

ANALISIS KOMPARATIF DEKODING BARCODE DEEP LEARNING: EVALUASI WECHATQRCODE VS PYZBAR PADA UNCONSTRAINED ENVIRONMENT

Saepudin Nirwan¹, Naufal Fachrudin Nirwan²

School of Information Technology, Universitas Logistik dan Bisnis Internasional, Sarijadi, Bandung Regency,
West Java 40151¹

Department of Data Science, Telkom University, Dayeuhkolot, Bandung Regency, West Java 40257, Indonesia²

email: ¹saepudin@ulbi.ac.id, Nafach@student.telkom.ac.id²

Abstrak

Penelitian ini menghadirkan kebaruan melalui integrasi sistem hibrida deteksi YOLO-v5 dan dekoding berbasis Convolutional Neural Network (CNN) untuk mengatasi degradasi visual pada barcode di lingkungan logistik unconstrained. Berbeda dengan sistem deteksi-dekoding standar (YOLO dan Pyzbar) yang dilaporkan mencapai akurasi 91% pada kondisi umum, penelitian ini mengungkap fenomena “Cliff Effect” pada algoritma heuristik tradisional yang mengalami kegagalan saat noise melampaui ambang batas kritis $\sigma=25$. Sebaliknya, penggunaan WeChatQRCode menunjukkan ketangguhan absolut dengan Success Rate 100% dan latensi deterministik sebesar 4,86 ms. Novelty penelitian ini terletak pada pembuktian bahwa integrasi neural decoding memberikan tingkat reliabilitas yang melampaui limitasi operasional metode scanline klasik.

Kata Kunci: Barcode Decoding, Deep Learning, WeChatQRCode, YOLO-v5, Robustness

Abstract

This research introduces a novel hybrid framework integrating YOLO-v5 object detection with Convolutional Neural Network (CNN)-based decoding to address severe visual degradation in unconstrained logistics environments. Compared to standard detection-decoding pipelines (YOLO+Pyzbar) reporting a 91% accuracy rate under general conditions, this study identifies and quantifies the “Cliff Effect” in traditional heuristic algorithms, which exhibit failure once Gaussian noise exceeds the critical threshold of $\sigma=25$. In contrast, the implementation of WeChatQRCode demonstrates absolute robustness with a 100% Success Rate and deterministic latency. The novelty of this work lies in proving that neural decoding provides a superior reliability foundation for Industry 4.0 than classic scanline methods under extreme signal degradation.

Keywords: Barcode Decoding, Deep Learning, WeChatQRCode, YOLO-v5, Robustness

1. PENDAHULUAN

Transformasi digital dalam rantai pasok global telah menempatkan teknologi identifikasi otomatis sebagai tulang punggung efisiensi operasional. Dalam konteks pergudangan pintar (*smart warehousing*) dan logistik unconstrained, sistem barcode dituntut untuk beroperasi pada performa puncak meskipun terpapar degradasi visual yang signifikan. Degradasi ini seringkali berasal dari faktor lingkungan seperti guncangan mekanis yang menyebabkan *motion blur*, pencahayaan yang tidak konsisten, hingga kontaminasi fisik pada label barcode itu sendiri.

Pendekatan tradisional dalam dekoding barcode umumnya mengandalkan teknik binarisasi adaptif dan pemindaian scanline. Meskipun efisien secara komputasi, metode ini sangat sensitif terhadap integritas tepi (*edge integrity*) dari modul barcode. Ketika rasio antara sinyal dan noise menurun, algoritma klasik seringkali gagal menemukan titik transisi warna yang diperlukan untuk rekonstruksi data. Di sisi lain, kemajuan dalam *Deep Learning* (DL) memberikan paradigma baru melalui ekstraksi fitur hirarkis yang mampu mengenali pola barcode secara holistik.

Beberapa penelitian terbaru telah mengeksplorasi penggunaan YOLOv5 untuk deteksi objek dalam berbagai skenario industri [7, 9, 10]. Secara khusus, integrasi YOLOv5 dan Pyzbar telah diusulkan sebagai standar efisiensi baru dengan tingkat akurasi dekoding mencapai 91% [21]. Namun, terdapat gap literatur yang signifikan mengenai performa sistem tersebut pada kondisi degradasi visual ekstrem (*noise* tinggi dan *heavy blur*). Penelitian ini bertujuan untuk melakukan analisis komparatif mendalam guna membuktikan bahwa integrasi CNN-based decoding (WeChatQRCode) mampu mengatasi limitasi "Cliff Effect" yang menghambat implementasi YOLO and Pyzbar pada lingkungan logistik yang tidak teregulasi [21].

