

Pengenalan Karakter Angka pada Meter-Air Analog Menggunakan Arsitektur *Convolutional Neural Network* (CNN)

Abdul Majid¹, Sajarwo Anggai², Arya Adhyaksa Waskita³
^{1,2,3}Program Studi Teknik Informatika S-2, Universitas Pamulang
e-mail: kangabdupati@gmail.com¹, sajarwo@gmail.com², aawaskita@gmail.com³

Abstrak – Sebagian besar Perusahaan Air Minum (PAM) di Indonesia hingga kini masih mengandalkan meter air analog *bertipe flow meter turbin*, bahkan pada wilayah operasional berskala besar dengan jumlah pelanggan aktif yang melebihi 100.000. Kendala utama dalam transisi ke teknologi yang lebih modern, seperti meter air pintar, adalah tingginya biaya pengadaan dan implementasinya. Akibatnya, proses pencatatan angka pemakaian air masih dilakukan secara manual setiap bulan, yang memerlukan keterlibatan tenaga kerja dalam jumlah besar dan tidak memungkinkan verifikasi pembacaan secara masif. Hal ini seringkali berdampak pada rendahnya akurasi data pencatatan, serta menimbulkan ketidakpuasan pelanggan akibat tagihan yang tidak sesuai dengan konsumsi riil. Untuk menjawab tantangan tersebut, kami mengusulkan solusi berbasis visi komputer dengan menerapkan model deteksi objek *You Only Look Once* versi 10 (YOLOv10), sebuah arsitektur berbasis *Convolutional Neural Network* (CNN) yang dirancang untuk kebutuhan deteksi waktu nyata (*real-time*). YOLOv10 mengusung pendekatan *Non-Maximum Suppression* (NMS)-free, yang memungkinkan kecepatan inferensi lebih tinggi dibandingkan generasi sebelumnya, tanpa mengorbankan akurasi deteksi. Berdasarkan hasil pengujian pada citra meter air analog, model YOLOv10 menunjukkan performa yang menjanjikan meskipun hanya dijalankan pada CPU. Model ini mampu mencapai nilai *precision* sebesar 0,9426 (94,26%) dan *recall* sebesar 0,9783 (97,83%) dengan rata-rata waktu inferensi 1,7157 detik per gambar. Temuan ini menunjukkan potensi penerapan teknologi deteksi otomatis dalam mendukung efisiensi operasional PAM dan meningkatkan akurasi pembacaan meter air secara signifikan.

Kata kunci: Meter air analog, Deteksi objek, CNN, YOLOv10

I. PENDAHULUAN

Sektor penyediaan air bersih di Indonesia, yang sebagian besar dijalankan oleh Perusahaan Air Minum (PAM), menghadapi tantangan besar dalam modernisasi sistem pencatatan pemakaian air. Hingga saat ini, sebagian besar PAM masih menggunakan meter air analog untuk mencatat konsumsi air pelanggan. Meskipun teknologi meter air pintar telah tersedia dan mulai diadopsi secara global, penerapannya di Indonesia masih terbatas karena biaya pengadaan yang tinggi, keterbatasan infrastruktur digital, serta kesiapan teknis di lapangan. Sebagai akibatnya, pencatatan angka meter air masih mengandalkan metode manual yang dilakukan oleh petugas lapangan setiap bulan. Proses ini tidak hanya menuntut sumber daya manusia dalam jumlah besar, tetapi juga rentan terhadap kesalahan pencatatan dan manipulasi data, yang pada akhirnya berdampak pada akurasi tagihan dan kepuasan pelanggan [1], [2], [3], [4].

Dalam upaya menjembatani kesenjangan antara keterbatasan teknologi dan kebutuhan akan efisiensi operasional, pendekatan berbasis visi komputer menawarkan alternatif yang menjanjikan. Salah satu pendekatan terkini dalam bidang ini adalah penggunaan model deteksi objek berbasis *deep learning*, khususnya arsitektur YOLOv10. Sebagai salah satu versi dalam keluarga YOLO, memperkenalkan sejumlah perbaikan signifikan, termasuk penghapusan kebutuhan akan *Non-Maximum Suppression* (NMS) melalui pendekatan *NMS-free decoder*, yang diklaim mampu meningkatkan kecepatan inferensi tanpa mengorbankan akurasi [5].

