

Pendeteksian Kecurangan Ujian Melalui CCTV Menggunakan Algoritma YOLOv5

Fitri Bimantoro¹, I Gede Pasek Suta Wijaya², Mizanul Ridho Aohana³

^{1,2,3}Teknik Informatika, Fakultas Teknik, Universitas Mataram

E-mail: ¹[*¹bimo@unram.ac.id](mailto:bimo@unram.ac.id), ²[g²psutawijaya@unram.ac.id](mailto:gpsutawijaya@unram.ac.id), ³[m³izanul.aohana@gmail.com](mailto:mizanul.aohana@gmail.com)

Abstrak – Penggunaan teknologi di sektor pendidikan, khususnya ketika ujian, masih menghadapi tantangan berupa tingkat kecurangan yang tinggi. Salah satu penerapan teknologi ini adalah pendeteksian kecurangan saat ujian menggunakan CCTV. YOLO merupakan salah satu metode yang cukup handal untuk melakukan deteksi objek, dan YOLOv5 adalah salah satu varian YOLO yang mampu memberikan performa baik pada perangkat yang minim. Penelitian ini mengusulkan penerapan algoritma YOLOv5 untuk mendeteksi kecurangan melalui CCTV. Penelitian ini fokus pada efisiensi dan performa, dengan membandingkan tiga varian YOLOv5, yaitu YOLOv5l, YOLOv5m, dan YOLOv5s. Dataset yang digunakan merupakan rekaman video CCTV yang berada pada ruang kelas, dimana dataset ini terdiri dari 5 kelas (1 kelas normal, dan 4 kelas tindakan kecurangan). Pengujian dilakukan dengan membandingkan performa dari ketiga varian YOLOv5. Berdasarkan hasil pengujian, beban komputasi YOLOv5s saat pelatihan adalah 9,1 ms, 7x jauh lebih kecil dari pada YOLOv5l dan 3x lebih kecil dari YOLOv5m. Selain itu performa YOLOv5s lebih baik dibandingkan dengan YOLOv5l dan YOLOv5m, dengan akurasi, AP, AR dan mAP:50 sebesar 0,43, 0,492, 0,431, dan 0,549 secara berurutan. Hasil tersebut menegaskan bahwa YOLOv5s yang terbaik baik secara beban komputasi maupun performa. Meskipun demikian, perlu dilakukan perbaikan kualitas dan kuantitas dataset dan juga metode untuk meningkatkan performa dari pendeteksi kecurangan melalui CCTV ini.

Kata Kunci — deteksi, kecurangan, ujian, CCTV, YOLOv5

1. PENDAHULUAN

Penggunaan teknologi di era digitalisasi ini memang sangat masif terjadi, hampir seluruh sektor kehidupan sudah menerapkan teknologi dalam proses optimasi yang dilakukan. Optimalisasi anggaran, efisiensi kerja, dan pengurangan beban kerja menjadi salah satu parameter kunci dalam penerapan teknologi. Salah satu sektor penggunaan teknologi adalah sektor Pendidikan. Hingga saat ini, penggunaan teknologi telah terbukti dapat mengoptimalkan proses belajar mengajar [1] dan terbukti dapat meningkatkan kualitas penyerapan materi pada siswa [2]. Tidak hanya dari sisi siswa, staff pengajar juga dapat menggunakan teknologi untuk meningkatkan pengalaman belajar yang diberikan [3].

Dalam dunia Pendidikan, ujian merupakan salah satu aspek penting dalam institusi pendidikan untuk mengukur seberapa jauh kemampuan dan pengetahuan siswa terkait materi yang sudah diberikan [4]. Ujian tulis [5] merupakan salah satu metode yang paling banyak digunakan sampai saat ini [6]. Walaupun beberapa kampus atau sekolah sudah melakukan ujian berbasis komputer [7]. Kendati demikian, ujian tulis dan digital tetap memiliki persentase kecurangan yang tinggi dalam pelaksanaannya. Hal ini bisa disebabkan oleh berbagai faktor, beberapa diantaranya seperti rendahnya rasa efikasi diri [8], [9] dan ketakutan siswa menghadapi kegagalan dalam mengerjakan ujian [10]. Faktor tersebut merupakan faktor internal yang didorong oleh kepribadian masing-masing siswa, namun terdapat pula faktor eksternal yang dapat mengakibatkan hal tersebut yakni rendahnya tingkat konsistensi proktor dalam mengawasi jalannya ujian.

Pemasangan Closed Circuit Television (CCTV) di ruang kelas merupakan salah satu upaya untuk mempermudah melakukan pengawasan ujian. Namun, dalam beberapa kasus, sering kali manusia atau proktor yang mengawasi ujian sering mengalami rasa jenuh dan bosan dalam melihat aktifitas yang monoton. Oleh karena itu, diperlukan sebuah algoritma visi komputer untuk mengoptimasi proses tersebut melalui CCTV [11]. Salah satu algoritma yang populer dalam dunia visi komputer saat ini adalah You Only Look Once (YOLO) [12], [13]. Pada implementasinya, YOLO sering kali digunakan untuk melakukan pendeteksian dan pengenalan objek, beberapa diantaranya seperti deteksi masker dan jarak sosial [14], [15], deteksi kecelakaan lalu lintas [16], deteksi ketertarikan pakaian [17], dan menghitung jumlah kendaraan yang lewat di jalan raya [18]. Berdasarkan informasi dari beberapa referensi di atas, maka algoritma ini juga sangat memungkinkan untuk diterapkan dalam mendeteksi aktivitas kecurangan siswa saat mengikuti ujian di dalam ruangan kelas [11].

