

***HYPERPARAMETER MODEL ARSITEKTUR RESNET50
DALAM MENGLASIFIKASI LARVA ZOPHOBAS MARIO
DAN TENEBRIO MOLITOR***

SKRIPSI

OLEH:

RUJITO

17.816.0039



PROGRAM STUDI TEKNIK INFORMATIKA

FAKULTAS TEKNIK

UNIVERSITAS MEDAN AREA

MEDAN

2023

UNIVERSITAS MEDAN AREA

© Hak Cipta Di Lindungi Undang-Undang

1. Dilarang Mengutip sebagian atau seluruh dokumen ini tanpa mencantumkan sumber
2. Pengutipan hanya untuk keperluan pendidikan, penelitian dan penulisan karya ilmiah
3. Dilarang memperbanyak sebagian atau seluruh karya ini dalam bentuk apapun tanpa izin Universitas Medan Area

Document Accepted 17/1/24

Access From (repository.uma.ac.id)17/1/24

**HYPERPARAMETER MODEL ARSITEKTUR RESNET50
DALAM MENGLASIFIKASI LARVA ZOPHOBAS MARIO
DAN TENEBRIO MOLITOR**

SKRIPSI

**Diajukan Sebagai Salah Satu Syarat Untuk Memperoleh Gelar
Sarjana di Fakultas Teknik Universitas Medan Area**



**OLEH:
RUJITO
17.816.0039**

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS TEKNIK
UNIVERSITAS MEDAN AREA
2023**

UNIVERSITAS MEDAN AREA

© Hak Cipta Di Lindungi Undang-Undang


1. Dilarang Mengutip sebagian atau seluruh dokumen ini tanpa mencantumkan sumber
2. Pengutipan hanya untuk keperluan pendidikan, penelitian dan penulisan karya ilmiah
3. Dilarang memperbanyak sebagian atau seluruh karya ini dalam bentuk apapun tanpa izin Universitas Medan Area


Document Accepted 17/1/24

Access From (repository.uma.ac.id)17/1/24

Judul Skripsi : *Hyperparameter Model Arsitektur ResNet50 dalam Mengklasifikasi Larva Zophobas Mario dan Tenebrio Molitor*
Nama : Rujito
NPM : 178160039
Fakultas : Teknik
Prodi : Teknik Informatika

Disetujui Oleh
Komisi Pembimbing


Muhallir, ST, M.Kom
Pembimbing I


Nurul Khairina, S.Kom, M.Kom
Pembimbing II

Mengetahui

Dekan Fakultas Teknik

Ka. Prodi


Dr. An Supriano, ST, MT
NIDN : 0102027402


Rizki Mulyanto, S.Kom, M.Kom
NIDN : 0109038902

Tanggal Lulus : 29 September 2023

HALAMAN PERNYATAAN

Saya menyatakan bahwa skripsi yang saya susun, sebagai syarat memperoleh gelar sarjana merupakan hasil karya tulis saya sendiri. Adapun bagian-bagian tertentu dalam penulisan skripsi ini yang saya kutip dari hasil karya orang lain telah dituliskan sumbernya secara jelas sesuai dengan norma, kaidah, dan etika penulisan ilmiah.

Saya bersedia menerima sanksi pencabutan gelar akademik yang saya peroleh dan sanksi-sanksi lainnya dengan peraturan yang berlaku, apabila di kemudian hari ditemukan adanya plagiat dalam skripsi ini.

Medan, 8 Desember 2023


METERAI TEMPEL
12AKX704190173
Rujito
178160039

HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI SKRIPSI UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademik Universitas Medan Area, saya yang bertanda tangan di bawah ini:

Nama : Rujito
NPM : 178160039
Program Studi : Teknik Informatika
Jenis Karya : Skripsi

demikian mengembangkan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Medan Area **Hak Bebas Royalti Noneksklusif (Non-exclusive Royalty-Free Right)** atas karya ilmiah saya yang berjudul : *Hyperparameter Model Arsitektur ResNet50 dalam Mengklasifikasi Larva Zophobas Mario dan Tenebrio Molitor*. Dengan Hak Bebas Royalti Noneksklusif ini Universitas Medan Area berhak menyimpan, mengalihmedia/format-kan, mengelola dalam bentuk pangkalan data (*database*), merawat, dan memublikasikan skripsi saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Demikian pernyataan ini saya buat dengan sebenarnya.

Dibuat di : Medan
Pada tanggal : 8 Desember 2023
Yang menyatakan


(Rujito)

ABSTRAK

Zophobas Morio dan *Tenebrio Molitor* merupakan larva yang populer sebagai bahan pakan yang banyak digunakan oleh pecinta hewan untuk pakan reptil, burung, dan unggas lainnya. Namun, kedua larva ini memiliki penampilan yang mirip tetapi kandungan nutrisinya jauh berbeda. *Zophobas Morio* lebih bergizi dan memiliki nilai ekonomi yang lebih tinggi dibandingkan dengan *Tenebrio Molitor*. Karena keterbatasan pengetahuan, banyak pecinta hewan yang kesulitan membedakan keduanya. Penelitian ini bertujuan untuk membangun konfigurasi model *hyperparameter* arsitektur ResNet50 terbaik yang mampu membedakan keduanya. Model dilatih menggunakan gambar yang diambil dari ponsel. Pelatihan dilakukan dengan menggunakan parameter *Epoch*, *Batch Size* dan *Optimizer*. Hasil percobaan pada dataset menunjukkan bahwa tingkat akurasi model *hyperparameter* arsitektur ResNet50 yang paling baik adalah pada Epoch 25, dengan Batch Size 32 dan Optimizer Adam dengan akurasi yang didapatkan sebesar 97% dimana waktu komputasi membutuhkan total waktu 66 menit. Konfigurasi *hyperparameter* Epoch 25, Batch Size 32 dan Optimizer Adam adalah *hyperparameter* yang paling optimal dalam klasifikasi larva *Zophobas Morio* dan *Tenebrio Molitor*.

Kata kunci: *Hyperparameter*, ResNet50, Klasifikasi, *Zophobas Morio*, *Tenebrio Molitor*

ABSTRACT

Zophobas Morio and Tenebrio Molitor are popular larvae as feed ingredients which are widely used by animal lovers to feed reptiles, birds and other poultry. However, these two larvae have a similar appearance but much different nutritional content. Zophobas Morio is more nutritious and has a higher economic value compared to Tenebrio Molitor. Due to limited knowledge, many animal lovers have difficulty distinguishing between the two. This study aims to build the best configuration of the ResNet50 architecture hyperparameter model that is able to distinguish between the two. The model is trained using images taken from mobile phones. Training is carried out using the Epoch, Batch Size and Optimizer parameters. The experimental results on the dataset show that the best level of accuracy for the ResNet50 architectural hyperparameter model is at Epoch 25, with Batch Size 32 and Optimizer Adam with an accuracy of 97% where the computing time requires a total of 66 minutes. Epoch 25, Batch Size 32 and Optimizer Adam hyperparameter configurations are the most optimal hyperparameters in the classification of Zophobas Morio and Tenebrio Molitor larvae.

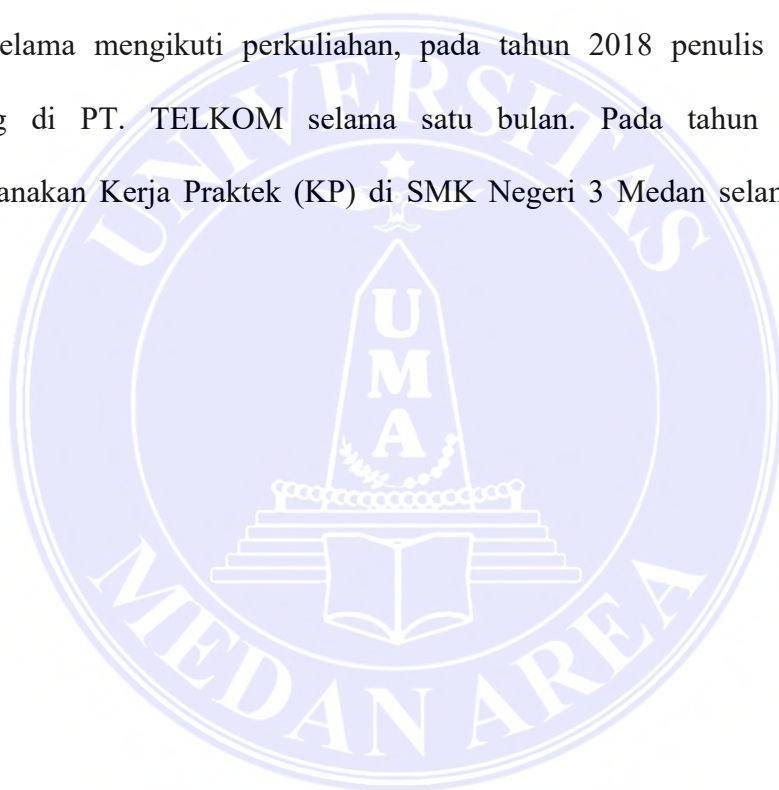
Keywords: Hyperparameter, ResNet50, Classification, Zophobas Morio, Tenebrio Molitor

RIWAYAT HIDUP

Penulis dilahirkan di Desa Selamat pada tanggal 1 Nopember 1999 dari ayah Irawan dan ibu Mariati. Penulis merupakan putra pertama dari dua bersaudara.

Tahun 2017, penulis lulus dari SMA Negeri 1 Delitua dan pada tahun 2017 terdaftar sebagai mahasiswa Fakultas Teknik Universitas Medan Area.

Selama mengikuti perkuliahan, pada tahun 2018 penulis melaksanakan magang di PT. TELKOM selama satu bulan. Pada tahun 2020 penulis melaksanakan Kerja Praktek (KP) di SMK Negeri 3 Medan selama satu bulan.



