

Hitung Cepat Buah Jeruk Berbeda Kultivar pada Pohon berbasis Citra Smartphone dan Kecerdasan Buatan

Quick Count of Different Orange Cultivar on Trees based on Smartphone Image and Artificial Intelligent

Surya Huda¹, Inggit Kresna Maharsih¹, Dimas Firmanda Al Riza¹

¹Departemen Teknik Biosistem, Fakultas Teknologi Pertanian, Universitas Brawijaya, Jl. Veteran Malang, Indonesia 65145

Email*): dimasfirmanda@ub.ac.id

Received:
21 February 2024

Revised:
19 August 2024

Accepted:
18 September 2024

Published:
29 September 2024

DOI:
10.29303/jrpb.v12i2.628

ISSN 2301-8119, e-ISSN
2443-1354

Available at
<http://jrpb.unram.ac.id/>

Abstract: Currently, predictions of orange fruit yield in an orchard are still done manually, namely by sampling manually to count the number of oranges on the tree. This method is not effective and the accuracy of predictions cannot be guaranteed. Automation in the process of counting citrus fruit on trees to predict yield can be done with computer vision using artificial intelligence models for object detection. One of the proposed model solutions that can be used for object detection is by using You Only Look Once (YOLO) architecture. However, the performance of the YOLO model for different varieties of orange trees in Indonesia is not yet known. Therefore, in this research, the development of the YOLOv5 model was carried out to quickly count orange fruit on trees of different varieties including the stages of image capture, image resizing, segmentation, model training with hyperparameters such as batch size and epoch, as well as model evaluation. In this study, the primary image dataset taken consisted of images of orange trees with two different cultivars, namely Pontianak Siamese oranges and Terigas Tangerines which have different characteristics. Then the YOLOv5 model is trained using labeled image data. The YOLOv5 model is trained with variations of hyperparameters and then the results are compared. The best model results in Siam Pontianak have a single label configuration in batch size 4 with parameters Mean Average Precision (mAP50), accuracy, precision, recall, and F1-score which produces a value of 0.88; 0.712; 0.853; 0.822; and 0.8372. Meanwhile, the best model results in Keprok Terigas have a single label configuration in batch size 10 with parameters Mean Average Precision (mAP50), accuracy, precision, recall, and F1-score which produces a value of 0.933; 0.75; 0.913; 0.878; and 0.8951.

Keywords: harvesting; orchard; quick counting; yield prediction; YOLO

Abstrak: Saat ini, prediksi yield buah jeruk pada suatu kebun jeruk masih dilakukan secara manual, yaitu dengan melakukan sampling menghitung manual jumlah buah pada pohon. Metode ini tidak efektif dan keakuratan prediksi tidak dapat dijamin. Otomasi dalam proses perhitungan buah jeruk pada pohon untuk memprediksi yield dapat dilakukan dengan komputer visi dengan menggunakan model kecerdasan buatan untuk deteksi obyek. Salah satu model yang dapat digunakan adalah model dengan arsitektur You Only Look Once (YOLO). Namun, belum diketahui performa model YOLO untuk pohon jeruk dengan varietas berbeda yang ada di Indonesia. Oleh karenanya, pada penelitian ini dilakukan pengembangan model YOLOv5 untuk menghitung cepat buah jeruk pada pohon dengan varietas yang berbeda. Pada penelitian ini dataset citra primer yang diambil terdiri dari citra pohon jeruk dengan dua kultivar yang berbeda yaitu jeruk Siam Pontianak dan Keprok Terigas yang memiliki karakteristik berbeda. Kemudian model YOLOv5 dilatih dengan menggunakan data citra yang telah dilabeli. Model YOLOv5 dilatih dengan variasi hyperparameter dan kemudian dibandingkan hasilnya. Hasil model terbaik pada Siam Pontianak memiliki konfigurasi label tunggal pada batch size 4 dengan parameter *Mean Average Precision* (mAP50), akurasi, presisi, *recall*, dan skor-F1 yang menghasilkan nilai

sebesar 0,88; 0,712; 0,853; 0,822; dan 0,8372. Sementara itu, Hasil model terbaik pada Keprak Terigas memiliki konfigurasi label tunggal pada *batch size* 10 dengan parameter *Mean Average Precision* (mAP50), akurasi, presisi, *recall*, dan skor-F1 yang menghasilkan nilai sebesar 0,933; 0,75; 0,913; 0,878; dan 0,8951.

