

TESIS

**PENGARUH AUGMENTASI DATA PADA DEEP LEARNING
DALAM DETEKSI OBJEK DRONE**



Disusun oleh:

Nama : Ariel Yonatan Alln
NIM : 21.51.2106
Konsentrasi : Intelligence Animation

**PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA**

2023

TESIS

**PENGARUH AUGMENTASI DATA PADA DEEP LEARNING
DALAM DETEKSI OBJEK DRONE**

***THE EFFECT OF DATA AUGMENTATION IN DEEP LEARNING
WITH DRONE OBJEK DETECTION***

Diajukan untuk memenuhi salah satu syarat memperoleh derajat Magister



Disusun oleh:

Nama : Ariel Yonatan Alin
NIM : 21.51.2106
Konsentrasi : Intelligence Animation

**PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA
2023**

HALAMAN PENGESAHAN

**PENGARUH AUGMENTASI DATA PADA DEEP LEARNING
DALAM DETEKSI OBJEK DRONE**

***THE EFFECT OF DATA AUGMENTATION IN DEEP LEARNING
WITH DRONE OBJEK DETECTION***

Dipersiapkan dan Disusun oleh

Ariel Yonatan Alln

21.51.2106

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Jumat, 1 Desember 2023

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer

Yogyakarta, 1 Desember 2023
Rektor

Prof. Dr. M. Suyanto, M.M.
NIK. 190302001

HALAMAN PERSETUJUAN
PENGARUH AUGMENTASI DATA PADA DEEP LEARNING
DALAM DETEKSI OBJEK DRONE

THE EFFECT OF DATA AUGMENTATION IN DEEP LEARNING
WITH DRONE OBJECT DETECTION

Dipersiapkan dan Disusun oleh

Ariel Yonatan Alln

21.51.2106

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Jumat, 1 Desember 2023

Pembimbing Utama

Anggota Tim Penguji

Prof. Dr. Kusriani, M.Kom.
NIK. 190302106

Tonny Hidayat, M.Kom., Ph.D
NIK. 190302182

Pembimbing Pendamping

Dhani Ariatmanto, M.Kom., Ph.D.
NIK. 190302197

Dr. Kumara Ari Yuana, S.T., M.T.
NIK. 190302575

Prof. Dr. Kusriani, M.Kom.
NIK. 190302106

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer

Yogyakarta, 1 Desember 2023
Direktur Program Pascasarjana

Prof. Dr. Kusriani, M.Kom.
NIK. 190302106

HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Ariel Yonatan Alin
NIM : 21.51.2106
Konsentrasi : Intelligence Animation

Menyatakan bahwa Tesis dengan judul berikut:
Pengaruh Augmentasi Data pada Deep Learning dalam Deteksi Objek Drone

Dosen Pembimbing Utama : Prof. Dr. Kusriani, M.Kom.
Dosen Pembimbing Pendamping : Dr. Kumara Ari Yuana, S.T., M.T.

1. Karya tulis ini adalah benar-benar ASLI dan BELUM PERNAH diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian SAYA sendiri, tanpa bantuan pihak lain kecuali arahan dari Tim Dosen Pembimbing
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas AMIKOM Yogyakarta
5. Pernyataan ini SAYA buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka SAYA bersedia menerima SANKSI AKADEMIK dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi

Yogyakarta, 1 Desember 2023

Yang Menyatakan,



METERAL TEMPEL
1304MKX77756267

Ariel Yonatan Alin

HALAMAN PERSEMBAHAN

Penulis telah menyelesaikan Tesisnya dalam menempuh studi Pascasarjana dan mempersembahkannya kepada:

1. Keluarga besar penulis terutama Ayah dan Ibu yang telah senantiasa memberikan dukungan finansial.
2. Orang-orang terdekat penulis yang telah mendukung dalam proses studi.
3. Segenap civitas akademika Universitas Amikom Yogyakarta, staff pengajar, karyawan, dan seluruh mahasiswa semoga tetap menjadi ujung tombak dalam bidang keilmuan, dan menjadi kebanggaan orang-orang terdidik di Indonesia.
4. Teman-teman penulis di Pascasarjana Universitas Amikom Yogyakarta yang telah berjuang bersama dalam menyelesaikan studi, dan telah banyak memberikan masukan, semangat, bantuan, hingga penulis dapat menyelesaikan Tesisnya.

HALAMAN MOTTO

"Humans are the outcome of blind evolutionary processes that operate without goal or purpose."

— **Yuval Noah Harari, Sapiens: A Brief History of Humankind**

"We are survival machines – robot vehicles blindly programmed to preserve the selfish molecules known as genes. This is a truth which still fills me with astonishment."

— **Richard Dawkins, The Selfish Gene**

"The nitrogen in our DNA, the calcium in our teeth, the iron in our blood, the carbon in our apple pies were made in the interiors of collapsing stars. We are made of starstuff."

— **Carl Sagan, Cosmos**

"The cosmos is within us. We are made of star-stuff. We are a way for the universe to know itself."

— **Carl Sagan**

"Those who are not shocked when they first come across quantum theory cannot possibly have understood it."

— **Niels Bohr, Essays 1932-1957 on Atomic Physics and Human Knowledge**

"Space-time tells matter how to move; matter tells space-time how to curve"

— **Albert Einstein, General Theory of Relativity**

KATA PENGANTAR

Penulis telah menyelesaikan Tesis yang berjudul "Pengaruh Augmentasi Data Pada Deep Learning dalam Deteksi Objek Drone". Tesis ini dibuat untuk memenuhi salah satu syarat dalam memperoleh gelar Magister Program Strata-2, Teknik Informatika, Universitas Amikom Yogyakarta.

Penyusunan Tesis ini tidak terlepas dari bantuan berbagai pihak, oleh karena itu pada kesempatan ini, penulis menyampaikan terima kasih kepada pihak-pihak tersebut diantaranya:

1. Bapak Prof. Dr. M. Suyanto, M.M., sebagai Rektor Universitas Amikom Yogyakarta.
2. Ibu Prof. Dr. Kusriani, M.Kom., sebagai dosen pembimbing utama yang telah mendampingi dalam penyusunan Tesis ini.
3. Bapak Dr. Kumara Ari Yuana, S.T., M.T., sebagai dosen pendamping yang memberi masukan-masukan dalam membimbing pengerjaan Tesis.
4. Orang tua, kakak, dan saudara yang telah memberikan dukungan finansial selama penulis menempuh program studi Strata-2.
5. Teman-teman MTI-2021 kelas A, terkhusus, Elfandry Bayunanda S.Kom., Maie Istighosah, S.Kom., Liana Trihardianingsih S.Kom., Mohammad Reza Pahlevi, S.Kom., Muhammad Ryandy Ghonim Asgar S.T., yang telah memberi dukungan dan semangat dalam penulis menyelesaikan Tesis.

Yogyakarta, 1 Desember 2023

Penulis

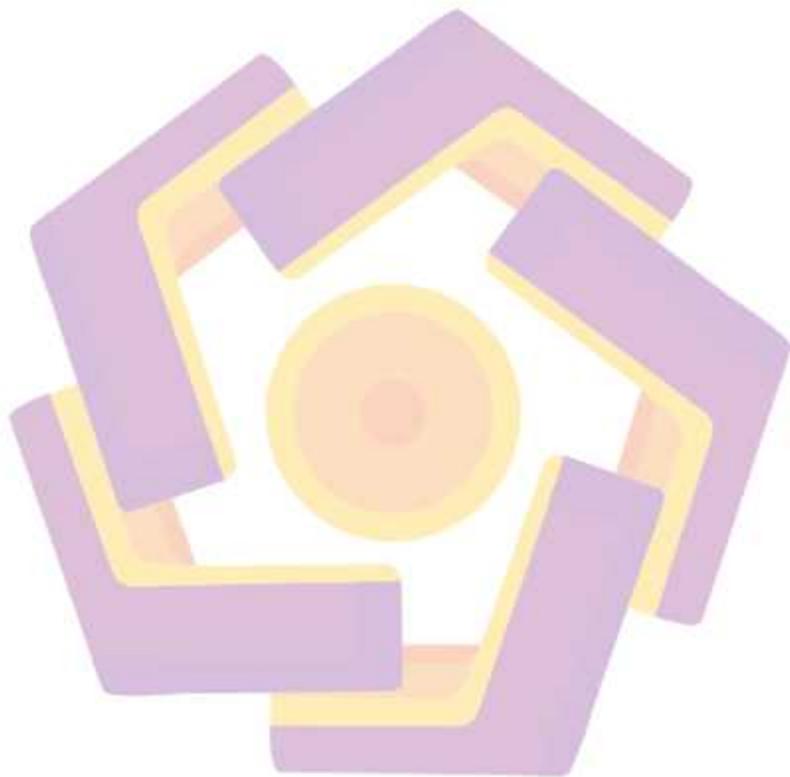
DAFTAR ISI

HALAMAN JUDUL.....	ii
HALAMAN PENGESAHAN.....	iii
HALAMAN PERSETUJUAN.....	iv
HALAMAN PERNYATAAN KEASLIAN TESIS.....	v
HALAMAN PERSEMBAHAN.....	vi
HALAMAN MOTTO.....	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	ix
DAFTAR TABEL.....	xi
DAFTAR GAMBAR.....	xii
INTISARI.....	xiii
ABSTRACT.....	xiv
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	6
1.3 Batasan Masalah.....	6
1.4 Tujuan Penelitian.....	7
1.5 Manfaat Penelitian.....	7
BAB II TINJAUAN PUSTAKA.....	9
2.1 Tinjauan Pustaka.....	9
2.2 Keaslian Penelitian.....	13
2.3 Landasan Teori.....	21
2.3.1 Drone.....	21
2.3.2 Roboflow.....	23

2.3.3	Google Colaboratory.....	24
2.3.4	Deep Learning.....	25
2.3.5	Convolutional Neural Network.....	26
2.3.6	Algoritma You Only Look Once (YOLO).....	26
2.3.7	Augmentasi Data.....	28
2.3.8	TensorFlow 2.0.....	31
BAB III METODE PENELITIAN.....		33
3.1	Jenis, Sifat, dan Pendekatan Penelitian.....	33
3.2	Metode Pengumpulan Data.....	34
3.3	Metode Analisis Data.....	35
3.4	Alur Penelitian.....	36
BAB IV HASIL PENELITIAN DAN PEMBAHASAN.....		41
4.1	Pengumpulan Data.....	41
4.2	Anotasi Data.....	42
4.3	Pembagian Data.....	43
4.4	Augmentasi Data.....	44
4.5	Skenario Pertama.....	45
4.6	Skenario Kedua.....	51
4.7	Implementasi YOLOv5.....	52
4.8	Evaluasi Model.....	59
4.9	Analisis dan Pembahasan.....	64
BAB V KESIMPULAN DAN SARAN.....		71
5.1	Kesimpulan.....	71
5.2	Saran.....	72
DAFTAR PUSTAKA.....		73

DAFTAR TABEL

Tabel 2.1 Perbandingan Matriks Review dan Posisi Penelitian.....	13
Tabel 4.1 Hasil Pengujian Skenario 1	64
Tabel 4.2 Hasil Pengujian Terhadap Augmentasi Data 2	66



DAFTAR GAMBAR

Gambar 2.1 Bentuk <i>Fixed-wing Drone</i>	22
Gambar 2.2 Bentuk <i>Rotary-wing Drone</i>	23
Gambar 2.3 Bentuk <i>Hybrid Drone</i>	23
Gambar 2.4 Ilustrasi Roboflow	24
Gambar 2.5 Hidden Layer pada Deep Learning	25
Gambar 2.6 Arsitektur Convolutional Neural Network	26
Gambar 2.7 Arsitektur YOLOv5	28
Gambar 2.9 Arsitektur TensorFlow 2.0	32
Gambar 3.1 Dataset Drone	35
Gambar 3.2 Anotasi Data	35
Gambar 3.3 Alur Penelitian	36
Gambar 4.1 Tampilan Dataset	42
Gambar 4.2 Anotasi Data	43
Gambar 4.3 Pembagian Train Set, Valid Set, Test Set	44
Gambar 4.4 Augmentasi data pada Roboflow	45
Gambar 4.5 Gabungan Augmentasi	47
Gambar 4.6 Tampilan Augmentasi Rotation dan Brightness	48
Gambar 4.7 Tampilan Augmentasi Rotation, Brightness dan Blur	50
Gambar 4.8 Tampilan Augmentasi Rotation, Brightness, Blur dan Noise	51
Gambar 4.9 Tampilan Tensorboard	56
Gambar 4.10 train_batch1	58
Gambar 4.11 val_batch2_pred	59
Gambar 4.12 Confusion Matrix Tanpa Augmentasi	60
Gambar 4.13 F1-Score Tanpa Augmentasi	61
Gambar 4.14 Precision-Convidence Curve	62
Gambar 4.15 Precision-Recall Curve	63
Gambar 4.16 Recall-Confidence Curve	64
Gambar 4.17 Perbandingan dengan penelitian sebelumnya	68

INTISARI

Deteksi objek drone merupakan salah satu penerapan utama dari teknologi pemrosesan gambar dan pengenalan pola menggunakan pembelajaran mendalam. Namun, terbatasnya data citra drone yang dapat diakses untuk melatih algoritma pendeteksian, menjadi tantangan tersendiri dalam pengembangan teknologi pendeteksian objek drone. Oleh karena itu, banyak penelitian yang telah dilakukan untuk meningkatkan jumlah data citra drone dengan menggunakan teknik augmentasi data. Penelitian ini bertujuan untuk mengevaluasi pengaruh augmentasi data terhadap akurasi pembelajaran mendalam pada deteksi objek drone dengan menggunakan algoritma YOLOv5.

Metode yang digunakan dalam penelitian ini meliputi pengumpulan data citra drone, augmentasi data dengan dua skenario, skenario yang pertama yakni menggabungkan beberapa augmentasi data untuk mengetahui penurunan nilai presisi. Skenario yang kedua mengambil 1/3 himpunan data yang dilakukan pelatihan, kemudian dilakukan augmentasi dengan generalisasi model sebanyak 3 kali dan membandingkannya dengan himpunan data asli tanpa diaugmentasi. Tipe augmentasi yang dilakukan dalam penelitian ini adalah rotasi, kecerahan, blur dan noise, masing - masing skenario menggunakan 100 epoch.

Hasil penelitian menunjukkan bahwa menggabungkan 4 tipe augmentasi menghasilkan nilai presisi 0.957. Selain itu jumlah augmentasi tidak memberikan dampak penurunan pada nilai presisi. Dengan mengambil 1/3 dataset yang di augmentasi, hasilnya belum mampu mendekati himpunan data asli yang tidak dilakukan augmentasi. Sehingga dalam penelitian ini, menggunakan jumlah himpunan data yang lebih banyak, memiliki keuntungan dalam hal keakuratan pendeteksian objek.

Kata Kunci: augmentasi data, deteksi objek drone, YOLOv5.

ABSTRACT

Drone object detection is one of the main applications of image processing and pattern recognition technology using deep learning. However, the limited drone image data that can be accessed for training detection algorithms is a challenge in developing drone object detection technology. Therefore, much research has been carried out to increase the amount of drone image data using data augmentation techniques. This research aims to evaluate the effect of data augmentation on the accuracy of deep learning in drone object detection using the YOLOv5 algorithm.

The method used in this research includes collecting drone image data, data augmentation with two scenarios, the first scenario is combining several data augmentations to determine the decrease in precision values. The second scenario takes 1/3 of the training data set, then augments it with a generalized model 3 times and compares it with the original data set without augmentation. The types of augmentation carried out in this research are rotation, brightness, blur and noise, each scenario uses 100 epochs.

The research results show that combining 4 types of augmentation produces a precision value of 0.957. Apart from that, the amount of augmentation does not have a decreasing impact on the precision value. By taking 1/3 of the dataset that was augmented, the results were not able to approach the original dataset that was not augmented. So in this research, using a larger number of data sets has advantages in terms of object detection accuracy.

Keywords: data augmentation, drone object detection, YOLOv5.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Pasar drone menyebar dengan cepat, penjualan unit akan tumbuh secara eksponensial dari 828.000 unit pada tahun 2021 menjadi hampir 1,4 juta unit pada tahun 2026. Akan banyak sektor yang memanfaatkan drone, mulai dari layanan kargo dan taksi hingga pertanian, bantuan bencana dan pemantauan infrastruktur penting (Kapustina et al., 2021).