KATA PENGANTAR

Dengan mengucapkan puja dan puji syukur kehadirat Allah SWT yang telah menganugerahkan segala rahmat, nikmat dan karunianya sehingga penulis dapat menyelesaikan penyusunan skripsi ini, adapun judul dari penelitian ini yaitu **“Hyperparameter Model Arsitektur ResNet50 dalam Mengklasifikasi Larva Zophobas Morio dan Tenebrio Molitor”**. Adapun maksud dan tujuan penyusunan skripsi ini untuk memenuhi tugas akhir dan melengkapi salah satu syarat kelulusan pada Program Studi Teknik Informatika Fakultas Teknik Universitas Medan Area. Dalam usaha menyelesaikan skripsi ini, penulis menyadari bahwa tulisan ini masih jauh dari kata sempurna dan juga terdapat kekurangan, baik dari segi bahasa, isi, dan tulisan. Penulis juga mengharapkan kritik dan saran yang sifatnya membangun dari pembaca. Kemudian penulis ingin mengucapkan terima kasih banyak kepada:

1. Bapak Prof. Dr. Dadan Ramdan, M.Eng., M.Sc., selaku Rektor Universitas Medan Area.
2. Bapak Dr. Eng. Supriatno, ST, MT., selaku Dekan Fakultas Teknik Universitas Medan Area.
3. Bapak Rizki Muliono, S.Kom., M.Kom., selaku Ketua Program Studi Teknik Informatika yang juga selaku sekretaris yang telah memberikan ilmu yang bermanfaat.
4. Bapak Muhathir, ST., M.Kom., selaku pembimbing I yang telah meluangkan waktunya dan memberikan ilmu yang bermanfaat guna membimbing penulis sehingga skripsi ini bisa diselesaikan.

5. Ibu Nurul Khairina, S.Kom., M.Kom., selaku pembimbing II yang telah memberikan ilmu yang bermanfaat serta masukan dalam menyelesaikan skripsi ini.
6. Seluruh dosen Program Studi Teknik informatika yang selama ini telah membekali penulis dengan ilmu-ilmu yang semoga di suatu saat nanti dapat diterapkan dengan baik.
7. Seluruh pegawai Universitas Medan Area yang telah membantu dalam proses administrasi.
8. Terkhusus kepada orang tua penulis Bapak Irawan dan Ibu Mariati yang dengan penuh kasih sayangnya telah mendidik serta dengan doa restunya pada penulis bisa menyelesaikan pendidikan hingga ke perguruan tinggi.
9. M. Farhan Ryandra dan Amri Tumanggor yang telah memberikan semangat dan dukungan kepada penulis.
10. Semua teman stambuk 2017 Program Studi Teknik Informatika.

Mengingat keterbatasan kemampuan yang penulis miliki, maka penulis menyadari bahwa penyusunan skripsi ini masih jauh dari kata sempurna, walaupun demikian penulis berharap semoga skripsi ini dapat memberikan manfaat bagi pihak-pihak yang membutuhkannya.

Medan, 8 Desember 2023

Rujito

178160039

DAFTAR ISI

	Halaman
ABSTRAK	vi
ABSTRACT	vii
RIWAYAT HIDUP	viii
KATA PENGANTAR	ix
DAFTAR ISI	xi
DAFTAR TABEL	xiii
DAFTAR GAMBAR	xiv
DAFTAR PERSAMAAN	xv
BAB I	1
PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan masalah	6
1.3 Tujuan Penelitian	6
1.4 Batasan Masalah	7
1.5 Manfaat Penelitian	7
1.6 Sistematika Penulisan	8
BAB II	9
LANDASAN TEORI	9
2.1 Larva	9
2.1.1 <i>Zophobas Morio</i>	10
2.1.2 <i>Tenebrio Molitor</i>	11
2.2 <i>Deep Learning</i>	12
2.3 <i>Convolutional Neural Network (CNN)</i>	13
2.4 <i>ResNet50</i>	14
2.5 Penelitian-penelitian Terdahulu	17

BAB III	19
METODOLOGI PENELITIAN	19
3.1 Spesifikasi Perangkat	19
3.1.1 Perangkat Keras (<i>Hardware</i>)	19
3.1.2 Perangkat Lunak (<i>Software</i>)	19
3.2 Alur Metodologi Penelitian	19
3.3 Parameter <i>Deep Learning</i>	21
3.4 <i>Dataset</i>	21
3.5 Metode Evaluasi	22
 BAB IV	 24
HASIL DAN PEMBAHASAN	24
4.1 Hasil	24
4.1.1 <i>Training ResNet50</i> Model dengan <i>Epoch 5</i>	24
4.1.2 <i>Training ResNet50</i> Model dengan <i>Epoch 15</i>	27
4.1.3 <i>Training ResNet50</i> Model dengan <i>Epoch 25</i>	30
4.1.4 Performa Kinerja ResNet50	33
4.2 Pembahasan	42
 BAB V	 45
KESIMPULAN DAN SARAN	45
5.1 Kesimpulan	45
5.2 Saran	45
 DAFTAR PUSTAKA	 47
LAMPIRAN-LAMPIRAN	50

DAFTAR TABEL


	Halaman
Tabel 3.1 Perangkat Keras (<i>Hardware</i>)	19
Tabel 3.2 Perangkat Lunak (<i>Software</i>)	19
Tabel 3.3 <i>Hyperparameter</i>	21
Tabel 3.4 <i>Confusion Matrix</i>	22
Tabel 4.1 Skenario <i>Epoch 5, Batch 8, dan Optimizer Adam</i>	33
Tabel 4.2 Skenario <i>Epoch 5, Batch 8, dan Optimizer RMSProp</i>	34
Tabel 4.3 Skenario <i>Epoch 5, Batch 16, dan Optimizer Adam</i>	34
Tabel 4.4 Skenario <i>Epoch 5, Batch 16, dan Optimizer RMSProp</i>	35
Tabel 4.5 Skenario <i>Epoch 5, Batch 32, dan Optimizer Adam</i>	35
Tabel 4.6 Skenario <i>Epoch 5, Batch 32, dan Optimizer RMSProp</i>	36
Tabel 4.7 Skenario <i>Epoch 15, Batch 8, dan Optimizer Adam</i>	36
Tabel 4.8 Skenario <i>Epoch 15, Batch 8, dan Optimizer RMSProp</i>	37
Tabel 4.9 Skenario <i>Epoch 15, Batch 16, dan Optimizer Adam</i>	37
Tabel 4.10 Skenario <i>Epoch 15, Batch 16, dan Optimizer RMSProp</i>	38
Tabel 4.11 Skenario <i>Epoch 15, Batch 32, dan Optimizer Adam</i>	38
Tabel 4.12 Skenario <i>Epoch 15, Batch 32, dan Optimizer RMSProp</i>	39
Tabel 4.13 Skenario <i>Epoch 25, Batch 8, dan Optimizer Adam</i>	39
Tabel 4.14 Skenario <i>Epoch 25, Batch 8, dan Optimizer RMSProp</i>	40
Tabel 4.15 Skenario <i>Epoch 25, Batch 16, dan Optimizer Adam</i>	40
Tabel 4.16 Skenario <i>Epoch 25, Batch 16, dan Optimizer RMSProp</i>	41
Tabel 4.17 Skenario <i>Epoch 25, Batch 32, dan Optimizer Adam</i>	41
Tabel 4.18 Skenario <i>Epoch 25, Batch 32, dan Optimizer RMSProp</i>	42
Tabel 4.19 Hasil <i>Training dan Validation</i>	42

DAFTAR GAMBAR

	Halaman
Gambar 2.1 Arsitektur <i>ResNet50</i>	15
Gambar 3.1 Alur Metodologi Penelitian	20
Gambar 3.2 Contoh Dataset	22
Gambar 4.1 <i>Training Accuracy ResNet50 Epoch 5</i>	24
Gambar 4.2 <i>Validation Accuracy ResNet50 Epoch 5</i>	25
Gambar 4.3 <i>Training Loss ResNet50 Epoch 5</i>	26
Gambar 4.4 <i>Validation Loss ResNet50 Epoch 5</i>	26
Gambar 4.5 <i>Training Accuracy ResNet50 Epoch 15</i>	27
Gambar 4.6 <i>Validation Accuracy ResNet50 Epoch 15</i>	28
Gambar 4.7 <i>Training Loss ResNet50 Epoch 15</i>	29
Gambar 4.8 <i>Validation Loss ResNet50 Epoch 15</i>	29
Gambar 4.9 <i>Training Accuracy ResNet50 Epoch 25</i>	30
Gambar 4.10 <i>Validation Accuracy ResNet50 Epoch 25</i>	31
Gambar 4.11 <i>Training Loss ResNet50 Epoch 25</i>	32
Gambar 4.12 <i>Validation Loss ResNet50 Epoch 25</i>	32

DAFTAR PERSAMAAN

	Halaman
Persamaan 2.1 Persamaan <i>Softmax</i>	16
Persamaan 2.2 Persamaan <i>Sigmoid</i>	17
Persamaan 2.3 Persamaan <i>Cross Entropy Loss</i>	17
Persamaan 3.1 Persamaan <i>Accuracy</i>	23
Persamaan 3.2 Persamaan <i>Precision</i>	23
Persamaan 3.3 Persamaan <i>Recall</i>	23
Persamaan 3.4 Persamaan <i>F-1 Score</i>	23



BAB I

PENDAHULUAN

1.1 Latar Belakang

Deep learning adalah konsep *machine learning* yang didasarkan pada jaringan saraf tiruan. Pada beberapa metode, model *deep learning* mengungguli model *machine learning* dangkal dan pendekatan analisis data tradisional (Janiesch, Zschech, & Heinrich, 2021). *Machine learning* memungkinkan komputer untuk mengatasi masalah dengan belajar dari data. *Deep learning* adalah jenis *machine learning* yang menggunakan rekombinasi fitur hierarkis untuk mengekstrak informasi yang bersangkutan, dan kemudian mempelajari pola yang direpresentasikan dalam data (Mater & Coote, 2019). *Deep learning* telah terbukti menjadi teknologi canggih untuk analisis data besar dengan sejumlah besar kasus yang berhasil dalam pemrosesan gambar, pengenalan ucapan, deteksi objek, dan sebagainya. Baru-baru ini, itu juga telah diperkenalkan dalam ilmu dan teknik pangan (Zhou, Zhang, Liu, Qiu, & He, 2019).