2. LANDASAN TEORI

Penelitian sebelumnya oleh Redmon dkk. mengenai YOLO (*You Only Look Once*) telah merevolusi kecepatan deteksi objek real-time [7]. Dalam konteks barcode, penggunaan CNN untuk pengenalan pola telah diusulkan oleh Putra dkk. [1] dan Fitrianto [2] yang menunjukkan keunggulan pada citra dengan resolusi rendah. Santoso dan Wijayanto [3] menekankan pentingnya YOLO v5 dalam melokalisasi area barcode (ROI) pada lini pengemasan otomatis untuk mengurangi beban komputasi dekoder.

Tinjauan terhadap sistem yang diusulkan oleh [21] mengungkap adanya limitasi mendasar pada arsitektur hibrida yang menggunakan detektor neural namun masih berbasis dekoder heuristik (*scanline-based*). Ketergantungan Pyzbar pada integritas gradien piksel menyebabkan sistem tersebut sangat rentan terhadap degradasi "sinyal-ke-noise" (SNR) yang rendah. Ketidakmampuan metode klasik dalam membedakan artefak noise dari modul barcode yang sah menciptakan kebocoran reliabilitas yang signifikan, terutama pada kondisi industri yang tidak teregulasi. Oleh karena itu, penelitian ini memunculkan *State-of-the-Art* dengan mengeliminasi ketergantungan pada ekstraksi fitur manual melalui integrasi penuh dekoding berbasis CNN, yang secara teoritis dan eksperimental mampu mempertahankan kemampuan inferensi pada tingkat gangguan di mana algoritma derivatif-gradien [21] mengalami kegagalan.

2.1 Landasan Matematis

Landasan matematis ini digunakan untuk memodelkan proses degradasi citra secara formal, memungkinkan analisis kuantitatif terhadap batas kegagalan algoritma dekoding.

Gaussian Blur (G):

$$G(x, y) = (1 / 2\pi\sigma^2) \exp(-(x^2+y^2)/2\sigma^2) \quad [1]$$

Persamaan [1] merepresentasikan filter linear yang digunakan untuk menghaluskan (*smoothing*) detail citra. Secara teknis, fungsi ini bertindak sebagai low-pass filter yang mensimulasikan kegagalan optik akibat defocusing atau guncangan kamera (*motion jitter*) yang umum terjadi pada sistem pemindaian bergerak.

Gaussian Noise (I):

$$I'(x, y) = I(x, y) + \eta, \eta \sim N(0, \sigma^2) \quad [2]$$

Persamaan [2] memodelkan Additive White Gaussian Noise (AWGN) yang mensimulasikan gangguan termal dan elektronik pada sensor citra. Distribusi η dengan rata-rata nol dan variansi σ^2 menciptakan fluktuasi intensitas piksel acak yang menguji stabilitas binarisasi dan deteksi tepi pada algoritma dekoding.

Rotasi (M):

$$[x', y']^T = M[x-cx, y-cy]^T + [cx, cy]^T \quad [3]$$

Persamaan [3] mendefinisikan transformasi afinitas untuk rotasi citra terhadap titik pusat (cx, cy). Pemetaan koordinat ini sangat krusial untuk mengevaluasi sifat invariant sudut (*angular invariance*) dari dekoder, terutama pada metode klasik yang sangat bergantung pada orientasi scanline yang sejajar dengan modul barcode.

Gradien Piksel (VI):

$$VI = [\partial I / \partial x, \partial I / \partial y]^T \quad [4]$$

Analisis derivatif pertama dari gradien piksel (VI) pada Persamaan [4] merupakan basis operasional bagi dekoder barcode tradisional. Metode heuristik seperti scanline detektor mengandalkan besaran gradien ($|VI|$) untuk mengidentifikasi transisi intensitas antara bar (gelap) dan *space* (terang). Keterkaitan matematis antara degradasi dan gradien terlihat jelas pada interaksi dengan *Gaussian Blur*;

