

SKRIPSI

**KLASIFIKASI KUALITAS CABAI KATOKKON DENGAN
DEEP LEARNING PADA PERANGKAT *EDGE COMPUTING*:
PENGEMBANGAN DAN IMPLEMENTASI**

Disusun dan diajukan oleh:

**WILLIAM ADAM
D121 19 1033**



**PROGRAM STUDI SARJANA TEKNIK INFORMATIKA
FAKULTAS TEKNIK
UNIVERSITAS HASANUDDIN
GOWA
2024**

LEMBAR PENGESAHAN SKRIPSI

Klasifikasi Kualitas Cabai Katokkon dengan *Deep learning* pada Perangkat *Edge computing*: Pengembangan dan Implementasi

Disusun dan diajukan oleh

**WILLIAM ADAM
D121191033**

Telah dipertahankan di hadapan Panitia Ujian yang dibentuk dalam rangka Penyelesaian Studi Program Sarjana Program Studi Teknik Informatika Fakultas Teknik Universitas Hasanuddin Pada tanggal 2 Oktober 2024 dan dinyatakan telah memenuhi syarat kelulusan

Menyetujui,

Pembimbing Utama,

Pembimbing Pendamping,



Dr. Eng. Muhammad Niswar, S.T., M.IT.
NIP 197309221999031001



Dr. Ir. Ingrid Nurtanio, M.T.
NIP 196108131988112001



Ketua Program Studi,

Prof. Dr. Ir. Indrabayu, S.T., M.T., M.Bus. Sys., IPM., ASEAN. Eng.
NIP 197507162002121004

PERNYATAAN KEASLIAN

Yang bertanda tangan dibawah ini ;
Nama : William Adam
NIM : D121191033
Program Studi : Teknik Informatika
Jenjang : S1

Menyatakan dengan ini bahwa karya tulisan saya berjudul

Klasifikasi Kualitas Cabai Katokkon dengan *Deep Learning* pada Perangkat *Edge Computing*: Pengembangan dan Implementasi

Adalah karya tulisan saya sendiri dan bukan merupakan pengambilan alihan tulisan orang lain dan bahwa skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri.

Semua informasi yang ditulis dalam skripsi yang berasal dari penulis lain telah diberi penghargaan, yakni dengan mengutip sumber dan tahun penerbitannya. Oleh karena itu semua tulisan dalam skripsi ini sepenuhnya menjadi tanggung jawab penulis. Apabila ada pihak manapun yang merasa ada kesamaan judul dan atau hasil temuan dalam skripsi ini, maka penulis siap untuk diklarifikasi dan mempertanggungjawabkan segala resiko.

Segala data dan informasi yang diperoleh selama proses pembuatan skripsi, yang akan dipublikasi oleh Penulis di masa depan harus mendapat persetujuan dari Dosen Pembimbing.

Apabila dikemudian hari terbukti atau dapat dibuktikan bahwa sebagian atau keseluruhan isi skripsi ini hasil karya orang lain, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Gowa, 13 September 2024

Yang Menyatakan

A 2000 Rupiah postage stamp with a signature over it. The stamp features the Garuda Pancasila emblem and the text 'REPUBLIK INDONESIA', '10000', 'TEL', '20 METERAI TEMPEL', and 'DACC2ALX373531209'. The signature is in black ink and appears to be 'William Adam'.

William Adam

ABSTRAK

WILLIAM ADAM. *Klasifikasi Kualitas Cabai Katokkon dengan Deep Learning pada Perangkat Edge Computing: Pengembangan dan Implementasi* (dibimbing oleh Muhammad Niswar dan Ingrid Nurtanio)

Cabai Katokkon adalah varietas dominan di daerah Toraja yang dikenal karena rasa pedas dan aroma khasnya, sering digunakan sebagai bumbu khas. Namun, cabai ini sering terancam oleh serangan hama dan penyakit seperti ulat dan lalat buah, yang dapat mengurangi produksi secara signifikan. Proses sortasi manual pasca-panen juga sering tidak konsisten, mempengaruhi efisiensi dan kualitas hasil. Penelitian ini mengusulkan penggunaan teknik deep learning, khususnya YOLO (*You Only Look Once*), untuk mengklasifikasikan kualitas cabai Katokkon secara otomatis pada perangkat *edge computing*. Hasil menunjukkan bahwa YOLOv8 memiliki keseimbangan antara performa dan penggunaan sumber daya yang terbaik (*Precision*: 0,69; *Recall*: 0,71; *mAP50*: 0,72; dan *mAP50-95*: 0,54) bersaing secara kompetitif dengan YOLOv7 (*Precision*: 0,66; *Recall*: 0,73; *mAP50*: 0,73; *mAP50-95*: 0,52) dan YOLOv9 (*Precision*: 0,61; *Recall*: 0,72; *mAP50*: 0,71; *mAP50-95*: 0,51). YOLOv8 juga menonjol dengan kecepatan inferensi rata-rata terendah di antara model lainnya, yaitu 427,42 ms, menjadikannya ideal untuk aplikasi *edge computing*. Selain itu, hasil menunjukkan bahwa resolusi gambar 224x224 memberikan keseimbangan terbaik untuk model (*Precision*: 0,62; *Recall*: 0,75; *F1-score*: 0,68; *mAP50*: 0,70; dan *mAP50-95*: 0,53), dan penggunaan sumber daya (kecepatan inferensi: 294,71 ms; penggunaan CPU: 80,08%; penggunaan memori: 23,16%). Dalam perbandingan antar perangkat, *Smartphone* menunjukkan kinerja terbaik dengan kecepatan inferensi rata-rata 3,26 ms, yang jauh lebih rendah dibandingkan *Raspberry Pi* (427,42 ms) dan *Jetson Nano* (228,60 ms). *Smartphone* juga menunjukkan penggunaan CPU yang lebih rendah (42,33%), menegaskan efisiensi energi yang lebih baik untuk aplikasi praktis dalam sistem sortasi otomatis cabai Katokkon.