Pasar drone yang tumbuh secara eksponensial membawa risiko yang lebih besar, drone dapat disalahgunakan untuk tujuan lain yang dapat membahayakan, seperti membawa bom, jual beli narkoba, dan memasuki kawasan terlarang. Menurut Kementerian Perhubungan Republik Indonesia, daerah terlarang untuk penerbangan drone antara lain: daerah yang seluruhnya diperuntukan bagi penerbangan pemerintah, atau penerbangan sipil, jarak 15 kilometer dari area landasan pacu pesawat, ketinggian diatas 150 meter, wilayah udara yang dikuasai dan wilayah udara kontrol lalu lintas udara (Volunteers, 2022)

Pada Januari 2015, sebuah drone yang diterbangkan oleh pejabat pemerintah yang mabuk jatuh tepat di depan halaman Gedung Putih (Bart Janen, 2015). Kecelakaan lain terjadi pada tahun 2017 di provinsi Quebec Kanada, di mana saat mendarat, sebuah pesawat bermesin ringan menabrak UAV di ketinggian 450m (Pham Sherisse, 2017). Pada bulan Desember 2018, Bandara Gatwick London ditutup selama 36 jam dengan laporan drone di atas landasan pacu, yang anehnya muncul setiap kali bandara mencoba untuk dibuka kembali (*Gatwick Flights*

Resume after Drone Sighting Caused More Disruption – as It Happened | Gatwick Airport | The Guardian, n.d.). Karena visibilitas deteksi yang rendah, drone dapat menjadi alat yang ideal untuk penyelundupan ilegal. Pada bulan April 2020, di negara bagian Georgia, tiga orang dituduh mengatur pengangkutan tembakau dan telepon melalui drone ke narapidana di Penjara Negara Bagian Hays di Trion (Walker, 2020). Untuk menjamin keamanan, beberapa perusahaan produsen drone telah menetapkan zona larangan terbang dengan melarang drone terbang dalam radius 25 km dari beberapa zona sensitif, seperti bandara, penjara, pembangkit listrik, dan fasilitas penting lainnya (Coluccia et al., 2021). Namun, dampak zona larangan terbang sangat dibatasi, dan tidak semua drone memiliki perlindungan bawaan tersebut. Oleh karena itu, untuk mengatasi masalah ini, pengembangan sistem anti-drone berkembang pesat, dan masalah pendeteksian drone secara real-time menjadi relevan (Wu et al., 2018).

Penting untuk mengontrol drone yang masuk ke area terlarang. Namun kendala yang dialami adalah sulitnya mendeteksi drone berukuran kecil. Drone yang berukuran kecil memancarkan gelombang elektromagnetik yang sangat kecil, sehingga sulit dideteksi oleh radar. Salah satu deteksi yang dapat digunakan adalah dengan menggunakan deteksi objek *deep learning* (Singha & Aydin, 2021).

Model *deep learning* memiliki kemampuan yang luar biasa dalam melakukan berbagai tugas dalam bidang *machine learning*. Beberapa tugas yang dapat dilakukan oleh model *deep learning* antara lain: deteksi objek, penerjemahan bahasa, pengenalan suara, analisis sentimen dan pengklasifikasian data (Shorten & Khoshgoftaar, 2019). Pada bidang deteksi objek, saat ini sedang berkembang pesat

dan mulai diterapkan di berbagai bidang, seperti: bidang industri otomotif, kesehatan, keamanan, e-commerce, manufaktur serta analisis citra. Pada bidang keamanan, deteksi objek menggunakan deep learning dapat bermanfaat untuk mengenali secara cepat dan mengurangi kesalahan akibat dari keterbatasan penglihatan manusia. Masalah yang dapat diminimalisir dengan menggunakan pendeteksian objek salah satunya adalah pendeteksian drone, sebab drone memiliki potensi untuk digunakan sebagai sarana kejahatan.

Deteksi objek adalah cabang penting di bidang *computer vision* dan *image processing*. Deteksi objek adalah proses mengidentifikasi kejadian dari jenis objek tertentu dalam gambar dan video. Algoritma deteksi objek dapat dibagi menjadi dua kategori, yang pertama adalah algoritma keluarga R-CNN (Region-Based Convolutional Neural Network) yang didasarkan pada proposal regional dan memiliki jaringan representatif seperti R-CNN, Fast R-CNN, Faster R-CNN, Mask R-CNN, dan lain-lain (Pan & Yan, 2020). Faster R-CNN merupakan versi peningkatan dari Fast RCNN, yang dibangun dari R-CNN. R-CNN menggunakan selective search (teknik proposal regional) untuk menghasilkan 2000 wilayah usulan. Teknik Fast R-CNN diketahui memiliki kemampuan 9 kali lebih cepat daripada R-CNN. Algoritma-algoritma tersebut dicirikan oleh penggunaan metode dua tahap (Alkentar et al., 2021).

R-CNN memiliki proses yang memakan waktu dalam mendeteksi objek pada gambar. Menggunakan algoritma pencarian selektif, RCNN menghasilkan sekitar 2000 region proposal per gambar, yang setiap wilayahnya kemudian dianalisis secara individual melalui CNN. Metode ini mengakibatkan proses yang

lambat, dengan kecepatan hanya sekitar 0,05 FPS, yang berarti memerlukan waktu hingga 20 detik untuk memproses satu gambar (Sanchez et al., 2020).

Sebaliknya, YOLO (You Only Look Once) memperkenalkan teknik yang lebih efisien. Dengan memproses keseluruhan gambar secara serentak menggunakan CNN, YOLO mampu memprediksi kotak pembatas dan klasifikasi dalam satu kali pandang, mempercepat proses deteksi. YOLO mencapai kecepatan signifikan hingga 45 FPS atau 22 milidetik per gambar. Meskipun dalam penerapannya YOLO mengorbankan sedikit akurasi dalam mean Average Precision (mAP) dibandingkan dengan RCNN, peningkatan kecepatannya yang signifikan membuatnya ideal untuk aplikasi deteksi objek real-time. Kecepatan ini memungkinkan YOLO untuk diterapkan dalam skenario di mana respons cepat diperlukan, menawarkan keseimbangan antara kecepatan dan akurasi yang sesuai untuk kebutuhan praktis (Sanchez et al., 2020).

Kategori berikutnya adalah algoritma satu tahap dan jaringan perwakilannya, seperti seri YOLO (You Only Look Once). YOLO adalah algoritma deep learning satu tahap yang menggunakan jaringan saraf konvolusional neural network untuk deteksi objek. YOLO terkenal karena kemampuan kecepatan dan akurasinya dalam mendeteksi objek. Karena YOLO mampu mendeteksi objek dalam sekali jalan, kemampuan ini membuat YOLO cocok digunakan untuk pendeteksian objek secara real-time. Penelitian yang dilakukan oleh Upesh Nepal dan Hossein Eslamiat menunjukkan bahwa kemampuan YOLOv5l mampu mengungguli YOLOv4 dan YOLOv3 dalam hal akurasi deteksi dan mampu mempertahankan kecepatan inferensi yang sedikit lebih lambat (Eslamiat, 2022).

Dari desain jaringan, perbedaan antara jaringan seri YOLO dan R-CNN adalah sebagai berikut: (1) pelatihan dan deteksi, ekstraksi fitur dan klasifikasi regresi YOLO, semuanya dilakukan dalam satu jaringan. Ini adalah jaringan end-to-end yang terpisah; (2) YOLO menganggap deteksi objek sebagai masalah regresi. Setelah gambar dimasukkan ke dalam jaringan, posisi semua objek dalam gambar, kategorinya, dan probabilitas kepercayaan yang sesuai dapat diperoleh. Hasil pendeteksian rangkaian RCNN dapat dibagi menjadi dua bagian yaitu kategori objek (klasifikasi), lokasi objek dan kotak pembatas (Meen et al., n.d.).

Pendeteksian drone menghadapi tantangan serius terkait dengan ketersediaan data pelatihan yang mencukupi. Dalam upaya untuk mengatasi masalah ini, peneliti telah mencoba menggunakan augmentasi data untuk memperbanyak dataset yang ada. Namun, disadari bahwa augmentasi data tidak selalu menghasilkan peningkatan akurasi. Dalam beberapa kasus, penggunaan augmentasi dapat menyebabkan penurunan akurasi deteksi. Oleh karena itu, penting untuk memahami sejauh mana augmentasi data memengaruhi kinerja model.

Salah satu solusi yang diusulkan pada penelitian ini adalah mengambil sebagian dari dataset dan mengaugmentasinya sebanyak tiga kali lipat untuk meningkatkan variasi dalam data. Hal tersebut bertujuan untuk mencari pengaruh dari augmentasi data, apakah dengan data yang lebih sedikit kemudian di-augmentasi, hasil deteksinya dapat menyamai data yang tidak di-augmentasi. Berdasarkan latar belakang yang dijabarkan di atas kontribusi penelitian ini dapat dirangkum sebagai berikut:

1. Melihat penurunan akurasi augmentasi pada 1 tipe augmentasi, gabungan 2 tipe augmentasi, gabungan 3 tipe augmentasi, dan gabungan 4 tipe augmentasi.
2. Mengetahui apakah dengan $1/3$ data yang di augmentasi dengan generalisasi model 3 kali lipat hasilnya dapat mendekati data asli yang tidak di augmentasi.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dipaparkan sebelumnya, maka masalah penelitian yang dirumuskan sebagai berikut:

1. Bagaimana pengaruh augmentasi yang dihasilkan dari penggabungan beberapa tipe augmentasi?
2. Apakah terjadi penurunan augmentasi yang signifikan apabila melakukan skenario dengan meng-augmentasi $1/3$ dataset, kemudian dilakukan generalisasi model sebanyak 3 kali, jika hasilnya dibandingkan dengan dataset asli tanpa augmentasi?

1.3 Batasan Masalah

Adapun batasan masalah yang digunakan dalam penelitian ini adalah sebagai berikut:

1. Dataset menggunakan data berupa gambar drone dengan menggunakan 1 kelas saja sehingga penelitian ini berfokus pada deteksi drone.
2. Dataset dapat berupa foto asli atau objek yang dibuat menggunakan komputer.
3. Pada setiap skenario yang dijalankan dengan menggunakan 100 Epoch.

4. Hasil penelitian yang dilakukan adalah perbandingan akurasi berdasarkan augmentasi yang dilakukan.
5. Tipe augmentasi yang digunakan pada penelitian ini adalah *Rotation*, *Brightness*, *Blur*, *Noise*.
6. Algoritma yang digunakan dalam penelitian ini menggunakan YOLOv5.
7. Platform yang digunakan dalam pendeteksian menggunakan Google Colab dan platform untuk melakukan augmentasi data menggunakan Roboflow.

1.4 Tujuan Penelitian

Berdasarkan rumusan masalah penelitian yang telah dijelaskan di atas, tujuan penelitian dan manfaat penelitian disusun sebagai berikut:

1. Mengetahui dampak apa yang ditimbulkan dari penggabungan beberapa tipe augmentasi dengan menggunakan algoritma YOLOv5.
2. Mengetahui apakah dengan dataset yang lebih sedikit kemudian di-augmentasi, hasil akurasi dapat mendekati dataset asli yang tidak di-augmentasi.

1.5 Manfaat Penelitian

Manfaat yang dapat diharapkan dari penelitian ini adalah sebagai berikut:

1. Model pendeteksian drone ini dapat disematkan ke dalam perangkat pengenalan gambar, untuk menggantikan deteksi drone secara manual.

2. Penelitian ini memberikan kontribusi ilmiah dalam mengetahui pengaruh gabungan augmentasi data terhadap deteksi objek drone.
3. Penelitian ini memberi kontribusi ilmiah dalam mengetahui apakah dataset yang lebih sedikit dapat dilakukan augmentasi agar mencapai titik deteksi yang sesuai atau perlu untuk mengumpulkan dataset lebih banyak agar tingkat deteksi lebih baik.



BAB II TINJAUAN PUSTAKA

2.1 Tinjauan Pustaka

Dalam penelitian ini penulis mencoba untuk mengumpulkan, mengevaluasi dan mensintesis informasi dari sumber-sumber tertulis atau pustaka yang relevan dengan topik penelitian yang akan dilakukan. Tujuan dari tinjauan pustaka ini untuk memahami apa yang telah diketahui dan dipelajari oleh orang lain tentang topik yang terkait. Berikut ini adalah beberapa hasil jurnal terdahulu yang telah berhasil penulis kumpulkan, yang memiliki kaitan dengan apa yang akan penulis teliti.

Berdasarkan penelitian sebelumnya deteksi *drone* merupakan topik penelitian yang telah dikembangkan oleh banyak peneliti-peneliti dari seluruh dunia. Dataset yang digunakan juga bervariasi dari yang berupa gambar hingga video. Penelitian yang dilakukan oleh Coluccia, dkk, yang berjudul "Deteksi Drone vs. Burung: Algoritma Pembelajaran Mendalam dan Hasil dari Tantangan Besar", tujuannya adalah untuk mendeteksi satu atau lebih drone yang muncul di beberapa titik waktu dalam rangkaian video di mana burung dan objek distraktor lainnya mungkin juga hadir, bersama dengan gerakan di latar belakang atau latar depan. Penelitian tersebut dilakukan oleh 3 tim yang masing masing menggunakan algoritma berbeda. Gradian Team menggunakan R-CNN dengan hasil AP 80%, Eagle Drone Team menggunakan Faster R-CNN dengan hasil AP 66,8%, Aleis Team menggunakan YOLOv3 dengan hasil AP 79,8%. Tantangan pada penelitian

ini adalah kemampuan pendeteksian objek sulit mengenali objek drone apabila ukuran drone kecil (Coluccia et al., 2021).

Penelitian yang dilakukan oleh Subroto Singha, dkk. Mendeteksi drone secara otomatis menggunakan YOLOv4, alasan menggunakan algoritma YOLOv4 karena memiliki kemampuan deteksi secara *real-time* dan tingkat presisi yang tinggi, jika dibandingkan dengan *Region-Based Convolutional Neural Network (R-CNN)* dan *Single-Shot Multi-box Detector (SSD)*. Meski proses pendeteksian yang cepat namun *mean average precision (mAP)* dari YOLOv4 masih di angka 74,36%. Saat penulis hendak melakukan penelitian ini, versi YOLO terbaru telah diluncurkan yakni YOLOv5, sehingga peneliti mencoba untuk melakukan penelitian pendeteksian *drone* menggunakan YOLOv5 serta melakukan berbagai proses augmentasi data untuk melihat performa perbandingan YOLOv5 terhadap setiap proses augmentasi (Singha & Aydin, 2021).

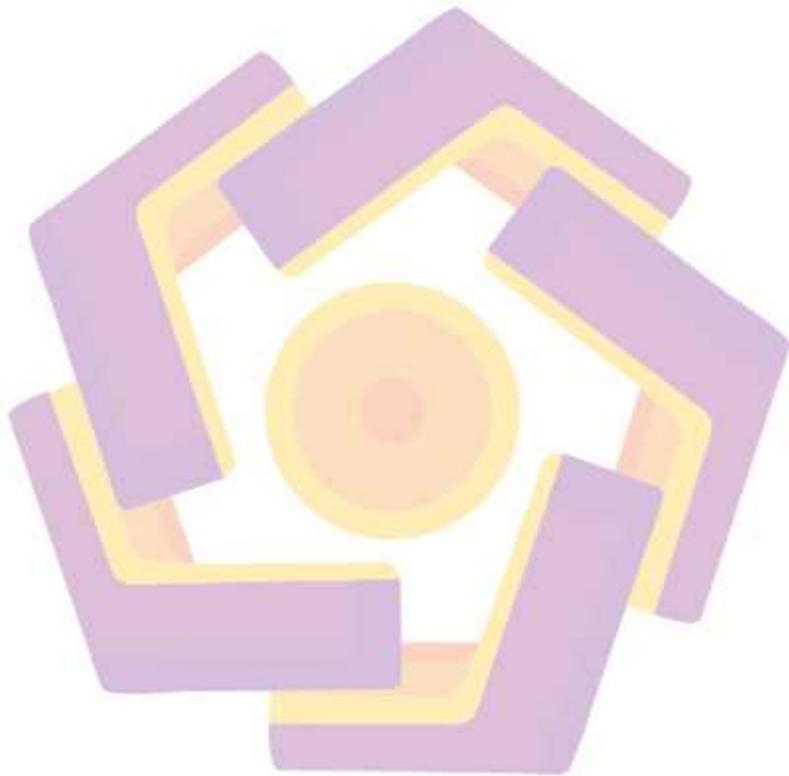
Penelitian yang dilakukan oleh Shorten, C., & Khoshgoftaar, yang berjudul "A survey on image data augmentation for deep learning" (Shorten & Khoshgoftaar, 2019). Penulis artikel ini mengidentifikasi bahwa masalah data yang tidak seimbang (*imbalanced data*) dan jumlah data pelatihan yang terbatas seringkali menjadi tantangan dalam pelatihan model *deep learning*. Oleh karena itu, teknik augmentasi data dapat membantu meningkatkan kualitas dan kuantitas data pelatihan, sehingga meningkatkan performa model. Artikel ini membahas tentang berbagai teknik augmentasi data yang dapat digunakan dalam *deep learning*, terutama untuk klasifikasi gambar. Penulis menyajikan berbagai teknik augmentasi

data, seperti *flip*, *rotation*, *brightness adjustment*, dan lain-lain, serta memberikan evaluasi performa dari masing-masing teknik.