Kata kunci: hitung cepat; kebun; panen; prediksi yield; YOLO

PENDAHULUAN

Latar Belakang

Tanaman jeruk merupakan tanaman buah yang bersifat tahunan dan banyak dibudidayakan. Menurut Badan Pusat Statistik (2024), jumlah produksi jeruk siam atau keprak di Indonesia mencapai 2.551.999 ton. Jeruk mudah ditemukan di wilayah Indonesia dengan ketinggian 900 hingga 1.200 meter di atas permukaan laut karena mudah beradaptasi (Murtando *et al.*, 2016). Indonesia memiliki beberapa jenis jeruk lokal, seperti jeruk siam, keprak dan jeruk besar. Adapun karakteristik dari jeruk siam, yaitu memiliki rasa yang manis, kulit tipis yang mudah dikupas, dan warna kulit kuning hijau sedikit mengkilat saat matang pada pohon (Barkah, 2020). Berbeda halnya dengan jeruk siam, jeruk keprak memiliki karakteristik rasa manis yang sedikit asam, kulit tebal, dan tekstur permukaan kulit yang kasar (Tuwo *et al.*, 2022).

Budidaya jeruk tidak lepas dari aktivitas berupa monitoring kondisi tanaman dan pertumbuhan buah. Monitoring buah jeruk masih dilakukan secara manual dengan cara mengukur diameter buah jeruk secara acak menggunakan jangka sorong digital per pohon, *bounding box* untuk menghitung *yield* atau *load* buah jeruk pada pohon, dan mencatat hasil yang didapatkan secara manual. Otomatisasi terkait perhitungan *yield* atau *load* buah jeruk pada pohon dapat dilakukan dengan bantuan *computer vision* (Cubero *et al.*, 2016). Perkembangan teknologi seperti *computer vision* sudah dikenal dan digunakan oleh manusia untuk mempermudah dalam hal melihat dan mengenali suatu objek yang ada di sekitar manusia (Purno & Wibowo, 2016). *Computer vision* dapat dikombinasikan dengan model kecerdasan buatan seperti *Convolutional Neural Network* (CNN) untuk melakukan segmentasi maupun deteksi obyek.

Terdapat beberapa jenis arsitektur model untuk melakukan deteksi objek, salah satunya adalah *You Only Look Once* (YOLO). Deteksi objek dengan model pendeteksi satu tahap seperti YOLO telah mengalami kemajuan yang signifikan dalam hal peningkatan kinerja. YOLOv5 merupakan arsitektur dengan kinerja yang lebih baik dari generasi sebelumnya (Jung & Choi, 2022). Kuznetsova *et al.* (2020) membandingkan penggunaan YOLOv3 dan YOLOv5 dengan data yang terlatih dari COCO *dataset*. Ditemukan bahwa YOLOv5 dapat mendeteksi apel dengan cukup tepat dengan hanya 2,8% apel yang tidak terdeteksi dan 3,5% objek yang terdeteksi sebagai apel yang berada di latar belakang. Hal ini menunjukkan potensi penggunaan YOLOv5 ini untuk kasus perhitungan buah jeruk di Indonesia. Namun, belum diketahui performa model YOLO untuk pohon jeruk dengan varietas berbeda yang ada di Indonesia, dimana karakteristik pohon dan buah dapat berbeda pula untuk varietas yang berbeda.

Tujuan

Penelitian deteksi jeruk bertujuan untuk mengetahui dan membandingkan performa algoritma YOLOv5 deteksi dan hitung cepat buah jeruk pada pohon dengan varietas yang berbeda yaitu dengan studi kasus pada varietas Siam Pontianak dan Keprak Terigas.