Kata Kunci: Cabai Katokkon, *Deep learning*, YOLO, *Smartphone*, *Raspberry Pi*, *Jetson Nano*, klasifikasi otomatis, *edge computing*

ABSTRACT

WILLIAM ADAM. *Klasifikasi Kualitas Cabai Katokkon dengan Deep learning pada Perangkat Edge computing: Pengembangan dan Implementasi* (supervised by Muhammad Niswar and Ingrid Nurtanio)

Katokkon chili is a dominant variety in the Toraja region, known for its spiciness and distinctive aroma, often used as a traditional spice. However, this chili is frequently threatened by pests and diseases such as caterpillars and fruit flies, which can significantly reduce production. The manual post-harvest sorting process is also often inconsistent, affecting the efficiency and quality of the results. This research proposes the use of deep learning techniques, specifically YOLO (You Only Look Once), to automatically classify the quality of Katokkon chili on edge computing devices. The results show that YOLOv8 has the best balance between performance and resource utilization (*Precision*: 0,69; *Recall*: 0,71; mAP50: 0,72; and mAP50-95: 0,54) competing effectively with YOLOv7 (*Precision*: 0,66; *Recall*: 0,73; mAP50: 0,73; mAP50-95: 0,52) and YOLOv9 (*Precision*: 0,61; *Recall*: 0,72; mAP50: 0,71; mAP50-95: 0,51). YOLOv8 also stands out with the lowest average inference speed among the models, at 427,42 ms, making it ideal for edge computing applications. Additionally, the results indicate that a 224x224 image resolution provides the best balance for model performance (*Precision*: 0,62; *Recall*: 0,75; F1-score: 0,68; mAP50: 0,70; and mAP50-95: 0,53) and resource usage (inference speed: 294,71 ms; CPU usage: 80,08%; memory usage: 23,16%). In comparison across devices, *Smartphones* demonstrated the best performance with an average inference speed of 3,26 ms, significantly lower than *Raspberry Pi* (427,42 ms) and *Jetson Nano* (228,60 ms). *Smartphones* also showed lower CPU usage (42,33%), confirming better energy efficiency for practical applications in the automatic sorting system of Katokkon chili.

Keywords: Katokkon chili, Deep learning, YOLO, *Smartphone*, *Raspberry Pi*, *Jetson Nano*, automated classification, edge computing

DAFTAR ISI

LEMBAR PENGESAHAN SKRIPSI	i
PERNYATAAN KEASLIAN.....	ii
ABSTRAK	iii
ABSTRACT	iv
DAFTAR ISI.....	v
DAFTAR GAMBAR	vii
DAFTAR TABEL	viii
DAFTAR SINGKATAN DAN ARTI SIMBOL	ix
DAFTAR LAMPIRAN.....	x
KATA PENGANTAR	xi
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	2
1.3 Tujuan Penelitian	3
1.4 Manfaat Penelitian	3
1.5 Ruang Lingkup.....	3
BAB II TINJAUAN PUSTAKA.....	4
2.1 Cabai	4
2.2 Visi Komputer.....	4
2.2.1 Pengolahan Citra.....	5
2.2.2 Augmentasi Gambar	5
2.2.3 Pengenalan Pola.....	5
2.3 Deteksi Objek.....	6
2.4 <i>Edge computing</i>	6
2.5 <i>Convolutional Neural Network</i>	7
2.5.1 <i>Local Receptive Field</i>	8
2.5.2 <i>Weight Sharing</i>	8
2.5.3 <i>Pooling</i>	8
2.5.4 Struktur CNN.....	8
2.6 Arsitektur Model YOLO	10
2.6.1 YOLOv7	10
2.6.2 YOLOv8	11
2.6.3 YOLOv9	12
BAB III METODE PENELITIAN.....	13
3.1 Tahapan Penelitian	13
3.2 Tempat dan Waktu Penelitian	14
3.3 Instrumen Penelitian	14
3.4 Rancangan Sistem	15
3.4.1 Dataset	17
3.4.2 Teknik Pengambilan Data.....	17
3.4.3 Karakteristik Data	18
3.4.4 Proses Dataset dan Pelabelan.....	18
3.4.5 Standar Kategorisasi Kualitas Cabai	19
3.4.6 Pelatihan Model	20
3.4.7 Evaluasi Sistem.....	21

3.4.8 Implementasi Model	22
BAB IV. HASIL DAN PEMBAHASAN	24
4.1 Hasil <i>Training</i> Model.....	24
4.1.1 <i>Confusion Matrix</i>	24
4.1.2 Kurva <i>F1-Confidence</i> dan <i>Precision-Recall</i>	27
4.2 Perbandingan Penggunaan CPU, Memori, dan Kecepatan Inferensi.....	30
4.2.1 Perbandingan antara YOLOv7, YOLOv8, dan YOLOv9	30
4.2.2 Perbandingan antara resolusi gambar	32
4.3 Observasi Hasil Training Model	41
4.4 Performa Model pada Setiap <i>Platform</i> Penerapan	47
4.4.1 Kecepatan Model pada Berbagai Platform	47
4.4.2 Penggunaan Sumber Daya tiap Platform	48
4.4.3 Power Delay Product	49
BAB V. KESIMPULAN DAN SARAN.....	50
5.1 Kesimpulan	50
5.2 Saran.....	52
DAFTAR PUSTAKA	53
LAMPIRAN.....	57