Penelitian yang dilakukan oleh Bochkovskiy A, Wang C dan Liao H membahas mengenai YOLOv4 sebagai versi terbaru dari YOLO (*You Only Look Once*), sebuah model *deep learning* untuk deteksi objek pada gambar dan video. YOLOv4 menawarkan peningkatan dalam kecepatan dan akurasi dibandingkan dengan model sebelumnya, YOLOv3. Artikel ini memaparkan beberapa fitur dan inovasi dalam YOLOv4, selain itu artikel ini juga membahas berbagai teknik augmentasi data yang digunakan untuk meningkatkan kualitas dan kuantitas data pelatihan. Misalnya, teknik CutMix, di mana dua gambar yang berbeda digabungkan dengan memotong dan menggabungkan bagian-bagian gambar tersebut. Artikel ini juga membahas penggunaan teknologi *mosaic augmentation* dan teknologi MixUp augmentation untuk meningkatkan variasi data pelatihan dan mengurangi *overfitting*. Secara keseluruhan, artikel ini menunjukkan bahwa YOLOv4 memperlihatkan peningkatan signifikan dalam kecepatan dan akurasi deteksi objek dibandingkan dengan model sebelumnya, dan teknik augmentasi data dapat meningkatkan kualitas dan kuantitas data pelatihan untuk model *deep learning* (Bochkovskiy et al., 2020).

Berdasarkan penjelasan dari penelitian-penelitian yang telah dijelaskan sebelumnya, didapatkanlah kesimpulan bahwa untuk dapat meningkatkan kemampuan pendeteksian objek, perlu adanya sebuah metode yang dikembangkan, salah satunya adalah augmentasi data. Augmentasi data dapat meningkatkan jumlah data yang tersedia untuk pelatihan, sehingga model pembelajaran mesin dapat lebih

akurat dalam memprediksi hasil. Augmentasi juga dapat mengurangi resiko *overfitting* dengan memperkenalkan variasi dalam pelatihan dan dengan banyaknya variasi pelatihan yang dilakukan dapat menghasilkan data tambahan dengan biaya yang rendah.



2.2 Keaslian Penelitian

Tabel 2.1 Perbandingan Matriks Review dan Posisi Penelitian
PENGARUH AUGMENTASI DATA PADA DEEP LEARNING
DALAM DETEKSI OBJEK DRONE

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1	Augmentasi Data Pengenalan Citra Mobil Menggunakan Pendekatan Random Crop, Rotate dan Mixup	Joseph Sanjaya, Mewati Ayub	Mendapatkan cara untuk menerapkan augmentasi data terhadap arsitektur ResNet. Melakukan studi komparatif terhadap arsitektur ResNet dengan dan tanpa teknik augmentasi data yang diusulkan	Dari hasil percobaan yang dihasilkan, didapatkan kesimpulan bahwa dengan memanfaatkan augmentasi data random crop, rotation dan mixup, model CNN dengan arsitektur ResNet dapat bekerja dengan performa akurasi yang lebih baik. Augmentasi dengan Mixup meningkatkan akurasi tetapi meningkatkan loss.	Diharapkan dilakukan studi banding arsitektur ResNet dengan algoritma CNN yang lain untuk mendapatkan metrik akurasi, ukuran model, dan kecepatan terbaik dalam pengenalan model mobil	Persamaan pada penelitian tersebut sama-sama bertujuan untuk melakukan skenario terhadap Augmentasi Data. Perbedaannya pada algoritma yang digunakan dan objek yang di deteksi.

Tabel 2.1 (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
2	Random Erasing Data Augmentation	Zhun Zhong, Liang Zheng, Guoliang Kang Shaozi Li, Yi Yang The Thirty-Fourth AAAI Conference on Artificial Intelligence (AAAI-20) 2020	Dalam penelitian ini, peneliti memperkenalkan metode augmentasi data baru untuk melatih jaringan saraf convolutional (CNN). Dalam prosesnya tindakan tersebut melakukan penghapusan secara acak dengan memilih wilayah persegi panjang dalam gambar dan menghapus pikselnya dengan nilai acak.	Dalam makalah ini, peneliti mengusulkan pendekatan augmentasi data baru bernama "Penghapusan Acak" untuk melatih jaringan saraf convolutional (CNN). Mudah diimplementasikan: Penghapusan Acak secara acak menutup wilayah arbitrer dari gambar input selama setiap iterasi pelatihan. Eksperimen yang dilakukan pada CIFAR10, CIFAR100, Fashion-MNIST dan ImageNet dengan berbagai arsitektur memvalidasi keefektifan metode peneliti.	Pada penelitian ini peneliti telah menerapkan banyak metode "Penghapusan Acak" pada CNN. Saran pada penelitian berikutnya, diharapkan "Penghapusan Acak" dapat dilakukan pada model Deep Learning dan dilihat peningkatan performanya.	Persamaan pada penelitian tersebut peneliti mengguakan teknik yang sama yakni "Penghapusan Acak" pada proses Augmentasi. Perbedaannya peneliti tidak hanya menggunakan "Penghapusan Acak" tetapi juga berbagai metode Augmentasi lain.

Tabel 2.1 (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
3	Augmentation for small object detection	Cornell University 2019	Masih terdapat perbedaan hasil objek deteksi yang signifikan pada objek kecil dan besar. Penelitian ini bertujuan untuk melakukan <i>oversample</i> dengan gambar yang berukuran kecil dan menambah masing-masing gambar tersebut dengan menyalin dan menempelkan objek kecil berkali-kali.	Hasil penelitian ini menyimpulkan, salah satu faktor dibalik presisi rata-rata yang buruk untuk objek kecil adalah kurangnya representasi objek kecil dalam data pelatihan. Kemudian peneliti mengusulkan dua metode untuk menambah database MS COCO, yakni dengan <i>oversampling</i> dan algoritma augmentasi berdasarkan copy-paste objek kecil selama pelatihan.	Dari penelitian yang dilakukan, saat peneliti mengganti setiap gambar dengan objek kecil dengan salinannya yang berisi lebih banyak objek kecil, kinerjanya menurun drastis. Disarankan untuk penelitian berikutnya menggunakan teknik <i>oversampling</i> dan augmentasi saja yang lebih efektif.	Persamaan pada penelitian ini memiliki tujuan dan cara yang sama untuk meningkatkan kemampuan deteksi objek untuk mendeteksi objek yang berukuran kecil. Perbedaannya adalah pada objek yang diteliti serta beberapa metode yang digunakan, seperti <i>oversampling</i> dan <i>copy-pasting strategies</i> .

Tabel 2.1 (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
4	Albumentations: Fast and Flexible Image Augmentations	Alexander Buslaev, Vladimir I. Iglovikov, Eugene Khvedchenya, Alex Parinov, Mikhail Druzhinin and Alexandr A. Kalinin Information MDPI 2019	Penelitian ini menghasilkan open source baru dalam augmentasi data. Albumentations adalah opensource yang cepat dan fleksibel untuk augmentasi gambar dengan berbagai operasi transformasi gambar yang tersedia.	Albumentasi bertujuan untuk menyeimbangkan beberapa persyaratan, memberikan kinerja yang unggul pada berbagai transformasi, ditambah dengan API yang ringkas dan struktur yang dapat diperpanjang.	Diharapkan untuk penelitian berikutnya, proses augmentasi in dapat berjalan di GPU.	Pada penelitian ini memiliki kesamaan penelitian tentang proses Augmentasi gambar pada data yang digunakan. Perbedaannya pada penelitian ini membuat sebuah sistem yang mudah digunakan untuk melakukan Augmentasi data gambar yang digunakan, bernama Albumentations. Sedangkan yang akan peneliti lakukan adalah menguji Augmentasi data terhadap akurasi gambar.

Tabel 2.1 (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
5	Low-Light Image Enhancement via a Deep Hybrid Network	Wenqi Ren, Sifei Liu, Lin Ma, Qianqian Xu, Xiangyu Xu, Xiaochun Cao, Junping Du, and Ming-Hsuan Yang IEEE Transaction on Image Processing 2019	Dalam penelitian ini bertujuan untuk membuat jaringan hybrid yang dapat dilatih untuk dapat meningkatkan visibilitas gambar yang rendah dan gelap.	Hasil eksperimen menunjukkan bahwa jaringan yang diusulkan bekerja dengan baik terhadap algoritme peningkatan gambar cahaya rendah yang canggih.	Saran dari penelitian ini adalah mencoba untuk menguji algoritma dengan inputan gambar yang lebih gelap lagi dengan hasil yang baik.	Pada penelitian ini memiliki kesamaan yakni menggunakan algoritma untuk meningkatkan kualitas deteksi gambar. Proses yang membedakannya adalah penelitian ini menggunakan teknik mencerahkan gambar serta peneliti mencoba untuk augmentasi data berupa merotasi, memotong dan menutup sebagian gambar dengan warna hitam.

Tabel 2.1 (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
6	DA-ActNN-YOLOv5: Hybrid YOLO v5 Model with Data DA-ActNN-YOLOv5: Hybrid YOLO v5 Model with Data Augmentation and Activation of Compression Mechanism for Potato Disease Identification	Guowei Dai, Lin Hu, Jingchao Fan Hindawi Computational Intelligence and Neuroscience 2022	Peneliti melakukan peningkatan model YOLO v5 yang ditingkatkan dengan DA-ActNN- YOLOv5 dan digunakan untuk mempelajari penyakit kentang. Tiga belas teknik augmentasi data digunakan untuk memperluas data untuk meningkatkan generalisasi model dan mencegah overfitting	Hasil penelitian menunjukkan bahwa pada skenario beberapa faktor kompleks yang saling berinteraksi, akurasi identifikasi penyakit hawar kentang awal dan akhir pada penelitian ini mencapai 99,81%. Teknik augmentasi data yang telah diperkenalkan meningkatkan akurasi rata-rata sebesar 9,22%.	Saran untuk penelitian ini adalah, penelitian ini dapat diperluas untuk dapat mencakup beberapa deteksi penyakit pada daun individu dan penyempurnaan lokalisasi penyakit dan estimasi tingkat keparahan penyakit, pengembangan sistem pemantauan real-time berbasis IoT, pengembangan situs web dan rilis di aplikasi seluler.	Persamaan pada penelitian ini adalah menggunakan algoritma YOLO v5 dan objek khusus untuk dilakukan deteksi. Penggunaan augmentasi data juga dijelaskan dalam penelitian ini. Perbedaannya adalah objek deteksinya serta pada penelitian tersebut menggunakan DA-ActNN-YOLOv5, peneliti menggunakan base model dari YOLOv5.

Tabel 2.1 (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
7	Effect of data-augmentation on fine-tuned CNN model performance	Ramaprasad Poojary, Roma Raina, Amit Kumar Mondal IAES International Journal of Artificial Intelligence (IJ- AI) Vol. 10, No. 1, March 2021	Pada penelitian ini, melakukan metode augmentasi data untuk mengatasi kebutuhan data pelatihan dalam jumlah besar, untuk menghasilkan kinerja tinggi.	Hasil percobaan menunjukkan bahwa model VGG16 dan ResNet50 mencapai akurasi pengujian yang lebih baik saat augmentasi data digunakan, dan model yang dibangun menggunakan ResNet50 mengungguli model berbasis VGG16 dengan akurasi pengujian 90% dengan augmentasi data & 82% tanpa augmentasi data.	Pada penelitian ini kurang adanya variasi terhadap penelitian yang dilakukam, visualisasi data juga terkesan kurang baik, alur dan proses penelitian masih banyak yang tidak dijabarkan, seperti bagaimana proses augmentasinya, dan langkah augmentasinya.	Persamaan pada penelitian ini sama-sama mengujicoba augmentasi data terhadap performa algoritma deteksi objek. Perbedaannya terdapat pada algoritma yang digunakan, yakni pada penelitian ini menggunakan ResNet 50 dan VGG 16, sedangkan yang akan penulis lakukan menggunakan algoritma YOLOv5

Tabel 2.1 (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
8	Suppressing Model Overfitting for Image Super-Resolution Networks	Ruicheng Feng, Jinjin Gu, Yu Qiao, Chao Dong CVPR 2019 Long Beach California June 16-20, 2019	Peneliti memperkenalkan prinsip pembelajaran sederhana MixUp untuk mengatasi masalah overfitting pada super resolution.	Dengan menggabungkan komponen ini – MixUp dan data pelatihan sintetik, model besar dapat dilatih tanpa overfitting di bawah sampel data yang sangat terbatas dan mencapai performa generalisasi yang memuaskan.	Penelitian ini mencoba untuk melakukan augmentasi data menggunakan MixUp, namun tidak ditunjukkan bagaimana hasil dari augmentasi data yang umum seperti (random crop, rotation, and flipping) dibandingkan dengan MixUp.	Pada penelitian ini sama-sama mengatasi masalah overfitting dengan data augmentation. Perbedaannya pada penelitian ini tidak menggunakan teknik augmentasi data yang digunakan secara umum seperti (random crop, rotation, and flipping) melainkan menggunakan MixUp. Peneliti mencoba untuk melakukan penelitian dengan augmentasi data yang umum digunakan.

2.3 Landasan Teori

2.3.1 Drone

Drone awalnya merupakan istilah resmi yang digunakan Angkatan Darat Amerika Serikat, *drone* didefinisikan sebagai "kendaraan darat, laut, atau udara yang dikendalikan dari jarak jauh atau otomatis" (Chamayou, n.d.). Drone tidak hanya terdiri dari objek terbang, melainkan dalam kategori drone juga ada drone terestrial, drone laut, drone kapal selam dan sebagainya. Asalkan tidak ada lagi awak manusia didalamnya, segala jenis kendaraan atau mesin yang dapat dikendalikan, dapat disebut drone. Drone juga memiliki nama lain, yakni *Unmanned Aerial Vehicles* (UAV) atau *Unmanned Combat Air Vehicles* (UCAV) perbedaan istilah tersebut bergantung pada apakah alat itu membawa senjata atau tidak. *Drone* dapat dikendalikan dengan baik dari jarak yang jauh, oleh operator manusia (*remote control*) atau secara mandiri dengan menggunakan robot (*auto pilot*). Dalam praktiknya *drone* masa kini dapat menggabungkan dua mode kontrol tersebut.

Drone memiliki bentuk yang sangat variatif, terdapat beberapa kategori *drone* yang dapat dibagi menjadi beberapa jenis. Salah satu perbedaan yang dapat dilihat adalah dari bentuk baling-balingnya. Menurut baling-balingnya *drone* dapat dibedakan menjadi 3 jenis, diantaranya adalah sebagai berikut:

a. *Fixed-wing Drone*

Fixed-wing drone adalah jenis *drone* yang model sayapnya tidak berputar. *Drone* jenis ini berbentuk seperti pesawat komersial dan digunakan untuk terbang dengan kecepatan tinggi dan memiliki daya jangkauan lebih luas. Pada umumnya

drone jenis ini digunakan untuk keperluan pemetaan (*mapping*) atau keperluan *area scanning*. *Drone* jenis ini pada umumnya memiliki baterai yang lebih hemat karena memanfaatkan aliran udara, sehingga membutuhkan energi yang lebih sedikit. Kekurangan yang dimiliki oleh *drone* jenis ini yaitu tidak dapat bergerak secara bebas dan hanya dapat bergerak maju dan keatas atau kebawah. Ilustrasi *fixed-wing drone* dapat di lihat di Gambar 2.1.



Gambar 2.1 Bentuk *Fixed-wing Drone*

b. *Rotary-wing Drone*

Rotary-wing drone merupakan *drone* yang memiliki sayap yang dapat berputar, seperti helikopter, kelebihan dari *drone* bentuk ini adalah memiliki kemampuan terbang vertikal, sehingga dapat melakukan lepas landas dan pendaratan secara instan serta memiliki kemampuan untuk melayang (*hover*), *drone* jenis ini cocok digunakan dalam ruang sempit dan banyak rintangan, misalnya pekerjaan inspeksi seperti pemantauan mesin dan pabrik industri. Namun *rotary-wing drone* memiliki kekurangan pada daya tahan terbang mereka dibandingkan dengan *fixed-wing drone* serta, memiliki jarak terbang yang pendek dan kecepatan terbang yang rendah. Ilustrasi *rotary-wing drone* dapat di lihat di Gambar 2.2.



