

IMPLEMENTASI SISTEM DETEKSI BATU PERMATA MENGGUNAKAN YOLOV7 (STUDI KASUS: TOKO MAGIC CRYSTALS)

Nona Alya Windyani¹, Purwanto², Ultach Enri³

^{1,2,3} Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Singaperbangsa Karawang Jl. HS. Ronggowaluyo, Telukjambe Timur, Karawang, Jawa Barat 41361

Keywords:

YOLOv7; Deteksi Objek; *Deep Learning*; Batu Permata; Flutter; Roboflow API.

Correspondent Email:

20110631170033@student.unsika.ac.id

Abstrak. Dengan tingginya minat konsumen terhadap batu permata di Toko Magic Crystals, didukung oleh katalog batu permata yang luas, mengungkapkan tantangan baru dalam layanan pelanggan. Berdasarkan survei yang dilakukan pada 161 pelanggan, terdapat 85,1% pelanggan mengalami kesulitan dalam mengingat nama batu permata yang telah dibeli, yang menunjukkan kebutuhan akan solusi teknologi untuk mempermudah identifikasi batu permata secara efisien. Hasil pelatihan menunjukkan bahwa model YOLOv7 memiliki performa tinggi dengan nilai rata-rata *precision (mAP)* sebesar 96,6%, *precision* sebesar 94,9%, dan *recall* sebesar 95,5%. Sistem ini diintegrasikan dengan aplikasi mobile berbasis Flutter untuk memproses deteksi secara real-time dengan latensi rendah menggunakan inferensi berbasis cloud. Penelitian ini berhasil membuktikan bahwa YOLOv7 dapat diterapkan secara efektif dalam konteks identifikasi batu permata, serta memberikan solusi praktis bagi industri perhiasan untuk mengoptimalkan efisiensi operasional.

Abstract. *The high consumer interest in gemstones at the Magic Crystals store, supported by a vast catalog of gemstones, has revealed new challenges in customer service. Based on a survey conducted with 161 customers, 85.1% reported difficulty remembering the names of the purchased gemstones, highlighting the need for a technological solution to facilitate efficient gemstone identification. The training results demonstrated that the YOLOv7 model achieved high performance with a mean Average Precision (mAP) of 96.6%, precision of 94.9%, and recall of 95.5%. The system was integrated into a Flutter-based mobile application to process real-time detection with low latency using cloud-based inference. This study successfully proved that YOLOv7 can be effectively applied in the context of gemstone identification, providing a practical solution for the jewelry industry to optimize operational efficiency.*



Copyright © [JITET](http://www.jitet.org) (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

1. PENDAHULUAN

Perkembangan teknologi digital dan media sosial telah merevolusi cara berbagai sektor bisnis beroperasi, termasuk industri batu permata. Platform seperti Instagram kini menjadi salah satu kanal utama untuk memperluas jangkauan pasar dan menarik pelanggan baru. Magic Crystals, yang telah

aktif di Instagram selama hampir empat tahun, menjadi salah satu contoh bisnis yang berhasil memanfaatkan potensi media sosial.

Dalam rentang 12 Juli 2024 hingga 9 Oktober 2024, Magic Crystals mencatatkan total 3.143.787 tayangan melalui kanal Instagram. Pertumbuhan pesat bisnis Magic Crystals telah meningkatkan jumlah pelanggan

secara signifikan, dengan banyak pelanggan membeli lebih dari satu jenis batu permata dalam satu pembelian.

Berdasarkan survei yang dilakukan terhadap 161 pelanggan Magic Crystals, sebanyak 67,1% responden melaporkan membeli 1-5 jenis batu permata dalam satu transaksi, sementara 16,8% membeli 6-10 jenis. Dengan banyaknya jenis batu yang dibeli, pelanggan sering kesulitan mengingat nama batu permata yang mereka miliki. Sebanyak 43,5% responden mengaku lupa mencatat nama batu yang dibeli. Sebanyak 65,8% responden melaporkan bahwa mereka telah menghubungi customer service lebih dari 6 kali untuk menanyakan nama batu yang tidak diingat.

Sebagai solusi, 98,1% responden percaya bahwa aplikasi yang mampu mendeteksi dan mengenali batu permata secara otomatis akan mempermudah mereka dalam mengidentifikasi jenis batu yang sulit diingat. Bahkan, 98,8% responden menyatakan bahwa mereka akan mempertimbangkan menggunakan aplikasi berbasis kamera yang dapat mendeteksi jenis batu permata secara *real-time*.

Teknologi *Computer Vision* seperti YOLOv7 (You Only Look Once) menawarkan solusi yang relevan untuk mengatasi permasalahan ini. Berdasarkan penelitian Wang, Bochkovskiy, dan Liao (2022), YOLOv7 merupakan model *object detection* terkini yang memiliki kecepatan dan akurasi tinggi dalam mendeteksi objek dari citra visual [1]. Dibandingkan dengan versi sebelumnya seperti YOLOv4 dan YOLOv5, YOLOv7 memiliki efisiensi lebih tinggi dalam memproses gambar dan mampu mendeteksi berbagai jenis objek secara *real-time*.

Dengan menggunakan YOLOv7, pelanggan dapat mengidentifikasi nama batu permata melalui gambar atau foto yang diambil dengan perangkat mereka. Sistem ini diintegrasikan dengan aplikasi mobile yang memproses gambar melalui server cloud, sehingga hasil deteksi dapat dikirimkan kembali kepada pengguna dalam waktu singkat.

2. TINJAUAN PUSTAKA

2.1. Implementasi Sistem

Implementasi sistem adalah proses penerapan sistem informasi manajemen yang mencakup penilaian kebutuhan, pemilihan dan

pengembangan sistem, pelatihan pengguna, uji coba, evaluasi, hingga pemeliharaan berkelanjutan [2]. Implementasi sistem deteksi batu permata berbasis YOLOv7 pada penelitian ini mencakup pelatihan model menggunakan dataset terannotasi dan integrasi dengan aplikasi mobile untuk deteksi real-time melalui kamera perangkat. Proses inferensi dilakukan menggunakan API berbasis cloud, memungkinkan visualisasi bounding box dan label objek secara langsung. Saat ini, integrasi sistem hanya mencakup penggunaan kamera perangkat untuk mendeteksi batu permata secara real-time, namun sistem memiliki ruang pengembangan lebih lanjut..

2.2. Deteksi

Menurut Goodfellow et al. (2016), deteksi dalam konteks kecerdasan buatan (AI) dan visi komputer mengacu pada kemampuan sistem untuk mengenali dan mengklasifikasikan objek atau pola dalam data visual, seperti gambar atau video [3]. Di bidang ini, deteksi sering kali melibatkan penggunaan algoritma canggih seperti jaringan saraf dalam (deep neural networks) yang memproses data masukan secara otomatis dan menentukan apakah terdapat objek atau elemen yang memenuhi kriteria tertentu. Dalam beberapa tahun terakhir, pendekatan berbasis pembelajaran mendalam seperti YOLO (Redmon et al., 2016) telah merevolusi kemampuan deteksi dengan tingkat akurasi yang semakin tinggi [4].

