



Pengembangan Sistem Deteksi Digit pada Meteran Air PDAM Menggunakan Model Deep Learning YOLOv5

* Albert Kingston Wang¹, Thoyyibah²

^{1,2}) Program Studi S2 Teknik Informatika, Program Pascasarjana, Universitas Pamulang, Banten

Email: albertkingston28@email.com

ABSTRACT

The use of PDAM (Regional Drinking Water Company) water meters has become the standard for measuring water consumption by customers in Indonesia. However, the process of reading water meters is still mostly done manually by officers, which can cause various problems. For example, reading errors can occur due to human factors or environmental conditions, such as poor lighting or a dirty water meter. Additionally, this process requires a lot of time and effort and has the potential to lead to fraud. To overcome this challenge, this research focuses on developing a digit detection system for PDAM water meters using the YOLOv5 deep learning model. Using a dataset covering various lighting conditions and viewing angles, the model is trained to recognize and classify the digits on water meters. Initial results show that this model can produce accurate predictions, with high levels of precision and recall. However, more testing and evaluation are needed to ensure that these systems can perform well in real-world conditions.

Keywords: PDAM, YOLO, Python, Augmentasi, Deep Learning, Automasi

ABSTRAK

Penggunaan meteran air PDAM (Perusahaan Daerah Air Minum) telah menjadi standar untuk mengukur konsumsi air oleh pelanggan di Indonesia. Namun, proses pembacaan meteran air masih banyak dilakukan secara manual oleh petugas, yang dapat menimbulkan berbagai masalah. Misalnya, kesalahan pembacaan dapat terjadi karena faktor manusia atau kondisi lingkungan, seperti pencahayaan yang buruk atau meteran air yang kotor. Selain itu, proses ini membutuhkan banyak waktu dan tenaga, serta berpotensi menimbulkan penipuan. Untuk mengatasi tantangan ini, penelitian ini berfokus pada pengembangan sistem deteksi digit pada meteran air PDAM menggunakan model deep learning YOLOv5. Dengan menggunakan dataset yang mencakup berbagai kondisi pencahayaan dan sudut pandang, model ini dilatih untuk mengenali dan mengklasifikasikan digit pada meteran air. Hasil awal menunjukkan bahwa model ini mampu menghasilkan prediksi yang akurat, dengan tingkat precision dan recall yang tinggi. Namun, lebih banyak pengujian dan evaluasi diperlukan untuk memastikan bahwa sistem ini dapat bekerja dengan baik dalam kondisi dunia nyata.

Kata kunci: PDAM, YOLO, Python, Augmentasi, Deep Learning, Automasi

1. PENDAHULUAN

Penggunaan meteran air PDAM (Perusahaan Daerah Air Minum) telah menjadi standar untuk mengukur konsumsi air oleh pelanggan di Indonesia. Namun, proses pembacaan meteran air masih banyak dilakukan secara manual oleh petugas, yang dapat menimbulkan berbagai masalah. Misalnya, kesalahan pembacaan dapat terjadi karena

faktor manusia atau kondisi lingkungan, seperti pencahayaan yang buruk atau meteran air yang kotor [1]. Selain itu, proses ini membutuhkan banyak waktu dan tenaga, serta berpotensi menimbulkan penipuan [2]. Meteran air PDAM (Perusahaan Daerah Air Minum) adalah alat yang digunakan untuk mengukur konsumsi air oleh pelanggan. Alat ini sangat penting dalam operasional perusahaan air minum atau PAM. Hasil pencatatan dari meter air akan menentukan tagihan rekening pelanggan, sehingga perusahaan bisa membiayai belanja pegawai, mengembalikan biaya investasi, pajak, dan keuntungan. Meteran air ini memiliki beberapa manfaat, seperti memastikan kepada pelanggan mengenai biaya yang dikenakan sesuai dengan proporsi air yang dikonsumsi, sistem untuk menunjukkan proses akuntabilitas, merekam setiap penggunaan air sehingga bersifat adil, mampu mendorong pelanggan untuk melakukan penghematan air terutama jika dibandingkan tingkat tarif, sebagai sistem utilitas yang mampu memantau volume air yang keluar, serta membantu mendeteksi kebocoran dan pipa yang patah dalam distribusi air bersih.