Model *deep learning* yang biasa digunakan untuk menganalisis data berupa teks yaitu CNN, RNN, LSTM, dan GRU. Sebagian besar penelitian saat ini banyak yang menggunakan *deep learning*, khususnya metode CNN. Hal inilah yang membuat perkembangan *deep learning* berkembang dengan pesat (Naquitasia, Fudholi, & Iswari, 2022). CNN diklaim merupakan metode terbaik dalam permasalahan deteksi dan pengenalan objek. Dengan menggunakan citra sebagai inputannya, CNN dapat melakukan pembelajaran citra sehingga dapat

menghasilkan sebuah model yang mampu mengklasifikasikan objek citra (Nadira, 2019).

ResNet50 sering digunakan untuk mengatasi kesalahan generalisasi, *overfitting*, *underfitting* dan *vanishing*. ResNet50 dapat memformulasi ulang lapisan jaringan dalam hal fungsi pembelajaran sisa dengan referensi pemetaan ke lapisan input dengan menyesuaikan lapisan yang ditumpuk ke pemetaan sisa. ResNet50 menggunakan pemetaan identitas untuk memprediksi yang diperlukan untuk mencapai prediksi akhir dari keluaran lapisan sebelumnya, yang mengurangi efek gradien hilang menggunakan jalur pintasan alternatif untuk dilewati. Pemetaan identitas memungkinkan model mengalir melalui lapisan yang tidak perlu. Ini membantu model untuk mengatasi masalah *overfitting* set pelatihan. Pendekatan ini memperluas pekerjaan sebelumnya dengan menggunakan teknik ekstraksi fitur multi-level untuk meningkatkan hasil klasifikasi (ElGhany, Ibraheem, Alruwaili, & Elmogy, 2021).

Pada penelitian penelitian sebelumnya tentang *deep learning* yaitu *Applications for Deep Learning in Ecology* (Christin, Hervet, & Lecomte, 2019) didapati bahwa *deep learning*, seperti algoritma *machine learning* lainnya, menyediakan metode yang berguna untuk menganalisis data non linier dengan interaksi yang kompleks dan karenanya dapat berguna untuk studi ekologi. Algoritma *deep learning* secara otomatis mendeteksi objek yang menarik dalam data, seperti mengidentifikasi hewan dalam foto, hanya dengan menginstruksikan contoh apa yang harus dicari.

Pada penelitian sebelumnya tentang *ResNet50* yaitu *Detection of COVID-19 from CT Images Using ResNet50* (Walvekar & Shinde, 2020) didapati bahwa arsitektur *ResNet50* memiliki tingkat akurasi mencapai 96% dalam mendeteksi penyakit covid melalui citra gambar CT. Pada penelitian sebelumnya tentang *ResNet50* yaitu *Classification of Encrypted Images Using Deep Learning ResNet50* (Alzamily, Ariffin, & Naser, 2022) didapati bahwa arsitektur *ResNet50* memiliki tingkat akurasi mencapai 99% dalam mengklasifikasikan citra gambar terenkripsi. Dan pada penelitian sebelumnya tentang *ResNet50* yaitu *Research on the Practical Classification and Privacy Protection of CT Images of Parotid Tumors based on ResNet50 Model* (Yuan, et al., 2020) didapati bahwa arsitektur *ResNet50* memiliki tingkat akurasi mencapai 90% dalam mengklasifikasikan citra gambar CT penyakit tumor parotis.

Dalam *machine learning*, *hyperparameter* adalah parameter yang nilainya mengontrol proses pembelajaran. Sebaliknya, nilai parameter lainnya diperoleh melalui pelatihan. *Hyperparameter* dapat diklasifikasikan sebagai *hyperparameter* model, yang tidak dapat ditentukan saat mesin diterapkan ke set pelatihan, karena mengacu pada fungsi pemilihan model, atau algoritma *hyperparameter*, yang nilainya juga tidak berpengaruh pada kinerja model namun mempengaruhi kecepatan dan kualitas proses pembelajaran. Contoh *hyperparameter* model tersebut adalah topologi dan ukuran jaringan saraf. Contoh algoritma *hyperparameter* adalah *learning rate*, *batch size*, dan *mini-batch size*. *Batch Size* dapat mengacu pada sampel data yang lengkap, sedangkan *mini-batch size* adalah kumpulan sampel data kecil (Yang & Shami, 2020).

Sebelum fase pelatihan, terlebih dahulu mencari satu set nilai *hyperparameter* yang mengarsipkan kinerja terbaik data dalam waktu yang wajar. Proses ini disebut optimisasi atau penyesuaian *hyperparameter* (Wu, Chen, Zhang, Xiong, Lei, & Deng, 2019). Penyesuaian *hyperparameter* juga merupakan masalah yang sulit. Sementara dengan teknik *machine learning* yang lebih sederhana, seseorang dapat melakukan beberapa percobaan dan sudah mendapatkan intuisi yang baik tentang kinerja dan sensitivitas *hyperparameter*, untuk *deep learning*, prosesnya jauh lebih kompleks. Jaringan saraf seperti CNN memiliki banyak *hyperparameter*, dan menguji semua opsi secara mendalam tidak mungkin dilakukan. Teknik penyesuaian sederhana seperti pencarian acak dan pencarian *grid* dapat memberikan hasil yang baik tetapi bergantung pada keberuntungan dan pengalaman perancang *machine learning* (Rijsdijk, Wu, Perin, & Picek, 2021).

Zophobas morio merupakan salah satu jenis kumbang gelap yang larvanya disebut dengan nama umum *superworm* atau hanya disingkat *Zophobas*. *Zophobas morio* banyak ditemukan di industri reptil sebagai pakan. Larvanya tampak seperti ulat bambu besar, berukuran panjang sekitar 50 hingga 60 mm pada ukuran maksimal, tetapi tidak seperti ulat bambu, ujung tubuhnya berwarna gelap, hampir menyerupai warna hitam. Ketika larva mencapai ukuran dewasa, larva menjadi kepompong, dan tampak sebagai kumbang besar berwarna terang yang lama kelamaan berubah menjadi hitam. *Zophobas Morio* umumnya diberikan untuk pakan hewan seperti kadal, kura-kura, katak, salamander, burung, ikan koi, dan hewan pemakan serangga lainnya. Nilai gizinya mirip dengan ulat bambu.. Dalam beberapa kasus, zophobas morio lebih disukai daripada ulat

bambu karena tubuh bagian luarnya yang lebih lembut, sehingga lebih mudah dicerna oleh beberapa reptil (Rumbos, Karapanagiotidis, Mente, Psafakis, & Athanassiou, 2020).

Tenebrio Molitor adalah bentuk dari larva kumbang kuning, sejenis kumbang gelap. Seperti semua serangga holometabolik, mereka melalui empat tahap kehidupan: telur, larva, pupa, dan dewasa. Larva biasanya berukuran sekitar 2,5 cm atau lebih, sedangkan larva dewasa biasanya memiliki panjang 1,25 hingga 1,8 cm. Kumbang kuning berkembang biak dengan subur. Kumbang jantan menggunakan *aedeagus* nya untuk memasukkan paket sperma. Setelah beberapa hari, kumbang betina akan bersembunyi di tanah yang empuk dan bertelur. Setelah 4 sampai 19 hari telur akan menetas. Selama tahap larva, *tenebrio molitor* memakan tumbuhan dan serangga mati, dan berganti kulit di setiap tahap perkembangan. Setelah semua bulu mereka berguguran, mereka akan menjadi kepompong. Pupa baru berwarna putih dan berubah menjadi coklat seiring waktu. Setelah 3 hingga 30 hari, tergantung pada kondisi lingkungan seperti suhu, kumbang tersebut muncul sebagai kumbang dewasa. Sampai fase umur dewasa sekitar 6 sampai 12 bulan, seekor kumbang kuning betina mampu bertelur mencapai 500 butir (Rumbos, Karapanagiotidis, Mente, Psafakis, & Athanassiou, 2020).

Arsitektur *ResNet50* ini dipilih karena memiliki performa yang baik pada event ILSVRC (*ImageNet Large Scale Visual Recognition Challenge*) pada tahun 2015. ILSVRC merupakan suatu kompetisi tahunan yang melombakan klasifikasi citra gambar dengan berbagai macam arsitektur CNN. Berdasarkan keunikan dan

kelebihan dari performa arsitektur *ResNet50* ini, maka pada penelitian kali ini akan menggunakan model arsitektur *ResNet50*.

Penelitian kali ini akan mencoba untuk mengklasifikasikan dua jenis larva tersebut yang hampir memiliki kesamaan pada motif dan corak warna pada tubuh larva menggunakan *hyperparameter* arsitektur *ResNet50* untuk melihat nilai akurasi dan waktu eksekusi pada arsitektur tersebut. Pada penelitian *Classification of Zophobas Morio and Tenebrio Molitor Using Transfer Learning* (Pratondo & Bramantoro, 2022) menggunakan empat jenis model, dan didapati bahwa masing-masing model mendapatkan nilai akurasi yaitu KNN sebesar 83%, SVM sebesar 92%, VGG-19 sebesar 94%, dan *Inception v3* sebesar 96%. Maka dari itu penelitian ini diharapkan mampu menunjukkan hasil terbaik dalam mengklasifikasikan citra larva tersebut menggunakan arsitektur *ResNet50*.

1.2 Rumusan Masalah

Bagaimana klasifikasi larva *Zophobas Morio* dan *Tenebrio Molitor* menggunakan *Hyperparameter* Arsitektur *ResNet50*?

1.3 Tujuan Penelitian

Tujuan penelitian ini adalah di harapkan mampu menunjukkan hasil klasifikasi yang paling baik dengan menggunakan *hyperparameter* arsitektur *ResNet50*.

