

HYPERPARAMETER MODEL ARSITEKTUR XCEPTION DALAM MENGIKLASIFIKASI ULAT JERMAN DAN ULAT HONGKONG

SKRIPSI

Oleh :

AMRI ISMAIL TUMANGGOR

178160045



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

UNIVERSITAS MEDAN AREA

© Hak Cipta Di Lindungi Undang-Undang

Document Accepted 19/4/24

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

Access From (repository.uma.ac.id)19/4/24

HYPERPARAMETER MODEL ARSITEKTUR XCEPTION DALAM MENGIKLASIFIKASI ULAT JERMAN DAN ULAT HONGKONG

SKRIPSI

Diajukan Sebagai Salah Satu Syarat Untuk Memperoleh
Gelar Sarjana (S1) di Fakultas Teknik
Universitas Medan Area

Oleh :

AMRI ISMAIL TUMANGGOR

178160045



PROGRAM STUDI TEKNIK INFORMATIKA

FAKULTAS TEKNIK

UNIVERSITAS MEDAN AREA

MEDAN

2023

LEMBAR PENGESAHAN

Judul Skripsi : **Hyperparameter Model Arsitektur Xception dalam Mengklasifikasi Ulat Jerman Dan Ulat Hongkong**

Nama : Amri Ismail Tumanggor

NPM : 178160045

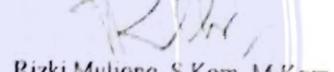
Fakultas : Teknik

Prodi : Teknik Informatika

Disetujui Oleh

Komisi Pembimbing


Muhathir, ST, M.Kom.
Pembimbing I


Rizki Muliono, S.Kom, M.Kom
Pembimbing II

Mengetahui


Drs. Paki Supriatno, S.T, M.T.
NIDN : 0102027402


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

Tanggal Lulus : 18 September 2023

iii

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, 18 September 2023

Amri Ismail Tumanggor
178160045

**HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS
AKHIR/SKRIPSI/TESIS UNTUK KEPENTINGAN AKADEMIS**

Sebagai civitas akademika Universitas Medan Area, Saya yang bertanda tangan dibawah ini.

Nama : Amri Ismail Tumanggor
NPM : 178160045
Program Studi : Informatika
Fakultas : Teknik
Jenis Karya : Skripsi

Demi pengembangan 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 Xception dalam Mengklasifikasi Ulat Jerman Dan Ulat Hongkong

beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Noneksklusif ini Universitas Medan Area berhak menyimpan, mengalihmedia/format-kan, mengelola dalam bentuk pangkalan data (database), merawat, dan mempublikasikan tugas akhir/skripsi/tesis 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 : 18 September 2023
Yang menyatakan

(Amri Ismail Tumanggor)

ABSTRAK

Dengan memanfaatkan *deep learning*, deteksi dan klasifikasi objek yang hampir sama merupakan hal mendasar dan tantangan untuk memberikan akurasi terbaik dalam membedakan dua larva yaitu ulat Jerman dan ulat hongkong. Ulat jerman dan ulat hongkong merupakan larva dengan morfologi yang sama namun ulat jerman lebih bergizi dibandingkan ulat hongkong. Karena kesamaan morfologi kedua larva tersebut pengetahuan masyarakat terutama pecinta hewan terbatas sehingga sedikit sulit membedakannya. Tujuan penelitian ini adalah menyajikan *hyperparameter* terbaik dalam klasifikasi Ulat Jerman dan Ulat hongkong dengan model arsitektur *Xception*. Model dilatih dengan menggunakan dataset berupa citra. Parameter yang digunakan dalam pelatihan yaitu *Epoch*, *Batch Size*, dan *Optimizer*. Hasil pengujian menunjukkan Parameter terbaik dan paling optimal dalam klasifikasi Ulat Jerman dan Ulat Hongkong adalah Parameter dengan kombinasi *Epoch 5 Batch Size 8* dengan *Optimizer SGD* dengan akurasi 100% dan waktu komputasi 27,9 menit.

Kata kunci: Ulat Jerman, Ulat Hongkong, *Xception*

ABSTRACT

By utilizing deep learning, the detection and classification of nearly identical objects are fundamental aspects and challenges to achieve the best accuracy in distinguishing two types of larvae, namely the Zophobas Morio and the Tenebrio molitor. Zophobas morio and Tenebrio molitor share similar morphologies, but Zophobas morio are more nutritious compared to Tenebrio molitor. Due to the morphological similarities between these larvae, public knowledge, especially among animal enthusiasts, is limited, making it somewhat challenging to differentiate them. The purpose of this research is to present the best hyperparameters for the classification of Zophobas morio and Tenebrio molitor using the Xception architecture model. The model was trained using a dataset consisting of images. The parameters used in training are Epoch, Batch Size, and Optimizer. The test results indicate that the optimal and best parameters for the classification of zophobas morio tenebrio molitor are the combination of Epoch 5, Batch Size 8, with Optimizer SGD, achieving an accuracy of 100% and a computational time of 27.9 minutes.

Keywords: *Zophobas Morio, Tenebrio Molitor, Zception*

RIWAYAT HIDUP

Penulis dilahirkan di Batugajah Pada tanggal 13 Desember 1998 dari Bapak Berawan Tumanggor dan Ibu Agustina Silalahi. Penulis merupakan anak ke-dua (2) dari empat (4) bersaudara. Tahun 2016 Penulis lulus dari MAN Doloksanggul dan pada tahun 2017 terdaftar sebagai mahasiswa Fakultas Teknik Universitas Medan Area. Selama mengikuti perkuliahan, penulis melaksanakan kerja praktek (KP) di SD 050713 Tanjung Beringin.



KATA PENGANTAR

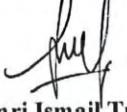
Puji dan Syukur penulis ucapkan kepada Allah SWT atas karunia dan hidayah-Nya, sehingga penulis bisa menyelesaikan Tugas Akhir dengan baik yang berjudul “ Hyperparameter Model Arsitektur Xception dalam Mengklasifikasi Ulat Jerman Dan Ulat Hongkong”. Tujuan dari penelitian ini adalah sebagai syarat dalam menyelesaikan Tugas Akhir Program Studi Teknik Informatika Universitas Medan Area.

Pada kesempatan ini, penulis mengucapkan banyak terima kasih kepada pihak-pihak yang telah memberikan dukungan, arahan serta bimbingan sehingga penulis dapat menyelesaikan skripsi ini dengan sebaik-baiknya. Oleh karena itu penulis mengucapkan terimakasih kepada:

1. Kedua Orang Tua serta kakak saya yang telah mendukung, memberikan semangat, motivasi dan banyak perhatian selama masa penyusunan Tugas Akhir/skripsi ini.
2. Bapak Rizki Muliono, S.Kom, M.Kom selaku Kepala Program Studi Teknik Informatika.
3. Bapak Dr. Eng., Supriatno, S.T, M.T., selaku Dekan Fakultas Teknik Universitas Medan Area Dan Pembimbing I Tugas Akhir.
4. Bapak Muhathir, S.T, M.Kom selaku Dosen Pembimbing I.
5. Seluruh Dosen dan staf Teknik Informatika yang telah membantu dalam penyusunan Tugas Akhir ini hingga dapat terselesaikan dengan baik.
6. Teman-teman seperjuangan semasa kuliah yang telah menemani dan menyemangati saya dari awal perkuliahan hingga saat ini.

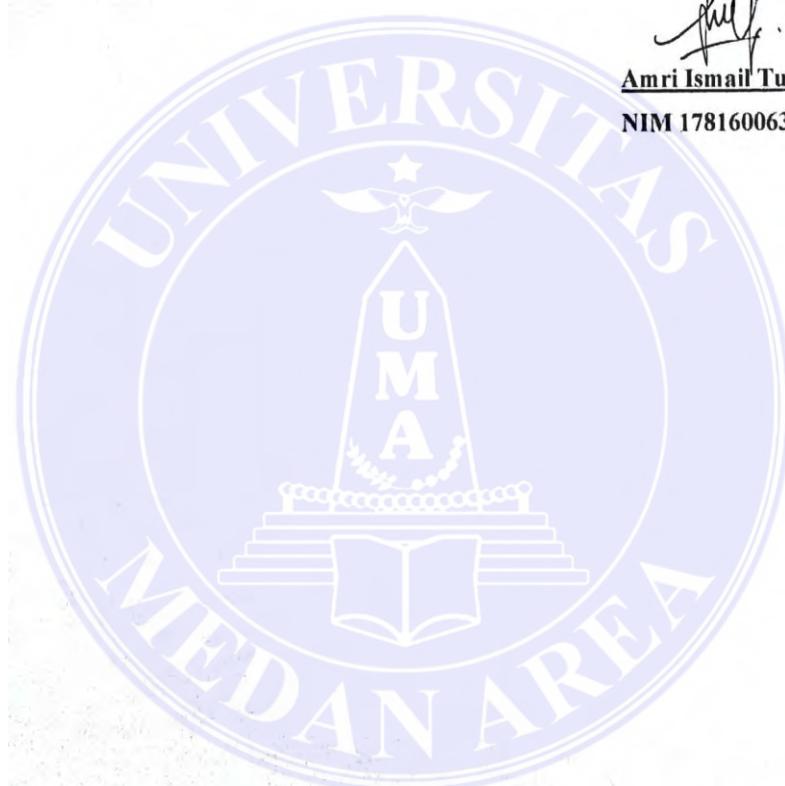
Penulis menyadari bahwa Tugas Akhir dan penyusunan laporan ini masih belum sempurna dikarenakan pengetahuan dan pengalaman penulis, untuk itu penulis mengharapkan kritik dan saran yang membangun dari pembaca untuk pengembangan selanjutnya.