Penelitian ini bertujuan untuk mengeksplorasi potensi penggunaan YOLOv10 dalam mendeteksi dan mengenali tampilan angka pada meter air analog. Dengan menggabungkan kecepatan inferensi dan akurasi deteksi yang tinggi, model ini diharapkan dapat digunakan sebagai fondasi sistem pembacaan meter otomatis berbasis citra, yang lebih efisien, akurat, dan dapat diterapkan pada skala besar tanpa harus mengganti infrastruktur meter yang ada.

II. METODE PENELITIAN

Penelitian ini bersifat eksperimental dengan pendekatan kuantitatif, di mana sistem otomatisasi pembacaan angka pada meter air analog dikembangkan dan diuji menggunakan algoritma CNN. Fokus utama penelitian adalah untuk mengetahui kinerja arsitektur model deteksi objek, terutama YOLOv10, dalam mengenali angka pada citra meter air analog. Metodologi yang digunakan mencakup tahapan mulai dari pengumpulan dan anotasi data, pelatihan model, pengujian performa, hingga evaluasi berdasarkan metrik akurasi, *recall*, serta kecepatan inferensi.

Dengan metode ini, diharapkan diperoleh pemahaman yang menyeluruh mengenai efektivitas masing-masing model dalam konteks pembacaan otomatis angka meter air, serta memberikan dasar bagi pengembangan sistem yang dapat diterapkan di lingkungan operasional PAM secara nyata.

A. Analisis Kebutuhan Data

Pengumpulan data yang dilakukan pada penelitian ini ada kombinasi dari pengumpulan data primer dan sekunder dengan perbandingan 50:50. Pembagian sumber data tersebut dilakukan untuk menambahkan variasi jenis meter air dari berbagai bentuk dan produsen. Data primer adalah data dari sumber awal/asli data tersebut berasal, dalam hal ini adalah hasil dari pembacaan meter air pelanggan PT. XYZ. Data sekunder adalah data yang sebelumnya dikumpulkan dan dibuat oleh seseorang baik diterbitkan atau tidak. Sumber data sekunder yang digunakan adalah berasal dari Kaggle dataset.

Selanjutnya dilakukan *image processing* yaitu pemilahan gambar dengan kualitas rendah/noise tinggi, *contrast fixing* (mencerahkan/menggelapkan),

B. Perancangan Penelitian

Penelitian ini dirancang untuk mengevaluasi efektivitas model YOLOv10 dalam mendeteksi digit pada meter air analog, dengan fokus pada keseimbangan antara akurasi dan efisiensi inferensi. Eksperimen dilakukan untuk mengetahui sejauh mana model ini dapat diterapkan dalam kondisi nyata, di mana keterbatasan perangkat keras seperti penggunaan CPU menjadi pertimbangan penting.