Gambar 2.2 Bentuk *Rotary-wing Drone*

c. *Hybrid Drone*

Hybrid drone merupakan gabungan antara *fixed-wing drone* dengan *rotary-wing drone*. Drone jenis ini memiliki keunggulan dari kedua jenis drone tersebut, yakni cepat dan stabil, memiliki daya tahan penerbangan yang lama dan memungkinkan lepas landas dan mendarat secara vertical (Sonkar et al., 2023). *Hybrid drone* tidak didesain untuk melayang. Ilustrasi *hybird drone* dapat dilihat di Gambar 2.3.



Gambar 2.3 Bentuk *Hybrid Drone*

2.3.2 Roboflow

Roboflow adalah platform berbasis web yang menyediakan berbagai fungsi terkait dataset. Platform ini dirancang untuk memfasilitasi pekerjaan dalam bidang

computer vision, khususnya yang berkaitan dengan *deep learning*, dengan menyederhanakan tugas-tugas terkait (Ciaglia et al., 2022). Kemampuan dari Roboflow adalah dapat memberikan anotasi pada dataset, *preprocessing* dataset, menggabungkan proyek atau dataset, mengecek kondisi dataset, mengekspor dataset dan melatih model (Theophilus, 2021). Ilustrasi Roboflow dapat dilihat di Gambar 2.4.



Gambar 2.4 Ilustrasi Roboflow

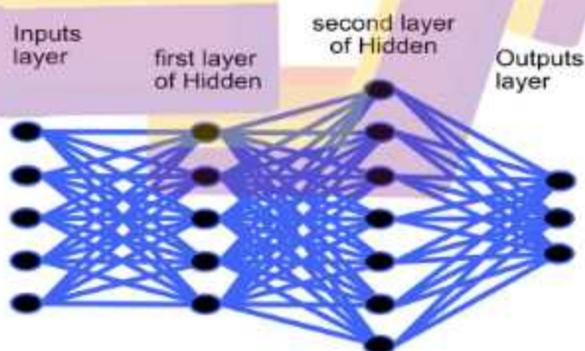
2.3.3 Google Colaboratory

Colaboratory, atau singkatnya “Colab”, adalah produk dari Google Research. Colab memungkinkan siapa saja untuk menulis dan mengeksekusi kode python arbitrer melalui *browser*, dan sangat cocok untuk *machine learning*, analisis data, dan pendidikan. Secara lebih teknis, Colab adalah layanan notebook Jupiter yang *dihosting* yang tidak memerlukan penyiapan untuk digunakan, sekaligus memberikan akses gratis ke sumber daya komputasi termasuk GPU (Google, n.d.).

2.3.4 Deep Learning

Deep learning merupakan salah satu cabang dari *Machine Learning* yang terdiri dari algoritma pemodelan abstraksi tingkat tinggi pada data yang menggunakan kumpulan-kumpulan fungsi transformasi non-linear yang ditata berlapis-lapis dan mendalam (A. Zhang et al., n.d.). *Deep learning* sangat cocok diterapkan dalam *supervised learning*, *unsupervised learning* dan *semi-supervised learning* maupun untuk *reinforcement learning* (Géron, n.d.) dalam berbagai aplikasi seperti pengenalan citra, suara, klasifikasi teks, dan sebagainya.

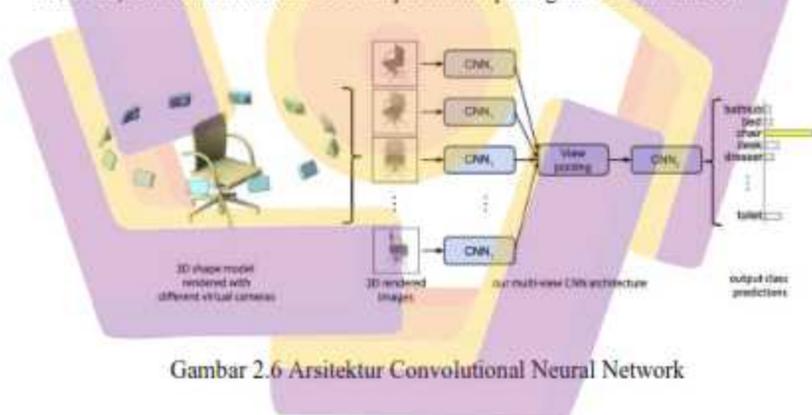
Model dalam *deep learning* pada dasarnya dibangun berdasarkan jaringan saraf tiruan atau *Neural Network*, riset ini sudah ada sejak tahun 80an, namun kini peningkatannya lebih *advance*, hal ini disebabkan dari perkembangan komputer modern yang semakin cepat (Alzubaidi et al., 2021). Jaringan saraf tiruan yang memiliki lebih dari 3 layer termasuk kedalam Deep Network. Ilustrasi hidden layer yang terdapat pada deep learning dapat dilihat pada Gambar 2.5 berikut.



Gambar 2.5 Hidden Layer pada Deep Learning

2.3.5 Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan jaringan saraf tiruan yang dapat divisualisasikan sebagai kumpulan neuron yang tersusun sebagai graf tanpa adanya loop di dalamnya. Ciri khas dalam CNN adalah adanya lapisan tersembunyi yang terhubung ke subset neuron di lapisan sebelumnya, karena konektivitas tersebut CNN dapat mempelajari fitur secara implisit (Wang et al., 2019). CNN memiliki empat lapisan, lapisan pertama difokuskan pada identifikasi tepian atau fluktuasi warna, kemudian lapisan kedua mengarah ke identifikasi bentuk, lapisan ketiga diarahkan untuk mempelajari bagian-bagian parsialisasi dari objek dan lapisan keempat digunakan untuk mengidentifikasi objek (Yamashita et al., 2018). Ilustrasi arsitektur CNN dapat dilihat pada gambar Gambar 2.6.



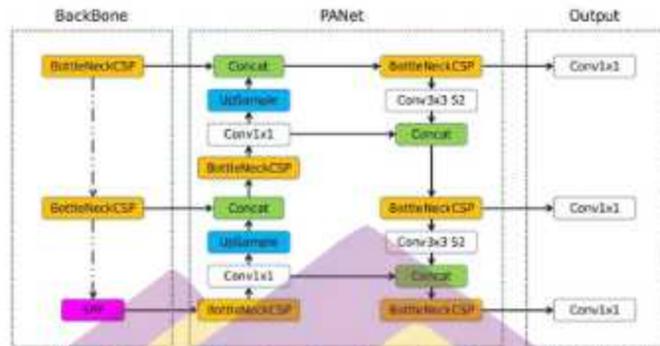
Gambar 2.6 Arsitektur Convolutional Neural Network

2.3.6 Algoritma You Only Look Once (YOLO)

Pendekatan baru untuk deteksi objek disebut You Only Look Once (YOLO) yang berarti bahwa sebuah gambar dapat diprediksi objek apa dan di mana mereka berada dalam satu pandangan. Sebagai metode pertama yang sepenuhnya

membuang jalur pipa, YOLO meringkai deteksi objek sebagai masalah regresi ke bounding boxes yang terpisah secara spasial dan probabilitas kelas terkait, yang diprediksi dengan jaringan saraf tunggal dari gambar penuh dalam satu evaluasi (Jiang et al., 2021). Selain itu, YOLO memilih GoogLeNet tetapi bukan VGG-16 sebagai jaringan dasar, karena kecepatan penghitungan transportasi penerusan versus presisi jauh lebih cepat daripada VGG. Jadi, YOLO dirancang dengan cepat dan real-time dengan tetap menjaga akurasi yang baik. Proses perkembangan YOLO dimulai dari YOLOv1, hingga penelitian ini dibuat YOLO telah mencapai YOLOv5.

You Only Look Once (YOLO) merupakan algoritma yang dikembangkan untuk pendeteksian objek secara real-time. YOLO menggunakan sistem pendeteksian dengan *repurpose classifier* atau *localizer* untuk melakukan deteksi. Sebuah model diterapkan pada sebuah citra di beberapa lokasi dan skala, daerah yang diberi score paling tinggi akan dianggap sebagai sebuah pendeteksian (Unsky, 2017). YOLO menggunakan jaringan saraf tiruan untuk pendeteksian objek pada sebuah citra, langkahnya dengan membagi citra tersebut menjadi beberapa wilayah kemudian memprediksi setiap *bounding boxes* atau kotak pembatas dan probabilitas untuk setiap wilayah. Kotak pembatas ini kemudian dibandingkan dengan setiap probabilitas yang diprediksi. Sistem prediksi pada YOLO tidak sama dengan R-CNN yang membutuhkan ribuan kali selective search untuk sebuah citra, sehingga membuat YOLO lebih cepat dibandingkan R-CNN. Ilustrasi dari arsitektur YOLOv5 dapat dilihat pada Gambar 2.7 berikut.



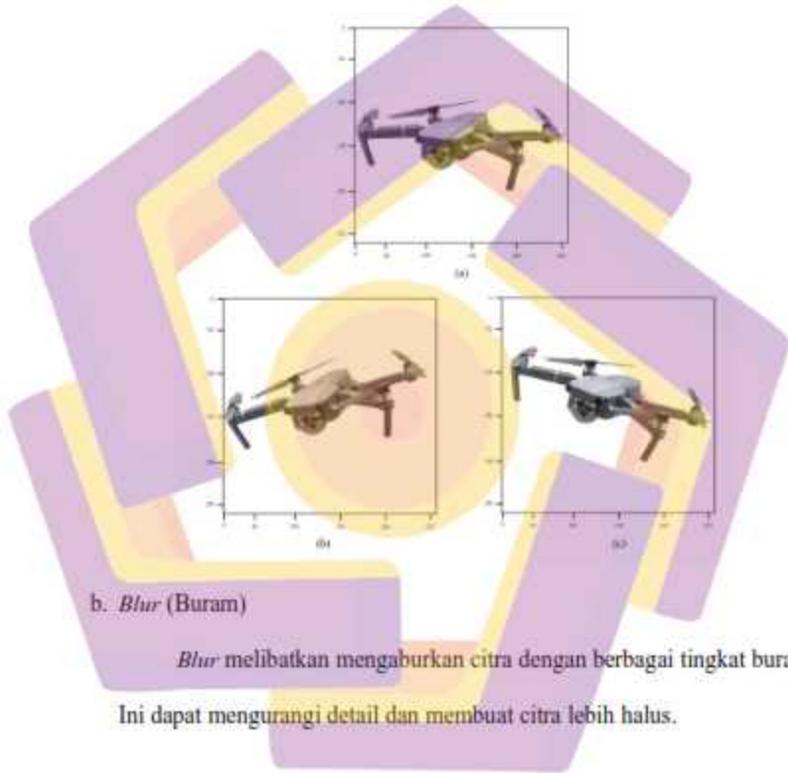
Gambar 2.7 Arsitektur YOLOv5

2.3.7 Augmentasi Data

Augmentasi data adalah teknik yang umum digunakan dalam pelatihan model *machine learning*, terutama dalam *computer vision*, untuk meningkatkan kinerja model dan membuatnya lebih tahan terhadap variasi dalam data. Augmentasi data menciptakan variasi data pelatihan dengan mengubah citra asli, yang membantu model untuk belajar pola yang lebih umum dan tidak hanya mempelajari kasus tertentu dalam data pelatihan (Singha & Aydin, 2021). Beberapa jenis augmentasi data yang cukup populer dan sering digunakan diantaranya adalah *Flip*, *Rotate*, *Crop*, dan sebagainya (*Augmentasi Data Pada Computer Vision | by Adhi Setiawan | Data Folks Indonesia | Medium, n.d.*). Penjelasan terkait jenis augmentasi tersebut adalah sebagai berikut.

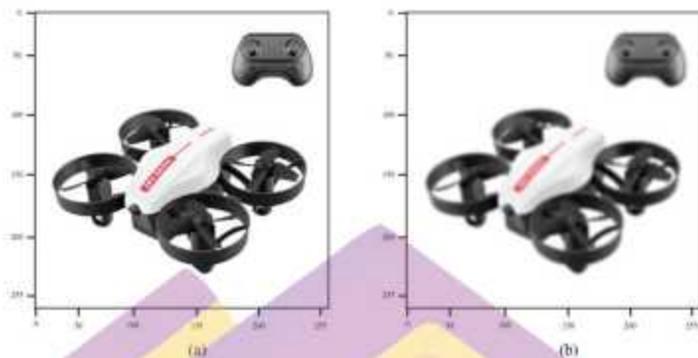
a. *Rotation* (Perputaran)

Rotation adalah memutar gambar searah atau berlawanan dengan jarum jam, besaran sudut putaran dapat bervariasi, pada penelitian ini menggunakan nilai 15° .



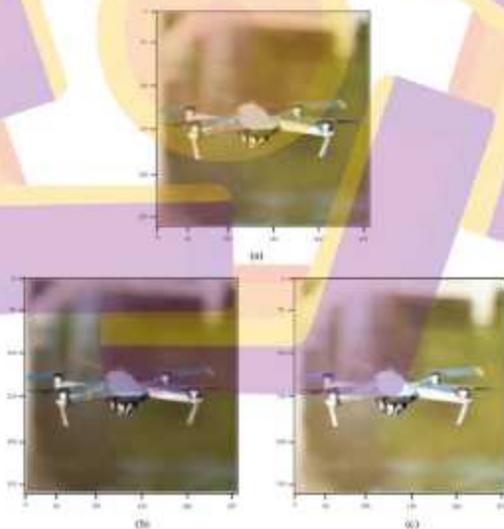
b. *Blur* (Buram)

Blur melibatkan mengaburkan citra dengan berbagai tingkat buram. Ini dapat mengurangi detail dan membuat citra lebih halus.



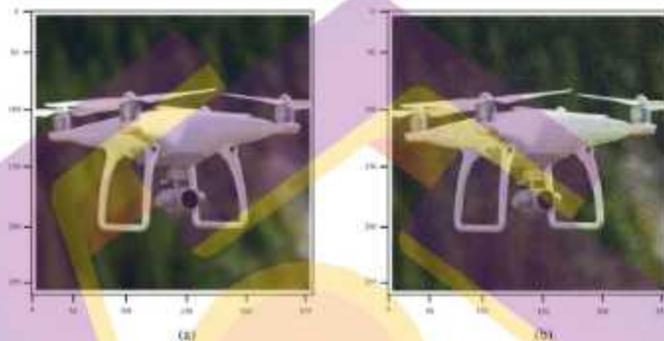
c. *Brightness* (Kecerahan)

Brightness berfungsi untuk meningkatkan atau mengurangi kecerahan dari keseluruhan citra.



d. Noise (Kebisingan)

Noise mengacu pada penambahan elemen-elemen acak pada citra, sehingga dengan menggunakan *noise* citra yang dihasilkan akan terlihat lebih kasar atau lebih alami.

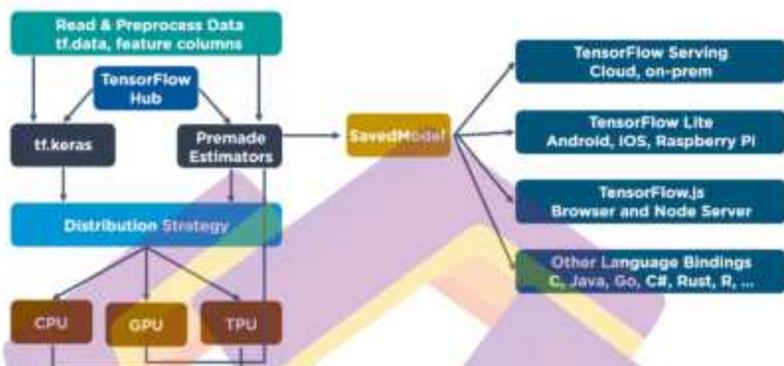


2.3.8 TensorFlow 2.0

TensorFlow 2.0 adalah library yang menyediakan ekosistem lengkap alat untuk developer, peneliti, dan organisasi yang ingin membangun aplikasi *Machine Learning* dan *Deep Learning*. TensorFlow adalah pustaka sumber terbuka populer yang dirilis pada tahun 2015 oleh tim Google Brain untuk membuat pembelajaran mesin dan model pembelajaran mendalam (Biswal, 2022). TensorFlow 2.0 didasarkan pada bahasa pemrograman Python dan melakukan perhitungan numerik menggunakan grafik aliran data untuk membangun model.