konvolusi citra dengan fungsi G [1] akan menurunkan frekuensi spasial tinggi, yang secara teknis mereduksi magnitudo derivatif $|VI|$. Akibatnya, batas modul menjadi landai (*smoothed edge*), sehingga ambang batas binarisasi adaptif gagal memicu deteksi transisi. Lebih lanjut, kehadiran *Gaussian Noise* (η) [2] menyisipkan komponen gradien acak (false transitions) ke dalam sinyal. Pada kondisi SNR rendah, noise frekuensi tinggi ini mendominasi sinyal asli, menyebabkan nilai $|VI|$ menjadi sangat fluktuatif (*volatil*). Fenomena ini menjelaskan kegagalan total (*cliff effect*) pada algoritma klasik, di atas ambang batas noise tertentu, karena sistem kehilangan kemampuan untuk membedakan antara modul barcode yang sah dengan artefak noise.

2.2 Metrik Statistik

Untuk memvalidasi integritas data dan efisiensi komputasi secara empiris, penelitian ini menerapkan kerangka kerja evaluasi statistik yang ketat. Metrik-metrik berikut digunakan untuk mentransformasikan observasi mentah menjadi representasi performa yang dapat dipelajari secara kuantitatif, memungkinkan analisis mendalam terhadap tendensi sentral, volatilitas sistem (*jitter*), dan probabilitas keberhasilan dekoding pada kondisi sinyal terdegradasi.

Mean ($\bar{x}$):

$$\bar{x} = (1/n) \sum(t_i) \quad [5]$$

Persamaan [5] merepresentasikan nilai rata-rata aritmatika dari latensi dekoding yang diukur selama n iterasi. Metrik ini memberikan indikasi kecenderungan sentral dari performa komputasi algoritma, memungkinkan perbandingan efisiensi dasar antara metode heuristik dan *deep learning*.

Std Dev (s):

$$s = \sqrt{[(1/(n-1)) \sum(t_i - \bar{x})^2]} \quad [6]$$

Standar deviasi pada Persamaan [6] digunakan untuk mengukur dispersi atau volatilitas latensi pemrosesan. Nilai s yang rendah mengindikasikan determinisme latensi, yang merupakan parameter krusial dalam perancangan sistem *hard real-time* di lingkungan industri.

Akurasi (Acc):

$$\text{Acc} = (S / N) * 100\% \quad [7]$$

Persamaan [7] mendefinisikan metrik reliabilitas sistem, di mana S adalah jumlah sampel yang berhasil didekode secara valid dan N adalah total populasi sampel. Akurasi ini menjadi indikator utama dalam pemetaan batas kegagalan (*failure boundary*) algoritma dekoding terhadap berbagai tingkat distorsi kanal.


WeChatQRCode memperkenalkan arsitektur detektor SSD internal yang dikombinasikan dengan modul *Super-Resolution*. Analisis derivatif pertama dari gradien piksel (VI) tetap relevan untuk memahami kegagalan metode klasik.

3. METODE PENELITIAN

Penelitian ini menerapkan pendekatan kuantitatif eksperimental dengan mengembangkan sistem hibrida yang menggabungkan deteksi objek dan dekoding neural. Alur kerja penelitian dirancang untuk memisahkan beban kerja antara lokalisasi objek dan interpretasi data, sesuai dengan standar praktik baik dalam *computer vision* modern.

Secara komprehensif, metodologi ini dibagi menjadi empat tahapan utama yang dapat dilihat pada Gambar 1:


1. Inisialisasi Model: Tahap awal melibatkan pemuatan (*loading*) arsitektur YOLO-v5 Nano yang ringan untuk deteksi dan weight WeChatQRCode (SSD-based) beserta modul SR untuk dekoding.
2. Deteksi dan Pre-processing: Citra input (normal maupun terdistorsi) diproses melalui YOLO-v5 untuk menghasilkan bounding box koordinat barcode. Jika terdeteksi, sistem melakukan ekstraksi *Region of Interest* (ROI) melalui proses *cropping*.
3. Dekoding Komparatif: ROI yang telah diekstrak secara bersamaan dikirim ke dua mesin dekoding; Pyzbar (heuristik) dan WeChatQRCode (*CNN-based*). Hal ini menjamin bahwa kedua algoritma diuji pada subset data citra yang identik (bit-identical).
4. Akuisisi Data: Status keberhasilan dekoding (*Success/Fail*) dan latensi eksekusi dicatat ke dalam benchmark logger untuk kemudian diolah secara statistik menggunakan metrik yang telah didefinisikan pada bagian 2.2.