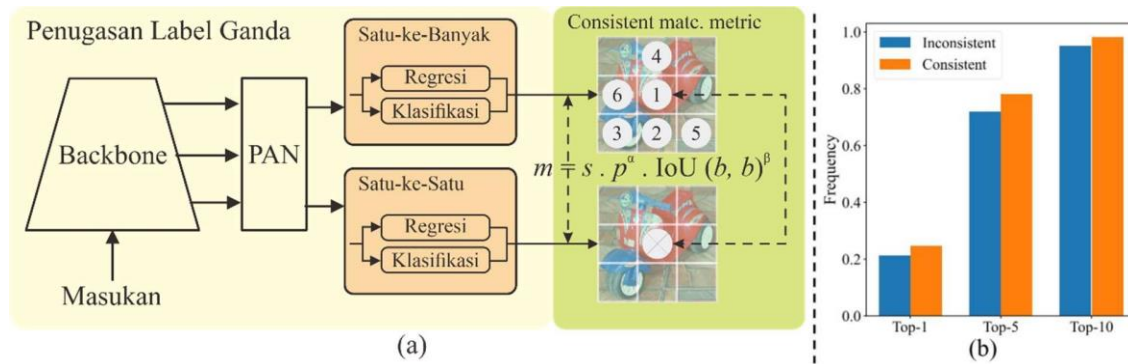
Model yang digunakan merupakan pengembangan dari keluarga YOLO yang dikenal karena kemampuannya dalam deteksi objek secara *real-time*. Dalam proses pelatihan YOLO, pendekatan *Top-Aware Labeling* (TAL) umumnya digunakan untuk menetapkan beberapa label positif untuk setiap objek, seperti yang diadopsi dalam YOLOv7 dan YOLOv8 [6], [7], [8], [9], [10], [11], [12], [13], [14], [15]. Penerapan penetapan satu-ke-banyak ini menghasilkan sinyal pengawasan yang lebih kaya, memfasilitasi optimasi dan menghasilkan kinerja yang lebih baik. Namun, ini membuat YOLO harus bergantung pada pemrosesan pasca NMS [7], yang menyebabkan efisiensi inferensi yang kurang optimal untuk penerapan. Sementara penelitian sebelumnya [16] mengeksplorasi pencocokan satu-ke-satu untuk menekan prediksi berlebihan, mereka biasanya memperkenalkan overhead inferensi tambahan atau menghasilkan kinerja yang kurang optimal.

YOLOv10 mengusung pendekatan baru yang menggabungkan pencocokan satu-ke-banyak dan satu-ke-satu dalam strategi pelatihan tanpa NMS (*NMS-free*). Metode ini menghilangkan kebutuhan akan tahap seleksi NMS dan memungkinkan inferensi yang lebih cepat tanpa mengorbankan akurasi. Pendekatan ini juga meningkatkan konsistensi antara tahap pelatihan dan inferensi, sekaligus menekan terjadinya prediksi berlebihan yang umum terjadi pada model sebelumnya [3], [16], [17].

Eksperimen dilakukan pada dataset gambar meter air analog yang telah dianotasi secara manual. Model dilatih dan diuji dalam lingkungan terbatas berbasis CPU, dengan metrik evaluasi mencakup *precision*, *recall*, dan rata-rata waktu inferensi per gambar untuk menilai kelayakan penerapan YOLOv10 dalam sistem pembacaan meter otomatis yang efisien dan andal.

C. YOLOv10 Dengan NMS-free

NMS-free atau dapat juga disebut penugasan label ganda [18]. Berbeda dengan proses satu-ke-banyak, pencocokan satu-ke-satu hanya menetapkan satu prediksi untuk setiap *ground truth* (yang menghasilkan nilai *confidence*), sehingga menghindari pasca-pemrosesan NMS. Namun, ini menyebabkan pengawasan yang lemah, yang menghasilkan akurasi dan kecepatan konvergensi yang kurang optimal [19]. Untungnya, kekurangan ini dapat dikompensasi dengan penugasan satu-ke-banyak (A. Wang et al., 2024). Untuk mencapai hal ini, dapat menggunakan penugasan label ganda untuk YOLOs untuk menggabungkan keunggulan kedua strategi tersebut. Secara khusus, seperti yang ditunjukkan pada Gambar 4, ditambahkan kepala satu-ke-satu untuk YOLOs. Struktur ini mempertahankan bentuk yang identik dan menggunakan tujuan optimasi yang sama dengan cabang satu-ke-banyak, tetapi memanfaatkan pencocokan satu-ke-satu untuk mendapatkan penugasan label. Selama pelatihan, kedua kepala ini dioptimalkan bersama dengan model, memungkinkan *backbone* dan *neck* mendapatkan pengawasan yang kaya dari penugasan satu-ke-banyak. Saat melakukan inferensi, kami membuang kepala satu-ke-banyak dan menggunakan kepala satu-ke-satu untuk membuat prediksi. Ini memungkinkan YOLOs melakukan *deployment end-to-end* tanpa biaya inferensi tambahan. Selain itu, dalam pencocokan satu-ke-satu, kami menggunakan pemilihan *top one*, yang menghasilkan performa yang sama dengan pencocokan Hungarian dengan waktu pelatihan ekstra yang lebih sedikit.



