

DOI: doi.org/10.21009/03.1301.FA06

OTOMASI PENGUKURAN KECEPATAN PADA EKSPERIMEN TETES MINYAK MILIKAN MENGGUNAKAN ALGORITMA YOLOv5

Siska Miati Jati Ningsih^{1a)*}, Hadi Nasbey^{2a)}, Haris Suhendar^{2a)}^{1a}Program Studi Fisika, FMIPA Universitas Negeri Jakarta, Jl. Rawamangun Muka, Jakarta Timur 13220, Indonesia.^{2a}FMIPA Universitas Negeri Jakarta, Jl. Rawamangun Muka, Jakarta Timur 13220, Indonesia.

*Penulis korespondensi: siskamiatijn@gmail.com

ABSTRAK

Eksperimen tetes minyak Milikan berperan penting dalam menentukan nilai dasar muatan elektron melalui perhitungan kecepatan tetesan minyak untuk mengukur gaya elektrostatis. Namun, analisis manual proses ini memakan waktu. Penelitian ini mengusulkan penggunaan algoritma YOLOv5 untuk otomatisasi pengukuran kecepatan tetesan minyak guna meningkatkan efisiensi dan akurasi. Algoritma YOLO merupakan pendekatan deteksi objek menggunakan teknik computer vision. Metode yang digunakan meliputi perekaman video tetes minyak, anotasi data dengan Roboflow, pelatihan model YOLOv5 dengan dataset yang diaugmentasi 10 kali, dan evaluasi menggunakan metrik *mean Average Precision* (mAP). Hasil penelitian menunjukkan nilai mAP sebesar 0.355 pada pelatihan, *precision* tertinggi mendekati 1.0 saat *recall* mendekati 0. Pengukuran kecepatan menggunakan YOLOv5 dibandingkan dengan metode manual menghasilkan kesalahan relatif sebesar 3.79% dan selisih waktu rata-rata 0.1274 detik. Meskipun nilai mAP tidak terlalu tinggi, model mampu mendeteksi tetesan minyak secara konsisten. Kinerja model sangat bergantung pada jenis jaringan, jumlah dataset, dan bentuk dataset. Akurasi perhitungan kecepatan cukup baik jika dibandingkan dengan data acuan dengan tingkat kesalahan dibawah 5%. Secara keseluruhan, algoritma juga menyederhanakan proses untuk melakukan percobaan.

Kata-kata kunci: *Computer Vision*, Eksperimen, Kecepatan, Tetes Minyak Milikan, YOLOv5

ABSTRACT

Milikan's oil drop experiment was instrumental in determining the fundamental value of electron charge through calculating the velocity of the oil drop to measure the electrostatic force. However, manual analysis of this process is time-consuming. This research proposes the use of the YOLOv5 algorithm for the automation of oil droplet velocity measurement to improve efficiency and accuracy. The YOLO algorithm is an object detection approach using computer vision techniques. The methods used include video recording of oil drops, data annotation with Roboflow, YOLOv5 model training with a dataset augmented 10 times, and evaluation using the mean Average Precision (mAP) metric. The results showed a mAP value of 0.355 in training, the highest precision was close to 1.0 when recall was close to 0. Speed measurement using YOLOv5 compared to the manual method resulted in a relative error of 3.79% and an average time difference of 0.1274 seconds. Although the mAP value is not very high, the model is able to detect oil droplets consistently. The performance of the model is highly dependent on the type of network, the number of datasets, and the shape of the datasets. The accuracy of the velocity calculation is quite good when compared to the reference data with an error rate below 5%. Overall, the algorithm also simplifies the process of conducting experiments.

Keywords: *Computer Vision, Experimentation, Speed, Milikan Oil Drops, YOLOv5*

PENDAHULUAN

Pengukuran dalam fisika merupakan proses penentuan nilai numerik dari suatu sifat fisik menggunakan alat ukur yang sesuai [1]. Ketepatan pengukuran sangat penting untuk mencegah

kesalahan dan memastikan keakuratan temuan dalam penelitian [2]. Pemilihan alat ukur yang tepat dapat menjamin hasil yang akurat [3]. Instrumen modern dirancang dengan teknologi canggih seperti sensor, transduser, dan pemrograman komputer untuk meningkatkan akurasi pengukuran. Saat ini, instrumen pengukuran didesain dengan menggunakan alat canggih seperti sensor, transduser, dan pemrograman komputer untuk meningkatkan akurasi pengukuran. Instrumen ilmiah yang tepat dapat memfasilitasi kemampuan para peneliti untuk mengukur beragam parameter fisik secara efektif. Salah satu contohnya adalah penggunaan perangkat lunak Adobe Flash CS5.5 untuk visualisasi eksperimen tetes minyak Milikan [4].

