



Deteksi Pohon Kelapa Sawit dengan Pendekatan *Deep Learning* pada Citra *Multispectral* di Indonesia

Desta Sandya Prasvita, Mayanda Mega Santoni, Noor Falih

Desta.sandya@upnvj.ac.id, megasantoni@upnvj.ac.id, falih@upnvj.ac.id

Universitas Pembangunan Nasional Veteran Jakarta

Informasi Artikel

Diterima : 5 Feb 2024

Direview : 1 Apr 2024

Disetujui : 23 Apr 2024

Kata Kunci

Deteksi Otomatis, *Deep Learning*, Kelapa Sawit, YOLOv5, Citra Multispektral

Abstrak

Perkebunan kelapa sawit memegang peran penting dalam ekonomi Indonesia, namun masih dihadapkan pada berbagai tantangan, salah satunya adalah tuduhan terkait deforestasi. Solusi untuk menangani permasalahan tersebut adalah dengan memanfaatkan teknologi remote sensing dan *computer vision*. Penggunaan kedua teknologi ini memungkinkan pemantauan otomatis pohon kelapa sawit dari jarak jauh. Penelitian ini berkontribusi dalam penerapan metode *deep learning* menggunakan teknologi *remote sensing* citra *multispectral* untuk deteksi pohon kelapa sawit. Data yang digunakan dalam penelitian ini juga merupakan data baru yang diperoleh dari perkebunan kelapa sawit di Kalimantan Timur, Indonesia. Metode *deep learning* berbasis deteksi objek yang digunakan adalah YOLOv5. Sebanyak enam belas model deteksi YOLOv5 dibangun dari kombinasi fitur citra *multispectral* (RGB, RGN, RBN, dan GBN) dan jaringan YOLOv5 yang berbeda (YOLOv5s, YOLOv5m, YOLOv5l, dan YOLOv5x) pada eksperimen penelitian ini. Model YOLOv5 terbaik untuk mendeteksi pohon kelapa sawit adalah RBN-YOLOv5m, dengan nilai $mAP@50$, $mAP@[0.5,0.95]$, dan $F1$ -score sebesar 78.3%, 44.9%, dan 81.0%. Kombinasi fitur *near-infrared* dan *red band* dapat memberikan informasi mengenai vegetasi sehingga kombinasi tersebut dapat meningkatkan hasil deteksi hanya dengan fitur RGB.

Keywords

Ditulis dengan bahasa Inggris. Maksimum 5 kata kunci (sesuai dengan ruang lingkup jurnal), dipisahkan dengan tanda koma, [Font Cambria 10, spasi tunggal, rata kiri, dan cetak miring]

Automatic Detection, Deep Learning, Palm Oil, YOLOv5, Multispectral Imagery

Abstract

Palm oil plantations play an important role in the Indonesian economy but are still faced with various challenges, including accusations of deforestation. The solution to address this issue is to leverage remote sensing and computer vision technology. The integration of these two technologies enables the automatic remote monitoring of oil palm trees. This research contributes to applying deep learning methods using multispectral image remote sensing technology for oil palm tree detection. The data used in this research is also new data obtained from oil palm plantations in East Kalimantan, Indonesia. The object detection-based deep learning method used is YOLOv5. A total of sixteen YOLOv5 detection models were built from a combination of multispectral image features (RGB, RGN, RBN, and GBN) and different YOLOv5 networks (YOLOv5s, YOLOv5m, YOLOv5l, and YOLOv5x) in this research experiment. The best YOLOv5 model for detecting oil palm trees is RBN-YOLOv5m, with $mAP@50$, $mAP@[0.5,0.95]$, and $F1$ -scores of 78.3%, 44.9%, and 81.0%. The combination of near-infrared and red band features can provide information about vegetation so that this combination can improve detection results using RGB features alone.

A. Pendahuluan

Sejak tahun 2006, Indonesia telah menjadi produsen minyak sawit terbesar di dunia, menyumbang 59% dari produksi global pada tahun 2023. Perkebunan kelapa sawit memegang peran penting dalam perekonomian Indonesia, berfungsi sebagai penyumbang devisa negara dan menyerap tenaga kerja dalam skala yang besar [1]. Meskipun luas lahan perkebunan kelapa sawit dan jumlah produksinya terus meningkat setiap tahun, namun jumlah kelapa sawit yang dihasilkan per hektar belum mencapai target yang diharapkan, bahkan mengalami penurunan dalam empat tahun terakhir [2]. Di Indonesia, peningkatan produksi minyak sawit masih terjadi melalui pembukaan lahan baru, bukan dengan mengoptimalkan lahan yang sudah tersedia. Ekspansi lahan perkebunan kelapa sawit baru menjadi sumber perdebatan. Meskipun memberikan keuntungan ekonomi, namun menimbulkan permasalahan sosial dan dampak negatif terhadap lingkungan hidup. Hal ini juga telah ditegaskan oleh Uni Eropa, terkait dengan isu deforestasi dan pembukaan lahan untuk perkebunan kelapa sawit di Indonesia [3].