Medan, 18 September 2023



Amri Ismail Tumanggor

NIM 178160063



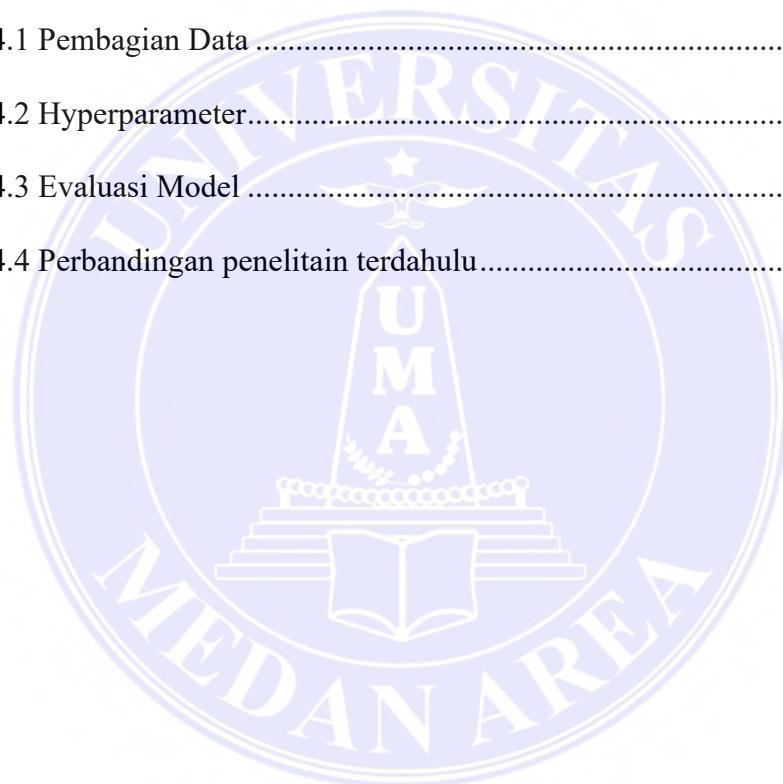
DAFTAR ISI

LEMBAR PENGESAHAN	iii
HALAMAN PERNYATAAN	iv
HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI.....	
Error! Bookmark not defined.	
ABSTRAK	vi
ABSTRACT.....	vii
RIWAYAT HIDUP	viii
KATA PENGANTAR.....	ix
DAFTAR ISI.....	
DAFTAR TABEL	xiii
DAFTAR GAMBAR.....	xiv
DAFTAR RUMUS	xv
I. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	4
1.3 Tujuan Penelitian	5
1.4 Batasan Masalah	5
1.5 Manfaat penelitian	5
1.6 Metodologi Penelitian.....	6
II. LANDASAN TEORI.....	8
2.1 Ulat Jerman	8
2.2 Ulat Hongkong.....	9
2.3 Deep Learning.....	9
2.4 Convolutional Neural Network (CNN).....	10
2.5 Xception.....	12
2.6 Hyperparameter	14
2.6 Penelitian Terdahulu	14
III. METODOLOGI PENELITIAN	17
3.1 Alat dan Bahan Penelitian.....	17
3.1.1 Perangkat Keras	17
3.1.2 Perangkat Lunak	17
3.2 Diagram Alur Penelitian	18
3.3 Metode Pengumpulan Data.....	19

3.4 Rancangan Arsitektur	20
3.5 Pembagian Data	21
3.7 Data Testing	21
3.8 Metode Evaluasi.....	22
IV. HASIL DAN PEMBAHASAN	23
4.1 Dataset.....	23
4.2 Hyperparameter.....	23
4.3 Hasil implementasi.....	23
4.4 Model Evaluasi	31
4.5 Confusion Matrix	33
4.6 Perbandingan Penelitian Terdahulu	35
V. KESIMPULAN DAN SARAN	37
5.1 Kesimpulan	37
5.2 Saran	37
DAFTAR PUSTAKA	39
LAMPIRAN	39

DAFTAR TABEL

Tabel.2.1 Hyperparameter.....	12
Tabel.2.2 Penelitian Terdahulu	12
Tabel.3.1.1 Perangkat Keras	17
Tabel.3.1.2 Perangkat Lunak	17
Tabel.3.3 Confusion Matrix	22
Tabel.4.1 Pembagian Data	23
Tabel.4.2 Hyperparameter.....	23
Tabel.4.3 Evaluasi Model	32
Tabel.4.4 Perbandingan penelitian terdahulu.....	35

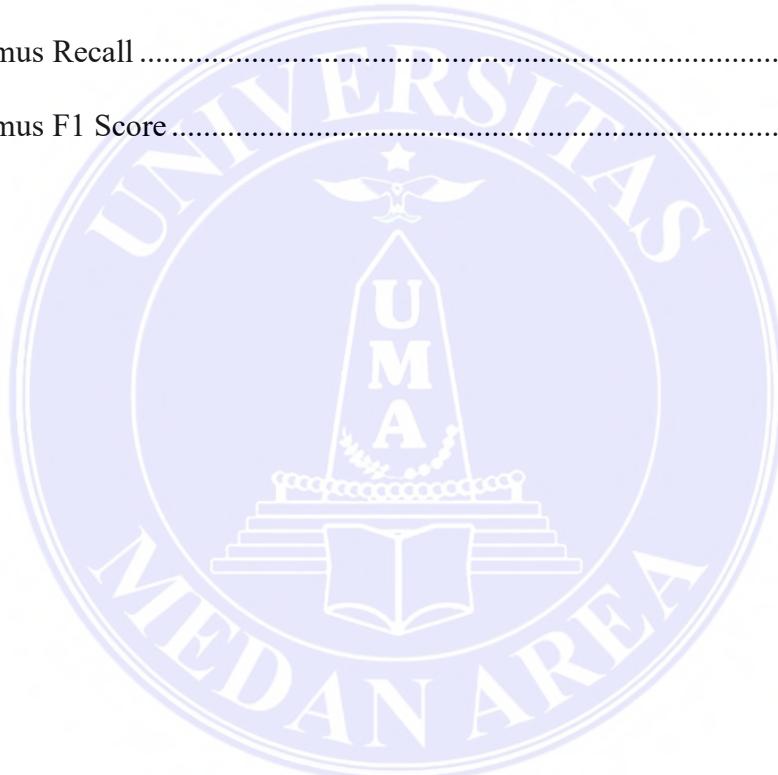


DAFTAR GAMBAR

Gambar 2.1	Representasi pooling layer	11
Gambar 2.2	Arsitektur Xception	13
Gambar 3.1	Alur Penelitian.....	18
Gambar 3.2	Citra Ulat	19
Gambar 3.3	Arsitektur Xception	20
Gambar 4.1	Training Accuracy Exception Epoch 5	24
Gambar 4.2	Validation Accuracy Xception Epoch 5.....	25
Gambar 4.3	Loss accuracy Xception Epoch 5	25
Gambar 4.4	Loss Validation Xception Epoch 5.....	26
Gambar 4.5	Training Accuracy Xception Epoch 10.....	27
Gambar 4.6	Accuracy Validasi Xception Epoch 10	27
Gambar 4.7	Loss Accuracy Xception Epoch 10	28
Gambar 4.8	Loss Validasi Xception Epoch 10	29
Gambar 4.9	Training accuracy Xception Epoch 15	29
Gambar 4.10	Accuracy Validation Xception Epoch 15.....	30
Gambar 4.11	Loss Accuracy Xception Epoch 15	30
Gambar 4.12	Validation loss Xception Epoch 15	31
Gambar 4.13	Confusion matrix Epoch 5 Batch Size 8	33
Gambar 4.14	Confusion matrix Epoch 10 Batch Size 8 SGD	33
Gambar 4.15	Confusion matrix Epoch 15 Batch Size 32 Adam.....	34
Gambar 4.16	Confusion matrix Epoch 15 Batch Size 32 SGD	34

DAFTAR RUMUS

2.1 Rumus Menentukan Konvolusi.....	12
2.2 Rumus Max Pooling.....	12
2.3 Rumus Klasifikasi.....	12
3.1 Rumus Accuracy	12
3.2 Rumus Precision	12
<u>3.3 Rumus Recall</u>	12
3.4 Rumus F1 Score	12



BAB I

PENDAHULUAN

1.1 Latar Belakang

Deep learning merupakan salah satu pengembangan dari *Machine Learning* yang dapat digunakan dalam mengklasifikasi citra untuk membantu manusia untuk mengenali atau mengklasifikasi objek dengan cepat, tepat, dengan banyak proses data secara bersamaan (Maulana & Rochmawati, n.d.). *Deep learning* cenderung mempelajari berbagai representasi data dengan tingkat abstraksi yang berbeda setiap level dan menggunakan beberapa tingkat unit pemrosesan *non-linear* untuk mengekstrak fitur penting dari data yang diberikan dan berjalan dengan otomatis (Khamparia, Aditya and Singh, 2019). Menurut (Maier dkk., 2019) *Deep learning* menggunakan algoritma yang dibuat berdasarkan pada hukum matematik yang bekerja layaknya otak manusia. Salah satu implementasi dari *deep learning* adalah bidang *image processing* atau pengolahan citra.

Kemampuan *deep learning* dalam memecahkan permasalahan dapat dibuktikan juga berdasarkan penelitian terdahulu antara lain (Ramanath dkk., 2019). Tentang *deep learning* dalam klasifikasi tutupan lahan dengan gambar dari udara dengan akurasi mencapai 85,3%, penelitian oleh (Ramanath dkk., 2019) melakukan deteksi tanaman menggunakan citra daun dengan data sebanyak 87.848 gambar yang berisi 25 tanaman berbeda dengan kinerja terbaik mencapai 90% tingkat keberhasilan, *deep learning* juga digunakan untuk klasifikasi objek 3D sebagaimana penelitian (Guo dkk., 2021) menyajikan klasifikasi bentuk 3D, yang dapat deteksi dan pelacakan objek 3D serta segmentasi objek 3D. Penelitian oleh (Dixit & Silakari, n.d.). Algoritma *deep learning* yang memungkinkan jaringan

untuk belajar dari data tanpa pengawasan dan memecahkan masalah yang kompleks. Penelitian oleh (Swapna dkk., 2018) peningkatan kinerja dalam klasifikasi untuk diagnosa diabetes meningkat dengan menggunakan *deep learning* dengan akurasi 95%.

Dengan memanfaatkan *deep learning*, deteksi dan klasifikasi objek yang hampir sama merupakan hal mendasar dan tantangan untuk memberikan akurasi terbaik dalam membedakan dua larva yaitu Ulat Jerman (*Zophobas morio*) dan Ulat Hongkong (*Tenebrio molitor*). Ulat jerman dan ulat hongkong merupakan larva dengan *morfologi* yang sama namun ulat jerman lebih bergizi dibandingkan ulat hongkong (Pratondo & Bramantoro, 2022). Karena kesamaan *morfologi* kedua larva tersebut pengetahuan masyarakat terbatas sehingga sedikit sulit membedakanya. Ulat jerman memiliki kandungan katin (kandungan zat tanduk yang biasa ditemukan diluar kerangka serangga/ulat) yang lebih sedikit dari ulat hongkong sehingga lebih baik untuk dijadikan bahan pakan unggas maupun burung kicau. Kedua larva ini popular digunakan untuk bahan pakan reptil, unggas dan burung kicauan, namun kepopuleran ulat jerman dalam bahan pakan burung kicau masih kalah dengan ulat hongkong berdasarkan penelitian oleh (Pradana, 2022).

