

PENERAPAN METODE YOLOV11 DALAM DETEKSI ANGKA PADA METERAN AIR PDAM STUDI KASUS PDAM KM 4 PALEMBANG

Dep` Niel Sinaga, Tinaliah

Teknik Informatika, Universitas Multi Data Palembang
Jl. Rajawali 14, 30113 Palembang, Indonesia
depniel08@gmail.com

ABSTRAK

Perkembangan *Artificial Intelligence* (AI) dan *Computer Vision* mendorong otomatisasi dalam proses pembacaan angka meteran air berbasis citra digital. Namun, proses pembacaan manual dari dokumentasi lapangan masih rentan terhadap kesalahan identifikasi serta memerlukan waktu pemrosesan yang relatif lama, terutama pada kondisi citra dengan pencahayaan rendah, buram, atau tertutup kotoran. Penelitian ini bertujuan untuk mengembangkan model deteksi angka meteran air menggunakan metode *You Only Look Once version 11 nano* (YOLOv11n) guna meningkatkan akurasi dan efisiensi proses pembacaan. Metode penelitian meliputi pengumpulan dan anotasi dataset citra meteran air, pelatihan model menggunakan konfigurasi *hyperparameter* terbaik (optimizer AdamW, *learning rate* 0,001–0,01, dan *epoch* 100), serta evaluasi kinerja model menggunakan metrik *precision*, *recall*, dan *mean Average Precision* (mAP). Hasil pengujian menunjukkan bahwa model YOLOv11n memperoleh nilai *precision* sebesar 98,2%, *recall* sebesar 97,2%, mAP50 sebesar 98,6%, dan mAP50–95 sebesar 82%. Hasil tersebut menunjukkan bahwa model memiliki tingkat akurasi dan konsistensi yang tinggi dalam mendeteksi angka meteran air pada berbagai kondisi citra, sehingga berpotensi mendukung proses pembacaan meteran air secara otomatis dengan lebih efisien dan andal.

Kata kunci : Deteksi Objek, Meteran Air, YOLOv11, PDAM

1. PENDAHULUAN

Perkembangan teknologi informasi dan komunikasi, khususnya dalam bidang *Artificial Intelligence* (AI) dan *Computer Vision*, telah mendorong transformasi digital di berbagai sektor, termasuk dalam pelayanan publik [1]. Salah satu sektor yang terdampak oleh perkembangan teknologi tersebut adalah pengelolaan sumber daya air bersih oleh Perusahaan Daerah Air Minum (PDAM). Sebagai Badan Usaha Milik Daerah (BUMD), PDAM memiliki tanggung jawab dalam menyediakan layanan air bersih yang layak bagi masyarakat serta memastikan keakuratan pencatatan konsumsi air pelanggan sebagai dasar utama dalam proses penagihan [2].

Dalam operasionalnya, pencatatan konsumsi air pelanggan dilakukan melalui dokumentasi visual berupa citra meteran air yang kemudian digunakan sebagai dasar dalam proses pencatatan data penggunaan air. Proses ini memiliki peran penting dalam menjaga konsistensi dan akurasi data yang tercatat dalam sistem. Namun, pembacaan angka meteran dari citra yang dihasilkan sering kali menghadapi berbagai kendala, seperti perbedaan kondisi pencahayaan, sudut pengambilan gambar, serta kualitas citra yang bervariasi. Kondisi tersebut berpotensi menyebabkan kesalahan identifikasi angka yang dapat memengaruhi ketepatan pencatatan konsumsi air pelanggan serta berdampak pada kualitas layanan yang diberikan [3].