Melihat pada penelitian yang dilakukan sebelumnya, Arinaldi A et al. [19] melakukan penelitian tentang kecurangan ujian berdasarkan gestur tubuh menggunakan Algoritma 3D CNN dan XGBoost. Dataset yang digunakan terdiri dari 6 class, yakni *Exchange Paper*, *Use Cheat Seet*, *Talking Friend*, *Giving Code*, *Looking Friend*, dan *No Cheat*. Penelitian ini berhasil memperoleh akurasi terbaik sebesar 81,1% menggunakan algoritma XGBoost disusul dengan 3D CNN dengan akurasi sebesar 70%.

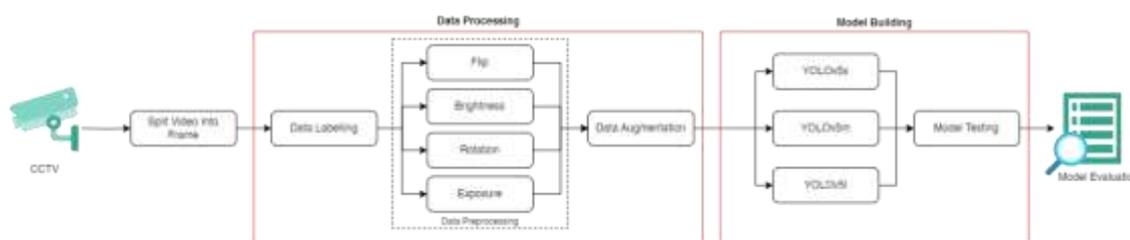
Kemudian, mengacu pada penelitian terbaru lainnya, Aqeel et al. [20] membuat model deteksi kecurangan elektronik yang memungkinkan pengawas dapat melakukan Deteksi dan Pelacakan Siswa/Orang, Mendeteksi aktivitas yang mencurigakan, Membuat peringatan, dan Menandai kehadiran. Deteksi siswa dari video dilakukan dengan menggunakan YOLOv7 dan pelacak DeepSort digunakan untuk melacak orang yang terdeteksi oleh algoritma YOLOv7. Akurasi yang didapatkan pada penelitian ini adalah 81.67%.

Studi komparasi terkait YOLOv5 dan YOLOv7 dilakukan dengan menggunakan dataset yang berbeda yakni untuk pendeteksian penyakit padi [21] dan dataset *Remote Weapon Station* [22] menghasilkan kesimpulan yang serupa. Berdasarkan pengujian yang dilakukan dengan dataset penyakit padi YOLOv5 dan YOLOv7 memiliki performa yang hampir sama. Selain itu, YOLOv5 memberikan kinerja yang lebih baik pada lingkungan dengan sumber daya yang minim[21]. Pada penelitian yang menggunakan pengenalan objek senjata sebagai objektifnya, YOLOv5 juga mampu memberikan performa yang lebih baik dibandingkan dengan YOLOv7. Pada penelitian ini dicatatkan bahwa akurasi YOLOv5 4% lebih baik daripada YOLOv7[22].

Berdasarkan beberapa referensi yang diuraikan diatas, penelitian ini akan fokus menggunakan algoritma YOLOv5. Pemilihan algoritma ini didasarkan pada tingkat eksistensinya dalam permasalahan visi komputer saat ini, khususnya pada permasalahan object detection dan object classification. Salah satu hal yang menarik dalam pemilihan algoritma ini adalah ukuran model YOLOv5 yang relatif kecil dan memiliki performa yang bagus dalam melakukan prediksi citra.

2. METODE PENELITIAN

Penelitian ini mengusung YOLOv5 sebagai solusi dalam mengoptimasi proses pengawasan ujian menggunakan CCTV. Detail dari metode penelitian yang diusulkan dapat dilihat pada gambar di bawah ini.



Gambar 1. Penelitian yang Diusulkan

Berdasarkan Gambar 1. penelitian ini akan menggunakan beberapa metode, diantaranya Pengumpulan Dataset, Data Pre-Processing, Object Detection dan Object Tracking menggunakan YOLOv5, dan evaluasi menggunakan metrik yang sudah ditentukan. Penelitian ini akan difokuskan untuk mengevaluasi kinerja yang diberikan oleh model YOLOv5 untuk mendeteksi kegiatan kecurangan di dalam kelas.

2.1 Pengumpulan Dataset

Penelitian ini menggunakan dataset yang dikumpulkan sendiri oleh peneliti melalui Closed Circuit Television (CCTV) dengan resolusi 1920x1080, 25 fps. Pengambilan dataset diambil di ruangan A3-01 yang berlokasi di Gedung A, Program Studi Teknik Informatika, Fakultas Teknik, Universitas Mataram. Ruangan ini memiliki kapasitas 35 orang dan memiliki luas sekitar 40 m³.



Gambar 2. Pengambilan Dataset

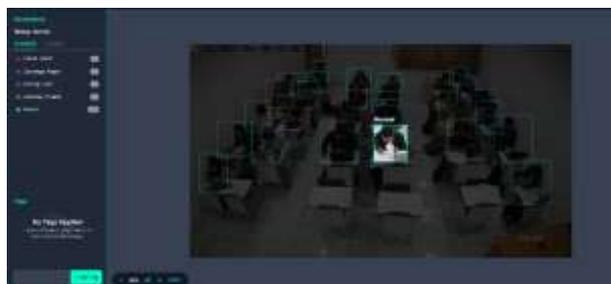
Gambar 2. merupakan gambar tangkapan layar dari video dataset yang diambil pada ruangan A3-01. Jika mengacu pada gambar tersebut, dataset yang diperoleh cukup jelas untuk dilakukan proses pelatihan model. Setelah video dikumpulkan, akan dilakukan proses perubahan video ke dalam bentuk frame untuk memudahkan proses training model.

