

**KLASIFIKASI OBJEK MAKANAN DENGAN
MENGGUNAKAN METODE *CONVOLUTIONAL
NEURAL NETWORK (CNN)***

TUGAS AKHIR



Oleh :

Cynthia Caroline

09011281520101

**JURUSAN SISTEM KOMPUTER
FAKULTAS ILMU KOMPUTER
UNIVERSITAS SRIWIJAYA
2021**

**KLASIFIKASI OBJEK MAKANAN DENGAN
MENGGUNAKAN METODE *CONVOLUTIONAL
NEURAL NETWORK (CNN)***

TUGAS AKHIR

Diajukan Untuk Melengkapi Salah Satu Syarat

Memperoleh Gelar Sarjana Komputer



CYNTHIA CAROLINE

09011281520101

**JURUSAN SISTEM KOMPUTER
FAKULTAS ILMU KOMPUTER
UNIVERSITAS SRIWIJAYA
2021**

LEMBAR PENGESAHAN

KLASIFIKASI OBJEK MAKANAN DENGAN MENGGUNAKAN METODE *CONVOLUTIONAL NEURAL NETWORK (CNN)*

TUGAS AKHIR

Diajukan Untuk Melengkapi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer

Oleh :

CYNTHIA CAROLINE
09011281520101

Palembang, Januari 2021

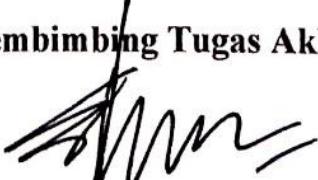
Mengetahui,

Ketua Jurusan Sistem Komputer,



Dr. Ir. Sukemi, M.T.
NIP. 196612032006041001

Pembimbing Tugas Akhir,



Prof. Dr. Ir. Siti Nurmaini, M.T.
NIP. 196908021994012001

HALAMAN PERSETUJUAN

Pada hari Rabu 30 Desember 2020 telah dilaksanakan ujian sidang tugas akhir oleh Sarjana Ilmu Komputer Fakultas Ilmu Komputer Universitas Sriwijaya

Nama : Cynthia Caroline

NIM : 09011281520101

Judul : Klasifikasi Objek Makanan dengan Menggunakan Metode
Convolutional Neural Network (CNN)

Tim Penguji :

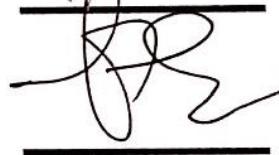
1. Ketua : Rendyansyah, M.T



2. Sekretaris : Rahmat Fadli Isnanto, M.Sc



3. Anggota I : Dr. Ir. Bambang Tutuko, M.T



Mengetahui,

Ketua Jurusan Sistem Komputer

Dr. Ir. Sukemi, M.T.
NIP. 196612032006041001



HALAMAN PERNYATAAN

Yang bertanda tangan di bawah ini :

Nama : Cynthia Caroline

NIM : 09011281520101

Judul : Klasifikasi Objek Makanan Dengan Menggunakan Metode *Convolutional Neural Network (CNN)*

Hasil pengecekan Software iThenticate/Turnitin : 1%

Menyatakan bahwa Laporan Tugas Akhir saya merupakan hasil karya sendiri dan bukan hasil penjiplakan atau plagiat. Apabila ditemukan unsur penjiplakan atau plagiat dalam Laporan Tugas Akhir ini, maka saya bersedia menerima sanksi akademik dari Universitas Sriwijaya. Demikian, pernyataan ini saya buat dalam keadaan sadar dan tidak dipaksakan.



Palembang,

Januari 2021



Cynthia Caroline

NIM. 09011281520101

KATA PENGANTAR

Puji syukur penulis panjatkan kepada Tuhan Yang Maha Esa, atas segala karunia dan rahmat-Nya sehingga penulis dapat menyelesaikan penyusunan Tugas Akhir ini dengan judul “Klasifikasi Objek Makanan Dengan Menggunakan Metode *Convolutional Neural Network (CNN)*”.

Tujuan penulisan Tugas Akhir ini untuk melengkapi salah satu syarat memperoleh gelar Sarjana Komputer di Jurusan Sistem Komputer, Fakultas Ilmu Komputer, Universitas Sriwijaya. Pada kesempatan ini, penulis juga menyampaikan ucapan terima kasih yang sebesar-besarnya kepada semua pihak yang telah membantu baik dari segi moril ataupun materil serta memberikan dorongan, saran dan kritik selama dalam proses penulisan Tugas Akhir ini. Oleh karena itu, pada kesempatan ini penulis sekaligus mengucapkan rasa syukur kepada Tuhan Yang Maha Esa dan terima kasih kepada yang terhormat :

1. Orang Tua dan ketiga saudara kandung penulis tercinta, yang selalu mendukung penulis meskipun kakak dan adik terpisah jarak yang jauh.
2. Direktorat Jendral Pembelajaran dan Kemahasiswaan Kementerian Riset, Teknologi, dan Pendidikan Tinggi Republik Indonesia yang telah membiayai dan mendukung kegiatan tim REOMAJAS serta Tugas Akhir ini sehingga dapat menyelesaikan proses Tugas Akhir ini dengan baik.
3. Bapak Jaidan Jauhari, S.Pd. M.T selaku Dekan Fakultas Ilmu Komputer Universitas Sriwijaya.
4. Bapak Dr. Ir. Sukemi, M.T. selaku Ketua Jurusan Sistem Komputer Fakultas Ilmu Komputer Universitas Sriwijaya
5. Ibu Prof. Dr. Ir. Siti Nurmaini, M.T. selaku Pembimbing Tugas Akhir Penulis yang selalu memberikan nasihat, arahan dan dukungan moril selama pembuatan tugas akhir.