Gambar 1 Ilustrasi Penugasan Label Ganda

1. Penugasan ganda konsisten untuk pelatihan tanpa NMS.
2. Frekuensi penugasan satu-ke-satu dalam hasil *Top-1/5/10* dari penugasan satu-ke-banyak untuk YOLOv10-S yang menggunakan $\alpha_{o2m}=0.5$ dan $\beta_{o2m}=6$ secara default. Untuk konsistensi, $\alpha_{o2o}=0.5$; $\beta_{o2o}=6$. Untuk inkonsistensi, $\alpha_{o2o}=0.5$; $\beta_{o2o}=2$

Consistent Matching Metric. Selama proses, pendekatan satu-ke-satu dan satu-ke-banyak menggunakan metrik untuk menilai secara kuantitatif tingkat kesesuaian antara prediksi dan *instance*. Untuk mencapai pencocokan yang mempertimbangkan prediksi pada kedua cabang, kami menggunakan metrik pencocokan yang seragam, perhatikan rujuk ke (1)

$$(m(\alpha, \beta) = s \cdot p^\alpha \cdot \text{IoU}(\hat{b}, b)^\beta) \quad (1)$$

di mana p adalah skor klasifikasi, \hat{b} dan b masing-masing menunjukkan bounding box dari prediksi dan *instance*. s merepresentasikan prior spasial yang menunjukkan apakah titik jangkar dari prediksi berada di dalam *instance*. α dan β adalah dua hiperparameter penting yang menyeimbangkan dampak dari tugas prediksi semantik dan tugas regresi lokasi. Cara ini disebut metrik satu-ke-banyak dan satu-ke-satu sebagai $m_{o2m}=m(\alpha_{o2m}, \beta_{o2m})$ dan $m_{o2o}=m(\alpha_{o2o}, \beta_{o2o})$, masing-masing. Metrik ini memengaruhi penugasan label dan informasi supervisi untuk dua kepala.

III. HASIL DAN PEMBAHASAN

Hasil pengujian menunjukkan bahwa model YOLOv10 mampu mendeteksi digit pada meter air analog dengan tingkat akurasi yang tinggi dan waktu inferensi yang relatif cepat, meskipun dijalankan pada lingkungan komputasi terbatas berbasis CPU. Model mencapai nilai *precision* sebesar 94,26% dan *recall* sebesar 97,83%, yang menunjukkan bahwa model memiliki kemampuan deteksi yang andal dengan tingkat kesalahan minimum dalam mengidentifikasi digit yang relevan.

Rata-rata waktu inferensi yang diperoleh sebesar 1,7157 detik per gambar, menunjukkan efisiensi pemrosesan yang cukup baik untuk aplikasi *real-time* pada perangkat dengan sumber daya terbatas. Performa ini sejalan dengan keunggulan arsitektur YOLOv10 yang menghilangkan kebutuhan akan NMS, sehingga mengurangi beban pemrosesan paska-inferensi yang umum ditemukan pada versi YOLO sebelumnya.

Visualisasi prediksi menunjukkan bahwa model dapat mendeteksi digit dalam berbagai kondisi pencahayaan, orientasi, dan tingkat ketajaman gambar, dengan tingkat keberhasilan yang konsisten. Beberapa kegagalan deteksi ditemukan pada gambar dengan refleksi tinggi atau digit yang sebagian tertutup, namun secara keseluruhan tidak mempengaruhi kinerja model secara signifikan.

