

BAB I

PENDAHULUAN

Bab ini memberikan gambaran umum dan landasan dasar yang menjadi acuan dalam pelaksanaan penelitian. Pembahasan pada bab ini mencakup latar belakang permasalahan yang mendasari pemilihan topik, rumusan masalah yang akan diselesaikan, tujuan dan manfaat yang diharapkan dari penelitian, ruang lingkup untuk membatasi pokok bahasan, serta sistematika penulisan yang memberikan gambaran struktur keseluruhan dari laporan skripsi ini.

1.1.Latar Belakang

Beton merupakan material utama yang paling banyak digunakan dalam pembangunan infrastruktur fisik seperti gedung, jembatan, dan jalan raya. Seiring dengan berjalannya waktu, beban mekanis, serta faktor lingkungan, infrastruktur beton sangat rentan mengalami degradasi struktural. Salah satu indikator awal dari kerusakan struktural tersebut adalah munculnya retakan (*cracks*) pada permukaan beton. Inspeksi dan deteksi retakan secara dini sangat krusial untuk memantau kesehatan struktur dan mencegah kegagalan yang dapat membahayakan keselamatan jiwa. Secara konvensional, proses inspeksi retakan pada beton dilakukan secara visual oleh tenaga ahli manusia. Namun, metode manual ini memiliki kelemahan karena memakan waktu yang lama, rentan terhadap kelelahan pengamat, serta memiliki tingkat subjektivitas yang tinggi. Oleh karena itu, diperlukan sebuah sistem otomatisasi berbasis *Computer Vision* yang dapat mendeteksi retakan secara cepat, konsisten, dan akurat (Al-Hagri dkk., 2024).

Perkembangan teknologi *Artificial Intelligence* (AI), khususnya di bidang *Deep Learning*, telah memberikan solusi yang signifikan untuk tugas klasifikasi citra. Algoritma *Convolutional Neural Network* (CNN) merupakan metode yang paling tangguh dalam mengenali pola visual spasial pada citra digital (Aggarwal, 2023). Beberapa penelitian terdahulu, seperti yang dilakukan oleh Golding dkk. (2022) dan Zadeh dkk. (2023), telah berhasil mendeteksi retak beton dengan akurasi tinggi. Namun, mereka masih bergantung pada arsitektur CNN konvensional yang sangat berat seperti VGG16 dan ResNet50 memiliki ~138 juta parameter sehingga membutuhkan operasi komputasi matematis yang besar. Untuk mengatasi hal tersebut, pendekatan *Transfer Learning* menggunakan arsitektur ringan

seperti MobileNetV2 yang dirancang khusus untuk memangkas jumlah parameter dan operasi komputasi tanpa mengorbankan kemampuan ekstraksi fitur secara signifikan, hal ini dicapai melalui teknik *Depthwise Separable Convolution* dan *Inverted Residuals* sehingga parameternya turun drastis menjadi hanya sekitar 3,4 juta (Sandler dkk., 2018).

Evaluasi kinerja model pada kasus keselamatan infrastruktur tidak dapat hanya bergantung pada nilai akurasi kumulatif. Penelitian sebelumnya yang menggunakan arsitektur MobileNetV2 seperti Sardika dan Widhiarso (2025), Nguyen dkk. (2024), Rizki dkk. (2025) umumnya menyamaratakan semua bobot kesalahan prediksi. Dalam realitasnya, terdapat fenomena ketidakseimbangan risiko (*Asymmetric Misclassification Cost*). Analisis secara mendalam pada *Confusion Matrix* sangat diperlukan untuk melihat seberapa baik model dapat meminimalisir angka *False Negative* (kesalahan model yang memprediksi beton retak sebagai beton tidak retak). Kesalahan jenis ini memiliki risiko bahaya yang jauh lebih fatal dibandingkan *False Positive*. Untuk mengatasi masalah yang diabaikan oleh penelitian terdahulu tersebut, terdapat dua pendekatan algoritma yang dapat diuji: pertama, memanipulasi *Custom Decision Threshold* pada probabilitas akhir prediksi supaya memberikan *Threshold* probabilitas lebih besar terhadap kelas berisiko tinggi (*Positive (Cracked)*) dan kedua, menerapkan metode *Cost-Sensitive Learning* yang memberikan penalti nilai *loss* lebih berat terhadap kelas berisiko tinggi dengan cara memodifikasi parameter bobot kelas (*Class Weight*) secara langsung di dalam fungsi kerugian (*Loss Function*) model (Johnson & Khoshgoftaar, 2019).