2.2 Data Pre-Processing

Preprocessing merupakan suatu teknik untuk meningkatkan kualitas gambar agar memperoleh hasil terbaik dari hasil yang diperoleh. Metode klasik yang umum digunakan meliputi deteksi tepi, peningkatan kontras, pengurangan noise gambar, dan normalisasi warna gambar. Sering digunakan untuk memfokuskan dan memperoleh gambar dari objek penelitian, dan metode deviasi standar sering digunakan untuk menampilkan warna gambar dengan lebih jelas [23].

Langkah awal yang dilakukan dalam proses Pre-Processing adalah perubahan format dataset, yang semula berformat “.mp4” menjadi potongan-potongan frame dalam format “.jpg”. Proses ini dilakukan menggunakan bahasa python dengan interval pengambilan frame setiap 7 detik.

Setelah melakukan transformasi format, penulis melakukan anotasi pada dataset gambar, anotasi ini bertujuan untuk mengambil objek manusia yang ada dalam gambar dan memisahkannya ke dalam kelas-kelas yang sudah ditentukan. Dalam implementasinya, penulis menggunakan bantuan *tools Roboflow* untuk membantu mempermudah proses anotasi dataset.



Gambar 3. Anotasi Dataset

Gambar 3. merupakan salah satu dataset yang telah menjalani proses anotasi. Proses anotasi ini akan mengelompokkan data ke dalam lima kelas, yaitu "normal," "cheating," "exchange paper," "giving code," dan "looking friends." Data-data ini dianotasi secara menyeluruh, mulai dari kepala hingga tangan peserta ujian, sehingga secara jelas memperlihatkan gestur tubuh yang diperagakan oleh peserta ujian.

Setelah proses anotasi selesai, proses selanjutnya adalah proses pre-processing dan augmentasi. Proses ini melibatkan 3 operasi manipulasi citra seperti flip horizontal, rotasi (antara -5° hingga 5°), peningkatan kecerahan (antara -25% hingga 25%), dan peningkatan exposure (antara -10% hingga 10%). Selain itu, dilakukan pula augmentasi pada dataset sebanyak tiga kali, sehingga jumlah total data yang telah dianotasi mencapai 10.252. Jika dijabarkan lebih lanjut, kelas "normal" memiliki 3.975 gambar, "Looking Friend" memiliki 3.897 gambar, "Cheat Sheet" memiliki 1.890 gambar, "Giving Code" memiliki 372 gambar, dan kelas terakhir, "Exchange Paper," memiliki 136 gambar.

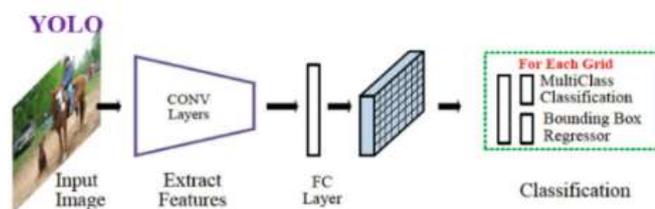
2.3 Algoritma YOLOv5

Pengenalan objek secara real time adalah elemen penting dalam sistem visi komputer [20]. Sedangkan pelacakan objek adalah salah aspek fundamental dalam konsep visi komputer yang mencoba mendeteksi dan melacak setiap objek dalam rangkaian gambar [24]. Pengenalan objek melibatkan pengklasifikasian dan

penentuan lokasi objek yang potensial dalam satu gambar secara bersamaan [25]. Terdapat banyak sekali algoritma yang dapat digunakan dalam object detection seperti Faster R-CNN, SSD, RetinaNet, and YOLO [20].

YOLOv5 adalah salah satu variasi model YOLO yang dirilis oleh ultralytics dan saat ini YOLOv5 merupakan model paling populer yang digunakan dalam dunia deteksi objek dan pelacakan objek. Saat ini pengembangan algoritma YOLO sudah sampai pada YOLOv8, tetapi hal yang menarik adalah YOLOv5 masih banyak digunakan oleh berbagai kalangan untuk berbagai kebutuhan. Arsitektur model yang efisien dan kecil dari segi ukuran menjadikan YOLOv5 masih menjadi primadona untuk melakukan berbagai pekerjaan. Oleh karena itu, peneliti tertarik untuk menggunakan algoritma YOLOv5 dalam kasus pendeteksian kecurangan ujian melalui CCTV.

Secara umum, arsitektur YOLO dapat digambarkan sebagai pendekatan deteksi objek yang memproses gambar secara keseluruhan dan menghasilkan prediksi objek dalam satu feedforward pass melalui neural network. Pendekatan ini memungkinkan deteksi objek yang cepat dan efisien. Dengan menggunakan berbagai varian YOLO, peneliti akan melakukan evaluasi kinerja dan keakuratan setiap model dalam mendeteksi perilaku mencurigakan selama ujian. Berikut arsitektur YOLO [26].