Keberhasilan ini menegaskan bahwa YOLOv10 tidak hanya unggul dalam hal efisiensi, tetapi juga mampu mempertahankan akurasi deteksi yang kompetitif, bahkan tanpa dukungan GPU. Dengan demikian, model ini layak dipertimbangkan sebagai solusi praktis dalam sistem pembacaan meter air otomatis, khususnya bagi perusahaan penyedia air minum yang ingin meningkatkan efisiensi operasional tanpa harus mengganti seluruh infrastruktur meter analog yang telah ada.

Pada bagian ini kami akan menjabarkan terkait proses pelatihan masing-masing model, beserta proses yang terjadi selama pelatihan dan setelahnya. Selain itu, kami juga akan membahas tantangan yang dihadapi selama proses pelatihan dan bagaimana solusi yang diterapkan untuk mengatasinya. Dengan pemahaman yang mendalam tentang proses ini, diharapkan pembaca dapat memahami kompleksitas dan pentingnya setiap langkah dalam pengembangan model.

A. Persiapan Pelatihan

Pelatihan model YOLOv10 dengan dataset kustom dilakukan pada lingkungan Kaggle Notebooks.


Berikut adalah informasi dasar saat pelatihan.

- Model pra-latih YOLOv10-L dari Ultralytics
- Batch = 32
- Ukuran gambar random original
- Epochs = 500
- Realisasi epochs = 179 (proses pelatihan dihentikan karena tidak ada perbaikan performa dari 50 *epochs* terakhir)
- Waktu pelatihan + 2 jam 50 menit

B. Hasil Pelatihan

Proses pelatihan dihentikan secara terkontrol untuk mencegah terjadinya *overfitting* terhadap data latih. Langkah ini penting dilakukan guna memperoleh model yang optimal dan mampu melakukan generalisasi dengan baik pada data uji.

1. Training Loss



Gambar 2 Grafik *training loss* pelatihan


Selama proses pelatihan, model YOLOv10 menunjukkan penurunan *training loss* yang konsisten, mengindikasikan proses belajar yang efektif sebagaimana ditunjukkan Gambar 2.

Train/box_loss: Nilai awal *loss* berada di kisaran ~4,0 dan turun secara stabil hingga ~1,5. Penurunan ini menunjukkan bahwa model semakin baik dalam memprediksi lokasi objek selama pelatihan berlangsung.

Train/cls_loss: Terjadi penurunan drastis dari ~8 menjadi di bawah ~1 hanya dalam 20 epoch pertama. Hal ini mencerminkan kemampuan model dalam mengenali dan membedakan masing-masing kelas objek dengan cepat.

Train/dfl_loss (*Distribution Focal Loss*): Dimulai dari ~2,5 dan turun stabil hingga ~1,6. Nilai ini menunjukkan bahwa model dapat memprediksi *bounding box* dengan presisi tinggi berdasarkan distribusi *offset grid*.

2. Validation Loss



Gambar 3 Grafik *validation loss* pelatihan


Perbandingan antara *training loss* dan *validation loss* menunjukkan adanya gap kecil yang menandakan kemungkinan *overfitting* ringan seperti yang ditampilkan pada Gambar 3.

Val/box_loss: Terjadi penurunan awal yang tajam dan kemudian menetap dengan fluktuasi kecil di sekitar 2,6. Hal ini bisa disebabkan oleh *noise* atau kompleksitas data validasi.

Val/cls_loss: Menurun stabil hingga berada di kisaran 0,8–1,0. Nilai ini masih relatif sejalan dengan *train/cls_loss*, meskipun terdapat sedikit perbedaan.

Val/dfl_loss: Menunjukkan stagnasi pada nilai ~2,0, sedikit lebih tinggi dibanding *train/dfl_loss*, yang menandakan bahwa model sedikit kesulitan dalam melakukan generalisasi prediksi *box* ke data validasi.

3. Evaluasi Metrik



Gambar 4 Grafik evaluasi Metrik hasil pelatihan


Model YOLOv10 menunjukkan kinerja yang sangat baik dalam hal akurasi dan konsistensi deteksi, perhatikan Gambar 4. *Precision (metrics/precision(B))*: Nilai *precision* > 0,95 menunjukkan bahwa model jarang menghasilkan *false positive* dan memiliki prediksi yang sangat akurat.

