

BAB I

PENDAHULUAN

1.1 Latar Belakang

Industri manufaktur logam memainkan peran penting dalam berbagai sektor, mulai dari otomotif, konstruksi, hingga peralatan mesin. Salah satu proses utama dalam industri ini adalah pengecoran (*casting*), yaitu proses penuangan logam cair ke dalam cetakan untuk membentuk produk yang diinginkan. Pengecoran merupakan metode yang efektif untuk memproduksi komponen logam dalam skala besar dengan presisi yang tinggi.

Dalam proses pengecoran, produk yang dihasilkan sering kali rentan terhadap berbagai jenis cacat, seperti lubang udara, porositas, retakan, dan anomali metalurgi (Bolla dkk., 2022), (Gupta dkk., 2023), (Hu dkk., 2023), (Nguyen dkk., 2021). Secara tradisional, inspeksi kualitas dalam pengecoran dilakukan secara manual oleh inspektor yang berpengalaman. Namun, metode ini tidak hanya memakan waktu, tetapi juga bergantung pada kemampuan inspektor, yang membuatnya rentan terhadap kesalahan manusia. Inspeksi manual sering kali tidak efektif dalam mendeteksi cacat halus atau ketidakraturan kecil yang mungkin memerlukan perhatian lebih lanjut. Dalam beberapa kasus, cacat yang tidak terdeteksi pada tahap awal dapat menimbulkan masalah serius di kemudian hari, termasuk kerugian finansial yang besar karena harus melakukan perbaikan atau penggantian produk (Mgonja, 2017).

Dalam rangka mengatasi keterbatasan metode manual, industri mulai beralih ke metode inspeksi berbantuan komputer (*Computer-Aided Inspection*). Pendekatan awal menggunakan teknik *computer vision* berbasis fitur manual, yang mengharuskan inspektor atau pengembang menentukan fitur visual spesifik agar dapat dikenali oleh komputer. Teknik seperti transformasi Har atau transformasi Fourier (Abdel-Qader et al., 2003) dan seleksi Region of interest (ROI) (Choi dkk., 2019), metode Sobel atau Canny (Muhammad Rizky Alditra Utama dkk., 2022) (Lynn dkk., 2021), serta filter GLCM (Daneshvari dkk., 2023) maupun LBP (Mäenpää dkk., 2003) telah digunakan untuk mengekstraksi fitur seperti tepi,

bentuk, dan tekstur pada citra produk logam yang diinspeksi. Meskipun metode ini membantu dalam deteksi awal, keterbatasannya terletak pada sulitnya beradaptasi dengan variasi bentuk kecacatan dinamis.

Guna mengatasi keterbatasan metode manual, pendekatan *machine learning* tradisional mulai diterapkan. Proses pelatihan dalam *machine learning* tradisional sangat bergantung pada rekayasa fitur manual, yang dilakukan secara eksplisit oleh inspektor atau pengembang. Fitur-fitur tersebut kemudian digunakan sebagai *input* untuk model machine learning seperti Support Vector Machines (SVM) (Listanto dkk., 2023), Random Forest (Wang dkk., 2022), atau k-Nearest Neighbors (k-NN) (Deng dkk., 2022), yang kemudian dilatih menggunakan data ini untuk mengklasifikasikan atau memprediksi kualitas produk berdasarkan fitur yang telah dirancang. Namun, pendekatan tersebut memiliki kelemahan karena sangat bergantung pada kualitas fitur yang diekstraksi secara manual (Cruz-Rojas dkk., 2023). Efektivitas model bergantung pada derajat kebaikan/ketepatan fitur-fitur tersebut dalam mewakili cacat atau anomali dalam produk. Selain itu, perekayasaan fitur manual ini dapat menjadi proses yang memakan waktu dan sulit beradaptasi dengan variasi atau bentuk cacat baru yang dinamis, sehingga membatasi fleksibilitas dan akurasi sistem (Chen dkk., 2020).

Pengembangan selanjutnya datang melalui *deep learning*, yang memperkenalkan pendekatan lebih maju dibandingkan dengan computer vision berbasis fitur manual dan machine learning tradisional, terutama dalam konteks *quality control* (QC) pada industri pengecoran logam (*casting*). Perbedaan utama antara *deep learning* dan metode sebelumnya terletak pada kemampuan model untuk mengekstraksi fitur secara otomatis, seperti deteksi porositas, retakan, lubang udara, dan anomali permukaan pada logam.