Algoritma yang sering dipakai dalam klasifikasi citra dalam *deep learning* salah satunya CNN (*Convolutional Neural Network*) yang mana memiliki beberapa arsitektur diantaranya *Exception*, yang merupakan pengembangan dari arsitektur *Inception* terdahulu yang memiliki 36 *layer convolutional* yang membentuk basis jaringan ekstraksi fitur (Darmasita, 2020). *Xception* merupakan singkatan dari *extreme inception* dan merupakan tumpukan linear dari *depthwise separable convolution* dengan koneksi *residual* (Rahimzadeh & Attar, 2020). *Xception*

menggunakan lapisan konvolusi yang dapat dipisahkan secara mendalam dengan residu koneksi untuk mengurangi kompleksitas waktu dan ruang dengan banyak rincian (X. Wu dkk., 2020). Arsitektur *Xception* memiliki tiga bagian utama yaitu aliran masuk (alliran yang memiliki yang memiliki 2 blok lapisan konvolusi), aliran tengah (aliran dengan perulangan 8 kali) dan aliran keluar (Soria dkk., 2020).

Arsitektur *Xception* memiliki jaringan konvolusi yang dapat dipisahkan secara mendalam, dan mengungguli arsitektur *inception V3* secara signifikan pada data gambar yang lebih besar yang terdiri dari 350 juta gambar dan 17.000 kelas. Dalam hal parameter *Xception* lebih unggul dari setiap model dalam dataset *ImageNet*, dari pendahulunya *inception* peningkatan kinerja ini bukan karena peningkatan kapasitas namun penggunaan model yang lebih efisien (Chollet, 2017). Pada penelitian (Esmail Karar dkk., 2022) melakukan pengujian dari 6 arsitektur diantaranya: *Resnet-50 V2*, *Mobile NetV2*, *Densenet-12*, *EcientNetBO*, *Xception*, dan *MixConvNet*. Penelitian ini bertujuan untuk mengidentifikasi larva kumbang sawit dan *Xception* menjadi salah satu arsitektur yang mempunyai kinerja tertinggi mencapai 94,16%.

Penelitian ini menggunakan Arsitektur *Xception* merupakan bagian dari *transfer learning* yang popular dan juga memiliki tingkat keberhasilan yang tinggi dilihat dari banyak hasil peneliti yang telah menggunakannya salah satunya penelitian (Lo dkk., 2019) tentang klasifikasi *malware* menggunakan *Xception* dan mendapatkan hasil pengujian tertinggi mencapai 99,7% dari 3 model lainnya (*VGG16*, *GIST+SVM* dan *KNN*).

Dalam meningkatkan kinerja dari sebuah model arsitektur ada peran dari *Hyperparameter* sebagai pengoptimal (Farag dkk., 2021). *Hyperparameter* adalah

variabel yang menjelaskan bagaimana struktur *Neural Network* dan cara *training* yang membuat sebuah mesin atau sebuah model untuk memperkirakan model klasifikasi atau mengoptimalkan klasifikasi (J. Wu dkk., 2019). *Hyperparameter* terdiri dari *Hyperparameter* pengoptimal (parameter yang lebih terkait dengan optimasi dan proses pelatihan) yang terdiri dari *Learning Rate*, *mini batch size* dan *number of epoch*. dan model *Hyperparameter* khusus yang terdiri dari *Number of hidden units* dan *first layer* (Tsai dkk., 2020).

Arsitektur *Xception* juga sering digunakan dalam berbagai penelitian klasifikasi hewan seperti penelitian oleh (Majumder dkk., 2021) tentang pengenalan ikan air tawar lokal menggunakan Arsitektur *transfer learning*, dalam pengenalan ikan lele, ikan garfish, dan belut zig-zag. Pada penelitian ini arsitektur *Xception* menyajikan akurasi keseluruhan ikan mencapai 98,81%.

Berdasarkan keunikan dan kemudahan Arsitektur *Xception* dalam mengklasifikasi, maka dalam penelitian ini mengujikan model arsitektur *Xception* untuk mengklasifikasi jenis ulat jerman dan ulat hongkong dengan memanfaatkan *hyperparameter*: *batch size*, *Optimizer* dan *epoch*. pemilihan *Hyperparameter* tersebut berlandas tingkat keakuratan sebagaimana yang dilakukan oleh penelitian terdahulu (Pratondo & Bramantoro, 2022). Dengan memanfaatkan *hyperparameter* tersebut penelitian ini diharapkan dapat memberikan hasil yang lebih baik.

1.2 Rumusan Masalah

Bagaimana membangun model deep learning arsitektur *Xception* yang baik menggunakan *hyperparameter* dalam mengklasifikasi Ulat jerman (*Zophobas morio*) dan Ulat hongkog (*Tenebrio molitor*).

1.3 Tujuan Penelitian

Tujuan penelitian ini adalah menyajikan *hyperparameter* terbaik dalam mengklasifikasi Ulat Jerman (*Zophobas morio*) dan Ulat hongkong (*Tenebrio molitor*). Untuk dapat dijadikan sebagai bahan pertimbangan dan referensi bagi masyarakat dalam membedakan kedua ulat tersebut.

1.4 Batasan Masalah

Adapun yang menjadi batasan masalah adalah sebagai berikut:

- a. Citra yang dipakai adalah foto berformat .jpg.
- b. Menggunakan *hyperparameter* : Optimizer, Epoch, dan batch size.
- c. Menggunakan dataset dua jenis ulat (Ulat jerman dan Ulat hongkong)
- d. Menggunakan Arsitektur Xception

1.5 Manfaat penelitian

Penelitian tentang klasifikasi *Zophobas morio* dan *Tenebrio molitor* dengan Arsitektur Xception diharapkan dapat bermanfaat secara teoritis maupun praktis

1. Secara teoritis
 - a. Untuk pengembangan ilmu pengetahuan, terutama bagi dunia teknik informatika.
 - b. Menemukan Parameter terbaik dalam implementasi arsitektur *Xception* untuk menklasifikasi ulat Jerman dan ulat Hongkong.
2. Secara Praktis
 - a. Bagi peneliti
 - 1) Memahami cara kerja Arsitektur *Xception* dan implementasinya
 - 2) Sebagai portofolio untuk peneliti yang akan berguna dimasa yang mendatang.
 - b. Bagi Universitas
 - 1) Sebagai bahan pembelajaran untuk penelitian mendatang

- 2) Sebagai bahan evaluasi pengetahuan yang berkaitan dengan *Deep Learning*.

1.6 Metodologi Penelitian

1. Studi Literatur

Pada studi literatur ini dilakukan cara mencari dan mengumpulkan data dari berbagai refensi yang menunjang dalam klasifikasi *Zophobas morio* (ulat jerman) dan *Tenebrio molitor* (ulat hongkong) menggunakan arsitektur *Xception*. Beberapa sumber berasal dari Jurnal. Hasil dari studi literatur yang di dapat akan digunakan sebagai refensi dalam penyusunan tugas akhir.

2. Pengumpulan data

Pengumpulan data yang dilakukan pada penelitian ini meliputi hal-hal yang berkaitan dengan ulat jerman dan ulat hongkong yang bersumber dari : <https://doi.org/10.6084/m9.figshare.16918873.v1>

3. Perancangan

Setelah data-data yang dibutuhkan cukup, maka dilakukan perancangan sistem dan analisa batasan-batasan masalah yang nantinya akan diolah dalam arsitektur *Xception* yang diimplementasikan dalam penelitian.

4. Implementasi

Pada tahap implementasi, tugas akhir menampilkan hasil penelitian dengan data sebenarnya yang digunakan pada klasifikasi ulat jerman dan ulat hongkong.

5. Output

Merupakan hasil dari klasifikasi zophobas morio (ulat jerman) dan tenebrio molitor (ulat hongkong) menggunakan arsitektur *Xception* dan diharapkan menghasilkan tingkat akurasi yang tinggi.



UNIVERSITAS MEDAN AREA

© Hak Cipta Di Lindungi Undang-Undang

7
Document Accepted 19/4/24

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

Access From (repository.uma.ac.id)19/4/24

BAB II

LANDASAN TEORI

2.1 Ulat Jerman

Ulat jerman dikenal dengan nama *King Mealworm* (*Zophobas Morio*, siklus hidup ulat jerman diawali dari telur yang diteteskan oleh kumbang jerman berwarna hitam. Ulat jerman merupakan bahan pakan popular yang banyak digunakan para penghobi untuk diberikan pada reptil burung kicau, dan unggas lainnya. Penggemar burung dan reptil di manca negara sering menyebutnya *Superworm*. Ukuran tubuhnya bisa mencapai 2 kali lipat lebih besar dari ulat hongkong, ulat jerman juga dianggap lebih aman ketimbang hongkong dan banyak digunakan penggemar burung di Indonesia (Santoso dkk., 2017).

Budidaya ulat Jerman semakin marak di Indonesia, meski jumlahnya masih kalah dibanding budidaya ulat hongkong. Awalnya bibit ulat jerman didatangkan dari Amerika tengah dan Amerika selatan. Sekarang tidak perlu impor lagi karena sudah banyak yang mengembang biakannya di Indonesia untuk pakan burung dan reptil sehingga ketika dijadikan pakan burung bisa membantunya untuk menangkal berbagai penyakit seperti virus, bakteri, jamur, maupun parasit semua ini makin menegaskan kalau ulat jerman lebih aman dan bermanfaat bagi burung kicauan (Rohman dkk., 2022). Menurut (Rumbos & Athanassiou, 2021) gizi yang terkandung dalam ulat jerman: bahan kering: 96,32% protein kasar : 49% ekstrak eter: 33,6% dan kitin : 45,9% selain dari kandungan gizi yang tinggi kandungan Khtin (zat bertanduk yang ada ditemukan diluar kerangka serangga/ulat) pada ulat jerman jauh lebih sedikit dari ulat hongkong.

2.2 Ulat Hongkong

Ulat hongkong (*Tenebrio molitor*) merupakan larva seperti cacing coklat dari kumbang *Tenebrionidae*. Mereka adalah tahap kedua dari empat tahap kehidupan dan hidup untuk makan dan tumbuh sampai mereka memiliki cukup energi untuk menjadi pupa dan kemudian jadi kumbang (Iding dkk., 2020).

Ulat hongkong (*Tenebrio molitor*) adalah larva dari kumbang beras yang memiliki nutrisi cukup tinggi, sepetibahan kering: 95,58%, protein kasar 47,0%, ekstrak eter: 29,6% dan kitin: 89,1% Selain nutrisi yang tinggi, ulat hongkong memiliki siklus hidup yang pendek dan mudah dalam memproduksinya. Penelitian (Purnamasari et al., 2019) menyebutkan bahwa penggunaan ulat hongkong dalam pakan sangat bagus untuk pakan burung dan ikan dan tidak menimbulkan dampak negatif.