Gambar 1. Alur Kerja Sistem Hibrida Deteksi YOLO-v5 dan Dekoding CNN

3.1 Pengembangan Dataset Sintetis

Dataset terdiri dari 400 sampel unik (ISO/IEC 18004, Level 'M'). Penggunaan data sintetis menjamin reproduksibilitas, isolasi variabel gangguan, serta integritas *ground-truth* absolut untuk metadata URL logistik.



Gambar 2. Kerangka Kerja Distorsi pada Dataset Uji

Gambar 2 merepresentasikan kategorisasi distorsi yang dirancang untuk mensimulasikan noise kanal (*channel noise*) pada lingkungan operasional nyata. Penggunaan *Gaussian Blur* memodelkan kegagalan optik akibat keterbatasan autofokus atau pergerakan objek yang cepat (*motion blur*), yang secara teknis mengaburkan gradien tepi pada modul barcode. Penambahan *Additive White Gaussian Noise* (AWGN) dengan magnitudo $\sigma=10$ hingga $\sigma=50$ bertujuan untuk menguji batas SNR (*Signal-to-Noise Ratio*) minimum di mana algoritma dekoding masih dapat mempertahankan integritas data. Terakhir, rotasi geometris diimplementasikan untuk mengevaluasi ketangguhan algoritma terhadap inkonsistensi sudut pandang kamera, yang seringkali menjadi titik lemah bagi dekoder berbasis scanline tradisional yang sangat bergantung pada orientasi horizontal atau vertikal yang presisi.

Meskipun fokus utama penelitian adalah analisis melalui simulasi terkontrol, studi ini menyertakan validasi kualitatif menggunakan sampel barcode dari lingkungan industri nyata. Sampel ini mencerminkan kondisi label yang terdeformasi secara fisik seperti ditunjukkan pada Gambar 3, memiliki kontras rendah akibat pencahayaan gudang, dan kontaminasi permukaan. Validasi ini dilakukan untuk memastikan bahwa profil kegagalan (*Cliff Effect*) yang terdeteksi pada data sintetis memiliki korelasi langsung dengan insidensi kegagalan di lapangan.



Gambar 3. Representasi Sampel Industri dengan Degradasi Ekstrem

3.2 Parameter Analisis Teknis

Evaluasi performa difokuskan pada dua metrik fundamental yang merepresentasikan *trade-off* antara kecepatan dan reliabilitas: latensi eksekusi dan *Success Rate* (SR).

1. Pengukuran Latensi: Latensi diukur dalam milidetik (ms) menggunakan fungsi `time.perf_counter()` yang menawarkan presisi tingkat nanodetik pada arsitektur sistem modern. Dua kategori latensi dianalisis secara terpisah: a) *Cold-Start Latency*, yang menangkap overhead inisialisasi awal termasuk pemuatan model ke dalam memori aplikasi dan kompilasi JIT (*Just-In-Time*); dan b) *Warm-Start Latency*, yang diukur melalui rata-rata dari 100 iterasi berkelanjutan untuk menangkap statistik performa *steady-state* tanpa interferensi dari caching awal.
2. *Success Rate (SR)*: Metrik ini didefinisikan sebagai rasio antara jumlah sampel citra yang berhasil didekode dengan benar secara sintaksis terhadap total populasi sampel ($N=400$). Keberhasilan dekoding ditentukan secara ketat melalui perbandingan string (*exact string matching*) antara output dekoder dengan *ground-truth* payload. Setiap ketidakcocokan karakter tunggal (jarak Levenshtein > 0) diklasifikasikan sebagai kegagalan dekoding ($SR=0$) untuk menjamin integritas data absolut dalam alur kerja logistik industri.