Selama beberapa tahun terakhir, komunitas developer telah menambahkan banyak komponen ke TensorFlow. Komponen-komponen ini akan dikemas bersama menjadi platform komprehensif yang mendukung alur kerja pembelajaran

mesin mulai dari pelatihan hingga penerapan. Arsitektur baru TensorFlow 2.0 dapat dilihat di Gambar 2.8 (Biswal, 2022).



Gambar 2.8 Arsitektur TensorFlow 2.0

BAB III METODE PENELITIAN

3.1 Jenis, Sifat, dan Pendekatan Penelitian

Penelitian yang dilakukan merupakan penelitian komputasi eksperimental yang bertujuan untuk menguji dan membandingkan gabungan augmentasi terhadap hasil deteksi pada YOLOv5 dengan objek drone. Dalam penelitian ini, skenario pertama peneliti melakukan serangkaian pengujian yang bersifat eksperimental mulai dari satu tipe augmentasi data, hingga gabungan empat tipe augmentasi data yang dilatih menggunakan 100 epoch. Untuk skenario kedua, peneliti mengambil 1/3 dataset kemudian di-augmentasi dengan generalisasi model 3x, untuk dibandingkan dengan dataset asli tanpa augmentasi. Sedangkan untuk dataset dalam pengujian menggunakan dataset yang sama dalam skenario yang berbeda, dataset berupa gambar drone yang terdiri dari berbagai tipe, model, dan posisi. Melalui eksperimen ini, peneliti dapat mengetahui apakah dengan penambahan beberapa augmentasi dapat menambah atau mengurangi akurasi dan apakah data yang lebih sedikit dapat mencukupi untuk dilakukan pendeteksian dibandingkan dengan dataset asli tanpa augmentasi.

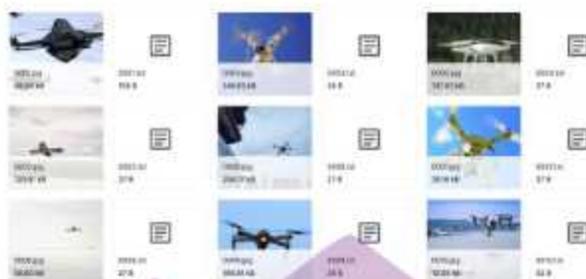
Penelitian ini didasarkan pada pendekatan kuantitatif, dimana hasil penelitian dinyatakan dalam bentuk angka yang dapat diukur, seperti *Mean Average Precision* (mAP), *Precision* (P), *Recall* (R), dan *F1 Score*. Pendekatan ini memungkinkan peneliti untuk secara objektif mengevaluasi performa kedua model dan melakukan perbandingan yang dapat diandalkan.

Penelitian ini bersifat verifikatif, bertujuan untuk menguji kebenaran hipotesis atau teori yang telah ada. Dengan melakukan eksperimen mengujicoba setiap proses agumentasi, apakah mendukung hipotesis atau tidak.

3.2 Metode Pengumpulan Data

Data yang digunakan pada penelitian ini merupakan jenis data sekunder yang dikumpulkan secara tidak langsung. Dataset berupa gambar, yakni gambar drone yang diambil dari platform Kaggle dapat diakses melalui <https://www.kaggle.com/dasmehdixtr/drone-dataset-uav>. Data yang didapat kemudian di download dan di *extract*, kemudian dimasukkan ke Roboflow untuk dilakukan anotasi data. Anotasi data adalah dengan menandai area yang terdapat drone dan area bukan drone, dengan menyeleksi area tersebut.

Dataset ini dikumpulkan oleh Mehdi Özel untuk kompetisi UAV (*Drone Dataset (UAV)*, n.d.). Tujuan dari pembuatan dataset ini adalah untuk melatih UAV, untuk memandu dan menghindari UAV lain. Ada 1359 foto dan semuanya berlabel. Dataset ini dapat dilatih di Darknet (YOLO), Tensorflow, dan Model PyTorch. Gambar dataset drone dan contoh penerapan anotasinya dapat dilihat di Gambar 3.1 dan Gambar 3.2.



Gambar 3.1 Dataset Drone



Gambar 3.2 Anotasi Data

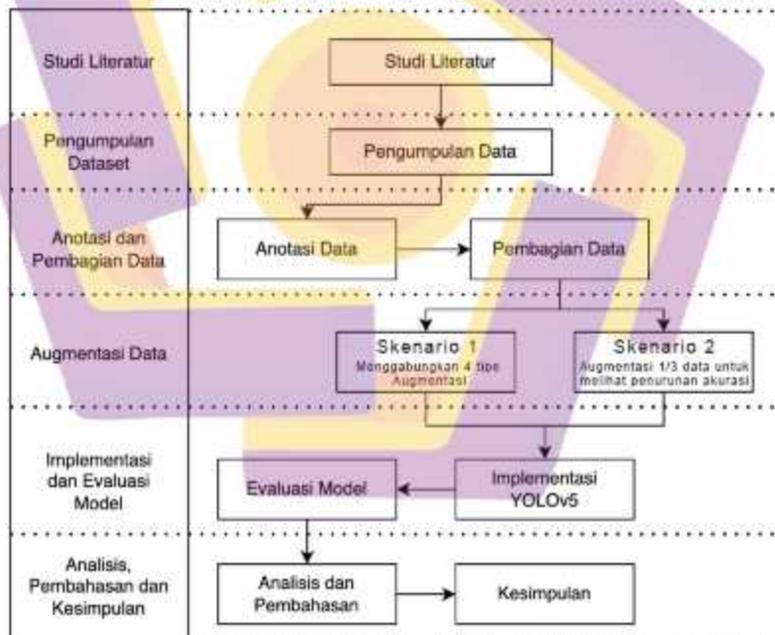
3.3 Metode Analisis Data

Setelah data yang dibutuhkan terkumpul, maka langkah selanjutnya adalah mengolah dataset yang didapat menjadi sebuah informasi. Untuk melakukan hal tersebut langkah pertama adalah melakukan seleksi terhadap area yang merupakan objek drone, seleksi tersebut dapat berupa pemberian area kotak (*bounding boxes*) terhadap area drone dalam gambar. Kemudian data dilakukan pre-processing data, yakni dengan mengubah data gambar yang terdiri dari berbagai ukuran menjadi seragam yakni 640x640 pixel. Selanjutnya data akan dibagi menjadi data latih

(*training set*), data validasi (*validation set*) dan data uji (*testing set*). Dataset yang digunakan dibagi menjadi 70% data training, 20% data validasi dan 10% data tesing.

3.4 Alur Penelitian

Adapun alur penelitian yang dilakukan terbagi menjadi 7 tahapan, yaitu studi literatur, pengumpulan data, anotasi data, pembagian data, augmentasi data, implementasi model dan evaluasi seperti yang dapat dilihat pada Gambar 3.3. Penjelasan terkait tahapan yang dilakukan adalah sebagai berikut.



Gambar 3.3 Alur Penelitian

1. Studi literatur

Tahap studi literatur bertujuan untuk membangun dasar teoretis, mengidentifikasi gap penelitian, dan merumuskan kerangka konseptual untuk penelitian. Studi literatur yang peneliti buat didasarkan pada pendalaman materi tentang tahap pengolahan citra, serta pengklasifikasian citra yaitu pada YOLO. Literatur yang digunakan berasal dari jurnal, artikel, buku dan website yang membahas mengenai materi tersebut.

2. Pengumpulan Data

Data yang digunakan dalam penelitian ini antar alain citra drone dari berbagai bentuk, tipe, merk, dan jarak yang berbeda. Data yang didapatkan merupakan data sekunder.

3. Anotasi Data

Tahap anotasi data adalah tahap memberikan keterangan pada setiap data citra. Keterangan tersebut berupa kotak pembatas yang berfungsi untuk membedakan antara objek drone dengan background. Keterangan ini nantinya digunakan untuk proses pelatihan dan pengujian.

4. Pembagian data

Tahap pembagian data yaitu membagi keseluruhan data untuk proses pelatihan dan uji validasi. Data yang digunakan untuk pelatihan yaitu 70%, validasi 20% dan data uji 10% dari total seluruh data.

5. Augmentasi data

Tahap augmentasi data adalah proses menghasilkan variasi tambahan dari dataset yang ada dengan cara mengubah atau memanipulasi

data yang ada. Tujuannya adalah untuk meningkatkan keanekaragaman dan jumlah data yang digunakan untuk melatih atau menguji model. Augmentasi data berguna terutama dalam situasi dimana jumlah data yang tersedia terbatas, karena dapat membantu mencegah overfitting dan meningkatkan kemampuan model untuk mengenali pola yang beragam.

Pada penelitian ini, ada 2 macam skenario augmentasi data yang digunakan. Skenario pertama yakni menggunakan semua data untuk dilakukan augmentasi, kemudian dilakukan pengujian dengan menggabungkan 1 tipe augmentasi, 2 tipe augmentasi, 3 tipe augmentasi dan 4 tipe augmentasi dengan menggunakan 100 epoch pada setiap perlakuan yang diberikan.

Skenario kedua dilakukan dengan melakukan augmentasi terhadap 1/3 data dari dataset yang digunakan, dengan generalisasi model sebanyak 3x. Kemudian dilakukan pengujian dengan menggabungkan 1 tipe augmentasi, 2 tipe augmentasi, 3 tipe augmentasi dan 4 tipe augmentasi dengan menggunakan 100 epoch pada setiap perlakuan yang diberikan, dan dibandingkan hasilnya dengan dataset asli tanpa saugmentasi. Pembagian terkait scenario yang dilakukan dapat dilihat pada Tabel 3.1.

Tabel 3.1 Skenario Penelitian

Perlakuan	Skenario 1 (Augmentasi terhadap keseluruhan data)	Skenario 2 (Augmentasi terhadap 1/3 data dengan generalisasi sebanyak 3 kali)
1 Augmentasi	Rotate	Rotate
2 Augmentasi	Rotate + Brightness	Rotate + Brightness

Tabel 3.1 (Lanjutan)

Perlakuan	Skenario 1 (Augmentasi terhadap keseluruhan data)	Skenario 2 (Augmentasi terhadap 1/3 data dengan generalisasi sebanyak 3 kali)
3 Augmentasi	Rotate + Brightness + Blur	Rotate + Brightness + Blur
4 Augmentasi	Rotate + Brightness + Blur + Noise	Rotate + Brightness + Blur + Noise

6. Implementasi YOLOv5

Pada penelitian ini, metode yang digunakan untuk mendeteksi dan mengklasifikasi objek drone adalah metode YOLOv5s dengan batch 16 dan menggunakan generic COCO pretrained sebagai pembobotan awal, kemudian model didapat dari ultralytics YOLOv5.

7. Evaluasi Model

Evaluasi model deteksi objek adalah proses untuk mengukur sejauh mana model tersebut mampu mengidentifikasi dan mengklasifikasikan objek dalam gambar dengan benar. Ada beberapa metode yang umum digunakan untuk evaluasi model deteksi objek:

a. Metrik deteksi objek standar

1. Precision digunakan mengukur seberapa akurat model dalam mengidentifikasi objek positif. Ini dihitung sebagai jumlah objek yang benar terdeteksi dibagi dengan total objek yang terdeteksi.
2. Recall digunakan untuk mengukur seberapa akurat model dalam mengidentifikasi objek positif. Ini dihitung sebagai

jumlah objek yang benar terdeteksi dibagi dengan total objek yang sebenarnya ada.

- b. F1-Score adalah ukuran gabungan dari precision dan recall, yang membantu mengukur trade-off antara kedua metrik tersebut. Ini digunakan untuk mengukur kinerja model secara keseluruhan.
- c. Mean Average Precision (mAP) adalah metrik yang umum digunakan untuk evaluasi deteksi objek. mAP mengukur sejauh mana model dapat mengklasifikasikan objek dengan benar dan mengukur presisi objek yang terdeteksi dengan skala berbeda. mAP dihitung dengan menghitung precision-recall curve dan mengambil rata-rata area di bawah kurva (AP) untuk setiap kelas objek. mAP sering digunakan untuk mengukur kinerja model multi-kelas.
- d. *Confusion Matrix* digunakan untuk membantu dalam menghitung jumlah benar dan salah positif serta benar dan salah negatif. Ini memberikan gambaran lebih rinci tentang kinerja model pada setiap kelas objek.
- e. Visualisasi Hasil dilakukan untuk melihat hasil deteksi objek pada gambar-gambar dari dataset validasi atau uji dapat memberikan pemahaman visual tentang sejauh mana model bekerja dengan baik.

BAB IV

HASIL PENELITIAN DAN PEMBAHASAN

Pada bab ini akan dijelaskan tentang analisa dan implementasi dari rancangan tahapan alur penelitian. Terdapat beberapa tahapan proses mulai dari studi literatur, pengumpulan data, anotasi data, pembagian data, augmentasi pertama, augmentasi kedua, implementasi YOLOv5, evaluasi model, analisis dan pembahasan.

4.1 Pengumpulan Data

Data yang digunakan pada penelitian ini diambil dari Kaggle dengan nama "Drone Dataset (UAV)". Data ini dikumpulkan dan dibuat oleh Mehdi Özel dari Yıldız Teknik Üniversitesi pada tahun 2022 (*Drone Dataset (UAV)*, n.d.). Drone Dataset (UAV) memiliki 2 jenis data, yang pertama adalah kumpulan data yang berisi 1359 gambar drone dengan jenis *rotary wing*, dan yang kedua berupa *bonding boxes* dalam bentuk file .txt, yang berisi titik koordinat area objek drone. Pada dataset ini memiliki satu kelas, yakni kelas drone. Gambar yang digunakan dalam pembuatan dataset tersebut diambil dari berbagai sumber dengan melakukan *scraping* dari Google dan Yandex. Dataset tersebut juga digunakan oleh beberapa penelitian diantaranya (Al-Qubaydhi et al., 2022a), dan (J. Zhang, n.d.). Gambar yang digunakan pada penelitian ini dapat dilihat pada Gambar 4.1 berikut.



Gambar 4.1 Tampilan Dataset

4.2 Anotasi Data

Anotasi data dilakukan dengan membuat garis disekitaran area yang ingin ditandai sebagai drone. Kemudian gambar tersebut ditandai sebagai drone dan area diluar kotak akan secara otomatis ditandai sebagai background. Proses ini dilakukan secara berulang terhadap seluruh data gambar drone. Anotasi data yang dilakukan pada penelitian ini menggunakan Roboflow sebagai salah satu platform yang digunakan untuk melakukan penggabungan anotasi terhadap gambar yang digunakan. Penganotasian yang dilakukan memungkinkan untuk menganotasi lebih dari satu objek dalam satu gambar. Tampilan anotasi data dapat dilihat pada Gambar 4.2 berikut.



Gambar 4.2 Anotasi Data. (a) Anotasi data satu objek, (b) Anotasi data dua objek.

4.3 Pembagian Data

Pada penelitian ini dalam tahap pembagian data dilakukan di Roboflow dengan membagi dataset menjadi 70% untuk train set, 20% untuk valid set, dan 10% untuk test set. Dengan pembagian ini, model memiliki cukup data untuk melatih dirinya sendiri (train set), mengukur kemampuannya dan mencegah overfitting (valid set), serta menguji kinerjanya pada data yang belum pernah dilihat sebelumnya (*test set*). Tampilan pembagian dataset yang digunakan dapat dilihat pada Gambar 4.3 berikut.