Eksperimen tetes minyak Milikan pertama kali dilakukan oleh Robert A. Millikan pada tahun 1909, merupakan upaya untuk menentukan muatan elektron [5]. Millikan menggunakan hukum Stokes dan gaya elektrostatis untuk menghitung massa dan muatan tetes minyak [6]. Hasil percobaan tersebut menunjukkan bahwa muatan elektron bersifat diskrit, yaitu gaya ke bawah pada tetes minyak milikan akan terhambat oleh gaya stokes [7]. Melalui eksperimennya, Millikan berhasil menentukan muatan listrik dasar yang dimiliki oleh tetes-tetes minyak tersebut dengan cara menemukan titik di mana gaya listrik mampu menyeimbangkan gaya gravitasi pada tetes minyak [8]. Pengukuran muatan elektron pada tetes minyak milikan memberikan pemahaman yang lebih baik tentang sifat-sifat dasar partikel subatomik [9].

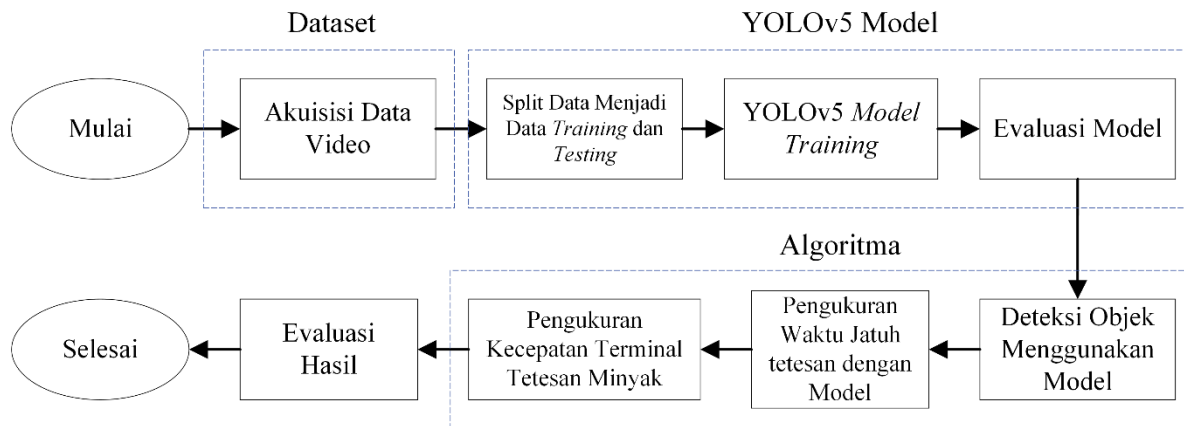
Metode tradisional untuk mengukur tetes minyak Milikan melibatkan pengamatan manual menggunakan mikroskop terhadap gerakan tetes minyak di antara dua pelat bermuatan. Meskipun metode ini memberikan hasil yang akurat pada masanya, namun terdapat beberapa keterbatasan yang mungkin terjadi [10]. Salah satu keterbatasan metode tradisional adalah ketergantungan pada pengamatan manual yang membutuhkan tingkat ketelitian yang tinggi. Proses ini rentan terhadap kesalahan manusia, baik dalam mengukur kecepatan tetes minyak maupun dalam merekam data secara konsisten [11]. Waktu yang diperlukan untuk melakukan pengukuran secara manual juga bisa menjadi faktor pembatas, terutama jika banyak sampel yang harus diukur. Oleh karena itu, diperlukan metode yang lebih efisien dan akurat.

Teknik computer vision menawarkan solusi identifikasi objek dalam gambar atau video digital dan penghitungan pergerakan benda secara otomatis [12]. Kita dapat mengetahui durasi turunnya suatu objek dengan metode deteksi objek. Penting untuk menggunakan metode yang tepat untuk mendeteksi objek untuk memastikan perhitungan pergerakan tetes minyak yang akurat [13]. Teknik ini dapat mengurangi kesalahan manusia dan meningkatkan efisiensi pengukuran [14]. Salah satu algoritma deteksi objek yang populer adalah You Only Look Once (YOLO), algoritma ini telah menjadi arah penelitian yang menarik bagi para ilmuwan dan peneliti di berbagai bidang [15]. Aspek menarik dalam penggunaan deteksi objek YOLO adalah penerapannya dalam konteks pengukuran [16]. Penelitian yang mencakup penggunaan deteksi objek YOLO untuk pengukuran adalah karya yang diterbitkan oleh Aldughayfiq et al. (2023) dalam *Journal Diagnostics* [17]. Dalam penelitiannya, mengadaptasi YOLO versi 5 (YOLOv5) untuk mendeteksi dan menghitung sel dalam mikroskop fluoresensi yang memiliki aplikasi penting dalam penelitian biomedis untuk menganalisis dinamika seluler dan mempelajari perkembangan penyakit. Algoritma ini menggunakan pendekatan *Convolutional Neural Network* (CNN) yang memungkinkan identifikasi objek dalam satu tahapan pemrosesan [18].

