



Deteksi Pemalsuan QRIS MPM Statis Menggunakan YOLO, PaddleOCR dan Metode Berbasis Aturan

I Putu Gede Dharma Saputra*, Made Windu Antara Kesiman, I Made Gede Sunarya

Fakultas Teknik dan Kejuruan, Program Studi Pendidikan Teknik Informatika, Universitas Pendidikan Ganesha, Singaraja, Indonesia

Email: ^{1,*}dharmasaputraa00@gmail.com, ²antara.kesiman@undiksha.ac.id, ³sunarya@undiksha.ac.id

Email Penulis Korespondensi: dharmasaputraa00@gmail.com

Abstrak—Transformasi sistem pembayaran digital melalui *Quick Response Code Indonesian Standard (QRIS) Merchant Presented Mode (MPM) Statis* telah memberikan kemudahan bagi UMKM, namun juga memicu peningkatan risiko keamanan serius berupa serangan *quishing* melalui penempelan stiker palsu. Penelitian ini bertujuan untuk mengembangkan sebuah sistem deteksi pemalsuan yang terintegrasi secara komprehensif menggunakan arsitektur *Single-Stage Detector YOLOv11* dan mesin inferensi berbasis aturan (*rule-based engine*). Metodologi penelitian ini mencakup pembangunan dataset yang representatif sebanyak 898 citra serta penerapan mekanisme tiga lapisan validasi utama yang meliputi analisis tata letak spasial sesuai standar ASPI, validasi semantik tekstual menggunakan PaddleOCR, serta verifikasi geospasial berdasarkan koordinat GPS. Sistem ini mengimplementasikan algoritma *SequenceMatcher* dengan ambang batas adaptif guna mengakomodasi keberagaman tipografi pada *merchant*. Hasil pengujian menunjukkan bahwa varian YOLOv11-m memberikan akurasi lokalisasi terbaik dengan skor *mean Average Precision (mAP) 50-95* sebesar 0,8682. Evaluasi *end-to-end* terhadap citra uji menghasilkan akurasi sistem keseluruhan sebesar 96,15%. Secara signifikan, sistem mencapai nilai *recall* 1,00 pada kelas *suspicious*, yang membuktikan kemampuan sistem dalam mengidentifikasi seluruh potensi ancaman manipulasi visual tanpa ada yang terlewatkan. Meskipun terdapat kendala pada citra buram yang menurunkan *recall* kelas *authentic* menjadi 0,90, prinsip keamanan tetap terjaga dengan mengklasifikasikan data yang tidak tervalidasi sebagai *suspicious*. Penelitian ini memberikan kontribusi nyata dalam memperkuat integritas pembayaran digital melalui mekanisme deteksi yang presisi, ringan, dan sesuai dengan regulasi nasional Indonesia.

Kata Kunci: QRIS; Pemalsuan; YOLOv11; PaddleOCR; Computer Vision; Keamanan Pembayaran

Abstract—Transforming the digital payment system through Quick Response Code Indonesian Standard (QRIS) Static Merchant Presented Mode (MPM) has provided convenience for MSMEs, yet also triggered significant security risks, particularly quishing attacks involving fraudulent sticker overlays. This research aims to develop a comprehensively integrated fraud detection system using the YOLOv11 Single-Stage Detector architecture and a rule-based inference engine. The research methodology includes the construction of a representative dataset of 898 images and the implementation of a three-layer validation mechanism comprising spatial layout analysis based on ASPI standards, textual semantic validation using PaddleOCR, and geospatial verification of GPS coordinates. The system utilizes the SequenceMatcher algorithm with adaptive thresholds to accommodate merchant typography variations. Experimental results indicate that the YOLOv11-m variant provides the best localization accuracy with a mean Average Precision (mAP) 50-95 score of 0.8682. End-to-end evaluation test images yielded an overall system accuracy of 96.15%. Significantly, the system achieved a recall of 1.00 for the suspicious class, proving its ability to identify all potential visual manipulation threats without omission. Although blurred images lowered the authentic class recall to 0.90, security principles remained intact by classifying unvalidated data as suspicious. This study provides a significant contribution to strengthening digital payment integrity through a precise, lightweight detection mechanism aligned with Indonesian national regulations.

Keywords: QRIS; Fraud; YOLOv11; PaddleOCR; Computer Vision; Payment Security

1. PENDAHULUAN

Transformasi digital telah menjadi pendorong utama modernisasi sistem pembayaran di Indonesia, menciptakan pergeseran fundamental menuju ekosistem non-tunai yang lebih inklusif. Salah satu instrumen utama yang menjadi katalisator perubahan ini adalah *Quick Response Code Indonesian Standard (QRIS)*, yang diluncurkan oleh Bank Indonesia melalui PBI No.21/18/PBI/2019 [1]. QRIS dirancang untuk menciptakan sistem pembayaran yang efisien dan terstandarisasi bagi berbagai platform pembayaran digital, sehingga memungkinkan interoperabilitas antar penyedia jasa pembayaran. Dalam penerapannya, QRIS memiliki dua mode utama: *Merchant Presented Mode (MPM)* dan *Customer Presented Mode (CPM)*. QRIS MPM statis, yang berbentuk stiker atau cetakan fisik, menjadi pilihan populer bagi segmen Usaha Mikro, Kecil, dan Menengah (UMKM) karena kemudahannya implementasinya tanpa memerlukan perangkat kasir yang kompleks [2]. Keberhasilan adopsinya tercermin dari jumlah merchant yang terus tumbuh pesat hingga mencapai angka puluhan juta di seluruh wilayah Indonesia, menjadikannya tulang punggung ekonomi digital nasional [3].

Namun, pesatnya adopsi QRIS MPM Statis memunculkan tantangan keamanan yang signifikan bagi ekosistem finansial digital. Karena mengandalkan media fisik seperti stiker atau *print-out*, QRIS ini sangat rentan terhadap manipulasi fisik seperti serangan *quishing (QR phishing)*, di mana pelaku menempelkan stiker QRIS palsu di atas QRIS asli milik pedagang. Kasus empiris yang mencuat pada tahun 2023 menunjukkan modus pemalsuan QRIS di kotak amal berbagai masjid di Jakarta, di mana dana donasi dialihkan ke rekening pribadi pelaku dengan memanipulasi tampilan visual nama *merchant* [4]. Insiden manipulasi visual seperti ini tidak hanya mengakibatkan kerugian finansial yang substansial tetapi juga berpotensi menggerus kepercayaan publik terhadap keandalan sistem pembayaran digital, yang jika dibiarkan dapat menghambat laju inklusi keuangan nasional.

Penelitian mitigasi sebelumnya telah dilakukan, seperti oleh Ajhari [5] yang mengusulkan sistem autentikasi ganda berbasis lokasi untuk mencegah *quishing*. Namun, pendekatan tersebut belum menginkorporasikan parameter validasi tampilan visual yang sesuai dengan regulasi resmi Asosiasi Sistem Pembayaran Indonesia (ASPI) dalam Buletin No:



3/III/2021 mengenai Tampilan QRIS MPM. Padahal, secara teknis, integritas atribut visual merupakan indikator fisik pertama yang dapat diverifikasi oleh sistem sebelum melakukan pemrosesan data digital lebih lanjut. Untuk menangani validasi struktur dokumen secara otomatis, beberapa teknologi telah dikembangkan. Penggunaan model multimodal seperti *LayoutLMv3* [6] menawarkan akurasi tinggi dalam memahami dokumen, namun terbukti tidak efisien untuk aplikasi seluler karena rendahnya kecepatan proses atau *Frame Per Second* (FPS) yang hanya sebesar 9,0 dibandingkan model deteksi objek yang lebih ringan [7]. Di sisi lain, penggunaan teknologi *Optical Character Recognition* (OCR) seperti pada penelitian Sasinath [8] dan Bagaria [9] menunjukkan efektivitas dalam ekstraksi teks, namun belum mampu melakukan validasi struktur dokumen secara utuh tanpa integrasi dengan model deteksi objek yang mumpuni.