2.3. YOLO (You Only Look Once) v7

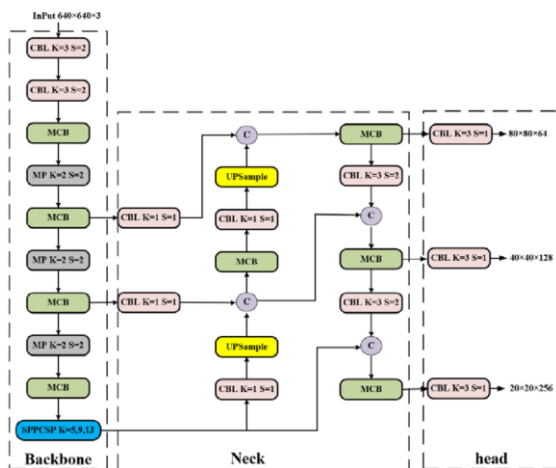
YOLO (You Only Look Once) adalah salah satu model deteksi objek yang populer dalam bidang *Computer Vision* dan *Deep Learning*. Model ini dikenal karena kemampuannya dalam melakukan deteksi objek dengan kecepatan tinggi melalui satu kali proses (*single forward pass*) dalam jaringan saraf tiruan [4].

Versi terbaru, YOLOv7, menawarkan peningkatan dibandingkan pendahulunya, dengan fokus pada efisiensi dan akurasi deteksi. Wang et al. (2022) menjelaskan bahwa YOLOv7 dirancang untuk mendeteksi objek secara real-time, memungkinkan pengenalan dan klasifikasi objek dengan kecepatan tinggi tanpa mengorbankan tingkat akurasi [1].

YOLOv7 melampaui semua detektor objek yang dikenal dalam hal kecepatan dan akurasi dalam rentang 5 FPS hingga 160 FPS, dan

memiliki akurasi tertinggi 56,8% AP di antara semua detektor objek real-time yang dikenal dengan 30 FPS atau lebih tinggi pada GPU V100.

YOLOv7 menggunakan arsitektur yang terdiri dari: (1) Backbone berbasis ELAN (Efficient Layer Aggregation Network), (2) Neck dengan Path Aggregation Network (PANet), dan (3) Head yang memprediksi *bounding box* pada tiga skala berbeda. [5]



Gambar 1 Diagram Struktur YOLOv7

2.4. Batu Permata

Batu permata adalah mineral, batu, atau bahan organik tertentu yang dipilih untuk digunakan sebagai perhiasan atau ornamen karena kelangkaan, keindahan, dan daya tahannya [6]. Agar layak dijadikan perhiasan, batu permata harus memiliki kekerasan yang cukup, yang umumnya diukur menggunakan Skala Mohs dengan rentang 1 (paling lunak) hingga 10 (paling keras). Batu yang lebih keras, seperti berlian (10 pada Skala Mohs), lebih tahan lama untuk penggunaan sehari-hari dibandingkan dengan batu yang lebih lunak, seperti opal (sekitar 5,5–6 pada Skala Mohs). Nilai batu permata ditentukan oleh karakteristik seperti warna, kejernihan, dan kelangkaannya.

Batu permata yang digunakan dalam penelitian ini terdiri dari berbagai jenis mineral dengan karakteristik fisik dan kimia yang berbeda. Amethyst, Citrine, dan Clear Quartz merupakan varietas kuarsa (SiO_2) dengan warna yang dipengaruhi oleh kandungan unsur tertentu, seperti besi. Aquamarine dan Emerald termasuk dalam kelompok beril ($\text{Be}_3\text{Al}_2(\text{SiO}_3)_6$), yang dikenal karena kejernihan dan warna khasnya. Sementara itu, Peridot


berasal dari mineral olivin, Garnet dari kelompok silikat kompleks, serta Diopside dari mineral piroksena. Obsidian berbeda karena merupakan kaca vulkanik alami tanpa struktur kristalin. Malachite merupakan mineral tembaga karbonat yang memiliki warna hijau terang, sedangkan London Blue Topaz adalah variasi topaz dengan warna biru tua. Moonstone, Labradorite, dan Sunstone termasuk dalam kelompok feldspar yang memiliki efek optik khas seperti adularescence dan labradorescence. Terakhir, Jade terdiri dari dua jenis mineral utama, yaitu nephrite dan jadeite, yang dikenal karena kekuatan dan nilai budayanya. Secara umum, batu-batu ini memiliki tingkat kekerasan yang bervariasi pada skala Mohs, sehingga cocok digunakan dalam berbagai aplikasi perhiasan maupun identifikasi berbasis sistem AI [6]

2.5. Cloud Computing dalam Pengolahan Data

Penggunaan cloud server dalam penelitian ini memungkinkan proses pengolahan gambar dan deteksi batu permata dilakukan secara terpusat pada server dengan kapasitas komputasi tinggi. Cloud computing menyediakan akses sumber daya komputasi secara on-demand melalui internet, sehingga memungkinkan sistem untuk bekerja secara lebih cepat, efisien, dan skalabel tanpa bergantung pada perangkat pengguna. Dengan pendekatan ini, sistem AI mampu melakukan deteksi secara real-time serta menghasilkan output yang optimal bagi pengguna [7].

2.6. Roboflow

Pada penelitian ini Roboflow digunakan sebagai Platform-as-a-Service (PaaS) yaitu model layanan komputasi awan yang menyediakan lingkungan kerja lengkap, termasuk infrastruktur, penyimpanan, dan alat pendukung, untuk mempermudah pembuatan, pengujian, dan penerapan aplikasi [8]. Dalam konteks visi komputer dan pengolahan data, PaaS memungkinkan pengguna menggunakan platform siap pakai untuk memproses data besar dan mengimplementasikan algoritma yang kompleks tanpa harus menangani pengaturan server atau infrastruktur [9].



Gambar 2 Platform-as-a-Service (PaaS)

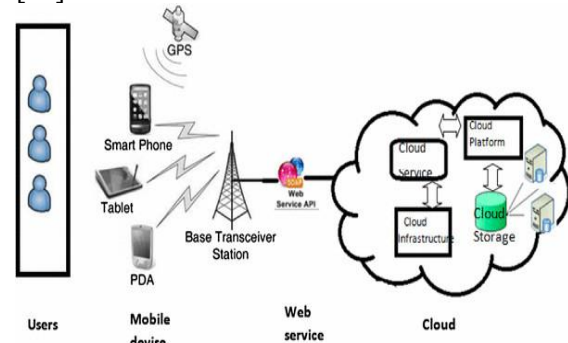
Roboflow menyediakan alat lengkap untuk mengunggah, mengelola, menganotasi, mengaugmentasi, melatih, dan mendeploy model melalui API, sehingga mempermudah proses pengembangan model. Selain itu, Roboflow juga menyajikan grafik hasil pelatihan dan perhitungan bounding box sehingga semuanya dilakukan secara otomatis tanpa perlu konfigurasi manual.

2.7. Mobile Application Development dan Mobile-Cloud Computing

Mobile Application Development adalah proses merancang, membuat, dan mengoptimalkan aplikasi untuk perangkat mobile seperti smartphone dan tablet [10]. Dalam konteks penelitian ini, pengembangan aplikasi mobile digunakan untuk menjalankan fungsi spesifik, yaitu memanfaatkan kamera perangkat seluler dalam menangkap gambar batu permata yang kemudian dikirim ke server cloud untuk diproses lebih lanjut. Teknologi mobile image capture memungkinkan aplikasi menggunakan kamera ponsel sebagai alat input utama, yang selanjutnya diintegrasikan dengan sistem berbasis cloud untuk analisis data. Penelitian oleh Manasi et al. (2022) menunjukkan bahwa integrasi antara perangkat mobile dan komputasi cloud dapat meningkatkan efisiensi energi serta mempercepat proses pengolahan data [11].