Media pemeliharaan ulat hongkong (*Tenebrio molitor*) digunakan sebagai pakan, tempat bereproduksi mempengaruhi pertumbuhan ulat, peternak ulat hongkong umumnya memanfaatkan ampas tahu kering sebagai media pakan selama pemeliharaan (Hapsari dkk., 2018).

2.3 Deep Learning

Deep Learning merupakan cabang dari *Machine Learning* yang terinspirasi dari *kortex manusia* dengan menerapkan jaringan syaraf tiruan yang dibuat untuk terus belajar diberbagai level. *Deep Learning* memperluas *meachine learning* dengan menambah lebih banyak kedalaman (kompleksitas) kedalam model serta mengubah data menggunakan berbagai fungsi yang memungkinkan representasi data secara *hierarkis*.

Keuntungan yang kuat dari *deep learning* adalah pembelajaran fitur yaitu ekstraksi fitur otomatis dari data mentah, *deep learning* dapat memecah masalah yang lebih kompleks dengan sangat baik dan cepat karena model yang digunakan lebih komplek dan memungkinkan perealisasian besar-besaran (Kamilaris & Prenafeta-Boldú, 2018).

2.4 Convolutional Neural Network (CNN)

Convolution Neural Network merupakan salah satu metode yang ada dalam *deep learning*. Jaringan syaraf *convolution* mewakili kelas jaringan umpan maju yang dalam, yang dibangun dengan meniru pola penghubung *neuron dikorteks* visual manusia. Arsitektur CNN (*Convolutional neural network*) yang khas biasanya terdiri dari lapisan *Convolutional (Conv)*, lapisan aktivasi, lapisan *Pooling (POOL)*, dan lapisan yang sepenuhnya terhubung (Liu dkk., 2021).

Convolutional Neural Network (CNN) merupakan evolusi dari *Multilayer Perceptron* (MLP) yang ada pada neural network bertipe *feed forward* (tidak berulang). *Convolutional Neural Network* dirancang agar memproses informasi yang dirancang khusus untuk pengenalan dan klasifikasi gambar. CNN juga masuk kedalam golongan *Deep Neural Network* dikarenakan kedalaman layer yang besar juga sering diimplementasikan pada data citra (Ihsan, 2021).

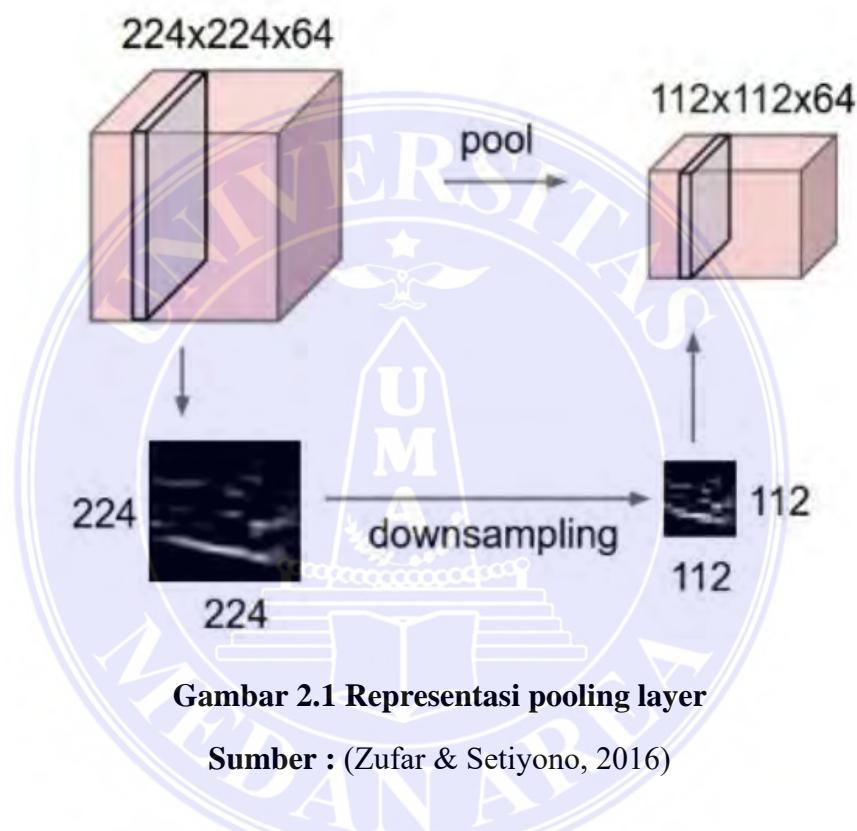
a. *Convolutional Layer*

Convolutional layer ialah lapisan pertama. Pada *Convolutional layer* terjadi proses operasi konvolusi dengan cara operasi kombinasi *linear* filter kepada wilayah lokal. Pada pemrosesan citra, konvolusi memiliki arti menerapkan satu kernel pada citra di semua *offset* yang membolehkan. Biasanya *library* yang

memakai CNN, tetapi tidak membalik kernel. contoh operasi konvolusi mengeluarkan hasil tunggal yaitu *feature map*.

b. Pooling Layer

Pooling layer akan mereduksi ukuran spasial dan jumlah parameter dalam jaringan serta mempercepat komputasi dan mengontrol terjadinya overfitting.



Gambar 2.1 Representasi pooling layer

Sumber : (Zufar & Setiyono, 2016)

Gambar 2.1. *Pooling layer* bekerja dengan blok spasial yang bergerak sepanjang ukuran feature pattern. Ukuran pergeseran blok pada umumnya adalah ukuran pada dimensi blok ($H \times H$) itu sendiri sehingga tidak ada *overlapping* seperti pada *Convolutional Layer*. Pergerakan blok diikuti dengan perhitungan *pooling* pada masukan pola fitur (u). Pada layer ini tidak memiliki parameter karena parameter sudah ditentukan sebelumnya (*fixed*). Lapisan *pooling* berfungsi untuk mereduksi dimensi spasial dari peta fitur yang dihasilkan oleh lapisan konvolusi. Biasanya,

max pooling digunakan, di mana nilai maksimum diambil dari setiap bagian dari peta fitur untuk mengurangi ukuran gambar secara bertahap. Ini membantu mengurangi jumlah parameter dan mempercepat proses pelatihan.

c. Lapisan *Fully-Connected*

Setelah melalui lapisan konvolusi dan pooling, hasilnya akan disampel dan kemudian disatukan dalam lapisan *fully-connected*. Lapisan *fully-connected* mirip dengan lapisan dalam jaringan saraf tiruan tradisional, di mana korelasi antara fitur-fitur yang diekstraksi ditemukan dan klasifikasi dilakukan.

Rumus Menentukan Konvolusi:

Max Pooling:

Klasifikasi:

keterangan :

Z adalah hasil konvolusi atau max pooling

I adalah gambar input

K adalah filter konvolusi

m dan n adalah indeks pada filter konvolusi

f adalah fungsi aktivasi (misalnya *ReLU* atau *Sigmoid*)

W adalah bobot lapisan *fully-connected*

x adalah vektor fitur hasil pooling

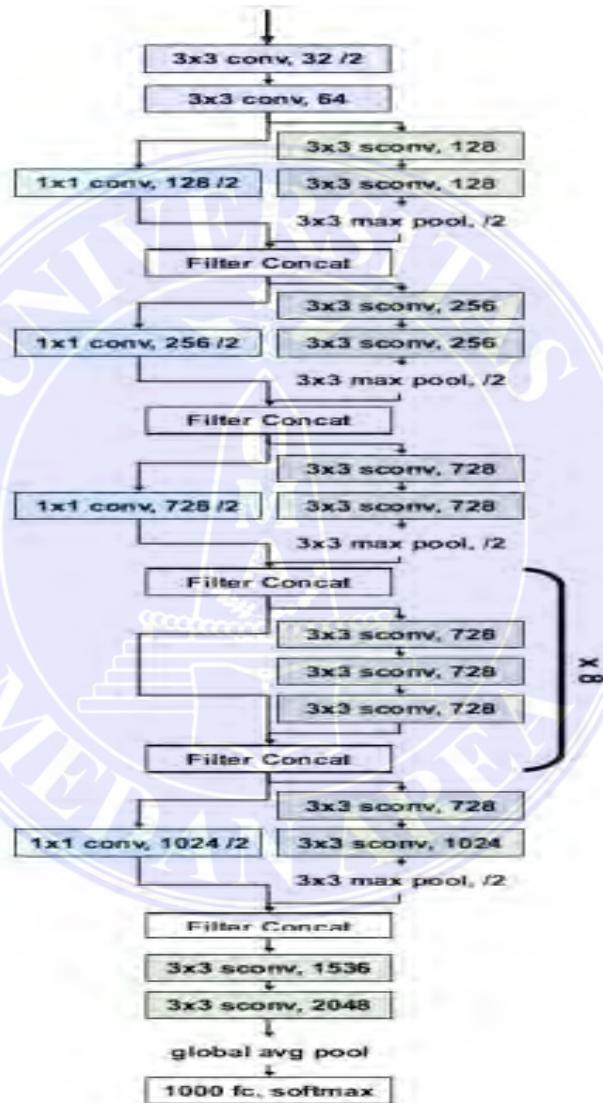
b adalah bias lapisan *fully-connected*

2.5 Xception

Arsitektur *Xception* merupakan singkatan dari *Extreme Inception*, *Xception* memiliki 36 lapisan konvolusi yang membentuk ekstraksi fitur jaringan. Dengan kata lain Arsitektur *Xception* adalah tumpukan linear lapisan konvolusi yang dapat

dipisahkan secara mendalam dengan koneksi residual, hal ini membuat arsitektur mudah untuk didefinisikan dan dimodifikasi(Darmasita, 2020).

Setelah blok *convolusional* pertama dijalankan, pemisahan setiap saluran secara spasial dengan cara menggunakan *convolusi* 1x1, nantinya keluaran tersebut disimpan untuk mendapatkan korelasi *cross-channel* (Leonardo dkk., 2019).



Gambar 2.2 Arsitektur Xception

Sumber : Leonardo et al., 2019)

2.6 Hyperparameter

Hyperparameter adalah konfigurasi dari luar model yang nilainya tidak dapat diestimasi/diperkirakan dari data dan membantu untuk memperkirakan model klasifikasi atau mengoptimalkan klasifikasi. *Hyperparameter* terdiri dari *hyperparameter* pengoptimal (terkait optimasi dan proses pelatihan) terdiri dari *Learning rate*, *mini batch size*, dan *number of epoch*, dan *Hyperparameter* khusus (parameter yang terkait dengan struktur model) yang terdiri dari *Number of hidden units* dan *firts layer* (Tsai dkk., 2020).

