

BAB II

TINJAUAN PUSTAKA

2.1 Evolusi Model YOLO dan Inovasi pada YOLOv11

Model YOLO (You Only Look Once) telah mengalami evolusi signifikan sejak diperkenalkan, dengan fokus pada keseimbangan antara kecepatan dan akurasi dalam deteksi objek real-time. Tinjauan komprehensif dari YOLOv1 hingga YOLOv11 menyoroti inovasi seperti deteksi tanpa anchor (anchor-free) pada versi terbaru, yang mengurangi kompleksitas komputasi sambil meningkatkan presisi pada objek kecil atau bervariasi [18]. Evolusi ini mencakup perbaikan pada backbone, neck, dan head arsitektur, di mana YOLOv11 memperkenalkan mekanisme perhatian (attention mechanisms) yang lebih canggih untuk ekstraksi fitur yang lebih robust terhadap variasi citra. Selain itu, YOLOv11 dirancang untuk mendukung tugas multi seperti segmentasi dan estimasi pose, yang relevan untuk aplikasi farmasi di mana deteksi area spesifik seperti teks nama obat memerlukan lokalisasi presisi tinggi. Namun, tantangan seperti stabilitas pelatihan pada varian tanpa anchor dan adaptasi terhadap pergeseran domain (domain shift) masih menjadi isu utama, yang menekankan pentingnya hyperparameter tuning untuk mengoptimalkan performa pada dataset khusus seperti citra kemasan obat.

2.2. Sistem Pengenalan Farmasi Berbasis Deep Learning

YOLOv11 telah menunjukkan potensi tinggi dalam aplikasi deteksi objek multi-kelas, termasuk dalam konteks medis dan farmasi. Studi proof-of-concept pada deteksi pil medis menggunakan YOLOv11 mencapai $mAP@0.5$ sebesar 0.995 pada dataset kecil (115 citra), yang menunjukkan kemampuan model dalam mengidentifikasi objek kecil dengan akurasi tinggi meskipun data terbatas [15]. Namun, skala dataset yang kecil menimbulkan risiko overfit, sehingga diperlukan validasi pada variasi kondisi lebih luas untuk memastikan generalisasi. Di sisi lain, klasifikasi obat real-time dengan YOLOv11 pada 5.000 citra (10 kelas) melaporkan precision 0.974, recall 0.976, dan $mAP@0.5$ 0.984, yang

menggarisbawahi keunggulan model dalam kecepatan inferensi sambil mempertahankan akurasi tinggi [14]. Aplikasi ini relevan untuk deteksi nama obat, di mana YOLOv11 dapat melokalisasi area teks secara eksplisit, berbeda dari pendekatan klasifikasi murni yang kurang efektif pada skenario multi-objek. Selain itu, fine-tuning YOLOv11 pada deteksi multi-kelas kendaraan udara menunjukkan peningkatan ketelitian melalui optimasi tugas-spesifik, yang dapat diadaptasi untuk variasi citra kemasan obat seperti pencahayaan rendah atau sudut miring [16]. Temuan ini memperkuat bahwa YOLOv11 cocok untuk otomatisasi farmasi, tetapi memerlukan tuning untuk mengatasi tantangan seperti oklusi atau noise pada citra *real-world*.

2.3. Evolusi dan Aplikasi Model YOLO dalam Deteksi Objek Berbasis Citra

Hyperparameter tuning menjadi krusial dalam meningkatkan performa YOLOv11, terutama pada tugas deteksi objek dengan dataset bervariasi. Studi menunjukkan bahwa fine-tuning YOLOv11 pada deteksi multi-kelas dapat meningkatkan ketelitian, tetapi keberhasilan bergantung pada pemilihan hyperparameter seperti learning rate dan regularisasi untuk menghindari pergeseran performa pada kondisi data baru [16]. Parameter seperti batch size dan optimizer memengaruhi stabilitas pelatihan, di mana tuning sistematis menggunakan data validasi terpisah dapat mengurangi sensitivitas model terhadap variasi desain. Pada konteks farmasi, tuning ini relevan untuk meningkatkan recall pada objek kecil seperti teks nama obat, di mana YOLOv11's anchor-free approach memerlukan penyesuaian untuk menangani skala objek yang beragam. Selain itu, integrasi teknik AutoML dapat memvalidasi hyperparameter secara otomatis, memastikan efisiensi inferensi tetap tinggi untuk aplikasi real-time. Tantangan seperti overfit pada dataset kecil dapat diatasi melalui augmentasi citra selama tuning, yang selaras dengan rekomendasi untuk validasi terukur pada kondisi nyata seperti low-light atau glare.

2.4. Hyperparameter Tuning dan Pengolahan Citra dalam Model Deep Learning

Pengolahan citra memainkan peran penting dalam keberhasilan YOLOv11 untuk deteksi nama obat, di mana variasi pencahayaan, sudut pengambilan, dan skala objek dapat memengaruhi ekstraksi fitur [17]. Literatur menekankan bahwa preprocessing seperti augmentasi (rotasi, flipping) dan normalisasi dapat meningkatkan robustitas model terhadap perubahan lingkungan, yang krusial untuk citra kemasan obat di apotek atau rumah. Tantangan seperti domain shift seperti perbedaan antara citra pelatihan dan uji dapat menyebabkan penurunan performa, sehingga hyperparameter tuning diperlukan untuk mitigasi. Pada YOLOv11, integrasi attention mechanisms membantu fokus pada fitur relevan seperti teks, tetapi memerlukan tuning untuk menghindari false positives pada kemasan mirip. Studi farmasi menunjukkan bahwa pendekatan ini dapat mengurangi medication error dengan meningkatkan akurasi lokalisasi, tetapi memerlukan evaluasi pada dataset lokal seperti kemasan obat Indonesia untuk adaptasi kontekstual. Secara keseluruhan, pengolahan citra yang optimal melalui tuning memastikan YOLOv11 efektif untuk mendukung kemandirian pasien dengan keterbatasan visual.