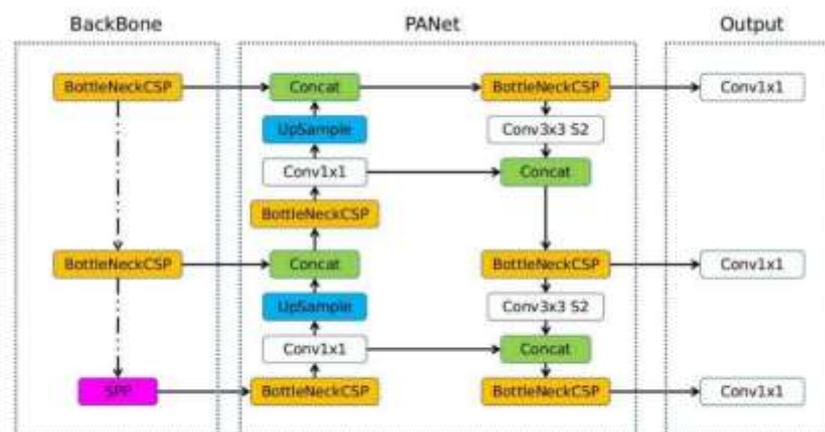


Gambar 4. Arsitektur Umum YOLO

Gambar 1. Memperlihatkan bahwa algoritma YOLO dimulai dengan memasukkan gambar sebagai langkah pertama. Masukan ini kemudian akan melewati serangkaian tahap ekstraksi fitur di dalam Convolutional Neural Network (CNN). Tahap ini bertujuan untuk mengidentifikasi fitur-fitur unik yang ada dalam gambar, seperti tepi objek, tekstur, warna, dan pola lainnya. Hasil dari tahap ekstraksi fitur ini adalah representasi data berdimensi tinggi yang menggambarkan gambar dengan cara yang lebih abstrak.

Setelah fitur-fitur tersebut berhasil diekstraksi, langkah selanjutnya adalah mengirimkannya ke lapisan Fully Connected Layer (FC) dalam Neural Network. Lapisan FC ini kemudian berfungsi untuk menggabungkan dan memproses fitur-fitur yang telah diambil sebelumnya. Dalam proses ini, pengolahan akan melibatkan perhitungan yang lebih kompleks dan pembentukan representasi data yang lebih abstrak. Output dari lapisan FC inilah yang akan menentukan hasil akhir dalam proses klasifikasi pada algoritma YOLO. Hasil output ini melibatkan informasi terkait lokasi objek (koordinat bounding box), kelas objek yang terdeteksi, dan tingkat kepercayaan (confidence) terhadap deteksi tersebut. Dengan kata lain, YOLO menggunakan fitur-fitur yang telah diproses melalui lapisan FC untuk menghasilkan informasi komprehensif tentang objek-objek dalam gambar, mencakup jenis objek, lokasinya, dan seberapa yakinnya algoritma terhadap deteksinya.

Jika dianalisis lebih jauh, penggunaan spesifik terhadap arsitektur YOLOv5 dapat divisualisasikan ke dalam bentuk Gambar 5.



Gambar 5. Arsitektur YOLOv5

Perbedaan utama dari YOLOv5 jika dibandingkan dengan model sejenis dan model sebelumnya terletak pada penggunaan CrossStage Partial Network (CSPNet) sebagai tulang punggung model dan Path Aggregation Network (PANet) sebagai leher agregasi fitur. Arsitektur model dapat dilihat pada Gambar 1. Perbaikan-perbaikan ini menghasilkan ekstraksi fitur yang lebih optimal dan peningkatan yang signifikan dalam nilai mAP score [27].

Dengan pendekatan ini, YOLOv5 dapat secara efisien dan akurat mendeteksi objek-objek dalam gambar dengan menggabungkan ekstraksi fitur yang canggih dengan pengolahan informasi dalam lapisan fully connected untuk memberikan hasil klasifikasi yang kuat.

2.4 Metrik Evaluasi

Untuk mengevaluasi kinerja model dalam penelitian ini, digunakan beberapa metrik alternatif seperti Confusion Matrix untuk mengukur kinerja klasifikasi model, Average Precision (AP), dan mean Average Precision (mAP) untuk mengukur seberapa jauh model mampu melakukan deteksi objek secara presisi. Ketiga evaluasi ini dilakukan secara berurutan untuk mendapatkan hasil evaluasi performa yang optimal.

Confusion Matrix merupakan salah satu skema evaluasi yang paling sering digunakan dalam machine learning, khususnya supervised learning [28]. Confusion matrix terdiri dari 4 nilai evaluasi, yakni True Positive (TP), True Negatif (TN), False Positif (FP) dan False Negatif (FN) [29].

Tabel 1. *Confusion Matrix Theory*

| | Prediction | | |
|--|------------|----------|----|
| | Positive | Negative | |
| | Actual | TP | TN |
| | Negative | FP | FN |

Tabel 1. Menunjukkan komposisi penyusunan yang ada pada confusion matrix, berdasarkan tabel tersebut dapat dihitung matrix evaluasi berupa accuracy, precision dan recall. Persamaan (1), (2), dan (3) merupakan persamaan yang digunakan untuk menghitung nilai evaluasi [30].

$$Acc = \frac{TP+TN}{TP+FN+FP+TN} \dots\dots\dots(1)$$

$$P = \frac{TP}{TP+FP} \dots\dots\dots(2)$$

$$R = \frac{TP}{TP+FN} \dots\dots\dots(3)$$

Accuracy (Acc) merupakan salah satu metode pengujian berdasarkan tingkat kedekatan keseluruhan antara nilai prediksi dengan nilai actual. Precision (P) didefinisikan sebagai ketepatan prediksi yang memiliki label benar dengan hasil positif. Sedangkan Recall (R) merepresentasikan bagaimana kuantitas dari kualitas pada seluruh proses prediksinya [31].