6. Bapak Deris Stiawan, M.T., Ph. D., selaku Dosen Pembimbing Akademik di Jurusan Sistem Komputer Fakultas Ilmu Komputer Universitas Sriwijaya.
7. Bapak Dr. Bambang Tutuko, M.T. dan Bapak Firdaus, M.Kom selaku Dewan Pengaji Sidang Seminar Proposal dan Komprehensif.
8. Seluruh bapak/ibu dosen Jurusan Sistem Komputer.
9. Kak Winda dan Kak Renny selaku Admin di Jurusan Sistem Komputer.
10. dr. Timotius Wira Yudha yang selalu membantu dan memotivasi penulis.
11. Seluruh teman-teman tercinta yang pernah bekerja sama dan memberikan inspirasi bagi penulis selama di PIMNAS ke-31 dan PIMNAS ke-32.
12. Seluruh teman-teman terdekat penulis yang selalu mendukung penulis.
13. Kakak-kakak baik dan teman – teman di Intelligent System Research Group.
14. Teman – teman seangkatan 2015 Sistem Komputer.
15. Semua teman dan pihak yang telah membantu secara langsung maupun tidak langsung. Penulis memohon maaf tidak dapat menyebutkan satu persatu namun tentunya penulis selalu mengingat seluruh jasa orang-orang yang terkandung dalam poin-poin yang telah dicantumkan penulis.

Penulis menyadari bahwa tugas akhir ini masih jauh dari kata sempurna dan masih membutuhkan peningkatan dari segi kualitas penelitian yang dilakukan. Oleh sebab itu, penulis mengharapkan kritik dan saran mengenai tugas akhir ini agar penelitian dikemudian hari dapat dilakukan dengan lebih baik. Diakhir, penulis berharap semoga tugas akhir ini dapat bermanfaat bagi kita semua, khususnya bagi mahasiswa-mahasiswi Fakultas Ilmu Komputer Universitas Sriwijaya sebagai sumbangannya dalam peningkatan mutu pembelajaran dan penelitian.

Palembang, Januari 2021
Penulis,

Cynthia Caroline
NIM. 09011281520101

KLASIFIKASI OBJEK MAKANAN DENGAN MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN)

Cynthia Caroline (09011281520101)

Jurusan Sistem Komputer, Fakultas Ilmu Komputer, Universitas Sriwijaya
Email : caroline@students.ilkom.unsri.ac.id

ABSTRAK

Media sosial merupakan wadah yang sering digunakan untuk berbagi momen dan strategi pemasaran, termasuk pemasaran makanan, namun beberapa foto makanan di media sosial tidak label keterangan. Masalah ini membuat pengguna sulit mengetahui jenis makanan tersebut jika jenis makanan tersebut tidak dijelaskan pada keterangannya. Oleh sebab itu, penelitian ini memberikan solusi untuk mengetahui jenis makanan secara cepat dan otomatis dengan tiga arsitektur dari metode Jaringan Saraf Konvolusional seperti AlexNet, Inception V3 dan Resnet 50 dan dikombinasikan dengan dua teknik pemrosesan gambar seperti Histogram Equalisation dan augmentasi data. Penelitian ini menggunakan dataset Food 101 yang merupakan kumpulan foto-foto yang diambil dari internet maupun media sosial. Melalui penelitian ini, didapatkan model dengan hasil terbaik, yaitu menggunakan metode Inception V3 dan augmentasi data dengan akurasi sebesar 99,03% sedangkan nilai presisi, sensitivitas dan nilai F1 dari metode tersebut mencapai 99%. Selain itu, nilai rata-rata error sebesar 0,005, nilai rata-rata positif palsu sebesar 0, dan nilai rata-rata negatif palsu sebesar 0,013. Disamping itu, penelitian ini juga mendapatkan bahwa metode AlexNet dan Histogram Equalisation merupakan model terburuk diantara lainnya dengan nilai akurasi, presisi, sensitivitas dan nilai F1 sebesar 23%. Kemudian, nilai rata-rata error sebesar 0,03, nilai rata-rata positif palsu sebesar 0,015, dan nilai rata-rata negatif palsu sebesar 0,76.

Kata Kunci : Klasifikasi Makanan, Pengenalan Gambar, Deep Learning, Jaringan Saraf Konvolusional

**FOOD IMAGE CLASSIFICATION BY USING CONVOLUTIONAL
NEURAL NETWORK (CNN)**

Cynthia Caroline (09011281520101)

*Departement of Computer Engineering, Faculty of Computer Science, Universitas
Sriwijaya*

Email : caroline@students.ilkom.unsri.ac.id

ABSTRACT

Social media are popular platforms frequently used to share mementos and as a means of marketing strategy, especially by the food industry. Unfortunately, most food photos in social media are not labelled or properly explained, and can lead to confusion by the user. To combat this problem, a novel solution was developed to detect food photos swiftly and automatically with three Convolutional Neural Network (CNN) architectures such as AlexNet, Inception V3, and Resnet 50. Two image processing techniques were implemented, namely Histogram Equalisation and data augmentation. The Food-101 dataset was used, which incorporated a range of diverse food images from the internet and social media. This study revealed that Inception V3 with data augmentation was the best model. Its accuracy was 99.03%, whereas the precision, recall, and F1-score was 99%. Moreover, it had an error rate of 0.005, false positive rate of 0, and false negative rate of 0.013. In addition, this paper demonstrated that the worst model was AlexNet with Histogram Equalization with an accuracy, precision, recall and F1-score of 23%. Furthermore, the error, false positive, and false negative rates were 0.03, 0.015, and 0.76, respectively.

Keywords : *Food Classification, Image Recognition, Deep Learning, Convolutional Neural Network*

DAFTAR ISI

| | Halaman |
|---|----------------|
| <u>Halaman Judul</u> | i |
| <u>Halaman Pengesahan</u> | ii |
| <u>Halaman Persetujuan</u> | .iii |
| <u>Halaman Pernyataan</u> | .iv |
| <u>Kata Pengantar</u> | v |
| <u>Abstrak</u> | v |
| <u>Abstract</u> | v |
| <u>Daftar Isi</u> | .viii |
| <u>Daftar Gambar</u> | xiii |
| <u>Daftar Tabel</u> | xvii |
| <u>Daftar Lampiran</u> | xx |
| | |
| BAB I PENDAHULUAN | 1 |
| 1.1. Latar Belakang..... | 1 |
| 1.2. Tujuan dan Manfaat..... | 2 |
| 1.2.1. Tujuan | 2 |
| 1.2.2. Manfaat | 3 |
| 1.3. Perumusan dan Batasan Masalah | 3 |
| 1.3.1. Perumusan Masalah | 3 |
| 1.3.2. Batasan Masalah..... | 3 |
| 1.4. Metodologi Penelitian | 4 |
| 1.4.1. Metode Studi Pustaka dan Literatur..... | 4 |