Berdasarkan tinjauan tersebut, muncul *gap analysis* di mana terdapat kebutuhan akan sistem keamanan yang akurat namun cukup ringan untuk melakukan analisis *layout* dokumen secara *real-time* di perangkat *mobile*. Oleh karena itu, penelitian ini berfokus pada pengembangan sistem deteksi objek menggunakan algoritma YOLO (*You Only Look Once*) yang dikombinasikan dengan metode *rule-based* untuk validasi spasial. YOLO merupakan algoritma deteksi objek yang populer karena kemampuannya dalam melakukan deteksi dalam satu proses jaringan saraf tunggal tanpa melalui tahap *region proposal* seperti pada metode dua tahap [10], [11], [12]. Pendekatan ini berimplikasi pada peningkatan efisiensi komputasi secara signifikan, sehingga model mampu memenuhi kriteria pemrosesan secara *real-time* bahkan pada perangkat dengan sumber daya terbatas seperti perangkat seluler [13]. Algoritma ini terus berkembang hingga versi terbaru yaitu YOLOv11 yang mengoptimalkan kecepatan dan akurasi secara bersamaan [11]. Penelitian terbaru oleh Natih [14] menunjukkan bahwa dalam implementasi praktis, pemilihan varian arsitektur dan *optimizer* pada YOLOv11 sangat krusial untuk menyeimbangkan antara *cost* (ukuran model dan kecepatan inferensi) serta *benefit* (akurasi deteksi).

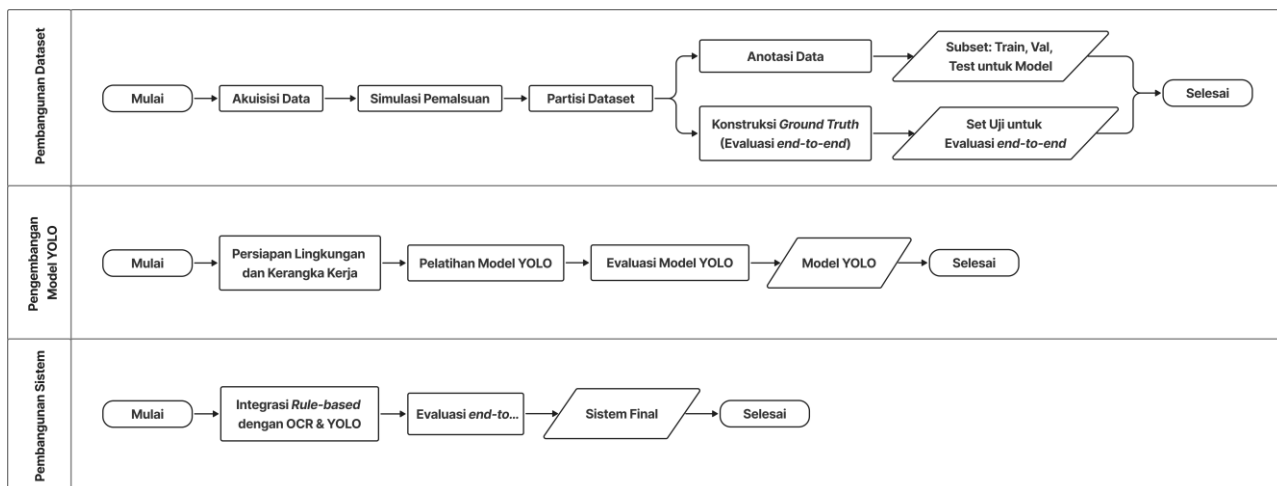
Efektivitas YOLO dalam analisis struktur dokumen telah dibuktikan oleh Santos Júnior [15], di mana YOLOv11 menunjukkan performa yang paling seimbang dalam mendeteksi struktur visual dokumen secara presisi. Temuan ini sejalan dengan studi analisis *cost-benefit* pada YOLOv11 yang menemukan bahwa varian model yang lebih ringan, seperti YOLOv11n, mampu memberikan keseimbangan optimal antara akurasi tinggi dan efisiensi komputasi [14]. Hal ini menjadikannya kandidat ideal untuk implementasi pada perangkat dengan sumber daya terbatas atau *edge devices* seperti *smartphone*. Inovasi pada arsitektur YOLOv11, seperti penggunaan blok C3K2, modul SPPF (*Spatial Pyramid Pooling - Fast*), dan blok C2PSA, meningkatkan kemampuan pemrosesan informasi spasial tanpa mengorbankan kecepatan inferensi [16], [17]. Namun, deteksi objek saja tidak cukup untuk menentukan keaslian dokumen tanpa adanya logika yang mengatur hubungan antar objek tersebut. Di sinilah metode *rule-based* menjadi komponen krusial untuk mengevaluasi apakah posisi logo GPN, logo QRIS, dan *QR Code* hasil deteksi YOLOv11 telah memenuhi parameter jarak serta tata letak yang diatur secara resmi oleh ASPI.

Penelitian ini mengusulkan sistem keamanan terintegrasi melalui tiga lapisan validasi. Lapisan pertama menggunakan model YOLOv11 yang dilatih untuk mengidentifikasi atribut visual wajib, yang kemudian diproses melalui metode *rule-based* untuk memastikan kepatuhan terhadap standar tata letak nasional. Lapisan kedua berfokus pada konsistensi data menggunakan teknologi PaddleOCRv5 untuk mengekstrak informasi tekstual seperti nama *merchant* dan NMID untuk dicocokkan dengan data dekode EMVCo. Terakhir, validasi lokasi memverifikasi koordinat GPS pengguna terhadap lokasi resmi *merchant*. Sistem ini dirancang untuk memberikan peringatan dini kepada pengguna jika terdeteksi potensi pemalsuan. Dengan memfokuskan pengembangan pada sinergi antara YOLOv11 dan metode *rule-based* sebagai inti dari analisis tata letak, penelitian ini bertujuan merancang sebuah model keamanan inovatif yang mampu memperkuat integritas ekosistem pembayaran digital di Indonesia melalui mekanisme deteksi yang presisi, ringan, dan sesuai dengan regulasi nasional.

Secara keseluruhan, penelitian ini memberikan kontribusi pada penguatan sistem keamanan pembayaran digital melalui tiga aspek utama. Pertama, pengembangan *pipeline* validasi yang menyelaraskan arsitektur YOLOv11 dengan standar visual resmi ASPI (Buletin ASPI No. 3/III/2021), sehingga sistem mampu melakukan verifikasi integritas tata letak sesuai standar, bukan sekadar deteksi objek umum. Kedua, optimalisasi model untuk *edge device* yang memungkinkan deteksi *real-time* dengan efisiensi komputasi tinggi, menjawab keterbatasan kecepatan pada model *multimodal* sebelumnya. Ketiga, penyediaan mekanisme pertahanan berlapis yang mengintegrasikan validasi visual, tekstual (OCR), dan spasial (GPS) sebagai solusi proaktif dalam memitigasi risiko serangan *quishing*. Kontribusi ini diharapkan dapat menjadi referensi teknis dalam menjaga kepercayaan publik terhadap ekosistem QRIS di Indonesia.