DAFTAR GAMBAR

Gambar 1 Struktur dari Convolutional Neural Network.....	8
Gambar 2 Arsitektur YOLO dari (Redmon et al., 2016)	10
Gambar 3 Tahapan Penelitian	13
Gambar 4 Rancangan Sistem	15
Gambar 5 Contoh Dataset Cabai Katokkon	17
Gambar 6 Anotasi menggunakan <i>LabelImg</i>	19
Gambar 7 Augmentasi Gambar dengan <i>Roboflow</i>	19
Gambar 8 Platform Penerapan: <i>Jetson Nano, Raspberry Pi, Smartphone</i>	22
Gambar 9 <i>Confusion Matrix</i> Model YOLOv7	24
Gambar 10 <i>Confusion Matrix</i> Model YOLOv8	25
Gambar 11 <i>Confusion Matrix</i> Model YOLOv9	25
Gambar 12 Kurva <i>F1-Confidence</i> Model YOLOv7	27
Gambar 13 Kurva <i>Precision-Recall</i> Model YOLOv7	28
Gambar 14 Kurva <i>F1-Confidence</i> Model YOLOv8	28
Gambar 15 Kurva <i>Precision-Recall</i> Model YOLOv8	29
Gambar 16 Kurva <i>F1-Confidence</i> Model YOLOv9	29
Gambar 17 Kurva <i>Precision-Recall</i> Model YOLOv9	30
Gambar 18 Kecepatan Inferensi YOLOv7 vs YOLOv8 vs YOLOv9	30
Gambar 19 Persentase Penggunaan CPU YOLOv7 vs YOLOv8 vs YOLOv9	31
Gambar 20 Persentase Penggunaan Memori YOLOv7 vs YOLOv8 vs YOLOv9.....	31
Gambar 21 Perbandingan Resolusi Gambar	32
Gambar 22 <i>Confusion Matrix</i> YOLOv8 untuk Resolusi 128x128	33
Gambar 23 Kurva <i>F1-Confidence</i> YOLOv8 untuk Resolusi 128x128.....	33
Gambar 24 Kurva <i>Precision-Recall</i> YOLOv8 untuk Resolusi 128x128.....	34
Gambar 25 <i>Confusion Matrix</i> YOLOv8 untuk Resolusi 224x224	34
Gambar 26 Kurva <i>F1-Confidence</i> YOLOv8 untuk Resolusi 224x224.....	35
Gambar 27 Kurva <i>Precision-Recall</i> YOLOv8 untuk Resolusi 224x224.....	35
Gambar 28 <i>Confusion Matrix</i> YOLOv8 untuk Resolusi 320x320	36
Gambar 29 Kurva <i>F1-Confidence</i> YOLOv8 untuk Resolusi 320x320.....	36
Gambar 30 Kurva <i>Precision-Recall</i> YOLOv8 untuk Resolusi 320x320.....	37
Gambar 31 <i>Confusion Matrix</i> YOLOv8 untuk Resolusi 512x512	37
Gambar 32 Kurva <i>F1-Confidence</i> YOLOv8 untuk Resolusi 512x512.....	38
Gambar 33 Kurva <i>Precision-Recall</i> YOLOv8 untuk Resolusi 512x512.....	38
Gambar 34 Kecepatan Inferensi berdasarkan Resolusi Gambar.....	40
Gambar 35 Persentase Penggunaan CPU berdasarkan Resolusi Gambar.....	40
Gambar 36 Persentase Penggunaan Memori berdasarkan Resolusi Gambar.....	41
Gambar 37 Perbandingan Kecepatan Model tiap Platform	47
Gambar 38 Kecepatan Inferensi tiap Platform.....	48
Gambar 39 Persentase Penggunaan CPU tiap Platform	48

DAFTAR TABEL

Tabel 1 Kategorisasi Kualitas Cabai Katokkon	20
Tabel 2 Spesifikasi Perangkat Penerapan	22
Tabel 3 Perbandingan Metrik Evaluasi antara YOLOv7, YOLOv8, dan YOLOv9	26
Tabel 4 Metrik Hasil Kalkulasi dari <i>Confusion Matrix</i>	26
Tabel 5 Perbandingan Penggunaan CPU, Memori, dan Kecepatan Inferensi YOLOv7, YOLOv8, dan YOLOv9	32
Tabel 6 Metrik Hasil Kalkulasi dari <i>Confusion Matrix</i> untuk model dengan berbagai resolusi	39
Tabel 7 Perbandingan Kinerja Model YOLOv8 Berdasarkan Resolusi Gambar pada <i>Raspberry Pi</i>	41
Tabel 8 Perbandingan Performa Platform untuk Model Deteksi Objek	49
Tabel 9 <i>Power Delay Product</i> (PDP)	49

DAFTAR SINGKATAN DAN ARTI SIMBOL

Lambang/Singkatan	Arti dan Keterangan
YOLO	<i>You Only Look Once</i>
mAP	<i>mean Average Precision</i>
FPS	<i>Frames Per Second</i>
PDP	<i>Power Delay Product</i>
CPU	<i>Central Processing Unit</i>
GPU	<i>Graphics Processing Unit</i>
IoU	<i>Intersection over Union</i>
CNN	<i>Convolutional Neural Network</i>
AI	<i>Artificial Intelligence</i>
DL	<i>Deep learning</i>
ML	<i>Machine Learning</i>
IoT	<i>Internet of Things</i>
RAM	<i>Random Access Memory</i>
ms	<i>millisecond</i>
W	<i>watt</i>

DAFTAR LAMPIRAN

Lampiran 1 Contoh Dataset Cabai Katokkon	57
Lampiran 2 <i>Source Code</i> Training Model YOLOv8 dan YOLOv9	58
Lampiran 3 <i>Source Code</i> Training Model YOLOv7	59
Lampiran 4 <i>Source Code</i> Inferensi <i>Raspberry Pi</i>	61
Lampiran 5 <i>Source Code</i> Inferensi <i>Jetson Nano</i>	64
Lampiran 6 Program Aplikasi Android.....	65
Lampiran 7 Dokumentasi Pengujian.....	66

KATA PENGANTAR

Puji dan syukur penulis panjatkan kepada Tuhan Yang Maha Esa atas berkat dan rahmat-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul **“Klasifikasi Kualitas Cabai Katokkon dengan *Deep learning* pada Perangkat *Edge computing*: Pengembangan dan Implementasi”** sebagai salah satu syarat dalam menyelesaikan jenjang Strata-1 di Departemen Teknik Informatika, Fakultas Teknik, Universitas Hasanuddin.