1.4 Batasan Masalah

Adapun yang menjadi batasan masalah pada penelitian ini yaitu sebagai berikut:

- a. Citra yang digunakan yaitu foto berformat jpg.
- b. Menggunakan *epoch* yang berjumlah 5, 15, dan 25.
- c. Menggunakan *batch size* 8, 16 dan 32.
- d. Menggunakan optimizer *Adam* dan *RMSprop*.
- e. Menggunakan dua jenis larva (*Zophobas Morio* dan *Tenebrio Molitor*).
- f. Bahasa pemrograman yang digunakan adalah *Python*.
- g. Data yang digunakan total berjumlah 2010 citra. Untuk *Zophobas Morio*, *data training* 829 dan *testing* 207. Untuk *Tenebrio Molitor*, *data training* 779 dan *testing* 195.
- h. Sumber data citra diambil dari situs *Kaggle.com*.

1.5 Manfaat Penelitian

Adapun manfaat pada penelitian ini yaitu sebagai berikut:

- a. Membantu klasifikasi *Zophobas Morio* dan *Tenebrio Molitor*
- b. Meningkatkan pengetahuan sebagai bahan pembelajaran dan referensi untuk penelitian-penelitian selanjutnya mengenai klasifikasi berbagai jenis objek citra, khususnya citra ulat.

1.6 Sistematika Penulisan

BAB I. Pendahuluan

Pada bab ini membahas tentang latar belakang, rumusan masalah, tujuan penelitian, batasan masalah, manfaat penelitian serta sistematika penulisan.

BAB II. Landasan Teori

Pada bab ini berisikan dasar-dasar teori yang digunakan untuk melanjutkan penelitian dalam mengklasifikasikan citra.

BAB III. Metodologi Penelitian

Pada bab ini akan dijelaskan implementasi *hyperparameter* arsitektur *ResNet50*.

BAB IV. Hasil dan Pembahasan

Pada bab ini akan membahas tentang langkah-langkah implementasi dan hasil program yang terdiri dari tampilan, alur program dan hasil dari implementasi arsitektur *ResNet50*.

BAB V. Kesimpulan dan Saran

Pada bab ini akan memaparkan tentang kesimpulan dari uji coba perangkat lunak dan saran untuk pengembangan, perbaikan serta penyempurnaan terhadap penelitian yang telah di buat.

BAB II

LANDASAN TEORI

2.1 Larva

Larva merupakan bentuk muda hewan yang perkembangannya melalui *metamorfosis*, seperti pada serangga dan *amfibia*. Bentuk larva bisa berbeda dengan bentuk saat dewasa, misalnya ulat dan kupu-kupu yang sangat berbeda bentuknya. Larva umumnya memiliki organ khusus yang tak terdapat pada bentuk dewasa dan juga tidak memiliki organ tertentu yang dimiliki pada bentuk dewasa. Suatu tahapan hidup disebut larva apabila dalam bentuk itu memiliki aktivitas yang tinggi (khususnya dalam bergerak dan mencari makanan). Kelompok hewan yang memiliki tahap larva cukup luas, mencakup serangga, berbagai *Porifera*, ubur-ubur dan kerabatnya (*Coelenterata*), berbagai *Crustacea*, *Echinodermata*, dan *amfibia*. Tidak semua serangga memiliki bentuk yang disebut larva, karena hanya mereka yang menempuh jalur *metamorfosis* penuh (*holometabola*) yang memiliki bentuk larva.

Larva serangga kelompok kupu-kupu dan kumbang dikenal luas sebagai ulat. Larva lalat dan beberapa kumbang dikenal sebagai bernga (berenga) atau belatung, namun larva lalat buah yang biasa ditemukan pada buah disebut sebagai "ulat" (buah) walaupun secara fisik lebih merupakan bernga (karena tidak berkaki). Larva nyamuk disebut jentik. Undur-undur lebih dikenal orang karena larvanya membangun struktur mirip corong terbalik di tanah pasir untuk menjebak mangsanya. Larva dari berbagai hewan memiliki nilai ekonomi, terutama digunakan sebagai bahan pakan untuk hewan peliharaan. Ulat jerman dan ulat

hongkong dijual sebagai pakan burung. Larva hewan air dijual sebagai pakan ikan akuarium. Larva dalam pertanian sering kali dianggap sesuatu yang merugikan secara ekonomi karena daya makan nya yang tinggi.

2.1.1 *Zophobas Morio*

Zophobas morio adalah kumbang gelap tropis yang banyak dimanfaatkan untuk pertumbuhan serangga komersial skala besar (Tokarev, Malysh, Volodartseva, Gerus, & Berezin, 2019). *Zophobas morio* adalah spesies yang ukuran tubuh, laju pertumbuhan, dan waktu perkembangannya dapat dimanipulasi dengan memvariasikan lingkungan sosial (keramaian). Adapun kondisi lainnya, respons hormonal kadang-kadang diamati sebagai respons terhadap kerumunan. Kerumunan yang ringan dapat meningkatkan umur yang panjang dan ukuran tubuh, sementara kerumunan yang parah dapat merusak laju pertumbuhan dan ukuran tubuh larva, mungkin karena pemberian makan secara bersama-sama atau stres ringan (VandenBrooks, Ford, & Harrison, 2020).

Zophobas morio merupakan sejenis serangga yang berkembang biak dengan cara bertelur dan aktif mencari makan pada malam hari. Oleh sebab itu sering disebut *dark beetle*. Makanan utama dari ulat ini yaitu buah-buahan. Di sebagian negara ulat ini dianggap hama perusak oleh para petani. Namun ternyata ulat ini memiliki kandungan nutrisi yang cukup baik untuk pakan hewan peliharaan seperti reptil, burung kicauan dan arwana, sehingga tidak menutup kemungkinan beberapa tahun yang akan datang *zophobas morio* bisa menjadi bahan pangan maupun campuran

bahan dasar kosmetik dan obat-obatan karena kandungannya yang kaya akan nutrisi (Rahman, Hamidi, & Kamelia, 2019).

2.1.2 *Tenebrio Molitor*

Tenebrio molitor adalah serangga *holometabola* yang dianggap menjadi hama berbahaya dari biji-bijian yang disimpan di Amerika Selatan. *Tenebrio molitor* merupakan hama utama pada gabah yang disimpan, meskipun larvanya berpotensi untuk digunakan sebagai makanan. Namun, sedikit yang diketahui tentang karakteristik instar larva individu spesies ini, dan jumlah instar masih diperdebatkan. Larva *Tenebrio molitor* juga dikenal sebagai *mealworm* dan *yellow mealworm*, dianggap sebagai sumber protein yang baik dengan nilai gizi, daya cerna, rasa, dan kemampuan fungsional. Selain itu, ulat ini mudah berkembang biak dan diberi makan karena memiliki kandungan protein yang stabil, terlepas dari makanan mereka. Oleh karena itu, larva *tenebrio molitor* telah diproduksi secara industri sebagai pakan hewan peliharaan, hewan kebun binatang, bahkan untuk hewan produksi (Hong, Han, & Kim, 2020).

Di antara spesies serangga yang paling menjanjikan untuk pemanfaatan industri dan produksi komersial skala besar adalah *yellow mealworm* atau larva *tenebrio molitor*. Spesies ini adalah salah satu kumbang terbesar (panjang tubuh dewasa antara 12 dan 20 mm) yang umumnya ditemukan menyerang produk pertanian yang disimpan. Ulat ini merupakan hama serangga yang ditemukan di berbagai jenis fasilitas dan komoditas, terutama biji-bijian dan komoditas amilase lainnya, seperti

tepung, dedak dan pasta. Namun demikian, pemanfaatannya sebagai sumber makanan bagi manusia dan hewan sangat diminati. Hal ini karena larva *tenebrio molitor* bergizi tinggi dengan kandungan protein yang tinggi (Rumbos, Karapanagiotidis, Mente, Psafakis, & Athanassiou, 2020).

2.2 Deep Learning

Deep Learning adalah bagian dari *machine learning* dan didasarkan pada algoritma yang di stimulasi oleh fungsi otak dan cara yang terstruktur. *Deep Learning* mendidik sistem komputer untuk menghasilkan hasil dengan melatih sistem pada contoh yang tersedia sebelumnya. Kemampuan *deep learning* telah memungkinkan untuk mencapai hasil yang tidak mungkin pada suatu waktu. Sisanya sebagai mekanisme penting di balik sebagian besar aplikasi yang ditemukan saat ini seperti kendaraan *self-driving*, kontrol suara dalam elektronik seperti telepon, televisi, mesin pintar dan lainnya (Bashar, 2019).

Deep Learning dengan jaringan saraf telah menjadi keberhasilan praktis yang signifikan di banyak bidang, termasuk visi komputer, *machine learning*, dan kecerdasan buatan. Seiring dengan keberhasilan praktisnya, *deep learning* telah secara teoritis dianalisis dan terbukti menarik dalam hal kekuatan ekspresifnya (Kawaguchi, Huang, & Kaelbling, 2019). *Deep learning* telah menunjukkan keunggulan kinerja dalam beberapa tugas seperti pengenalan gambar, bahasa alami pemrosesan, dan sintesis gambar (Suzuki & Nitanda, 2021).

Selama beberapa dekade terakhir, *machine learning* telah menghasilkan berbagai kemajuan luar biasa dalam algoritma pembelajaran yang canggih dan

teknik pra-pemrosesan yang efisien. Salah satu kemajuan ini adalah evolusi jaringan saraf tiruan (JST) menuju arsitektur jaringan saraf yang semakin dalam dengan peningkatan kemampuan pembelajaran yang diringkas sebagai *deep learning*. Untuk aplikasi tertentu, *deep learning* sudah menunjukkan kinerja sangat baik dengan mengungguli kemampuan manusia. Namun, manfaat tersebut juga ada harganya karena ada beberapa tantangan yang harus diatasi agar berhasil menerapkan model analitik (Janiesch, Zschech, & Heinrich, 2021).