2. METODOLOGI PENELITIAN

Metodologi penelitian ini mengadopsi pendekatan sistematis yang terbagi menjadi tiga tahapan utama, yang dirancang secara sekuensial untuk mencapai tujuan deteksi pemalsuan secara presisi dan reliabel. Pendekatan terstruktur ini penting untuk memastikan bahwa setiap komponen sistem, mulai dari kualitas data hingga logika pengambilan keputusan, memiliki validitas yang tinggi sebelum diintegrasikan. Tahapan tersebut meliputi: (1) pembangunan dataset melalui akuisisi data lapangan dan simulasi anomali guna menciptakan basis pengetahuan model; (2) pengembangan model YOLO melalui proses pelatihan intensif, optimasi arsitektur, dan evaluasi metrik deteksi; serta (3) pembangunan sistem terintegrasi yang menggabungkan deteksi objek dengan ekstraksi teks PaddleOCRv5 dan *rule-based engine* sebagai logika validasi spasial akhir. Alur kerja lengkap yang menggambarkan interkoneksi antar proses dalam penelitian ini dipaparkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

2.1 Pembangunan Dataset

Tahap pembangunan dataset bertujuan untuk menghasilkan himpunan data citra QRIS MPM Statis yang representatif, beragam, dan sesuai untuk kebutuhan pelatihan serta evaluasi sistem deteksi pemalsuan. Alur proses ini mencakup akuisisi data, simulasi pemalsuan, partisi dataset, anotasi, serta penyusunan *ground truth* untuk evaluasi *end-to-end*.

2.1.1 Akuisisi Data

Dataset diperoleh melalui pengambilan gambar langsung di berbagai unit usaha UMKM menggunakan kamera digital dan smartphone. Penggunaan kamera *smartphone* dipilih untuk mereplikasi skenario penggunaan perangkat yang umum tersedia di masyarakat dan memastikan model dapat bekerja pada perangkat dengan sumber daya terbatas [14]. Pendekatan pengambilan sampel dari berbagai lokasi ini penting untuk meningkatkan variasi citra sehingga sistem dapat lebih akurat dalam mempelajari fitur visual yang beragam [18]. Contoh sample citra QRIS MPM Statis diperlihatkan pada Gambar 2.



Gambar 2. Sampel citra QRIS MPM Statis

2.1.2 Pra-pemrosesan Geometris

Setiap citra QRIS diproses melalui tahap pemotongan (*cropping*) dan koreksi perspektif untuk menghasilkan gambar yang tegak lurus dan konsisten. Tahap pra-pemrosesan ini krusial untuk menstandarisasi input model dan memfokuskan area kerja pada objek yang relevan sebelum masuk ke tahap pelatihan [18], [19]. Hal ini dilakukan untuk mengoptimalkan kualitas visual citra sebelum dilakukan anotasi.

2.1.3 Rekayasa Data dan Simulasi Anomali

Proses rekayasa data dilakukan secara manual untuk mensimulasikan berbagai anomali pada atribut QRIS. Teknik manipulasi atau augmentasi data sintesis seperti ini terbukti efektif untuk memperkaya variasi data latih, terutama ketika data asli untuk kasus tertentu (seperti pemalsuan) sulit didapatkan dalam jumlah besar [20]. Skenario manipulasi mencakup empat kategori utama: penghapusan atribut standar, perubahan tata letak, penggantian atribut (*spoofing*), dan penambahan elemen anomali.

2.1.4 Partisi Dataset

Data yang sudah terkumpul kemudian dipartisi secara acak menjadi tiga subset independen. Pembagian dilakukan dengan rasio data latih sebagai porsi mayoritas untuk generalisasi model, serta data validasi dan data uji untuk memantau



performa selama dan setelah proses pengembangan. Data tersebut dipartisi secara acak menjadi tiga subset independen dengan rasio 80% data latih, 10% data validasi, dan 10% data uji. Rasio pembagian 80:10:10 ini merupakan praktik umum dalam pengembangan model *machine learning* untuk menjaga keseimbangan antara pembelajaran fitur dan validasi performa [14], [20]. Proporsi data latih yang dominan ini juga sejalan dengan prinsip Pareto yang sering diterapkan dalam *data mining* untuk memaksimalkan pola yang dapat dipelajari oleh model [18].

2.1.5 Anotasi Data

Seluruh dataset dianotasi menggunakan Label Studio dengan pendekatan *bounding box*. Teknik pelabelan *bounding box* dipilih karena kemampuannya yang presisi dalam melokalisasi objek spesifik dalam citra, yang merupakan standar dalam pelatihan model deteksi objek seperti YOLO [14], [21]. Pelabelan difokuskan pada dua jenis label utama:

- Atribut Standar QRIS: Mencakup atribut resmi sesuai Buletin ASPI No. 3/III/2021 yaitu Logo QRIS, Logo GPN, Nama *Merchant*, NMID, Terminal ID, QR code, Slogan, Situs QRIS, Informasi Cetak, dan Cara Pembayaran.
- Kelas Anomali: Untuk elemen visual tidak sah berupa teks dan gambar tambahan.

2.1.6 Penyusunan *Ground Truth* untuk Evaluasi *End-to-End*

Untuk setiap citra pada data uji, disusun berkas *ground truth* berformat JSON yang berfungsi sebagai referensi absolut dalam evaluasi sistem secara menyeluruh. Berkas ini memuat informasi status keaslian QRIS, konten QR, teks OCR, lokasi transaksi atau lokasi *merchant* serta anotasi atribut. Penggunaan *ground truth* yang terstruktur sangat penting untuk membandingkan hasil prediksi model dengan kondisi sebenarnya (*actual values*) guna mendapatkan metrik performa yang objektif [19]. Status keaslian diklasifikasikan ke dalam beberapa kategori, yaitu *Authentic*, *Suspicious*, *Authentic Loc Not Match*, *QR Link*, *No QR*, dan *QR Other*. *Ground truth* ini digunakan untuk membandingkan hasil prediksi sistem dengan kondisi sebenarnya sehingga memungkinkan evaluasi performa *end-to-end* secara objektif dan konsisten.

2.2 Pengembangan Model YOLO

Penelitian ini menggunakan arsitektur *Single-Stage Detector* modern, YOLOv11, yang menawarkan keseimbangan optimal antara kecepatan dan akurasi untuk memvalidasi integritas visual QRIS secara *real-time* [11]. Pendekatan *single-stage* seperti YOLO memiliki keunggulan kecepatan yang signifikan dibandingkan metode dua tahap (seperti R-CNN) karena memproses prediksi *bounding box* dan probabilitas kelas dalam satu evaluasi tunggal jaringan saraf [14]. Dalam konteks aplikasi praktis di lapangan, varian arsitektur YOLO yang lebih ringan (seperti YOLOv11n) terbukti memberikan efisiensi komputasi yang tinggi tanpa mengorbankan akurasi secara drastis, menjadikannya ideal untuk perangkat dengan sumber daya terbatas [14].

2.2.1 Persiapan Lingkungan Kerja

Pelatihan model YOLOv11 dilakukan pada lingkungan komputasi berbasis Python untuk memastikan efisiensi proses *training* yang intensif. Penggunaan lingkungan berbasis Python dan pustaka *deep learning* seperti PyTorch memungkinkan pemanfaatan akselerasi GPU secara optimal, yang krusial untuk mempercepat proses komputasi yang berat [14], [22].

2.2.2 Pelatihan Model

Pelatihan model dilakukan menggunakan arsitektur YOLOv11 (skala n hingga m) dengan pendekatan *transfer learning* untuk mengoptimalkan deteksi atribut QRIS dan elemen anomali. *Transfer learning* memungkinkan model memanfaatkan bobot yang telah dilatih sebelumnya (*pre-trained weights*) dari dataset besar, sehingga mempercepat konvergensi dan meningkatkan kinerja model pada dataset spesifik yang lebih kecil [24]. Pemilihan optimizer AdamW dimaksudkan untuk menjaga stabilitas pelatihan dan mencegah *overfitting* [16].