Mobile-Cloud Computing (MCC) merupakan konsep kolaborasi antara perangkat mobile dan cloud, di mana proses komputasi intensif dilakukan di server cloud, sementara perangkat mobile berfungsi sebagai antarmuka pengguna. Pendekatan ini memungkinkan pengolahan data kompleks, seperti pengenalan gambar dan analisis real-time, tanpa terbatas oleh kapasitas perangkat mobile. Menurut Dinh et al. (2013), MCC mampu mengatasi keterbatasan sumber daya komputasi dan penyimpanan pada perangkat mobile dengan

memanfaatkan infrastruktur cloud [12]. Arsitektur Mobile Cloud Computing menggambarkan bagaimana data dari perangkat mobile dikirim ke server untuk diproses, kemudian hasilnya dikembalikan ke pengguna [13].



Gambar 3 Mobile Cloud Computing Architecture

2.8. Penelitian Sebelumnya

Penelitian yang dilakukan saat ini berfokus pada pengembangan model deteksi batu permata berbasis YOLOv7 yang diintegrasikan dengan aplikasi mobile dan pemrosesan berbasis cloud. Sistem ini memungkinkan pelanggan untuk mengenali jenis batu permata secara otomatis melalui gambar yang diambil menggunakan kamera ponsel, yang kemudian dikirim ke server cloud untuk diproses menggunakan model YOLOv7. Pendekatan ini memungkinkan deteksi objek kecil dan kompleks secara real-time, sehingga meningkatkan efisiensi serta kemudahan bagi pengguna dalam mengidentifikasi produk tanpa bergantung pada interaksi manual dengan admin.

Beberapa penelitian sebelumnya telah mengkaji penerapan YOLOv7 dalam berbagai konteks. Oluwaseyi et al. (2023) membandingkan kinerja YOLOv5 dan YOLOv7 pada aplikasi Remote Weapon Station dan menunjukkan bahwa YOLOv7 unggul dalam recall [14]. Fu et al. (2023) menerapkan YOLOv7 untuk deteksi objek pada gambar drone dengan modifikasi untuk meningkatkan kemampuan deteksi objek kecil [15]. Ni (2022) menggunakan YOLOv7 untuk mendeteksi objek perhiasan seperti cincin dan anting dalam sistem pengawasan pintar [16]. Kusuma & Soewito (2023) mengimplementasikan YOLOv7 untuk deteksi multi-objek real-time pada perangkat mobile

[17], sedangkan Li et al. (2023) mengembangkan model YOLOv7 dengan penambahan modul Attention dan Dynamic Convolution yang meningkatkan performa deteksi objek kecil dengan peningkatan mAP sebesar 5,2% [18].

Selain itu, penelitian lain juga menunjukkan penggunaan model YOLO dalam berbagai domain, seperti Hesnanda (2025) yang mengimplementasikan YOLOv5 untuk mendeteksi korek api dalam konteks keamanan penerbangan menggunakan Roboflow sebagai platform anotasi dan augmentasi dataset [19], serta Golfantara (2024) yang menggunakan YOLOv8 untuk mengidentifikasi berbagai jenis rempah-rempah dengan tingkat akurasi mencapai 86% [20].

Meskipun berbagai penelitian tersebut menunjukkan efektivitas YOLO dalam deteksi objek, sebagian besar masih berfokus pada bidang keamanan, pengawasan, aerial imagery, maupun pengenalan objek umum. Perbedaan utama penelitian ini terletak pada penerapan YOLOv7 dalam konteks industri ritel batu permata yang diintegrasikan dengan aplikasi mobile dan pemrosesan berbasis cloud. Pendekatan ini memberikan kontribusi baru dalam pemanfaatan teknologi computer vision untuk meningkatkan efisiensi operasional serta pengalaman pelanggan, sekaligus menawarkan solusi praktis yang dapat langsung diimplementasikan dalam bisnis digital jewelry.

3. METODE PENELITIAN

3.1. Objek Penelitian

Objek pada penelitian ini adalah Magic Crystals, toko yang menyediakan berbagai macam batu permata dan kristal, yang legal dan terdaftar sebagai PT Magic Crystals Indonesia (Nomor: AHU-028632.AH.01.30.Tahun 2024) berdasarkan hukum Republik Indonesia. Dataset gambar diperoleh dari koleksi batu permata di toko Magic Crystals untuk memastikan relevansi dengan kondisi nyata.

3.2. Metodologi Penelitian

Proses model deteksi objek berbasis YOLOv7 dilakukan melalui delapan tahapan utama secara sistematis [21]

(1) *Image Acquisition*: Mengumpulkan 3.504 gambar batu permata dari koleksi 15 jenis batu permata milik Magic Crystals

menggunakan perangkat iPhone XR, iPhone 11, dan iPhone 14 Pro Max dengan ring light Midio RL30, dalam periode 15 September hingga 8 Oktober 2024.

(2) *Organization*: Dataset diorganisasi ke dalam *Training Set* (2.453 gambar, 70%), *Validation Set* (701 gambar, 20%), dan *Test Set* (350 gambar, 10%) menggunakan platform Roboflow.

(3) *Annotation*: Setiap gambar diberi label *bounding box* menggunakan platform Roboflow, menghasilkan 4.524 *bounding box* dari 3.504 gambar.

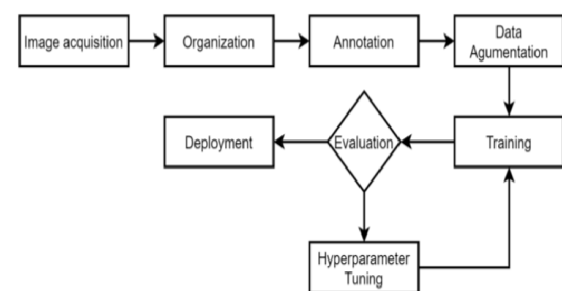
(4) *Data Augmentation*: Diterapkan teknik flip horizontal/vertikal, rotasi 90 derajat, dan rotasi acak (-15° hingga +15°) hanya pada *Training Set*, meningkatkan total gambar dari 3.504 menjadi 8.406 gambar.

(5) *Training*: Model YOLOv7 dilatih selama 140 epoch menggunakan dataset yang telah diaugmentasi di platform Roboflow.

(6) *Evaluation*: Model dievaluasi menggunakan metrik *mAP*, *Precision*, *Recall*, dan *F1-score*.

(7) *Hyperparameter Tuning*: Dilakukan review konfigurasi parameter untuk memastikan performa optimal.

(8) *Deployment*: Model diintegrasikan dengan aplikasi mobile berbasis Flutter melalui Roboflow API.

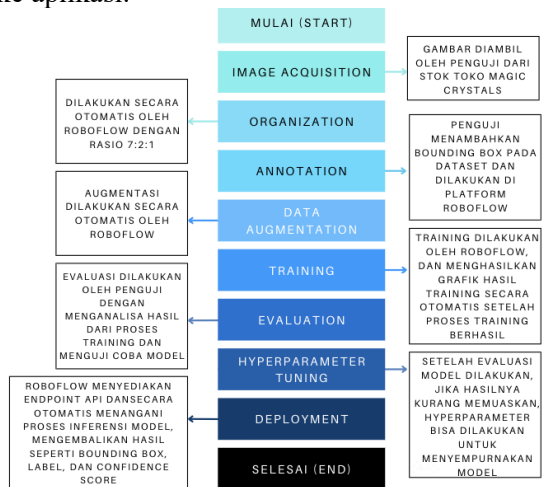


Gambar 4 Diagram Blok Proses Pelatihan YOLOv7

3.3. Rancangan Penelitian

Penelitian ini dirancang secara sistematis untuk model deteksi objek berbasis YOLOv7. Proses ini melibatkan beberapa tahap utama, yaitu pengumpulan gambar (*Image Acquisition*), organisasi data, anotasi data, augmentasi data, pelatihan model, evaluasi performa, penyempurnaan model melalui

tuning hyperparameter, hingga deploy model ke aplikasi.