2.3 Convolutional Neural Network (CNN)

Convolutional Neural Network telah mencapai sebuah keberhasilan yang signifikan dalam komunitas *computer vision*, seperti pengenalan objek, segmentasi semantik, deteksi objek dan analisis video. Karena penyimpanan dan komputasi yang membutuhkan biaya yang besar, model ini sulit diterapkan pada *platform* dengan sumber daya terbatas, seperti perangkat seluler (Zhao, Ni, Zhang, Zhao, Zhang, & Tian, 2019). *Convolutional* adalah operasi dasar dalam banyak pengolahan citra dan aplikasi *computer vision* dan blok bangunan utama arsitektur *Convolutional Neural Network* (CNN). Metode ini membentuk salah satu cara paling menonjol untuk menyebarkan dan mengintegrasikan fitur di seluruh piksel gambar karena kesederhanaannya dan pengimplementasian CPU/GPU yang sangat optimal (Su, Jampani, Sun, Gallo, Miller, & Kautz, 2019).

Performa superior CNN biasanya berasal dari arsitektur yang lebih dalam dan lebih luas, yang menyebabkan biaya komputasi yang sangat mahal. Bahkan jika kita menggunakan lebih banyak arsitektur yang efisien, seperti koneksi residual atau modul awal, masih sulit dalam menerapkan model CNN yang

canggih di perangkat seluler. Misalnya, *ResNet-152* memiliki 60,2 juta parameter dengan ruang penyimpanan 231MB, selain itu juga perlu lebih dari 380MB memori dan waktu enam detik untuk memproses satu gambar pada CPU. Penyimpanan, memori, dan komputasi model rumit ini secara signifikan melebihi batasan komputasi perangkat seluler saat ini. Oleh karena itu, penting untuk mempertahankan ukuran kecil dari model CNN yang memiliki biaya komputasi yang relatif rendah tetapi akurasi tinggi dalam aplikasi.

2.4 *ResNet50*

ResNet50 memiliki 50 lapisan dengan 25 juta parameter. Pada 2015, *ResNet50* adalah pemenang tantangan *ImageNet*. *ResNet50* menggunakan koneksi pintasan dan membuat blok sisa. Blok perantara residu mempelajari cara beradaptasi dengan input untuk fitur berkualitas tinggi. *ResNet50* memperkenalkan "koneksi pintasan identitas" yang melompati satu atau lebih lapisan (Nesa & Layek, 2021). *Resnet50* menggunakan lapisan konvolusi dan jaringan residual di depannya untuk mengekstrak fitur gambar (mirip dengan fitur hog, tetapi efeknya lebih baik daripada fitur hog), lalu menggunakan fungsi *cross entropy loss* untuk memperbarui parameter jaringan, sehingga jaringan *ResNet50* dapat memprediksi kategori gambar, yaitu memasukkan gambar berwarna 224 X 224 3 saluran, dan menampilkan kategori gambar (Li, 2020).

ResNet50 adalah anggota keluarga jaringan *deep neural* yang dikenal sebagai "*Residual Networks*". Jaringan ini memiliki koneksi khusus yang disebut "*residual connections*" yang mengizinkan jaringan melewati lapisan tertentu dan "*skip connections*" yang memungkinkan gradien mengalir lebih lancar melalui

Lapisan conv pertama terbuat dari ukuran kernel 7×7 dan 64 berbeda kernel dengan ukuran langkah ke 2. Kemudian 3×3 max pooling dengan langkah tersebut ukuran 2 diterapkan. Dalam konvolusi berikutnya, ada tiga lapisan konv (1×1 , 64 kernel), (3×3 , 64 kernel) dan (1×1 , 256 kernel) masing-masing dan ketiga lapisan ini diulang sebanyak 3 kali. Di dalam proses yang sama, tiga lapisan konv (1×1 , 128 kernel), (3×3 , 128 kernel) dan (1×1 , 512 kernel) masing-masing diulang empat kali, tiga lapisan konv (1×1 , 256 kernel), (3×3 , 256 kernel) dan (1×1 , 1024 kernel) masing-masing diulang enam kali dan tiga lainnya lapisan konv (1×1 , 512 kernel), (3×3 , 512 kernel) dan (1×1 , 2048 kernel) masing-masing diulang sebanyak 3 kali. Kemudian *average pooling* (*avg pool*) diterapkan. Sebagian besar *hidden layers* menggunakan *Batch Normalization*, dan ReLU diikuti oleh lapisan conv. Lapisan terakhir dari aslinya Model ResNet50 adalah lapisan *fully connected* (fc) dengan 1000 fitur luar (untuk kelas 1000).. Lapisan fc pertama memiliki 2048 fitur keluar, kemudian menerapkan *dropout* dengan probabilitas 0,5. Lapisan fc kedua sama dengan lapisan fc pertama. Setelah lapisan fc kedua, ReLU dan *dropout* dengan probabilitas 0,5 diterapkan. Lapisan fc terakhir terdiri dari 2048 *infeatures* dan hanya 2 *out-features* untuk klasifikasi dua kelas.

Hasil setiap filter akan melewati *average pooling* dan masuk ke jaringan *fully connected* dengan fungsi softmax untuk mengetahui hasil klasifikasi.

$$\text{softmax}(x)_i = \frac{\exp(x_i)}{\sum_{j=1}^n \exp(x_j)} \quad (1)$$

Softmax adalah fungsi yang menghitung probabilitas setiap kelas target terhadap semua kemungkinan kelas target dan membantu menentukan kelas dari

target masukan tertentu. Kelebihan *softmax* adalah rentang probabilitas keluaran dengan nilai dari 0 hingga 1 dan jumlah semua probabilitas akan sama dengan 1. Fungsi ini biasanya digunakan di akhir lapisan *fully connected* yang digunakan dalam CNN untuk menghasilkan nilai probabilitas suatu objek relatif terhadap lapisan yang ada. Rumus *softmax* dapat dilihat pada persamaan 1 dimana menghitung nilai eksponen xi relatif terhadap jumlah seluruh nilai eksponen yang ada.

$$\text{sigmoid}(x) = \left(\frac{1}{1 + \exp^{-x}} \right) \quad (2)$$

Sigmoid terkadang disebut fungsi logistik. Fungsi sigmoid digunakan untuk memprediksi probabilitas keluaran sebagai klasifikasi biner. Rumus sigmoid dapat dilihat pada persamaan 2. Jumlah probabilitas sigmoid tidak harus 1.

$$CE = - \sum t_i \log(S_i) \quad (3)$$

Untuk memperbaiki kesalahan selama pelatihan, model menggunakan fungsi cross entropy loss pada persamaan 3. Fungsi ini akan menghitung kelas actual t_i banding s_i yang akan menghitung jumlah log negatif dari hasil perkalian nilai prediksi dikalikan kelas aslinya, lalu dibagi dengan jumlah kelas.

2.5 Penelitian-Penelitian Terdahulu

No.	Penulis	Hasil
1.	- Agus Pratondo - Arif Bramantoro	Pada penelitian ini (2022) diusulkan beberapa model untuk mengklasifikasikan <i>zophobas morio</i> dan <i>tenebrio molitor</i> yaitu KNN, SVM, VGG-19, dan Inception V3. Dataset yang digunakan berjumlah 640 gambar, dengan masing-masing kelas 320 gambar. Data training berjumlah masing-masing 288 gambar dan data tes 32. Dan hasil akhir didapati bahwa akurasi dari 4 model diatas yaitu KNN sebesar 83%, SVM sebesar 92%,

		VGG-19 sebesar 94% dan Inception V3 sebesar 96%.
2.	-Faiz Nashrullah -Suryo Adhi Wibowo -Gelar Budiman	Pada penelitian ini (2020) dikembangkan sistem pendeteksi konten pornografi menggunakan metode CNN arsitektur ResNet50 dengan menerapkan berbagai konfigurasi <i>epoch</i> untuk mendapatkan hasil terbaik. Dan didapati bahwa dalam proses perancangan sistem, hasil cenderung meningkat seiring dengan penambahan <i>epoch</i> , dengan performa terbaik didapat pada konfigurasi <i>epoch</i> 60 dengan akurasi 91%.
3.	-Arif Bastanta Sinuhaji -Aji Gautama Putrada -Hilal Hudan Nuha	Pada penelitian ini (2021) dilakukan pengklasifikasian gambar satwa yang diindungi yang diambil dari sebuah prototype kamera trap menggunakan CNN dengan model arsitektur <i>ResNet50</i> . Didapati bahwa model ini menghasilkan nilai akurasi sebesar 99%.
4.	- Ivan Pratama Putra -Rusbandi -Derry Alamsyah	Pada penelitian ini (2022) dilakukan pengklasifikasian penyakit pada daun jagung menggunakan metode CNN dengan arsitektur ResNet50. Pada kasus ini digunakan pula beberapa optimizer yaitu Adam, Nadam, dan SGD. Dataset yang digunakan berjumlah 4225 gambar yang dibagi menjadi 3380 gambar untuk data training dan 845 gambar untuk data tes dengan ukuran resolusi gambar 224X224 piksel. Kemudian didapati bahwa tingkat akurasi tertinggi dengan menggunakan optimizer Adam sebesar 98%.
5.	-Sarah Lasniari -Jasril -Suwanto Sanjaya -Febi Yanto -Muhammad Affandes	Pada penelitian ini (2022) melakukan klasifikasi citra pada daging sapi dan daging babi menggunakan metode CNN dengan arsitektur ResNet50. Jumlah data yang digunakan sebanyak 457 gambar, citra terbagi menjadi 3 kelas, yaitu daging babi, daging oplosan dan daging sapi. Setiap kelas memiliki ukuran gambar yang sama yaitu 300X300 piksel. Pembagian data dengan perbandingan 70% data latih : 30% data uji, 80% data latih : 20% data uji, dan 90% data latih : 10% data uji. Kemudian didapati bahwa hasil dari pengujian model dengan Confusion Matrix menunjukkan performa klasifikasi tertinggi pada konfigurasi batch size 32, 0.001 Learning Rate, epoch 75 dan split data 90% : 10%.