| | | |
|-------------------------------------|---|-----------|
| 1.4.2. | Metode Konsultasi | 4 |
| 1.4.3. | Metode Pembuatan Model | 4 |
| 1.4.4. | Metode Pengujian dan Validasi | 4 |
| 1.4.5. | Metode Hasil dan Analisa | 5 |
| 1.4.6. | Metode Penarikan Kesimpulan dan Saran | 5 |
| 1.5. | Sistematika Penulisan..... | 5 |
| BAB II TINJAUAN PUSTAKA..... | | 7 |
| 2.1. | Dataset Gambar Makanan | 7 |
| 2.1.1. | <i>Pittsburgh Food Image Dataset</i> | 7 |
| 2.1.2. | UEC Food 100 dan UEC Food 256..... | 9 |
| 2.1.3. | UPMC Food 101 dan ETHZ Food-101..... | 10 |
| 2.1.4. | ImageNet | 10 |
| 2.1.5. | Menu Match | 11 |
| 2.1.6. | Dataset 50-data | 11 |
| 2.2. | <i>Label Encoding Dataset</i> | 12 |
| 2.3. | Kecerdasan Buatan | 12 |
| 2.4. | Pembelajaran Mesin (<i>Machine Learning</i>)..... | 13 |
| 2.5. | <i>Deep Learning</i> | 14 |
| 2.6. | <i>Convolutional Neural Network (CNN)</i> | 15 |
| 2.6.1. | Jenis-Jenis Layer <i>Convolutional Neural Network</i> | 15 |
| 2.6.2. | Arsitektur <i>Convolutional Neural Network</i> | 21 |
| 2.7. | Optimasi | 25 |
| 2.7.1. | <i>Stochastic Gradient Descent (SGD)</i> | 26 |
| 2.7.2. | Adam | 26 |
| 2.8. | <i>Transfer Learning</i> | 27 |
| BAB III METODOLOGI..... | | 29 |

| | | |
|--------|---|----|
| 3.1. | Tahapan Pelaksanaan..... | 29 |
| 3.2. | Perangkat Keras..... | 30 |
| 3.3. | Persiapan Dataset..... | 30 |
| 3.4. | <i>Pre-processing</i> Data Gambar | 33 |
| 3.4.1. | Augmentasi Data..... | 33 |
| 3.4.2. | Histogram Equalization..... | 36 |
| 3.5. | Model Klasifikasi <i>Convolution Neural Network</i> (CNN)..... | 38 |
| 3.5.1. | <i>Learning Rate</i> dan <i>Momentum</i> | 39 |
| 3.5.2. | AlexNet | 40 |
| 3.5.3. | Inception V3..... | 41 |
| 3.5.4. | Resnet 50..... | 42 |
| 3.5.5. | <i>Early Stopping</i> dan <i>Callbacks</i> | 43 |
| 3.5.6. | Rancangan Pelatihan Dataset | 44 |
| 3.5.7. | Rancangan Pengujian Dataset | 45 |
| 3.6. | <i>Library</i> | 46 |
| 3.7. | Model Klasifikasi <i>Convolution Neural Network</i> (CNN)..... | 47 |
| 3.7.1. | <i>Confusion Matrix</i> | 48 |
| 3.7.2. | Presisi dan Sensitivitas | 50 |
| 3.7.3. | Akurasi | 51 |
| 3.7.4. | Spesifisitas..... | 52 |
| 3.7.5. | F1-score..... | 52 |
| | BAB IV HASIL DAN PEMBAHASAN | 54 |
| 4.1. | Pendahuluan | 55 |
| 4.2. | Detail Jaringan Saraf | 55 |
| 4.3. | Hasil Klasifikasi Objek Makanan dengan Menggunakan <i>Histogram Equalization</i> dan Metode <i>Convolutional Neural Network</i> | 61 |

| | | |
|---------------------------------|--|-----|
| 4.3.1. | Hasil Kinerja Model dengan Menggunakan AlexNet | 65 |
| 4.3.2. | Hasil Kinerja Model dengan Menggunakan Inception V3 | 85 |
| 4.3.3. | Hasil Kinerja Model dengan Menggunakan Resnet 50..... | 103 |
| 4.4. | Hasil Klasifikasi Objek Makanan dengan Menggunakan Augmentasi dan Metode <i>Convolutional Neural Network</i> | 121 |
| 4.4.1. | Hasil Kinerja Model dengan Menggunakan AlexNet | 123 |
| 4.4.2. | Hasil Kinerja Model dengan Menggunakan Inception V3 | 140 |
| 4.4.3. | Hasil Kinerja Model dengan Menggunakan Resnet 50..... | 157 |
| BAB V KESIMPULAN DAN SARAN..... | | 175 |
| 5.1. | Kesimpulan..... | 175 |
| 5.2. | Saran | 176 |
| DAFTAR PUSTAKA | | 177 |

DAFTAR GAMBAR

| | Halaman |
|---|----------------|
| Gambar 2.1 Beberapa contoh jenis makanan dan kategori dari dataset UEC-Food-100..... | 9 |
| Gambar 2.2 <i>Noise</i> yang ada pada dataset Food-101. | 10 |
| Gambar 2.3 Gambaran hubungan antara kecerdasan buatan, pembelajaran mesin, <i>deep learning</i> | 12 |
| Gambar 2.4 Arsitektur CNN | 14 |
| Gambar 2.5 96 filter konvolusi yang berukuran $3 \times 11 \times 11$ di lapisan pertama. Filter tersebut dilatih di ILSVRC-2010 | 15 |
| Gambar 2.6 Dua layer yang fully connected tanpa dropout dan menggunakan dropout menurunkan 50% koneksi yang terjadi | 20 |
| Gambar 2.7 Arsitektur AlexNet | 22 |
| Gambar 2.8 Arsitektur ResNet (a) Modul Residual Asli, (b) Modul Residual yang menggunakan pra-aktivasi | 23 |
| Gambar 2.9 Modul Inception yang Digunakan GoogLeNet | 24 |
| Gambar 2.10 Tiga cara untuk membuat transfer meningkatkan pembelajaran..... | 28 |
| Gambar 3.1 Diagram alur metode penelitian | 29 |
| Gambar 3.2 Isi dataset yang digunakan | 32 |
| Gambar 3.3 Augmentasi data (a) gambar sesungguhnya (b) rentang putaran (c) <i>shear range</i> (d) rentang pergeseran lebar..... | 34 |
| Gambar 3.4 Augmentasi data (a) rentang pergeseran tinggi (b) perbesar (c) <i>horizontal flip</i> (d) <i>fill mode</i> | 35 |
| Gambar 3.5 Penerapan Histogram Equalization pada gambar RGB | 37 |
| Gambar 3.6 Diagram alur klasifikasi | 39 |
| Gambar 3.7 Alur pengujian dataset | 45 |
| Gambar 3.8 Alur pengujian dataset..... | 46 |