Penulis menyadari bahwa penyusunan dan penulisan tugas akhir ini tidak dapat terselesaikan dengan baik tanpa adanya bantuan, bimbingan, serta dukungan dari berbagai pihak. Oleh karena itu, penulis ingin menyampaikan ucapan terima kasih banyak kepada:

1. Kedua orang tua penulis, Bapak Iwan Ignatius Adam dan Ibu Rufina Ishak yang tidak pernah lelah mendoakan, memberikan semangat serta dukungan kepada penulis.
2. Bapak Dr. Eng. Muhammad Niswar, S.T., M.IT. selaku pembimbing I dan Ibu Dr. Ir. Ingrid Nurtanio, M.T. selaku pembimbing II, yang senantiasa menyediakan waktu, tenaga, pikiran dan perhatian dalam mengarahkan penulis dalam penyusunan tugas akhir.
3. Segenap staf dan dosen Departemen Teknik Informatika, Fakultas Teknik, Universitas Hasanuddin yang telah membantu semasa perkuliahan dan dalam penyelesaian tugas akhir.
4. Teman-teman peneliti yang berada dalam satu grup penelitian smart farming, yakni Juan Jimmy Dwiangga AL, kak Syahril Saputra, kak Fauzul Ichwan, kak Serwil Han Yon Pirade, kak Ilham, dan kak Jacklyn Mantong atas bimbingannya selama penelitian ini berlangsung.
5. Teman-teman peneliti dalam Lab Cloud Computing, Arfandi, Artia, Brili, Dita, Faiz, Juan, Marcel, Rajab, Rayyan, Sayyid, Sila, yang selalu ada di lab membantu penulis dalam melakukan penelitiannya.
6. Teman - Teman Signifier 2019 atas dukungan, bantuan, dan semangat yang telah diberikan selama ini.

7. Serta seluruh pihak yang tak sempat penulis sebutkan satu per satu, tanpa sadar telah menjadi motivasi penulis dalam menyelesaikan tugas akhir.

Akhir kata, harapan Penulis semoga Tugas Akhir ini dapat memberikan manfaat bagi siapa saja yang membacanya.

Gowa, Agustus 2024

Penulis,
William

BAB I PENDAHULUAN

1.1 Latar Belakang

Cabai Katokkon (*Capsicum annum L. var. sinensis*) adalah jenis cabai yang paling banyak dikonsumsi di daerah Toraja, mendominasi 80% kelompok cabai besar di Kabupaten Toraja Utara. Cabai ini memiliki rasa yang sangat pedas dan aroma khas, sehingga selalu dicari sebagai bumbu penyedap, khususnya untuk makanan khas Toraja. Dengan waktu tanam hingga panen yang hanya tiga bulan, cabai Katokkon dapat dipanen sebanyak 4-5 kali, menjadikannya komoditas unggulan bagi petani cabai di Toraja (Daryono & Tammu, 2022).

Namun, budidaya cabai Katokkon seringkali dihadapkan pada serangan hama dan penyakit, seperti ulat dan lalat buah, yang dapat menyebabkan kerugian produksi yang signifikan (Daryono & Tammu, 2022). Oleh karena itu, dalam proses pascapanen, sortasi cepat dan tepat berdasarkan standar SNI mengenai kadar kotoran, tingkat kerusakan, dan busuk cabai menjadi sangat penting. Cabai Katokkon memiliki daya simpan hanya sekitar 7-10 hari (Daryono & Tammu, 2022), sehingga efisiensi dalam proses sortasi adalah krusial.

Proses sortasi yang dilakukan secara manual oleh perusahaan pengolah maupun petani sering kali memakan waktu lama dan tidak konsisten karena keterbatasan manusia. Kelelahan dan perbedaan persepsi mengenai kualitas cabai dapat mengakibatkan ketidakkonsistenan dalam hasil sortasi. Oleh karena itu, diperlukan sistem otomatis yang dapat mengenali kualitas cabai dan melakukan sortasi secara efisien dan konsisten, seperti sistem sortasi otomatis yang memanfaatkan teknik pengolahan citra digital.

Teknik *Deep learning* (DL), bagian dari *Machine Learning* yang berfokus pada jaringan saraf buatan dengan tiga atau lebih lapisan, dapat digunakan untuk pengolahan citra. Salah satu metode yang sangat efektif untuk deteksi dan klasifikasi objek dalam citra adalah YOLO (*You Only Look Once*). YOLO mampu melakukan deteksi objek secara *real-time* dengan akurasi tinggi, menjadikannya sangat cocok untuk tugas sortasi otomatis cabai Katokkon. Jaringan-jaringan ini meniru beberapa aspek fungsi otak manusia dan mampu mempelajari data-data

kompleks, memungkinkan peningkatan prediksi melalui paparan dataset yang ekstensif (Goodfellow et al., 2016; IBM; Redmon et al., 2016).

Penelitian ini akan mengevaluasi performa *Deep learning* yang diimplementasikan pada perangkat *edge computing*. Perangkat *edge computing* melakukan pemrosesan data secara lokal, dekat dengan sumbernya, menawarkan kecepatan, responsivitas tinggi, pengurangan beban jaringan, dan keamanan data yang lebih baik dibandingkan dengan komputasi *cloud* (Satyanarayanan, 2017). Penelitian terkait menunjukkan bahwa perangkat *edge* dapat mengurangi beban komputasi pada sistem terpusat dan meningkatkan efisiensi memori dan waktu eksekusi (Dhiman et al., 2023; Li et al., 2018).