BAB III

METODOLOGI PENELITIAN

3.1 Spesifikasi Perangkat

Berikut ini merupakan perangkat keras (*hardware*) dan perangkat lunak (*software*) yang digunakan dalam penelitian ini:

3.1.1. Perangkat Keras (*Hardware*)

Tabel 3.1 Perangkat Keras (*Hardware*)

No.	Hardware	Spesifikasi
1.	Perangkat	Laptop Acer Aspire ES 14
2.	Processor	Intel Celeron-N3050 1.60 GHz
3.	Monitor	14 Inch
4.	Ram	2.00 GB

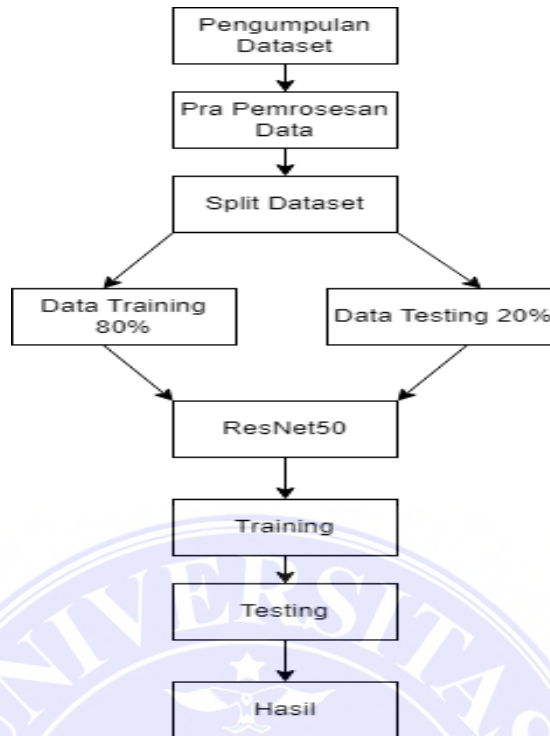
3.1.2. Perangkat Lunak (*Software*)

Tabel 3.2 Perangkat lunak (*Software*)

No.	Software	Spesifikasi
1.	OS	Windows 8.1 Single Language 64-bit
2.	Tools	Google Colab
3.	Bahasa Pemrograman	Python

3.2 Alur Metodologi Penelitian

Metodologi penelitian yang dilakukan terdiri dari pengumpulan *dataset*, membangun model klasifikasi, *training* model klasifikasi, *testing*, dan perhitungan performa. Gambar 3.1 menunjukkan alur metodologi penelitian.



Gambar 3.1. Alur metodologi penelitian

Sebelum melakukan proses klasifikasi menggunakan *ResNet50*, terlebih dahulu dilakukan pengumpulan data yaitu ulat jerman dan ulat hongkong. Kemudian dilakukan pra-pemrosesan, citra ulat jerman dan ulat hongkong yang telah dikumpulkan diubah ukuran piksel citra nya sehingga setiap citra memiliki ukuran piksel yang sama yaitu 224×224 piksel. Langkah selanjutnya yaitu membagi data menjadi data *training* sebanyak 80% dan data testing sebanyak 20% dari total data yg sudah dikumpulkan. Selanjutnya merancang model *hyperparameter* arsitektur *ResNet50*. Setelah arsitektur telah dibentuk maka selanjutnya proses pelatihan data. Selanjutnya setelah data dilatih dilanjutkan proses pengujian untuk menguji model arsitektur mengklasifikasi citra sesuai dengan kelasnya.

3.3 Parameter *Deep Learning*

Selama proses *training*, beberapa nilai parameter yang di inisialisasi antara lain *optimizer Adam* dan *batch size*. Dalam penggunaan algoritma *optimizer Adam*, perlu menentukan besar *learning rate* yang akan digunakan dalam melakukan *training dataset*. *Learning rate* merupakan salah satu parameter *training* yang ditentukan untuk menghitung nilai bobot pada waktu proses *training*. Menentukan nilai *learning rate* memang merupakan tantangan tersendiri karena jika nilai terlalu kecil maka *training* akan membutuhkan waktu yang lama sebaliknya jika terlalu besar maka *training* akan menjadi kurang optimal karena terlalu cepat dan proses *training* menjadi tidak stabil. *Batch size* juga perlu ditentukan dalam proses *training*. *Batch size* merupakan istilah yang digunakan dalam *machine learning* yang mengacu pada jumlah pelatihan yang digunakan dan merupakan salah satu *hyperparameter* terpenting untuk ditentukan.

Berikut ini merupakan parameter yang akan digunakan pada penelitian kali ini:

Tabel 3.3. *Hyperparameter*

No.	Nama	Nilai
1.	Epoch	(5, 15, 25)
2.	Batch Size	(8, 16, 32)
3.	Optimizer	(Adam, RMSprop)

3.4 *Dataset*

Data yang digunakan pada penelitian ini diambil melalui laman *website kaggle.com*, kemudian membagi *dataset* gabungan menjadi dua kelas yaitu *Zophobas Morio* (ulat jerman) dan *Tenebrio Molitor* (ulat hongkong). Sumber

referensi sampel data dibawah ini diambil dari halaman <https://doi.org/10.7717/peerjcs.884/fig-1>.



(a).

(b).

Gambar 3.2. Contoh Dataset (a). Ulat Jerman, (b). Ulat Hongkong

3.5 Metode Evaluasi

Untuk mengevaluasi kinerja kuantitatif dari usulan model ini, metrik yang akan digunakan yaitu *Accuracy*, *Precision*, *Recall*, dan *F1 Score*. Untuk memahami metrik yang akan digunakan, sebelumnya akan didefinisikan terlebih dahulu bahwa *true positive* (TP), *false positive* (FP), *false negative* (FN) dan *true negative* (TN) seperti yang ditunjukkan pada tabel *confusion matrix* dibawah ini:

Tabel 3.4. *Confusion Matrix*

		Kelas Sebenarnya	
		Positif	False Positive
Prediksi	Positif	True Positive	False Positive
	Negatif	False Negative	True Negative

TP didefinisikan sebagai data positif yang diprediksi sebagai positif dan TN didefinisikan sebagai data negatif yang di prediksi sebagai negatif. Sedangkan FN

merupakan kebalikan dari TP yaitu data positif yang diprediksi sebagai negatif dan, FP kebalikan dari TN, yaitu data negatif yang diprediksi positif.

Dibawah ini berturut-turut menunjukkan rumus perhitungan dari *Accuracy*, *Precision*, *Recall*, dan *F1 Score*:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

Keterangan :

TP = *true positive*

FP = *false positive*

FN = *false negative*

TN = *true negative*

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil dari pengujian dataset pada citra larva *zophobas morio* dan *tenebrio molitor* dengan arsitektur *ResNet50*, maka dapat disimpulkan bahwa:

- a. *Epoch* yang paling baik adalah *epoch* yang berjumlah 25, dengan *batch size* yang paling baik adalah 32 dan *optimizer* yang paling baik adalah *Adam*. Secara keseluruhan *hyperparameter* yang paling optimal yaitu pada konfigurasi *epoch* 25, *batch* 32 dan *optimizer Adam* dengan akurasi sebesar 97%. Dengan nilai presisi, sensitifitas, dan *f1 score* berturut-turut sebesar 97%, 97% dan 97%.
- b. Diantara *optimizer Adam* dan *RMSprop*, dapat dilihat bahwa *optimizer* yang paling optimal adalah *optimizer Adam*.

5.2 Saran

Pada penelitian kali ini, ada beberapa hal yang dapat ditingkatkan, yaitu:

- a. Dapat melakukan penelitian dengan menggunakan arsitektur yang lainnya, seperti VGG19, *MobileNet*, atau *DenseNet*.
- b. Dapat melakukan penelitian dengan menggunakan optimizer yang lainnya, seperti SGD, *Adadelta*, *Adagrad*, atau *Nadam*.
- c. Dapat menambah jumlah data sebanyak 1500 citra larva atau lebih untuk masing-masing jenis larva di penelitian selanjutnya.

- d. Secara umum, kinerja arsitektur *ResNet50* dalam mengklasifikasi larva *zophobas morio* dan *tenebrio molitor* sudah sangat baik, akan lebih baik lagi jika dapat menemukan kombinasi *hyperparameter* yang lebih tepat.



DAFTAR PUSTAKA

- Alzamily, J. Y., Ariffin, S. B., & Naser, S. S. (2022). Classification of Encrypted Images Using Deep Learning ResNet50. *Journal of Theoretical and Applied Information Technology* .
- Bashar, A. (2019). Survey on Evolving Deep Learning Neural Network. *Journal of Artificial Intelligence and Capsule Networks* , 73-82.
- Chen, H., Wang, Y., Guo, T., Xu, C., Deng, Y., Liu, Z., et al. (2021). Pre-Trained Image Processing Transformer. 12299-12310.
- Christin, S., Hervet, É., & Lecomte, N. (2019). Applications for Deep Learning in Ecology. 1632 - 1644.
- Cinar, A., Eroglu, Y., & Yildirim, M. (2020). Classification of Pneumonia Cell Images Using Improved ResNet50 Model. *IETA (International Information and Engineering Technology Association)* .
- Fawwaz, M. A., Ramadhani, K. N., & Sthevanie, F. (2021). Klasifikasi Ras pada Kucing menggunakan Algoritma Convolutional Neural Network(CNN). *Jurnal Tugas Akhir Fakultas Informatika* .
- Heryadi, Y., & Irwansyah, E. (2020). Deep Learning: Aplikasinya di Bidang Geospasial.
- Hong, J., Han, T., & Kim, Y. Y. (2020). Mealworm (*Tenebrio molitor* Larvae) as an Alternative Protein Source for Monogastric Animal.
- Iftinanto, A. N. (2021). Penerapan Deep Learning Untuk Penentuan Event Gempaan dan Fase Gelombang Pada Wilayah Sulawesi.
- Jacob, J., & Darney, E. (2021). Design of Deep Learning Algorithm for IoT Application by Image based Recognition. 276-290.
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine Learning and Deep Learning. 685-695.
- Kawaguchi, K., Huang, J., & Kaelbling, L. P. (2019). Effect of Depth and Width on Local Minima in Deep Learning. *Neural Computation* , 1462-1498.
- Kusumawardani, R., & Karningsih, P. D. (2020). Deteksi dan Klasifikasi Cacat Kemasan Kaleng Menggunakan Convolutional Neural Network. *Prozima* .
- Li, Z. (2020). Practice of Gesture Recognition Based on ResNet50. *Journal of Physics: Conference Series* .
- Mater, A. C., & Coote, M. L. (2019). Deep Learning in Chemistry. *Journal of Chemical Information and Modeling* , 2545-2559.
- Miranda, D. N., Novamizanti, L., & Rizal, S. (2020). Convolutional Neural Network Pada Klasifikasi Sidik Jari Menggunakan Resnet-50. *Jurnal Teknik Informatika (JUTIF)* .