Penggunaan YOLOv5 dalam eksperimen tetes minyak Milikan diharapkan dapat mengotomasi proses pengukuran kecepatan, sehingga mengurangi keterlibatan manusia dan potensi kesalahan subjektif. Algoritma ini dapat digunakan untuk melacak posisi tetes minyak dari frame ke frame dalam rekaman video, menghitung kecepatan pergerakannya dan menentukan kecepatan tetesan berdasarkan data tersebut. Hasil dari YOLOv5 akan dibandingkan dengan pengamatan manual untuk mengevaluasi akurasi dan efisiensi metode ini. Penelitian ini bertujuan untuk mengembangkan metode pengukuran yang lebih mutakhir dan mengoptimalkan eksperimen tetes minyak Milikan dengan teknologi deteksi objek yang canggih.

METODE


Prosedur Penelitian



Dataset

Data yang terkumpul terdiri dari gambar dan video yang berisi objek tetesan minyak yang melibatkan penggunaan kamera ponsel untuk merekam pergerakan tetes minyak saat diamati melalui mikroskop. Pendekatan ini mempertimbangkan penggunaan kamera ponsel untuk merekam gerakan tetes minyak yang sedang diamati melalui mikroskop. Hal ini mengharuskan perencanaan yang cermat terkait pencahayaan yang tepat, pengaturan fokus, dan sudut pengambilan gambar agar memastikan kualitas dan akurasi dalam merekam pergerakan tetes minyak. Dua set data yang digunakan dalam penelitian ini adalah gambar yang digunakan untuk melatih model YOLOv5 dan video yang digunakan untuk deteksi objek dengan model YOLOv5 pada eksperimen tetes minyak milikan. Objek yang perlu dideteksi dalam penelitian ini adalah pergerakan jatuh dan naiknya tetesan yang telah ditentukan sebelumnya. Jenis minyak yang disemprotkan adalah minyak gliserin, dan variasi sumber tegangan (115,5V; 240,4V; 390,6V; 500,5V; dan 552,5V) yang dialirkan pada pelat digunakan sebagai variabel kontrol. Variasi data termasuk kondisi pencahayaan, ukuran objek, dan sudut pemotretan digunakan dalam kumpulan data gambar pada model YOLOv5. Sementara itu, video eksperimen tetes minyak milikan diambil menggunakan *setup* yang ditunjukkan dalam Gambar 1. dan direkam pada 60 *frame* per detik. Data dikumpulkan menggunakan peralatan seperti ponsel, *tripod*, seprangkat alat eksperimen tetes minyak milikan dan laptop.

Annotasi data dilakukan pada dataset gambar menggunakan model YOLOv5 yang bertujuan untuk menandai objek-objek yang menjadi fokus penelitian. Aplikasi yang digunakan untuk proses annotasi data pada model YOLOv5 adalah Roboflow. Melalui platform ini, pengguna dapat secara manual menandai gambar dengan membuat kotak pembatas untuk mengidentifikasi dan membatasi wilayah objek yang ingin diidentifikasi. Roboflow juga memfasilitasi pembangunan model deteksi dengan fitur-fitur seperti pelabelan, penyeragaman ukuran piksel, dan augmentasi data. Dataset dibagi dengan proporsi 80% data *train* dan 20% data *test*.



GAMBAR 1. Setup experiment

Pelatihan dan evaluasi Model YOLOv5

Pelatihan model YOLOv5 dimulai dengan membuat *ground truth*. *Ground truth* adalah informasi data citra pelatihan yang diperoleh dari hasil pelabelan bounding box tetesan minyak selama tahap pra-pemrosesan, yang kemudian disimpan sebagai data anotasi. Data ini mencakup label kelas dan koordinat posisi *ground truth box*. *Ground truth* digunakan sebagai referensi selama tahap pelatihan untuk menghitung nilai *error* antara hasil prediksi dan data sebenarnya. Tahap berikutnya mengonversi ukuran citra gambar asli yang memiliki resolusi 2048×2048 dengan penambahan *zero padding* pada citra gambar. Setelah *zero padding* ditambahkan maka ukuran citra gambar tersebut akan diperkecil menjadi 416×416 dengan tujuan untuk mempercepat proses pelatihan namun tidak terlalu mengurangi kualitas dari citra gambar tersebut.