Kinerja optimal dari model *Deep Learning* sangat bergantung pada stabilitas jaringan selama masa pelatihan (Yang, 2024). Penelitian yang sudah ada sebelumnya hanya berfokus pada hasil akhir performa model tanpa menyajikan analisis terkait *Hyperparameter Tuning* secara empiris. Padahal, konfigurasi *Hyperparameter* yang tepat mutlak diperlukan agar algoritma optimasi, seperti Adam (*Adaptive Moment Estimation*) (Kingma & Ba, 2015), dapat mencapai titik konvergensi dengan baik. Oleh karena itu, penelitian ini melakukan eksperimen *Hyperparameter Tuning* menggunakan pendekatan *One Factor at A Time* (OFAT). Pendekatan ini dipilih untuk mengisolasi dan menganalisis secara spesifik pengaruh dua variabel utama, yaitu *Learning Rate* dan *Batch Size*, secara bergantian (Yu, 2024).Eksplorasi ini dilakukan untuk mengetahui kestabilan dan ketangguhan dari model terhadap perubahan *Hyperparameter Tuning*. *Learning Rate* menentukan seberapa besar langkah pembaruan bobot jaringan pada setiap iterasi; nilai yang tidak tepat dapat memicu

fenomena *overfitting* sehingga model gagal konvergen secara stabil. Sementara itu, *Batch Size* memengaruhi jumlah data citra yang diproses dalam satu waktu; ukuran *batch* yang terlalu kecil dapat menghasilkan efek gangguan (*noise*) komputasi yang membuat pergerakan nilai *loss* fluktuatif, sedangkan ukuran yang lebih besar dapat mengoptimalkan paralelisme memori perangkat keras untuk memangkas waktu pelatihan secara efisien (Yang & Shami, 2020).

Berdasarkan permasalahan dan celah penelitian tersebut, skripsi ini bertujuan untuk mengimplementasikan arsitektur MobileNetV2 berbasis *Transfer Learning* untuk klasifikasi citra retak beton. Penelitian ini mencakup implementasi *Cost-Sensitive Learning*, penggunaan *Custom Decision Threshold*, serta pendekatan hibrida dari keduanya untuk menangani masalah pengabaian ketidakseimbangan risiko. Kemudian juga penerapan *Hyperparameter Tuning* yang dilakukan menggunakan pendekatan *One Factor at A Time* (OFAT) untuk mengeksplorasi pengaruh *Batch Size* dan *Learning Rate* secara independen. Selanjutnya, hasil penelitian akan disusun untuk bahan analisis secara empiris guna mengetahui performa model yang telah dilatih dan diuji. Penelitian diharapkan mampu mendapatkan kesimpulan atas berhasil tidaknya upaya penanganan *False Negative* yang telah dilakukan selama proses eksperimen.

1.2.Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, maka rumusan masalah dalam penelitian ini adalah:

1. Bagaimana mengimplementasikan algoritma *Deep Learning Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2 untuk tugas klasifikasi citra beton retak (*Cracked*) dan tidak retak (*Not Cracked*)?
2. Bagaimana pengaruh *Hyperparameter Tuning* (*Learning Rate* dan *Batch Size*) menggunakan pendekatan *One Factor at A Time* (OFAT) terhadap dinamika kurva pembelajaran (*learning curve*) khususnya terkait fenomena *overfitting*, efek gangguan komputasi (*noise*) dan efisiensi waktu pelatihan?
3. Bagaimana perbandingan tingkat efektivitas antara metode *Cost-Sensitive Learning*, modifikasi *Custom Decision Threshold*, serta pendekatan hibrida keduanya dalam meminimalisir angka *False Negative* dibandingkan dengan model *Baseline*?

1.3. Tujuan dan Manfaat

1. Tujuan Penelitian

Tujuan yang ingin dicapai dalam penelitian ini adalah:

- a. Membangun model klasifikasi citra retak beton menggunakan arsitektur MobileNetV2.
- b. Mengevaluasi dan menganalisis pengaruh *Hyperparameter Tuning* (*Learning Rate* dan *Batch Size*) secara OFAT terhadap dinamika kurva pembelajaran (*learning curve*), khususnya dalam membuktikan fenomena *overfitting* akibat *Learning Rate* dan efek *noise* akibat *Batch Size*.
- c. Mengevaluasi dan melakukan analisis komparatif antara efektivitas penerapan *Cost-Sensitive Learning*, *Custom Decision Threshold*, dan pendekatan hibrida keduanya dalam menekan risiko kesalahan klasifikasi fatal (*False Negative*) serta mengevaluasi efisiensi waktu pelatihan.