Perkembangan metode *deep learning* telah memberikan pendekatan yang efektif dalam menyelesaikan permasalahan deteksi objek berbasis citra. Salah satu metode yang banyak digunakan

adalah *You Only Look Once* (YOLO), yaitu algoritma deteksi objek berbasis *single-stage detector* yang mampu melakukan proses deteksi dan klasifikasi objek secara langsung dalam satu tahapan pemrosesan. Pendekatan ini memungkinkan YOLO memiliki keunggulan dalam hal kecepatan dan efisiensi dibandingkan metode *two-stage detector* seperti *Region-based Convolutional Neural Network* (R-CNN) [4]. Selain itu, YOLO juga memiliki kemampuan yang baik dalam mendeteksi objek berukuran kecil maupun banyak objek dalam satu citra, sehingga berpotensi digunakan dalam proses deteksi digit angka pada meteran air [5].

Beberapa penelitian sebelumnya telah memanfaatkan metode deteksi objek berbasis *deep learning* untuk pengenalan karakter pada citra. Namun, penerapan metode tersebut pada citra meteran air masih menghadapi berbagai tantangan, terutama pada kondisi citra yang tidak ideal seperti pencahayaan rendah, citra buram, serta objek yang tertutup sebagian oleh kotoran atau gangguan visual lainnya [6],[7]. Variasi kondisi tersebut dapat memengaruhi kinerja model dalam mendeteksi digit angka secara akurat, sehingga diperlukan pendekatan deteksi objek yang lebih efisien dan robust terhadap variasi kondisi citra.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk menerapkan metode deteksi objek berbasis *You Only Look Once version 11 nano* (YOLOv11n) dalam mendeteksi dan mengenali digit angka pada citra meteran air. Model YOLOv11n dipilih karena memiliki arsitektur yang ringan dan efisien sehingga mampu melakukan proses deteksi objek secara cepat dengan tingkat akurasi yang tinggi. Kontribusi utama penelitian ini terletak pada

penerapan model YOLOv11n untuk mendeteksi digit angka pada citra meteran air dengan mempertimbangkan variasi kondisi citra di lapangan. Hasil penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan metode deteksi objek berbasis Computer Vision, khususnya dalam pengenalan digit angka pada meteran air menggunakan pendekatan deep learning.

2. TINJAUAN PUSTAKA


Computer Vision merupakan cabang dari Artificial Intelligence yang memungkinkan sistem komputer untuk memahami dan menginterpretasikan informasi visual dari citra digital. Salah satu tugas utama dalam Computer Vision adalah *object detection*, yaitu proses mengidentifikasi objek serta menentukan lokasinya dalam suatu citra. Perkembangan *deep learning*, khususnya *Convolutional Neural Network* (CNN), telah meningkatkan kemampuan deteksi objek secara signifikan. CNN mampu mengekstraksi fitur secara hierarkis, mulai dari fitur dasar seperti tepi dan tekstur hingga fitur kompleks seperti bentuk dan pola, sehingga memungkinkan deteksi objek secara akurat dalam berbagai kondisi citra [8].

Salah satu metode deteksi objek berbasis CNN yang banyak digunakan adalah *You Only Look Once* (YOLO). YOLO merupakan algoritma deteksi objek berbasis *single-stage detector* yang mampu mendeteksi objek secara *real-time* dengan memproses citra dalam satu kali evaluasi jaringan saraf. Metode ini membagi citra menjadi beberapa *grid*, di mana setiap *grid* bertanggung jawab untuk memprediksi keberadaan objek, koordinat *bounding box*, dan probabilitas kelas objek [9]. Untuk meningkatkan akurasi, digunakan *Intersection over Union* (IoU) sebagai metrik evaluasi serta *Non-Max Suppression* (NMS) untuk menghilangkan deteksi yang tumpang tindih. Pendekatan ini memungkinkan YOLO mencapai keseimbangan antara kecepatan dan akurasi dalam deteksi objek [10].