| | |
|--|-----|
| Gambar 4.1 Salah satu gambar makanan bernama edamame yang telah diterapkan Histogram Equalization. Kiri merepresentasikan gambar asli dan kanan merepresentasikan gambar yang telah menggunakan HE..... | 62 |
| Gambar 4.2 Grafik representasi sebelum pemerataan histogram..... | 63 |
| Gambar 4.3 Grafik representasi hasil dari pemerataan histogram | 63 |
| Gambar 4.4 Grafik proses pelatihan dataset dengan menampilkan nilai akurasi pada setiap <i>epoch</i> | 65 |
| Gambar 4.5 Grafik proses pelatihan dataset dengan menampilkan nilai <i>loss</i> pada setiap <i>epoch</i> | 66 |
| Gambar 4.6 Nilai akurasi setiap gambar (a) Gyoza (b) Baklava | 67 |
| Gambar 4.7 Confusion matrix AlexNet dan Histogram Equalization dengan 25 kelas dari 50 kelas (a) | 68 |
| Gambar 4.8 Confusion matrix AlexNet dan Histogram Equalization dengan 25 kelas dari 50 kelas (b) | 69 |
| Gambar 4.9 Grafik proses pelatihan dataset dengan menampilkan nilai akurasi pada setiap <i>epoch</i> | 86 |
| Gambar 4.10 Grafik proses pelatihan dataset dengan menampilkan nilai loss pada setiap <i>epoch</i> | 86 |
| Gambar 4.11 <i>Confusion Matrix</i> Inception V3 dengan menggunakan Histogram Equalization sebanyak 25 kelas dari 50 kelas (a) | 88 |
| Gambar 4.12 <i>Confusion Matrix</i> Inception V3 dengan menggunakan Histogram Equalization sebanyak 25 kelas dari 50 kelas (b)..... | 89 |
| Gambar 4.13 Grafik proses pelatihan dataset dengan menampilkan nilai akurasi pada setiap <i>epoch</i> | 103 |
| Gambar 4.14 Grafik proses pelatihan dataset dengan menampilkan nilai loss pada setiap <i>epoch</i> | 104 |
| Gambar 4.15 Nilai akurasi dari gambar Macarons dan Dumplings yang dimasukan ke sistem (a) Benar memprediksi Macarons (b) Salah memprediksi Dumplings..... | 104 |
| Gambar 4.16 Confusion Matrix Resnet 50 dengan menggunakan Histogram Equalization sebanyak 25 kelas dari 50 kelas (a) | 106 |

| | |
|---|-----|
| Gambar 4.17 Confusion Matrix Resnet 50 dengan menggunakan Histogram Equalization sebanyak 25 kelas dari 50 kelas (b)..... | 107 |
| Gambar 4.18 Grafik proses pelatihan dataset dengan menampilkan nilai akurasi pada setiap <i>epoch</i> | 124 |
| Gambar 4.19 Grafik proses pelatihan dataset dengan menampilkan nilai loss pada setiap <i>epoch</i> | 124 |
| Gambar 4.20 Nilai akurasi dari gambar Deviled Eggs dan Oysters yang dimasukan ke sistem (a) Benar memprediksi Deviled Eggs (b) Salah memprediksi Oyster..... | 125 |
| Gambar 4.21 <i>Confusion Matrix</i> AlexNet dengan menggunakan augmentasi sebanyak 25 kelas dari 50 kelas (a) | 126 |
| Gambar 4.22 <i>Confusion Matrix</i> AlexNet dengan menggunakan augmentasi sebanyak 25 kelas dari 50 kelas (b) | 127 |
| Gambar 4.23 Grafik proses pelatihan dataset dengan menampilkan nilai akurasi pada setiap <i>epoch</i> | 140 |
| Gambar 4.24 Grafik proses pelatihan dataset dengan menampilkan nilai <i>loss</i> pada setiap <i>epoch</i> | 141 |
| Gambar 4.25 Nilai akurasi dari gambar yang dimasukan ke sistem (a) Benar memprediksi Cannoli (b) Benar memprediksi Pho | 142 |
| Gambar 4.26 <i>Confusion Matrix</i> Inception V3 dengan menggunakan augmentasi 25 kelas dari 50 kelas (a)..... | 143 |
| Gambar 4.27 <i>Confusion Matrix</i> Inception V3 dengan menggunakan augmentasi 25 kelas dari 50 kelas (b)..... | 144 |
| Gambar 4.28 Grafik proses pelatihan dataset dengan menampilkan nilai akurasi pada setiap <i>epoch</i> | 158 |
| Gambar 4.29 Grafik proses pelatihan dataset dengan menampilkan nilai <i>loss</i> pada setiap <i>epoch</i> | 158 |
| Gambar 4.30 Nilai akurasi dari gambar yang dimasukan ke sistem (a) Pizza (b) Mussels | 159 |
| Gambar 4.31 <i>Confusion Matrix</i> Resnet 50 dengan menggunakan augmentasi 25 kelas dari 50 kelas (a) | 160 |

Gambar 4.32 *Confusion Matrix* Resnet 50 dengan menggunakan augmentasi
25 kelas dari 50 kelas (b) 161