Hyperparameter penting untuk algoritma *Mechine Learning* sebagai kontrol perilaku algoritma pelatihan termasuk dalam deep learning dan memiliki pengaruh yang signifikan terhadap kinerja model arsitektur (J. Wu dkk., 2019). Berikut ini merupakan beberapa macam parameter yang sering digunakan pada banyak penelitian:

Tabel 2.1. Hyperparameter

No	Nama	Nilai
1	Optimizer	(Adam, SGD, RMSprop)
2	Epoch	(5, 10, 15, 20, 40, 50)
3	Batch Size	(8, 16, 32, 64, 128, 256)

2.6 Penelitian Terdahulu

Tabel 2.2. 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.

		<p>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 didapatkan bahwa akurasi dari 4 model diatas yaitu KNN sebesar 83%, SVM sebesar 92%, VGG-19 sebesar 94% dan Inception V3 sebesar 96%.</p>
2	<ul style="list-style-type: none"> -Anushree Ramanath -Saipreethi Muthunusriniswasan -Yiquin Xie -Sashi Shekar - Barathkumar Ramachandra 	<p>Pada penelitian ini (2019) tentang NDVI Versus CNN Feature in Deep Learning for Land Cover Clasification of Aerial Images dan menyajikan analisis metode untuk klasifikasi tutupan lahan dengan citra Satelit dengan fitur NDVI dan KNN dan menghasilkan 85.3% akurasi oleh KNN</p>
3	<ul style="list-style-type: none"> -Konstantinos P. Ferentinos 	<p>Pada penelitian ini (2015) tentang Deep Learning untuk deteksi dan diagnosis penyakit Tanaman. Pada penelitian ini menggunakan 25 tanaman berbeda yang sudah dibagi menjadi 2 kelas yaitu tanaman sehat dan berpenyakit, arsitektur yang digunakan CNN dan berhasil mencapai 90% tingkat akurasi.</p>

4	<ul style="list-style-type: none"> -Yulan Guo -Hanyun Wang -Qingyong Hu -Hao Liu - Muhammad Bennamoun 	<p>Pada penelitian ini (2019) penelitian berjudul Deep Learning for 3D Point Clouds: A Survey peran deep learning dalam penelitian ini memberikan hasil yang baik dalam memcahkan masalah dalam point coud dengan megklasifikasi bentuk dari 3D, mendeteksi, dan juga segmentasi dan memberikan hasil yang baik</p>
5	<ul style="list-style-type: none"> -Mohammad Abdul Ghani -Fathur Fahrizal -Armin Lawi 	<p>Penelitain tahun 2021 Implementasi arsitektur Xception untuk klasifikasi Citra Covid-19 Radiography padap penlitian ini menggunakan dataset Radiography dari Covid-19 dan dibagi menjadi 4 kelas data: Lung-Opacity, Normal, Covil, dan pneumonia. Klasifikasi yang dilakukan dengan training 70% data dan testing 30% data dengan menggunakan batch size 16 dan hasil pelatihan terbaik mencapai 92% tingkat akurasi dan validasi sebesar 91%.</p>

BAB III

METODOLOGI PENELITIAN

3.1 Alat dan Bahan Penelitian

Dalam penelitian ini, menggunakan peralatan dan bahan pendukung agar penelitian ini berjalan dengan lancar. Adapun perangkat keras dan perangkat lunak yang digunakan pada penelitian ini adalah sebagai berikut:

3.1.1 Perangkat Keras

Perangkat keras merupakan bagian fisik yang dari komputer yang tersusun dari komponen-komponen elektronika yang dirakit membentuk modul. Adapun spesifikasi perangkat keras yang digunakan dalam penelitian ini dapat dilihat pada tabel dibawah ini:

Tabel 3.1.1. Tabel Perangkat Keras

No	Perangkat Keras	Deskripsi
1	Device	Laptop Lenovo Yoga 500-15ISK
2	Processor	Intel(R) Core(TM) i5-6200U @2.30GHZ
3	HDD	1 TB
4	Ram	4.00 GB

3.1.2 Perangkat Lunak

Adapun perangkat lunak yang digunakan untuk menyelesaikan penelitian ini dapat dilihat pada tabel dibawah ini:

Tabel 3.1.2 Tabel Perangkat lunak

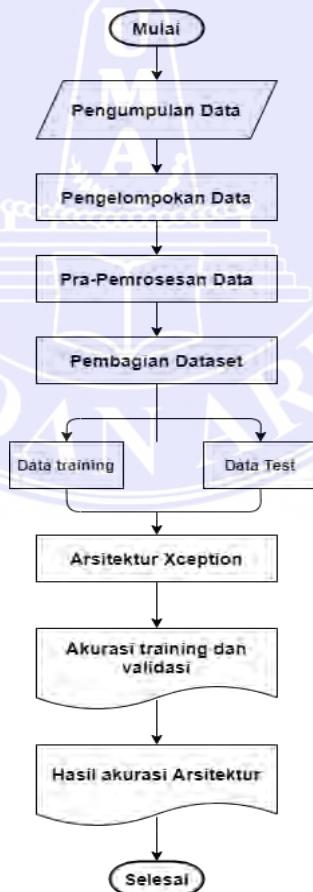
No	Perangkat Lunak	Deskripsi
1	Sistem Operasi	Windows 10 Pro 64 Bit
2	Google Colab	Tools
3	Python	Bahasa Pemrograman

4	TensorFlow	Library
---	------------	---------

Tabel 3.1.2 menyajikan sistem operasi yang gunakan yaitu *Windows 10 Professional* 64 bit, *Google Collab* merupakan platform yang berbasis awan untuk menjalankan kode *Python*, *Python* merupakan bahasa pemrograman yang digunakan dan *Tensorflow* merupakan *library machine learning* sumber terbuka yang dikembangkan oleh *Google*, banyak digunakan untuk melatih model *Deep Learning*.

3.2 Diagram Alur Penelitian

Diagram alur pada penelitian ini adalah dimulai dengan melakukan Pengumpulan data gambar untuk dijadikan *dataset*. Setelah semua telah terkumpul data di kelompokkan sesuai *class* masing-masing, diagram alur diilustrasikan pada gambar dibawah ini.



Gambar 3.1 Alur Penelitian

Data yang telah dikelompokkan 2 kelas Ulat Jerman dan Ulat Hongkong kemudian dilanjutkan dengan prapemrosesan dengan mengcompress ukuran gambar agar tidak terlalu besar setiap gambar memiliki ukuran 299x299 piksel, kemudian membagi *dataset* menjadi data *training* dan data *test*, dengan 80% jumlah data training dan 20% data *testing*. Setelah itu melakukan perancangan dengan arsitektur yang digunakan yaitu *Xception*. Tahap selanjutnya adalah *training* dan *testing* data hingga menghasilkan akurasi *training* dan validasi yang kemudian diketahui hasil akurasi arsitektur terkait.

3.3 Metode Pengumpulan Data

Dataset yang dikumpulkan adalah citra ulat yang dibagi menjadi dua yaitu: *Zophobas Morio* (Ulat Jerman) dan *Tenebrio molitor* (Ulat Hongkong). Sumber data : <https://doi.org/10.6084/m9.figshare.16918873.v1>



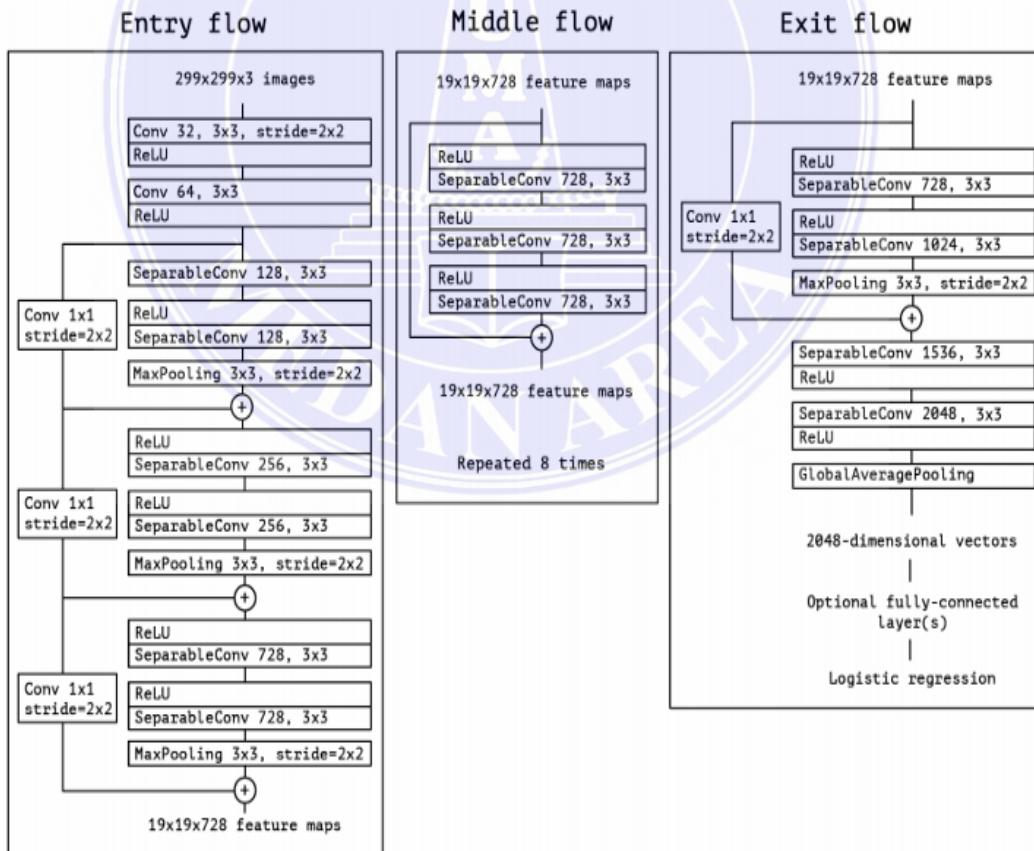
Zophobas morio (Ulat Jerman)

Tenebrio Molitor (Ulat Hongkong)

Gambar 3.2 Citra Ulat

3.4 Rancangan Arsitektur

Perancangan sistem penelitian ini menggunakan Arsitektur *Xception* untuk melakukan *training* dengan memakai model yang sudah dilatih terlebih dulu. Berikut adalah gambaran arsitektur dari *Xception*, dengan input citra Citra 299x299. Arsitektur *Xception* memiliki 36 tahap konvolusi, dengan input citra berukuran 299x299 yang kemudian di konvolusi dengan filter 3 x 3 stride 2 dimana inception modul diganti dengan konvolusi yang dapat dipisah secara mendalam. *Xception* menggiring hipotesis secara *Extreme* seperti korelasi lintas channel (*Cross Feature map*) dan dialihkan ke konvolusi 1 x 1 lalu melakukan konvolusi 3 x 3 untuk setiap *output* identik (Banumathi dkk., 2021).