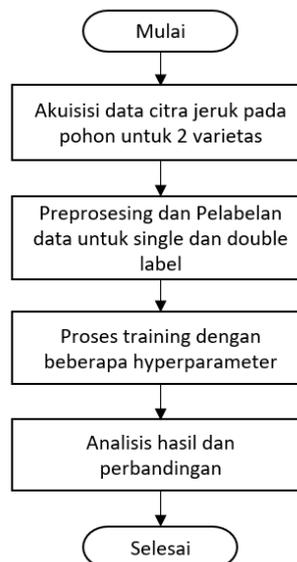
METODE PENELITIAN

Alat dan Bahan

Penelitian ini dilaksanakan di Balai Penelitian Tanaman Jeruk dan Buah Subtropika (BALITJESTRO) Kota Batu. Alat yang digunakan pada penelitian ini yaitu ponsel pintar dengan nama dagang Xiaomi dengan tipe Redmi Note 10S dan pengolahan data menggunakan laptop dengan nama dagang yang sama dengan tipe laptop, yaitu Redmibook 15. Bahan penelitian ini, yaitu pohon jeruk yang masih memiliki buah pada tiap dahannya dengan varietas Siam Pontianak dan Keprok Terigas.

Metode Penelitian

Metode pelaksanaan dimulai dari persiapan alat dan bahan, akuisisi citra digital, pra-pemrosesan citra digital, pembelajaran model, dan evaluasi kinerja model. Metode pelaksanaan ini dilakukan sebagai prosedur penelitian yang dilakukan. Adapun diagram alir metode pelaksanaan dapat dilihat pada Gambar 1. Prosedur penelitian pada Gambar 1 diulangi kembali untuk uji dengan label ganda.



Gambar 1. Prosedur Pelaksanaan Penelitian

Penelitian ini menggunakan pohon jeruk varietas Siam Pontianak dan Keprok Terigas yang berada di lahan Balitjestro Kota Batu sebagai objek untuk dideteksi. Jumlah pohon yang digunakan sebanyak 85 pohon per varietas. Alat yang digunakan untuk mengambil data citra yaitu ponsel pintar dengan sistem operasi Android.

Citra digital setiap pohon Citra digital setiap pohon Jeruk Siam Pontianak dan Keprok Terigas diakuisisi menggunakan kamera gawai dari empat sisi yang berbeda (arah Utara, Selatan, Barat dan Timur pohon) sehingga menghasilkan 340 data citra dari 85 pohon jeruk. Pencahayaan objek berasal dari cahaya matahari tanpa menggunakan flash kamera. Pengambilan citra dimulai dari pagi hari hingga sore hari. Jarak kamera dengan pohon bervariasi, pengambilan gambar fokus pada *frame* sebuah pohon jeruk. Konfigurasi kamera diatur secara otomatis oleh fitur gawai yang meliputi ISO, *shutter speed*, dan *aperture* (bukaan lensa kamera). Kemudian, seluruh citra digital yang telah diambil dipindahkan ke laptop dalam satu folder.

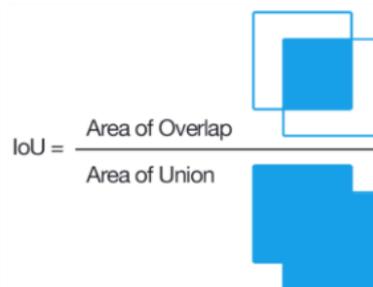
Selanjutnya melakukan *resize dataset*, segmentasi, dan pelatihan dan validasi. Tahap *resize dataset* berfungsi untuk mengubah ukuran citra digital yang digunakan sebagai objek deteksi. Data citra yang telah diperoleh dilakukan *resize* menjadi 20% dari ukuran awal untuk mengurangi beban komputasi dan disimpan dalam format JPG. Tahap segmentasi berfungsi

dalam membuat label yang digunakan untuk menandai objek pada citra digital. Target objek pada jenis label ganda terdiri dari dua jenis kelas yaitu, jeruk kuning dan jeruk hijau yang digunakan untuk membedakan jeruk matang dan mentah sesuai dengan obesrvasi langsung dengan berdasarkan warna kulit. Sementara itu, target objek pada jenis label tunggal hanya memiliki satu kelas saja yaitu jeruk. Terakhir, hasil labeling diunduh dalam bentuk (.txt) pada laman website *makesense.ai*. Langkah selanjutnya, membagi dataset menjadi dua yaitu data pelatihan dan data validasi. Penelitian ini menggunakan 310 data pelatihan dan 30 data validasi.