DAFTAR TABEL

| | Halaman |
|---|----------------|
| Tabel 1 Perbandingan dataset publik untuk klasifikasi makanan | 8 |
| Tabel 2 Spesifikasi dataset Food-101 | 30 |
| Tabel 3 Parameter augmentasi dataset yang digunakan..... | 33 |
| Tabel 4 Spesifikasi model yang diterapkan pada AlexNet | 40 |
| Tabel 5 Spesifikasi model yang diterapkan pada Inception V3..... | 41 |
| Tabel 6 Spesifikasi model yang diterapkan pada ResNet 50..... | 43 |
| Tabel 7 Deskripsi <i>confusion matrix</i> | 48 |
| Tabel 8 TP, TN, FP, dan FN pada kelas A | 49 |
| Tabel 9 Arsitektur AlexNet yang digunakan | 55 |
| Tabel 10 Arsitektur Inception V3 | 57 |
| Tabel 11 Arsitektur Resnet 50 | 59 |
| Tabel 12 Nilai rata-rata pada perfoma model | 70 |
| Tabel 13 Top 5 hasil klasifikasi yang paling jelek pada dataset (dalam persen) | 71 |
| Tabel 14 Perfoma model terhadap kelas terbaik dan terburuk pada dataset | 72 |
| Tabel 15 Top 5 kelas teratas dengan kesalahan prediksi tertinggi (error tipe 2) | 73 |
| Tabel 16 Top 5 kelas teratas dengan kesalahan prediksi tertinggi (error tipe 1) | 76 |
| Tabel 17 Top 5 kelas teratas dengan kesalahan prediksi terendah (error tipe 2) | 80 |
| Tabel 18 Top 5 kelas teratas dengan kesalahan prediksi terendah (error tipe 1) | 83 |
| Tabel 19 Nilai rata-rata pada perfoma model | 90 |
| Tabel 20 Top 5 hasil klasifikasi yang paling jelek pada dataset (dalam persen) | 91 |
| Tabel 21 Perfoma model terhadap kelas terbaik dan terburuk pada dataset | 92 |

| | |
|--|-----|
| Tabel 22 Top 5 kelas teratas dengan kesalahan prediksi tertinggi (error tipe 2) | 93 |
| Tabel 23 Top 5 kelas teratas dengan kesalahan prediksi tertinggi (error tipe 1) | 96 |
| Tabel 24 Top 5 kelas teratas dengan kesalahan prediksi terendah (error tipe 2) | 98 |
| Tabel 25 Top 5 kelas teratas dengan kesalahan prediksi terendah (error tipe 1) | 101 |
| Tabel 26 Nilai rata-rata pada perfoma model | 108 |
| Tabel 27 Top 5 hasil klasifikasi yang paling jelek pada dataset (dalam persen) | 109 |
| Tabel 28 Perfoma model terhadap kelas terbaik dan terburuk pada dataset | 111 |
| Tabel 29 Top 5 kelas teratas dengan kesalahan prediksi tertinggi (error tipe 2) | 112 |
| Tabel 30 Top 5 kelas teratas dengan kesalahan prediksi tertinggi (error tipe 1) | 114 |
| Tabel 31 Top 5 kelas teratas dengan kesalahan prediksi terendah (error tipe 2) | 117 |
| Tabel 32 Top 5 kelas teratas dengan kesalahan prediksi terendah (error tipe 1) | 119 |
| Tabel 33 Nilai rata-rata pada perfoma model | 128 |
| Tabel 34 Top 5 hasil klasifikasi yang paling jelek pada dataset (dalam persen) | 129 |
| Tabel 35 Perfoma model terhadap kelas terbaik dan terburuk pada dataset | 130 |
| Tabel 36 Top 5 kelas teratas dengan kesalahan prediksi tertinggi (error tipe 2) | 131 |
| Tabel 37 Top 5 kelas teratas dengan kesalahan prediksi tertinggi (error tipe 1) | 133 |
| Tabel 38 Top 5 kelas teratas dengan kesalahan prediksi terendah (error tipe 2) | 136 |

| | |
|--|-----|
| Tabel 39 Top 5 kelas teratas dengan kesalahan prediksi terendah (error tipe 1) | 138 |
| Tabel 40 Nilai rata-rata pada perfoma model | 145 |
| Tabel 41 Top 5 hasil klasifikasi yang paling jelek pada dataset (dalam persen) | 146 |
| Tabel 42 Perfoma model terhadap kelas terbaik dan terburuk pada dataset | 147 |
| Tabel 43 Top 5 kelas teratas dengan kesalahan prediksi tertinggi (error tipe 2) | 148 |
| Tabel 44 Top 5 kelas teratas dengan kesalahan prediksi tertinggi (error tipe 1) | 150 |
| Tabel 45 Top 5 kelas teratas dengan kesalahan prediksi terendah (error tipe 2) | 153 |
| Tabel 46 Top 5 kelas teratas dengan kesalahan prediksi terendah (error tipe 1) | 155 |
| Tabel 47 Nilai rata-rata pada perfoma model | 162 |
| Tabel 48 Top 5 hasil klasifikasi yang paling jelek pada dataset (dalam persen) | 163 |
| Tabel 49 Perfoma model terhadap kelas terbaik dan terburuk pada dataset | 164 |
| Tabel 50 Top 5 kelas teratas dengan kesalahan prediksi tertinggi (error tipe 2) | 165 |
| Tabel 51 Top 5 kelas teratas dengan kesalahan prediksi tertinggi (error tipe 1) | 168 |
| Tabel 52 Top 5 kelas teratas dengan kesalahan prediksi terendah (error tipe 2) | 170 |
| Tabel 53 Top 5 kelas teratas dengan kesalahan prediksi terendah (error tipe 1) | 172 |

DAFTAR LAMPIRAN

Lampiran 1. 50 Jenis makanan yang digunakan dalam penelitian

Lampiran 2. Jenis makanan dataset Food-101

Lampiran 3. Metrik *confusion matrix* dengan menggunakan AlexNet dan augmentasi

Lampiran 4. Hasil pengukuran perfoma model menggunakan AlexNet dan augmentasi

Lampiran 5. Metrik *confusion matrix* dengan menggunakan Inception V3 dan augmentasi

Lampiran 6. Hasil pengukuran perfoma model menggunakan Inception V3 dan augmentasi

Lampiran 7. Metrik *confusion matrix* dengan menggunakan Resnet 50 dan augmentasi

Lampiran 8. Hasil pengukuran perfoma model menggunakan Resnet 50 dan augmentasi

Lampiran 9. Metrik *confusion matrix* dengan menggunakan AlexNet dan Histogram Equalization

Lampiran 10. Hasil pengukuran perfoma model menggunakan AlexNet dan Histogram Equalization

Lampiran 11. Metrik *confusion matrix* dengan menggunakan Inception V3 dan Histogram Equalization

Lampiran 12. Hasil pengukuran perfoma model menggunakan Inception V3 dan Histogram Equalization

Lampiran 13. Metrik *confusion matrix* dengan menggunakan Resnet 50 dan Histogram Equalization

Lampiran 14. Hasil pengukuran perfoma model menggunakan Resnet 50 dan Histogram Equalization

Lampiran 15. Berkas Revisi Tugas Akhir

Lampiran 16. Hasil Cek Plagiat

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Dalam tubuh manusia terdapat hormon ghrelin yang dilepaskan dalam jumlah yang besar ketika manusia menerima rangsangan visual melalui mata [1]. Ghrelin diproduksi di perut dan meningkatkan nafsu makan sehingga ketika manusia melihat foto makanan, ghrelin dengan cepat dilepaskan ke aliran darah dan menyebabkan lonjakan nafsu makan [2].