Gambar 3.3 Arsitektur Xception

Sumber : (Chollet, 2017)

Pada Gambar 3.3 memiliki 3 bagian utama yaitu: aliran masuk, aliran tengah (looping 8 kali) dan aliran keluar. Aliran masuk memiliki dua blok lapisan. Dan beberapa filter (ukuran karnel). Dan demikian pada bagian tengah dan aliran keluar menunjukkan ukuran gambar, lapisan, filter, jenis penggabungan yang saling terhubung, setiap lapisan konvolusi dan *separable convolution* diikuti oleh *batch Normalization* (Chollet, 2017).

3.5 Pembagian Data

Penelitian ini menggunakan data berupa gambar yang atau citra dari ulat jerman dan ulat hongkong yang akan di bagi menjadi 80% data training dan 20% data testing, penentuan pembagian data berlandaskan penelitian-penelitian sebelumnya.

3.6 Data Training

Data training adalah proses *training* dataset dengan menggunakan arsitektur *Xception*. Proses ini membutuhkan inisialisasi parameter pelatihan. Paramater yang digunakan di inisialisasi untuk proses training ini adalah *Batch size, Epoch, dan Optimizer*.

3.7 Data Testing

Tahap data testing dimulai dengan memproses input citra yang akan diuji, Kemudian sistem akan mengidentifikasi model yang sudah dilatih sebelumnya. nantinya citra yang diuji akan diproses menggunakan arsitektur *Xception*. Setelah itu, sistem akan menampilkan akurasi dan validasi akurasi dari serta nilai *loss*.

3.8 Metode Evaluasi

Untuk mengevaluasi kinerja kuantitatif dari model ini, *confusion matrix* yang akan digunakan yaitu *Accuracy*, *Precision*, *Recall*, dan *F1 Score*. Untuk memahami metriks yang akan digunakan, sebelumnya akan didefinisikan terlebih dahulu bahwa TP, FP, FN dan TN seperti yang ditunjukkan pada *confusion matrix*

TP arti sebagai data positif yang diduga sebagai positif dan TN memiliki arti sebagai data negatif yang di diduga sebagai negatif. Sedangkan FN ialah lawan dari TP yaitu data positif yang diduga sebagai negatif dan FP, lawan dari TN, yaitu data negatif yang diduga positif. *confusion matrix* bisa kita lihat pada table berikut:

Tabel 3.3 Confusion Matrix

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

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

$$F1 Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \dots \dots \dots \quad (3.4)$$

Keterangan :

$TP = \text{true positive}$ $FN = \text{false negative}$

TP = true positive *FN* = false negative
FP = false positive *TN* = true negative

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil dari pengujian dari model arsitektur *Xception* dalam mengklasifikasi Ulat Jerman dan Ulat hongkong maka dapat disimpulkan bahwa:

- a. Kinerja dari model Arsitektur *Xception* dalam menklasifikasi Ulat Jerman dan Ulat Hongkong sudah sangat baik jika kombinasikan dengan parameter yang tepat.
- b. Terdapat 4 parameter yang menunjukkan akurasi yang tinggi mencapai 100% antara lain: *Epoch 5 Batch Size 8 Optimizer SGD*, *Epoch 10 Batch Size 8 Optimizer SGD*, *Epoch 15 Batch size 32 Adam*, dan *Epoch 15 Batch size 32 SGD*. Namun dengan pertimbangan waktu komputasi maka Parameter yang paling baik adalah konfigurasi dari *Epoch 5, Batch Size 8* dengan *Optimizer SGD* dengan waktu komputasi 27,9 menit.
- c. Tinggi nilai dari akurasi tidak menentukan model tersebut paling optimal dan waktu komputasi yang rendah juga tidak menentukan model tersebut paling optimal namun hasil paling optimal adalah pertimbangan rendahnya waktu komputasi dan tingginya nilai akurasi serta pertimbangan *presisi, recall* dan juga *F1-score*.

5.2 Saran

Berdasarkan penelitian yang telah dilakukan, terdapat hal yang dapat dijadikan saran yaitu:

- a. Ditinjau dari tinggi nilai akurasi yang dihasilkan oleh Model Exception maka penelitian selanjutnya diharapkan dapat dikembangkan dengan menambah jumlah data, dan juga ukuran *batch size* dan *Epoch* yang bervariasi atau lebih besar.
- b. Penelitian selanjutnya diharapkan dapat mengembangkan model arsitektur *Xception* dengan penerapan yang lebih mudah untuk digunakan masyarakat luas.



DAFTAR PUSTAKA

- Banumathi, J., Muthumari, A., Dhanasekaran, S., Rajasekaran, S., Pustokhina, I. V., Pustokhin, D. A., & Shankar, K. (2021). An Intelligent Deep Learning Based Xception Model for Hyperspectral Image Analysis and Classification. In *Computers, Materials and Continua* (Vol. 67, Nomor 2, hal. 2393–2407). <https://doi.org/10.32604/cmc.2021.015605>
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017* (Vol. 2017-Janua). Fchollet@google.com. <https://doi.org/10.1109/CVPR.2017.195>
- Darmasita. (2020). Deteksi Penggunaan Masker Menggunakan Xception Transfer Learning. In *JURNAL INSTEK (Informatika Sains dan Teknologi)* (Vol. 5, hal. 279–288).
- Dixit, P., & Silakari, s. (n.d.). *Deep Learning Algorithms for Cybersecurity Applications*. Elsevier.
- Esmail Karar, M., Abdel-Aty, A. H., Algarni, F., Fadzil Hassan, M., Abdou, M. A., & Reyad, O. (2022). Smart IoT-based system for detecting RPW larvae in date palms using mixed depthwise convolutional networks. *Alexandria Engineering Journal*, 61(7), 5309–5319. <https://doi.org/10.1016/j.aej.2021.10.050>
- Farag, H. H., Said, L. A. A., Rizk, M. R. M., & Ahmed, M. A. E. (2021). Hyperparameters optimization for ResNet and Xception in the purpose of diagnosing COVID-19. *Journal of Intelligent and Fuzzy Systems*, 41(2), 3555–3571. <https://doi.org/10.3233/JIFS-210925>
- Guo, Y., Wang, H., Hu, Q., Liu, H., Liu, L., & Bennamoun, M. (2021). Deep Learning for 3D Point Clouds: A Survey. In *IEEE Transactions on Pattern Analysis and Machine Intelligence* (Vol. 43, Nomor 12, hal. 4338–4364). <https://doi.org/10.1109/TPAMI.2020.3005434>
- Hapsari, D. G. P. L., Fuah, A. M., & Endrawati, Y. C. (2018). Produktifitas Ulat Hongkong (*Tenebrio molitor*) pada Media Pakan yang Berbeda. In *Jurnal Ilmu Produksi dan Teknologi Hasil Peternakan* (Vol. 6, Nomor 2, hal. 53–59). <https://doi.org/10.29244/jipthp.6.2.53-59>
- Iding, I., Bakrie, B., & Wahyuningrum, M. A. (2020). Pertambahan Bobot Badan Larva Ulat Hongkong (*Tenebrio Molitor L.*) dengan Penambahan Styrofoam Di Dalam Pakan. In *Jurnal Ilmiah Respati* (Vol. 11, Nomor 2, hal. 103–113). <https://doi.org/10.52643/jir.v11i2.1105>
- Ihsan, C. N. (2021). Klasifikasi Data Radar Menggunakan Algoritma Convolutional Neural Network (CNN). *DoubleClick: Journal of Computer and Information Technology*, 4(2), 115. <https://doi.org/10.25273/doubleclick.v4i2.8188>
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. In *Computers and Electronics in Agriculture* (Vol. 147, hal. 70–90). <https://doi.org/10.1016/j.compag.2018.02.016>
- Khamparia, Aditya and Singh, K. M. (2019). A Systematic Review On Deep Learning Architectures And Applications. *Expert Systems*, 36, e12400.
- Leonardo, M. M., Carvalho, T. J., Rezende, E., Zucchi, R., & Faria, F. A. (2019).

- Deep Feature-Based Classifiers for Fruit Fly Identification (Diptera: Tephritidae). In *Proceedings - 31st Conference on Graphics, Patterns and Images, SIBGRAPI 2018*. Tephritidae). IEEE. <https://doi.org/10.1109/SIBGRAPI.2018.00012>
- Liu, Y., Pu, H., & Sun, D. W. (2021). Efficient extraction of deep image features using convolutional neural network (CNN) for applications in detecting and analysing complex food matrices. *Trends in Food Science and Technology*, 113, 193–204. <https://doi.org/10.1016/j.tifs.2021.04.042>
- Lo, W. W., Yang, X., & Wang, Y. (2019). An xception convolutional neural network for malware classification with transfer learning. In *2019 10th IFIP International Conference on New Technologies, Mobility and Security, NTMS 2019 - Proceedings and Workshop* (hal. 1–5). <https://doi.org/10.1109/NTMS.2019.8763852>
- Maier, A., Syben, C., Lasser, T., & Riess, C. (2019). A gentle introduction to deep learning in medical image processing. *Zeitschrift fur Medizinische Physik*, 29(2), 86–101. <https://doi.org/10.1016/j.zemedi.2018.12.003>
- Majumder, A., Rajbongshi, A., Rahman, M. M., & Biswas, A. A. (2021). Local Freshwater Fish Recognition Using Different CNN Architectures with Transfer Learning. *International Journal on Advanced Science, Engineering and Information Technology*, 11(3), 1078–1083. <https://doi.org/10.18517/ijaseit.11.3.14134>
- Maulana, F. F., & Rochmawati, N. (n.d.). *Image Classification of fruits using Convolutioan Neural Network*. Jurnal of Informatics and Computer Science.
- Pradana, T. (2022). *Analisis perbandingan usaha budidaya ulat jerman dan ulat hongkong di kota medan skripsi* (hal. 1–40).
- Pratondo, A., & Bramantoro, A. (2022). Classification of Zophobas morio and Tenebrio molitor using transfer learning. In *PeerJ Computer Science* (Vol. 8). Peer J Computer Science. <https://doi.org/10.7717/PEERJ-CS.884>
- Purnamasari, D., Syamsuhaidi, E., Wirayawan, K., & Nurmaya. (n.d.). *Growth and Survival Rate Of Larvae Tenebrio Molitor Provided by Diffrent Feed Media*. Jurnal Peternakan Sriwijaya.
- Rahimzadeh, M., & Attar, A. (2020). A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2. In *Informatics in Medicine Unlocked* (Vol. 19, hal. 1–9). <https://doi.org/10.1016/j.imu.2020.100360>
- Ramanath, A., Muthusrinivasan, S., Xie, Y., Shekhar, S., & Ramachandra, B. (2019). Ndvi versus cnn features in deep learning for land cover classification of aerial images. In *International Geoscience and Remote Sensing Symposium (IGARSS)* (Vol. 2019-July, hal. 6483–6486). <https://doi.org/10.1109/IGARSS.2019.8900165>
- Rohman, F., Saefulhadjar, D., & Sinaga, S. (2022). Pengaruh Pemberian Media Nutrisi Yang Berbeda Terhadap Pertambahan Bobot Badan, Efisiensi Pakan Dan Daya Hidup Ulat Jerman (Zophobas morio). In *Jurnal Nutrisi Ternak Tropis dan Ilmu Pakan* (Vol. 4, Nomor 2, hal. 53). <https://doi.org/10.24198/jnttip.v4i2.40519>
- Rumbos, C. I., & Athanassiou, C. G. (2021). The superworm, zophobas morio (Coleoptera:Tenebrionidae): A ‘sleeping giant’ in nutrient sources. *Journal of*