Gambar 5 Rancangan Penelitian

Tabel 1 Jumlah Gambar Untuk Setiap Jenis Batu Permata

Batu Permata	Jumlah Gambar
<i>Amethyst</i>	279
<i>Aquamarine</i>	249
<i>Citrine</i>	224
<i>Clear Quartz</i>	210
<i>Diopside</i>	282
<i>Emerald</i>	228
<i>Garnet</i>	278
<i>Jade</i>	218
<i>Labradorite</i>	250
<i>London Blue Topaz</i>	201
<i>Malachite</i>	209
<i>Moonstone</i>	210
<i>Obsidian</i>	221
<i>Peridot</i>	237
<i>Sunstone</i>	208
Total	3.504

4. HASIL DAN PEMBAHASAN

4.1. Image Acquisition

Pengumpulan data dalam penelitian ini dilakukan pada periode 15 September 2024 hingga 8 Oktober 2024 dengan menggunakan metode fotografi langsung terhadap koleksi batu permata dari Magic Crystals. Dataset yang digunakan terdiri dari 3.504 gambar yang mencakup 15 jenis batu permata, yaitu Amethyst, Aquamarine, Citrine, Clear Quartz, Diopside, Obsidian, Garnet, Malachite, Peridot, Emerald, London Blue Topaz, Moonstone, Labradorite, Sunstone, dan Jade. Setiap jenis batu permata dikelompokkan ke dalam folder terpisah sesuai dengan labelnya untuk mempermudah proses pengelolaan data dan pelatihan model YOLOv7. Distribusi jumlah gambar pada masing-masing kelas dibuat relatif seimbang untuk menghindari bias pada model selama proses pelatihan.

Proses pengambilan gambar dilakukan secara manual oleh peneliti dengan bantuan admin Magic Crystals menggunakan beberapa perangkat smartphone, yaitu iPhone XR, iPhone 11, dan iPhone 14 Pro Max. Untuk memastikan kualitas pencahayaan yang optimal, digunakan ring light Midio RL30 sebagai sumber pencahayaan tambahan. Variasi kondisi pencahayaan diterapkan dalam proses pengambilan data, meliputi pencahayaan hangat (warm light), pencahayaan putih (white light), dan pencahayaan redup (dim light). Selain itu, setiap objek batu permata difoto dengan berbagai sudut pengambilan gambar, seperti tampilan atas, samping, dan perspektif tiga perempat, guna menangkap karakteristik visual secara menyeluruh.

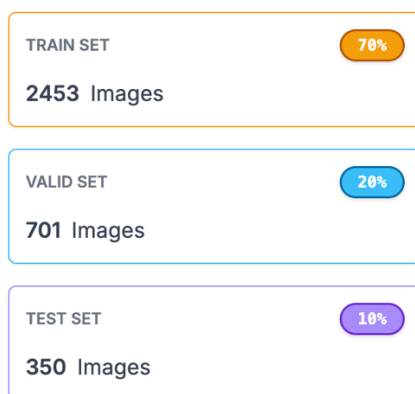


Gambar 6 Contoh Variasi Dataset Batu Permata Malachite

Variasi tambahan juga diterapkan pada tingkat kecerahan dan latar belakang untuk meningkatkan keragaman dataset. Latar belakang yang digunakan mencakup warna hitam, putih, dan pink, sehingga menciptakan kondisi visual yang lebih kompleks dan realistis. Variasi ini bertujuan untuk meningkatkan kemampuan generalisasi model dalam mendeteksi batu permata pada berbagai kondisi lingkungan. Dengan pendekatan ini, dataset yang dihasilkan diharapkan mampu mendukung performa model YOLOv7 dalam melakukan deteksi objek secara akurat dan robust dalam skenario penggunaan nyata.

4.2. Organization

Dataset yang digunakan dalam penelitian ini terdiri dari 3.504 gambar batu permata yang telah diorganisasikan secara otomatis menggunakan platform Roboflow ke dalam tiga subset utama, yaitu training set, validation set, dan test set.



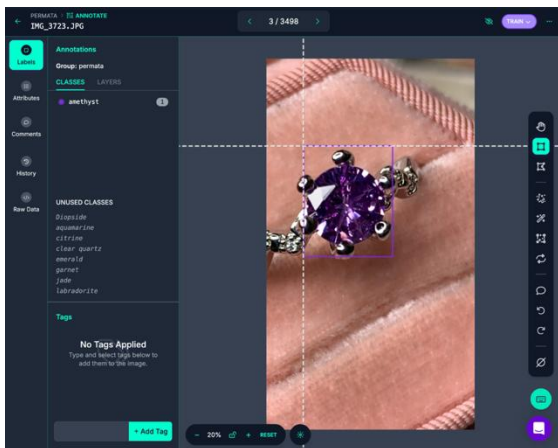
Gambar 7 Pembagian Dataset

Pembagian dataset ini bertujuan untuk memastikan proses pelatihan, validasi, dan pengujian model YOLOv7 dilakukan secara terstruktur dan menghasilkan performa yang optimal. Sebanyak 2.453 gambar (70%) digunakan sebagai data pelatihan (training set) untuk melatih model dalam mengenali pola dari 15 jenis batu permata dengan berbagai variasi sudut pengambilan gambar, kondisi pencahayaan (warm light, white light, dan dim light), serta latar belakang yang beragam.

Selanjutnya, sebanyak 701 gambar (20%) digunakan sebagai data validasi (validation set) untuk mengevaluasi performa model selama proses pelatihan dan mencegah terjadinya overfitting. Sementara itu, sebanyak 350 gambar (10%) digunakan sebagai data pengujian (test set) untuk mengukur kinerja model secara independen setelah proses pelatihan selesai. Data uji ini tidak terlibat dalam proses pelatihan maupun validasi, sehingga hasil evaluasi yang diperoleh dapat memberikan gambaran objektif mengenai kemampuan model YOLOv7 dalam mendeteksi dan mengklasifikasikan batu permata pada kondisi nyata.

4.3. Annotation

Proses anotasi dataset dalam penelitian ini dilakukan menggunakan platform Roboflow, di mana setiap gambar diberi label sesuai dengan jenis batu permata, seperti Amethyst, Aquamarine, Citrine, Clear Quartz, Diopside, Obsidian, Garnet, Malachite, Peridot, Emerald, London Blue Topaz, Moonstone, Labradorite, Sunstone, dan Jade. Anotasi dilakukan dengan metode bounding box, yaitu penandaan objek menggunakan kotak yang mengelilingi batu permata dalam gambar.



Gambar 8 Contoh Proses Pelabelan Batu Permata Amethyst

Bounding box ini memberikan informasi penting kepada model YOLOv7 mengenai lokasi dan ukuran objek, serta dilengkapi dengan label kategori untuk setiap jenis batu permata. Dataset yang telah dianotasi kemudian menghasilkan struktur data yang lengkap, termasuk koordinat objek dan label kelas, yang digunakan sebagai input utama dalam proses pelatihan model.