Dalam algoritma YOLO, salah satu indikator utama untuk menilai performa model adalah dengan menghitung nilai Mean Average Precision (mAP) [32]. Metrics mAP adalah metrik yang umum digunakan dalam tugas deteksi objek untuk mengukur sejauh mana model mampu mendeteksi dan mengklasifikasikan objek dengan akurasi tinggi [33].

Secara konsep, mAP akan menghitung presisi rata-rata (Average Precision) untuk setiap kelas objek [34] Presisi mengukur sejauh mana deteksi yang dilakukan oleh model benar-benar merupakan objek yang dimaksud, dan ini dihitung dengan menghitung jumlah true positive (TP) dibagi dengan jumlah total prediksi positif yang dibuat oleh model [35].

$$AP = \sum_{i=1}^N P(i)\Delta R(i) \dots\dots\dots(4)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP(img_i) \dots\dots\dots(5)$$

Dimana AP mendefinisikan average precision, sedangkan N mendefinisikan jumlah class dan img_i melambangkan image pada tiap iterasi. Nilai AP dan mAP memiliki rentang 0-1, sedangkan nilai ideal pada kedua tolak ukur tersebut adalah 1.

3. HASIL DAN PEMBAHASAN

Pengujian yang dilakukan pada penelitian ini dengan membandingkan beban komputasi, performa dan menganalisis hasil prediksi dari 3 jenis YOLOv5 yaitu YOLOv5l, YOLOv5m, dan YOLOv5s. Berdasarkan Tabel 1, beban komputasi dari ketiga jenis YOLOv5 dihitung berdasarkan jumlah parameter, GFLOPS dan waktu eksekusi ketika preproses, pelatihan dan pengujian. Tabel 3 menunjukkan bahwa YOLOv5s memiliki jumlah parameter yang jauh lebih kecil dari YOLOv5 yang lainnya, hampir 7 kali lebih kecil dari YOLOv5l dan

3x lebih kecil dari YOLOv5m. Hal ini tentu mempengaruhi waktu pelatihannya, dapat dilihat waktu pelatihan meningkat sesuai dengan jumlah parameter yang dimiliki masing-masing model. Namun hal tersebut tidak mempengaruhi secara signifikan waktu preproses dan pengujian. Parameter lainnya yang menyatakan beban komputasi adalah GFLOPs, berdasarkan Tabel 3 YOLOv5l memiliki GFLOPs tertinggi, sedangkan YOLOv5m dan YOLOv5s memberikan GFLOPs yang serupa. Secara umum, Tabel 1 menunjukkan bahwa YOLOv5s memiliki beban komputasi yang paling ringan dibandingkan 2 varian YOLOv5 yang lainnya.

Tabel 3. Komparasi Komputasi YOLOv5

| Algoritma | Parameter | GFLOPs | Waktu rata-rata | | |
|-----------|---------------|---------------|-----------------|---------------|---------------|
| | | | preproses | pelatihan | pengujian |
| YOLOv5l | 46.13 M | 107.7 | 0.4 ms | 40.6 ms | 1.6 ms |
| YOLOv5m | 20.87 M | 47.9 | 0.4 ms | 22.0 ms | 1.6 ms |
| YOLOv5s | 7.02 M | 45.153 | 0.4 ms | 9.1 ms | 1.2 ms |

Tabel 4 menunjukkan performa untuk ketiga YOLOv5 berdasarkan nilai akurasi, rata-rata presisi (AP), rata-rata recall (AR), dan mAP:50. Nilai akurasi, AP dan AR yang dihasilkan oleh YOLOv5s lebih baik daripada kedua YOLOv5 lainnya. Sedangkan YOLOv5l dan YOLOv5m memiliki performa yang serupa pada metrik evaluasi ini. Namun hal ini berbeda ketika melihat nilai mAP:50, walaupun tidak signifikan, YOLOv5l dan YOLOv5s memberikan nilai mAP yang serupa sedangkan YOLOv5m memiliki nilai yang sedikit lebih rendah. Dapat disimpulkan berdasarkan Tabel 4, secara performa YOLOv5s memberikan performa yang lebih baik dibandingkan YOLOv5l dan YOLOv5m.

Tabel 4. Metrik Evaluasi YOLOv5

| Algoritma | Akurasi | AP | AR | mAP:50 |
|-----------|-------------|--------------|--------------|--------------|
| YOLOv5l | 0,39 | 0,401 | 0,391 | 0,555 |
| YOLOv5m | 0,39 | 0,406 | 0,385 | 0,497 |
| YOLOv5s | 0,43 | 0,492 | 0,431 | 0,549 |

Tabel 5 memberikan informasi tentang hasil prediksi 5 kelas dari YOLOv5 yang terdiri dari *Cheat Sheet* (CS), *Exchange Paper* (EP), *Giving Code* (GC), *Looking Friend* (LF) dan Normal (N). Kelas LF merupakan kelas yang konsisten memberikan nilai ketepatan yang tinggi dibandingkan kelas yang lainnya pada setiap metode, sedangkan kelas GC merupakan kelas dengan nilai ketepatan prediksi terendah, bahkan hanya YOLOv5s yang mampu memberikan nilai prediksi diatas 0. YOLOv5l baik dalam menentukan kelas normal dengan ketepatan 76%, sedangkan YOLOv5m sangat baik dalam melakukan prediksi LF. Namun secara umum, YOLOv5s mampu menghasilkan prediksi bukan 0 pada setiap kelas, dan juga unggul dalam melakukan prediksi pada kelas EP dan GC dimana kedua kelas ini memiliki jumlah dataset yang paling sedikit. Walaupun pada kelas yang lainnya tidak unggul, namun perbedaan jumlah prediksi yang diberikan tidaklah signifikan.