Jaringan YOLOv5 melakukan deteksi objek dengan menerapkan prediksi pada tiga skala berbeda, yaitu 13×13 , 26×26 , dan 52×52 . Proses prediksi ini dilakukan menggunakan lapisan convolusi dengan kernel berukuran 1×1 , sehingga ukuran peta prediksi sama dengan ukuran peta fitur sebelumnya. Pada setiap skala, YOLOv5 menggunakan *anchor box* untuk melakukan prediksi terhadap kelas objek. Setiap grid dalam skala tertentu memiliki tiga *anchor box* dengan lebar dan tinggi yang berbeda-beda. *Bounding box* terbentuk sangat banyak, sedangkan dalam proses deteksi hanya akan didapat sebuah objek yang benar. Dengan input citra berukuran 416×416 , YOLOv5 menghasilkan prediksi sebanyak $((13 \times 13) + (26 \times 26) + (52 \times 52)) \times 2 = 7098$ *bounding box* [19]. Objek yang dideteksi hanya berjumlah beberapa tetesan minyak saja, sehingga YOLOv5 perlu mengurangi hasil deteksi yang semula berjumlah 7098 menjadi hanya beberapa *bounding box* sesuai dengan banyak nya tetesan minyak yang turun kebawah.

Kinerja model YOLOv5 dievaluasi menggunakan metrik evaluasi *Mean Average Precision* (mAP) pada data uji. mAP digunakan untuk mengevaluasi model YOLOv5 karena menggabungkan *precision* dan *recall*, mengatasi variasi ambang deteksi, mempertimbangkan tingkat kepercayaan (*Confidence*), dan melakukan evaluasi multi-kelas. Nilai mAP diperoleh dengan cara menghitung rata-rata dari nilai AP untuk semua kelas yang terdeteksi, seperti sensor dan tetesan minyak, setelah menerima nilai AP untuk masing-masing kelas tersebut. Persamaan berikut digunakan untuk menghitung mAP dari setiap nilai AP.

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

dengan N merupakan jumlah data AP.


Metode Pendeteksian dan Pelacakan Objek

Dalam tahapan ini terdiri dari dua proses yaitu deteksi tetesan minyak yang terlihat turun kebawah menggunakan YOLOv5 dan proses pelacakan menggunakan DeepSORT. YOLOv5 melakukan pemrosesan memecah gambar menjadi bagian *grid* kecil, dan setiap *grid* bertanggung jawab untuk mendeteksi objek di dalamnya. YOLOv5 menggunakan jaringan saraf tiruan untuk mengklasifikasikan dan menghitung kotak pembatas (*bounding box*) untuk objek bulir-bulir tetesan minyak yang terdeteksi.

YOLOv5 bertanggung jawab atas deteksi awal objek dan menyaring informasi yang relevan. DeepSORT memungkinkan pelacakan yang lebih canggih dan akurat terhadap objek yang bergerak di dalam video. DeepSORT menggunakan konsep ReID (*Re-identification*) untuk mengidentifikasi dan melacak objek dari satu bingkai ke bingkai berikutnya [20]. ReID adalah teknik yang membandingkan fitur visual dari objek untuk mengenali objek yang sama di berbagai bingkai. Keluaran dari tahap ini adalah sistem mampu mendeteksi dan menandai setiap tetesan minyak dengan *ID tracking*. Dalam DeepSORT diperlukan pengaturan konfigurasi seperti *max_dist*, *min_confidence*, *max_iou_distance* Indeks *IoU max_age*. Keluaran dari tahap ini adalah sistem mampu mendeteksi dan menandai setiap tetesan minyak yang terdeteksi dengan *ID tracking*.

Perhitungan waktu jatuh tetesan dan kecepatan terminal

Pengukuran waktu tempuh dimulai ketika tetesan bergerak dari batas atas menuju batas bawah, hal tersebut dapat dilakukan untuk mendapatkan besarnya waktu tempuh. Pengukuran waktu akan berhenti saat tetesan melewati batas-batas yang dituju, dapat dilihat pada Gambar 2.