Train/Test Split
Here is how you split your images when you added them to the dataset:

TRAIN SET	VALID SET	TEST SET
936 Images	267 Images	136 Images

Continue Rebalance

Gambar 4.3 Pembagian Train Set, Valid Set, Test Set

4.4 Augmentasi Data

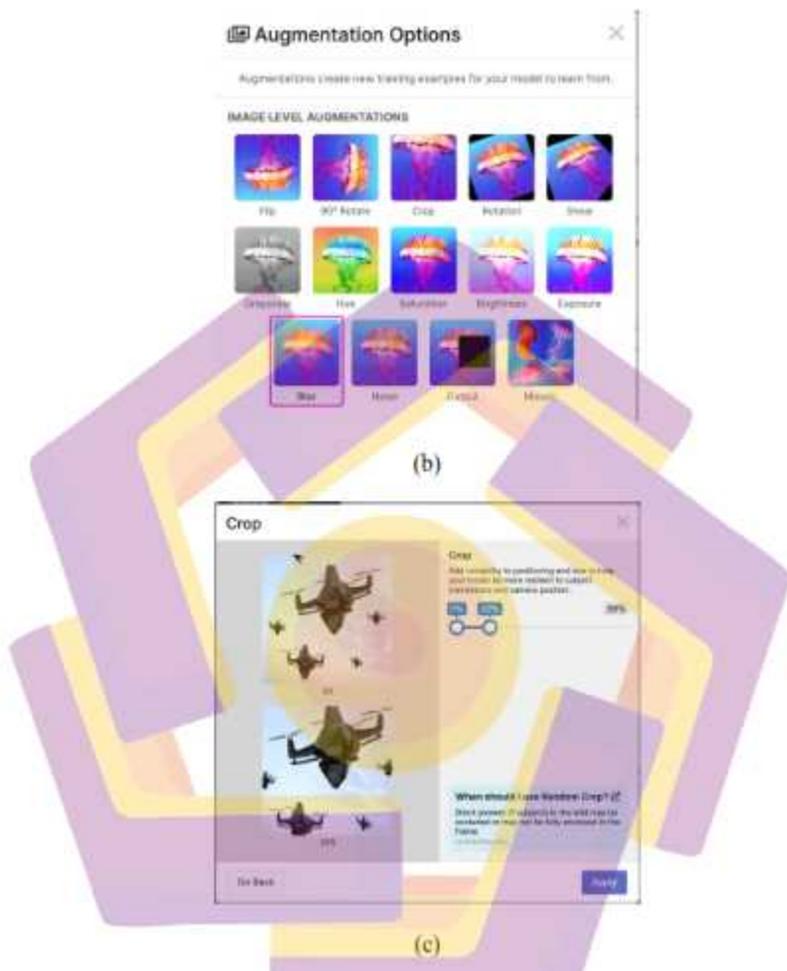
Proses augmentasi yang dilakukan menggunakan platform Roboflow. Platform Roboflow memiliki beberapa fitur yang salah satunya, adalah untuk mengaugmentasi data. Augmentasi data dilakukan dengan cara menambahkan proses augmentasi dalam Roboflow seperti pada Gambar 4.4 (a), kemudian memilih beberapa jenis augmentasi yang akan digunakan untuk penelitian ini, kemudian roboflow akan men-generate gambar tersebut Gambar 4.4 (b), sesuai dengan jenis augmentasi yang dipilih secara otomatis. Beberapa tipe augmentasi memiliki parameter yang dapat diatur, seperti yang dapat dilihat pada Gambar 4.4 (c).

4 Augmentation
Create new training examples for your model to learn from by generating augmented versions of each image in your training set.

+ Add Augmentation Step

Continue

(a)



Gambar 4.4 Augmentasi data pada Roboflow. (a) Penambahan augmentasi, (b) Pemilihan tipe augmentasi, (c) Pengaturan parameter augmentasi.

4.5 Skenario Pertama

Skenario pertama melibatkan penggunaan augmentasi dengan empat variasi yang berbeda. Augmentasi pertama adalah Rotasi, di mana gambar-gambar dalam dataset diputar untuk menciptakan variasi posisi. Augmentasi kedua

menggabungkan Rotasi dan Brightness, yang melibatkan penyesuaian tingkat kecerahan pada gambar. Augmentasi ketiga memasukkan gabungan Rotasi, Brightness, dan Blur, di mana efek blur diterapkan untuk menciptakan variasi yang lebih lembut. Augmentasi keempat adalah kombinasi dari Rotasi, Brightness, Blur, dan Noise, di mana noise ditambahkan untuk menciptakan variasi dengan detail yang lebih acak.

Setiap kombinasi augmentasi tersebut diuji secara terpisah dengan menggunakan 100 epoch pada masing-masing pengujian. Dengan menjalankan 100 epoch, model memiliki kesempatan untuk menyesuaikan bobot dan parameter internalnya secara iteratif, dengan harapan meningkatkan kemampuan generalisasinya terhadap data yang beragam.

Pendekatan ini memungkinkan untuk mengevaluasi kontribusi masing-masing augmentasi terhadap kinerja model. Hasil dari pengujian ini akan memberikan wawasan tentang seberapa baik setiap jenis augmentasi berkontribusi terhadap peningkatan generalisasi model, serta apakah gabungan augmentasi memberikan manfaat tambahan dalam meningkatkan kemampuan model untuk menangani variasi dalam data. Berikut merupakan macam macam augmentasi yang digunakan pada skenario pertama:

a. Rotation

Augmentasi rotasi adalah teknik augmentasi data yang melibatkan memutar gambar-gambar dalam dataset pelatihan dari sumbu 0° hingga 45° untuk menciptakan variasi tambahan dalam data. Pada penelitian ini, sumbu rotasi yang digunakan adalah 15° . Alasan mengapa augmentasi ini dipilih

adalah saat drone terbang, drone mengalami perubahan sudut kemiringan, saat drone terbang kedepan, bagian belakang drone terangkat sedikit ke atas, apabila drone bergerak ke kiri, bagian kanan drone terangkat sedikit keatas, dan sebaliknya, sehingga augmentasi rotation diharapkan dapat menambah model pelatihan terhadap drone yang sedang bergerak. Tujuan dari augmentasi rotasi adalah untuk membuat model lebih tahan terhadap variasi orientasi objek dalam gambar. Contoh augmentasi rotation dapat dilihat pada



Gambar 4.5 Gabungan Augmentasi

b. Rotation dan Brightness

Gabungan augmentasi yang mungkin terjadi di skenario dunia nyata, adalah rotation dan brightness, alasan mengapa brightness dipilih adalah

karena dalam pendeteksian objek drone, seringkali kamera menghadap ke langit, langit memungkinkan terjadinya perubahan cahaya, seperti menjadi lebih terang pada siang hari atau menjadi lebih gelap saat sore atau mendung. Augmentation brightness memungkinkan karena dapat menurunkan dan menaikkan pencahayaan dalam gambar sebesar -10 atau $+10$. Augmentasi ini diharapkan dapat melatih mesin untuk dapat mengenali objek drone dalam kondisi cahaya yang lebih terang atau lebih gelap. Hasil training dalam pendeteksian drone dengan gabungan augmentasi rotation dan brightness dapat dilihat pada Gambar 4.6.



Gambar 4.6 Tampilan Augmentasi Rotation dan Brightness

a. Rotation, Brightness, dan Blur

Gabungan augmentasi berikutnya adalah rotation, brightness dan blur. Rotation dan Brightness telah dijelaskan dalam penjelasan sebelumnya. Augmentasi blur digunakan dalam skenario ini karena blur memungkinkan terjadi di dunia nyata. Pada pendeteksian objek drone, memerlukan kamera, yang mana kemampuan kamera dapat berbeda-beda bergantung pada kualitas dan jenis kamera. Beberapa tipe kamera memiliki sistem autofocus yang memungkinkan terjadinya perubahan fokus dalam jarak tertentu, apabila fokus tidak jatuh tepat pada objek drone, maka objek drone menjadi blur. Blur juga dapat terjadi apabila lensa kamera kotor, seperti terkena debu atau terkena tetesan air. Sehingga augmentasi blur digunakan dalam penelitian ini diharapkan dapat objek drone dalam kondisi yang kurang tajam. Hasil dari augmentasi rotation, brightness, dan blur dapat diamati pada Gambar 4.7.



Gambar 4.7 Tampilan Augmentasi Rotation, Brightness dan Blur

b. Rotation, Brightness, Blur, dan Noise

Gabungan augmentasi berikutnya adalah rotation, brightness, blur, dan noise. Noise merupakan kondisi dalam gambar, mengalami pixel-pixel warna yang berubah, hal ini dapat terjadi karena kemampuan kamera dalam menangkap cahaya, umumnya terjadi dalam kondisi cahaya yang kurang, sehingga processor pada kamera bekerja ekstra untuk menambahkan cahaya, mengakibatkan gambar menjadi noise. Noise memungkinkan terjadi di dunia nyata, terutama saat pendeteksian objek drone dalam kondisi mendung atau gelap. Sehingga dengan penambahan augmentasi noise diharapkan dapat membuat model lebih terlatih mengenali drone dalam

kondisi noise. Ilustrasi penggabungan augmentasi tersebut dapat dilihat pada Gambar 4.8



Gambar 4.8 Tampilan Augmentasi Rotation, Brightness, Blur dan Noise

4.6 Skenario Kedua

Skenario kedua dalam eksperimen ini melibatkan penerapan augmentasi pada 1/3 bagian dari dataset yang digunakan, dengan tujuan utama meningkatkan generalisasi model hingga 3 kali lipat. Dalam konteks ini, sebanyak sepertiga dari dataset akan mengalami proses augmentasi, di mana variasi yang dihasilkan diharapkan dapat membantu model untuk lebih efektif dalam menangani berbagai situasi.

Proses selanjutnya melibatkan pengujian model yang telah diaugmentasi dengan menggabungkan berbagai variasi augmentasi. Ada empat variasi yang diuji,

yaitu menggunakan 1 jenis augmentasi, 2 jenis augmentasi, 3 jenis augmentasi, dan 4 jenis augmentasi secara bersamaan. Setiap variasi perlakuan diuji sebanyak 100 epoch, mengacu pada jumlah iterasi latihan model, untuk memastikan model memiliki cukup waktu untuk menyesuaikan diri dengan data yang telah diubah.

Hasil dari pengujian ini kemudian dibandingkan dengan model yang dilatih menggunakan dataset asli tanpa augmentasi. Dengan membandingkan performa model pada dataset yang telah mengalami augmentasi dengan model pada dataset asli, dapat dilihat sejauh mana augmentasi mempengaruhi kinerja generalisasi model. Hal ini memberikan gambaran yang lebih komprehensif tentang seberapa efektif augmentasi terhadap peningkatan kemampuan model dalam menangani data baru atau tidak terlihat sebelumnya. Berikut merupakan skenario augmentasi yang digunakan pada skenario kedua:

4.7 Implementasi YOLOv5

a. Menginstal Kebutuhan

YOLOv5 kali ini kita implementasikan dalam Google Colab sehingga kita perlu mengklon repository (*clone repo*) YOLOv5 dari GitHub ke dalam direktori saat ini. Kemudian menginstall *dependencies* yang diperlukan oleh YOLOv5, dan menjalankan paket-paket yang diperlukan untuk menjalankan YOLOv5. Kemudian menginstall roboflow, kali ini menggunakan versi roboflow 1.0.1. Import torch untuk mengimport modul 'torch' yang merupakan library PyTorch, yang berfungsi untuk pelatihan dan inferensi model YOLOv5. Import os digunakan untuk berinteraksi dengan sistem berkas dan direktori. Display import Image berguna

untuk menampilkan gambar dalam notebook. Print berfungsi untuk mencetak pesan ke layar, yang memberi tahu bahwa pengaturan awal telah selesai.

```
#clone YOLOv5 and
!git clone https://github.com/ultralytics/yolov5 # clone repo
%cd yolov5
!pip install -qr requirements.txt # install dependencies
!pip install roboflow==1.0.1

import torch
import os
from IPython.display import Image, clear_output # to display
images

print(f"Setup complete. Using torch {torch.__version__}
      {(torch.cuda.get_device_properties(0).name if
torch.cuda.is_available() else 'CPU')}")
```

b. Memanggil Dataset

Memanggil dataset yang telah disiapkan di Roboflow dengan kode program berikut ini. `Os.environ` berfungsi mengatur variabel lingkungan ('DATASET_DIRECTORY') untuk menunjuk ke direktori '/content/dataset'. Nantinya digunakan dalam menentukan direktori penyimpanan dataset. Pip install roboflow berfungsi untuk menginstal pustaka 'roboflow' menggunakan 'pip'. 'roboflow' adalah pustaka Python untuk berinteraksi dengan layanan Roboflow, yang merupakan platform untuk pengelolaan dan augmentasi dataset. Kemudian mengimpor kelas 'Roboflow' dari modul 'roboflow'. Kelas ini digunakan untuk berinteraksi dengan API Roboflow. Kemudian membuat objek 'rf' dari kelas 'Roboflow'. Objek ini digunakan untuk berinteraksi dengan API Roboflow. Kunci API Key memberikan akses ke proyek dan dataset di Roboflow. `Project` berfungsi untuk mengakses proyek tertentu di Roboflow. Proyek yang diakses adalah proyek dengan nama "drononly-xq7bl" di dalam ruang kerja "ariel-9dvi8". Nama proyek

dan ruang kerja dapat berbeda-beda. Baris terakhir mengunduh dataset dari proyek yang telah diakses sebelumnya. Dalam kode ini, versi dataset dengan nomor 3 dari proyek "droneonly-xq7bl" diunduh dengan nama "yolov5".

```
# set up environment
os.environ["DATASET_DIRECTORY"] = "/content/datasets"

!pip install roboflow

from roboflow import Roboflow
rf = Roboflow(api_key="zA5102JUGSqdF2UfitYP")
project = rf.workspace("ariel-9dvi8").project("droneonly-xq7bl")
dataset = project.version(3).download("yolov5")
```

c. Melatih Kustom Model YOLOv5

Python `train.py` berfungsi untuk menjalankan 'train.py'. `--img 416` berfungsi untuk mengatur resolusi gambar input selama pelatihan. Dalam hal ini, gambar akan dirubah menjadi resolusi 416x416 piksel. `--batch 16` merupakan ukuran batch yang akan digunakan selama pelatihan. Dalam hal ini, ukuran batch adalah 16 gambar. Ukuran batch memengaruhi seberapa banyak data yang diproses dalam satu iterasi pelatihan. `--epochs 25` merupakan siklus pelatihan yang akan dijalankan selama pelatihan. Dalam hal ini, penelitian akan berlangsung selama 25 epoch. Pada penelitian ini epoch dapat berbeda-beda, bergantung pada skenario yang digunakan. `--data` mengacu pada file konfigurasi data yang digunakan selama pelatihan. Nama argumen ini adalah alamat dari file 'data.yaml' yang kemudian berisi informasi tentang dataset, jalur ke gambar pelatihan, jalur ke gambar validasi, jumlah kelas, dan parameter lain yang diperlukan untuk pelatihan. `--weights` mengacu pada berat awal yang akan digunakan untuk pelatihan. Dalam hal ini, model awal yang digunakan adalah 'yolov5s.pt'. `--cache` digunakan untuk

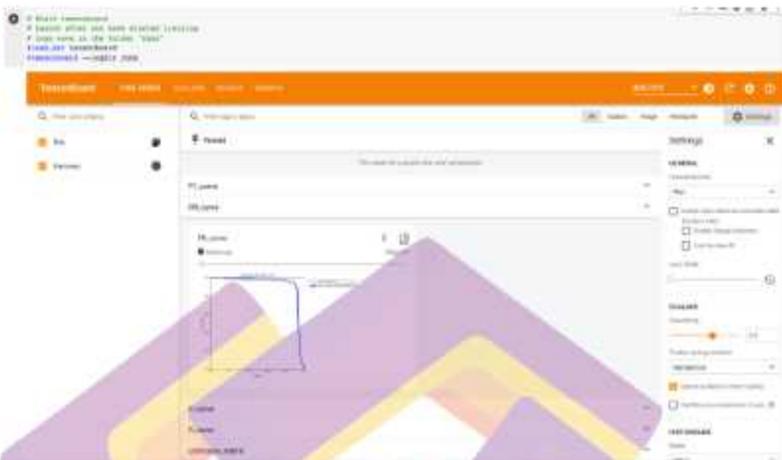
mempercepat proses pelatihan, dengan menyimpan beberapa data yang telah diproses dalam memori, sehingga dapat membantu mengurangi waktu yang dibutuhkan untuk membaca gambar dari disk selama pelatihan.

```
|python train.py --img 416 --batch 16 --epochs 25 --data
(dataset.location)/data.yaml --weights yolov5s.pt --cache
```

d. Mengevaluasi Kinerja Detektor YOLOv5

Untuk mengevaluasi kinerja detektor menggunakan perintah berikut. `%load_ext tensorboard`, memuat ekstensi TensorBoard di dalam notebook. TensorBoard berguna untuk memantau pelatihan model, mengukur kinerja, dan menganalisis log pelatihan. `%tensorboard --logdir runs` berfungsi untuk menjalankan TensorBoard dengan parameter `--logdir` yang mengacu pada direktori "runs". Direktori ini biasanya berisi catatan pelatihan yang dihasilkan selama pelatihan model. TensorBoard akan mengakses direktori ini dan mengambil informasi yang diperlukan untuk visualisasi. Tampilan TensorBoard dapat dilihat pada Gambar 4.9.

```
%load_ext tensorboard
%tensorboard --logdir runs
```



Gambar 4.9 Tampilan Tensorboard

e. Menjalankan Inferensi Dengan Bobot Terlatih

Untuk menjalankan inferensi dengan bobot terlatih, menggunakan kode program berikut. `!python detect.py` berfungsi untuk menjalankan skrip `'detect.py'`, fungsinya untuk menjalankan inferensi atau deteksi objek dengan model YOLOv5. `--weights` mengacu pada berat model yang akan digunakan selama inferensi. Dalam hal ini model yang digunakan merupakan model dengan hasil tertinggi yang didapatkan selama pelatihan. Path `'runs/train/exp/weights/best.pt'` menunjukkan lokasi berat model tertinggi tersebut. Berat model ini dipilih berdasarkan metrik yang mengukur kinerja model. `--img 416` mengatur resolusi gambar input yang akan digunakan selama inferensi, gambar input akan dirubah menjadi resolusi `416x416`. `--conf 0.1` mengatur ambang batas (*threshold*) kepercayaan (*confidence threshold*) untuk deteksi objek. Ini berarti hanya deteksi dengan kepercayaan lebih besar dari atau sama dengan `0,1` akan disimpan dan ditampilkan. `--source` mengacu

pada sumber data direktori yang berisi gambar-gambar yang akan diuji dengan model. Path `{dataset.location}/test/images` adalah lokasi dari folder yang berisi gambar-gambar uji.

```
!python detect.py --weights runs/train/exp/weights/best.pt --  
img 416 --conf 0.1 --source {dataset.location}/test/images
```

"Train batch1" adalah istilah yang merujuk kepada kelompok pertama (batch pertama) dari data pelatihan (training data) yang digunakan dalam pelatihan model machine learning atau deep learning. Dalam pelatihan model dengan pendekatan mini-batch, data pelatihan dibagi menjadi beberapa kelompok atau *batch*, dan model diperbarui pada setiap *batch* tersebut. Tujuan dari dibentuknya batch ini adalah memungkinkan pelatihan model yang lebih efisien karena model tidak perlu memproses seluruh data sekaligus. Setiap batch memiliki ukuran yang dapat diatur, misalnya ukuran batch 16 berarti ada 16 sampel dalam setiap batch. Tampilan dari training batch yang digunakan dapat dilihat pada Gambar 4.10.