Dalam beberapa tahun terakhir, teknologi kecerdasan buatan, khususnya Deep Learning, telah berkembang pesat dan menunjukkan potensi besar dalam berbagai aplikasi, termasuk pengenalan pola dan deteksi objek [3]. Salah satu model Deep Learning yang menjanjikan adalah YOLOv5 (You Only Look Once version 5), yang telah terbukti efektif dalam mendeteksi dan mengenali objek dalam gambar dengan akurasi yang tinggi [4]. YOLO (You Only Look Once) adalah pendekatan baru dalam deteksi objek yang pertama kali diperkenalkan oleh Joseph Redmon [5]. Berbeda dengan metode deteksi objek sebelumnya yang menggunakan classifier, YOLO memandang deteksi objek sebagai masalah regresi terhadap bounding box yang terpisah secara spasial dan probabilitas kelas yang terkait [5]. Sebuah jaringan neural tunggal memprediksi bounding box dan probabilitas kelas langsung dari gambar penuh dalam satu evaluasi. Karena seluruh pipeline deteksi adalah satu jaringan, ini dapat dioptimalkan secara end-to-end langsung pada kinerja deteksi. Dibandingkan dengan sistem deteksi state-of-the-art, YOLO membuat lebih banyak kesalahan lokalisasi tetapi jauh lebih kecil kemungkinannya untuk memprediksi false positives di mana tidak ada objek. Akhirnya, YOLO belajar representasi objek yang sangat umum. Ini mengungguli metode deteksi lainnya, termasuk DPM dan R-CNN, ketika menggeneralisasi dari gambar alami ke domain lain seperti karya seni [5].

Adapun pencegahan terhadap Tindakan penipuan dengan sistem pembacaan otomatis, potensi penipuan dalam pembacaan meteran air dapat diminimalkan. Sistem ini dapat membantu PDAM dalam memastikan bahwa data yang diperoleh adalah akurat dan valid melalui pemantauan Real-Time. Sistem ini juga dapat memberikan pemantauan real-time terhadap penggunaan air oleh pelanggan. Hal ini sangat berguna untuk mendeteksi kebocoran atau penggunaan air yang tidak normal. Sehingga pengolahan data dapat dilakukan secara otomatis, data yang diperoleh dari sistem ini dapat langsung diolah dan digunakan untuk penagihan, analisis konsumsi, dan keperluan lainnya. Hal ini dapat mempercepat proses penagihan dan meningkatkan layanan kepada pelanggan.

2. METODE

Metode penelitian ini dirancang untuk mengembangkan sistem deteksi digit pada meteran air PDAM menggunakan model Deep Learning YOLOv5. Proses ini melibatkan beberapa tahapan penting, mulai dari pengumpulan data, pra-pemrosesan data, pelabelan data, pelatihan model, evaluasi model, implementasi model, hingga uji coba dan evaluasi sistem. Setiap tahapan ini memainkan peran penting dalam menjamin keberhasilan penelitian.

2.1. Pengumpulan Data

Langkah pertama dalam penelitian ini adalah pengumpulan data. Data yang dibutuhkan adalah gambar meteran air PDAM yang berisi digit pembacaan. Gambar-gambar ini dapat diperoleh dari berbagai sumber, seperti langsung dari PDAM atau dari internet. Dalam penelitian ini Data yang dikumpulkan berupa data angka yang terdapat pada meteran air PDAM dengan dibagi menjadi 10 bagian yaitu untuk mengidentifikasi angka 0 hingga 9 pada meteran air PDAM.

Tabel 1. Jumlah Dataset Total, Dataset Train dan Dataset Test

Total Data	Train Data	Test Data
2526	2274	252

2.2. Pra-Pemrosesan Data

Pra-pemrosesan data adalah tahap penting dalam pipeline pengolahan gambar dan merupakan langkah awal dalam banyak aplikasi pengenalan pola dan pembelajaran mesin. Dalam konteks deteksi objek menggunakan YOLOv5, pra-pemrosesan data