Number of Images	Number of Annotations	Average Image Size
3504	4524	6.97 mp

Gambar 9 Jumlah Anotasi

Hasil anotasi menunjukkan bahwa dari total 3.504 gambar terdapat 4.524 bounding box, yang mengindikasikan bahwa beberapa gambar mengandung lebih dari satu objek. Dataset ini memiliki rata-rata resolusi sebesar 6,97 megapiksel, sehingga memberikan detail visual yang cukup untuk proses deteksi.

Tabel 2 Jumlah pembagian anotasi setiap kelas

Class	Train	Valid	Test	Total
Amethyst	216	57	26	299
Aquamarine	390	123	71	584
Citrine	223	42	32	297
Clear Quartz	231	62	26	319
Diopside	246	66	25	337
Emerald	136	42	22	200
Garnet	209	69	41	319
Jade	291	101	61	453
Labradorite	252	72	42	366
London Blue Topaz	140	40	21	201

Malachite	188	53	17	258
Moonstone	124	71	20	215
Obsidian	196	56	18	270
Peridot	120	35	24	179
Sunstone	167	40	20	227

Distribusi anotasi pada setiap kelas telah dibagi ke dalam subset train, validation, dan test untuk memastikan keseimbangan data dalam proses pelatihan dan evaluasi model. Pembagian ini memungkinkan model YOLOv7 untuk belajar secara optimal dari berbagai variasi data sekaligus mempertahankan kemampuan generalisasi yang baik dalam mendeteksi batu permata pada kondisi yang beragam.


4.4. Data Augmentation

Data augmentasi merupakan teknik yang diterapkan dalam penelitian ini untuk memperluas dan memperkaya variasi dataset. Proses augmentasi dilakukan secara otomatis menggunakan platform Roboflow dengan menerapkan beberapa teknik transformasi, yaitu flip, rotasi 90 derajat, dan rotasi acak. Teknik flip dilakukan dengan pencerminan gambar secara horizontal dan vertikal untuk menciptakan variasi orientasi objek. Selanjutnya, rotasi 90 derajat dilakukan dengan memutar gambar searah jarum jam (clockwise), berlawanan arah jarum jam (counter-clockwise), serta rotasi 180 derajat (upside down) untuk menghasilkan variasi sudut pandang objek. Selain itu, rotasi acak diterapkan dalam rentang sudut antara -15° hingga $+15^\circ$ untuk mensimulasikan variasi kecil dalam orientasi objek.

Preprocessing	Auto-Orient: Applied Resize: Stretch to 640x640
Augmentations	Outputs per training example: 3 Flip: Horizontal, Vertical 90° Rotate: Clockwise, Counter-Clockwise, Upside Down Rotation: Between -15° and $+15^\circ$


Gambar 10 Detail Preprocessing dan Augmentasi Data pada Dataset Penelitian Menggunakan Roboflow

Pada tahap preprocessing, gambar juga mengalami penyesuaian otomatis berupa orientasi (auto-orient) serta perubahan ukuran menjadi resolusi 640×640 piksel (resize: stretch to 640×640). Penyesuaian ini dilakukan untuk memastikan seluruh gambar memiliki format yang konsisten dan sesuai dengan kebutuhan model YOLOv7. Proses augmentasi ini hanya diterapkan pada data pelatihan (training set), sedangkan subset data validasi dan pengujian tetap menggunakan gambar asli tanpa modifikasi guna menjaga objektivitas evaluasi model.



Gambar 11 Detail Dataset Setelah Augmentasi

Setelah proses augmentasi dilakukan, jumlah dataset meningkat dari 3.504 gambar menjadi 8.406 gambar. Dataset yang telah diaugmentasi kemudian diorganisasikan kembali ke dalam tiga subset utama, yaitu training set sebanyak 7.355 gambar (87%), validation set sebanyak 701 gambar (8%), dan test set sebanyak 350 gambar (4%).



Gambar 12 Pembagian Dataset Setelah Augmentasi

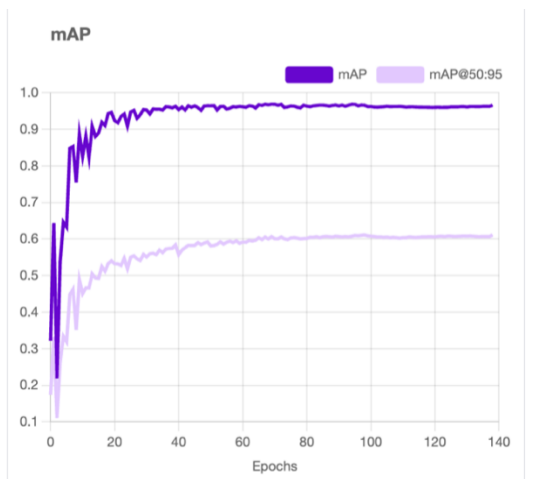
Pembagian ini bertujuan untuk memastikan model dapat dilatih secara optimal, sekaligus

dievaluasi secara objektif terhadap kemampuan generalisasi. Variasi data yang dihasilkan dari proses augmentasi ini diharapkan dapat meningkatkan kemampuan model dalam mendeteksi dan mengklasifikasikan batu permata pada berbagai kondisi pencahayaan, sudut pengambilan gambar, dan latar belakang yang beragam.

4.5. Training


Proses *training* dilakukan di Roboflow menggunakan model YOLOv7 dengan dataset yang sudah diaugmentasi dan terdiri dari 8.406 gambar yang terbagi menjadi 7.355 gambar untuk *Training Set* (87%), 701 gambar untuk *Validation Set* (8%), dan 350 gambar untuk *Test Set* (4%). Proses pelatihan dilaksanakan menggunakan platform Roboflow, yang menyediakan alat untuk augmentasi dataset, pelatihan model, dan evaluasi performa. Proses pelatihan dilakukan sebanyak 140 *epoch*, *epoch* adalah istilah yang digunakan dalam pelatihan model machine learning, khususnya pada neural network, untuk menggambarkan satu putaran penuh dari proses pelatihan model menggunakan seluruh dataset. yang merepresentasikan jumlah iterasi penuh pada seluruh dataset, sehingga memastikan model mencapai performa maksimal tanpa mengalami *overfitting*. Data dilatih dalam batch kecil untuk mempercepat proses pelatihan sekaligus memanfaatkan kapasitas memori GPU secara efisien.

Hasil pelatihan ditunjukkan melalui grafik evaluasi metrik seperti *mean Average Precision (mAP)*, *Box Loss*, *Class Loss*, dan *Object Loss*, yang menunjukkan tren penurunan loss secara konsisten dan stabil hingga konvergensi pada *epoch* terakhir yang dihasilkan secara otomatis oleh roboflow ketika proses training selesai.



Gambar 13 Grafik Mean Average Precision (mAP) Model YOLOv7 Berdasarkan Jumlah Epoch


Grafik mAP menunjukkan peningkatan yang signifikan pada awal pelatihan, dengan konvergensi yang stabil setelah sejumlah epoch tertentu. Hal ini mencerminkan bahwa model secara bertahap belajar untuk mendeteksi objek dengan lebih akurat seiring waktu. Kurva mAP@50:95 sedikit lebih rendah dibandingkan dengan mAP@50, karena mAP@50:95 mengukur performa deteksi dalam berbagai threshold IoU, sehingga lebih ketat. Namun, stabilitas kurva menunjukkan bahwa model bekerja baik pada berbagai tingkat ketelitian.