Salah satu teknik yang populer adalah *Convolutional Neural Networks* (CNN), yang menggunakan *kernel* sebagai filter untuk mentransformasi citra *input* menjadi peta fitur (*feature map*). *Kernel* bekerja dengan mengalikan elemen-elemen di dalamnya dengan nilai piksel pada *grid* lokal di gambar *input*, lalu bergeser secara sistematis ke *grid* berikutnya dengan langkah yang disebut *stride*, hingga mencakup seluruh area gambar. Hasilnya adalah peta fitur, yang merepresentasikan

pola-pola visual seperti tepi, tekstur, atau bentuk, yang digunakan untuk analisis lebih lanjut seperti klasifikasi atau deteksi cacat. Setelah peta fitur dihasilkan, pooling diterapkan untuk mengurangi dimensi peta fitur sambil mempertahankan informasi penting. Selanjutnya, peta fitur yang diproses diteruskan ke lapisan fully connected yang ditandai dengan setiap *neuron* terhubung dengan *neuron* pada lapisan sebelumnya untuk membuat prediksi atau klasifikasi berdasarkan informasi yang telah diekstraksi.

Setelah era CNN, muncul paradigma *transfer learning* dalam pemrosesan citra, yang memanfaatkan bobot dan bias yang telah dipelajari dari model yang dilatih pada dataset besar, seperti ImageNet dan ResNet. Dalam transfer learning, lapisan awal yang mengenali fitur-fitur dasar seperti tepi dan tekstur dipertahankan, sementara lapisan akhir yang lebih spesifik dilatih ulang untuk menyesuaikan dengan tugas baru, seperti mendeteksi cacat pada produk pengecoran logam (Gupta dkk., 2023).

Meskipun transfer learning menawarkan keuntungan dalam hal efisiensi pelatihan, pendekatan ini seringkali membutuhkan sumber daya komputasi yang besar, terutama karena model pre-trained seperti ResNet atau Inception cenderung memiliki ukuran yang sangat besar, baik dari segi jumlah parameter maupun konsumsi memori. Dalam lingkungan industri, seperti dalam lini *quality control* di pabrik pengecoran logam, penerapan model yang sangat besar ini bisa menjadi tantangan. Tantangan bisa muncul karena kebutuhan implementasi pada perangkat dengan daya rendah atau terbatas, seperti FPGA (*Field Programmable Gate Array*) atau *embedded systems*.

Dalam rangka menghindari isu di atas, perlu dikembangkan CNN yang memiliki akurasi yang baik dan sepadan dengan model transfer learning. Salah satu batasan dalam meningkatkan akurasi CNN adalah adanya isu kedalaman jaringan. Masalah ini terjadi ketika gradien yang digunakan untuk memperbarui bobot dalam jaringan menjadi sangat kecil pada lapisan-lapisan awal, sehingga pelatihan model menjadi tidak efisien. Akibatnya, jaringan tidak dapat mempelajari representasi fitur yang lebih kompleks dengan baik, dan nilai akurasi bisa mencapai titik saturasi atau bahkan menurun.

Strategi untuk mengatasi batasan tersebut antara lain adalah *residual blocks* dapat diterapkan dalam arsitektur CNN. *Residual blocks* bekerja dengan memperkenalkan skip connections atau shortcut connections, yang memungkinkan informasi dan gradien untuk melewati satu atau lebih lapisan tanpa transformasi penuh. Dengan strategi ini, gradien tetap stabil, bahkan di jaringan yang sangat dalam, sehingga jaringan tetap dapat belajar secara efektif tanpa kehilangan informasi penting. Dengan demikian, *residual blocks* membantu model CNN untuk mempelajari representasi fitur yang lebih kompleks tanpa menghadapi masalah gradien yang hilang, memungkinkan peningkatan akurasi secara berkelanjutan.

Pengembangan model CNN dengan *residual blocks* memiliki potensi manfaat untuk diterapkan dalam quality control (QC) pada proses pengecoran (*casting*) logam. Strategi menerapkan *residual blocks* dalam model CNN diharapkan dapat meningkatkan kedalaman jaringan tanpa mengalami masalah vanishing gradient, sehingga pelatihan lebih akurat. Oleh karenanya, perlu dilakukan penelitian yang menyelidiki bagaimana mengembangkan model CNN dengan *residual blocks* untuk mendeteksi cacat pada citra produk pengecoran (*casting*) logam.