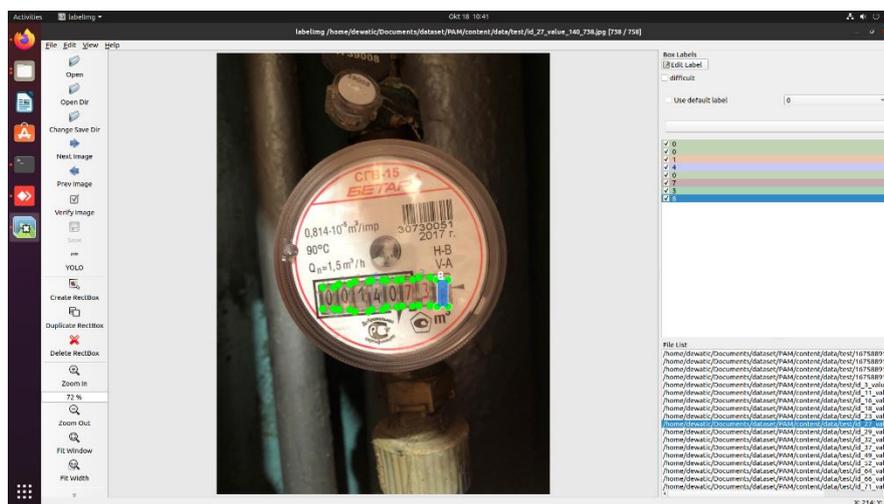
melibatkan beberapa langkah [6]. Augmentasi data adalah teknik yang digunakan untuk meningkatkan jumlah dan variasi data pelatihan dalam pembelajaran mesin. Teknik ini melibatkan pembuatan variasi dari gambar asli melalui transformasi seperti rotasi, translasi, pembalikan. Dalam konteks deteksi objek menggunakan YOLOv5, pra-pemrosesan data melibatkan beberapa langkah seperti pengubahan ukuran gambar, normalisasi, dan augmentasi data [7].

Tabel 2. Jumlah Dataset setelah diberikan augmentasi

Total Data	Train Data	Test Data
7578	6820	758

2.3. Pelabelan Data

Pelabelan data adalah proses penting dalam pembelajaran mesin dan deteksi objek. Dalam konteks deteksi objek menggunakan YOLOv5, setelah pra-pemrosesan data, gambar meteran air perlu dilabeli dengan bounding box di sekitar setiap digit dan label kelas yang sesuai. Pelabelan data dapat dilakukan secara manual atau dengan menggunakan alat pelabelan otomatis. Salah satu alat pelabelan yang populer adalah LabelImg, sebuah aplikasi grafis open source untuk anotasi gambar. Dengan LabelImg, Anda dapat dengan mudah menarik bounding box di sekitar objek yang ingin Anda deteksi dan memberikan label kelas yang sesuai [8].



Gambar 2. Proses pemberian label pada gambar menggunakan labeling

Proses pelabelan ini sangat penting karena ini adalah cara model belajar untuk mengenali objek yang berbeda. Dengan kata lain, model akan belajar untuk mengenali dan mendeteksi objek berdasarkan label yang Anda berikan selama proses pelabelan.

2.4. Pelatihan Model

Pelatihan model adalah tahap penting dalam pembelajaran mesin dan deteksi objek. Dalam konteks deteksi objek menggunakan YOLOv5, setelah data telah dilabeli, langkah selanjutnya adalah pelatihan model. Pelatihan model melibatkan pengaturan parameter model, seperti learning rate, jumlah epoch, dan ukuran batch. Selama proses pelatihan, model belajar untuk mengenali dan mendeteksi objek berdasarkan label yang diberikan selama proses pelabelan.

Tabel 3. Tabel hyper parameter yang digunakan untuk melakukan training pada model

Parameters	Nilai	Parameters	Nilai	Parameters	Nilai
lr0	0.01	iou_t	0.2	fliplr	0.0
lrf	0.01	anchor_t	4.0	mosaic	1.0
momentum	0.937	fl_gamma	0.0	mixup	0.0
weight_decay	0.0005	hsv_h	0.7	copy_paste	0.0
warmup_epochs	3.0	hsv_s	0.4	epochs	400
warmup_momentum	0.8	hsv_v	0.0	batch_size	128
warmup_bias_lr	0.1	degrees	0.0	imgsz	480
box	0.05	translate	0.1	device	0,1
cls	0.5	scale	0.5	optimizer	SGD
cls_pw	1.0	shear	0.0	workers	8
obj	1.0	perspective	0.0	cos_lr	false
obj_pw	1.0	flipud	0.0	cache	ram