Model pembelajaran objek deteksi menggunakan YOLOv5. Pemrograman dilakukan menggunakan Bahasa Phyton dengan bantuan *Google Colaboratory*. Ukuran gambar diatur menjadi 640×640 piksel. Jumlah kelas (label) pada model terbagi menjadi dua yaitu label tunggal dan label ganda (label jeruk hijau dan jeruk kuning). Kemudian, *hyperparameter* yang digunakan pada proses pembelajaran model sebagai pembanding yaitu *batch size* dan *epochs*. *Batch size* adalah ukuran atau jumlah data training yang digunakan untuk satu iterasi. *Batch size* yang digunakan sebesar 4, 8, 10, dan 32 (Musahada, 2023). *Epochs* adalah jumlah iterasi secara maju dan mundur data pelatihan yang akan dilakukan dalam proses training. *Epochs* yang digunakan sebesar 25, 50, 100, dan 150 (Musahada, 2023). Kemudian melakukan evaluasi model untuk mengetahui kinerja sebagai pembanding dari hasil pembelajaran model. Parameter yang diukur meliputi nilai mAP, *recall*, *precision*, dan skor-F1.

Seluruh model yang berasal dari hasil pengambilan citra varietas Siam Pontianak dan Keprok Terigas dihasilkan melalui pembelajaran model dan dievaluasi dengan basis data *training* dan *validation*. Setiap *epochs* yang dijalankan menghasilkan pembaruan prediksi pembobotan pada setiap cabang topologi CNN untuk model deteksi. Hasil model sebagai pendeteksi objek diukur menggunakan parameter nilai mAP50. Adapun arti dari mAP50 yaitu tingkat presisi dan akurasi berdasarkan *Intersect over Union* (IoU) yang bernilai lebih dari atau sama dengan 0,5 (Zitnick & Dollár, 2014). Semakin besar nilai dari mAP50 maka tingkat akurasi dan presisi dalam mendeteksi objek semakin baik. Model pembelajaran yang telah dihasilkan kemudian dibandingkan guna mendapatkan hasil model deteksi objek terbaik (Ditria *et al.*, 2020).

Intersection over Union (IoU) adalah angkah untuk mengevaluasi dalam mengukur akurasi deteksi objek terhadap suatu dataset. IoU memerlukan dua area yang akan dipotong (Intersect) dan digabung (Union). Adapun dua area yang diperlukan adalah *bounding box* aktual dan area deteksi dari model yang dibangun, sehingga apabila nilai IoU semakin besar maka hasil area deteksi yang diprediksi semakin tepat (Shianto *et al.*, 2019). Adapun ilustrasi dari IoU dapat dilihat pada Gambar 2.

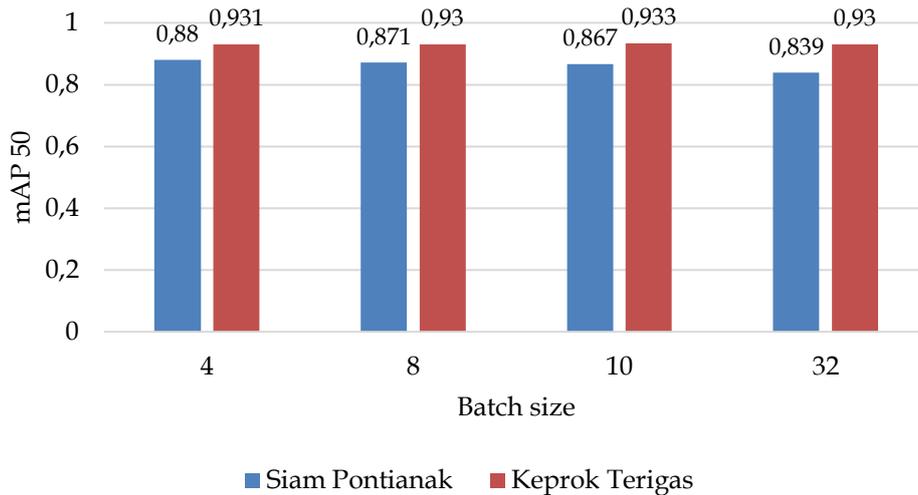


Gambar 2. *Intersection over Union* (Shianto *et al.*, 2019)