GAMBAR 2. Setup batas atas dan bawah pada eksperimen

Kemudian, diamati dan dicatat dengan melakukan beberapa percobaan dengan nilai tegangan yang berbeda. Ketidakpastian dalam pengukuran waktu jatuh objek akan diukur dan dianalisis. Berdasarkan waktu jatuh yang diukur, nilai kecepatan terminal dapat dihitung menggunakan persamaan 2.

$$V = \frac{S}{t} \quad (2)$$

dengan t adalah waktu turun dalam satuan sekon dan S merupakan jarak tempuh jatuh tetesan minyak pada saat turun dalam satuan meter. Ketidakpastian pengukuran muatan elektron menggunakan YOLOv5 akan dihitung. Nilainya akan dibandingkan dengan ketidakpastian pengukuran muatan kecepatan menggunakan perhitungan manual. Oleh karena itu, kesalahan relatif kedua metode akan dihitung menggunakan persamaan 3.

$$\frac{|V_A - V_B|}{V_A} \times 100\% \quad (3)$$


Simbol V_A merujuk pada hasil perhitungan kecepatan menggunakan perhitungan manual dalam satuan m/s dan simbol V_B merujuk pada hasil perhitungan kecepatan menggunakan YOLOv5 dalam satuan m/s .

HASIL DAN PEMBAHASAN


Hasil Tahap Pelatihan

Pada penelitian ini, dataset yang didapatkan dilakukan proses augmentasi sebanyak 10 *layer* sehingga jumlah total dataset sebanyak 2403 gambar. *Batch size* yang digunakan adalah 128 dan *epoch* yang digunakan untuk tahap pelatihan sebanyak 629. Berikutnya akan dilakukan pengujian pada proses pelatihan dengan menggunakan data validasi agar dapat menghasilkan *trained weights* terbaik dari banyaknya *epoch* yang digunakan. mAP_{0,5} pada tahap pelatihan dapat dilihat pada Gambar 3. Nilai mAP pada titik 0,5 adalah 0,355 untuk semua kelas menunjukkan kinerja model secara keseluruhan.

Precision tertinggi mendekati 1.0 ketika *recall* mendekati 0, dan *precision* menurun seiring dengan meningkatnya *recall*. Kurva ini memberikan gambaran yang jelas mengenai kemampuan model untuk mempertahankan *precision* pada berbagai tingkat *recall*.