2.2.3 Evaluasi dan Metrik Kinerja Model

Dalam konteks deteksi objek menggunakan YOLO, kinerja model diukur berdasarkan komponen *Confusion Matrix* yang terdiri dari *True Positive* (TP), *False Positive* (FP), dan *False Negative* (FN). Komponen-komponen tersebut kemudian diturunkan menjadi metrik utama [14], [18], [21], [23], yaitu:

a. *Precision*

Metrik ini mengukur seberapa akurat prediksi positif yang dihasilkan oleh model. Nilai presisi yang tinggi mengindikasikan bahwa model memiliki tingkat kesalahan deteksi palsu (*False Positive*) yang rendah [24], [25].

$$Precision = \frac{TP}{TP+FP} \quad (1)$$

b. *Recall*

Dikenal juga sebagai sensitivitas, metrik ini mengukur kemampuan model dalam menemukan seluruh objek yang seharusnya terdeteksi (*ground truth*). Nilai *recall* yang tinggi menunjukkan bahwa model mampu meminimalkan objek yang terlewat (*False Negative*) [24], [25].

$$Recall = \frac{TP}{TP+FN} \quad (2)$$



c. *F1-Score*

Merupakan rata-rata harmonik dari *Precision* dan *Recall*. Metrik ini memberikan gambaran kinerja tunggal yang menyeimbangkan antara ketepatan deteksi dan kelengkapan deteksi, yang sangat berguna ketika terdapat ketidakseimbangan kelas dalam dataset [21], [24].

$$F1\ score = 2 \frac{Precision * Recall}{Precision + Recall} \quad (3)$$

d. *Mean Average Precision (mAP)*

Metrik mAP merupakan rata-rata dari *Average Precision (AP)* di seluruh kelas objek yang dideteksi. Dalam penelitian ini, evaluasi dilakukan menggunakan dua standar ambang batas *Intersection over Union (IoU)* sebagai berikut [14], [21], [23]:


1. mAP₅₀: Merepresentasikan rata-rata presisi pada ambang batas IoU sebesar 0,5. Metrik ini merupakan standar utama dalam deteksi objek, di mana sebuah prediksi dianggap benar (TP) jika area tumpang tindih (*overlap*) antara kotak prediksi dan *ground truth* mencapai minimal 50%.
2. mAP₅₀₋₉₅: Merupakan rata-rata dari nilai mAP yang dihitung pada rentang ambang batas IoU mulai dari 0,5 hingga 0,95 dengan interval 0,05. Metrik ini memberikan evaluasi yang lebih ketat dan komprehensif mengenai seberapa presisi posisi *bounding box* yang dihasilkan model terhadap objek target.

e. *Frames Per Second (FPS)*

Kecepatan Inferensi yang diukur untuk menguji efisiensi pemrosesan model.

2.3 Pembangunan Sistem Terintegrasi

Tahapan pengembangan sistem bertujuan untuk membangun sistem deteksi pemalsuan QRIS MPM Statis yang terintegrasi secara *end-to-end*. Pendekatan ini mengadopsi alur kerja siklus proyek AI (*AI Project Cycle*) yang mencakup akuisisi data, eksplorasi, pemodelan, hingga evaluasi untuk memastikan sistem dapat berjalan secara otomatis dan efisien [19]. Integrasi ini dirancang untuk mensinkronisasi aliran data dari berbagai sumber yang berbeda mulai dari citra visual, ekstraksi teks, hingga koordinat lokasi ke dalam satu *pipeline* pemrosesan tunggal. Hal ini sangat krusial untuk menjamin responsivitas sistem saat diimplementasikan pada perangkat seluler, di mana kecepatan eksekusi harus seimbang dengan kompleksitas data yang diolah. Pada tahap ini, seluruh komponen utama (YOLO, OCR, dan *Rule-Based*) digabungkan ke dalam satu kesatuan sistem utuh dengan alur yang digambarkan pada Gambar 3.



Gambar 3. Flowchart Sistem Terintegrasi/End-to-End.

2.3.1 Integrasi *Rule-Based*

Modul ini berfungsi sebagai pusat pengambilan keputusan (*decision-making center*) yang mengagregasi keluaran dari model YOLOv11 dan hasil ekstraksi teks menggunakan PaddleOCRv5. Mekanisme integrasi dibagi menjadi 3 lapisan validasi yang berfungsi sebagai pusat pengambilan keputusan antara lain:

a. Analisis Kehadiran & Tata Letak Spasial

Memverifikasi hierarki atribut visual berdasarkan koordinat *bounding box* YOLO. Teknik ini serupa dengan metode validasi dokumen kerja sama yang menggunakan deteksi objek untuk memverifikasi keberadaan dan jumlah komponen vital (seperti stempel, meterai, dan tanda tangan) dalam sebuah area *Region of Interest (ROI)* tertentu [19]. Dalam konteks ini, sistem memastikan elemen kritis berada pada posisi yang seharusnya sesuai Buletin ASPI No: 3/III/2021. Jika komponen wajib tidak terdeteksi atau jumlahnya tidak sesuai dengan *ground truth* standar, dokumen dapat langsung dikategorikan sebagai anomali.

b. Validasi Tekstual

Validasi tekstual dilakukan melalui inspeksi terhadap konten teks yang berhasil diekstraksi oleh modul OCR untuk menjamin integritas data semantik. Proses ini diawali dengan tahap normalisasi teks menggunakan *Regular Expression (Regex)* untuk membersihkan simbol-simbol *noise* hasil pemindaian. Selanjutnya, tingkat kesesuaian teks dihitung menggunakan metode *SequenceMatcher* untuk mendapatkan rasio kemiripan antara teks hasil pemindaian dengan data referensi standar EMVCo. Penggunaan algoritma pembandingan ini memungkinkan sistem tetap toleran terhadap kesalahan tipografi kecil pada OCR, namun tetap tegas terhadap perbedaan data yang signifikan yang mengindikasikan upaya pengalihan dana.

c. Verifikasi Geospasial

Mencocokkan koordinat GPS pengguna dengan metadata lokasi pada QRIS yaitu pada Tag 60 untuk Kota dan Tag 61 untuk Kode Pos mengikuti panduan EMVCo. Verifikasi ini bertujuan untuk memitigasi risiko serangan *quishing* yang dilakukan secara jarak jauh, di mana sebuah kode QR dari wilayah geografis yang berbeda ditempatkan secara ilegal di lokasi baru. Dengan membandingkan radius lokasi transaksi dengan metadata QRIS, sistem dapat mendeteksi diskrepansi lokasi meskipun secara visual dokumen tersebut terlihat autentik.



Hasil agregasi dari lapisan validasi spasial, semantik, dan geospasial diklasifikasikan ke dalam enam status keputusan akhir. Klasifikasi ini bertujuan untuk memberikan informasi spesifik mengenai jenis anomali atau tingkat risiko yang terdeteksi, sebagaimana dijelaskan pada Tabel 1.

Tabel 1. Definisi dan Logika Status Keputusan Akhir

Status Keputusan	Deskripsi Kondisi / Logika
<i>Authentic</i>	Seluruh parameter visual, semantik, dan lokasi sesuai dengan standar ASPI dan metadata QRIS
<i>Suspicious</i>	Terdeteksi pelanggaran pada tata letak (<i>layout</i>) atau ketidaksesuaian data semantik (indikasi manipulasi).
<i>Authentic Loc Not Match</i>	Atribut visual dan data semantik dinyatakan valid, namun terdapat diskrepansi antara lokasi fisik dan metadata geospasial.
<i>QR Link</i>	QR <i>code</i> bukan merupakan <i>string</i> QRIS, melainkan tautan URL eksternal atau situs web.
<i>No QR</i>	Tidak adanya QR <i>code</i> yang terbaca pada citra
<i>QR Other</i>	QR <i>code</i> terdeteksi, namun menggunakan protokol atau format di luar spesifikasi QRIS MPM Statis.