Penggunaan GPU (*Graphics Processing Unit*) dapat mempercepat proses pelatihan model deep learning secara signifikan. Menurut penelitian yang dilakukan oleh IPB University, penggunaan GPU dalam model deep learning dapat mempercepat proses pelatihan hingga 100 kali lipat. Selain itu, proses hyperparameter tuning juga sangat terbantu dengan adanya GPU karena dapat mempersingkat proses hingga 55 kali lebih cepat [10].

Namun, perlu diingat bahwa efisiensi penggunaan GPU sangat bergantung pada spesifikasi dan kapabilitas GPU itu sendiri. GPU dengan spesifikasi yang lebih tinggi biasanya akan memberikan kinerja yang lebih baik dalam pelatihan model deep learning..

2.5. Evaluasi Model

Evaluasi model adalah tahap penting dalam pembelajaran mesin dan deteksi objek. Dalam konteks deteksi objek menggunakan YOLOv5, setelah model dilatih, perlu dilakukan evaluasi untuk menentukan seberapa baik model bekerja. Metrik evaluasi yang umum digunakan termasuk precision, recall, dan F1-score. Untuk

menghitung metrik-metrik ini dapat menggunakan confusion matrix². Confusion matrix adalah matriks 2x2 yang merepresentasikan hasil klasifikasi biner pada suatu dataset [11]. Adapun penjelasan tentang bagaimana menghitung nilai-nilai dalam confusion matrix menggunakan nilai TP (True Positives), TN (True Negatives), FP (False Positives) dan FN (False Negatives) Dengan nilai-nilai ini, kita dapat menghitung metrik evaluasi berupa Precision, Recall, F1-Score dan mAP.

3. HASIL DAN PEMBAHASAN

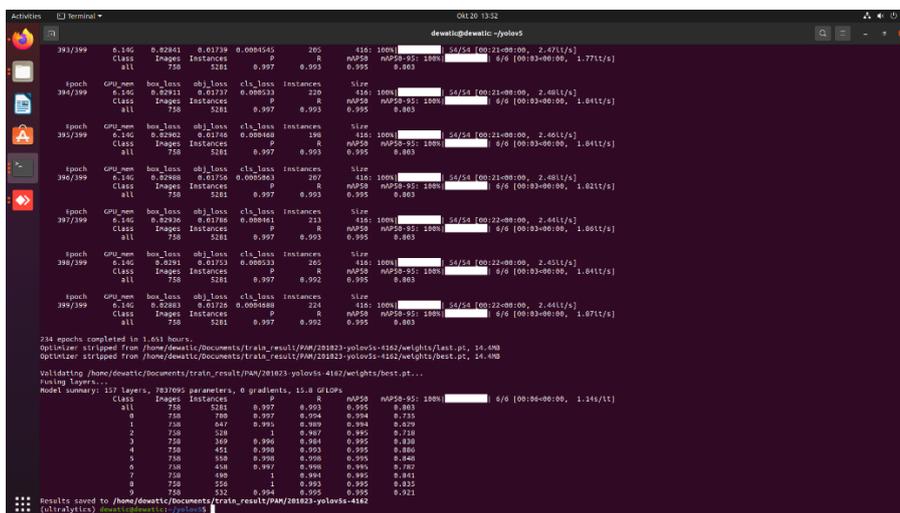
Uji coba dan evaluasi sistem adalah tahap penting dalam pengembangan sistem deteksi digit pada meteran air PDAM. Setelah sistem selesai dikembangkan, perlu dilakukan uji coba dan evaluasi sistem untuk memastikan bahwa sistem bekerja dengan baik dalam kondisi nyata. Uji coba dapat dilakukan dengan menggunakan data yang berbeda dari data pelatihan atau data dari situasi dunia nyata. Tujuan dari uji coba ini adalah untuk memastikan bahwa sistem dapat bekerja dengan baik dalam berbagai kondisi dan dapat menangani variasi dalam data [1].