Dapat dilihat pada gambar 1 merupakan arsitektur YOLOv11 yang terdiri dari tiga komponen utama, yaitu *backbone*, *neck*, dan *head* [11]. *Backbone* berfungsi mengekstraksi fitur dari citra input, *neck* menggabungkan fitur dari berbagai skala untuk meningkatkan kemampuan deteksi objek dengan ukuran yang bervariasi, dan *head* menghasilkan prediksi akhir berupa lokasi dan klasifikasi objek. Struktur ini memungkinkan YOLO mendeteksi objek secara efisien dengan tingkat akurasi yang tinggi.

Berbagai penelitian sebelumnya menunjukkan bahwa YOLO efektif dalam mendeteksi karakter numerik dari citra. Penelitian oleh Sa'adat dan Widiyanto menunjukkan bahwa YOLOv8 mampu mendeteksi angka dengan akurasi tinggi dan beradaptasi terhadap variasi kondisi lingkungan [6]. Sebagai perbandingan, metode *Template Matching* hanya mencapai akurasi sekitar 85% dan memiliki keterbatasan dalam kondisi citra yang dinamis, sedangkan YOLOv4 mencapai akurasi 95,7% namun masih terbatas dalam deteksi *multi-digit*. YOLOv5s juga menunjukkan performa yang baik, namun masih memerlukan optimasi untuk meningkatkan akurasi dan efisiensi deteksi [12]. Hal ini menunjukkan bahwa metode berbasis YOLO memiliki performa yang unggul dibandingkan metode konvensional, namun masih terdapat peluang untuk peningkatan lebih lanjut.

Perkembangan terbaru menghadirkan YOLOv11 sebagai model yang dirancang untuk meningkatkan efisiensi dan akurasi deteksi objek melalui optimisasi arsitektur dan parameter model. Varian YOLOv11 *nano* memiliki jumlah parameter yang lebih efisien sehingga mampu menghasilkan proses pelatihan yang lebih cepat dan inferensi yang lebih ringan tanpa mengurangi akurasi. Dengan kemampuan ekstraksi fitur yang kuat, efisiensi komputasi yang tinggi, serta performa deteksi yang optimal, YOLOv11 *nano* memiliki potensi untuk meningkatkan akurasi dan keandalan deteksi karakter numerik dari citra dibandingkan metode sebelumnya.



Gambar 1. Arsitektur YOLOv11

3. METODE PENELITIAN

Dalam penelitian ini terdapat delapan tahapan yang dilakukan, yaitu identifikasi masalah, analisis solusi, pengumpulan data, pengembangan model, perancangan sistem, implementasi, pengujian dan evaluasi. Tahapan tersebut dilakukan secara sistematis untuk mengembangkan dan mengevaluasi model deteksi berbasis YOLOv11 dalam mendukung proses deteksi objek secara akurat dan efisien.

3.1. Identifikasi Masalah

Proses pencatatan penggunaan air pada PDAM masih dilakukan secara manual melalui pengambilan foto meteran air dan pembacaan angka meteran berdasarkan hasil foto. Proses ini memerlukan waktu yang relatif lama dan berpotensi menimbulkan kesalahan dalam pembacaan maupun pencatatan angka meteran. Kondisi tersebut dapat menyebabkan

keterlambatan serta ketidaktepatan informasi penggunaan air

3.2. Analisis Solusi

Berdasarkan permasalahan yang telah diidentifikasi, solusi dipilih dengan mempertimbangkan aspek efisiensi, keberlanjutan, dan kemudahan implementasi. Pendekatan yang diusulkan menggunakan algoritma deteksi objek *You Only Look Once* (YOLO) untuk membaca angka pada meteran air secara otomatis dari citra. YOLO versi 11 *nano* dipilih karena memiliki kecepatan tinggi dan efisiensi komputasi yang baik dalam mendeteksi objek, khususnya karakter numerik. Selain itu, arsitektur yang ringan memungkinkan penerapan pada perangkat dengan sumber daya terbatas tanpa mengurangi kinerja deteksi secara signifikan. Pendekatan ini diharapkan mampu meningkatkan akurasi dan efisiensi dalam proses pembacaan angka meteran air serta mendukung peningkatan keandalan pencatatan data penggunaan air.