Tabel 5. Confusion Matrix YOLOv5s

| | | YOLOv5-L | | | | | | YOLOv5-M | | | | | | YOLOv5-S | | | | | |
|--------|----|----------|------|------|-------------|------|------|----------|------|------|-------------|------|------|----------|------|------|-------------|------|------|
| | | CS | EP | GC | LF | N | BG | CS | EP | GC | LF | N | BG | CS | EP | GC | LF | N | BG |
| Actual | CS | 0,71 | 0,06 | 0,03 | 0,04 | 0,05 | 0,3 | 0,69 | 0,08 | 0,01 | 0,05 | 0,07 | 0,28 | 0,69 | 0,06 | 0,03 | 0,04 | 0,08 | 0,25 |
| | EP | 0 | 0,08 | 0 | 0 | 0 | 0 | 0 | 0,08 | 0 | 0 | 0 | 0 | 0 | 0,25 | 0 | 0 | 0 | 0,03 |
| | GC | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0,03 | 0,11 | 0 | 0,01 | 0,02 |
| | LF | 0,1 | 0,58 | 0,62 | 0,79 | 0,15 | 0,42 | 0,11 | 0,64 | 0,65 | 0,82 | 0,17 | 0,5 | 0,11 | 0,56 | 0,57 | 0,78 | 0,14 | 0,39 |
| | N | 0,14 | 0,03 | 0,17 | 0,11 | 0,76 | 0,27 | 0,12 | 0 | 0,13 | 0,08 | 0,72 | 0,22 | 0,14 | 0 | 0,17 | 0,11 | 0,75 | 0,31 |
| | BG | 0,05 | 0,25 | 0,18 | 0,05 | 0,04 | 0 | 0,08 | 0,19 | 0,21 | 0,05 | 0,04 | 0 | 0,06 | 0,11 | 0,13 | 0,05 | 0,03 | 0 |

Berdasarkan analisis yang telah dilakukan, YOLOv5s mampu memberikan performa yang lebih optimal daripada kedua varian YOLOv5 yang lain. Hal ini terlihat bagaimana arsitektur YOLOv5s yang kecil mampu membuat beban komputasinya jadi jauh lebih ringan. Walaupun dengan arsitektur yang kecil, YOLOv5s

memberikan performa yang baik, selain itu YOLOv5s mampu mendeteksi dengan baik kelas EP dan GC yang tidak mampu dideteksi oleh YOLOv5l dan YOLOv5m.

4. SIMPULAN

YOLOv5 merupakan varian YOLO yang baik digunakan untuk pendeteksian objek. Dalam menentukan kecurangan melalui CCTV, YOLOv5 mampu memberikan performa yang cukup baik walaupun masih jauh dari kata ideal. Hal ini terlihat dari akurasi, AP, AR, dan mAP terbaik sebesar 0,43, 0,492, 0,431, dan 0,555. Salah satu yang menjadi penyebabnya adalah adanya ketidakseimbangan jumlah data pada setiap kelasnya. Selanjutnya, YOLOv5s, yang merupakan varian YOLOv5 dengan arsitektur paling kecil mampu memberikan yang terbaik dari kedua model lainnya. Dengan keunggulan jumlah parameter paling sedikit, YOLOv5s memberikan performa yang paling baik walaupun tidak signifikan. Selain itu, YOLOv5s mampu memprediksi dua kelas yang tidak dapat diprediksi oleh YOLOv5l dan YOLOv5m.

5. SARAN

Berdasarkan penelitian yang telah dilakukan, rencana penelitian kedepannya yakni dengan memperbaiki kualitas dataset dengan upaya memperbanyak jumlah dataset terutama pada kelas-kelas dengan jumlah data paling sedikit. Selain itu, perlu dilakukan pengujian dengan menggunakan metode-metode deep learning yang lainnya disertai *tuning* pada hyperparameternya. Diharapkan dengan melakukan hal tersebut akan membuat performa dari pendeteksi kecurangan melalui CCTV akan meningkat.