Gambar 4.10 train_batch1

Val batch pred adalah istilah yang merujuk kepada hasil prediksi (*predictions*) yang dihasilkan oleh model machine learning atau deep learning pada data validasi (*validation data*) dalam bentuk batch atau kelompok data. Ini

berhubungan dengan proses pengujian atau evaluasi kinerja model pada dataset validasi.

"Val" singkatan dari "validation", yang mengacu pada dataset validasi. "Batch" merujuk kepada kelompok data yang diambil sekaligus dari dataset validasi untuk dievaluasi oleh model, tujuannya untuk efisiensi komputasi. "Pred" singkatan dari "predictions", yang merupakan hasil prediksi yang dihasilkan oleh model untuk setiap sampel dalam batch tersebut, seperti yang terlihat pada Gambar 4.11 berikut.

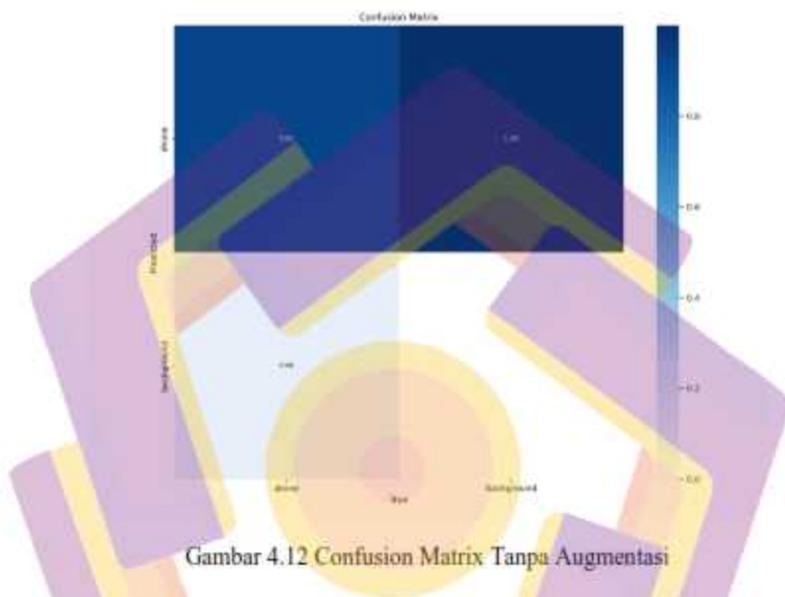


Gambar 4.11 val_batch2_pred

4.8 Evaluasi Model

Confusion Matrix adalah alat evaluasi yang digunakan untuk mengukur kinerja model deteksi objek. *Confusion matrix* digunakan untuk menghitung sejauh mana model berhasil dalam melakukan klasifikasi objek yang benar dan

menganalisis jenis kesalahan yang dibuat oleh model. Umumnya confusion matrix digunakan untuk deteksi objek yang menggunakan multi-kelas. Gambar confusion matrix dapat dilihat pada Gambar 4.12.

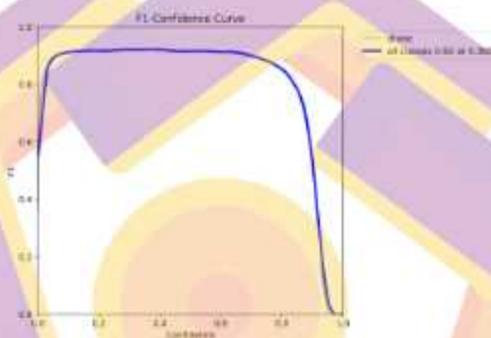


Gambar 4.12 Confusion Matrix Tanpa Augmentasi

F1-Score adalah metrik evaluasi yang menggabungkan Precision dan Recall untuk memberikan gambaran tentang kerja model deteksi objek. F1-Score adalah ukuran keseimbangan antara presisi (tingkat objek positif yang terdeteksi dengan benar) dan recall (tingkat objek positif yang terdeteksi dari total objek positif yang seharusnya terdeteksi). F1-Score digunakan untuk mengukur sejauh mana model dapat mengidentifikasi objek dengan benar tanpa menghasilkan banyak false positif. Confidence score adalah nilai yang diberikan oleh model YOLOv5 untuk setiap prediksi deteksi objek, yang mengartikan seberapa yakin model dalam prediksinya. Pada umumnya, tingkat keyakinan digunakan untuk memfilter hasil

deteksi objek; objek dengan tingkat keyakinan dibawah ambang batas tertentu dianggap sebagai false positif.

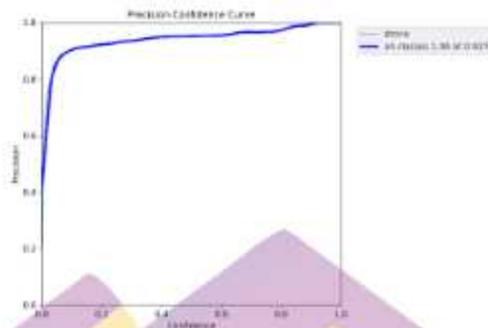
F1-Confidence Curve mengacu pada grafik yang menggambarkan kinerja model deteksi objek dengan variasi ambang batas *confidence score*, maka grafik ini akan menunjukkan bagaimana nilai F1-Score berubah ketika ambang batas *confidence score* berubah. Seperti yang terlihat pada Gambar 4.13.



Gambar 4.13 F1-Score Tanpa Augmentasi

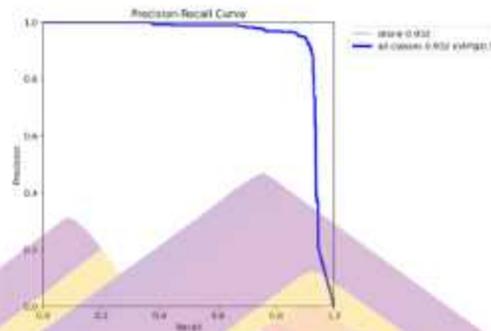
Precision adalah metrik evaluasi yang mengukur sejauh mana deteksi objek yang dilakukan oleh model adalah benar. Presisi menghitung berapa banyak objek yang terdeteksi dengan benar (True Positives, TP) dibagi oleh total objek yang diprediksi sebagai positif (True Positives dan False Positives, TP + FP).

Precision-Confidence Curve menggambarkan bagaimana nilai presisi berubah ketika ambang batas *confidence score* diubah. Grafik ini menyajikan trade-off antara tingkat presisi yang dihasilkan oleh model pada berbagai tingkat keyakinan. Pada Gambar 4.14 dapat dilihat bagaimana tingkat presisi berfluktuasi seiring dengan peningkatan atau penurunan ambang batas *confidence score*.



Gambar 4.14 Precision-Confidence Curve

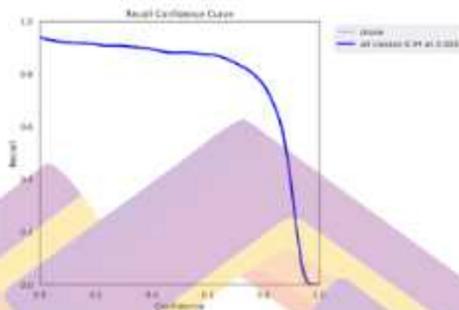
Precision-Recall Curve adalah grafik yang menggambarkan trade-off antara tingkat presisi dan tingkat recall pada berbagai ambang batas (threshold) confidence score. Pada grafik ini, setiap titik data mewakili hasil dari model pada satu ambang batas tertentu. *All classes* mengartikan bahwa metrik ini mengambil semua kelas objek yang ada dalam dataset menjadi pertimbangan. Dalam konteks deteksi objek, dataset biasanya berisi berbagai kelas objek yang berbeda. mAP (*Mean Average Precision*) adalah metrik evaluasi yang mengukur sejauh mana model dapat mendeteksi objek dengan benar dalam berbagai kelas objek. mAP adalah rata-rata dari nilai Precision-Recall pada semua kelas objek dalam dataset. @0.5 merujuk pada ambang batas (*threshold*) tingkat keyakinan (*confidence score*) yang digunakan dalam perhitungan mAP. Ambang batas 0.5 adalah ambang batas umum yang digunakan dalam banyak tugas deteksi objek. 0.5 mengindikasikan bahwa objek yang diprediksi dengan tingkat keyakinan di atas 0.5 dianggap sebagai deteksi yang benar. Grafik Precision-Recall Curve dapat dilihat pada Gambar 4.15.



Gambar 4.15 Precision-Recall Curve

Recall adalah metrik evaluasi yang mengukur sejauh mana model dapat mendeteksi semua objek positif yang sebenarnya dalam dataset. Recall menghitung berapa banyak objek positif yang terdeteksi dengan benar (*True Positives*, TP) dibagi oleh total objek positif yang seharusnya terdeteksi (*True Positives* dan *False Negatives*, TP + FN). Sebuah Recall Curve adalah grafik yang menggambarkan perubahan tingkat recall pada berbagai ambang batas (*threshold*) tingkat keyakinan

(confidence score). Grafik Recall-Confidence Curve dapat dilihat pada Gambar 4.16 berikut.



Gambar 4.16 Recall-Confidence Curve

4.9 Analisis dan Pembahasan

Hasil dari pengujian terkait augmentasi data 1 yang dilakukan dapat dilihat pada Tabel 4.1 berikut.

Tabel 4.1 Hasil Pengujian Skenario 1

Skenario 1				
	Precision	Recall	F1 Score	mAP
Tanpa Augmentasi	0.927	0.94	0.92	0.932
1 Augmentasi (Rotation)	0.938	0.94	0.93	0.937
2 Augmentasi (Rotation, Brightness)	0.956	0.94	0.93	0.941
3 Augmentasi (Rotation, Brightness, Blur)	0.931	0.95	0.93	0.95
4 Augmentasi (Rotation, Brightness, Blur, Noise)	0.957	0.95	0.92	0.939

Pada Tabel 4.1 diperlihatkan hasil pengujian dari skenario 1 yang dilakukan pengujian dengan menggunakan penggabungan beberapa augmentasi, dengan tujuan untuk melihat seberapa besar penurunan terhadap nilai presisi yang terjadi

pada 1 tipe augmentasi, gabungan 2 tipe augmentasi, gabungan 3 tipe augmentasi, dan gabungan 4 tipe augmentasi. Masing-masing tipe augmentasi yang digunakan pada skenario 1 adalah tipe augmentasi yang mungkin terjadi di dunia nyata, seperti: Rotation (-15° dan $+15^\circ$), Brightness (-25% dan $+25\%$), Blur (Up to 2.5px), Noise (Up to 5% of pixels).

Pada tabel diatas terlihat bahwa hasil pengujian yang memiliki nilai terendah berada pada skenario tanpa augmentasi, dengan nilai precision yang dihasilkan adalah 0,927. Hal tersebut dikarenakan pada saat melakukan pelatihan, model yang digunakan tidak dapat menggeneralisasi objek dengan baik, sehingga model kesulitan untuk membaca fitur khusus yang ada pada objek.

Berdasarkan hasil pengujian yang ditampilkan pada tabel diatas terlihat bahwa pengujian dengan menggunakan gabungan dari 4 tipe augmentasi memberikan nilai yang lebih tinggi dibandingkan dengan pengujian lainnya. Hal tersebut dapat dijelaskan menjadi beberapa alasan, dimana dengan menggunakan berbagai jenis augmentasi, model yang digunakan dapat lebih mempelajari fitur khusus yang ada pada gambar, sehingga model yang digunakan dapat mengatasi berbagai transformasi data yang mungkin terjadi dalam data dunia nyata. Hal tersebut membuat model lebih siap untuk menangani variasi dalam data uji dan dapat menghasilkan hasil yang lebih baik dalam situasi dunia nyata.

Tabel 4.2 Hasil Pengujian Terhadap Augmentasi Data 2

Skenario 2				
	Precision	Recall	F1 Score	mAP
Tanpa Augmentasi (Hasil dari skenario 1)	0.927	0.94	0.92	0.932
1 Augmentasi (Rotation)	0.659	0.99	0.98	0.985
2 Augmentasi (Rotation, Brightness)	0.429	1	0.98	9.994
3 Augmentasi (Rotation, Brightness, Blur)	0.575	0.99	0.97	0.984
4 Augmentasi (Rotation, Brightness, Blur, Noise)	0.622	0.98	0.97	0.975

Pada Tabel 4.2 diatas diperlihatkan hasil pengujian skenario 2 dengan menggunakan arsitektur YOLOv5. Tabel tersebut menunjukkan hasil pengujian dengan menggunakan 1359 data tanpa augmentasi, dengan mengambil 1/3 datanya kemudian dilakukan augmentasi dengan 1 tipe augmentasi, 2 tipe augmentasi, 3 tipe augmentasi dan 4 tipe augmentasi, dengan masing-masing di generalisasi sebesar 3 kali.

Berdasarkan hasil pengujian yang dilakukan pada skenario 2, dapat dilihat bahwa pengujian dengan menggunakan 2 tipe augmentasi memiliki hasil terendah dengan nilai yang dihasilkan adalah 0.429 dan nilai tertinggi didapatkan oleh skenario dengan menggunakan 1 tipe augmentasi dengan nilai yang didapatkan adalah 0.659. Hal tersebut dapat terjadi karena beberapa alasan, diantaranya adalah karena ketika hanya sebagian data di yang diaugmentasi, model akan kesulitan dalam menemukan pola yang konsisten di seluruh dataset sehingga menghambat proses konvergensi ke solusi optimal atau ketika ukuran sampel yang di-augmentasi terlalu kecil, variasi tambahan dari augmentasi mungkin tidak cukup untuk

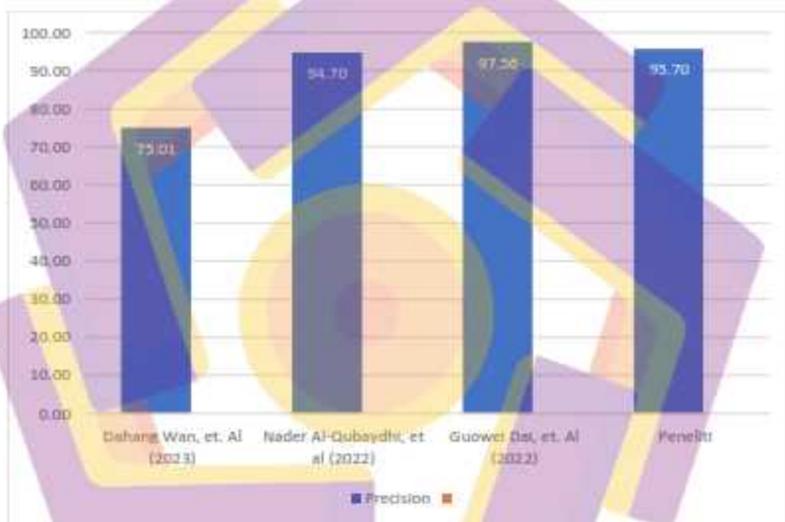
membantu model. Sebaliknya, menggunakan seluruh dataset bisa memberikan representasi yang lebih baik.