3.3. Pengumpulan Data

Pada tahap pengumpulan data, citra meteran air diperoleh menggunakan perangkat smartphone dalam kondisi nyata di lapangan. Data yang dikumpulkan berupa gambar digital meteran air dengan variasi kondisi, seperti perbedaan pencahayaan, sudut pengambilan gambar, serta kondisi fisik meteran yang bersih maupun kotor. Untuk menjaga konsistensi, pengambilan data dilakukan berdasarkan panduan teknis yang mencakup kriteria kualitas citra dan format penamaan file sesuai dengan nomor pelanggan.

Selanjutnya, data yang telah dikumpulkan dianotasi menggunakan platform *Roboflow* yang menyediakan layanan anotasi untuk pengembangan model deteksi. Proses anotasi dilakukan dalam dua tahap, yaitu segmentasi dan deteksi. Pada tahap segmentasi, anotasi dilakukan untuk menandai area kotak yang berisi angka meteran dengan total 9.002 data, yang terdiri dari 7.200 data pelatihan, 901 data validasi, dan 901 data pengujian. Tahap ini bertujuan untuk memfokuskan area deteksi pada bagian angka meteran yang dapat dilihat pada gambar 2.



Gambar 2. Dataset segmentasi

Selanjutnya, tahap deteksi dilakukan dengan memberikan anotasi pada masing-masing digit angka 0 sampai 9 yang terdapat pada hasil segmentasi. Total data yang digunakan pada tahap deteksi adalah 16.520 data, yang terdiri dari 13.216 data pelatihan, 1.652 data validasi, dan 1.652 data pengujian. Dataset ini digunakan untuk model agar mampu mengenali dan mendeteksi setiap digit angka pada meteran air secara akurat yang dapat dilihat pada gambar 3.



Gambar 3. Dataset deteksi

3.4. Pengembangan Model

Tahapan pengembangan model pada penelitian ini menggunakan algoritma *You Only Look Once* (YOLO) versi 11, yaitu *YOLOv11n-seg* untuk segmentasi area angka dan *YOLOv11n* untuk deteksi digit angka [13]. Pengembangan model dilakukan menggunakan pendekatan *supervised learning* dengan memanfaatkan *pretrained weights* dari *library Ultralytics* melalui teknik *transfer learning* untuk meningkatkan efisiensi pelatihan dan performa model. Arsitektur YOLOv11 terdiri dari tiga komponen utama, yaitu *backbone*, *neck*, dan *head* [11]. *Backbone* berfungsi mengekstraksi fitur citra menggunakan jaringan saraf konvolusi yang dilengkapi *Batch Normalization* dan fungsi aktivasi *Sigmoid Linear Unit* (SiLU). Selanjutnya, *neck* menggabungkan fitur dari berbagai skala menggunakan modul *C2f*, *Spatial Pyramid Pooling-Fast* (SPPF), dan *Cross Stage Partial with Spatial Attention* (C2PSA) untuk meningkatkan representasi fitur. Head digunakan untuk menghasilkan prediksi berupa lokasi dan kelas objek secara akurat.

Sebelum proses pelatihan, dataset dianotasi menggunakan format YOLO, yaitu *bounding box* untuk model deteksi dan *polygon* untuk model segmentasi. Selanjutnya, dilakukan augmentasi data berupa rotasi sebesar 15° dan flip 180° untuk meningkatkan kemampuan generalisasi model terhadap variasi posisi dan orientasi objek. Dataset kemudian dibagi menjadi data pelatihan, validasi, dan pengujian untuk memastikan proses pelatihan dan evaluasi model dilakukan secara objektif. Proses pelatihan dilakukan menggunakan *optimizer AdamW* untuk mengoptimalkan pembaruan bobot model dan meningkatkan stabilitas konvergensi. Model yang dihasilkan selanjutnya digunakan untuk melakukan segmentasi area angka dan mendeteksi digit angka pada citra meteran air secara otomatis.