Evaluasi sistem melibatkan penilaian kinerja sistem berdasarkan metrik tertentu. Metrik ini dapat mencakup akurasi deteksi, kecepatan deteksi, dan lainnya. Evaluasi ini penting untuk mengetahui sejauh mana sistem memenuhi tujuan dan persyaratan yang telah ditetapkan. Selain itu, evaluasi juga dapat melibatkan pengujian sistem dalam kondisi operasional sebenarnya. Misalnya, sistem dapat diuji dalam lingkungan PDAM untuk melihat bagaimana kinerjanya dalam mendeteksi dan membaca meteran air secara otomatis.

3.1. Akurasi Mode

Akurasi model dalam konteks deep learning seringkali diukur menggunakan metrik seperti Mean Average Precision (mAP) dan F1-Score. Dalam penelitian ini model YOLOv5 telah menunjukkan kinerja yang mengesankan, dengan mencapai mAP(50) 99.5% dan mAP(50-95) 80.3% dalam mendeteksi digit meteran PDAM. Namun, perlu diingat bahwa akurasi model sangat bergantung pada kualitas dan variasi data pelatihan yang digunakan. Oleh karena itu, penting untuk memastikan bahwa data pelatihan mencakup berbagai kondisi pencahayaan, sudut pandang, dan variasi lainnya yang mungkin ditemui oleh sistem dalam penggunaan sehari-hari. Selain itu, pelabelan data pelatihan harus sangat akurat dan konsisten untuk mencapai hasil terbaik[6].