Dengan percepatan perkembangan media sosial, hormon ghrelin manusia digunakan sebagai strategi pemasaran. Saat ini, terdapat lebih dari 410 juta foto makanan pengguna media sosial membagi foto makanan di Instagram untuk berbagi dan melakukan pemasaran. Disamping itu, melalui survei yang dilakukan McGuire pada tahun 2015, lebih dari 88% responden menganggap makanan sebagai elemen penentu dalam memilih perjalanan tujuan [3]. Namun, sebagian besar foto makanan yang disebarluaskan melalui media sosial hampir semuanya hanya memuat lokasi tetapi dalam keadaan tidak berlabel dan membuat sebagian besar pencarian makanan tidak teratur dan sulit dibaca komposisinya.

Dalam mengembangkan perangkat lunak yang mampu mengidentifikasi citra dengan label secara cepat, metode *deep learning* sedang populer digunakan untuk klasifikasi gambar dan pengenalan pola. Sifatnya yang terinspirasi dari otak manusia dan kuat membuat arsitektur ini semakin dikembangkan dan membuat perfomanya lebih baik dibandingkan algoritma pembelajaran sebelumnya serta mampu memproses jumlah data gambar yang besar. Oleh sebab itu, penulis tertarik untuk mengembangkan suatu perangkat lunak yang mampu mengenali jenis makanan secara otomatis dan cepat dengan menggunakan algoritma *computer vision* dan konsep *deep learning*, yaitu *Convolutional Neural Networks* (CNN).

Pada penelitian sebelumnya juga telah dilakukan penelitian serupa, seperti penelitian Gwo Giun Lee *et al.* yang menggunakan dataset sebanyak 372.095 gambar dan 24 kategori pada tahun 2020 [4]. Penulis tersebut menggunakan pemrosesan gambar *Automatic White Balancing* (AWB) dan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) namun penulis tersebut hanya melakukan pemrosesan gambar tanpa melakukan pelatihan dataset dengan menggunakan arsitektur apapun sehingga tidak bisa dibuktikan bahwa teknik pemrosesan gambar tersebut benar.

Selain itu, ada penelitian yang serupa juga dikembangkan oleh Marc Bolanos pada tahun 2017 dengan menggunakan dataset Food 101, arsitektur Inception V3 dan arsitektur Resnet 50 namun tanpa menggunakan pemrosesan gambar [5]. Hasil presisi, sensitivitas dan nilai F1 pada arsitektur Resnet 50 di penelitian ini adalah 58,55%, 28,49% dan 38,33% sedangkan penelitian dengan menggunakan Inception V3 menghasilkan presisi sebesar 53,43%, sensitivitas 42,77% dan nilai F1 sebesar 47,51%. Oleh sebab itu, penelitian tugas akhir ini melakukan pengujian perfoma arsitektur CNN terhadap dataset dengan menggunakan beberapa metode berbeda dan berfokus pada implementasi teknik-teknik yang telah ada dan melakukan revisi pada penelitian tersebut untuk bertujuan sebagai referensi penelitian selanjutnya.

1.2 Tujuan dan Manfaat

1.2.1. Tujuan

Adapun tujuan dari penulisan Tugas Akhir ini adalah sebagai berikut :

1. Merancang model klasifikasi objek makanan dengan menggunakan beberapa metode *Convolutional Neural Network*.
2. Menganalisis TP, TN, FP, FN, spesifisitas, *false positive rate*, *false negative rate*, keakurasi, presisi, *recall* dan *f1-score* dari metode yang digunakan untuk mendeteksi jenis makanan yang diinputkan.

1.2.2. Manfaat

Manfaat dari penulisan Tugas Akhir ini, yaitu:

1. Untuk mengetahui kemampuan CNN terhadap dataset yang digunakan.
2. Penelitian ini dapat digunakan sebagai rujukan untuk penelitian selanjutnya.

1.3 Perumusan dan Batasan Masalah

1.3.1. Perumusan Masalah

Berdasarkan penelitian sebelumnya telah ada dilakukan penelitian mengenai klasifikasi objek makanan dengan kecerdasan buatan, salah satu metode yang memiliki nilai perfoma yang baik adalah *Convolutional Neural Network (CNN)*. Metode CNN memiliki beberapa bagian seperti Inception V3, AlexNet, VGG16, Resnet 50, hingga Xception. Oleh sebab itu, rumusan masalah dari penelitian ini adalah bagaimana mengklasifikasi objek makanan dengan menggunakan *Convolutional Neural Network (CNN)* untuk menghasilkan perfoma prediksi gambar yang baik sehingga dalam penelitian ini, penulis menggunakan bahasa pemrograman Python untuk melakukan pelatihan dan pengujian dengan menggunakan dataset Food-101. Hasil dari penelitian ini akan didapatkan hasil kinerja klasifikasi gambar makanan.

1.3.2. Batasan Masalah

Batasan masalah pada tugas akhir ini meliputi beberapa poin sebagai berikut:

1. Penelitian hanya membahas mengenai pengenalan gambar makanan.
2. Penelitian menggunakan 50 jenis makanan dari dataset Food-101.
3. Penelitian berfokus pada bagaimana arsitektur *Convolutional Neural Network (CNN)* diterapkan.
4. Keluaran hasil penelitian ini adalah nilai akurasi keseluruhan, nilai akurasi per kelas, nilai *true negative* setiap kelas, nilai *true positive* setiap kelas,

nilai *false positive* setiap kelas, nilai *false negative* setiap kelas, nilai rata-rata presisi, *f1-score*, *false positive rate*, *false negative rate*, spesifisitas dan sensitivitas serta nilai setiap kelasnya dari metode yang digunakan.

1.4. Metodologi Penelitian

Metodologi yang digunakan pada tugas akhir ini adalah sebagai berikut :

1.4.1. Metode Studi Pustaka dan Literatur

Metode ini menggunakan pengumpulan dan pencarian referensi berupa literature yang ada pada buku elektronik, jurnal dan website yang berkaitan dengan tugas akhir yang sedang dikerjakan.