Gambar 14 Grafik Box Loss terhadap Jumlah Epochs selama proses pelatihan YOLOv7


Box Loss menurun secara signifikan selama pelatihan, terutama pada awal epoch. Penurunan ini menunjukkan bahwa model

semakin baik dalam memprediksi lokasi kotak pembatas (bounding box) yang sesuai dengan posisi objek yang sebenarnya.



Gambar 15 Grafik Class Loss Model YOLOv7 Berdasarkan Jumlah Epoch

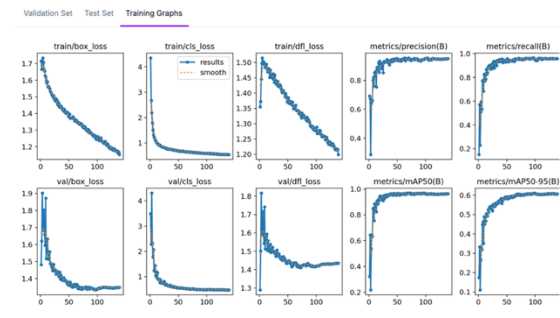
Class Loss menurun tajam di awal pelatihan, kemudian mendekati nilai mendatar saat pelatihan berlangsung. Penurunan ini menunjukkan bahwa model semakin akurat dalam mengklasifikasikan objek ke dalam kelas yang benar.



Gambar 16 Grafik Object Loss Model YOLOv7 Berdasarkan Jumlah Epoch

Object Loss menurun tajam pada tahap awal pelatihan, kemudian mulai mendekati nilai mendatar seiring bertambahnya epoch. Penurunan ini menunjukkan bahwa model

semakin baik dalam mendeteksi keberadaan objek dalam gambar secara akurat.



Gambar 17 Grafik Performa Model YOLOv7 Selama Proses Pelatihan Berdasarkan Berbagai Metrik

Grafik ini menunjukkan perkembangan performa model dari awal hingga akhir pelatihan, dengan berbagai metrik penting seperti *Precision*, *Recall*, dan *mAP* pada *setiap epoch*.

Selama proses pelatihan, performa model YOLOv7 dievaluasi menggunakan berbagai metrik, termasuk train loss, validation loss, serta metrik evaluasi seperti precision, recall, dan mean Average Precision (mAP). Nilai train box loss menunjukkan penurunan yang stabil dari awal hingga akhir epoch, yang mengindikasikan bahwa model semakin akurat dalam menentukan posisi bounding box objek. Hal serupa juga terlihat pada train class loss yang menurun secara signifikan, menunjukkan peningkatan kemampuan model dalam mengklasifikasikan objek ke dalam kelas yang tepat. Selain itu, train DFL (Distribution Focal Loss) juga mengalami penurunan yang konsisten, yang mencerminkan peningkatan presisi dalam distribusi prediksi bounding box.


Dari sisi metrik evaluasi, nilai precision menunjukkan peningkatan yang cepat pada tahap awal pelatihan dan mencapai konvergensi mendekati 1.0, yang menandakan bahwa model mampu meminimalkan kesalahan prediksi positif palsu. Sementara itu, nilai recall juga meningkat secara bertahap hingga mendekati nilai optimal, yang menunjukkan kemampuan model dalam mendeteksi sebagian besar objek yang ada dalam dataset. Evaluasi pada data validasi menunjukkan tren yang serupa, di mana validation box loss, validation class loss, dan validation DFL loss mengalami penurunan yang stabil. Hal ini menunjukkan bahwa model tidak hanya belajar dengan baik pada data

pelatihan, tetapi juga mampu melakukan generalisasi dengan baik pada data yang belum pernah dilihat sebelumnya.

Selain itu, nilai mAP50 yang mendekati 1.0 menunjukkan bahwa model memiliki kemampuan deteksi objek yang sangat baik pada threshold IoU sebesar 50%. Sementara itu, nilai mAP50-95 yang juga mengalami peningkatan menunjukkan bahwa model tetap mampu mempertahankan akurasi pada berbagai tingkat overlap yang lebih ketat. Secara keseluruhan, hasil pelatihan ini menunjukkan bahwa model YOLOv7 mampu mengenali dan mendeteksi batu permata dengan performa yang tinggi, meskipun dataset yang digunakan memiliki variasi kondisi yang kompleks.

4.6. Evaluation


Pada tahap ini dilakukan evaluasi terhadap performa model YOLOv7 menggunakan subset validasi dan pengujian untuk menilai kemampuan model dalam mendeteksi serta mengklasifikasikan objek secara akurat. Hasil evaluasi menunjukkan bahwa model mencapai nilai mean Average Precision (mAP) sebesar 96,6%, precision sebesar 94,9%, dan recall sebesar 95,5%, yang mengindikasikan performa deteksi yang sangat baik.



Gambar 18 Hasil Evaluasi Akhir Model YOLOv7


Nilai ini menunjukkan bahwa model mampu mengenali sebagian besar objek dengan tingkat kesalahan yang rendah, serta memiliki keseimbangan yang baik antara ketepatan prediksi dan kemampuan deteksi objek secara menyeluruh.

Analisis lebih lanjut berdasarkan kelas menunjukkan bahwa beberapa kategori batu permata memiliki performa sangat tinggi dengan nilai mAP mencapai 100%, seperti Emerald, London Blue Topaz, Obsidian, Peridot, dan Sunstone.



Gambar 19 Rata-Rata Precision (mAP50) Berdasarkan Kelas pada Dataset Validasi Model YOLOv7

Namun, terdapat beberapa kelas dengan performa yang sedikit lebih rendah, seperti Aquamarine, Citrine, dan Labradorite, yang disebabkan oleh kemiripan karakteristik visual antar kelas atau variasi kondisi pencahayaan dan tekstur.




Gambar 20 Rata-Rata Precision (mAP50) Berdasarkan Kelas pada Dataset Pengujian Model YOLOv7

Pada subset pengujian, rata-rata nilai mAP mencapai 96%, dengan sebagian besar kelas menunjukkan performa yang konsisten, meskipun masih terdapat beberapa kelas dengan nilai lebih rendah akibat kompleksitas visual objek.



Gambar 21 Contoh eteksi akurat objek Clear Quartz dengan tingkat kepercayaan 94%

Visualisasi hasil deteksi menunjukkan bahwa model mampu menghasilkan prediksi yang akurat dengan tingkat kepercayaan tinggi pada kondisi pencahayaan yang baik dan objek yang jelas.



Gambar 22 Contoh Deteksi akurat objek London Blue Topaz dengan tingkat kepercayaan 55.72%

Namun, pada beberapa kasus, model menghasilkan deteksi dengan confidence score rendah meskipun klasifikasi sudah benar, yang umumnya disebabkan oleh kualitas gambar yang kurang optimal atau kemiripan warna antar objek.




Gambar 23 Contoh missed detection pada objek Labradorite

Selain itu, ditemukan beberapa kasus missed detection (false negative), di mana objek tidak terdeteksi akibat ukuran yang terlalu kecil, tertutup sebagian, atau kondisi pencahayaan yang tidak sesuai dengan data pelatihan.



Gambar 24 Kesalahan klasifikasi model, di mana objek asing salah diklasifikasikan sebagai "Garnet"

Terdapat pula kasus kesalahan klasifikasi (false positive), di mana objek diklasifikasikan secara tidak tepat akibat kemiripan fitur visual seperti warna dan tekstur antar kelas.