Recall (metrics/recall(B)): *Recall* juga > 0,95, menunjukkan bahwa model hampir tidak melewatkan objek yang seharusnya terdeteksi. Ini sangat baik, mengingat *recall* biasanya lebih sulit ditingkatkan dibanding *precision*.

mAP50 (*metrics/mAP50(B)*): Memberikan hasil sangat tinggi, yang menunjukkan bahwa sebagian besar *bounding box* sudah sesuai dengan *ground truth* pada toleransi IoU > 0,5.

mAP50–95 (*metrics/mAP50-95(B)*): Meskipun merupakan metrik yang lebih ketat, model tetap menunjukkan hasil yang baik, mendekati nilai 0,7. Ini mengindikasikan ketepatan yang tetap tinggi dalam berbagai rentang toleransi IoU.


4. Confusion Matrix



Gambar 5 Grafik *confusion matrix* hasil pelatihan

Gambar 5 menunjukkan hasil *confusion matrix* yang dinormalisasi menunjukkan performa deteksi antar kelas digit yang cukup merata. Model menunjukkan ketepatan sangat tinggi pada kelas 0 (0,98) dan performa sedikit lebih rendah pada kelas 4 dan 7 (masing-masing 0,93 dan 0,91). Model juga efektif dalam mengenali *background*, meskipun terdapat prediksi keliru terhadap *background* di beberapa kelas (~0,7). Kesalahan prediksi umumnya terjadi pada angka yang memiliki kemiripan bentuk visual, seperti antara 1 dan 7, 0 dan 9, atau 4 dan 5.

5. F1-Score dan Confidence Threshold



Gambar 6 F1-Score dan *Confidence Threshold*

Gambar 6 menampilkan analisis *F1-score* menggambarkan hubungan antara nilai *confidence* dan kualitas prediksi. Titik optimal *F1-score* tercapai pada nilai 0,96, dengan *confidence threshold* terbaik di sekitar 0,456.

Kurva *F1-score* menunjukkan peningkatan tajam pada rentang *confidence* 0–0,3, mencapai puncak antara 0,4–0,5, lalu menurun drastis setelah nilai *confidence* > 0,85. Penurunan ini menunjukkan indikasi *over-confidence*, yaitu model terlalu yakin terhadap prediksi yang keliru. Pada *confidence* sangat rendah (~0,2), *F1-score* menurun tajam karena tingginya *false positive*. Zona paling stabil berada di kisaran *confidence* 0,4–0,6.

Kelas 6 menunjukkan performa F1 yang sedikit lebih rendah dibanding kelas lain, terutama pada *confidence* tinggi, sedangkan kelas 3 dan 8 tampil sangat stabil dan mendekati maksimum.

6. Kesimpulan Awal

Secara keseluruhan, model YOLOv10 menunjukkan kinerja pelatihan yang konsisten, akurasi prediksi tinggi, serta stabilitas yang baik dalam mendeteksi digit pada meter air analog. Dengan nilai *F1-score* yang tinggi dan distribusi kesalahan yang dapat diterima, model ini sangat potensial untuk diimplementasikan secara nyata dengan kebutuhan penyesuaian parameter yang minimal.

C. Percobaan prototipe YOLOv10

Sebagai bagian dari validasi eksternal, percobaan prototipe dilakukan untuk menguji performa model YOLOv10 dalam konteks aplikasi nyata, yaitu pembacaan digit pada meter air analog. Tujuan utama dari percobaan ini adalah untuk menilai keandalan dan efisiensi model saat digunakan di luar lingkungan pelatihan, serta mengevaluasi potensi penerapannya dalam sistem pembacaan meter otomatis berbasis visi komputer.