Terlihat penurunan yang cukup besar terhadap nilai yang dihasilkan pada kedua skenario yang dilakukan. Dimana pada skenario 1, nilai tertinggi yang berhasil didapatkan adalah dengan menggunakan 4 tipe augmentasi, dengan nilai presisi yang dihasilkan sebesar 0.957. Sedangkan pada skenario 2, nilai yang menggunakan 4 tipe augmentasi, mendapatkan nilai presisi sebesar 0.622. Perbedaan nilai tersebut terjadi karena pada skenario kedua, jumlah data yang diaugmentasi relatif lebih sedikit atau tidak merata dibandingkan dengan skenario pertama. Hal ini bisa menyebabkan kurangnya variasi yang cukup untuk membantu model mempelajari pola-pola yang kompleks.

Berdasarkan hasil pengujian dari kedua skenario yang telah dilakukan, maka didapatkan kesimpulan bahwa pada skenario 1 yang menggunakan augmentasi secara menyeluruh pada setiap datanya, dapat memberikan hasil yang lebih baik dibandingkan dengan skenario 2 yang hanya melakukan augmentasi pada 1/3 datanya saja. Hal tersebut dapat terjadi karena dengan menerapkan augmentasi pada keseluruhan data, model yang digunakan akan mempelajari lebih banyak variasi data, sehingga model yang digunakan dapat lebih mempelajari fitur khusus yang ada pada gambar.

Dengan demikian, penelitian yang dilakukan mengkonfirmasi pentingnya penggunaan augmentasi pada dataset dalam pengembangan model untuk melakukan deteksi. Hal tersebut sejalan dengan temuan-temuan sebelumnya yang pernah dilakukan dalam bidang serupa. Hal ini memberikan landasan yang kuat

untuk penggunaan augmentasi data sebagai bagian dari strategi pemrosesan data dalam tugas-tugas deteksi yang melibatkan dataset yang minim. Untuk mempermudah perbandingan dengan penelitian serupa yang pernah dilakukan dapat dilihat pada Gambar 4.17 yang merupakan grafik perbandingan dengan penelitian terdahulu yang pernah dilakukan dalam bidang deteksi objek.



Gambar 4.17 Perbandingan dengan penelitian sebelumnya

Berdasarkan hasil dari 4 penelitian yang ditampilkan pada Gambar 4.17 diatas, penggunaan augmentasi pada dataset yang digunakan memiliki pengaruh terhadap hasil deteksi objek yang dihasilkan. Penelitian yang dilakukan mengungguli nilai presisi dari penelitian sebelumnya yang hanya menggunakan satu atau dua jenis augmentasi saja.

Pengembangan dari penelitian ini menggambarkan kemajuan penelitian dalam deteksi objek terutama drone, dengan fokus pada pengaruh dari penerapan augmentasi data terhadap hasil deteksi. Beberapa penelitian yang telah disebutkan, yaitu (Dai et al., 2022), (Wan et al., 2023) dan (Al-Qubaydhi et al., 2022b), memberikan pandangan yang lebih luas terkait bagaimana augmentasi data dapat memengaruhi hasil deteksi objek yang dilakukan.

Dalam penelitian pertama (Dai et al., 2022), fokus utama adalah meningkatkan kemampuan deteksi objek dengan menerapkan berbagai teknik augmentasi sebagai salah satu parameternya. Penelitian tersebut berhasil mencapai tingkat presisi yang sangat tinggi sebesar 97.60%. Hasil tersebut menunjukkan bahwa penggunaan augmentasi dalam skenario pengujian telah menghasilkan peningkatan yang signifikan dalam akurasi deteksi objek. Hal ini berarti bahwa penggunaan teknik augmentasi mampu meningkatkan keandalan sistem deteksi objek, menghasilkan hasil yang lebih konsisten dan akurat. Penemuan ini memiliki potensi besar dalam berbagai aplikasi, termasuk pengenalan objek otomatis, pengawasan keamanan, dan lainnya, yang memerlukan tingkat ketepatan yang tinggi dalam deteksi objek.

Penelitian berikutnya, yang dilakukan oleh (Wan et al., 2023) pada tahun 2022, berhasil mencapai tingkat presisi tertinggi sebesar 75.01%. Namun, angka ini ternyata lebih rendah dibandingkan dengan penelitian sebelumnya. Perbedaan ini disebabkan oleh fokus penelitian yang berbeda, yakni pada peningkatan kecepatan deteksi objek. Dalam usahanya untuk meningkatkan efisiensi waktu proses, penelitian ini mengorbankan sebagian tingkat presisi deteksi objek. Hasil yang

diperoleh menunjukkan bahwa dalam konteks penelitian ini, kecepatan proses lebih diutamakan daripada presisi mutlak, dan hal ini memberikan wawasan berharga dalam pengembangan sistem deteksi objek yang mempertimbangkan berbagai aspek kinerja.

Berikutnya penelitian yang dilakukan oleh (Al-Qubaydhi et al., 2022b) membahas tentang penggunaan teknik deep learning untuk mendeteksi dan mencegah penggunaan drone secara tidak sah. Penelitian ini menggunakan model YOLOv5 dan transfer learning untuk meningkatkan akurasi deteksi drone. Selain itu, dilakukan juga augmentasi data untuk memperkaya dataset dan memungkinkan pelatihan yang lebih baik. Hasil penelitian menunjukkan bahwa model yang diusulkan mampu mencapai presisi deteksi drone sebesar 94,7% pada set pengujian, yang lebih tinggi dibandingkan dengan model yang diusulkan oleh Behera dan Bazil serta Tan et al. Penelitian ini memiliki potensi aplikasi yang luas dalam mencegah penggunaan drone secara tidak sah di berbagai bidang, seperti keamanan dan privasi.

Meskipun penelitian ini mencapai hasil yang positif, penekanannya juga ditempatkan pada tantangan yang masih ada dalam deteksi objek dengan jumlah kelas yang banyak. Pengembangan tersebut masih menjadi sebuah tantangan yang sulit dan masih menyisakan ruang untuk pengembangan lebih lanjut kedepannya, mengingat bidang deteksi drone merupakan salah satu tugas yang rumit, dikarenakan bentuk, serta jenis drone berkembang tiap tahunnya.

BAB V KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil pada percobaan yang telah dilakukan, maka dapat disimpulkan bahwa:

1. Berdasarkan penelitian yang dilakukan, jika mengacu pada nilai *precision*, nilai tertinggi yang berhasil didapatkan berada pada skenario 1 yang menggabungkan 4 tipe augmentasi, dengan nilai *precision* yang dihasilkan sebesar 0.957.
2. Jika mengacu pada jumlah augmentasi, jumlah augmentasi tidak memberikan dampak penurunan pada nilai *precision*, namun efek teknik augmentasi memberikan nilai *precision* yang berbeda.
3. Pada skenario kedua, dengan mengambil 1/3 dataset yang di augmentasi, hasilnya terjadi penurunan yang signifikan pada nilai akurasi dan tidak mampu mendekati akurasi dataset asli yang tidak dilakukan augmentasi. Sehingga dalam penelitian ini, menggunakan jumlah dataset yang lebih banyak, memiliki keuntungan dalam hal keakuratan pendeteksian objek. Hal tersebut dikarenakan, dengan melakukan augmentasi terhadap seluruh data yang digunakan, dapat menambahkan lebih banyak variasi terhadap data yang digunakan. Sehingga model akan semakin akurat untuk membaca fitur khusus yang ada pada objek yang dideteksi.

5.2 Saran

Adapun beberapa saran yang dapat direkomendasikan untuk penelitian selanjutnya pada topik penelitian yang sama adalah sebagai berikut.

1. Harapan untuk penelitian berikutnya adalah adanya peningkatan jumlah dan keragaman dari data yang digunakan, yang nantinya akan membantu model dalam mengenali objek dalam berbagai kondisi dengan lebih baik.
2. Harapannya, penelitian yang akan datang akan memiliki data terhadap model-model drone terbaru atau bahkan penggabungan model drone yang lebih kompleks.
3. Harapan untuk penelitian mendatang adalah, adanya implementasi pendeteksian objek drone secara *real-time* menggunakan algoritma YOLO.

DAFTAR PUSTAKA

PUSTAKA MAJALAH, JURNAL ILMIAH ATAU PROSIDING

- Alkentar, S. M., Alsahwa, B., Assalem, A., & Karakolla, D. (2021). Practical comparison of the accuracy and speed of YOLO, SSD and Faster RCNN for drone detection. *Journal of Engineering*, 27(8), 19–31. <https://doi.org/10.31026/j.eng.2021.08.02>
- Al-Qubaydhi, N., Alenezi, A., Alannzi, T., Senyor, A., Alanezi, N., Alotaibi, B., Alotaibi, M., Razaque, A., Abdelhamid, A. A., & Alotaibi, A. (2022a). Detection of Unauthorized Unmanned Aerial Vehicles Using YOLOv5 and Transfer Learning. *Electronics (Switzerland)*, 11(17). <https://doi.org/10.3390/electronics11172669>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaria, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1). <https://doi.org/10.1186/s40537-021-00444-8>
- Ciaglia, F., Zuppichini, F. S., Guerrie, P., McQuade, M., & Solawetz, J. (2022). *Roboflow 100: A Rich, Multi-Domain Object Detection Benchmark*. <http://arxiv.org/abs/2211.13523>
- Coluccia, A., Fascista, A., Schumann, A., Sommer, L., Dimou, A., Zarpalas, D., Méndez, M., de la Iglesia, D., González, I., Mercier, J. P., Gagné, G., Mitra, A., & Rajashekar, S. (2021). Drone vs. Bird detection: Deep learning

- algorithms and results from a grand challenge. *Sensors*, 21(8), 1–27.
<https://doi.org/10.3390/s21082824>
- Dai, G., Hu, L., & Fan, J. (2022). DA-ActNN-YOLOV5: Hybrid YOLO v5 Model with Data Augmentation and Activation of Compression Mechanism for Potato Disease Identification. *Computational Intelligence and Neuroscience*, 2022. <https://doi.org/10.1155/2022/6114061>
- Eslamiat, H. (2022). Comparing YOLOv3, YOLOv4 and YOLOv5 for Autonomous Landing Spot Detection in Faulty UAVs.
- Jiang, P., Ergu, D., Liu, F., Cai, Y., & Ma, B. (2021). A Review of Yolo Algorithm Developments. *Procedia Computer Science*, 199, 1066–1073.
<https://doi.org/10.1016/j.procs.2022.01.135>
- Kapustina, L., Izakova, N., Makovkina, E., & Khmelkov, M. (2021). The global drone market: main development trends. *SHS Web of Conferences*, 129, 11004. <https://doi.org/10.1051/shsconf/202112911004>
- Meen, T.-H., Institute of Electrical and Electronics Engineers. Tainan Section, Sensors Council Chapter, International Institute of Knowledge Innovation and Invention, & Institute of Electrical and Electronics Engineers. (n.d.). Knowledge Innovation and Invention : 1st IEEE International Conference on Knowledge Innovation and Invention (IEEE ICKII 2018) : Jeju Island, South Korea, July 23-27, 2018.
- Mumuni, A., & Mumuni, F. (2022). Data augmentation: A comprehensive survey of modern approaches. *Array*, 16, 100258.
<https://doi.org/https://doi.org/10.1016/j.array.2022.100258>

- Pan, C., & Yan, W. Q. (2020). Object detection based on saturation of visual perception. *Multimedia Tools and Applications*, 79(27–28), 19925–19944. <https://doi.org/10.1007/s11042-020-08866-x>
- Sanchez, S. A., Romero, H. J., & Morales, A. D. (2020). A review: Comparison of performance metrics of pretrained models for object detection using the TensorFlow framework. *IOP Conference Series: Materials Science and Engineering*, 844(1). <https://doi.org/10.1088/1757-899X/844/1/012024>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1). <https://doi.org/10.1186/s40537-019-0197-0>
- Singha, S., & Aydin, B. (2021). Automated drone detection using YOLOv4. *Drones*, 5(3). <https://doi.org/10.3390/drones5030095>
- Sonkar, S., Kumar, P., Puli, Y. T., George, R. C., Philip, D., & Ghosh, A. K. (2023). Design & Implementation of an Electric Fixed-wing Hybrid VTOL UAV for Asset Monitoring. *Journal of Aerospace Technology and Management*, 15. <https://doi.org/10.1590/jatm.v15.1297>
- Wan, D., Lu, R., Wang, S., Shen, S., Xu, T., & Lang, X. (2023). YOLO-HR: Improved YOLOv5 for Object Detection in High-Resolution Optical Remote Sensing Images. *Remote Sensing*, 15(3). <https://doi.org/10.3390/rs15030614>
- Wang, Y., Li, Y., Song, Y., & Rong, X. (2019). Facial expression recognition based on random forest and convolutional neural network. *Information (Switzerland)*, 10(12). <https://doi.org/10.3390/info10120375>

Wu, M., Xie, W., Shi, X., Shao, P., & Shi, Z. (2018). Real-time drone detection using deep learning approach. *Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, LNICST*, 251, 22–32. https://doi.org/10.1007/978-3-030-00557-3_3

Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology. In *Insights into Imaging* (Vol. 9, Issue 4, pp. 611–629). Springer Verlag. <https://doi.org/10.1007/s13244-018-0639-9>

Zhang, J. (n.d.). *Towards a High-Performance Object Detector: Insights from Drone Detection Using ViT and CNN-based Deep Learning Models*

Zhang, A., Lipton, Z. C., Li, M. U., & Smola, A. J. (n.d.). *Dive into Deep Learning*.

PUSTAKA ELEKTRONIK

Augmentasi Data Pada Computer Vision | by Adhi Setiawan | Data Folks Indonesia | Medium. (n.d.). Retrieved September 19, 2023, from <https://medium.com/data-folks-indonesia/augmentasi-data-pada-computer-vision-45c5ebe10e8f>

Bart Janen. (2015, January 26). Drone crash at White House reveals security risks. *USA TODAY*. <https://www.usatoday.com/story/news/2015/01/26/drone-crash-secret-service-faa/22352857/>

Biswal, A. (2022, March 28). What is TensorFlow 2.0 [The Best Guide to Understand TensorFlow 2.0]. *Simplilearn*. <https://www.simplilearn.com/tutorials/deep-learning-tutorial/tensorflow-2>

- Drone Dataset (UAV). (n.d.). Retrieved October 15, 2023, from <https://www.kaggle.com/datasets/dasmehdixtr/drone-dataset-uav>
- Gatwick flights resume after drone sighting caused more disruption – as it happened | Gatwick airport | The Guardian. (n.d.). Retrieved January 23, 2023, from <https://www.theguardian.com/uk-news/live/2018/dec/21/gatwick-drone-airport-limited-flights-live>
- Géron, A. (n.d.). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow SECOND EDITION Concepts, Tools, and Techniques to Build Intelligent Systems*.
- Google. (n.d.). Google Colab. Retrieved December 5, 2022, from <https://research.google.com/colaboratory/faq.html>
- Pham Sherisse. (2017, October 16). Drone hits passenger plane in Canada. CNN Business. <https://money.cnn.com/2017/10/16/technology/drone-passenger-plane-canada/index.html>
- Theophilus, S. (2021, September 3). Roboflow: Converting Annotations for Object Detection | by Samuel Theophilus | Analytics Vidhya | Medium. Medium. <https://medium.com/analytics-vidhya/converting-annotations-for-object-detection-using-roboflow-5d0760bd5871>
- Volunteers. (2022). Drone Laws in Indonesia [Updated March 29, 2022]. https://drone-laws.com/drone-laws-in-indonesia/#Agencies_Responsible_for_regulating_drones_in_the_Republic_of_Indonesia

Walker, D. (2020, April 13). Report: Trio planned to use drone to to get tobacco, phones to inmate | | northwestgeorgianews.com. Rome News-Tribune. https://www.northwestgeorgianews.com/report-trio-planned-to-use-drone-to-to-get-tobacco-phones-to-inmate/article_44c25a12-7d96-11ea-8c97-73fe94e065d4.html