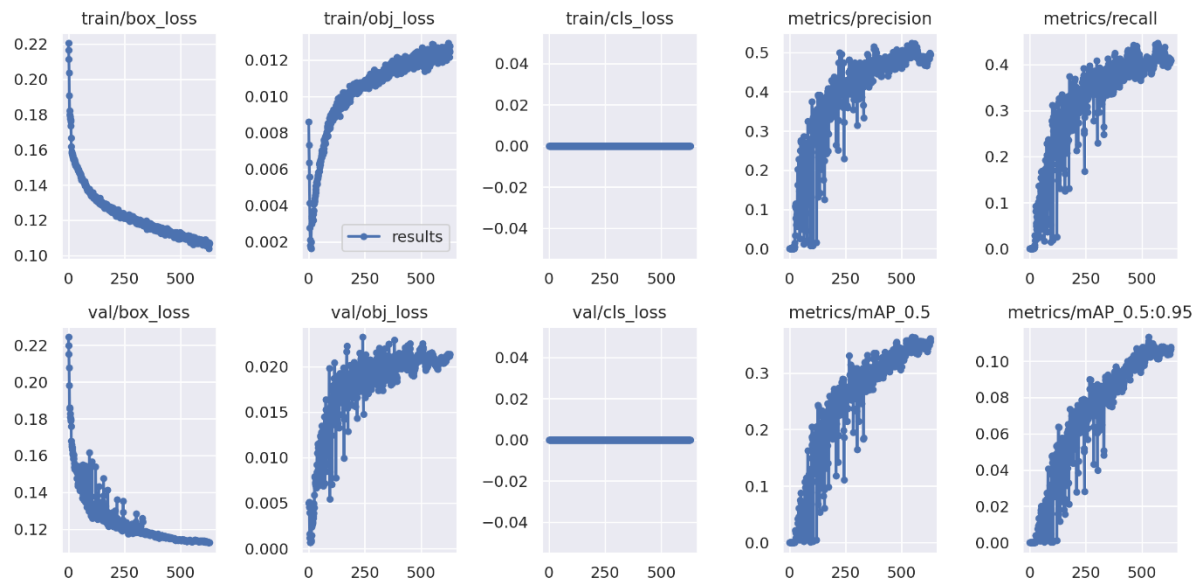


GAMBAR 3. Kurva hubungan antara *Precision* dengan *Recall*




GAMBAR 4. Kurva hubungan antara *Recall* dengan *Confidence*

Pada Gambar 4. Grafik menunjukkan bahwa *recall* menurun secara signifikan seiring dengan meningkatnya *confidence*. *Recall* tertinggi mencapai sekitar 0.52 pada *confidence* 0.000 yang berarti model lebih jarang mendeteksi tetesan minyak saat *confidence* meningkat. Hal ini dipengaruhi oleh Kualitas dataset yang kurang baik. Alat eksperimen yang digunakan terdapat pencahayaan yang hanya berpusat pada satu titik pada lensa objektif mikroskop, sehingga menyebabkan bias pada tetesan minyak dan membuat model sulit mengenalinya. Hal ini mengindikasikan adanya *trade-off* antara *recall* dan *confidence*. Sedangkan, jika dilihat berdasarkan kinierja untuk setiap proses pelatihan maupun pengujian di tiap *epoch*nya mengalami kemajuan dan perbaikan dimana hal ini dapat ditunjukkan pada Gambar 5.




GAMBAR 5. Hasil evaluasi data *training* untuk data *test* maupun data validitas

Nilai dari *harmonic mean* dari besaran untuk nilai *precision* dan *recall* dapat dilihat pada kurva nilai F1 Gambar 6. Besar F1-Score untuk semua kelas mencapai nilai tertinggi 0.46 pada *confidence* 0.085 menunjukkan bahwa pada tingkat *confidence* ini, model memiliki kinerja terbaik secara keseluruhan untuk semua kelas. Kurva ini mengindikasikan bahwa pada nilai *confidence* tersebut, model memiliki keseimbangan terbaik antara *precision* dan *recall* untuk kelas "Oil" di antara semua kelas yang diuji.



GAMBAR 6. Kurva nilai F1 terhadap *confidence*




GAMBAR 7. Kurva besar *precision* terhadap *confidence*


Pada Gambar 7 ini, grafik *Precision-Confidence* menunjukkan bahwa presisi meningkat seiring dengan peningkatan *confidence*. Namun, terdapat fluktuasi pada *confidence* di sekitar 0.6 hingga 0.8, dan presisi mencapai 1.0 pada *confidence* 0.616. Hal ini menunjukkan bahwa model lebih akurat dalam prediksi positifnya saat *confidence* meningkat.

Deteksi Tetesan Minyak

Proses deteksi dan *tracking* tetesan minyak terdiri dari beberapa tahapan yang dimulai dari objek deteksi hingga pelacakan. Proses deteksi dilakukan dengan membuat fungsi *loop* yang mendeteksi objek dalam setiap *frame* dan memproses hasil deteksi tersebut secara berkelanjutan. Keluaran dari tahap deteksi adalah penandaan setiap tetesan minyak yang melintas dengan *Bounding Box* dan pemberian ID pada setiap tetesan, seperti yang ditunjukkan pada Gambar 8. Sistem dianggap berhasil jika *Bounding Box* terus menerus mendeteksi tetesan pada setiap *frame* dan ID tetesan tetap sama sampai tetesan tersebut menghilang dari *frame*. Setelah deteksi objek diolah ke *format* DeepSORT, algoritma DeepSORT melakukan *tracking* dengan memberikan informasi lokasi dan ID setiap objek pada *frame* yang terlihat pada Gambar 9.



GAMBAR 8. Memperllihatkan sampel dari hasil deteksi dan pelacakan tetesan minyak.



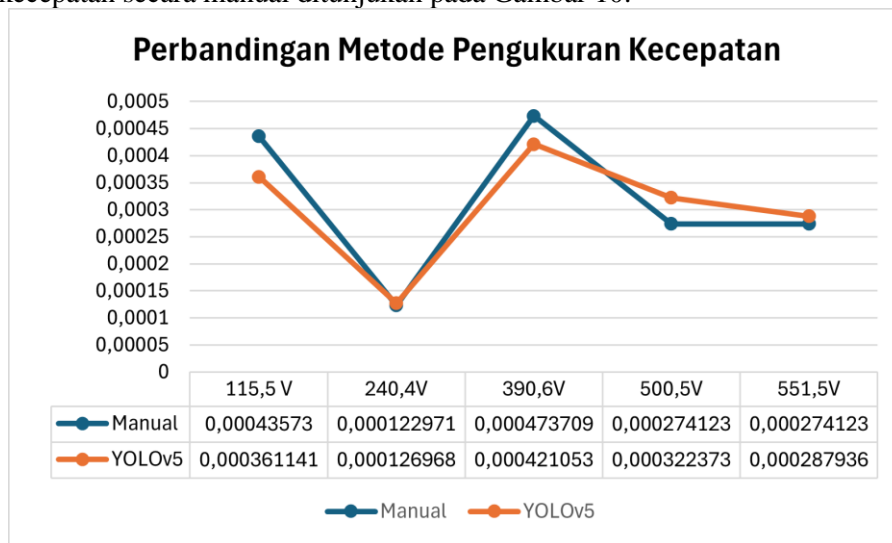
GAMBAR 9. Contoh hasil deteksi tetesan minyak dengan *ID Tracking*

Dengan pendekatan ini, sistem dapat mendeteksi dan melacak tetesan secara efisien dalam sebuah video, memastikan setiap tetesan diberi ID unik yang konsisten selama tetesan tersebut ada dalam frame.