1.4.2. Metode Konsultasi

Pada metode ini, penulis melakukan konsultasi baik secara langsung maupun tidak langsung kepada beberapa narasumber yang memiliki keilmuan yang baik dalam mengatasi permasalahan pada tugas akhir ini.

1.4.3. Metode Pembuatan Model

Metode ini dilakukan dengan cara merancang permodelan dengan menggunakan bahasa pemrograman Python.

1.4.4. Metode Pengujian dan Validasi

Metode pengujian terhadap perangkat lunak dilakukan untuk melihat dan melakukan validasi seberapa baik sistem yang telah dibuat.

1.4.5. Metode Hasil dan Analisa

Hasil dari pengujian dan validasi yang dilakukan, dianalisa keseluruhannya untuk mengetahui kekurangan serta kelebihan dari sistem tersebut, sehingga nantinya dapat digunakan sebagai referensi untuk penelitian selanjutnya.

1.4.6. Metode Penarikan Kesimpulan dan Saran

Di tahap terakhir, diambil kesimpulan sederhana dari hasil dan analisa penelitian yang dilakukan sekaligus memberikan saran dari penelitian yang dilakukan agar kedepannya dapat digunakan sebagai bahan rujukan penelitian selanjutnya.

1.5. Sistematika Penulisan

Dalam menyederhanakan penulisan dalam tugas akhir ini, berikut penataan penulisan tugas akhir sebagai berikut:

BAB I - PENDAHULUAN

Pada Bab I akan menjelaskan latar belakang dari tugas akhir, tujuan, rumusan masalah dan sistematika penulisan tugas akhir.

BAB II - TINJAUAN PUSTAKA

Pada Bab II akan berisikan dasar teori mengenai dataset gambar makanan yang akan digunakan pada penelitian ini, *label encoding dataset*, teori dasar mengenai kecerdasan buatan, pembelajaran mesin, dan *deep learning*, menjelaskan rinci salah satu metode dari *deep learning* yaitu *Convolutional Neural Network* (CNN), membahas macam-macam model yang digunakan untuk klasifikasi, fungsi-fungsi yang akan digunakan dan beberapa teori yang penting lainnya akan dibahas dalam bab II ini.

BAB III - METODOLOGI

Pada Bab III akan menjelaskan mengenai metodologi dan perancangan untuk mengklasifikasi objek makanan dengan menggunakan metode *Convolutional Neural Network* (CNN) dengan model Inception V3, Resnet 50 dan AlexNet. Pada bab ini akan dijelaskan secara rinci dengan menggunakan visual berupa gambar serta penjelasan rincian dari gambar-gambar tersebut.

BAB IV - HASIL DAN PEMBAHASAN

Pada Bab IV akan menjelaskan hasil dan pembahasan mengenai pengklasifikasian gambar makanan yang telah dibuat dengan menggunakan metode *deep learning*, *Convolutional Neural Network* (CNN).

BAB V - KESIMPULAN DAN SARAN

Pada Bab V berisi kesimpulan dari hasil penelitian yang telah dilaksanakan dan kemudian dituangkan ke dalam bab ini serta dijabarkan dengan singkat mengenai penelitian yang telah dilakukan.

DAFTAR PUSTAKA

- [1] C.Spence, K. Okajima, A.D. Cheok, O. Petit dan C. Michel, "Eating with our eyes: From visual hunger to digital satiation," *Brain and Cognition*, vol. 110, pp. 53-63, 2016.
- [2] G. Pradhan, S.L. Samson dan Y. Sun., "Ghrelin: much more than a hunger hormone," *Curr Opin Clin Nutr Metab Care*, vol. 16, no.6, pp. 619-624, 2013.
- [3] S. McGuire, " 88.2% Of People Travel The World To Get Their Hands On This," *Venngage*, diakses melalui <https://venngage.com/blog/88-2-of-people-travel-the-world-to-get-their-hands-on-this-infographic/>, 2015.
- [4] G. G. Lee, C. Huang, J. Chen, S. Chen dan H. Chen, " AIFood: A Large Scale Food Images Dataset for Ingredient Recognition," *TENCON 2019 - 2019 IEEE Region 10 Conference (TENCON)*, pp. 802-805, 2019.
- [5] M. Bolaños, A. Ferrà. dan P. Radeva, "Food Ingredients Recognition Through Multi-label Learning," *International Conference on Image Analysis and Processing*, pp. 394-402, 2017.
- [6] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein, A. C. Berg dan L. Fei-Fei, "ImageNet Large Scale Visual Recognition Challenge," *International Journal of Computer Vision*, vol. 115, no. 3, pp. 211–252, 2015.
- [7] A. Krizhevsky, "Learning Multiple Layers of Features from Tiny Images," *Science Department, University of Toronto*, pp. 1–60, 2009.
- [8] M. Chen, K. Dhingra, W. Wu, L. Yang, R. Sukthankar, dan J. Yang, "PDIF: Pittsburgh Fast-Food Image Dataset," pp. 289-292, 2009.
- [9] Y. Kawano dan K. Yanai, "Automatic expansion of a food image dataset leveraging existing categories with domain adaptation," *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, no. 8927, pp. 3–17, 2015.
- [10] Y. Matsuda, H. Hoashi dan K. Yanai, "Recognition of multiple-food images by detecting candidate regions," *Proceedings - IEEE International*