Berbagai penelitian sebelumnya mengenai klasifikasi buah menggunakan teknik pemrosesan gambar dan *deep learning* menunjukkan penggunaan dataset yang bervariasi dan berbagai algoritma pendeteksi objek seperti YOLOv7 dan Faster R-CNN, dengan akurasi berkisar antara 86% hingga lebih dari 99% (Amin et al., 2023; Basri et al., 2019; Khatun et al., 2020; Liu et al., 2020; Mimma et al., 2022). Penelitian-penelitian ini juga membandingkan berbagai arsitektur model jaringan saraf konvolusi (CNN), seperti ResNet50, VGG16, dan MobileNetV2, serta efisiensi komputasi yang berperan penting dalam aplikasi praktis (Amin et al., 2023; Basri et al., 2019; Liu et al., 2020)

Berdasarkan uraian di atas, maka penulis mengangkat sebuah penelitian dengan judul “**Klasifikasi Kualitas Cabai Katokkon dengan *Deep learning* pada Perangkat *Edge computing*: Pengembangan dan Implementasi**”.

1.2 Rumusan Masalah

Berdasarkan latar belakang permasalahan yang telah dipaparkan di atas, maka rumusan masalah yang akan diselesaikan adalah:

1. Bagaimana mengembangkan sebuah model berbasis *Deep learning* pada perangkat *edge computing* yang dapat mengklasifikasikan kualitas cabai katokkon secara efisien dan akurat?
2. Bagaimana performa model pada berbagai perangkat *edge computing* dalam mengenali tingkat kualitas cabai?

1.3 Tujuan Penelitian

Tujuan dari penelitian ini adalah:

1. Mengembangkan model berbasis *Deep learning* pada *perangkat edge computing* yang dapat mengklasifikasikan berbagai tingkat kualitas dari cabai Katokkon secara akurat.
2. Menganalisis performa model pada berbagai perangkat *edge computing*.

1.4 Manfaat Penelitian

Manfaat dari penelitian yang akan dilaksanakan ini adalah sebagai berikut:

1. Menghasilkan sebuah model pembelajaran mesin yang mampu mengenali tingkat kualitas cabai Katokkon dengan baik.
2. Mempermudah proses penyortiran cabai Katokkon, memberikan bantuan signifikan bagi para petani dan produsen dalam mengurangi waktu dan biaya yang dibutuhkan untuk sortasi manual.
3. Menyediakan referensi bagi penelitian selanjutnya dalam bidang klasifikasi citra buah.

1.5 Ruang Lingkup

1. Jenis data yang digunakan adalah gambar cabai katokkon.
2. Klasifikasi yang akan dibuat adalah sebanyak 4 kelas, yaitu *Grade A*, *Grade B*, *Defect*, dan *Fly Bites*.
3. Arsitektur CNN yang digunakan adalah YOLO (YOLOv7, YOLOv8, YOLOv9).
4. Kinerja model akan dievaluasi menggunakan metrik yang sesuai seperti *Precision*, *Recall*, *mAP*, dan *F1-score*.
5. Perangkat yang digunakan adalah *Smartphone*, *Raspberry Pi*, dan *Jetson Nano*.

BAB II TINJAUAN PUSTAKA

2.1 Cabai

Cabai (*Capsicum*) adalah buah dari tanaman genus *Capsicum* yang berasal dari Amerika. Cabai termasuk dalam keluarga *Solanaceae*, yang juga beranggotakan tomat, kentang, dan terong. Jenis cabai yang banyak dibudidayakan di Indonesia ialah cabai merah (*Capsicum annuum L.*) dan cabai rawit (*Capsicum frutescens L.*). (Daryono & Tammu, 2022). Selain sebagai bumbu dapur yang menambah rasa pedas pada makanan, juga memiliki banyak manfaat kesehatan karena mengandung senyawa bioaktif seperti karotenoid, asam askorbat, senyawa fenolik, capsaicinoid, dan kapsinoid. Senyawa-senyawanya memberikan cabai sifat antioksidan, antiinflamasi, antikanker, pereda nyeri, kardiovaskular, gastrointestinal, antidiabetes, anti-obesitas, antimikroba, dan antijamur. Komposisi kimiawi cabai bisa berbeda-beda tergantung pada variasi kultivar yang ada. Ketersediaan senyawa bioaktif yang beragam membuat cabai menjadi agen alami yang berharga untuk pencegahan berbagai penyakit, terutama yang berkaitan dengan radikal bebas dan mikroba (Duranova et al., 2022).

Selain cabai merah dan cabai rawit, Indonesia juga memiliki beragam varietas cabai lokal yang unik, salah satunya adalah cabai katokkon. Berdasarkan data pendaftaran varietas dari PVTTP tahun 2014, cabai katokkon secara ilmiah diklasifikasikan sebagai *Capsicum annuum L. var. sinensis* (PVTTP 2014). Cabai ini terkenal dengan aromanya yang khas dan rasanya yang sangat pedas sehingga sering digunakan sebagai bumbu masakan Toraja.

2.2 Visi Komputer

Visi komputer adalah bidang kecerdasan buatan yang berfokus pada kemampuan komputer untuk memahami dan menginterpretasikan informasi visual dari gambar atau video. Hal ini melibatkan pengembangan algoritme dan teknik untuk mengekstrak wawasan, pola, dan pengetahuan yang bermakna dari data visual, yakni meniru kemampuan persepsi visual manusia (Gupta, 2022). Visi komputer merupakan kombinasi dari pengolahan citra dan pengenalan pola.