mAP (Mean Average Precision) adalah metrik yang digunakan untuk mengukur kualitas model deteksi objek. mAP menghitung rata-rata presisi pada semua kelas objek. mAP@50: Ini berarti bahwa Intersection over Union (IoU) antara bounding box yang diprediksi dan bounding box sebenarnya harus lebih besar dari 50 agar dianggap sebagai deteksi yang benar. Dengan kata lain, jika overlap antara bounding box yang diprediksi dan bounding box sebenarnya lebih dari 50%, maka itu dianggap sebagai deteksi yang benar, sedangkan mAP@[50:95]: Ini adalah rata-rata mAP di berbagai ambang batas IoU, mulai dari 50 hingga 95, dengan langkah 5 (50, 55, 60, 65, 70, 75, 80, 85, 90, 95). Dengan kata lain, ini adalah rata-rata mAP di berbagai tingkat ketatnya persyaratan overlap antara bounding box yang diprediksi dan bounding box sebenarnya[6].



```
399/399 0.146 0.0281 0.0177 0.000545 265 116: 100% 5/5 [00:21:00.00, 2.4711/s]
Class Instances P R mAP50 mAP50-95: 100% 6/0 [00:03:00:00, 1.7711/s]
all 758 5281 0.997 0.993 0.995 0.803

epoch  CPU_mem  box_loss  obj_loss  cls_loss  Instances  Size
399/399 0.146 0.0281 0.0177 0.000545 267 116: 100% 5/5 [00:21:00.00, 2.4811/s]
Class Instances P R mAP50 mAP50-95: 100% 6/0 [00:03:00:00, 1.0811/s]
all 758 5281 0.997 0.993 0.995 0.803

epoch  CPU_mem  box_loss  obj_loss  cls_loss  Instances  Size
399/399 0.146 0.0282 0.0178 0.000548 198 116: 100% 5/5 [00:21:00.00, 2.4611/s]
Class Instances P R mAP50 mAP50-95: 100% 6/0 [00:03:00:00, 1.0811/s]
all 758 5281 0.997 0.993 0.995 0.803

epoch  CPU_mem  box_loss  obj_loss  cls_loss  Instances  Size
399/399 0.146 0.0280 0.0176 0.000583 267 116: 100% 5/5 [00:21:00.00, 2.4811/s]
Class Instances P R mAP50 mAP50-95: 100% 6/0 [00:03:00:00, 1.0211/s]
all 758 5281 0.997 0.993 0.995 0.803

epoch  CPU_mem  box_loss  obj_loss  cls_loss  Instances  Size
397/399 0.146 0.0286 0.0178 0.00061 273 116: 100% 5/5 [00:22:00.00, 2.4411/s]
Class Instances P R mAP50 mAP50-95: 100% 6/0 [00:03:00:00, 1.0611/s]
all 758 5281 0.997 0.993 0.995 0.803

epoch  CPU_mem  box_loss  obj_loss  cls_loss  Instances  Size
398/399 0.146 0.0291 0.0173 0.000533 265 116: 100% 5/5 [00:22:00.00, 2.4511/s]
Class Instances P R mAP50 mAP50-95: 100% 6/0 [00:03:00:00, 1.0811/s]
all 758 5281 0.997 0.992 0.995 0.803

epoch  CPU_mem  box_loss  obj_loss  cls_loss  Instances  Size
399/399 0.146 0.0283 0.0175 0.000688 224 116: 100% 5/5 [00:22:00.00, 2.4411/s]
Class Instances P R mAP50 mAP50-95: 100% 6/0 [00:03:00:00, 1.0711/s]
all 758 5281 0.997 0.992 0.995 0.803

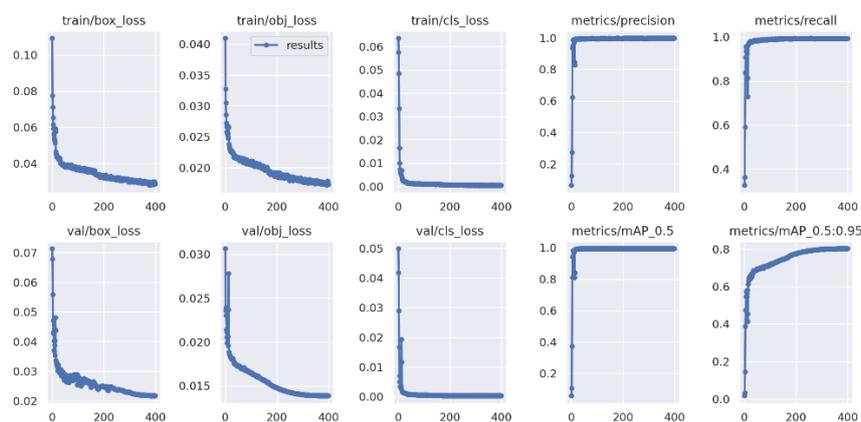
214 epochs completed in 1.061 hours
Optimizer stripped from /home/dewatic/Documents/train_result/PAN/2018023-yolov5s-4162/weights/last.pt, 16.4MB
Optimizer stripped from /home/dewatic/Documents/train_result/PAN/2018023-yolov5s-4162/weights/best.pt, 16.4MB

Validating /home/dewatic/Documents/train_result/PAN/2018023-yolov5s-4162/weights/best.pt...
Fusing layers...
Model summary: 127 layers, 7037095 parameters, 0 gradients, 15.8 GFLOPs
Class Instances P R mAP50 mAP50-95: 100% 6/0 [00:06:00:00, 1.1641/s]
all 758 5281 0.997 0.993 0.995 0.803
0 758 780 0.997 0.994 0.994 0.728
1 758 647 0.995 0.989 0.994 0.629
2 758 589 0.987 0.985 0.994 0.728
3 758 389 0.990 0.984 0.995 0.830
4 758 411 0.990 0.990 0.995 0.860
5 758 360 0.990 0.990 0.995 0.860
6 758 458 0.997 0.996 0.995 0.787
7 758 480 1 0.991 0.995 0.861
8 758 356 1 0.993 0.995 0.835
9 758 532 0.994 0.995 0.995 0.921

Results saved to /home/dewatic/Documents/train_result/PAN/2018023-yolov5s-4162
Ctrl+C to quit
```

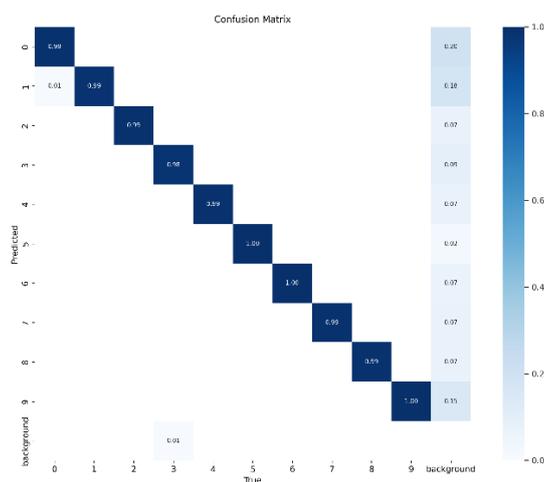
Gambar 3. Output hasil setelah selesai proses training model pada terminal