Dengan mempertimbangkan keunggulan *residual blocks* dalam menjaga stabilitas gradien dan memungkinkan pelatihan jaringan yang lebih dalam tanpa mengalami penurunan akurasi, bagian pertama dalam penelitian ini berfokus pada : pengembangan model klasifikasi berbasis CNN yang lebih efisien dalam mengenali dan mengklasifikasikan cacat pada produk pengecoran logam.

Meskipun pendekatan berbasis klasifikasi menggunakan CNN memiliki potensi untuk klasifikasi cacat pada produk pengecoran logam, metode ini memiliki keterbatasan dalam aplikasi industri yang memerlukan deteksi lokasi (region) cacat secara langsung dalam suatu citra. Pendekatan klasifikasi hanya mampu memberikan keputusan apakah suatu produk memiliki cacat atau tidak, tetapi tidak dapat secara langsung menunjukkan di mana cacat tersebut berada pada permukaan produk. Hal ini menjadi kendala dalam inspeksi otomatis, terutama dalam proses quality control yang membutuhkan deteksi cacat secara presisi untuk evaluasi dan tindakan korektif yang cepat.

Sebagai solusi atas keterbatasan ini, pendekatan *object detection* berbasis *deep learning* mulai banyak diterapkan dalam deteksi cacat industri. *Object detection* tidak hanya mengklasifikasikan apakah sebuah objek terdapat dalam gambar, tetapi juga menentukan lokasi objek tersebut melalui bounding box. Dengan demikian, pendekatan ini memungkinkan sistem inspeksi otomatis untuk mengenali dan menyoroti (*highlight*) bagian produk yang mengalami kecacatan, sehingga meningkatkan efisiensi dan akurasi deteksi.

Pendekatan deteksi objek berbasis *deep learning* telah menjadi solusi yang banyak diterapkan dalam inspeksi kualitas industri, termasuk dalam deteksi cacat pada produk pengecoran logam. Dengan kemampuannya dalam mengidentifikasi, mengklasifikasikan, dan menentukan lokasi cacat secara otomatis, metode ini menawarkan efisiensi lebih tinggi dibandingkan pendekatan klasifikasi konvensional (Bai & Xu, 2025), (Li, N. dkk., 2024), (Tan dkk., 2020), (Xie & Zhao, 2025), (Zheng dkk., 2024).

Secara umum, algoritma deteksi objek dapat dikategorikan ke dalam dua pendekatan utama, yaitu metode dua tahap (*two-stage*) dan metode satu tahap (*one-stage*). Metode dua tahap, seperti Fast R-CNN (Girshick, 2015) dan Faster R-CNN (Ren dkk., 2017), bekerja dengan cara menghasilkan region proposals terlebih dahulu, sebelum melakukan klasifikasi dan regresi lokasi objek dalam gambar. Pendekatan ini menawarkan akurasi yang lebih tinggi, tetapi memiliki kelemahan dalam kecepatan inferensi, yang membuatnya kurang ideal untuk aplikasi real-time dalam industri manufaktur.

Sebaliknya, metode satu tahap seperti seri YOLO (You Only Look Once) (Redmon dkk., 2016) dapat menyelesaikan tugas deteksi dalam satu kali pemrosesan (*forward pass*), tanpa memerlukan tahap region proposal. Pendekatan ini lebih unggul dalam hal kecepatan deteksi, arsitektur yang lebih sederhana, serta efisiensi optimasi dibandingkan metode dua tahap. Oleh karena itu, dalam skenario deteksi cacat secara real-time di lingkungan industri, model satu tahap lebih sering digunakan karena lebih praktis dan efektif.

Seiring berkembangnya kebutuhan deteksi objek yang semakin kompleks, berbagai teknik tambahan telah diperkenalkan untuk meningkatkan performa

model. Salah satu pendekatan yang menarik adalah BiFPN (Bi-directional Feature Pyramid Network) yang diperkenalkan dalam (Tan dkk., 2020). BiFPN dirancang untuk meningkatkan fusi fitur multi-skala secara lebih efisien, sehingga memungkinkan model untuk mengenali objek dengan ukuran bervariasi lebih akurat.