2.2.1 Pengolahan Citra

Pengolahan citra adalah proses analisis dan manipulasi gambar digital untuk meningkatkan kualitasnya, mengekstrak informasi yang berguna, atau melakukan tugas-tugas tertentu. Proses ini melibatkan transformasi gambar menjadi bentuk yang lebih berguna dan dapat dimengerti oleh manusia atau digunakan dalam aplikasi komputasi lainnya. Pengolahan citra melibatkan teknik dan algoritma seperti pra-pemrosesan, segmentasi, augmentasi, ekstraksi fitur, restorasi dan rekonstruksi, serta pemrosesan spasial dan frekuensi (A et al., 2023)

2.2.2 Augmentasi Gambar

Augmentasi gambar adalah teknik yang digunakan dalam pemrosesan gambar untuk meningkatkan ukuran dan keragaman kumpulan data secara artifisial dengan menerapkan berbagai transformasi pada gambar yang ada. Teknik ini biasanya digunakan dalam pembelajaran mesin dan tugas-tugas visi komputer untuk meningkatkan kinerja dan generalisasi model. Beberapa teknik augmentasi gambar yang umum meliputi: rotasi, translasi, *scaling*, *flipping*, penambahan *noise*, dan penyesuaian kecerahan/kontras. Augmentasi gambar membantu mengurangi overfitting, meningkatkan ketahanan model, dan meningkatkan keragaman data pelatihan (A et al., 2023)

2.2.3 Pengenalan Pola

Pengenalan pola adalah metode analisis data yang menggunakan algoritme pembelajaran mesin untuk secara otomatis mengenali pola dan keteraturan dalam data. Metode ini dapat dibagi menjadi tiga jenis utama: statistik, struktural, dan neural, tergantung pada mekanisme yang digunakan untuk mengklasifikasikan data input. Dalam konteks pengenalan gambar, pengenalan pola melibatkan pencocokan piksel dan pola untuk mengidentifikasi gambar dan bagian-bagiannya. Setiap gambar adalah kombinasi angka yang mewakili kedalaman warna (Kumar, 2023).

2.3 Deteksi Objek

Deteksi objek adalah teknik komputer yang dapat mencari objek-objek tertentu dari dalam gambar dan video digital seperti orang, bangunan, dan mobil. Deteksi objek memiliki keterkaitan dengan visi komputer dan pemrosesan gambar. Pendeteksian objek berguna dalam berbagai tugas pengenalan visual, termasuk pengambilan gambar dan pemantauan video. Teknologi ini telah ditingkatkan berkali-kali untuk meningkatkan kinerja dalam hal kecepatan dan akurasi. Algoritme pembelajaran mendalam (*Deep learning*) telah memainkan peran penting dalam meningkatkan kinerja deteksi objek, yang bermanfaat bagi berbagai aplikasi seperti deteksi pejalan kaki, pencitraan medis, robotika, mobil swakemudi, dan pengenalan wajah. Deteksi objek digunakan secara luas dalam industri, mulai dari pengamanan individu hingga produktivitas bisnis (Namdev et al., 2022).

2.4 *Edge computing*

Edge computing, atau Komputasi Tepi, adalah pendekatan pemrosesan data yang dilakukan dengan menyimpan informasi langsung di perangkat atau lokasi terdekat dengan sumber data, alih-alih mengirim semuanya ke pusat data. Konsep ini memungkinkan komputasi dilakukan di "tepi" jaringan, bukan di pusatnya (Satyanarayanan, 2017). *Edge computing* menjadi semakin penting dalam era *Internet of Things* (IoT) dan aplikasi *real-time*. Berikut adalah beberapa manfaat utamanya:

1. Latensi yang Lebih Baik

Dengan mendekatkan sumber daya komputasi dan penyimpanan ke perangkat dan pengguna, *edge computing* mengurangi waktu yang dibutuhkan data untuk melakukan perjalanan bolak-balik antara perangkat dan cloud. Ini menghasilkan latensi yang lebih rendah dan waktu respons yang lebih cepat. Misalnya, dalam aplikasi industri atau kendaraan otonom, pengurangan latensi ini sangat krusial untuk operasional yang aman dan efisien.

2. Peningkatan *Bandwidth*

Edge computing memungkinkan data diproses dan dianalisis secara lokal, mengurangi kebutuhan untuk mengirim data dalam jumlah besar ke *cloud*. Hal

ini membantu mengurangi kepadatan jaringan dan meningkatkan *bandwidth* yang tersedia untuk aplikasi lain. Contohnya, kamera keamanan pintar yang menggunakan *edge computing* dapat menganalisis video secara lokal dan hanya mengirimkan data yang relevan ke *cloud*.

3. Keamanan

Dengan *edge computing*, data dapat diproses dan disimpan secara lokal, mengurangi kebutuhan untuk mengirim informasi sensitif ke *cloud*. Ini meningkatkan privasi dan keamanan data, serta membangun kepercayaan antara pengguna dan penyedia layanan. Sebagai contoh, data medis yang diproses di *edge* perangkat medis dapat menjaga kerahasiaan pasien dengan lebih baik dibandingkan jika data tersebut dikirim ke *cloud*.

4. Kemampuan Bertahan yang Lebih Baik

Mendistribusikan sumber daya komputasi dan penyimpanan di seluruh tepi jaringan meningkatkan ketahanan dan daya tahan sistem secara keseluruhan. Hal ini sangat penting dalam skenario di mana konektivitas jaringan mungkin tidak dapat diandalkan atau terputus-putus, seperti di daerah terpencil atau selama bencana alam.

Edge computing menawarkan pendekatan terdesentralisasi untuk komputasi yang membawa kemampuan komputasi lebih dekat ke perangkat dan pengguna, memungkinkan proses yang lebih cepat dan lebih efisien.

2.5 Convolutional Neural Network

Convolutional Neural Network (CNN) adalah jenis jaringan saraf yang dirancang untuk memproses data dalam bentuk grid, seperti gambar. CNN efektif dalam menangani tugas pengenalan objek dan visi komputer, serta menunjukkan hasil yang menjanjikan dalam pemrosesan bahasa alami (NLP) dan pengenalan suara (Bacchi et al., 2019; Manaswi, 2018).