2.3.2 Evaluasi End-to-End

Sistem dievaluasi menggunakan data testing *end-to-end* yang telah dikonsolidasikan dengan *ground truth*. Evaluasi dilakukan melalui dua pendekatan utama untuk memastikan keandalan sistem secara menyeluruh:

a. Evaluasi Kinerja Prediksi

Menggunakan metrik *Precision*, *Recall*, *F1-Score*, serta *Confusion Matrix* multi-kelas. Metrik ini bertujuan memetakan distribusi prediksi terhadap label aktual di antara enam kategori keputusan, sehingga dapat diidentifikasi kelas mana yang paling sering mengalami kesalahan klasifikasi [24], [25]. Akurasi keseluruhan dihitung berdasarkan persentase total prediksi status akhir yang benar terhadap keseluruhan data uji sesuai dengan Persamaan (4).

$$\text{Akurasi Keseluruhan} = \frac{TP+TN}{TP+FP+FN+TN} \quad (4)$$

b. Evaluasi Efisiensi Operasional

Selain akurasi, peneliti melakukan pengukuran waktu pemrosesan (*processing time*) pada setiap komponen inti AI (YOLOv11 dan PaddleOCR). Pengukuran ini dilakukan untuk memvalidasi responsivitas sistem dalam menangani permintaan pengguna secara *real-time* serta mengidentifikasi titik hambat (*bottleneck*) dalam *pipeline* deteksi.

3. HASIL DAN PEMBAHASAN

Bagian ini memaparkan seluruh temuan yang diperoleh dari setiap tahapan penelitian, mulai dari hasil pembangunan dataset, performa pelatihan model deteksi objek, hingga evaluasi integrasi sistem secara *end-to-end*. Hasil yang disajikan mencakup data kuantitatif dalam bentuk tabel dan metrik performa, yang kemudian dianalisis pada bagian pembahasan untuk memberikan interpretasi mengenai penggunaan YOLOv11, PaddleOCRv5, dan *Rule-Based Engine* dalam mendeteksi pemalsuan QRIS MPM Statis.

3.1 Implementasi Lingkungan Kerja

Pelatihan model dan pengembangan sistem dilaksanakan pada lingkungan komputasi yang dioptimalkan untuk pengolahan *deep learning*. Lingkungan ini dirancang untuk menjamin efisiensi pelatihan serta kecepatan inferensi model YOLOv11. Seluruh eksperimen dijalankan dengan dukungan akselerasi CUDA pada perangkat keras yang terdiri dari prosesor AMD Ryzen 5 7500F, kartu grafis NVIDIA GeForce RTX 4060 dengan memori 8 GB, serta memori utama sebesar 32 GB DDR5. Dari sisi perangkat lunak, sistem menggunakan sistem operasi Windows 11 dengan bahasa pemrograman Python versi 3.13.5. Framework utama yang digunakan adalah PyTorch versi 2.9.0 dengan dukungan CUDA 12.8, didukung oleh pustaka *deep learning* Ultralytics versi 8.3.221 dan CUDA Toolkit versi 12.9 untuk memastikan kompatibilitas serta performa komputasi yang optimal.

3.2 Hasil Pembangunan Dataset

Tahap pembangunan dataset merupakan fase krusial dalam penelitian ini untuk memastikan model YOLOv11 memiliki variasi data yang cukup untuk generalisasi. Total 898 citra yang terkumpul dikurasi secara ketat untuk merepresentasikan kondisi penggunaan QRIS MPM Statis di ekosistem UMKM.

3.2.1 Hasil Akuisisi Data Lapangan

Dari total dataset, sebanyak 509 citra merupakan data yang diambil melalui kamera *smartphone* dengan berbagai kondisi pencahayaan. Variasi ini penting untuk memastikan sistem tetap andal saat digunakan di lokasi dengan cahaya redup maupun pantulan cahaya matahari pada cetakan QRIS yang menggunakan laminasi *glossy*.



3.2.2 Hasil Pra-pemrosesan

Data mentah hasil akuisisi seringkali memiliki distorsi akibat sudut pengambilan gambar. Proses koreksi perspektif dilakukan untuk menstandarisasi input model. Sebagaimana diperlihatkan pada Gambar 4, proses ini berhasil mentransformasi citra yang miring menjadi tegak lurus. Hal ini secara teknis akan mempermudah modul PaddleOCR dalam mengenali karakter teks, karena distorsi geometri pada huruf-huruf NMID dan nama *merchant* telah diminimalisir.



(a)

(b)

Gambar 4. (a) Sebelum; (b) Sesudah dipotong & Koreksi Perspektif

3.2.1 Implementasi Rekayasa Data dan Simulasi Anomali

Untuk menutupi kelangkaan data serangan nyata (*real-world fraud*), penelitian ini mengimplementasikan teknik simulasi anomali secara manual menggunakan perangkat lunak Adobe Photoshop. Proses rekayasa ini menghasilkan variasi anomali yang sistematis untuk melatih kepekaan model terhadap perubahan atribut. Dengan distribusi data hasil rekayasa disajikan pada Tabel 3.

Tabel 3. Skenario Rekayasa dan Simulasi Anomali QRIS

Kategori Rekayasa	Deskripsi Manipulasi	Jumlah	Sample Hasil
Penghapusan Atribut Standar	Penghilangan elemen wajib seperti nama <i>merchant</i> , NMID, <i>Terminal ID</i> , logo QRIS, atau teks pada logo.	149	
Perubahan Tata Letak	Pemindahan posisi atribut utama (Logo QRIS, GPN, atau nama <i>merchant</i>) dari posisi standarnya.	60	
Penggantian Atribut (<i>Spoofing</i>)	Penggantian kode QR asli dengan QR <i>merchant</i> lain, tautan URL eksternal, atau <i>string</i> teks <i>dummy</i> .	90	
Penambahan Elemen Anomali	Penambahan teks atau gambar mencurigakan yang tumpang tindih dengan desain asli QRIS MPM.	90	
Total Citra Rekayasa		389	



3.2.2 Hasil Partisi Dataset

Data yang terkumpul dipartisi secara acak untuk menjamin objektivitas evaluasi sesuai perancangan. Hasil partisi disajikan pada Tabel 4.

Tabel 4. Hasil Partisi Dataset

Kategori	Proporsi	Jumlah Citra
<i>Training Set</i>	80%	718
<i>Validation Set</i>	10%	88
<i>Test Set</i>	10%	92

Selain data uji berjumlah 92, penelitian ini menyiapkan tambahan 38 citra bukan QRIS (seperti foto menu, objek umum, atau QR non-pembayaran) sebagai *negative samples*. Total data untuk evaluasi *end-to-end* berjumlah 130 citra yang telah dikonsolidasikan dengan *ground truth*. Penggunaan tambahan data non-QRIS ini bertujuan untuk menguji kemampuan sistem dalam menolak input yang tidak relevan secara otomatis sebelum diproses oleh lapisan validasi yang lebih mendalam.

3.3 Hasil & Evaluasi Model YOLO

Proses pelatihan model dilakukan secara sistematis menggunakan arsitektur YOLOv11 (*nano*, *small*, dan *medium*) dengan pendekatan *transfer learning*. Konfigurasi *hyperparameter* yang diterapkan dirancang untuk mengoptimalkan proses konvergensi bobot pada dataset spesifik QRIS MPM, sembari mempertimbangkan batasan sumber daya perangkat keras yang digunakan. Dapat dilihat pada Tabel 5 yaitu detail konfigurasi yang digunakan.