3.5. Implementasi

Pada tahap ini, model dilatih dengan menggunakan layanan *cloud Kaggle* dengan menggunakan *Jupyter Notebook* untuk mengeksekusi kode Bahasa pemrograman *Python*. Model khusus yang telah dibuat dihubungkan kedalam *framework python* menggunakan *FastAPI*.

3.6. Pengujian

Dalam tahap ini, dilakukan pengujian terhadap kinerja model yang dibuat dan akan dievaluasi menggunakan prosedur *hyperparameter tuning*. Tujuan dari ukuran pengujian ini adalah untuk memastikan bahwa model dapat mendapatkan hasil terbaik dari proses pelatihan model.

3.7. Evaluasi

Dari hasil beberapa pelatihan, model akan dievaluasi melalui tingkat keakuratan deteksi dengan menggunakan *mean average precision* (mAP). mAP digunakan untuk mengukur tingkat performa deteksi objek dari hasil *training* model. Sebelum melakukan pengukuran mAP, dilakukan penyetelan nilai *threshold* pada IoU untuk validasi objek yang dideteksi. *Threshold* merupakan nilai ambang batas untuk pembeda dalam menentukan apakah hasil dari deteksi dianggap valid atau tidak. Nilai *Intersection over Union* (IoU) digunakan untuk menentukan seberapa cocok kotak prediksi yang dihasilkan dengan kotak yang sebenarnya. Kedua konsep ini merupakan hal yang sangat penting dalam mengevaluasi kinerja model deteksi objek. Untuk mendapatkan mAP dibutuhkan nilai *average precision* (AP) yang didapatkan dari *precision* dan *recall*. Rumus dari mAP, *precision* dan *recall* dapat dilihat pada persamaan (1), (2) dan (3).

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \quad (1)$$

$$precision = \frac{TP}{TP+FP} \quad (2)$$

$$recall = \frac{TP}{TP+FN} \quad (3)$$

Keterangan rumus:

n : Jumlah AP

AP : *Average Precision*

TP : *True Positive*

FP : *False Positive*

TN : *True Negative*

FN : *False Negative*

4. HASIL DAN PEMBAHASAN

Berdasarkan pengujian proses pelatihan model, didapatkan hasil evaluasi melalui beberapa parameter yang dipilih sebelumnya.


Tabel 1. Hasil pengujian pelatihan model



Epoch	lr0	lrf	Precision	Recall	mAP
100	0.01	0.1	97.9%	96.1%	98.2%
100	0.001	0.01	98.2%	97.2%	98.6%

Pada Tabel 1 ditunjukkan hasil beberapa percobaan pelatihan model dengan variasi parameter *learning rate*. Seluruh percobaan dilakukan menggunakan *epoch* sebanyak 100 untuk memastikan model mencapai kondisi konvergensi yang stabil. Berdasarkan hasil percobaan, kombinasi *initial learning rate* (lr0) sebesar 0,001 dan *final learning rate* (lrf) sebesar 0,01 menghasilkan performa terbaik dibandingkan konfigurasi lainnya, dengan nilai *precision* sebesar 98,2%, *recall* sebesar 97,2%, dan *mean average precision* (mAP) sebesar 98,6%. Hasil ini menunjukkan bahwa konfigurasi *learning rate* tersebut mampu mengoptimalkan proses pembaruan bobot model secara lebih efektif, sehingga meningkatkan kemampuan model dalam mendeteksi objek secara akurat dan konsisten.