- Nadira, M. (2019). Implementasi Deep Learning dengan Metode Convolutional Neural Network Untuk Identifikasi Citra Bahan Kulit Hewan.
- Naquitasia, R., Fudholi, D. H., & Iswari, L. (2022). Analisis Sentimen Berbasis Aspek Pada Wisata Halal dengan Metode Deep Learning. 156-164.
- Nashrullah, F., Wibowo, S. A., & Budiman, G. (2020). Investigasi Parameter Epoch Pada Arsitektur ResNet- 50 Untuk Klasifikasi Pornografi. *Journal of Computer, Electronic, and Telecommunication* .
- Nesa, N. J., & Layek, A. (2021). Parkinson's Disease Detection Using ResNet50 with Transfer Learning. *International Journal of Computer Vision and Signal Processing* , 17-23.
- Peryanto, A., Yudhana, A., & Umar, R. (2020). Rancang Bangun Klasifikasi Citra dengan Teknologi Deep Learning Berbasis Metode Convolutional Neural Network. 138.
- Pratondo, A., & Bramantoro, A. (2022). Classification of Zophobas Morio and Tenebrio Molitor Using Transfer Learning.
- Raffel, C., Shazeer, N., Roberts, A., Lee, K., Narang, S., Matena, M., et al. (2020). Exploring the Limits of Transfer Learning with a Unified. *Journal of Machine Learning Research* , 1-67.
- Rahman, Z. B., Hamidi, E. A., & Kamelia, L. (2019). Sistem Pengaturan Suhu Pada Kandang Ulat Jerman Menggunakan Arduino Uno. 103-109.
- Ramadhani, N., Hendryli, J., & Herwindianti, D. E. (2019). Pencarian Objek Wisata Bersejarah di Pulau Jawa Menggunakan Convolutional Neural Network. *Jurnal Ilmu Komputer dan Sistem Informasi* .
- Rijsdijk, J., Wu, L., Perin, G., & Picek, S. (2021). Reinforcement Learning for Hyperparameter Tuning in Deep Learning based Side Channel Analysis. 677-707.
- Ruder, S., Peters, M. E., Swayamdipta, S., & Wolf, T. (2019). Transfer Learning in Natural Language Processing. 15-18.
- Rumbos, C. I., Karapanagiotidis, I. T., Mente, E., Psoufakis, P., & Athanassiou, C. G. (2020). Evaluation of Various Commodities for the Development of the Yellow Mealworm, Tenebrio Molitor.
- Setiawan , W. (2019). Perbandingan Arsitektur Convolutional Neural Network untuk Klasifikasi Fundus. *Jurnal Ilmiah SimanteC* .
- Sinha, S., & Gupta, N. (2020). Computer Aided Diagnosis of Malaria through Transfer Learning Using the ResNet50 Backbone.
- Strubell, E., Ganesh, A., & McCallum, A. (2019). Energy and Policy Considerations for Deep Learning in NLP. *Computation and Language* .
- Su, H., Jampani, V., Sun, D., Gallo, O., Miller, E. L., & Kautz, J. (2019). Pixel-Adaptive Convolutional Neural Networks. 11166-11175.

- Suzuki, T., & Nitanda, A. (2021). Deep Learning is Adaptive to Intrinsic Dimensionality of Model Smoothness in Anisotropic Besov Space. *Neural Information Processing Systems* .
- Tamma, S. (2019). Transfer learning using VGG-16 with Deep Convolutional Neural Network for Classifying Images.
- Tokarev, Y., Malysh, S., Volodartseva, Y. V., Gerus, A. V., & Berezin, M. v. (2019). Molecular Identification of a Densovirus in Healthy and Diseased *Zophobas morio* (Coleoptera, Tenebrionidae). *Intervirolgy* , 222-226.
- VandenBrooks, J. M., Ford, C. F., & Harrison, J. F. (2020). Responses to Alteration of Atmospheric Oxygen and Social Environment Suggest Trade-Offs among Growth Rate, Life Span, and Stress Susceptibility in Giant Mealworms (*Zophobas morio*). *Physiological and Biochemical Zoology* .
- Walvekar, S., & Shinde, S. (2020). Detection of COVID-19 from CT Images Using resnet50.
- Wu, J., Chen, X. Y., Zhang, H., Xiong, L. D., Lei, H., & Deng, S. H. (2019). Hyperparameter Optimization for Machine Learning Models Based on Bayesian Optimization. *Journal of Electronic Science and Technology* , 26-40.
- Yuan, J., Fan, Y., Lv, X., Chen, C., Li, D., Hong, Y., et al. (2020). Research on the Practical Classification and Privacy Protection of CT Images of Parotid Tumors based on ResNet50 Model. *Journal of Physics: Conference Series* .
- Zhao, C., Ni, B., Zhang, J., Zhao, Q., Zhang, W., & Tian, Q. (2019). Variational Convolutional Neural Network Pruning. 2780-2789.
- Zhou, L., Zhang, C., Liu, F., Qiu, Z., & He, Y. (2019). Application of Deep Learning in Food. *Comprehensive Reviews in Food Science and Food Safety* , 1793-1811.

LAMPIRAN

1. Kode Program

```
from google.colab import drive
drive.mount('/content/drive')

from __future__ import print_function, division
from builtins import range, input

from tensorflow.keras.layers import Input, Lambda, Dense, Flatten,
AveragePooling2D, Dropout
from tensorflow.keras.models import Model, load_model
from tensorflow.keras.applications import ResNet50
from tensorflow.keras.applications.resnet50 import preprocess_input
from tensorflow.keras.preprocessing import image
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from sklearn.preprocessing import LabelBinarizer
from tensorflow.keras.utils import to_categorical
from builtins import range, input
from sklearn.metrics import classification_report
from sklearn.model_selection import train_test_split

from sklearn.metrics import confusion_matrix, roc_curve
import seaborn as sns
import numpy as np
import matplotlib.pyplot as plt
import cv2
from glob import glob

from keras.callbacks import ModelCheckpoint, EarlyStopping
import time
```

```

import datetime

#define paths
UJ_path = '/content/drive/MyDrive/dataset/train/Zophobas'
UH_path = '/content/drive/MyDrive/dataset/train/Tenebrio'

# Use glob to grab images from path .jpg or jpeg
UJ_files = glob(UJ_path + '/*')
UH_files = glob(UH_path + '/*')

from keras.preprocessing.image import ImageDataGenerator

train_datagen = ImageDataGenerator (rescale= 1./224,
                                    shear_range = 0.2,
                                    zoom_range = 0.2,
                                    horizontal_flip = True)

test_datagen = ImageDataGenerator (rescale= 1./224)

training_set = train_datagen.flow_from_directory
('/content/drive/MyDrive/dataset/train',
class_mode='categorical')

test_set = test_datagen.flow_from_directory
('/content/drive/MyDrive/dataset/test',
class_mode='categorical')

#Preparing Labels
UJ_labels = []
UH_labels = []

UJ_images=[]

```

```
UH_images=[]
```

```
for i in range(len(UJ_files)):
    image = cv2.imread(UJ_files[i])
    image = cv2.cvtColor(image, cv2.COLOR_BGR2RGB)
    image = cv2.resize(image,(224,224))
    UJ_images.append(image)
    UJ_labels.append('Ulat Jerman')
for i in range(len(UH_files)):
    image = cv2.imread(UH_files[i])
    image = cv2.cvtColor(image, cv2.COLOR_BGR2RGB)
    image = cv2.resize(image,(224,224))
    UH_images.append(image)
    UH_labels.append('Ulat Hongkong')
```

```
UJ_images = np.array(UJ_images) / 255
UH_images = np.array(UH_images) / 255
```

```
# Split into training and testing sets
UJ_x_train, UJ_x_test, UJ_y_train, UJ_y_test = train_test_split(
    UJ_images, UJ_labels, test_size=0.2)
```

```
UH_x_train, UH_x_test, UH_y_train, UH_y_test = train_test_split(
    UH_images, UH_labels, test_size=0.2)
```

```
# Merge jerman and hongkong images
X_train = np.concatenate((UH_x_train, UJ_x_train), axis=0)
X_test = np.concatenate((UH_x_test, UJ_x_test), axis=0)
y_train = np.concatenate((UH_y_train, UJ_y_train), axis=0)
y_test = np.concatenate((UH_y_test, UJ_y_test), axis=0)
```

```
# Assign labels 0 and 1
```

```
y_train = LabelBinarizer().fit_transform(y_train)
```

```
y_train = to_categorical(y_train)
```

```
y_test = LabelBinarizer().fit_transform(y_test)
```

```
y_test = to_categorical(y_test)
```

```
# Building Model
```

```
resnet = ResNet50(weights="imagenet", include_top=False,  
    input_tensor=Input(shape=(224, 224, 3)))
```

```
outputs = resnet.output
```

```
outputs = Flatten(name="flatten")(outputs)
```

```
outputs = Dropout(0.5)(outputs)
```

```
outputs = Dense(2, activation="softmax")(outputs)
```

```
model = Model(inputs=resnet.input, outputs=outputs)
```

```
for layer in resnet.layers:
```

```
    layer.trainable = False
```

```
model.compile(  
    loss='categorical_crossentropy',  
    optimizer='Adam',  
    metrics=['accuracy']  
)
```

```
# Visualize Model
```

```
model.summary()
```

```
from builtins import range, input
```

```
from tensorflow.keras.layers import Input
```

```
from tensorflow.keras.models import Model, load_model
```

```
import time
```

```
import datetime
```

```

def modelGridConfig():
    n_epochs = [5]
    n_batch_size=[8]
    n_optimizer = ['Adam']

    config = list()
    for i in n_epochs:
        for j in n_batch_size:
            for m in n_optimizer:
                cfg = [i, j, m]
                config.append(cfg)
    print("Total Configs: %d" % len(config))
    return config

cfg_list = modelGridConfig()
print(cfg_list)
count = 0
for cfg in cfg_list:
    count = count + 1
    print("config no", count)
    epoch, batch, optimizer = cfg
    res = ResNet50(weights="imagenet", include_top=False,
        input_tensor=Input(shape=(224, 224, 3)))

    outputs = res.output
    outputs = Flatten(name="flatten")(outputs)
    outputs = Dropout(0.5)(outputs)
    outputs = Dense(2, activation="softmax")(outputs)
    model = Model(inputs=res.input, outputs=outputs)

    for layer in res.layers:
        layer.trainable = False