Tabel 5. Konfigurasi *Hyperparameter* Pelatihan

<i>Hyperparameter</i>	Nilai
<i>Input Image Size</i>	640x640px
<i>Epoch</i>	100
<i>Patience</i>	20
<i>Batch Size</i>	32
<i>Optimizer</i>	AdamW
<i>Initial Learning Rate (lr_0)</i>	0.001
<i>Final Learning Rate (lr_f)</i>	0.01
<i>Momentum</i>	0,9

3.3.1 Perbandingan Metrik Performa Model


Evaluasi dilakukan untuk mengukur efektivitas model dalam mengenali atribut visual QRIS serta menguji efisiensi pemrosesan. Pengujian ini membandingkan tiga skala arsitektur YOLOv11, yaitu varian *Nano* (n), *Small* (s), dan *Medium* (m), guna menemukan keseimbangan terbaik antara akurasi lokalisasi dan kecepatan inferensi. Hasil pengujian performa tersebut disajikan secara rinci pada Tabel 6.

Tabel 6. Hasil Evaluasi Metrik Performa dan Kecepatan Model YOLOv11

Model	<i>Precision</i>	<i>Recall</i>	F1-Score	mAP ₅₀	mAP ₅₀₋₉₅
yolo11-n	0.9971	0.9977	0.9974	0.9943	86.23
yolo11-s	0.9947	0.9949	0.9948	0.9945	90.33
yolo11-m	0.9964	0.9948	0.9956	0.994	75.97

Berdasarkan data pada Tabel 6 menunjukkan bahwa seluruh varian model memiliki nilai *Precision* dan *Recall* yang sangat stabil di atas 0.99. Hal ini mengindikasikan bahwa model memiliki kemampuan yang sangat baik dalam meminimalisir kesalahan deteksi (*false positive*) maupun objek yang terlewat (*false negative*). Metrik mAP₅₀₋₉₅, yang merupakan indikator utama akurasi lokalisasi pada berbagai ambang batas *Intersection over Union* (IoU), mencapai nilai tertinggi pada varian yolo11-m sebesar 0.8682. Di sisi lain, varian yolo11-s mencatatkan kecepatan inferensi tertinggi dengan 90.33 FPS, memberikan keseimbangan paling optimal antara akurasi deteksi dan kecepatan pemrosesan data.

Analisis melalui *Confusion Matrix* pada Gambar 5 mengonfirmasi bahwa model mampu mengklasifikasikan atribut standar QRIS dan elemen anomali dengan tingkat kesalahan yang minimal. Kemampuan model dalam mempertahankan akurasi deteksi pada berbagai tingkat *Intersection over Union* (IoU) membuktikan bahwa arsitektur YOLOv11 sangat reliabel untuk digunakan sebagai lapisan pertahanan utama dalam mengidentifikasi integritas visual QRIS. Mengingat sistem ini dikembangkan untuk tujuan validasi keamanan yang memprioritaskan akurasi posisi atribut secara detail, maka varian yolo11-m dipilih sebagai model yang diimplementasikan ke dalam sistem *end-to-end*. Meskipun yolo11-s menawarkan efisiensi operasional yang lebih tinggi dari sisi kecepatan inferensi, keunggulan yolo11-m dalam melokalisasi objek secara detail menjadi prioritas guna meminimalisir risiko kesalahan deteksi pada atribut kritis QRIS.



Gambar 5. Confusion Matrix Normalized Model YOLO11: (a) YOLO11-n, (b) YOLO11-s, dan (c) YOLO11-m.


3.4 Hasil Evaluasi Sistem End-to-End

Evaluasi *end-to-end* bertujuan untuk memvalidasi performa sistem secara utuh, mulai dari pemrosesan citra mentah hingga pengambilan keputusan akhir terkait status keaslian QRIS. Pengujian ini menggunakan dataset independen sebanyak 130 citra yang mencakup skenario variatif, termasuk citra non-QRIS untuk menguji ketahanan sistem terhadap input yang tidak relevan. Kinerja sistem diukur menggunakan metrik *Precision*, *Recall*, dan *F1-Score* untuk setiap kelas status, sebagaimana disajikan pada Tabel 7.

Tabel 7. Laporan Metrik Klasifikasi Evaluasi End-to-End

Class	Precision	Recall	F1-Score
<i>Authentic</i>	1.00	0.90	0.95
<i>Suspicious</i>	0.89	1.00	0.94
<i>Authentic Loc Not Match</i>	1.00	1.00	1.00
<i>QR Link</i>	1.00	1.00	1.00
<i>No QR</i>	1.00	1.00	1.00
<i>QR Other</i>	1.00	1.00	1.00
<i>Overall Accuracy</i>	96,15%		

Berdasarkan Tabel 7, sistem menunjukkan performa dengan akurasi keseluruhan mencapai 96,15%. Capaian *F1-Score* sebesar 1.00 pada kelas-kelas teknis seperti *Authentic Loc Not Match*, *No QR*, *QR Link*, dan *QR Other* mengindikasikan bahwa logika sistem dalam melakukan kategorisasi jenis kode QR serta validasi metadata geospasial berbasis koordinat GPS telah berjalan dengan akurasi yang konsisten pada dataset uji ini. Tingginya nilai presisi pada kelas-kelas anomali tersebut menunjukkan bahwa sistem memiliki sensitivitas yang sangat baik dalam mendeteksi pemalsuan pada QRIS MPM Statis, sehingga berkontribusi pada pengurangan risiko penipuan dalam transaksi digital menggunakan QRIS.



Gambar 7. Confusion Matrix Pengujian Sistem End-to-End.

Visualisasi pada Gambar 7 memperlihatkan bahwa meskipun performa sistem cukup tinggi, terdapat 5 kasus di mana data *Authentic* terprediksi sebagai *Suspicious*. Secara statistik, hal ini tercermin pada nilai *Recall* kelas *Authentic* yang berada di angka 0,90, berbanding terbalik dengan nilai *Recall* kelas *Suspicious* yang mencapai 1,00. Fenomena ini mengindikasikan bahwa sistem cenderung bersifat *over-strict* atau sangat ketat dalam melakukan validasi.

3.4.1 Analisis Log Sistem dan Kegagalan Ekstraksi

Penelusuran pada *log* sistem (Gambar 8) menunjukkan bahwa model YOLOv11-m sebenarnya berhasil menjalankan tugasnya dengan sangat baik. Model mampu melokalisasi seluruh atribut visual (Sesuai Buletin ASPI No: 3/III/2021) dengan *confidence score* yang tinggi.

```

0004.json | AUTHENTIC | → SUSPICIOUS
0050.json | AUTHENTIC | → SUSPICIOUS
0238.json | AUTHENTIC | → SUSPICIOUS
0530.json | AUTHENTIC | → SUSPICIOUS
qris_switch-0027.json | AUTHENTIC | → SUSPICIOUS
    
```

Gambar 8. Log Mismatch/False Predict dari Evaluasi End-to-End.

Namun, kegagalan terjadi pada tahap ekstraksi teks oleh modul PaddleOCR. Ketidampungan mesin OCR dalam membaca karakter teks disebabkan oleh kualitas citra input yang mengalami *blur* atau kerusakan visual, sebagaimana diperlihatkan pada Gambar 9. Kegagalan ekstraksi NMID ini menyebabkan *Rule-Based Engine* tidak memiliki data pembandingan untuk dicocokkan dengan hasil decode QR, sehingga sistem secara otomatis mengambil keputusan konservatif dengan memberikan label *Suspicious*. Meskipun mengakibatkan *false positive*, karakteristik sistem yang konservatif ini memastikan bahwa tidak ada upaya manipulasi visual yang lolos dari deteksi (*zero false negative*), yang menjadi prioritas utama dalam pengembangan sistem keamanan finansial.