Berbeda dengan jaringan saraf biasa, CNN memiliki fitur ekstraksi yang terdiri dari lapisan konvolusi dan lapisan *down-sampling*. Sebuah neuron pada CNN hanya terhubung ke bagian tertentu dari input, yang dikenal sebagai bidang reseptif

lokal. Lapisan konvolusi biasanya memiliki beberapa peta fitur, di mana setiap peta fitur terdiri dari sejumlah *neuron*, dan bobot *neuron* dibagi di antara peta fitur yang sama. Pembagian bobot ini mengurangi jumlah koneksi dan parameter dalam jaringan, membantu mencegah *overfitting*. Nilai awal kernel konvolusi dihasilkan secara acak dan diperbarui selama proses pelatihan. *Down-sampling*, atau *pooling*, adalah proses konvolusi khusus yang mengurangi dimensi data.

2.5.1 Local Receptive Field

Pada CNN, setiap *neuron* di lapisan tersembunyi terhubung ke area kecil pada lapisan *input*, yang disebut bidang reseptif lokal. Setiap koneksi memiliki bobot parameter dan offset yang dapat dipelajari (Tian, 2020).

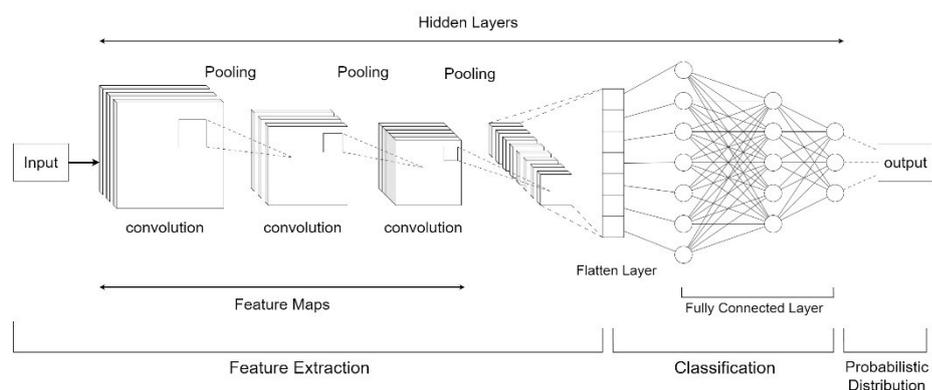
2.5.2 Weight Sharing

Weight sharing berarti bobot yang digunakan oleh neuron-neuron di lapisan tersembunyi adalah sama. Ini mengurangi jumlah parameter yang harus dipelajari dan mempercepat proses pelatihan (Tian, 2020).

2.5.3 Pooling

Lapisan *pooling* biasanya ditempatkan setelah lapisan konvolusi untuk mengurangi dimensi data dan jumlah parameter. *Pooling* mengurangi ukuran peta fitur dengan cara *down-sampling* (Tian, 2020).

2.5.4 Struktur CNN



Gambar 1 Struktur dari Convolutional Neural Network

CNN terdiri dari beberapa lapisan berjenjang yang mencakup lapisan input, lapisan tersembunyi untuk ekstraksi fitur, dan lapisan *output* untuk klasifikasi. Lapisan tersembunyi sering kali memiliki beberapa lapisan konvolusi dan *pooling*. Optimalisasi lapisan konvolusi dan *perceptron* dapat meningkatkan akurasi ekstraksi fitur dan efek klasifikasi (Tian, 2020).

1. *Convolutional Layer*

Lapisan konvolusi menggunakan *filter* (kernel) yang diterapkan pada *input* untuk mengekstraksi fitur gambar. Proses konvolusi membantu mengurangi *noise* dan meningkatkan fitur yang relevan. Konvolusi dilakukan di dalam bidang reseptif lokal, memungkinkan filter untuk menganalisis wilayah tertentu dari gambar. Pembagian bobot dalam konvolusi meningkatkan efisiensi parameter (Tian, 2020).

2. *Pooling Layer*

Pooling layer mengurangi dimensi spasial dari peta fitur yang dihasilkan oleh lapisan konvolusi. Ini mengurangi ukuran peta fitur dan kompleksitas komputasi dengan melakukan *down-sampling*.

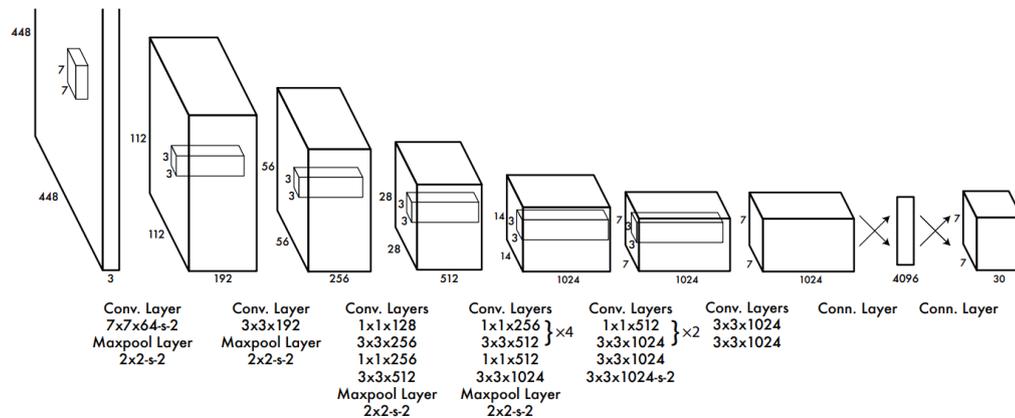
3. *Activation Layer*

Activation layer menerapkan fungsi aktivasi *non-linear* pada *output* dari *pooling layer*. Fungsi ini memperkenalkan *non-linearitas* ke dalam model, memungkinkan model untuk mempelajari representasi yang lebih kompleks dari data *input*. Fungsi aktivasi yang umum digunakan termasuk *sigmoid*, *Tanh*, *ReLU*, dan *leaky ReLU*.