Prototipe dikembangkan menggunakan bahasa pemrograman Python dan pustaka Ultralytics untuk kebutuhan inferensi berbasis YOLOv10. Implementasi dilakukan pada perangkat dengan spesifikasi komputasi minimal (CPU-only), guna mensimulasikan kondisi operasional yang umum dijumpai pada perangkat *edge* atau komputer lapangan dengan sumber daya terbatas. Model hasil pelatihan sebelumnya digunakan tanpa modifikasi, dan diterapkan pada kumpulan citra meter air yang belum pernah dilibatkan dalam proses pelatihan maupun validasi.



Gambar 7 Hasil deteksi menggunakan model YOLOv10

Gambar 7 menunjukkan hasil penerapan model YOLOv10 dalam mendeteksi digit angka pada meter air. Deteksi difokuskan pada digit berwarna hitam, karena angka merah merepresentasikan pecahan satuan (desimal) yang tidak dihitung dalam volume m^3 yang ditagihkan. Hasil ini menunjukkan bahwa model dapat dilatih untuk membedakan bagian yang relevan dan diabaikan dalam proses deteksi. Selain itu, model juga terbukti mampu melakukan deteksi dengan akurat meskipun citra mengandung *noise* sedang hingga tinggi.

Secara keseluruhan, percobaan prototipe membuktikan bahwa model YOLOv10 tidak hanya unggul pada tingkat pelatihan dan validasi, tetapi juga menunjukkan performa yang kuat dalam situasi dunia nyata. Temuan ini memperkuat argumen bahwa arsitektur YOLOv10 layak dipertimbangkan sebagai solusi praktis dan efisien untuk sistem pembacaan meter air berbasis gambar, dengan kebutuhan *fine-tuning* yang minimal serta kompatibilitas tinggi terhadap perangkat dengan keterbatasan komputasi.

IV. KESIMPULAN

Penelitian ini memperlihatkan bahwa pendekatan deteksi objek berbasis YOLOv10 memiliki potensi besar untuk diterapkan dalam sistem pembacaan meter air analog secara otomatis. Efisiensi komputasi dan stabilitas deteksi yang ditunjukkan oleh model, bahkan dalam kondisi citra yang bervariasi dan tidak ideal, memberikan dasar yang kuat untuk pengembangan solusi praktis di sektor pelayanan publik, khususnya perusahaan air minum yang masih bergantung pada pembacaan manual.

Hasil yang dicapai tidak hanya relevan dalam konteks teknis, tetapi juga berdampak signifikan dalam aspek operasional dan ekonomi. Implementasi sistem berbasis visi komputer dapat mengurangi ketergantungan terhadap pembacaan lapangan secara manual, meminimalkan kesalahan pencatatan, dan meningkatkan transparansi layanan pelanggan.

Ke depan, pengembangan sistem ini dapat diarahkan pada integrasi dengan perangkat mobile atau edge device untuk memungkinkan pembacaan langsung di lapangan. Selain itu, pelatihan model dengan data dari berbagai jenis dan merek meter air akan meningkatkan kemampuan generalisasi dan memperluas cakupan penerapannya. Perlu juga dikaji pendekatan berbasis OCR terintegrasi untuk ekstraksi nilai digit secara otomatis, guna mendukung proses pelaporan dan penagihan secara real-time.

Dengan pendekatan yang adaptif dan biaya implementasi yang relatif rendah, solusi berbasis YOLOv10 ini dapat menjadi salah satu alternatif strategis dalam mendukung digitalisasi dan efisiensi operasional di sektor utilitas air.