- Conference on Multimedia and Expo*, pp. 25–30, 2012.
- [11] Y. Matsuda, H. Hoashi, dan K. Yanai, " Recognition of Multiple- Food Images By Detecting Candidate Regions," pp. 1-10, 2012.
 - [12] L. Bossard, M. Guillaumin dan L. Van Gool, "Food-101 – Mining Discriminative Components with Random Forests," *Computer Vision - ECCV*, pp. 446–461, 2014.
 - [13] D. Kumar, N. Thome, M. Cord dan F. Precioso, "Recipe recognition with large multimodal food dataset," *2015 IEEE International Conference on Multimedia & Expo Workshops (ICMEW)*, no. 1, pp. 1–6, 2015.
 - [14] R. Batuwita and V. Palade, "Class Imbalance Learning Methods for Support Vector," *Imbalanced Learning: Foundations, Algorithms, Applications*, pp. 83–100, 2013.
 - [15] O. Beijbom, N. Joshi, D. Morris, S. Saponas dan S. Khullar, "Menu-Match: Restaurant-Specific Food Logging from Images," *2015 IEEE Winter Conference on Applications of Computer Vision*, pp. 844–851, 2015.
 - [16] M. Chen, Y. Yang, C. Ho dan S. Wang, "Automatic chinese food identification and quantity estimation," *SIGGRAPH Asia*, 2012.
 - [17] N.J. Nilsson, "The Quest For Artificial Intelligence : A History of Ideas and Achievements," *Standford University*, 2010.
 - [18] A. Oppermann, Artificial Intelligence vs. Machine Learning vs. Deep Learning, diakses melalui <https://www.deeplearning-academy.com/p/ai-wiki-machine-learning-vs-deep-learning>, 2019.
 - [19] L. Arnold, S. Rebecchi, S. Chevallier, dan H.P. Moisy, "An Introduction to Deep Learning," pp. 477-488, 2011.
 - [20] Y. LeCun, L. Bottou, Y. Bengio dan P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no.11, pp. 2278–2323, 1998.
 - [21] S. Christodoulidis and M. Anthimopoulos. "Food Recognition for Dietary Assessment Using Deep Convolutional Neural Networks." In: *New Trends in Image Analysis and Processing – ICIAP 2015 Workshops*. Vol. 9281, pp. 458–465, 2015.
 - [22] M.S. Islan, F.A. Foysal, N. Neehal, E. Karim, dan S.A. Hossain, "InceptB :

- A CNN Based Classification Approach for Recognizing Traditional Bengali Games," vol. 143, pp. 295-602, 2018.
- [23] A. Krizhevsky, I. Sutskever dan G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, pp. 1097–1105, 2012.
 - [24] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke dan A. Rabinovich. "Going Deeper with Convolutions," pp. 1–12, 2014.
 - [25] J. Patterson, dan A. Gibson, Deep Learning : A Practitioner's Approach, Amerika Serikat : O'Reilly Media, Inc., 2017.
 - [26] C. Maklin. Dropout Neural Network Layer In Keras Explained, diakses melalui <https://towardsdatascience.com/machine-learning-part-20-dropout-keras-layers-explained-8c9f6dc4c9ab>, 2019.
 - [27] H. Kaiming *et al.* "Identitiy Mappings in Deep Residual Networks," pp. 260-280, 2016.
 - [28] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, dan A. Rabinovich, "Going Deeper with Convolutions," pp. 113-280, 2015.
 - [29] R. Yamashita, M. Nishio, R.K.G. Do, dan K. Togashi, "Convolutional Neural Networks : An Overview and Application in Radiology." ,vol. 9, pp. 661-629, 2018.
 - [30] H. Kaiming *et al.*, "Deep Residual Learning for Image Recognition," pp.113-279, 2015.
 - [31] H. Kaiming *et al.* "Identitiy Mappings in Deep Residual Networks," pp. 260-280, 2016.
 - [32] B. Zhao, J. Feng, X. Wu, dan S. Yan, "A Survey on Deep Learning Based Fine Grained Object Classification and Semantic Segmentation", vol. 2, pp. 119-135, 2017.
 - [33] D.P Kingma dan J.L Ba, "Adam: A Method For Stochastic Optimization," *3rd International Conference on Learning Representations*, 2015.
 - [34] L. Torrey, dan J. Shavlik, "Transfer Learning,"pp. 1-22, 2009.
 - [35] A. Dosovitskiy, J. T. Springenberg, dan T. Brox, "Unsupervised feature

- learning by augmenting single images," p. 7, 2013.
- [36] S. Easwaran, "Simplified Teaching And Understanding Of Histogram Equalization In Digital Image Processing," *American Society for Engineering Education*, 2009.
- [37] S.H. Tsang, Review : Inception-V3-1st Runner Up (Image Classification) in ILSVRC 2015, diakses melalui <https://medium.com/@sh.tsang/review-inception-v3-1st-runner-up-image-classification-in-ilsvrc-2015-17915421f77c>, 2018.
- [38] M. Sokolova dan G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Information Processing and Management: an International Journal. Manage*, vol. 45, no. 4, pp. 427–437, 2009.
- [39] P. Joshi, V. Godoy dan D.M Escriva, "OpenCV By Example," *PACKT Publishing*, 2016.
- [40] P. Pandey, A. Deepthi, B. Mandal dan N. B. Puhan, "FoodNet: Recognizing Foods Using Ensemble of Deep Networks," *IEEE Signal Processing Letters*, vol. 24, no. 12, pp. 1758-1762, 2017.
- [41] Q. Yu, "Deep Learning Based Food Recognition," *Stanford University*, 2016.
- [42] H. Hassannejad, G. Matrella, P. Ciampolini, I. Munari, M. Mordonini dan S. Cagnoni, "Food Image Recognition Using Very Deep Convolutional Networks," *Proceedings of the 2nd International Workshop on Multimedia Assisted Dietary Management*, pp. 41-49, 2016.
- [43] C. Liu, Y.Cao, Y.Luo, G.Chen, V.Vokkarane dan Y.Ma, " DeepFood: Deep Learning-Based Food Image Recognition for Computer-Aided Dietary Assessment," *ICOST 2016: Inclusive Smart Cities and Digital Health*, pp.37-48, 2016.
- [44] C.Kiourt, G.Pavlidis dan S.Markantonatou, " Deep Learning Approaches in Food Recognition," *Machine Learning Paradigms. Learning and Analytics in Intelligent Systems*, vol. 18, pp. 83-108, 2020.
- [45] J. Qiu J., F.P.W. Lo, Y. Sun, S. Wang dan B. Lo, " Mining Discriminative Food Regions for Accurate Food Recognition," *British Machine Vision*

- Conference*, pp. 1-11, 2019.
- [46] E. Aguilar, M.Bolaños dan P.Radeva, " Food Recognition Using Fusion of Classifiers Based on CNNs," *International Conference on Image Analysis and Processing*, pp. 213-224, 2017.
 - [47] M. Jiang, " Food Image Classification with Convolutional Neural Networks," *Standford University*, 2019.
 - [48] N. Martinel, G.L. Foresti dan C. Micheloni, "Wide-Slice Residual Networks for Food Recognition," *IEEE Winter Conference on Applications of Computer Vision (WACV)*, pp. 567-576, 2018.