Dalam konteks deteksi cacat pada produk pengecoran logam, permasalahan utama yang sering muncul adalah variasi ukuran dan bentuk cacat yang tidak selalu seragam, seperti porositas halus, retakan, atau inklusi logam. Model deteksi berbasis YOLO secara konvensional menggunakan struktur Feature Pyramid Network (FPN) untuk menangani objek dengan skala berbeda. Namun, FPN standar memiliki keterbatasan karena hanya melakukan fusi fitur secara top-down, sehingga informasi dari lapisan bawah kurang dimanfaatkan secara optimal.

Sebagai solusi, BiFPN mengusulkan mekanisme fusi dua arah (bi-directional fusion) yang memungkinkan model menggabungkan informasi dari berbagai skala dengan lebih efektif. Pendekatan ini membuat deteksi objek kecil, seperti porositas halus, menjadi lebih akurat. Integrasi YOLO dengan BiFPN telah menunjukkan peningkatan signifikan dalam berbagai tugas deteksi objek, terutama dalam lingkungan dengan variasi skala yang kompleks. Penelitian dalam (Li, S. dkk., 2023) mengimplementasikan BiFPN pada YOLOv4, yang terbukti mampu meningkatkan akurasi deteksi pada objek kecil dan bertekstur halus. Selain itu, penelitian dalam (Zhao dkk., 2023) menggabungkan Res2Net dan DFPN untuk lebih memperkaya representasi fitur dalam model YOLO.

Dengan mempertimbangkan keunggulan BiFPN, bagian kedua dalam penelitian ini berfokus pada: cara mengintegrasikan BiFPN dengan YOLO agar dapat mendeteksi cacat pada produk pengecoran logam, terutama dalam mengatasi variasi bentuk dan ukuran cacat.

1.2 Tujuan Penelitian

Penelitian ini bertujuan untuk memodifikasi sistem inspeksi cacat pada produk pengecoran logam. Tujuan utama penelitian ini dibagi menjadi dua bagian,

yaitu (i) modifikasi model klasifikasi dan (ii) mengimplementasikan model deteksi cacat, dengan penjelasan sebagai berikut:

1. Mengembangkan model klasifikasi, dengan sub tujuan sebagai berikut:
 - 1) Mengintegrasikan *residual block* pada model arsitektur CNN;
 - 2) Mengevaluasi kinerja model yang dihasilkan pada poin 1.1 dengan metrik evaluasi akurasi, *precision*, *recall* dan F1-score;
 - 3) Mengkomparasi hasil pada poin 1.2 dibandingkan dengan model lain; dan
 - 4) Mengkomparasi ukuran (*size*) model klasifikasi yang dihasilkan dalam poin 1.1, dibandingkan *size* model klasifikasi lainnya.
2. Mengembangkan model deteksi dengan sub tujuan sebagai berikut:
 - 1) Mengintegrasikan BiFPN pada arsitektur YOLO
 - 2) Mengintegrasikan model klasifikasi yang dikembangkan pada poin 1;
 - 3) Mengevaluasi kinerja model yang dihasilkan pada poin 2.2 dengan metrik evaluasi *Precision*, *Recall*, dan *Mean Average Precision*;
 - 4) Mengkomparasi hasil pada poin 2.2 dibandingkan dengan model lain; dan
 - 5) Mengkomparasi ukuran (*size*) antara model deteksi yang dihasilkan pada poin 2.2, dibandingkan *size* model deteksi lainnya.

1.3 Manfaat Penelitian

Penelitian ini diharapkan dapat berkontribusi dalam menyediakan alternatif pendekatan dalam sistem inspeksi otomatis untuk mendeteksi cacat pada produk pengecoran logam dengan mengeksplorasi: (i) klasifikasi berbasis CNN dengan *residual blocks* serta (ii) deteksi objek menggunakan YOLO yang diintegrasikan dengan BiFPN. Melalui pendekatan ini, penelitian ini dapat memberikan gambaran komparatif mengenai kinerja kedua model dalam mengidentifikasi dan melokalisasi cacat, yang dapat menjadi pertimbangan dalam pengembangan sistem *quality control* di lingkungan industri.