HASIL DAN PEMBAHASAN

Kinerja Deteksi Objek Terhadap Label Tunggal

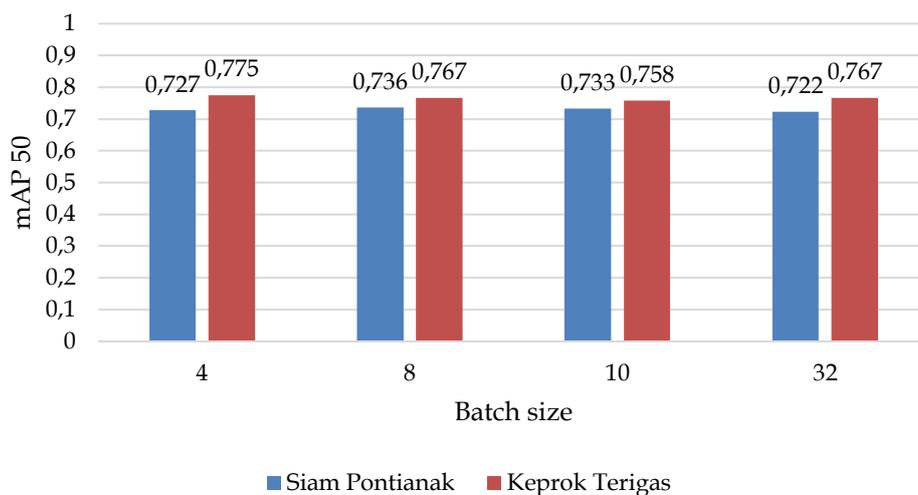
Gambar 3. adalah gambar grafik hasil deteksi dari jeruk Siam Pontianak dan Keprok Terigas yang menggunakan label tunggal. Hasil model deteksi terbaik dari Siam Pontianak dan Keprok Terigas menggunakan *batch size* 4 dan 10. Nilai mAP dari masing-masing model terbaik, yaitu 0,88 dan 0,933. Berdasarkan Gambar 3. di bawah, penggunaan arsitektur dan nilai *hyperparameter* yang sama dari dua deteksi objek yang berbeda menghasilkan variasi akurasi yang beragam. Perbedaan Nilai mAP50 dapat disebabkan adanya fluktuasi nilai yang diakibatkan oleh *overfitting* dari system (Nashrullah *et al.*, 2020).



Gambar 3. Kinerja Model Deteksi Objek Terhadap Label Tunggal

Kinerja Deteksi Objek Terhadap Label Ganda

Gambar 4. gambar grafik hasil deteksi dari jeruk Siam Pontianak dan Keprok Terigas yang menggunakan label ganda. Hasil model deteksi terbaik dari Siam Pontianak dan Keprok Terigas menggunakan *batch size* 8 dan 10. Nilai mAP dari masing-masing model terbaik, yaitu 0,736 dan 0,775.



Gambar 4. Kinerja Model Deteksi Objek Terhadap Label Ganda

Perbandingan Kinerja Deteksi Objek Terhadap Jenis Label

Berdasarkan model deteksi yang digunakan, yaitu label tunggal dan label ganda, didapatkan nilai mAP50 terbaik pada label tunggal sebesar 0,857. Model dari dua jenis label memiliki *hyperparameter* yang sama, yaitu nilai *batch size* sebesar 8. Perbandingan antara kedua jenis label dapat dilihat pada Tabel 1. Adapun hasil mAP50 dari label ganda memiliki nilai sebesar 0,736. Selaras dengan hal yang ditulis oleh Widyawati dan Reni (2021) semakin tinggi nilai mAP50 yang dihasilkan oleh suatu model deteksi, maka semakin akurat model tersebut dalam mendeteksi.

Tabel 1. Perbandingan Nilai mAP50 Terhadap Jenis Label

Objek Deteksi	Batch Size	Jenis Label	mAP50
Siam Pontianak	4	Tunggal	0,88
	8	Ganda	0,736
Keprak Terigas	10	Tunggal	0,933
	4	Ganda	0,775

Hasil Perhitungan Objek Terhadap Label Tunggal

Nilai Skor-F1 terbaik sebagai kinerja perhitungan objek yaitu sebesar 0,8372 pada varietas Siam Pontianak, sementara itu nilai Skor-F1 terbaik pada varietas Keprak Terigas sebesar 0,8951. Hasil model berasal dari nilai pada *batch size* 4 dan 10. Hasil kinerja perhitungan objek masing-masing model berjenis label tunggal secara rinci dapat dilihat pada Tabel 2.