Gambar 25 Deteksi objek dalam kondisi ekstrem dengan latar belakang yang rumit

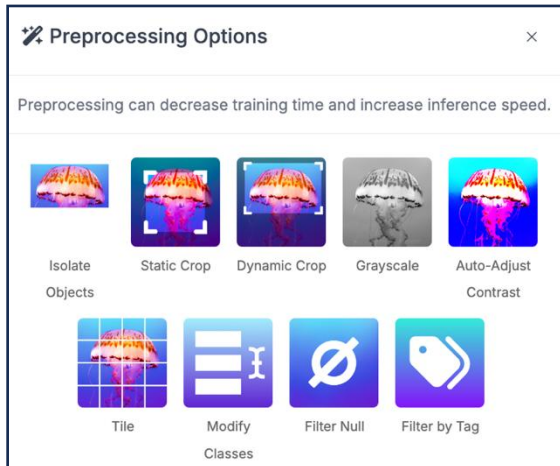
Pada kondisi ekstrem, seperti pencahayaan rendah atau latar belakang yang kompleks, performa model cenderung menurun, meskipun secara umum model masih mampu memberikan hasil deteksi yang cukup baik. Secara keseluruhan, hasil evaluasi ini menunjukkan bahwa model YOLOv7 memiliki kemampuan deteksi yang tinggi dan robust, namun tetap memiliki keterbatasan pada kondisi visual yang kompleks, yang menjadi area potensial untuk pengembangan lebih lanjut.

4.7. Hyperparameter Tuning

Pada penelitian ini, proses pelatihan model YOLOv7 dilakukan menggunakan konfigurasi hyperparameter default tanpa dilakukan tuning lebih lanjut. Keputusan ini didasarkan pada hasil performa model yang telah memenuhi ekspektasi penelitian, dengan nilai mean Average Precision (mAP) sebesar 96,6%, precision sebesar 94,9%, dan recall sebesar 95,5% pada subset validasi. Hasil tersebut menunjukkan bahwa konfigurasi awal sudah cukup optimal dalam mendeteksi dan mengklasifikasikan objek pada dataset yang digunakan. Selain itu, hyperparameter tuning yang tidak dilakukan secara hati-hati berpotensi menyebabkan overfitting, sehingga model kehilangan kemampuan generalisasi terhadap data baru. Oleh karena itu, dalam penelitian ini dipilih untuk mempertahankan konfigurasi default yang telah terbukti memberikan performa yang baik dan stabil.

Pengaturan hyperparameter seperti learning rate dan batch size disesuaikan secara otomatis oleh framework Roboflow sesuai dengan kebutuhan model YOLOv7, tanpa

adanya penyesuaian manual selama proses pelatihan. Pelatihan dilakukan selama 140 epoch, dengan pembagian dataset sebesar 70% untuk training set, 20% untuk validation set, dan 10% untuk test set.



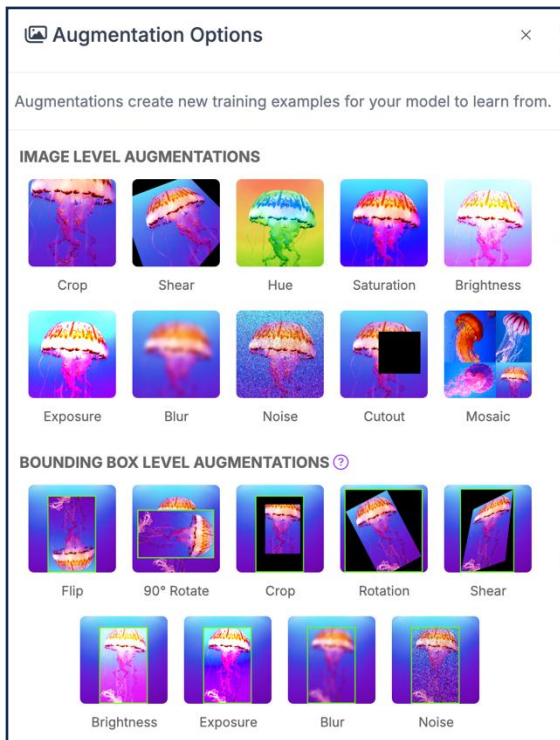
Gambar 26 Pilihan Preprocessing pada Roboflow

Pada tahap preprocessing, seluruh gambar diseragamkan menjadi resolusi 640×640 piksel, serta dilakukan penyesuaian orientasi (auto-orient) untuk memastikan konsistensi data.

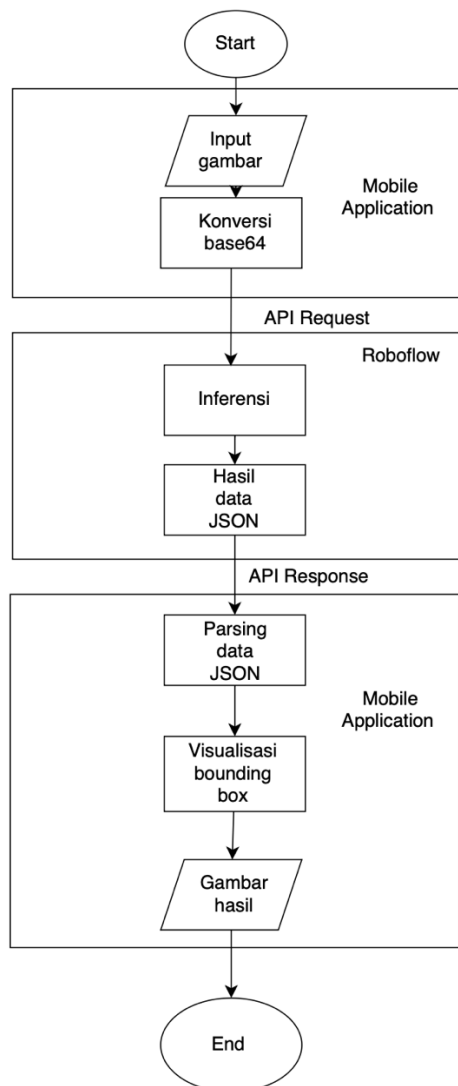
Selain itu, proses augmentasi diterapkan pada data pelatihan dengan teknik seperti flip (horizontal dan vertikal), rotasi 90 derajat, serta penambahan grayscale pada sebagian data untuk memperkaya variasi dataset. Konfigurasi anchor box yang digunakan juga mengikuti pengaturan default dari YOLOv7 tanpa modifikasi tambahan.

Meskipun hasil yang diperoleh sudah optimal, pengembangan lebih lanjut masih memungkinkan untuk meningkatkan performa model melalui proses hyperparameter tuning. Beberapa pendekatan yang dapat dilakukan antara lain penambahan jumlah dataset untuk meningkatkan representasi data, penerapan preprocessing tambahan seperti penyesuaian kontras atau cropping dinamis, serta eksplorasi teknik augmentasi lain seperti penambahan noise, mosaic, atau shear. Selain itu, pengaturan parameter pelatihan seperti jumlah epoch dan proporsi pembagian dataset juga dapat disesuaikan untuk mencapai konvergensi yang lebih optimal. Dengan pendekatan ini, model diharapkan dapat memiliki kemampuan generalisasi yang lebih baik dalam berbagai kondisi penggunaan nyata.

4.8. Deployment



Gambar 27 Opsi Augmentasi pada Roboflow



Gambar 28 Flowchart Alur Proses Inferensi Aplikasi Flutter dengan Roboflow API

Proses inferensi dalam penelitian ini dimulai ketika pengguna mengakses aplikasi mobile berbasis Flutter dan mengambil gambar batu permata menggunakan kamera atau memilih gambar dari galeri. Gambar yang telah dipilih kemudian dikonversi ke dalam format Base64, yang memungkinkan data gambar dikodekan menjadi bentuk teks sehingga dapat dikirim melalui protokol HTTP. Selanjutnya, data gambar dalam format Base64 dikirimkan ke endpoint API Roboflow menggunakan metode HTTP POST. Endpoint ini mengarahkan data ke model YOLOv7 yang telah dilatih sebelumnya untuk melakukan proses deteksi objek.