Gambar 9. Sampel Citra Penyebab Kegagalan OCR (a) Gambar 0004; (b) Gambar 0050; (c) Gambar 0238, (d) Gambar 0530; (e) Gambar qris_switch-0027



3.4.2 Analisis Efisiensi dan Kelayakan Implementasi

Untuk memvalidasi kelayakan sistem dalam skenario penggunaan nyata, peneliti melakukan pengukuran terhadap waktu pemrosesan pada setiap komponen utama. Data pada Tabel 8 menunjukkan rata-rata latensi yang dihasilkan oleh modul deteksi objek, ekstraksi teks, dan mesin inferensi.

Tabel 8. Laporan Metrik Klasifikasi Evaluasi *End-to-End*

Komponen Sistem	Rata-rata Waktu Proses (Detik)
YOLOv11-m	0,061
PaddleOCRv5	0,568
Rule-Based Engine	< 0,01
Total Core Process	0,629

Berdasarkan Tabel 8, terlihat bahwa YOLOv11-m bekerja dengan sangat efisien, hanya membutuhkan sekitar 0,06 detik untuk memetakan seluruh atribut visual QRIS. Hal ini menunjukkan keunggulan arsitektur *single-stage detector* terbaru yang mampu melakukan komputasi berat dengan latensi minimal. Sebaliknya, modul PaddleOCRv5 mengonsumsi hampir 90% dari total waktu pemrosesan, yang mengindikasikan bahwa komponen ini merupakan *bottleneck* utama dalam *pipeline* deteksi. Dominasi waktu pada tahap ekstraksi teks ini menunjukkan bahwa sistem masih memerlukan optimasi lebih lanjut, baik melalui penyederhanaan arsitektur OCR maupun implementasi teknik *preprocessing* yang lebih efisien, guna meningkatkan reliabilitas sistem saat menangani volume transaksi yang tinggi.

3.5 Pembahasan

Hasil pengujian menunjukkan bahwa integrasi antara deteksi objek berbasis *deep learning* dan logika aturan (*rule-based*) menghasilkan sistem pertahanan berlapis yang tangguh.

3.5.1 Batasan Sistem terhadap Kualitas Citra

Kesalahan klasifikasi pada 5 data *Authentic* yang terbaca sebagai *Suspicious* memberikan gambaran nyata mengenai batasan operasional sistem. Dalam skenario ini, integritas sistem tetap terjaga karena ia lebih memilih untuk menandai gambar yang tidak tervalidasi secara sempurna sebagai *Suspicious* daripada meloloskan data yang berpotensi membahayakan pengguna. Dari sudut pandang keamanan siber, fenomena ini dikenal sebagai *False Frustrating* (pengguna asli yang terhalang) yang lebih baik daripada *False Acceptance* (penipu yang lolos). Hal ini memperkuat reliabilitas sistem dalam menghadapi kondisi pengambilan gambar yang tidak ideal di lapangan.

3.5.2 Sinergi Lapisan Validasi

Keunggulan utama sistem ini terletak pada kemampuannya mencapai nilai *Recall* 1.00 pada kelas *Suspicious* dan *QR Link*. Hal ini berarti sistem tidak melewatkan satu pun potensi ancaman pemalsuan yang ada pada data uji. Konsistensi ini dicapai melalui sinergi tiga lapisan validasi utama:

- Lapisan Visual: YOLOv11-m bertindak sebagai gerbang pertama untuk memastikan seluruh komponen fisik QRIS sesuai dengan standar ASPI No. 3/III/2021 secara spasial.
- Lapisan Semantik: Validasi tekstual melalui PaddleOCR memastikan data yang tercetak secara fisik sinkron dengan konten digital yang tertanam di dalam kode QR. Lapisan ini efektif mencegah penggantian kode QR (*sticker overlay*).
- Lapisan Geospasial: Verifikasi lokasi menggunakan metadata GPS memastikan *merchant* beroperasi pada koordinat yang sesuai dengan wilayah pendaftaran NMID (Tag 60 dan 61 pada spesifikasi EMVCo).

3.5.3 Analisis Efektivitas Deteksi QR Link dan QR Other

Identifikasi sempurna (*F1-Score* 1.00) pada kategori *QR Link* menunjukkan sensitivitas tinggi sistem terhadap serangan *quishing* yang mencoba mengalihkan pengguna ke situs web eksternal. Dengan melakukan inspeksi terhadap *payload* dari kode QR yang dipindai, sistem mampu mengenali format *string* yang tidak sesuai dengan protokol QRIS MPM Statis. Hal ini memberikan perlindungan preventif yang krusial, mengingat banyak serangan pemalsuan QRIS saat ini tidak mengubah tampilan fisik namun mengubah tujuan transaksi secara digital.

4. KESIMPULAN

Sistem deteksi pemalsuan QRIS MPM Statis yang dikembangkan melalui integrasi model deteksi objek, teknologi OCR, dan mesin inferensi berbasis aturan telah menunjukkan hasil yang sangat efektif dalam memitigasi berbagai risiko penipuan digital. Penggunaan arsitektur YOLOv11-m terbukti memberikan akurasi lokalisasi atribut visual yang sangat presisi dengan nilai mAP50-95 sebesar 0,8682, sehingga mampu mengenali seluruh komponen wajib QRIS sesuai dengan Buletin ASPI No: 3/III/2021. Melalui pengujian *end-to-end* terhadap 130 citra uji, sistem ini mencatatkan performa yang sangat impresif dengan tingkat *Overall Accuracy* mencapai 96,15%, serta nilai *Recall* sebesar 1,00 pada kelas *Suspicious* yang menjamin seluruh potensi manipulasi visual berhasil diidentifikasi. Meskipun terdapat beberapa kasus kesalahan klasifikasi pada citra dengan tingkat keaburan (*blur*) yang ekstrem, sistem secara konsisten menerapkan prinsip



keamanan ketat dengan menandai data yang tidak tervalidasi sebagai *Suspicious*. Namun, evaluasi performansi menunjukkan bahwa efisiensi operasional sistem masih sangat bergantung pada modul OCR, di mana total durasi pemrosesan inti sebesar 0,629 detik didominasi oleh modul PaddleOCRv5 yang mengambil porsi 90,3% dari keseluruhan beban proses. Hal ini mengindikasikan bahwa optimasi pada modul ekstraksi teks merupakan syarat mutlak untuk meningkatkan reliabilitas pada perangkat dengan spesifikasi terbatas. Pengembangan masa depan disarankan fokus pada integrasi modul *image enhancement* atau *super-resolution* guna meningkatkan ketahanan terhadap citra berkualitas rendah, perluasan dataset dengan kondisi fisik QRIS yang rusak, serta optimasi model ke format TensorRT atau ONNX untuk memastikan kecepatan deteksi tetap optimal saat diimplementasikan secara luas pada perangkat seluler guna menjaga integritas ekosistem pembayaran digital di Indonesia.