Hasil Pengujian Deteksi Pengukuran Kecepatan

Pengujian dilakukan dengan melakukan pengambilan video saat eksperimen tetes minyak milikan dilakukan sebanyak 5 kali dengan variasi tegangan (115,5V, 240,4V, 390,6V, 500,5V, dan 551,5V).

Hasil dari sistem otomasi pengukuran kecepatan tetesan minyak, kemudian akan dibandingkan dengan pengukuran kecepatan secara manual ditunjukkan pada Gambar 10.



GAMBAR 10. Hasil pengukuran kecepatan tetes minyak

Grafik tersebut menunjukkan bahwa metode manual dan YOLOv5 memberikan hasil yang cukup berbeda pada beberapa titik tegangan. Pada tegangan 115,5V dan 390,6V, metode manual menunjukkan hasil yang lebih tinggi dibandingkan YOLOv5. Sedangkan, YOLOv5 memberikan hasil yang sedikit lebih tinggi dibandingkan metode manual terlihat pada tegangan 240,4V, 500,5V, dan 551,5V. Secara keseluruhan, kesalahan relatif kecepatan yang diperoleh adalah 3,79%, dan selisih waktu rata-rata antara kedua metode adalah 0,1274 detik. Hal ini menunjukkan bahwa metode YOLOv5 memiliki akurasi yang cukup kompetitif dengan metode manual sehingga variasi hasil tetap dalam batas toleransi. Meskipun YOLOv5 memiliki nilai mAP yang rendah, model tersebut konsisten mendeteksi objek dengan baik sehingga pengukuran kecepatan dapat dilakukan dengan hasil yang andal dan stabil.

KESIMPULAN

Pada penelitian ini telah dilakukan solusi otomatis program pengukuran muatan kecepatan berbasis YOLOv5. Model YOLOv5 yang dilatih menghasilkan alur kerja yang baik untuk mendeteksi tetesan minyak jatuh diantara dua pelat. Model YOLOv5 yang terintegrasi dengan algoritma beroperasi dengan baik. Secara keseluruhan, sistem deteksi objek untuk otomasi pengukuran kecepatan tetes minyak milikan berdasarkan video rekaman dengan YOLOv5 mendapatkan hasil yang cukup bagus. Meskipun nilai mAP yang dihasilkan tidak terlalu tinggi sebesar 0,355, YOLOv5 berhasil mendeteksi objek dengan konsisten untuk mendapatkan data waktu jatuh dan kecepatan terminal tetesan. Perbandingan hasil menunjukkan bahwa kesalahan relatif antara kedua metode cukup kecil yaitu 3,79% dan selisih rata-rata waktu 0.1274 detik pada tiap variasi tegangan. Model ini mampu mempertahankan presisi tinggi pada tingkat kepercayaan tertentu, menunjukkan keandalan dalam prediksi positif. Namun, perlu diingat kinerja model deteksi objek dapat dipengaruhi oleh berbagai faktor seperti kualitas dataset, jumlah data, jumlah epoch yang digunakan, dan hyperparameter lainnya. Oleh karena itu, untuk memperbaiki kinerja YOLOv5, perlu dilakukan berbagai upaya seperti peningkatan kualitas dataset pelatihan dan penggunaan arsitektur model yang lebih kompleks.

UCAPAN TERIMA KASIH

Peneliti mengucapkan terima kasih kepada Dr. Hadi Nasbey, S.Pd.,M.Si dan Haris Suhendar, S.Si., M.Sc selaku dosen pembimbing dan laboran-laboran Universitas Negeri Jakarta yang telah memberikan bimbingan, membantu pemakaian alat eksperimen dalam mengambil dataset, masukan penelitian serta dukungan dalam menyelesaikan penelitian eksperimen ini.