Pada sisi server, Roboflow memproses gambar menggunakan model YOLOv7 untuk mendeteksi objek dan menghasilkan output berupa bounding box, label objek, serta confidence score. Nilai confidence score dihitung berdasarkan probabilitas keberadaan objek (objectness score) yang dikalikan dengan Intersection over Union (IoU), yang mengukur kesesuaian antara bounding box prediksi dan ground truth. Jika tidak ada objek yang terdeteksi, sistem tetap mengembalikan respons tanpa informasi bounding box.

Hasil inferensi kemudian dikirim kembali ke aplikasi dalam format JSON untuk diproses lebih lanjut. Aplikasi Flutter melakukan parsing data tersebut untuk menentukan apakah terdapat objek yang terdeteksi. Jika tidak ada bounding box, aplikasi akan menampilkan gambar asli tanpa anotasi. Sebaliknya, jika objek terdeteksi, koordinat bounding box dan label akan digunakan untuk menampilkan hasil deteksi pada gambar. Visualisasi dilakukan dengan menggambar bounding box serta label beserta nilai confidence score pada gambar menggunakan fitur canvas melalui library custom_paint.



Gambar 29 Contoh hasil visualisasi bounding box

Secara keseluruhan, hasil akhir inferensi ditampilkan kepada pengguna dalam bentuk gambar yang telah dilengkapi dengan bounding box dan label objek, atau gambar asli apabila tidak terdapat deteksi. Proses ini memungkinkan pengguna untuk memperoleh hasil identifikasi batu permata secara cepat dan real-time melalui aplikasi mobile, tanpa

memerlukan interaksi tambahan dengan sistem eksternal.

5. KESIMPULAN

Berdasarkan hasil penelitian, dapat disimpulkan:

1. Model deteksi objek berbasis YOLOv7 berhasil dibuat untuk mendeteksi 15 jenis batu permata secara otomatis. Dataset terdiri dari 3.504 gambar yang setelah augmentasi diperluas menjadi 8.406 gambar.

2. Model YOLOv7 berhasil diintegrasikan dengan aplikasi mobile berbasis Flutter dan Roboflow API, memungkinkan deteksi batu permata secara *real-time* dengan visualisasi bounding box langsung kepada pengguna.

3. Model YOLOv7 menunjukkan performa tinggi dengan nilai rata-rata mAP sebesar 96% pada subset uji. Beberapa kelas seperti London Blue Topaz dan Peridot mencapai mAP sempurna (100%). Sistem terbukti andal dalam berbagai kondisi pencahayaan, sudut, dan latar belakang yang bervariasi.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Purwantoro, M.Kom. dan Ultach Enri, M.Kom. atas bimbingan dan arahnya, serta kepada tim Magic Crystals yang telah memberikan data dan kerja sama dalam penelitian ini.

DAFTAR PUSTAKA

- [1] Wang, C. Y., Bochkovskiy, A., & Liao, H. Y. M. (2022). YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. arXiv preprint arXiv:2207.02696.
- [2] Rahmawati, S., Juledi, A., & Sihombing, V. (2024). Implementasi Sistem Informasi Manajemen dalam Perguruan Tinggi: Studi Kasus tentang Efisiensi Operasional dan Pelayanan Mahasiswa. Jurnal Ilmu Komputer dan Sistem Informasi (JIKOMSI), 7, 75–77. <https://doi.org/10.55338/jikoms.v7i1.2716>
- [3] Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.
- [4] Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. In Proceedings of the IEEE Conference on CVPR, 779–788.
- [5] Zhang, L., Du, X., Zhang, R., & Zhang, J. (2023). A Lightweight Detection Algorithm for Unmanned Surface Vehicles Based on Multi-Scale Feature Fusion. doi: 10.20944/preprints202306.0780.v1
- [6] Schumann, W. (2013). Gemstones of the World (5th ed.). Sterling Publishing.
- [7] Mittal, A. (2025). (detail referensi belum ditemukan)
- [8] Armbrust, M., et al. (2010). A View of Cloud Computing. Communications of the ACM, 53(4), 50–58.
- [9] Sharma, S., et al. (2018). (detail referensi belum ditemukan)
- [10] Proietti Mattia, G., & Beraldi, R. (2021). Leveraging Reinforcement Learning for online scheduling of real-time tasks in the Edge/Fog-to-Cloud computing continuum. Sapienza University of Rome.
- [11] Manasi, A., Panchanadeswaran, S., Sours, E., & Lee, S. J. (2022). Mirroring the bias: gender and artificial intelligence. Gender, Technology and Development. <https://doi.org/10.1080/09718524.2022.2128254>
- [12] Dinh, H. T., et al. (2013). A Survey of Mobile Cloud Computing: Architecture, Applications, and Approaches. Wireless Communications and Mobile Computing, 13, 1587–1611. <https://doi.org/10.1002/wcm.1203>
- [13] Jemal, H., Kechaou, Z., & Ben Ayed, M. (2016). An enhanced healthcare system in mobile cloud computing environment. Vietnam Journal of Computer Science, 3. <https://doi.org/10.1007/s40595-016-0076-y>
- [14] Oluwaseyi, O., Irhebhude, M., & Ewwiekpaefe, A. (2023). A Comparative Study of YOLOv5 and YOLOv7 Object Detection Algorithms. Journal of Machine Learning and Computer Vision.
- [15] Fu, X., Wei, G., Yuan, X., Liang, Y., & Bo, Y. (2023). Efficient YOLOv7-Drone: An Enhanced Object Detection Approach for Drone Aerial Imagery. Journal of Applied Computer Science and AI Research.
- [16] Ni, W. (2022). Implementation of a CNN-based Object Detection Approach for Smart Surveillance Applications. International Journal of Advanced Computer Science and Applications, 14(12), 1215. doi: 10.14569/IJACSA.2023.0141215
- [17] Kusuma, P. C., & Soewito, B. (2023). Multi-Object Detection Using YOLOv7 Object Detection Algorithm on Mobile Device. Proceedings of the International Conference on Computer Vision Applications, 45–53.
- [18] Li, K., Wang, Y., & Hu, Z. (2023). Improved YOLOv7 for Small Object Detection Algorithm Based on Attention and Dynamic Convolution. Applied Sciences, 13, 9316.
- [19] Hesandanda, R. (2025). Implementasi Model YOLO V5 untuk Deteksi Korek Api dalam

- Keamanan Penerbangan. *Jurnal Informatika dan Teknik Elektro Terapan (JITET)*, 13(1). <https://doi.org/10.23960/jitet.v13i1.5553>
- [20] Golfantara, M. F. (2024). Penggunaan Algoritma YOLO V8 untuk Identifikasi Rempah-Rempah. *Jurnal Informatika dan Teknik Elektro Terapan (JITET)*, 12(3S1). <https://doi.org/10.23960/jitet.v12i3S1.5221>
- [21] Chen, Q., Wan, L., Ravichandran, P., Pan, Y.-J., & Chang, Y. (2022). Vision-based Impedance Control of a 7-DOF Robotic Manipulator for Pick-and-Place Tasks in Grasping Fruits. doi: 10.7939/r3-s2px-f403