DAFTAR PUSTAKA

- [1] H. Cai and I. King, "Education Technology for Online Learning in Times of Crisis," in *Proceedings of 2020 IEEE International Conference on Teaching, Assessment, and Learning for Engineering, TALE 2020*, Institute of Electrical and Electronics Engineers Inc., Dec. 2020, pp. 758–763. doi: 10.1109/TALE48869.2020.9368387.
- [2] L. Al-Labadi and S. Sant, "Enhance Learning Experience Using Technology In Class," *J Technol Sci Educ*, vol. 11, no. 1, pp. 44–52, Sep. 2021, doi: 10.3926/jotse.1050.
- [3] M. Alahmari, "Exploring the Influential Factors Affecting Staff Willingness to Adopt Augmented Reality," *International Journal of Information and Education Technology*, vol. 13, no. 7, pp. 1078–1084, Jul. 2023, doi: 10.18178/ijiet.2023.13.7.1907.
- [4] S. R. Sletten, "Rethinking Assessment: Replacing Traditional Exams with Paper Reviews," *J Microbiol Biol Educ*, vol. 22, no. 2, Sep. 2021, doi: 10.1128/jmbe.00109-21.
- [5] É. Cambron-Goulet, J. P. Dumas, É. Bergeron, L. Bergeron, and C. St-Onge, "Guidelines for Creating Written Clinical Reasoning Exams: Insight from a Delphi Study," *Health Professions Education*, vol. 5, no. 3, pp. 237–247, Sep. 2019, doi: 10.1016/j.hpe.2018.09.001.
- [6] R. Ellis, J. Cleland, D. SG. Scrimgeour, A. J. Lee, J. Hines, and P. A. Brennan, "Establishing the predictive validity of the intercollegiate membership of the Royal Colleges of surgeons written examination: MRCS Part A," *The Surgeon*, Aug. 2023, doi: 10.1016/j.surge.2023.07.004.
- [7] A. Manurung, A. Fildzah, and J. Rajagukguk, "Computer Based Test (CBT) System for Student Academic Examination," European Alliance for Innovation n.o., Oct. 2019. doi: 10.4108/eai.18-10-2018.2287186.
- [8] A. Fadillah, "Hubungan Antara Efikasi Diri Dengan Perilaku Menyontek Pada Mahasiswa," *Psikoborneo: Jurnal Ilmiah Psikologi*, vol. 7, no. 4, pp. 657–664, 2019.
- [9] D. Septiana, "HUBUNGAN EFIKASI DIRI DAN STRES AKADEMIK DENGAN PERILAKU MENYONTEK SISWA," UNIVERSITAS ISLAM NEGERI RADEN INTAN LAMPUNG, Lampung, 2022. Accessed: Nov. 18, 2023. [Online]. Available: <http://repository.radenintan.ac.id/17318/>
- [10] C. M. Ifeagwazi, J. C. Chukwuorji, S. O. Egbodo, and M. B. Nwoke, "Peer pressure, fear of failure and examination cheating behavior in the university: Does gender make the difference?," *Cognition, Brain, Behavior. An Interdisciplinary Journal*, vol. 23, no. 1, pp. 43–62, 2019, doi: 10.24193/cbb.2019.23.03.
- [11] J. Nishchal, S. Reddy, and P. N. Navya, "Automated Cheating Detection in Exams using Posture and Emotion Analysis," in *2020 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT)*, IEEE, Jul. 2020, pp. 1–6. doi: 10.1109/CONECCT50063.2020.9198691.
- [12] C. Wu, Q. Luo, and D. Shou, "Image Recognition Technology and Development of YOLO Algorithm," in *Advances in Transdisciplinary Engineering*, IOS Press BV, Dec. 2022, pp. 32–38. doi: 10.3233/ATDE221146.