REFERENCES

- [1] D. Paramitha and D. Kusumaningtyas, *QRIS*, no. 76. Fakultas Ekonomi Universitas Nusantara PGRI Kediri, 2020. Accessed: Feb. 24, 2026. [Online]. Available: <https://www.scribd.com/document/843402941/Buku-QRIS-Paramitha-2020>
- [2] Bank Indonesia, "QR Code Indonesian Standard (QRIS)," Indonesia, Sep. 2020. Accessed: Jan. 23, 2025. [Online]. Available: <https://www.bi.go.id/id/edukasi/Pages/QR-Code-Indonesian-Standard.aspx>
- [3] Kumparan, "QRIS Sudah Digunakan di 35,1 Juta Merchant, 90 Persen UMKM," Kumparan Bisnis. Accessed: Jan. 19, 2025. [Online]. Available: <https://kumparan.com/kumparanbisnis/qr-is-sudah-digunakan-di-35-1-juta-merchant-90-persen-umkm-2485WtMzpEC>
- [4] I. R. S. Rahayu and E. Djumena, "Fakta-fakta Kasus Pemalsuan QRIS Kotak Amal Masjid," Kompas.com. Accessed: Jan. 19, 2025. [Online]. Available: <https://money.kompas.com/read/2023/04/11/090600126/fakta-fakta-kasus-pemalsuan-qr-is-kotak-amal-masjid>
- [5] A. A. Ajhari, "Analisis Keamanan Sistem Pembayaran Digital Quick Response Code Indonesian Standard (QRIS)," *Info Kripto*, vol. 18, no. 3, pp. 119–125, Dec. 2024, doi: 10.56706/ik.v18i3.112.
- [6] Y. Huang, T. Lv, L. Cui, Y. Lu, and F. Wei, "LayoutLMv3: Pre-training for Document AI with Unified Text and Image Masking," in *Proceedings of the 30th ACM International Conference on Multimedia*, ACM, Oct. 2022, pp. 4083–4091. doi: 10.1145/3503161.3548112.
- [7] Z. Zhao, H. Kang, B. Wang, and C. He, "DocLayout-YOLO: Enhancing Document Layout Analysis through Diverse Synthetic Data and Global-to-Local Adaptive Perception," Oct. 2024, doi: 10.48550/arXiv.2410.12628.
- [8] D. Sasinath, V. Surya, U. Vaishali, and C. Sangeetha, "Survey on Efficient Automated Number Plate Recognition System using YOLOv8 And Paddle OCR," *International Research Journal of Modernization in Engineering Technology and Science*, vol. 07, no. 03, pp. 4386–4389, Mar. 2025, doi: 10.56726/IRJMETS69511.
- [9] S. Bagaria, S. Irene, Harikrishnan, and E. V M, "A Novel Implementation of Marksheet Parser Using PaddleOCR," Jun. 2024, doi: 10.48550/arXiv.2407.11985.
- [10] N. Jegham, C. Y. Koh, M. Abdelatti, and A. Hendawi, "YOLO Evolution: A Comprehensive Benchmark and Architectural Review of YOLOv12, YOLOv11, and Their Previous Versions," Mar. 2025, doi: 10.48550/arXiv.2411.00201.
- [11] Y. Luo, "The Evolution of YOLO: from YOLOv1 to YOLOv11 with a Focus on YOLOv7's Innovations in Object Detection," *Theoretical and Natural Science*, vol. 87, no. 1, pp. 82–90, Jan. 2025, doi: 10.54254/2753-8818/2025.20335.
- [12] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, Jun. 2016, pp. 779–788. doi: 10.1109/CVPR.2016.91.
- [13] A. Zhang, Z. C. Lipton, M. Li, and A. J. Smola, *Dive into Deep Learning*. Cambridge: Cambridge University Press, 2023. Accessed: Feb. 24, 2026. [Online]. Available: <https://d2l.ai/>
- [14] I. D. G. A. W. Natih, M. W. A. Kesiman, and I. M. G. Sunarya, "Analisis Perbandingan Arsitektur dan Optimizer YOLOv11 untuk Estimasi Buah Kelapa," *RIGGS: Journal of Artificial Intelligence and Digital Business*, vol. 4, no. 4, pp. 12–19, Nov. 2025, doi: 10.31004/riggs.v4i4.3329.
- [15] E. S. dos Santos Júnior, T. Paixão, and A. B. Alvarez, "Comparative Performance of YOLOv8, YOLOv9, YOLOv10, and YOLOv11 for Layout Analysis of Historical Documents Images," *Applied Sciences*, vol. 15, no. 6, p. 3164, Mar. 2025, doi: 10.3390/app15063164.
- [16] R. Khanam and M. Hussain, "YOLOv11: An Overview of the Key Architectural Enhancements," Oct. 2024, doi: 10.48550/arXiv.2410.17725.
- [17] N. Rao, "YOLOv11 Explained: Next-Level Object Detection with Enhanced Speed and Accuracy," Medium. Accessed: Jul. 05, 2025. [Online]. Available: <https://medium.com/@nikhil-rao-20/yolov11-explained-next-level-object-detection-with-enhanced-speed-and-accuracy-2dbe2d376f71>
- [18] D. A. Pusparani, M. W. A. Kesiman, and K. Y. E. Aryanto, "Identification of Little Tuna Species Using Convolutional Neural Networks (CNN) Method and ResNet-50 Architecture," *Indonesian Journal of Artificial Intelligence and Data Mining*, vol. 8, no. 1, p. 86, Dec. 2024, doi: 10.24014/ijaidm.v8i1.31620.
- [19] K. J. K. Jaya, M. W. A. Kesiman, and I. M. D. Maysanjaya, "Document Validation for Cooperation Agreement Documents at The Undiksha Cooperation and Public Relations Agency (Badan Kerja Sama dan Kehumasan) using Local Binary Pattern (LBP) and YOLOv5 Methods," *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, vol. 12, no. 3, pp. 426–436, Dec. 2023, doi: 10.23887/janapati.v12i3.66070.
- [20] P. Z. E. S. Nugraha, I. M. G. Sunarya, and I. M. D. Maysanjaya, "Binary Semantic Segmentation of Dolphin on UAV Image Using U-Net," in *2023 International Seminar on Intelligent Technology and Its Applications (ISITIA)*, IEEE, Jul. 2023, pp. 728–733. doi: 10.1109/ISITIA59021.2023.10221152.
- [21] I. M. G. Sunarya, I. M. D. Maysanjaya, I. B. M. Y. Wirawan, and G. B. Setiawan, "The Detection of a Single Wet Rice Field Bund on Unmanned Aerial Vehicle Image Using a Convolutional Neural Network," in *Proceedings of the 4th International Conference on Vocational Education and Technology, IConVET 2021, 27 November 2021, Singaraja, Bali, Indonesia*, EAI, 2022. doi: 10.4108/eai.27-11-2021.2315531.



- [22] N. P. D. A. S. Dewi, M. W. A. Kesiman, I. M. G. Sunarya, G. A. A. D. Indradewi, and I. G. Andika, “Klasifikasi Jenis Daun Tumbuhan Herbal Berdasarkan Lontar Usada Taru Pramana Menggunakan CNN,” *Techno.Com*, vol. 23, no. 1, pp. 271–283, Feb. 2024, doi: 10.62411/tc.v23i1.9510.
- [23] I. G. N. B. P. Asmara, M. W. A. Kesiman, and G. Indrawan, “Balinese Shadow Puppet Characters Detection In The Wayang Peteng Performance Using The Yolov5 Algorithm,” *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, vol. 12, no. 3, pp. 388–397, Dec. 2023, doi: 10.23887/janapati.v12i3.65906.
- [24] M. W. A. Kesiman, I. M. G. Sunarya, and I. G. L. T. Sumantara, “Comparative Analysis of CNN Methods for Periapical Radiograph Classification,” *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, vol. 13, no. 2, pp. 204–214, Jul. 2024, doi: 10.23887/janapati.v13i2.71664.
- [25] I. M. A. D. Putra, I. Md. D. Maysanjaya, and M. W. A. Kesiman, “Pendekatan Berbasis U-Net untuk Segmentasi Hard Exudate dalam Citra Fundus Retina,” *INSERT: Information System and Emerging Technology Journal*, vol. 4, no. 1, pp. 26–36, Jun. 2023, doi: 10.23887/insert.v4i1.59034.