3.3 Implementasi Algoritma

Implementasi sistem ini didasarkan pada arsitektur hibrida yang memisahkan beban kerja antara lokalisasi objek dan interpretasi data (decoding). Pendekatan ini dipilih untuk memaksimalkan efisiensi komputasi dengan membatasi area pencarian dekoder hanya pada wilayah yang memiliki probabilitas tinggi mengandung barcode, sehingga meminimalkan kegagalan akibat noise latar belakang yang kompleks. Alur logika sistematis dari framework ini disajikan dalam *pseudo-code* berikut:

ALGORITMA Dekoding_Barcode_Hibrida_Detail:
MASUKAN: Citra_Uji I, Model_YOLOv5 M_det,
Model_WeChat M_dec
KELUARAN: Hasil_Dekoding S, Metadata_Studi T

1. INISIALISASI:
 - a. Muat Bobot M_det (YOLOv5-Nano)
 - b. Muat Arsitektur M_dec (SSD + Super_Resolution)
2. PROSES_MULAI:
 - a. Mulai Pencatat_Waktu (Resolusi Nanodetik)
 - b. Lakukan Inferensi: $\text{Prediksi_Box} = \text{M_det.Deteksi}(I)$
3. KONTROL_LOGIKA:

JIKA Prediksi_Box ditemukan MAKA:

 - a. Ekstraksi Koordinat (x, y, w, h)

- b. Lakukan Cropping: $\text{ROI} = \text{Citra_Potong}(I, \text{Prediksi_Box})$
- c. Lakukan Dekoding Paralel:
 - i. $\text{S_Tradisional} = \text{Pyzbar.Dekode}(\text{ROI})$
 - ii. $\text{S_Neural} = \text{M_dec.Dekode_SR}(\text{ROI})$
- d. Verifikasi_Integritas:

JIKA $\text{S_Neural} == \text{Ground_Truth}$ MAKA:

Status = "SUKSES", Hasil = S_Neural

ELSE JIKA $\text{S_Tradisional} == \text{Ground_Truth}$ MAKA:

Status = "SUKSES", Hasil = S_Tradisional

ELSE:

Status = "GAGAL", Hasil = NULL

ELSE:

Status = "TIDAK_TERDETEKSI", Hasil = NULL
4. AKUISISI_DATA:
 - a. Berhenti_Pencatat_Waktu -> Durasi_Eksekusi
 - b. Simpan (Hasil, Status, Durasi_Eksekusi) ke Database_Benchmark
5. SELESAI

Secara teknis, algoritma ini menerapkan prinsip redundansi data di mana dua mesin dekoding bekerja secara paralel terhadap *Region of Interest (ROI)* yang sama. YOLO-v5 Nano bertindak sebagai penapis awal untuk menjamin integritas spasial, sementara modul *Super-Resolution (SR)* pada WeChatQRCode berfungsi sebagai modul prapemrosesan neural yang merekonstruksi tepi barcode yang telah terdegradasi sebelum tahap klasifikasi akhir. Struktur percabangan pada kontrol logika memastikan bahwa sistem selalu memprioritaskan hasil dengan integritas data tertinggi (*exact matching*), sekaligus mencatat metrik latensi *Cold-Start* dan *Warm-Start* untuk keperluan analisis statistik yang mendalam.

4. HASIL DAN PEMBAHASAN

4.1 Karakteristik Latensi: Deterministik vs Probabilistik


Analisis data pada Tabel 1 menunjukkan bahwa Pyzbar secara konsisten lebih cepat dalam skenario ideal. Namun, terdapat variabilitas yang lebih tinggi pada Pyzbar karena alurnya yang berbasis percabangan heuristik (probabilistik).

Tabel 1. Statistik Latensi Warm-Start (100 Iterasi)

Method	Mean	Std	Min
Pyzbar	1.346	0.111	1.238
WeChat	4.855	0.497	4.32

Data pada Tabel 1 memperlihatkan kontras yang signifikan antara pendekatan berbasis *scanline* dan *neural inference*.

Meskipun Pyzbar mencapai nilai rata-rata (*mean*) terendah sebesar 1.35 ms, standar deviasinya mencerminkan ketidakpastian (*jitter*) yang lebih besar karena ketergantungannya pada iterasi *bar-search* yang bersifat probabilistik tergantung pada kompleksitas citra. Sebaliknya, WeChatQRCode menunjukkan nilai standar deviasi yang sangat rendah relatif terhadap rata-ratanya, yang menunjukkan profil latensi deterministik. Hal ini disebabkan oleh arsitektur *backbone neural network* yang melakukan operasi perkalian matriks secara konstan pada setiap bingkai input, memberikan jaminan waktu eksekusi yang lebih terprediksi, suatu kriteria mutlak yang seringkali mengungguli kecepatan murni dalam desain sistem otomasi industri yang kritis.