- [13] T. Diwan, G. Anirudh, and J. V. Tembhurne, "Object detection using YOLO: challenges, architectural successors, datasets and applications," *Multimed Tools Appl*, vol. 82, no. 6, pp. 9243–9275, Mar. 2023, doi: 10.1007/s11042-022-13644-y.
- [14] V. Senthilkumar, G. Kanagaraj, T. Primya, J. Joycema, M. B. Joan, and J. A. Vicram, "Application of AI And Computer Vision To Face Mask And Social Distance Detection in CCTV Video Streams," in *2021 International Conference on Advancements in Electrical, Electronics, Communication, Computing and Automation (ICAECA)*, IEEE, Oct. 2021, pp. 1–5. doi: 10.1109/ICAECA52838.2021.9675746.
- [15] B. Hardiansyah and A. Primasetya, "Sistem Deteksi Penggunaan masker (Face Mask Detection) Menggunakan Algoritma Deep Learning YOLOv4," *STAINS (SEMINAR NASIONAL TEKNOLOGI & SAINS)*, vol. 2, no. 1, pp. 313–318, Jan. 2023, Accessed: Dec. 25, 2023. [Online]. Available: <https://proceeding.unpkediri.ac.id/index.php/stains/article/view/2820>
- [16] A. Srinivasan, A. Srikanth, H. Indrajit, and V. Narasimhan, "A Novel Approach for Road Accident Detection using DETR Algorithm," in *2020 International Conference on Intelligent Data Science Technologies and Applications, IDSTA 2020*, Institute of Electrical and Electronics Engineers Inc., Oct. 2020, pp. 75–80. doi: 10.1109/IDSTA50958.2020.9263703.
- [17] E. P. Ijjina, A. S. Joshi, and G. Kanahasabai, "Detection of Customer Interested Garments in Surveillance Video using Computer Vision," in *2020 11th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, Kharagpur, India: IEEE, Jul. 2020, pp. 1–5. doi: 10.1109/ICCCNT49239.2020.9225571.
- [18] N. Chhadikar, P. Bhamare, K. Patil, and S. Kumari, "Image processing based Tracking and Counting Vehicles," in *2019 3rd International conference on Electronics, Communication and Aerospace Technology (ICECA)*, Coimbatore, India: IEEE, Jun. 2019, pp. 335–339. doi: 10.1109/ICECA.2019.8822070.
- [19] A. Arinaldi and M. I. Fanany, "Cheating Video Description Based on Sequences of Gestures," in *2017 5th International Conference on Information and Communication Technology, ICoICT 2017*, Institute of Electrical and Electronics Engineers Inc., Oct. 2017. doi: 10.1109/ICoICT.2017.8074679.
- [20] A. Zaffar, M. Jawad, M. Shabbir, P. O. Factory, and W. Cantt, "A Novel CNN-RNN Model for E-Cheating Detection Based on Video Surveillance," *UW JOURNAL OF COMPUTER SCIENCE*, vol. 5, no. 1, Jun. 2023, Accessed: Sep. 11, 2023. [Online]. Available: <https://uwjcs.org.pk/index.php/ojs/article/view/64>
- [21] M. T. Mulyani, "Analisis Perbandingan Algoritma Yolov5 Dan Yolov7 Dalam Pendeteksian Penyakit Padi Pada Raspberry Pi," Jakarta, Jul. 2023. Accessed: Dec. 25, 2023. [Online]. Available: https://repository.pnj.ac.id/id/eprint/12477/1/PEMBUKAAN%20sd%20BAB%20I_Meutia%20Tri%20Mulyani.pdf
- [22] O. E. Olorunshola, M. E. Irhebhude, and A. E. Ewwiekpaefe, "A Comparative Study of YOLOv5 and YOLOv7 Object Detection Algorithms 1*," *Journal of Computing and Social Informatics*, vol. 2, no. 1, p. 1, 2023.
- [23] U. P. Sanjaya, Z. Alawi, A. R. Zayn, and G. Dirgantara, "Optimasi Convolutional Neural Network dengan Standard Deviasi untuk Klasifikasi Pneumonia pada Citra X-rays Paru," *Generation Journal*, vol. 7, no. 3, pp. 40–47, Oct. 2023, doi: <https://doi.org/10.29407/gj.v7i3.20183>.
- [24] Z. Soleimanitaleb, M. A. Keyvanrad, and A. Jafari, "Object Tracking Methods:A Review," in *2019 9th International Conference on Computer and Knowledge Engineering (ICCKE)*, IEEE, Oct. 2019, pp. 282–288. doi: 10.1109/ICCKE48569.2019.8964761.
- [25] Z. Q. Zhao, P. Zheng, S. T. Xu, and X. Wu, "Object Detection with Deep Learning: A Review," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 30, no. 11. Institute of Electrical and Electronics Engineers Inc., pp. 3212–3232, Nov. 01, 2019. doi: 10.1109/TNNLS.2018.2876865.
- [26] O. E. Olorunshola, M. E. Irhebhude, and A. E. Ewwiekpaefe, "A Comparative Study of YOLOv5 and YOLOv7 Object Detection Algorithms," *Journal of Computing and Social Informatics*, vol. 2, no. 1, pp. 1–12, Feb. 2023, doi: 10.33736/jcsi.5070.2023.
- [27] D. Dlužnevskij, P. Stefanovč, and S. Ramanauskaite, "Investigation of YOLOv5 efficiency in iPhone supported systems," *Baltic Journal of Modern Computing*, vol. 9, no. 3, pp. 333–344, 2021, doi: 10.22364/bjmc.2021.9.3.07.
- [28] M. Hasnain, M. F. Pasha, I. Ghani, M. Imran, M. Y. Alzahrani, and R. Budiarto, "Evaluating Trust Prediction and Confusion Matrix Measures for Web Services Ranking," *IEEE Access*, vol. 8, pp. 90847–90861, May 2020, doi: 10.1109/ACCESS.2020.2994222.
- [29] R. Ilahi, F. Bimantoro, R. Dwiyanaputra, and R. Farinda, "Classification of Pringgasela Typical Songket Using Multi Texton Co-occurrence Descriptor and K-Nearest Neighbor," in *Proceedings of the First Mandalika International Multi-Conference on Science and Engineering 2022, MIMSE 2022 (Informatics and Computer Science)*, Dordrecht: Atlantis Press International BV, 2022, pp. 352–366. doi: 10.2991/978-94-6463-084-8_30.

-
- [30] G. Tripathi and R. Kumar, “Early Prediction of Diabetes Mellitus Using Machine Learning,” in *2020 8th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO)*, IEEE, Jun. 2020, pp. 1009–1014. doi: 10.1109/ICRITO48877.2020.9197832.
- [31] L. Farokhah, “IMPLEMENTASI K-NEAREST NEIGHBOR UNTUK KLASIFIKASI BUNGA DENGAN EKSTRAKSI FITUR WARNA RGB,” *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 7, no. 6, pp. 1129–1135, 2019, doi: 10.25126/jtiik.202072608.
- [32] J. Lee and K. il Hwang, “YOLO with adaptive frame control for real-time object detection applications,” *Multimed Tools Appl*, vol. 81, no. 25, pp. 36375–36396, Oct. 2022, doi: 10.1007/s11042-021-11480-0.
- [33] M. Durve, F. Bonaccorso, A. Montessori, M. Lauricella, A. Tiribocchi, and S. Succi, “Tracking droplets in soft granular flows with deep learning techniques,” *The European Physical Journal Plus*, vol. 136, no. 8, p. 864, Aug. 2021, doi: 10.1140/epj/s13360-021-01849-3.
- [34] D. Gros *et al.*, “Anaphora Resolution,” *International Journal of Information Retrieval Research*, vol. 8, no. 3, pp. 33–45, Jul. 2018, doi: 10.4018/IJIRR.2018070103.
- [35] M. Zhu, “Recall, Precision and Average Precision,” Canada, Aug. 2004. Accessed: Sep. 14, 2023. [Online]. Available: https://www.researchgate.net/publication/228874142_Recall_precision_and_average_precision