


BAB III METODOLOGI PENELITIAN

3.1 Peta Jalan Penelitian


Rencana penelitian ini sejalan dengan peta jalan yang ada pada Universitas Siliwangi pada bagian *artificial intelligence*. Topik penelitian yang dipilih yaitu *computer vision and robotics* pada ranah *basic application of intelligence informatics*. Roadmap penelitian dapat dilihat pada gambar 3.1.



Gambar 3.1. Roadmap Penelitian (AIS Universitas Siliwangi, 2020)

3.2 Tahapan Penelitian

Metodologi penelitian ini dirancang untuk mengimplementasikan dan mengevaluasi model YOLOv11 dalam mendeteksi serta mengklasifikasikan lima jenis cacat pada permukaan rel kereta api secara multi-kelas. Penelitian ini melibatkan beberapa tahapan utama yang mencakup studi literatur, pengumpulan data, pra-pemrosesan, implementasi dan pelatihan model, serta evaluasi komprehensif melalui eksperimen sistematis seperti yang ditampilkan pada Gambar 3.2. Eksperimen dilakukan secara sistematis untuk mengidentifikasi pengaruh resolusi input, strategi augmentasi data, dan modifikasi arsitektur terhadap performa deteksi.



Gambar 3.2 Tahapan Penelitian

1. Studi Literatur

Sebelum mengembangkan model, dilakukan kajian pustaka untuk membangun pemahaman yang komprehensif mengenai metode deteksi cacat rel

dan implementasi deep learning dalam domain ini. Kajian ini meliputi telaah berbagai penelitian terdahulu terkait deteksi dan klasifikasi cacat rel, teknik deteksi objek berbasis *computer vision*, serta penggunaan arsitektur YOLO untuk tugas serupa. Selain itu, dilakukan kajian terhadap tantangan dalam deteksi multi-kelas seperti ketidakseimbangan kelas dan deteksi objek berukuran kecil, serta strategi yang dapat meningkatkan performa model seperti *transfer learning*, peningkatan resolusi input, dan augmentasi data.

Literatur dalam penelitian ini dikumpulkan dari berbagai sumber akademik, antara lain jurnal ilmiah, prosiding konferensi, dan artikel penelitian yang terindeks di IEEE Xplore, Springer, ScienceDirect, arXiv, MDPI, serta repositori akademik lain yang relevan. Selain itu, referensi pendukung juga diperoleh dari dokumentasi teknis resmi seperti Ultralytics documentation untuk YOLOv11, serta sumber web seperti blog teknis dan forum diskusi yang membahas implementasi praktis YOLO untuk tugas deteksi objek.

2. Pengumpulan Data

Dataset yang digunakan diperoleh dari repositori terbuka Roboflow Universe dengan nama "Clipping", yang merupakan dataset publik yang dapat diakses secara online. Dataset yang dipilih merupakan kumpulan gambar yang menampilkan berbagai kondisi cacat pada permukaan rel kereta api, yang diperoleh dari repositori terbuka Roboflow Universe. Koleksi data ini telah dilengkapi dengan anotasi dan mencakup lima kategori berbeda, yang terdiri dari empat tipe kerusakan spesifik yaitu *breaks*, *cracks*, *lightband*, dan *scars*, serta satu kategori untuk lokalisasi struktur rel (*rails*).

3. Pra-pemrosesan Data

Tahapan ini dimulai dengan dataset akan dipartisi ke dalam tiga kelompok utama dengan proporsi yang telah ditetapkan, yaitu 80% untuk data pelatihan, 10% untuk data validasi, dan 10% untuk data pengujian. Pembagian ini bertujuan untuk memastikan objektivitas dalam proses evaluasi performa model. Untuk memperkaya variasi data dan meningkatkan kemampuan adaptasi model.

4. Implementasi dan Pelatihan Model YOLOv11

YOLOv11s dipilih sebagai arsitektur utama dalam penelitian ini berdasarkan beberapa pertimbangan: (1) keseimbangan optimal antara akurasi deteksi dan kecepatan pemrosesan, aspek yang sangat vital dalam aplikasi inspeksi rel kereta api, (2) efisiensi komputasi dengan 9.4M parameter dan 21.6 GFLOPs yang memungkinkan *deployment* pada *hardware* dengan *resource terbatas*, dan (3) arsitektur modular yang terdiri dari *Backbone*, *Neck*, dan *Head* yang memfasilitasi ekstraksi fitur multi-skala untuk menangani objek dengan ukuran bervariasi. YOLOv11s merupakan varian small dari keluarga YOLOv11 yang mengadopsi beberapa peningkatan arsitektural dibanding versi sebelumnya, termasuk modul C2PSA (*Cross-Stage Partial with Self-Attention*) untuk menangkap informasi kontekstual secara lebih efektif, serta penggantian blok C2f dengan C3k2 yang lebih efisien.