Tabel 2. Kinerja Perhitungan Objek Model Terhadap Label Tunggal

Objek Deteksi	Batch Size	Akurasi	Presisi	Recall	Skor-F1
Siam Pontianak	4	0,712	0,853	0,822	0,8372
	8	0,681	0,86	0,787	0,8219
	10	0,684	0,877	0,785	0,8285
	32	0,656	0,871	0,802	0,8351
Keprak Terigas	4	0,747	0,92	0,864	0,8911
	8	0,747	0,918	0,865	0,8907
	10	0,75	0,913	0,878	0,8951
	32	0,728	0,897	0,886	0,8914

Hasil Perhitungan Objek Terhadap Label Ganda

Nilai Skor-F1 terbaik sebagai kinerja perhitungan objek yaitu sebesar 0,8372 pada varietas Siam Pontianak, sementara itu nilai Skor-F1 terbaik pada varietas Keprak Terigas sebesar 0,8951. Hasil model berasal dari nilai pada *batch size* 4 dan 10. Hasil kinerja perhitungan objek masing-masing model berjenis label ganda secara rinci dapat dilihat pada Tabel 3.

Tabel 3. Kinerja Perhitungan Objek Model Terhadap Label Ganda

Objek Deteksi	Batch Size	Akurasi	Presisi	Recall	Skor-F1
Siam Pontianak	4	0,51	0,663	0,746	0,6866
	8	0,52	0,695	0,705	0,6999
	10	0,491	0,721	0,665	0,6918
	32	0,514	0,712	0,671	0,6908
Keprak Terigas	4	0,561	0,726	0,741	0,7334
	8	0,547	0,726	0,736	0,7309
	10	0,554	0,712	0,735	0,7233
	32	0,55	0,717	0,725	0,7209

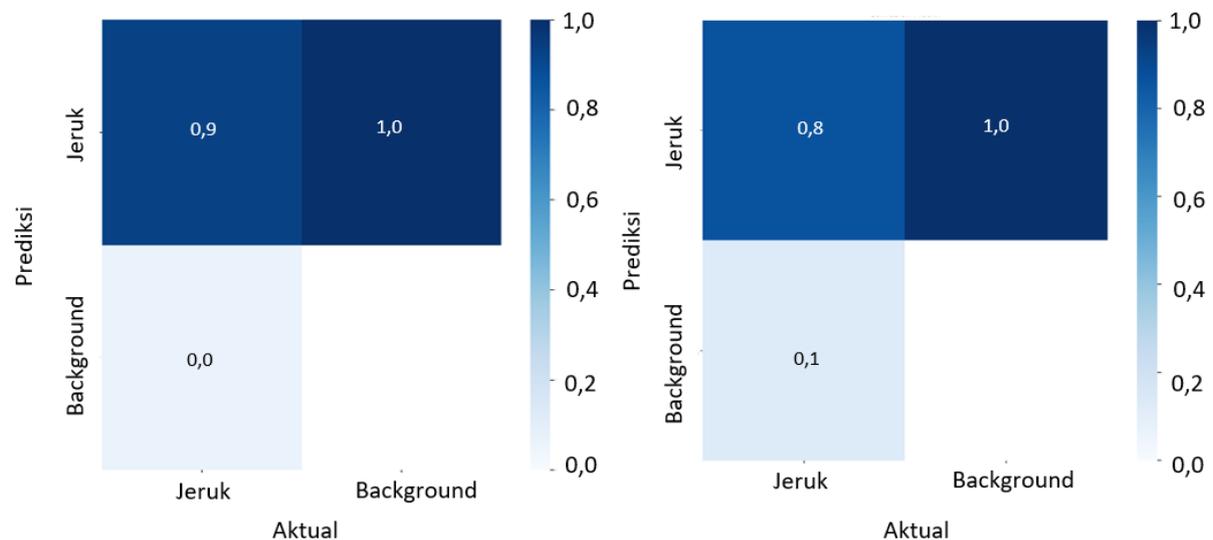
Perbandingan Hasil Perhitungan Objek Terhadap Jenis Label