Adapun F1 Score adalah metrik yang digunakan untuk mengukur kualitas model dalam deteksi objek. F1 Score adalah rata-rata harmonik dari Precision (P) dan Recall dari sebuah classifier, dengan $\alpha=1$. Ini berarti bahwa kedua metrik memiliki kepentingan yang sama[13]. Dalam konteks YOLOv5, ada sebuah grafik F1 Curve yang secara otomatis dihasilkan setelah pelatihan. Grafik ini menunjukkan hubungan antara F1 Score dengan tingkat kepercayaan (confidence level). Nilai confidence yang mengoptimalkan precision dan recall adalah 0.503, yang sesuai dengan nilai F1 maksimum (0.90)[13].



Gambar 4. Grafik hasil training pada model pendeteksian meteran pdam

Dalam penelitian ini juga dapat melihat bagaimana hasil model berkerja pada setiap kelas menggunakan confusion matrix. Confusion Matrix adalah visualisasi yang menunjukkan bagaimana model Anda bekerja pada kelas-kelas yang telah dilatih. Dalam konteks YOLOv5, Confusion Matrix dapat dibuat dengan menggunakan paket Python open source bernama supervision. Confusion Matrix menunjukkan kinerja model dalam memprediksi setiap kelas. Setiap baris matriks mewakili instance dari kelas aktual, sementara setiap kolom mewakili instance dari kelas yang diprediksi. Nilai diagonal matriks menunjukkan jumlah prediksi yang benar (true positives), sementara elemen lainnya menunjukkan kesalahan (false positives dan false negatives)[14].



Gambar 5. Confusion matrix model training

3.2. Pengujian Model

Uji coba dan evaluasi model adalah tahap penting dalam pengembangan sistem deteksi digit pada meteran air PDAM menggunakan model deep learning YOLOv5.

Tahap ini melibatkan pengujian model yang telah dilatih terhadap data yang belum pernah dilihat sebelumnya untuk mengevaluasi sejauh mana model dapat membuat prediksi yang akurat.

Pada tahap ini dapat dilihat pengukuran beberapa metrik kinerja seperti Precision, Recall, dan mAP (Mean Average Precision) pada Akurasi Model. Precision mengukur sejauh mana model dapat menghindari false positive, sementara Recall mengukur sejauh mana model dapat menghindari false negative. mAP adalah rata-rata dari Precision di semua kelas objek, dan sering digunakan sebagai metrik utama untuk mengevaluasi kualitas model deteksi objek. Selain itu, kita juga dapat menggunakan kurva Precision-Recall untuk memvisualisasikan hubungan antara Precision dan Recall untuk berbagai ambang batas keputusan. Area di bawah kurva Precision-Recall (AUC of PR curve) sering digunakan sebagai metrik untuk mengevaluasi kualitas model deteksi objek.



Gambar 6. Hasil pendeteksian menggunakan model training pada foto baru

```
blob = cv2.dnn.blobFromImage(img, scalefactor= 1/255, size=(imgsz, imgsz), mean=[0,0,0], swapRB= True, crop= False)
net.setInput(blob)
detections = net.forward(net.getUnconnectedOutLayersNames())
```

Gambar 7. Salah satu bagian code yang berfungsi untuk melakukan pendeteksian lalu hasil dari pendeteksia tersebut disimpan dalam variabel “detections”

4. KESIMPULAN

Berdasarkan pembahasan yang telah dilakukan, dapat disimpulkan bahwa pengembangan sistem deteksi digit pada meteran air PDAM menggunakan model deep learning YOLOv5 memiliki potensi yang signifikan. Model ini menawarkan kemampuan membaca dengan cepat dan akurasi yang baik. Namun, perlu diingat bahwa kinerja model sangat bergantung pada kualitas dan variasi data pelatihan yang digunakan. Oleh karena itu, penting untuk memastikan bahwa data pelatihan mencakup berbagai kondisi pencahayaan, sudut pandang, dan variasi lainnya yang mungkin ditemui oleh sistem dalam penggunaan sehari-hari.