2. Manfaat Penelitian

Adapun manfaat yang diharapkan dari penelitian ini adalah:

- a. Bagi Akademis/Keilmuan: Memberikan kontribusi literatur serta pemahaman empiris mengenai pengaruh *hyperparameter tuning* dan penanganan *False Negative* pada CNN MobileNetV2 dalam domain *Computer Vision*.
- b. Bagi Praktisi/Masyarakat: Menghasilkan rancangan model klasifikasi yang berpotensi untuk dikembangkan lebih lanjut menjadi aplikasi inspeksi otomatis guna membantu pemeliharaan dan audit keselamatan infrastruktur sipil.

1.4. Ruang Lingkup

Agar penelitian ini lebih terarah dan tidak menyimpang dari tujuan pokok, maka ditetapkan ruang lingkup penelitian sebagai berikut:

1. Data citra dibatasi pada dataset publik "*Concrete Crack Images for Classification*" (Kaggle). Label *Positive* (*Cracked*) merujuk pada retakan struktural yang terlihat jelas secara visual. Cacat permukaan minor seperti retak rambut, goresan, atau tekstur kasar beton yang ada dalam dataset diklasifikasikan sebagai label *Negative* (*Not Cracked*).
2. Algoritma klasifikasi yang digunakan dibatasi pada *Convolutional Neural Network* (CNN) menggunakan arsitektur MobileNetV2. Sistem tidak dirancang untuk

memetakan lokasi spasial retakan (*Object Detection/Segmentation*) dan tidak dikomparasikan dengan arsitektur *Deep Learning* lainnya.

3. Sistem yang dibangun berfokus pada klasifikasi biner dan mengasumsikan bahwa citra masukan (*input*) yang diberikan ke dalam model adalah citra yang sudah dipastikan berupa permukaan beton (kondisi ideal) sesuai dengan dataset yang digunakan dari Kaggle.

1.5.Sistematika Penulisan

Untuk memberikan gambaran menyeluruh mengenai penyusunan skripsi ini, sistematika penulisan dibagi menjadi lima bab dengan rincian sebagai berikut:

BAB I PENDAHULUAN

Bab ini menguraikan latar belakang masalah, rumusan masalah, tujuan dan manfaat penelitian, ruang lingkup atau batasan masalah, serta sistematika penulisan laporan skripsi.

BAB II TINJAUAN PUSTAKA

Bab ini berisi landasan teori dan kajian pustaka dari penelitian-penelitian terdahulu yang relevan. Teori yang dibahas meliputi konsep dasar pengolahan citra digital, *Deep Learning*, algoritma *Convolutional Neural Network* (CNN), arsitektur MobileNetV2, *Hyperparameter Tuning*, penyesuaian ambang batas keputusan (*Custom Decision Threshold*), penerapan *Cost-Sensitive Learning* (pembobotan kelas), penerapan *Hybrid Cost-Sensitive Learning* dan *Custom Decision Threshold*, serta metrik evaluasi performa model menggunakan *Confusion Matrix*.

BAB III METODOLOGI PENELITIAN

Bab ini menjelaskan tahapan dan prosedur penelitian secara sistematis. Pembahasan meliputi alur penelitian, pengumpulan dan pembagian data (*data splitting*), membangun model *end-to-end* secara terintegrasi (mulai dari pra-pemrosesan hingga klasifikasi), kemudian eksperimen penelitian yang menerapkan OFAT *Hyperparameter Tuning* dan penanganan *False Negative*, serta ditutup dengan rekapitulasi dan analisis kinerja model.

BAB IV HASIL DAN PEMBAHASAN

Bab ini menguraikan lingkungan implementasi sistem serta hasil pengujian dari eksperimen penelitian yang dilakukan. Pembahasan difokuskan pada analisis grafik

pelatihan, penjabaran hasil metrik evaluasi pada *Confusion Matrix*, serta diakhiri dengan analisis rekapitulasi performa model secara keseluruhan.

BAB V KESIMPULAN DAN SARAN

Bab ini merupakan bagian penutup yang berisi kesimpulan dari hasil penelitian guna menjawab rumusan masalah yang ada, serta memberikan saran-saran konstruktif untuk pengembangan penelitian selanjutnya di masa yang akan datang.