REFERENSI

- [1] S. W. R. Nasution, "Pengaruh Penguasaan Pengukuran Terhadap Hasil Belajar Fisika Siswa Pada Materi Besaran dan Satuan," *Jurnal Education and development*, vol.7, no. 4, pp. 176, 2019.
- [2] T. Yusuf, H. S. Putra, N. Faliza, *Dasar Metodologi Penelitian: Teori, Desain, dan Analisis Data*. Sumatera Barat: Tazaka Innovatix Labs, 2023.
- [3] M. M. Sanaky, L. M. Saleh, H. D. Titaley. "Analisis Faktor-Faktor Penyebab Keterlambatan Pada Proyek Pembangunan Gedung Asrama MAN 1 Tulehu Maluku Tengah," *Jurnal Simetrik*, vol. 11, no. 1, pp. 433, 2021.
- [4] A. Elyas, *Pembuatan Perangkat Lunak Visualisasi Eksperimen Tetes Minyak Milikan dengan Menggunakan Adobe Flash*. Surakarta: Universitas Sebelas Maret, 2013.
- [5] M. I. Alim, et al., *Tetes Minyak Milikan*. Surabaya: Institut teknologi Sepuluh Nopember, 2017.
- [6] S. Elzsa, et al., "Tetes Minyak Milikan," *Journal Fisika Modern*, vol. 1, no. 1, pp. 1-3, 2018, doi: <https://doi.org/04/04>.
- [7] R. A. Serway, *Modern Physics*. United States: Thomson Brook, 2019.
- [8] P. A. Tipler, *Modern Physics Fifth Edition*. New York: W.H. Freeman and Company, 2017.
- [9] Y. Khery, A. Nufida, Suryati, *Serial Modul Pembelajaran Berorientasi Nature Of Science (NOS) Kimia Umum: Atom, Molekul, dan Sifat Zat*. Yogyakarta: Deepublish, 2019
- [10] R. Firmansyah, R. Rohmah, F. Salimatul, E. Yahya, "Tetes Minyak Milikan," *Jurnal Fisika Modern Tetes Minyak Milikan*, vol. 1, no. 3, pp. 1-6, 2018
- [11] N. Rahmawati, Roihatur, Leni., E. Yahya, "Tetes Minyak Milikan," *Jurnal Praktikum Tetes Minyak Milikan*, pp. 1-5, 2017
- [12] A. Esteva, K. Chou, S. Yeung, N. Naik, A. Madani, A. Mottaghi, Y. Liu, E. Topol, J. Dean, R. Socher, "Deep learning-enabled medical computer vision," *Nature Partner Journals Digital Medicine*, vol. 4, no.5, pp. 1, 2021, doi: <https://doi.org/10.1038/s41746-020-00376-2>
- [13] P. E. Cahyo, A. M. Rolly, R. Andarsyah, *Tutorial Object Detection People With Faster region-Based Convolutional Neural Network (Faster R-CNN)*. Bandung: Kreatif Industri Nusantara, 2020.
- [14] Arnita, et all. *Computer Vision dan Pengolahan Citra Digital*. Surabaya: Pustaka Aksara, 2022
- [15] Q. Aini, "Deteksi dan Pengenalan Objek dengan Model Machine Learning: Model YOLO," *CESS (Journal of Computer Engineering System and Science)*, vol. 6, no. 2, pp. 192-193, 2021, e-ISSN :2502-714x.
- [16] T. Diwan, G. Anirudh, V. Jitendra, Tembhurne, "Object detection using YOLO: challenges, architectural successors, datasets and applications," *Multimedia Tools and Applications*, pp. 9243-9244, doi: <https://doi.org/10.1007/s11042-022-13644-y>.
- [17] B. Aldughayfiq, F. Ashfaq, N. Z. Jhanjhi, M. Humayun, "YOLOv5-FPN: A Robust Framework for Multi-Sized Cell Counting in Fluorescence Images," *Journal Diagnostics*, vol. 13, no. 2280, pp. 1-2, 2023.
- [18] G. B. Prananta, H. A. Azzikri, C. Rozikin. "Deteksi dan Pengenalan Gestur Tangan Secara Real-Time Menggunakan Jaringan saraf Tiruan Konvolusional," *Jurnal Methodika*, vol. 9, no. 2, pp. 31, 2023
- [19] N. Hidayat, S. Wahyudi, A. A. Diaz, "Pengenalan Individu Melalui Identifikasi Wajah Menggunakan Metode You Only Look Once (YOLOv5)," *Jurnal Seminar Nasional Matematika, Geometri, Statistika, dan Komputasi*, 2022, <https://magestic.unej.ac.id/>
- [20] A. H. S. B. Budi, M. A. Baiqumi, B. Mulyanti, M. Fadli, "Sistem Deteksi Laju dan Plat Nomor Kendaraan Berbasis Video Rekaman Menggunakan YOLOv5-DeepSORT dan HyperLPR," *Jurnal Telekomtran*, vol. 11, no. 2, pp.142-143, 2023