DAFTAR PUSTAKA

- [1] N. Saetan and K. Dittakan, "EasyChair Preprint Thailand Water Meter Reading Using Convolutional Neural Networks From Smartphone Imagery Thailand Water Meter Reading Using Convolutional Neural Networks From Smartphone Imagery," 2024.
- [2] Y. Liang, Y. Liao, S. Li, W. Wu, T. Qiu, and W. Zhang, "Research on water meter reading recognition based on deep learning," *Sci Rep*, vol. 12, no. 1, Dec. 2022, doi: 10.1038/s41598-022-17255-3.
- [3] Y. Wang and X. Xiang, "GMS-YOLO Improved water meter reading recognition algorithm based on YOLOv8," 2024, doi: 10.21203/rs.3.rs-4453194/v1.
- [4] L. Sun, Y. Yuan, S. Qiao, and R. Qi, "Detection of Water Meter Digits Based on Improved Faster R-CNN," *Journal of Computer and Communications*, vol. 12, no. 03, pp. 1–13, 2024, doi: 10.4236/jcc.2024.123001.
- [5] A. Wang *et al.*, "YOLOv10: Real-Time End-to-End Object Detection," May 2024, [Online]. Available: <http://arxiv.org/abs/2405.14458>
- [6] T. Yang, S. Zhou, A. Xu, J. Ye, and J. Yin, "An Approach for Plant Leaf Image Segmentation Based on YOLOV8 and the Improved DEEPLABV3+," *Plants*, vol. 12, no. 19, Oct. 2023, doi: 10.3390/plants12193438.
- [7] J. Terven and D. Cordova-Esparza, "A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS," Apr. 2023, doi: 10.3390/make5040083.
- [8] O. M. Khare, S. Gandhi, A. M. Rahalkar, and S. Mane, "YOLOv8-Based Visual Detection of Road Hazards: Potholes, Sewer Covers, and Manholes," Oct. 2023, [Online]. Available: <http://arxiv.org/abs/2311.00073>
- [9] D. Reis, J. Kupec, J. Hong, and A. Daoudi, "Real-Time Flying Object Detection with YOLOv8," May 2023, [Online]. Available: <http://arxiv.org/abs/2305.09972>
- [10] Z. Huang, L. Li, G. C. Krizek, and L. Sun, "Research on Traffic Sign Detection Based on Improved YOLOv8," *Journal of Computer and Communications*, vol. 11, no. 07, pp. 226–232, 2023, doi: 10.4236/jcc.2023.117014.
- [11] R. Jia, B. Lv, J. Chen, H. Liu, L. Cao, and M. Liu, "Underwater Object Detection in Marine Ranching Based on Improved YOLOv8," *J Mar Sci Eng*, vol. 12, no. 1, Jan. 2024, doi: 10.3390/jmse12010055.
- [12] Q. Liu, Y. Liu, and D. Lin, "Revolutionizing Target Detection in Intelligent Traffic Systems: YOLOv8-SnakeVision," *Electronics (Switzerland)*, vol. 12, no. 24, Dec. 2023, doi: 10.3390/electronics12244970.
- [13] J. Moosmann *et al.*, "Ultra-Ef cient On-Device Object Detection on AI-Integrated Smart Glasses with TinyissimoYOLO," 2023.
- [14] X. Wang, H. Gao, Z. Jia, and Z. Li, "BL-YOLOv8: An Improved Road Defect Detection Model Based on YOLOv8," *Sensors (Basel)*, vol. 23, no. 20, Oct. 2023, doi: 10.3390/s23208361.
- [15] A. Dumitriu, F. Tatui, F. Miron, R. T. Ionescu, and R. Timofte, "Rip Current Segmentation: A Novel Benchmark and YOLOv8 Baseline Results," 2023. [Online]. Available: www.noaa.gov/.
- [16] Y. Chen, Q. Chen, Q. Hu, and J. Cheng, "DATE: Dual Assignment for End-to-End Fully Convolutional Object Detection," Nov. 2022, [Online]. Available: <http://arxiv.org/abs/2211.13859>
- [17] F. Wang, Q. Bao, Z. Wang, and Y. Chen, "Optimizing Transformer based on high-performance optimizer for predicting employment sentiment in American social media content."
- [18] A. Wang *et al.*, "Mitigating the Negative Impact of Over-association for Conversational Query Production," Sep. 2024, [Online]. Available: <http://arxiv.org/abs/2409.19572>
- [19] J. Redmon and A. Farhadi, "YOLOv3: An Incremental Improvement," Apr. 2018, [Online]. Available: <http://arxiv.org/abs/1804.02767>