4. *Fully Connected Layer*

Fully connected layer adalah lapisan yang menghubungkan semua *neuron* pada lapisan sebelumnya ke semua *neuron* pada lapisan berikutnya. Lapisan ini menggabungkan fitur-fitur yang dipelajari oleh lapisan konvolusi dan *pooling* untuk membuat prediksi.

2.6 Arsitektur Model YOLO



Gambar 2 Arsitektur YOLO dari (Redmon et al., 2016)

YOLO (*You Only Look Once*) adalah model pendeteksian objek dan segmentasi gambar yang populer, dikembangkan oleh Joseph Redmon dan Ali Farhadi di Universitas Washington. Diluncurkan pada tahun 2015, YOLO dengan cepat mendapatkan popularitas karena kecepatannya yang tinggi. Model ini unik karena mendeteksi objek dalam sebuah gambar dengan sekali pandang (*one look*), berbeda dengan pendekatan lain yang melakukan deteksi secara berulang

2.6.1 YOLOv7

YOLOv7 adalah pendeteksi objek *real-time* terbaru yang mencapai kinerja terbaik di antara semua pendeteksi objek yang dikenal, baik dalam hal kecepatan maupun akurasi, dengan rentang 5 FPS hingga 160 FPS. YOLOv7 memiliki akurasi tertinggi (56.8% AP) di antara semua pendeteksi objek *real-time* yang mencapai 30 FPS atau lebih pada GPU V100. Selain itu, YOLOv7 mengungguli pendeteksi objek lainnya seperti YOLOR, YOLOX, Scaled-YOLOv4, YOLOv5, dan banyak lagi dalam hal kecepatan dan akurasi (Wang et al., 2022)

Fitur kunci yang diperkenalkan oleh YOLOv7 meliputi:

1. *Model Re-parameterization*: YOLOv7 menggunakan strategi re-parameterisasi terencana yang dapat diterapkan pada lapisan-lapisan di berbagai jaringan dengan konsep jalur propagasi gradien.

2. *Dynamic Label Assignment*: Untuk mengatasi masalah penugasan target dinamis untuk keluaran dari berbagai cabang pada model dengan beberapa lapisan keluaran, YOLOv7 memperkenalkan metode penugasan label baru yang disebut penugasan label *coarse-to-fine lead guided*.
3. *Extended and Compound Scaling*: YOLOv7 mengusulkan metode "*extend*" dan "*compound scaling*" untuk pendeteksi objek *real-time* yang dapat secara efektif memanfaatkan parameter dan komputasi.
4. *Efficiency*: Metode yang diusulkan oleh YOLOv7 dapat mengurangi sekitar 40% parameter dan 50% komputasi dari pendeteksi objek *real-time* mutakhir, serta memiliki kecepatan inferensi yang lebih cepat dan akurasi deteksi yang lebih tinggi.

2.6.2 YOLOv8

YOLOv8 menawarkan kinerja terdepan dalam hal akurasi dan kecepatan. Dengan membangun atas kemajuan versi YOLO sebelumnya, YOLOv8 memperkenalkan fitur-fitur dan optimasi baru yang membuatnya menjadi pilihan ideal untuk berbagai tugas pendeteksian objek dalam berbagai aplikasi. Fitur kunci yang diperkenalkan oleh YOLOv8 meliputi:

1. *Advanced Backbone and Neck Architectures*: YOLOv8 menggunakan arsitektur backbone dan neck terbaru, yang menghasilkan peningkatan ekstraksi fitur dan kinerja pendeteksian objek.
2. *Anchor-free Split Ultralytics Head*: YOLOv8 mengadopsi kepala Ultralytics split tanpa *anchor*, yang berkontribusi pada akurasi yang lebih baik dan proses pendeteksian yang lebih efisien dibandingkan pendekatan berbasis *anchor*.
3. *Optimized Accuracy-Speed Tradeoff*: Dengan fokus pada pemeliharaan keseimbangan optimal antara akurasi dan kecepatan, YOLOv8 cocok untuk tugas pendeteksian objek *real-time* di berbagai area aplikasi.
4. *Variety of Pre-trained Models*: YOLOv8 menawarkan berbagai model yang telah dilatih sebelumnya untuk memenuhi berbagai tugas dan kebutuhan kinerja, membuatnya lebih mudah untuk menemukan model yang tepat untuk kasus penggunaan spesifik Anda.

2.6.3 YOLOv9

YOLOv9 menandai kemajuan signifikan dalam pendeteksian objek *real-time*, memperkenalkan teknik-teknik inovatif seperti *Programmable Gradient Information* (PGI) dan *Generalized Efficient Layer Aggregation Network* (GELAN). Model ini menunjukkan peningkatan luar biasa dalam efisiensi, akurasi, dan adaptabilitas, menetapkan tolok ukur baru pada dataset MS COCO (Wang et al., 2024).

Inovasi inti dari YOLOv9 meliputi:

1. *Programmable Gradient Information* (PGI): Mengatasi tantangan kehilangan informasi yang melekat dalam jaringan neural dalam, PGI meningkatkan kapasitas pembelajaran model dengan memastikan retensi informasi penting selama proses pendeteksian.
2. *Generalized Efficient Layer Aggregation Network* (GELAN): Arsitektur GELAN yang serbaguna meningkatkan kapasitas pembelajaran model dan memastikan informasi penting dipertahankan, yang menghasilkan akurasi dan kinerja yang luar biasa.
3. *Efficiency and Accuracy*: Dengan prinsip *Information Bottleneck* dan penggunaan fungsi reversibel yang inovatif, YOLOv9 menjaga efisiensi dan akurasi yang tinggi.