UNIVERSITAS MEDAN AREA

- Insect Science*, 21(2), 1–11. <https://doi.org/10.1093/jis/esa/ieab014>
- Santoso, E. P., Afrila, A., & Fitiasari, E. (2017). Peningkatan Produksi Ulat Jerman Melalui Kombinasi Pemanfaatan Limbah Sayuran Pasar Pada Formulasi Media Pakan Yang Berbeda. In *Buana Sains* (Vol. 17, Nomor 1, hal. 33). <https://doi.org/10.33366/bs.v17i1.576>
- Soria, X., Riba, E., & Sappa, A. (2020). Dense extreme inception network: Towards a robust CNN model for edge detection. In *Proceedings - 2020 IEEE Winter Conference on Applications of Computer Vision, WACV 2020*. IEEE. <https://doi.org/10.1109/WACV45572.2020.9093290>
- Swapna, G., Vinayakumar, R., & Soman, K. P. (2018). Diabetes detection using deep learning algorithms. *ICT Express*, 4(4), 243–246. <https://doi.org/10.1016/j.icte.2018.10.005>
- Tsai, C. W., Hsia, C. H., Yang, S. J., Liu, S. J., & Fang, Z. Y. (2020). Optimizing hyperparameters of deep learning in predicting bus passengers based on simulated annealing. *Applied Soft Computing Journal*, 88, 1–9. <https://doi.org/10.1016/j.asoc.2020.106068>
- 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*, 17(1), 26–40. <https://doi.org/10.11989/JEST.1674-862X.80904120>
- Wu, X., Liu, R., Yang, H., & Chen, Z. (2020). An Xception Based Convolutional Neural Network for Scene Image Classification with Transfer Learning. *Proceedings - 2020 2nd International Conference on Information Technology and Computer Application, ITCA 2020*, 262–267. <https://doi.org/10.1109/ITCA52113.2020.00063>
- Zufar, M., & Setiyono, B. (2016). Convolutional Neural Networks Untuk Pengenalan Wajah Secara Real-Time. In *Jurnal Sains dan Seni ITS* (Vol. 5, Nomor 2). Sains dan Seni ITS.

LAMPIRAN

1. Sourcecode

```
from google.colab import drive
drive.mount('/content/drive')
Mounted at /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 Xception
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./299,
                                    shear_range = 0.2,
                                    zoom_range = 0.2,
                                    horizontal_flip = True)

test_datagen = ImageDataGenerator (rescale= 1./299)

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')

Found 1537 images belonging to 2 classes.
Found 469 images belonging to 2 classes.

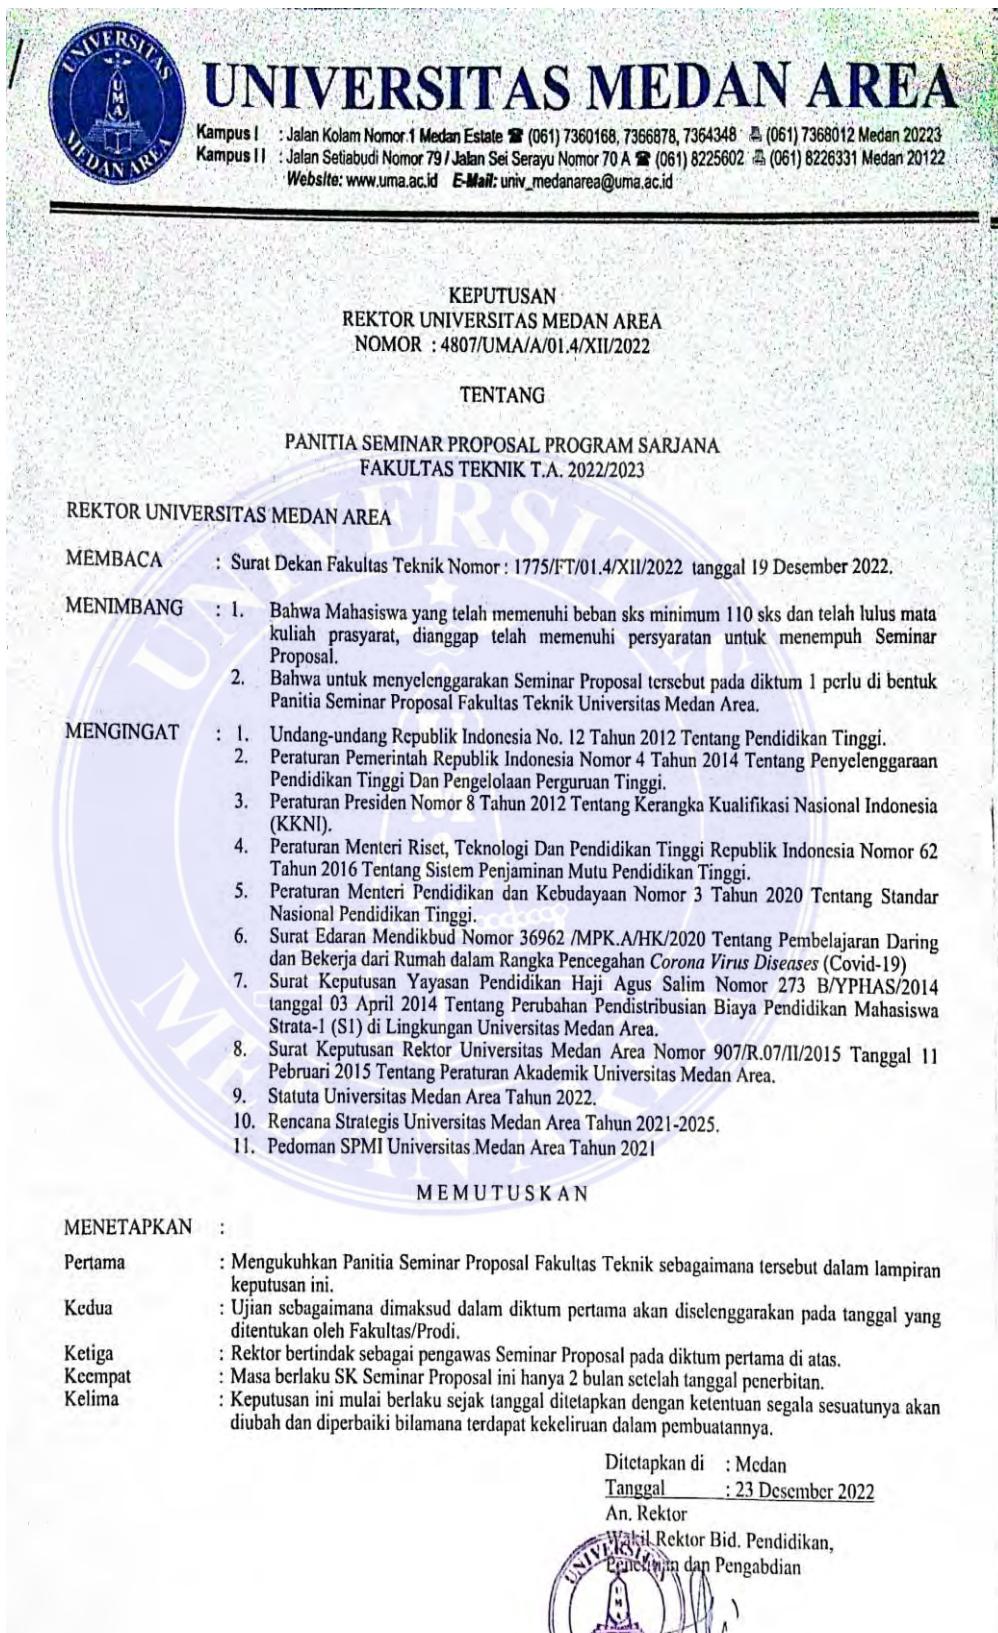
[ ] #Preparing Labels
UJ_labels = []
UH_labels = []

UJ_images=[]
UH_images=[]

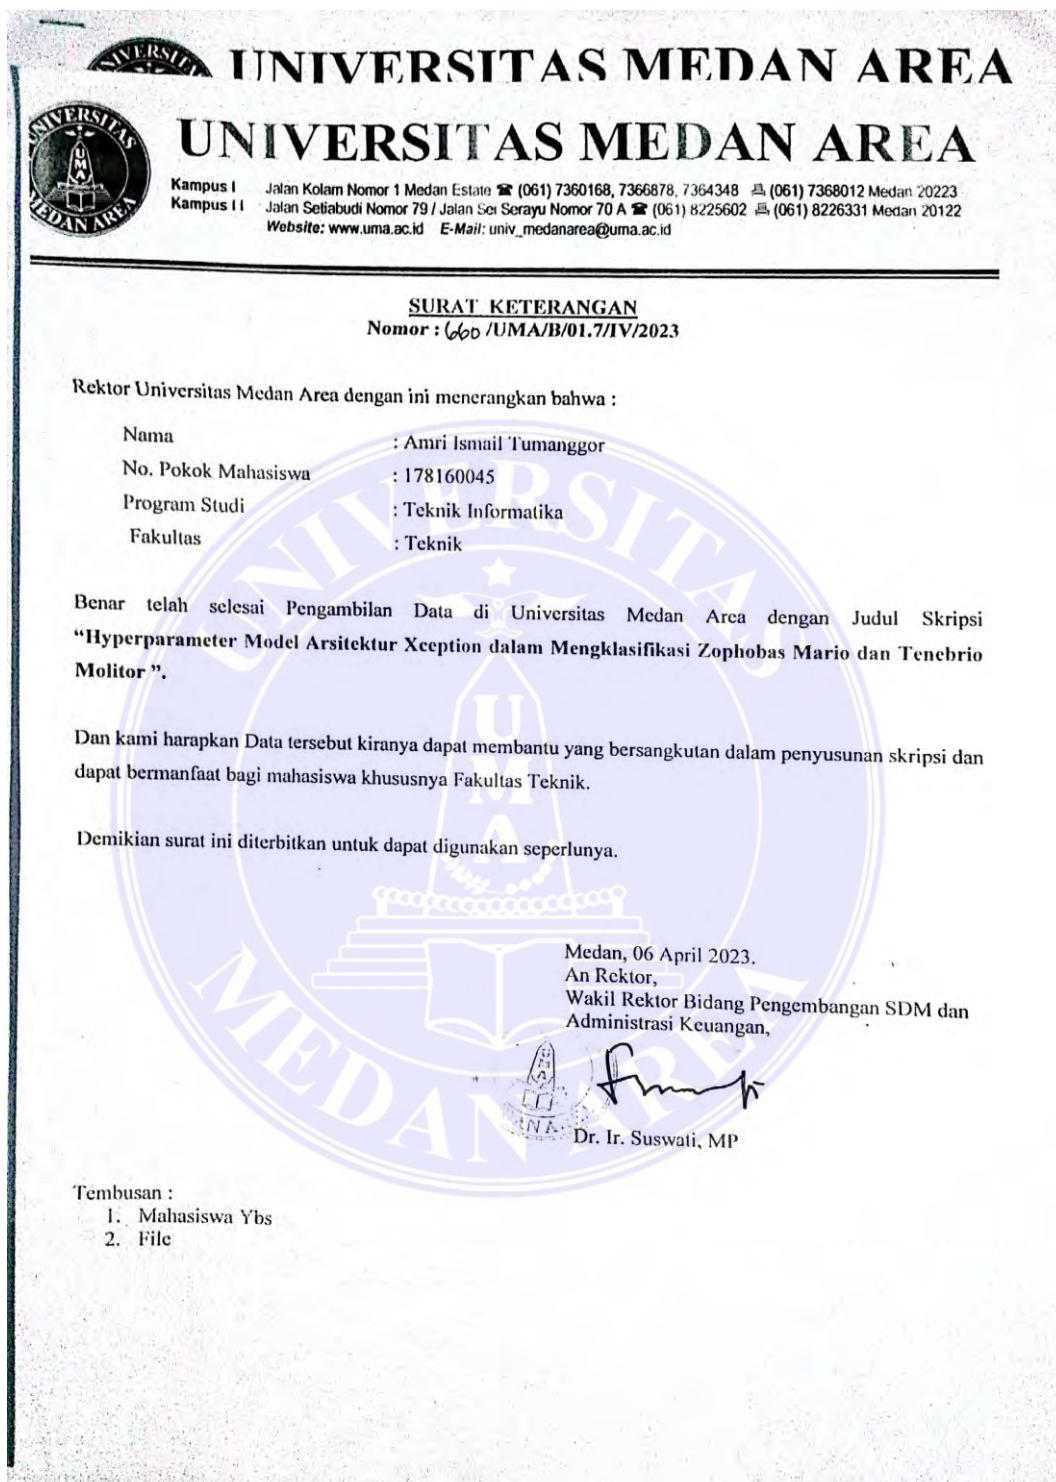
for i in range(len(UJ_files)):
    image = cv2.imread(UJ_files[i])
    image = cv2.cvtColor(image, cv2.COLOR_BGR2RGB)
    image = cv2.resize(image,(299, 299))
    UJ_images.append(image)
    UJ_labels.append('Ulat Jerman')
for i in range(len(UH_files)):
    image = cv2.imread(UH_files[i])
    image = cv2.cvtColor(image, cv2.COLOR_BGR2RGB)
    image = cv2.resize(image,(299, 299))
    UH_images.append(image)
    UH_labels.append('Ulat Hongkong')

[ ] #Normalisasi array
UJ_images = np.array(UJ_images) / 255
UH_images = np.array(UH_images) / 255
```