Selanjutnya, model diuji menggunakan citra meteran air dengan berbagai kondisi lingkungan untuk mengevaluasi kemampuan generalisasi model. Variasi kondisi pengujian meliputi meteran dalam kondisi bersih, buram, kotor, pencahayaan baik, pencahayaan rendah, pantulan cahaya berlebihan, serta kondisi meteran yang sebagian tertutup di luar area angka. Hasil pengujian menunjukkan bahwa model tetap mampu mendeteksi area angka meteran air dengan baik pada berbagai kondisi tersebut. Hal ini menunjukkan bahwa proses augmentasi data dan penggunaan arsitektur *YOLOv11n-seg* dan *YOLOv11n* efektif dalam meningkatkan ketahanan model terhadap variasi kondisi visual di lingkungan nyata. Hasil pengujian deteksi objek dapat dilihat pada tabel 2.

Tabel 2. Pengujian deteksi model

No	Kondisi Meteran	Gambar	Status
1.	Bersih dan semua digit angka terlihat jelas dengan pencahayaan yang baik		Angka terdeteksi dengan benar
2.	Buram dan kotor dengan pencahayaan yang rendah		Angka terdeteksi dengan benar

No	Kondisi Meteran	Gambar	Status
3.	Buram dengan pencahayaan yang rendah		Angka terdeteksi dengan benar
4.	Kotor dengan pencahayaan yang baik		Angka terdeteksi dengan benar
5.	Kotor dan digit angka tertutup pasir dengan pencahayaan baik		Angka terdeteksi dengan benar
6.	Kotor dan satu digit angka tertutup lumpur kering dengan pencahayaan baik		Angka terdeteksi dengan benar
7.	Buram dan pencahayaan yang rendah		Angka terdeteksi dengan benar
8.	Bersih dan jelas dengan pantulan cahaya yang berlebih.		Angka terdeteksi dengan benar

Berdasarkan hasil pengujian yang ditunjukkan pada Tabel 2, model mampu mendeteksi angka meteran air dengan baik pada sebagian besar kondisi citra. Namun, pada beberapa kondisi tertentu, masih ditemukan ketidaktepatan dalam proses deteksi. Hal ini disebabkan oleh faktor kualitas citra yang rendah, seperti pencahayaan yang kurang memadai, keberadaan kotoran atau lumpur yang menutupi angka meteran, kondisi citra yang buram, serta tingkat visibilitas angka yang sangat rendah sehingga sulit dikenali bahkan secara visual oleh manusia. Kondisi tersebut mempengaruhi kemampuan model dalam mengekstraksi fitur secara optimal, sehingga berdampak pada penurunan kinerja deteksi.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil pengujian yang telah dilakukan, model YOLOv11 nano (YOLOv11n) dengan konfigurasi *hyperparameter* terbaik, yaitu *optimizer AdamW*, *initial learning rate* sebesar 0,001, *final learning rate* sebesar 0,01, jumlah *epoch* sebanyak 100, *mask ratio* sebesar 4, *confidence threshold* sebesar 0,3, dan *intersection over union*

(IoU) sebesar 0,7, menunjukkan kinerja yang sangat baik dalam mendeteksi angka meteran air. Model menghasilkan nilai *precision* sebesar 98,2%, *recall* sebesar 97,2%, *mAP50* sebesar 98,6%, dan *mAP50-95* sebesar 82%. Hasil tersebut menunjukkan bahwa model memiliki tingkat akurasi, konsistensi, dan kemampuan generalisasi yang tinggi dalam mendeteksi digit angka pada berbagai kondisi citra meteran air. Dengan demikian, model YOLOv11n yang dikembangkan terbukti efektif dan andal untuk digunakan dalam proses deteksi angka meteran air secara otomatis berbasis citra digital.

Model YOLOv11n yang dikembangkan masih memiliki potensi untuk ditingkatkan melalui eksplorasi konfigurasi *hyperparameter* yang lebih luas, seperti variasi *learning rate scheduling*, penyesuaian *batch size*, serta penambahan jumlah *epoch* untuk memperoleh konvergensi yang lebih optimal. Selain itu, peningkatan jumlah dan keberagaman dataset, khususnya pada kondisi pencahayaan rendah, citra buram, dan objek yang tertutup sebagian, dapat meningkatkan kemampuan generalisasi model. Penerapan teknik augmentasi yang

lebih kompleks serta penggunaan arsitektur YOLO dengan kapasitas yang lebih besar juga dapat dipertimbangkan untuk meningkatkan akurasi dan stabilitas deteksi pada kondisi visual yang menantang.