Model perhitungan objek terbaik pada setiap varietas memiliki jenis label tunggal. Adapun nilai Skor-F1 terbaik pada varietas Siam Pontianak yang diperoleh yaitu, 0,8372 dan nilai Skor-F1 terbaik pada varietas Keprok Terigas sebesar 0,8951. Perbandingan nilai perhitungan objek terhadap model dengan jenis label yang berbeda dapat dilihat pada Tabel 4. Nilai skor-F1 pada label tunggal lebih tinggi dibandingkan dengan label ganda disebabkan adanya pengaruh jumlah kelas dan bias data saat proses pembuatan dataset (Tiyar & Fudholi, 2021).

Tabel 4. Perbandingan Kinerja Model Perhitungan Objek Terhadap Jenis Label

Objek Deteksi	Batch Size	Jenis Label	Akurasi	Presisi	Recall	Skor-F1
Siam	4	Tunggal	0,712	0,853	0,822	0,8372
Pontianak	8	Ganda	0,52	0,695	0,705	0,6999
Keprok	10	Tunggal	0,75	0,913	0,878	0,8951
Terigas	4	Ganda	0,561	0,726	0,741	0,7334

Confusion matrix dari model terbaik pada setiap varietas dalam bentuk gambar berpetak pada label tunggal dapat dilihat pada Gambar 5. Nilai *threshold* pada IoU yang digunakan pada deteksi sebesar 0,6. Hasil TP, FP, dan FN pada Siam Pontianak sebesar 0,87; 1; dan 0,13 sementara itu Hasil TP, FP, dan FN pada Keprok Terigas sebesar 0,93; 1; dan 0,07. Nilai TN tidak dipertimbangkan dalam hal model deteksi objek (Padilla *et al.*, 2020). Hal tersebut dilakukan karena pendeteksi objek yang menjadi tujuan utama, sehingga tidak memerlukan tanda kotak pembatas untuk mendeteksi selain objek pada suatu gambar. Kesalahan prediksi terhadap jenis objek lain pada tiap varietas sebesar 0,13 dan 0,07 artinya, model dapat mendeteksi antara jeruk dengan *background* dengan akurat (Musahada, 2023). Hasil deteksi jeruk dapat dilihat pada Gambar 6.



Gambar 5. Hasil *Confusion Matrix* Siam Pontianak (A) dan Hasil *Confusion Matrix* Keprok Terigas (B)

