar pada saat dilakukan pelatihan model.

Keempat, Penelitian ini menggunakan metodologi Faster R-CNN untuk mengenali dan memisahkan objek cengkih dan puing dalam gambar. Algoritma gabungan *Region Proposal Network* (RPN) dan *Convolutional etwork* (CNN) untuk deteksi objek yang cepat dan akurat.



Kelima, hasil. Model yang dapat melakukan multi deteksi dan klasifikasi cengkih dari puing (ranting dan daun) pada *belt conveyor*.

