

BAB I

PENDAHULUAN

1.1 Latar Belakang

Permintaan produk fisik yang semakin banyak dan berkembang, menjadikan industri sebagai sektor utama dalam sistem ekonomi modern yang berperan dalam menciptakan produk kebutuhan masyarakat. Hal ini menjadi salah satu yang mendorong inovasi teknologi serta peningkatan efisiensi produksi sehingga tercipta industri 4.0, di mana era tersebut telah merevolusi proses manufaktur dengan menggabungkan teknologi digital (Deokar dkk., 2025). Pentingnya industri yang semakin berkembang membuat peran *Quality Control* (QC) menjadi lebih krusial untuk memastikan produk yang dihasilkan terhindar dari cacat guna menciptakan produk yang sesuai dengan standar kebutuhan (Juhaeti, 2024).

Metode QC manual memakan waktu yang lebih lama dan biaya jangka panjang yang lebih mahal (Sabri, 2022) karena keterbatasan visual manusia yang melakukan penilaian secara subjektif sehingga dapat menyebabkan inkonsistensi hasil. Di era pabrik pintar (*smart factory*) yang memasuki revolusi industri keempat, metode QC manual dinilai sudah tidak relevan untuk mengimbangi kebutuhan produk industri yang berjalan masif, sehingga dibutuhkan otomatisasi untuk menjamin kualitas produk secara *real-time* (Hütten dkk., 2024). Tantangan pada pengembangan sistem ini yaitu ketersediaan sampel produk cacat jauh lebih sedikit dibandingkan dengan sampel produk normal (Shiferaw & Yao, 2024), sehingga pendekatan *Unsupervised Learning* yang hanya menggunakan data normal sebagai sampel untuk pelatihan (*training*) menjadi solusi yang unggul (Batzner dkk., 2024).

Convolutional Autoencoder (CAE) merupakan salah satu metode *Unsupervised Anomaly Detection* (UAD) yang dilatih untuk merekonstruksi citra input, di mana model akan gagal merekonstruksi anomali yang tidak pernah dipelajari selama fase pelatihan (Shiferaw & Yao, 2024).

Penelitian sebelumnya, (Sabri, 2022) yang mengimplementasikan CAE untuk deteksi cacat pada tekstur tertentu menemukan bahwasanya hasil akurasi pada model juga dipengaruhi oleh kompleksitas objek. Objek kompleks seperti *Zipper* membutuhkan ukuran *bottleneck* yang cukup besar dengan ukuran 300 hingga 500 agar fitur detail tertangkap, sedangkan objek sederhana seperti *Grid* membutuhkan ukuran *bottleneck* lebih kecil yang hanya 100 agar anomali tidak ikut terekonstruksi (Sabri, 2022). Pendekatan yang dilakukan (Sabri, 2022) menggunakan ukuran *bottleneck* secara statis dengan mengandalkan proses *trial-and-error* dalam penentuan ukuran *bottleneck* yang menjadi celah (*gap*) pada penelitian ini karena penentuan ukuran *bottleneck* secara manual atau statis memiliki kelemahan berupa generalisasi berlebih (*over-generalization*) di mana model akan mampu memulihkan pola tidak normal dengan sangat baik sehingga cacat gagal terdeteksi sebagai anomali.

Penelitian selanjutnya oleh (Yang & Guo, 2024) berhasil mengatasi masalah penentuan ukuran *bottleneck* statis menjadi adaptif dan *over-generalization* dengan menggunakan *Memory Module* (M) sebagai penyimpanan jangka panjang fitur-fitur normal untuk kemudian dicocokkan serta memanfaatkan fungsi *shrinkage* pada aktivasi *ReLU* dan ambang batas (λ) guna meregulasi fitur-fitur yang tidak relevan dalam proses pencocokkan.

Penelitian lainnya oleh (Stepien dkk., 2026) juga berhasil mengatasi masalah *over-generalization* dengan menggunakan *Dynamic Top-K* untuk menyesuaikan ukuran *bottleneck* secara otomatis berdasarkan tingkat kompleksitas masing-masing data input dengan fungsi aktivasi *Sigmoid*. Proses pencocokkan di setiap iterasi dengan *Memory Module* membebani komputasi secara signifikan, begitupun penelitian yang memerlukan operator *Soft Top-K* dengan melibatkan proses pengurutan (*sorting*) secara kontinu sehingga memakan biaya komputasi yang tinggi dan membatasi skalabilitas model.