DAFTAR PUSTAKA

- [1] A. Maulana Yusuf *et al.*, “Perancangan UI/UX Sistem Informasi Pembayaran Penggunaan Air Dengan Metode Design Thinking,” *Teknologi Sistem Informasi dan Sistem Komputer TGD*, Jan. 2023, [Online]. Available: <https://ojs.trigunadharma.ac.id/index.php/jsk/index>
- [2] H. Hendra and A. Halbadika Fahlevi, “Implementation of Good Corporate Governance (GCG) Principles in PDAM Tirta Ogan, Ogan Ilir District,” *Iapa Proceedings Conference*, p. 187, Oct. 2024, doi: 10.30589/proceedings.2024.1052.
- [3] R. Carvalho, J. Melo, R. Graça, G. Santos, and M. J. M. Vasconcelos, “Deep learning-powered system for real-time digital meter reading on edge devices,” *Applied Sciences (Switzerland)*, vol. 13, no. 4, Feb. 2023, doi: 10.3390/app13042315.
- [4] Y. Ren, C. Zhu, and S. Xiao, “Object Detection Based on Fast/Faster RCNN Employing Fully Convolutional Architectures,” *Math. Probl. Eng.*, vol. 2018, 2018, doi: 10.1155/2018/3598316.
- [5] W. Liu *et al.*, “SSD: Single shot multibox detector,” Dec. 2016, doi: 10.1007/978-3-319-46448-0_2.
- [6] F. Sa’adat and E. P. Widiyanto, “Implementasi YOLOv8 dalam deteksi angka meteran air PDAM,” Palembang, Sep. 2024. Accessed: Aug. 01, 2025. [Online]. Available: <https://doi.org/10.35957/jatisi.v11i3.9081>
- [7] R. Laroca, A. B. Araujo, L. A. Zanlorensi, E. C. De Almeida, and D. Menotti, “Towards Image-Based Automatic Meter Reading in Unconstrained Scenarios: A Robust and Efficient Approach,” *IEEE Access*, vol. 9, pp. 67569–67584, 2021, doi: 10.1109/ACCESS.2021.3077415.
- [8] P. Jiang, D. Ergu, F. Liu, Y. Cai, and B. Ma, “A review of YOLO algorithm developments,” in *Procedia Computer Science*, Elsevier B.V., 2021, pp. 1066–1073. doi: 10.1016/j.procs.2022.01.135.
- [9] M. Imran, H. Anwar, M. Tufail, A. Khan, M. Khan, and D. A. Ramli, “Image-based automatic energy meter reading using deep learning,” *Computers, Materials and Continua*, vol. 74, no. 1, pp. 203–216, 2023, doi: 10.32604/cmc.2023.029834.
- [10] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You only look once: Unified, real-time object detection,” 2016. [Online]. Available: <http://pjreddie.com/yolo/>
- [11] S. J. Kim and M. J. Kim, “Human action recognition using YOLOv11Ultralytics: A comprehensive study for real-time applications,” *Journal of Advanced Artificial Intelligence, Engineering and Technology*, vol. 01, no. 02, 2025, doi: 10.56147/aaiet.1.2.14.
- [12] F. Martinelli, F. Mercaldo, and A. Santone, “Water meter reading for smart grid monitoring,” *Sensors*, vol. 23, no. 1, Jan. 2023, doi: 10.3390/s23010075.
- [13] R. Khanam and M. Hussain, “YOLOv11: An overview of the key architectural enhancements,” Oct. 2024, [Online]. Available: <http://arxiv.org/abs/2410.17725>