Gambar 4. Perbandingan Profil Latensi Antar Algoritma.

Visualisasi profil latensi pada Gambar 3 mempertegas perbedaan fundamental dalam mekanisme pemrosesan data. Grafik Pyzbar menunjukkan fluktuasi (*spikes*) yang sering terjadi, yang mencerminkan sifat algoritma heuristik di mana waktu komputasi sangat bergantung pada posisi barcode dalam frame dan tingkat kompleksitas noise latar belakang. Sifat non-deterministik ini dapat menyebabkan antrean data pada buffer sistem dalam skenario throughput tinggi. Sebaliknya, profil latensi WeChatQRCode membentuk garis yang hampir linear dan stabil. Stabilitas ini merupakan manifestasi dari arsitektur fixed-depth neural network, di mana setiap citra melewati jumlah lapisan konvolusi dan *pooling* yang sama. Dalam konteks integrasi sistem industri, linearitas latensi ini memungkinkan perancangan parameter Quality of Service (QoS) yang lebih presisi dan mengurangi risiko kegagalan sinkronisasi pada lini produksi otomatis.

4.2 Robustness dan Fenomena “Cliff Effect”

Temuan paling signifikan adalah kerentanan Pyzbar terhadap noise Gaussian. Grafik pada Gambar 4 menunjukkan penurunan performa yang mendadak atau Cliff Effect.

Robustness Comparison across Channel Distortions

Visual Constraint Scenario	Pyzbar	WeChat
Clean	OK	OK
Blur 3x3	OK	OK
Blur 5x5	OK	OK
Blur 7x7	OK	OK
Rotate 5	OK	OK
Rotate 15	OK	OK
Rotate 30	OK	OK
Noise $\sigma=10$	OK	OK
Noise $\sigma=25$	FAIL	OK
Noise $\sigma=50$	FAIL	OK
Low Contrast	OK	OK

Framework

Gambar 5. Matriks Ketangguhan Terhadap *Noise* dan *Blur*

Gambar 4 menyajikan perbandingan success rate yang sangat kontras melalui visualisasi heatmap. Fenomena *Cliff Effect* terlihat jelas pada Pyzbar, di mana performa dekoding jatuh secara drastis dari 100% menjadi 0% saat intensitas *noise Gaussian* melewati ambang batas kritis $\sigma=25$. Kegagalan ini secara matematis berkorelasi dengan degradasi gradien piksel (∇I) yang dibahas pada bagian 2.1, di mana noise frekuensi tinggi menginterferensi proses binarisasi adaptif. Sebaliknya, WeChatQRCode menunjukkan ketahanan absolut (warna solid pada *heatmap*) di seluruh spektrum gangguan. Ketangguhan ini berasal dari arsitektur konvolusional yang secara intrinsik melakukan operasi pemulusan (*smoothing*) dan ekstraksi fitur tingkat tinggi yang kebal terhadap artefak noise tingkat rendah hingga menengah. Hal ini membuktikan bahwa pendekatan *deep learning* mampu mempertahankan integritas informasi spasial bahkan pada kondisi sinyal terdegradasi parah yang melampaui limitasi algoritma pengolahan citra klasik.

Tabel 2. Tingkat Keberhasilan Skenario Berbasis Ketegaran

Skenario Distorsi	Akurasi Pyzbar (%)	Akurasi WeChat (%)	Avg Lat (ms) Pyz	Avg Lat (ms) WC
blur	100.0%	100.0%	2.29	7.71
clean	100.0%	100.0%	2.05	6.84
noise	0.0%	100.0%	14.23	7.76
rotate	100.0%	100.0%	2.68	7.37

Implementasi YOLOv5 yang digabungkan dengan dekoder tradisional seperti Pyzbar sebelumnya telah dilaporkan efektif dengan tingkat keberhasilan 91% pada dataset industri [21]. Namun, hasil eksperimen pada Tabel 2 menunjukkan bahwa reliabilitas tersebut bersifat *fragile* terhadap interferensi kanal. Berbeda dengan studi [21], penelitian ini mengekspos fenomena *Cliff Effect* di mana akurabilitas Pyzbar jatuh dari 100% menjadi 0% secara instan saat noise σ melampaui 25. Keunggulan dari penggunaan WeChatQRCode adalah kemampuannya mempertahankan *Success Rate* (SR) 100% secara konsisten, menjustifikasi overhead latensi 3,6x sebagai investasi bagi reliabilitas sistem logistik mandiri yang mutlak diperlukan pada ekosistem Industri 4.0.