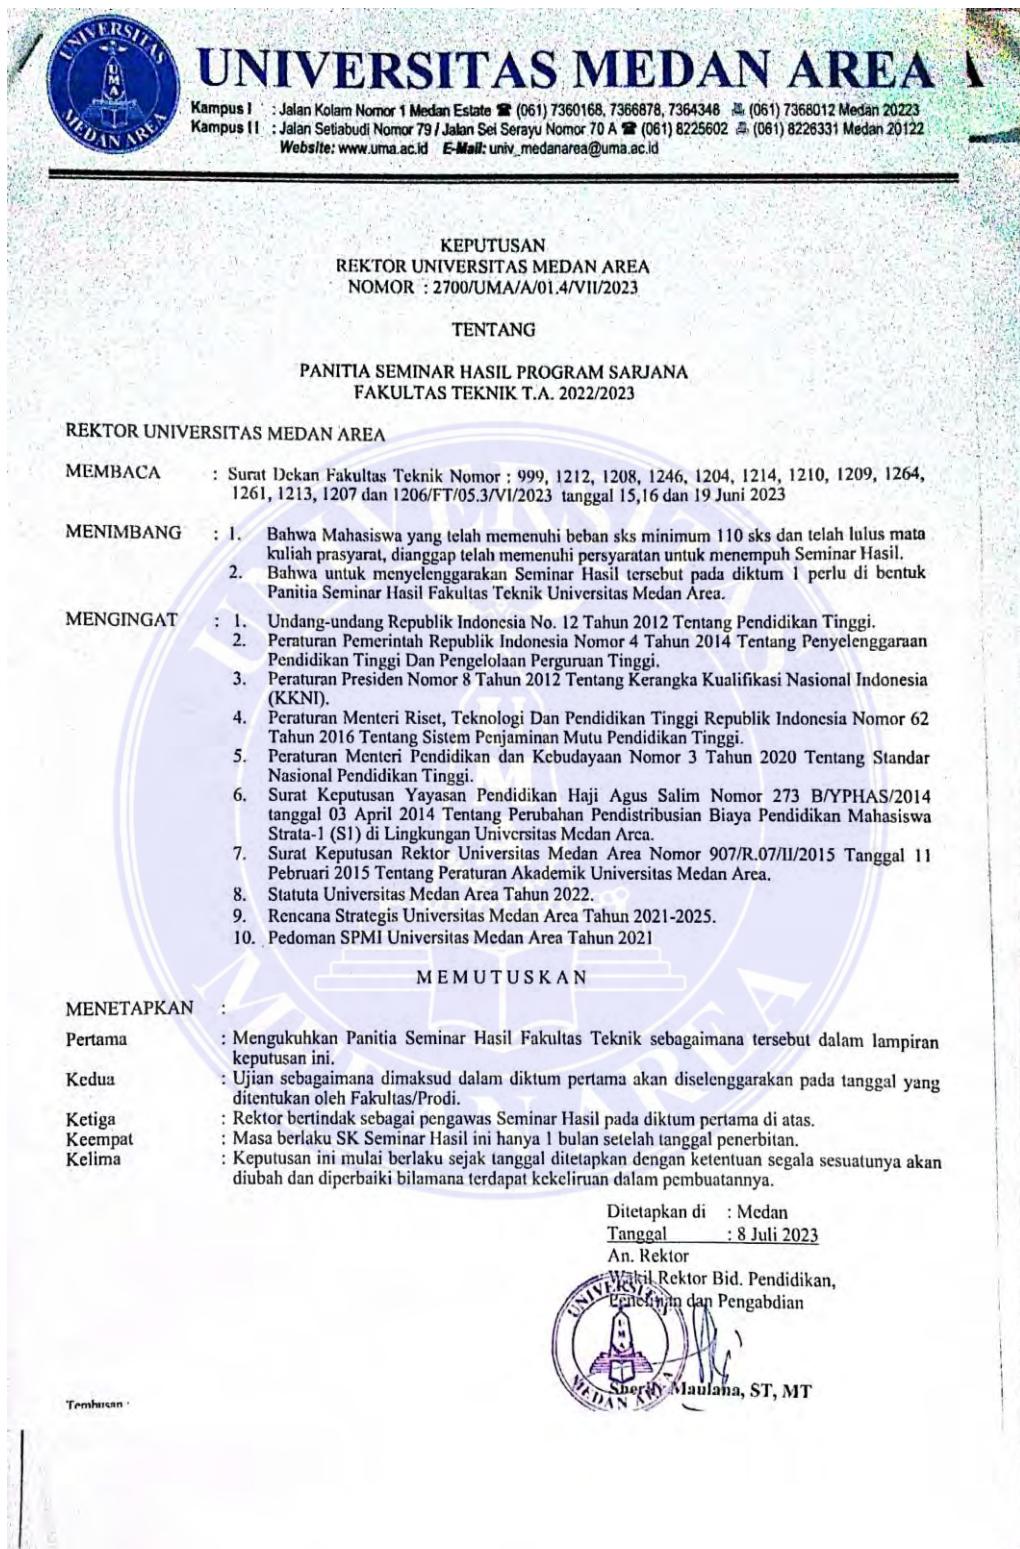
2. Sk Seminar Proposal



3. Surat Riset Data Tugas Akhir



4. Sk Seminar Hasil



5. Turnitin

 Similarity Report ID: oid:29477:54364212

PAPER NAME	AUTHOR
Amri Turnitin 1.docx	Amri Ismail Tumanggor
WORD COUNT	CHARACTER COUNT
5022 Words	30854 Characters
PAGE COUNT	FILE SIZE
38 Pages	1011.9KB
SUBMISSION DATE	REPORT DATE
Mar 13, 2024 11:45 AM GMT+7	Mar 13, 2024 11:46 AM GMT+7

● 22% Overall Similarity
The combined total of all matches, including overlapping sources, for each database.

- 21% Internet database
- Crossref database
- 7% Submitted Works database
- 4% Publications database
- Crossref Posted Content database

● Excluded from Similarity Report

- Small Matches (Less than 10 words)