DAFTAR REFERENSI

- Badan Pusat Statistik. (2024). *Produksi Tanaman Buah-Buahan*. <https://www.bps.go.id/id/statistics-table/2/NjIjMg==/produksi-tanaman-buah-buahan.html>
- Barkah, M. F. (2020). Klasifikasi Rasa Buah Jeruk Pontianak Berdasarkan Warna Kulit Buah Jeruk Menggunakan Metode K-Nearest Neighbor. *Coding Jurnal Komputer Dan Aplikasi*, 8(1). <https://doi.org/10.26418/coding.v8i1.39193>
- Cubero, S., Lee, W. S., Aleixos, N., Albert, F., & Blasco, J. (2016). Automated Systems Based on Machine Vision for Inspecting Citrus Fruits from the Field to Postharvest – a Review. *Food and Bioprocess Technology*, 9(10), 1623–1639. <https://doi.org/10.1007/s11947-016-1767-1>
- Ditria, E. M., Lopez-Marcano, S., Sievers, M., Jinks, E. L., Brown, C. J., & Connolly, R. M. (2020). Automating the Analysis of Fish Abundance Using Object Detection: Optimizing Animal Ecology With Deep Learning. *Frontiers in Marine Science*, 7. <https://doi.org/10.3389/fmars.2020.00429>
- Jung, H.-K., & Choi, G.-S. (2022). Improved YOLOv5: Efficient Object Detection Using Drone Images under Various Conditions. *Applied Sciences*, 12(14), 7255. <https://doi.org/10.3390/app12147255>
- Khairunnas, K., Yuniarno, E. M., & Zaini, A. (2021). Pembuatan Modul Deteksi Objek Manusia Menggunakan Metode YOLO untuk Mobile Robot. *Jurnal Teknik ITS*, 10(1). <https://doi.org/10.12962/j23373539.v10i1.61622>
- Kusuma, T. A. A. H., Usman, K., & Saidah, S. (2021). People Counting for Public Transportations Using You Only Look Once Method. *Jurnal Teknik Informatika (Jutif)*, 2(1), 57–66. <https://doi.org/10.20884/1.jutif.2021.2.2.77>
- Kuznetsova, A., Maleva, T., & Soloviev, V. (2020). *Detecting Apples in Orchards Using YOLOv3 and YOLOv5 in General and Close-Up Images* (pp. 233–243). https://doi.org/10.1007/978-3-030-64221-1_20
- Mulyana, D. I., & Rofik, M. A. (2022). Implementasi Deteksi Real Time Klasifikasi Jenis Kendaraan Di Indonesia Menggunakan Metode YOLOV5. *Jurnal Pendidikan Tambusai*, 6(3), 13971–13982. <https://doi.org/10.31004/jptam.v6i3.4825>
- Murtando, H., Sahiri, N., & Madauna, I. (2016). Identifikasi Karakter Morfologi dan Anatomi Tanaman Jeruk Lokal (Citrus Sp) di Desa Karya Abadi Kecamatan Taopa Kabupaten Parigi Moutong. *Agrotekbis*, 4(6), 642–649.
- Musahada, L. C. (2023). *Komparasi Model Deteksi dan Penghitungan Objek Jeruk Mandarin (Citrus Reticulata Blanco cv Batu 55) dengan Label Tunggal dan Label Ganda Berbasis Convolutional Neural Network Menggunakan YOLOv7*. Universitas Brawijaya.
- Nashrullah, F., Wibowo, S. A., & Budiman, G. (2020). The Investigation of Epoch Parameters in ResNet-50 Architecture for Pornographic Classification. *Journal of Computer, Electronic, and Telecommunication*, 1(1). <https://doi.org/10.52435/complete.v1i1.51>
- Nuha, M. S., & Alexandro H., R. (2022). Pemanfaatan Yolo untuk Pengenalan Kesegaran Buah Mangga. *Joutica*, 7(1), 513. <https://doi.org/10.30736/jti.v7i1.747>
- Padilla, R., Netto, S. L., & da Silva, E. A. B. (2020). A Survey on Performance Metrics for Object-Detection Algorithms. *2020 International Conference on Systems, Signals and Image Processing (IWSSIP)*, 237–242. <https://doi.org/10.1109/IWSSIP48289.2020.9145130>
- Purno, A., & Wibowo, W. (2016). Implementasi Teknik Computer Vision Dengan Metode Colored Markers Trajectory Secara Real Time. *Jurnal Teknik Informatika*, 8(1).
- Shianto, K. A., Gunadi, K., & Setyati, E. (2019). Deteksi Jenis Mobil Menggunakan Metode YOLO Dan Faster R-CNN. *Jurnal INFRA*, 7(1).
- Tiyar, R. I., & Fudholi, D. H. (2021). Kajian Pengaruh Dataset dan Bias Dataset terhadap Performa Akurasi Deteksi Objek. *PETIR*, 14(2), 258–268. <https://doi.org/10.33322/petir.v14i2.1350>

- Tuwo, M., Tambaru, E., & Marianty, N. (2022). Respon Pertumbuhan Biji Jeruk Keprok *Citrus reticulata* Blanco Pada Beberapa Teknik Sterilisasi. *Jurnal Ilmu Alam Dan Lingkungan*, 13(2), 32-39. <https://journal.unhas.ac.id/index.php/jai2>
- Widyawati, W., & Febriani, R. (2021). Real-time detection of fruit ripeness using the YOLOv4 algorithm. *Teknika: Jurnal Sains Dan Teknologi*, 17(2), 205. <https://doi.org/10.36055/tjst.v17i2.12254>
- Zitnick, C. L., & Dollár, P. (2014). *Edge Boxes: Locating Object Proposals from Edges* (pp. 391-405). https://doi.org/10.1007/978-3-319-10602-1_26