5. KESIMPULAN DAN SARAN

4.1 Kesimpulan Utama

Penelitian ini menyimpulkan bahwa implementasi sistem hibrida YOLOv5 dan WeChatQRCode memberikan lonjakan reliabilitas yang signifikan dibandingkan konfigurasi standar YOLOv5 dan Pyzbar [21]. Sementara studi [21] melaporkan tingkat akurasi dekoding sebesar 91%, hasil eksperimen kami membuktikan bahwa penggunaan *CNN-based decoding* (WeChatQRCode) mampu mencapai *Success Rate* (SR) 100% secara konsisten, bahkan pada spektrum gangguan ekstrem. Keunggulan penelitian ini terletak pada identifikasi fenomena *Cliff Effect* pada $\sigma=25$ bagi algoritma tradisional, sebuah batasan operasional yang tidak terdeteksi dalam penelitian sebelumnya [21]. Meskipun terdapat peningkatan latensi rata-rata sebesar 3,6x, stabilitas latensi deterministik yang ditawarkan oleh arsitektur neural memberikan fondasi reliabilitas yang jauh lebih kokoh bagi ekosistem Industri 4.0

yang menuntut redundansi data absolut dalam lingkungan *unconstrained*.

Meskipun hasil eksperimen menunjukkan keunggulan mutlak WeChatQRCode dalam aspek reliabilitas, terdapat beberapa kritik kuantitatif yang perlu diperhatikan bagi implementasi praktis. Pertama, terkait konsumsi sumber daya, WeChatQRCode memerlukan beban memori (RAM) yang diperkirakan 15-20 kali lebih besar dibandingkan Pyzbar, dengan latensi rata-rata yang meningkat sebesar 3,6x (dari 1,35 ms menjadi 4,86 ms). Konsekuensi teknis ini menjadikan Pyzbar tetap sebagai opsi yang lebih rasional untuk perangkat IoT daya rendah (low-power MCU) dengan keterbatasan memori di bawah 128MB, meskipun terdapat risiko kegagalan dekoding pada kondisi bising. Kedua, dari sisi kompleksitas integrasi, WeChatQRCode melibatkan dependensi pada empat file model eksternal dengan total ukuran sekitar 30,5 MB, jauh melampaui ukuran biner Pyzbar yang berada di bawah 2 MB, sehingga berdampak pada proses distribusi aplikasi dan waktu inisialisasi (*Cold-Start*) yang lebih lambat. Terakhir, limitasi pengujian saat ini yang didominasi oleh noise sintetis terkontrol menyisakan gap penelitian pada distorsi non-linear seperti pantulan cahaya (*specular reflection*) atau distorsi perspektif ekstrem yang mungkin memiliki profil kegagalan berbeda bagi arsitektur neural tersebut.

4.2 Arah Penelitian Lanjutan

Penelitian ini membuka beberapa peluang pengembangan strategis untuk penelitian lanjutan di masa depan. Pertama, optimasi model melalui teknik kuantisasi (*quantization*) dan pemangkasan (*pruning*) sangat diperlukan untuk mereduksi overhead komputasi WeChatQRCode tanpa mengorbankan ketangguhan deteksi. Kedua, pengujian lapangan menggunakan data video real-time dari infrastruktur CCTV industri perlu dilakukan untuk menguji sistem terhadap degradasi visual non-sintetis seperti motion blur asli dan fluktuasi pencahayaan ekstrem. Terakhir, integrasi akselerasi perangkat keras berbasis kerangka kerja OpenVINO atau TensorRT menjadi langkah krusial untuk memindahkan beban inferensi neural ke unit NPU atau GPU terintegrasi, yang berpotensi menekan latensi hingga ke level sub-milidetik [13, 20].