Mengatasi keterbatasan penelitian-penelitian sebelumnya, penelitian ini mengusulkan sebuah mekanisme penentuan ukuran *bottleneck* yang adaptif guna memitigasi resiko *over-generalization* tanpa melibatkan beban komputasi yang berat menggunakan *Sparsity Gating Network* dengan hanya memanfaatkan satu lapisan linear (*fully connected*) dan aktivasi *Sigmoid*, model ini mampu menekan fitur anomali secara dinamis (*elemen-wise multiplication*) dengan kompleksitas waktu komputasi yang konstan, sehingga sangat efisien untuk penerapan industri secara *real-time*.

1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut, rumusan masalah penelitian ini dirumuskan sebagai berikut:

1. Bagaimana merancang mekanisme *bottleneck* adaptif pada *Autoencoder* guna mencegah masalah generalisasi berlebih (*over-generalization*) untuk segmentasi anomali citra industri?

2. Bagaimana mengevaluasi efisiensi komputasi dari arsitektur *Adaptive Bottleneck Autoencoder* dengan mekanisme *Gating* untuk segmentasi anomali citra industri?

1.3 Tujuan Penelitian

Tujuan utama penelitian ini adalah mengembangkan, mengimplementasikan, dan memvalidasi model *Adaptive Bottleneck Autoencoder* sebagai solusi deteksi cacat permukaan *unsupervised* yang *robust* dan efisien.

Secara spesifik, tujuan penelitian mencakup:

1. Merancang dan mengimplementasikan model *Adaptive Bottleneck Autoencoder* dengan mekanisme *Gating* untuk segmentasi anomali citra industri.
2. Mengevaluasi dan menganalisis tingkat efisiensi komputasi dari arsitektur *Adaptive Bottleneck Autoencoder* dengan mekanisme *Gating* untuk segmentasi anomali citra industri.

1.4 Manfaat Penelitian

Adapun manfaat penelitian yang dilakukan sebagai berikut:

1. Secara teoritis, memperkaya literatur di bidang *Computer Vision*, khususnya terkait teknik *unsupervised learning* menggunakan arsitektur Autoencoder melalui integrasi mekanisme *Adaptive Bottleneck* berbasis *Sparsity Gating Network*, serta memberikan wawasan baru mengenai efisiensi komputasi dengan memanfaatkan satu lapisan linear (*fully connected*) dan aktivasi *Sigmoid* pada model *Adaptive Bottleneck Autoencoder*.

2. Secara praktis, memberikan solusi alternatif bagi industri manufaktur untuk mengotomatisasi proses inspeksi visual secara *real-time* yang selama ini bergantung pada pengamatan manusia.

1.5 Batasan Masalah

Adapun batasan masalah pada penelitian ini sebagai berikut:

1. Data yang digunakan dalam pengujian dan pelatihan model adalah dataset publik *MVTec AD (MVTec Anomaly Detection)* dan hanya berfokus pada citra *Grid* dan *Zipper*.
2. Metode yang digunakan adalah *unsupervised learning*, dimana model hanya dilatih menggunakan data citra normal (tanpa cacat).
3. Algoritma utama yang dibangun adalah *Convolutional Autoencoder* dengan modifikasi pada lapisan *bottleneck* yang bersifat adaptif (*Adaptive Bottleneck*) untuk mengoptimalkan representasi fitur.
4. Evaluasi performa model dibatasi hanya pada penghitungan metrik AUROC (*Area Under the Receiver Operating Characteristic*) serta analisis kualitatif melalui visualisasi prediksi biner. Metrik *Precision*, *F1-Score*, dan *Accuracy* tidak ditampilkan dalam laporan hasil.
5. Penelitian ini berfokus pada pengembangan dan pengujian model, tanpa melakukan implementasi *real-time* atau sistem produksi.