```



```

now = datetime.datetime.now
t = now()

model.compile(
    loss='binary_crossentropy',
    optimizer=optimizer,
    metrics=['accuracy']
)
history = model.fit(X_train,
                    y_train,
                    epochs=epoch,
                    batch_size=batch,
                    validation_data=(X_test, y_test))

results = model.evaluate(X_test, y_test)
print(results)

print('Training time: %s' % (now() - t))

model.evaluate(X_test, y_test)


y_pred = model.predict(X_test, batch)

from sklearn.metrics import confusion_matrix, roc_curve
y_pred = model.predict(X_test)
# Convert to Binary classes
y_pred_bin = np.argmax(y_pred, axis=1)
y_test_bin = np.argmax(y_test, axis=1)

def plot_confusion_matrix(normalize):
    classes = ['UJ', 'UH']
    tick_marks = [0.5, 1.5]
    cn = confusion_matrix(y_test_bin, y_pred_bin, normalize=normalize)
    from sklearn.metrics import confusion_matrix
    confusion_matrix(y_test_bin, y_pred_bin)

```

2. SK Pembimbing



UNIVERSITAS MEDAN AREA

FAKULTAS TEKNIK

Kampus I : Jalan Kolan Nomor 1 Medan Estate/Jalan PBSI Nomor 1 ☎ (061) 7398878, 7380168, 7364348, 7366781, Fax.(061) 7366998 Medan 20223
Kampus II : Jalan Setiabudi Nomor 79 / Jalan Sei Sengay Nomor 70 A, ☎ (061) 8225402, Fax. (061) 8226331 Medan 20122
Website: www.fteknik.uma.ac.id E-mail: univ_medan@uma.ac.id

Nomor : 385/FT.6/01.10/V/2023 27 Mei 2023
Lamp : -
Hal : **Perubahan Judul Tugas Akhir**

Yth, Pembimbing Tugas Akhir
Muhathir, ST, M.Kom
Nurul Khairina, S.Kom, M.Kom
di
Tempat

Dengan hormat, Sehubungan dengan adanya perubahan judul tugas akhir maka perlu diterbitkan kembali SK Pembimbing Skripsi baru atas nama mahasiswa tersebut :

Nama : Rujito
NPM : 178160039
Jurusan : Teknik Informatika

Maka dengan hormat kami mengharapkan kesediaan saudara :


1. Muhathir, ST, M.Kom (Sebagai Pembimbing I)
2. Nurul Khairina, S.Kom, M.Kom (Sebagai Pembimbing II)

Adapun Tugas Akhir Skripsi berjudul :

"Hyperparameter Model Arsitektur ResNet50 dalam Mengklasifikasi Zophobas Mario dan Tenebrio Molitor".




SK Pembimbing ini berlaku selama enam bulan terhitung sejak SK ini diterbitkan. Jika proses pembimbing melebihi batas waktu yang telah ditetapkan, SK ini dapat ditinjau ulang.

Demikian kami sampaikan, atas kesediaan saudara diucapkan terima kasih.




Dekan,
Dr. Rahmad Syah, S. Kom, M. Kom

3. Surat Pengantar Riset

	UNIVERSITAS MEDAN AREA FAKULTAS TEKNIK								
Kampus I : Jalan Kolam Nomor 1 Medan Estaria/Ujan PBSI Nomor 1 ☎ (061) 7398878, 7360168, 7364348, 7366781, Fax (061) 7366998 Medan 20225 Kampus II : Jalan SeiBelud Nomor 79 / Jalan Sei Seraya Nomor 70 A, ☎ (061) 8225602, Fax, (061) 8226331 Medan 20122 Website: www.fakult.teknik.uma.ac.id E-mail: univ_medanarea@uma.ac.id									
Nomor : 130 /FT.6/01.10/II/2023	16 Februari 2023								
Lamp : -									
Hal : Penelitian Dan Pengambilan Data Tugas Akhir									
Yth. Wakil Rektor Bid. Pengembangan SDM & Adm. Keuangan Jln. Kolam No.1 Di Medan									
Dengan hormat, kami mohon kesediaan ibu kiranya berkenan untuk memberikan izin dan kesempatan kepada mahasiswa kami tersebut dibawah ini :									
<table border="1"><thead><tr><th>NO</th><th>NAMA</th><th>NPM</th><th>PRODI</th></tr></thead><tbody><tr><td>1</td><td>Rujito</td><td>178160039</td><td>Teknik Informatika</td></tr></tbody></table>	NO	NAMA	NPM	PRODI	1	Rujito	178160039	Teknik Informatika	
NO	NAMA	NPM	PRODI						
1	Rujito	178160039	Teknik Informatika						
Untuk melaksanakan Penelitian dan Pengambilan Data Tugas Akhir di Laboratorium Komputer Program Studi Teknik Informatika Fakultas Teknik Universitas Medan Area.									
Perlu kami jelaskan bahwa Pengambilan Data tersebut adalah semata-mata untuk tujuan Ilmiah dan Skripsi, yang merupakan salah satu syarat bagi mahasiswa tersebut untuk mengikuti ujian sarjana pada Fakultas Teknik Universitas Medan Area dan tidak untuk dipublikasikan, dengan judul :									
Hyperparameter Model Arsitektur SqueezeNet dalam Mengklasifikasi Larva Zophobas Morio dan Tenebrio Molitor.									
Mohon kiranya tanggal Surat Izin Pengambilan Data Tugas Akhir agar disesuaikan dengan tanggal Terbitnya SK ini.									
Atas perhatian dan kerja sama yang baik diucapkan terima kasih.									
 Dekan									
 Dr. Rahmadsyah, S. Kom, M. Kom									
Tembusan : 1. Ka. BAMA 2. Mahasiswa 3. File									

4. Surat Selesai Riset



UNIVERSITAS MEDAN AREA

Kampus I : Jalan Kolam Nomor 1 Medan Estate ☎ (061) 7360168, 7366878, 7364348 ☎ (061) 7368012 Medan 20223
Kampus II : Jalan Setiabudi Nomor 79 / Jalan Sei Serayu Nomor 70 A ☎ (061) 8225602 ☎ (061) 8226331 Medan 20122
Website: www.uma.ac.id E-Mail: univ_medanarea@uma.ac.id

SURAT KETERANGAN
Nomor : 659 /UMA/B/01.7/IV/2023


Rektor Universitas Medan Area dengan ini menerangkan bahwa :

Nama	: Rujito
No. Pokok Mahasiswa	: 178160039
Program Studi	: Teknik Informatika
Fakultas	: Teknik

Benar telah selesai Pengambilan Data di Universitas Medan Area dengan Judul
"Hyperparameter Model Arsitektur SqueezeNet Dalam Mengklasifikasi Larva Zophobas Morio dan Tenebrio Molitor".


Dan kami harapkan Data tersebut kiranya dapat membantu yang bersangkutan dalam penyusunan skripsi dan dapat bermanfaat bagi mahasiswa khususnya Fakultas Teknik.

Demikian surat ini diterbitkan untuk dapat digunakan seperlunya.


Medan, 06 April 2023,
An Rektor,
Wakil Rektor Bidang Pengembangan SDM dan
Administrasi Keuangan,

Dr. Ir. Suswati, MP

Tembusan :

1. Mahasiswa Yhs
2. File



5. Hasil Cek Plagiat Turnitin



The image shows a Turnitin similarity report for a document titled 'Turnitin_Rujito_178160039.docx' by the author 'Rujito Rujito'. The report includes statistics such as word count (6609 words), character count (40296 characters), page count (46 pages), and file size (2.5MB). It also shows the submission date (Dec 4, 2023 10:27 AM GMT+7) and the report date (Dec 4, 2023 10:28 AM GMT+7). The overall similarity is 21%, with a breakdown: 20% from the Internet database, 3% from Publications database, 8% from Submitted Works database, and 3% from Crossref database. Excluded matches include small matches (less than 10 words). A large watermark of Universitas Medan Area is visible in the background.

turnitin Similarity Report ID: oid:29477:47636769

PAPER NAME: Turnitin_Rujito_178160039.docx AUTHOR: Rujito Rujito

WORD COUNT: 6609 Words CHARACTER COUNT: 40296 Characters

PAGE COUNT: 46 Pages FILE SIZE: 2.5MB

SUBMISSION DATE: Dec 4, 2023 10:27 AM GMT+7 REPORT DATE: Dec 4, 2023 10:28 AM GMT+7

21% Overall Similarity
The combined total of all matches, including overlapping sources, for each database.

- 20% Internet database
- 3% Publications database
- Crossref database
- Crossref Posted Content database
- 8% Submitted Works database

Excluded from Similarity Report

- Small Matches (Less than 10 words)

Summary