Selain itu, evaluasi model yang komprehensif adalah langkah penting sebelum menerapkannya secara luas. Metrik seperti Precision, Recall, dan mAP (Mean Average Precision) dapat digunakan untuk mengevaluasi kualitas model. Kurva Precision-Recall juga dapat digunakan untuk memvisualisasikan hubungan antara Precision dan Recall untuk berbagai ambang batas keputusan. Secara keseluruhan, meskipun ada beberapa tantangan yang perlu diatasi, penggunaan YOLOv5 untuk deteksi digit pada meteran air PDAM tampaknya menjadi pendekatan yang menjanjikan dan layak untuk diteliti lebih lanjut.

5. DAFTAR PUSTAKA

- [1] Hermawan, Indra. "Rancang Bangun Sistem Pendeteksi dan Pengenalan Angka Pada Meteran Air PDAM Menggunakan Metode Template Matching Correlation." *Jurnal Teknologi Terpadu* 1.2 (2015).
- [2] Juwiantho, Hans, Esther Irawati Setiawan, and Joan Santoso. "Image Sentiment Analysis Menggunakan Deep Convolutional Neural Network Dengan Fitur Konsep." *The 12th National Conference on Information Technology and Electrical Engineering*. 2019.
- [3] Widiyari, Cyntia, and Laxsmana Anugrah Zulkarnain. "Rancang Bangun Sistem Monitoring Penggunaan Air PDAM Berbasis IoT." *Jurnal Komputer Terapan* 7.2 (2021): 153-162.
- [4] GARDAMUKTI, M. GALANG. *Metode You Only Look Once (YOLO) untuk Sistem Pengenalan Rambu Lalu Lintas*. Diss. Universitas Gadjah Mada, 2021.
- [5] Redmon, Joseph, et al. "You only look once: Unified, real-time object detection."

- Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.
- [6] Aini, Q., et al. "Deteksi dan Pengenalan Objek Dengan Model Machine Learning: Model Yolo. CESS (Journal of Computer Engineering, System and Science), 6 (2), 192." (2021).
- [7] Ganda, Lukas Hansel, and Hendra Bunyamin. "Penggunaan Augmentasi Data pada Klasifikasi Jenis Kanker Payudara dengan Model Resnet-34." *Jurnal STRATEGI-Jurnal Maranatha* 3.1 (2021): 187-193.
- [8] Lin, Moule, Changxi Chen, and Chunchi Lai. "Object detection algorithm based AdaBoost residual correction Fast R-CNN on network." *Proceedings of the 2019 3rd International Conference on Deep Learning Technologies*. 2019.
- [9] Lusiana, Lusiana, Ari Wibowo, and Tika Kartika Dewi. "Implementasi Algoritma Deep Learning You Only Look Once (YOLOv5) Untuk Deteksi Buah Segar Dan Busuk." *Paspalum: Jurnal Ilmiah Pertanian* 11.1 (2023): 123-130.
- [10] Darmawan, Refianto Damai. *Optimasi Deep Learning untuk Prediksi Drug-Target Interaction dengan Graphic Processing Unit*. Diss. IPB University.
- [11] Horvat, Marko, and Gordan Gledec. "A comparative study of YOLOv5 models performance for image localization and classification." *Central European Conference on Information and Intelligent Systems*. Faculty of Organization and Informatics Varazdin, 2022.
- [12] Tu, Xiaoguang, et al. "An improved YOLOv5 for object detection in visible and thermal infrared images based on contrastive learning." *Frontiers in Physics* 11 (2023): 354.
- [13] Aldughayfiq, Bader, et al. "YOLOv5-FPN: A Robust Framework for Multi-Sized Cell Counting in Fluorescence Images." *Diagnostics* 13.13 (2023): 2280.
- [14] Oraño, Jannie Fleur V., et al. "Automated Coral Lifeform Classification Using YOLOv5: A Deep Learning Approach." *Novel & Intelligent Digital Systems Conferences*. Cham: Springer Nature Switzerland, 2023.