Seluruh eksperimen pada penelitian ini dilatih menggunakan konfigurasi hyperparameter yang ditetapkan di awal, meliputi nilai *learning rate*, *batch size*, jenis *optimizer*, dan jumlah *epoch*. Nilai-nilai tersebut mengacu pada rekomendasi

konfigurasi YOLOv11 dan penyesuaian awal yang dilakukan secara terbatas, kemudian dipertahankan konstan pada setiap eksperimen agar perbandingan performa antar model tetap adil. Proses training dilakukan selama 100 *epoch* hingga model mencapai tingkat akurasi yang optimal dan *loss function* yang stabil (A Ilemobayo dkk., 2024).

Proses optimasi memainkan peran penting dalam meningkatkan akurasi dan efisiensi deteksi. Optimasi mencakup beberapa aspek seperti:

- a. Augmentasi Data, yaitu teknik manipulasi gambar seperti rotasi, pencerminan, perubahan pencahayaan, dan *cropping*, khusus untuk mengatasi permasalahan pada dataset. (Alfath Zulkarnain & Kusri, 2025)
- b. Penggunaan *Attention Mechanism*, penelitian ini dilakukan dengan menambahkan modul EMA (*Efficient Multi-scale Attention*) untuk membantu model menonjolkan fitur penting dan mengurangi gangguan dari pola latar yang mirip dengan cacat. EMA dipilih berdasarkan temuan penelitian terdahulu yang menunjukkan bahwa mekanisme atensi multi-skala dapat membantu deteksi objek kecil pada *remote sensing*. Pada penelitian ini, modul EMA diintegrasikan pada bagian *neck*, yaitu setelah blok C3K2 pada jalur penggabungan fitur, sehingga informasi dari beberapa level fitur dapat diperkuat sebelum masuk ke *head* deteksi. Eksperimen ini bertujuan untuk mengevaluasi apakah penambahan EMA dapat memberikan peningkatan performa dibandingkan modul atensi bawaan YOLOv11. (Wei dkk., 2025)

- c. Optimasi Resolusi Input Citra, eksperimen dilakukan dengan membandingkan dua tingkat resolusi: 640 piksel (*baseline*) dan 1280 piksel (*high resolution*). Peningkatan resolusi bertujuan untuk mempertahankan informasi spasial detail yang diperlukan untuk mendeteksi cacat berukuran kecil, dimana pada resolusi rendah informasi detail cenderung hilang akibat *downsampling* berturut-turut. Hipotesis yang diuji adalah bahwa resolusi tinggi akan meningkatkan kemampuan model dalam mendeteksi objek kecil karena mempertahankan representasi yang lebih detail. Pada resolusi 640 piksel, objek berukuran 10×10 piksel hanya menghasilkan representasi kurang dari 1 piksel, sedangkan resolusi 1280 piksel menghasilkan representasi sekitar 4 piksel.

Ketiga strategi tersebut akan diuji dalam penelitian ini untuk menemukan konfigurasi terbaik dalam mendeteksi multi-kelas cacat permukaan rel kereta api.

Pada eksperimen baseline YOLOv11, model dilatih menggunakan data asli tanpa augmentasi untuk memperoleh performa dasar. Selanjutnya, data hasil augmentasi digunakan pada seluruh eksperimen lanjutan, termasuk pengujian resolusi gambar, serta integrasi *attention mechanism*, guna meningkatkan kemampuan generalisasi model.

5. Evaluasi Model

Tahap evaluasi model melibatkan penilaian menyeluruh untuk memahami kualitas dan kinerja sistem yang telah dikembangkan. Evaluasi ini menggunakan tiga metrik utama: Precision, *Recall*, dan mAP (mean Average Precision). Evaluasi

juga dirancang untuk mengidentifikasi kemungkinan terjadinya *overfitting* atau *underfitting*, serta menentukan pengaturan jumlah *epoch* yang paling optimal untuk proses pelatihan. Hasil dari tahap evaluasi ini akan memberikan pemahaman mendalam mengenai kekuatan dan kelemahan model yang telah dikembangkan, sekaligus menyediakan dasar untuk perbaikan dan pengembangan model di masa yang akan datang.