6. DAFTAR PUSTAKA

- [1] A. S. Putra et al., "Quick response code recognition based on convolutional neural network," *TELKOMNIKA*, vol. 18, no. 1, pp. 542–550, 2020.
- [2] M. A. F. Fitrianto, "Barcode recognition using deep learning approach for automated logistics," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 12, no. 3, pp. 2891–2900, 2022.
- [3] H. Santoso and A. Wijayanto, "Deep Learning-based QR Code Detection in Industrial Packaging Lines using Convolutional Neural Networks," *Jurnal Teknologi dan Sistem Komputer (JTSISKOM)*, vol. 11, no. 1, pp. 45–52, 2023.
- [4] R. Ramadhan et al., "Comparison of YOLOv5 and YOLOv7 for QR Code Detection in Smart Warehouse Environments," *Scientific Journal of Informatics (SJI)*, vol. 10, no. 2, pp. 215–224, 2023.
- [5] A. Pradana, "YOLOv8 Implementation for High-Speed Barcode Detection in Logistics Systems," *Register: Jurnal Ilmiah Teknologi Sistem Informasi*, vol. 10, no. 1, pp. 12–25, 2024.
- [6] D. Setiawan and B. Pratama, "Real-time Barcode Scanner using Deep Learning for Warehouse Management," *CommIT (Communication and Information Technology) Journal*, vol. 15, no. 2, pp. 89–98, 2021.
- [7] F. Kurniawan et al., "Facemask detection using the YOLO-v5 algorithm: assessing dataset variation and resolutions," *Register: Jurnal Ilmiah Teknologi Sistem Informasi*, vol. 9, no. 2, pp. 95–102, 2023.
- [8] B. S. Prajatmeto et al., "Deteksi Pelanggaran Lalu Lintas di Jalan Tol Menggunakan YOLOv5," *Jurnal Teknologi dan Sistem Komputer (JTSISKOM)*, vol. 11, no. 2, pp. 65–72, 2023.
- [9] I. G. N. A. C. Putra et al., "Implementation of YOLOv5 for Smart Parking System based on Object Detection," *JNTETI*, vol. 11, no. 3, pp. 180–187, 2022.
- [10] J. Jumali et al., "Real-time helmet detection on motorcyclists using YOLOv5 for safety compliance," *Bulletin of Electrical Engineering and Informatics (BEEI)*, vol. 11, no. 4, pp. 2210–2218, 2022.
- [11] K. S. Al-Sabbagh et al., "Face mask detection using YOLOv5 for COVID-19 safety monitoring," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 11, no. 5, pp. 4320–4329, 2021.
- [12] Y. A. Singgalen, "Performance Evaluation of YOLOv8 for Object Detection in Uncontrolled Industrial Environments," *Register: Jurnal Ilmiah Teknologi Sistem Informasi*, vol. 10, no. 1, pp. 45–58, 2024.
- [13] S. L. Mohammad et al., "High-performance object detection using modified YOLOv5 in traffic monitoring," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 12, no. 1, pp. 750–759, 2022.
- [14] M. Ridho et al., "YOLO vs. CNN Algorithms: A Comparative Study in Masked Face Recognition," *Scientific Journal of Informatics (SJI)*, vol. 11, no. 1, pp. 139–150, 2024.
- [15] N. Nazir et al., "Deep Learning-based Image Enhancement for Low-Light Object Detection in Security Systems," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 13, no. 2, pp. 1520–1530, 2023.
- [16] M. A. U. Naser, "QR code based two-factor authentication to verify paper-based documents against forgery," *TELKOMNIKA*, vol. 18, no. 6, pp. 3140–3148, 2020.
- [17] A. M. Al-Ghaili, "QR code based authentication method for IoT applications using cryptographic techniques," *TELKOMNIKA*, vol. 18, no. 6, pp. 2854–2863, 2020.
- [18] S. Ningsih et al., "Sign language detection system using YOLOv5 and Transfer Learning," *Scientific Journal of Informatics (SJI)*, vol. 9, no. 2, pp. 178–188, 2022.
- [19] T. Mantoro et al., "Implementation of CNN for Industrial Barcode Recognition under Complex Backgrounds," *ComTech*, vol. 13, no. 1, pp. 33–42, 2022.
- [20] M. Yani et al., "Advanced Noise Reduction in Computer Vision using Deep CNN for Industrial Applications," *Scientific Journal of Informatics (SJI)*, vol. 11, no. 2, pp. 250–262, 2024.
- [21] *IOSR Journal of Computer Engineering*, "Integrating YOLO-v5 and Pyzbar for Accurate and Efficient Barcode Recognition System," *IOSR-JCE*, vol. 26, no. 3, pp. 42–46, 2024.