Untuk meningkatkan produktivitas dan menjadikan perkebunan kelapa sawit berkelanjutan, program peremajaan perlu terus digalakkan melalui penanaman kembali bibit unggul. Pemantauan dan pendeteksian pohon kelapa sawit penting dilakukan untuk mengetahui produktivitasnya, sehingga pohon-pohon kelapa sawit yang terdeteksi berumur tua dan tidak produktif dapat segera diambil keputusan untuk dilakukan peremajaan. Mengingat luasnya lahan perkebunan kelapa sawit di Indonesia dan sulitnya akses, hal tersebut cukup sulit jika dilakukan manual oleh Manusia. Penerapan *precision farming* dengan memanfaatkan teknologi penginderaan jauh (*remote sensing*) merupakan solusi efektif untuk memantau perkebunan kelapa sawit dari jarak jauh. Dengan didukung dengan metode *computer vision* juga memungkinkan deteksi pohon sawit jarak jauh dilakukan secara otomatis. Dengan menerapkan teknologi ini, diharapkan perkebunan kelapa sawit akan terus berkembang, dengan tetap menjaga kelestarian hutan dan lingkungan, sesuai dengan tujuan optimalisasi penggunaan sumber daya dan perlindungan lingkungan melalui sistem pengelolaan lahan yang mengadopsi teknologi [4].

Beberapa penelitian telah dilakukan dengan menggunakan teknologi *penginderaan jauh* untuk deteksi individu pohon. Teknologi akuisisi penginderaan jauh yang digunakan pada penelitian sebelumnya meliputi akuisisi dengan citra satelit, pesawat terbang, dan *Unmanned Aerial Vehicle* (UAV). Teknologi sensor penginderaan jauh juga semakin berkembang, antara lain sensor foto udara dengan RGB, *multispectral*, dan LiDAR. Telah dilakukan penelitian untuk deteksi pohon kelapa sawit tua dan muda secara otomatis menggunakan satelit WorldView-3 dengan fitur RGB [5]. Teknologi UAV juga telah diterapkan untuk mendeteksi pohon kurma melalui akuisisi gambar menggunakan drone dengan lensa sensor kamera RGB [6], dan masih banyak lagi penelitian yang menggunakan sensor foto udara dengan RGB [7], [8], [9], [10].

Kamera RGB hanya dapat menangkap informasi spektral dalam pita tampak. Maka, untuk mengatasi keterbatasan kamera RGB, dikembangkan teknologi akuisisi sensor multimodal yang memungkinkan peningkatan kemampuan persepsi kamera RGB. Salah satunya dengan menggunakan citra *multispectral* yang menggabungkan data citra RGB dan *near-infrared*. Citra *multispectral* memberikan informasi

gelombang yang tampak oleh mata manusia (pita RGB) dan gelombang yang tidak tampak (pita *near-infrared*). Fitur pada citra *multispectral* juga dapat memberikan informasi indeks vegetasi suatu objek melalui fitur turunannya [11]. Sensor *multispectral* yang diperoleh dengan menggunakan UAV telah diimplementasikan untuk mendeteksi kanopi dan ketinggian pohon secara otomatis [12]. Penelitian juga telah dilakukan untuk deliniasi kanopi pohon menggunakan citra *multispectral* dengan pendekatan Fuzzy [13]. Citra *multispectral* banyak digunakan di bidang pertanian dan perkebunan karena dapat memberikan indeks vegetasi pada objek di permukaan bumi. Salah satu fitur turunan dari citra *multispectral* adalah NDVI (*Normalized Difference Vegetage Index*), yaitu kombinasi matematis antara *red band* dan *infrared band*.

Metode *deep learning* berbasis deteksi objek, seperti R-CNN [14], *Fast R-CNN* [15], *Faster R-CNN* [16], dan YOLO [17], membuat performa deteksi objek semakin meningkat baik dari segi kecepatan dalam mendeteksi objek maupun akurasi. Penelitian untuk deteksi pohon, baik pohon kelapa sawit maupun pohon secara umum, juga telah dikembangkan dengan pendekatan *deep learning* berbasis deteksi objek. Metode YOLO Versi 5 (YOLOv5) telah digunakan untuk deteksi otomatis kerusakan pohon [18]. Penelitian juga telah dilakukan untuk deteksi otomatis pohon kurma menggunakan citra *drone* menggunakan YOLOv5, dan menunjukkan bahwa YOLOv5 memiliki nilai *mAP* yang lebih tinggi dibandingkan metode SSD300, YOLOv3, dan YOLOv4 [6]. Telah dilakukan juga penelitian yang membandingkan pendekatan *deep learning* YOLO dengan pendekatan pengolahan citra digital klasik untuk model deteksi pohon kelapa sawit di Indonesia. Penelitian tersebut menunjukkan performa deteksi lebih tinggi dilakukan dengan menggunakan pendekatan *deep learning* dengan nilai *F1-score* sebesar 91,05%, sedangkan dengan pendekatan pengolahan citra digital klasik hanya sebesar 40,59% [7], [8].

Meskipun sudah banyak penelitian dilakukan terkait deteksi otomatis pohon kelapa sawit, namun penelitian ini tetap menarik untuk dikembangkan, terutama dalam konteks perkebunan kelapa sawit di Indonesia. Selain mempertimbangkan metode deteksi objek yang tepat, peningkatan kinerja deteksi pohon kelapa sawit juga dapat dicapai dengan memanfaatkan sensor *remote sensing* yang sesuai. Oleh karena itu, penelitian ini menerapkan metode *deep learning* berbasis deteksi objek menggunakan YOLOv5 dan memanfaatkan data citra *multispectral* yang cocok diterapkan di bidang pertanian dan perkebunan. Dengan pendekatan ini, diharapkan mampu mengatasi tantangan dalam deteksi pohon kelapa sawit di Indonesia secara lebih efektif, membuka peluang untuk pemahaman yang lebih mendalam tentang kondisi perkebunan kelapa sawit melalui analisis citra *multispectral* yang lebih akurat.

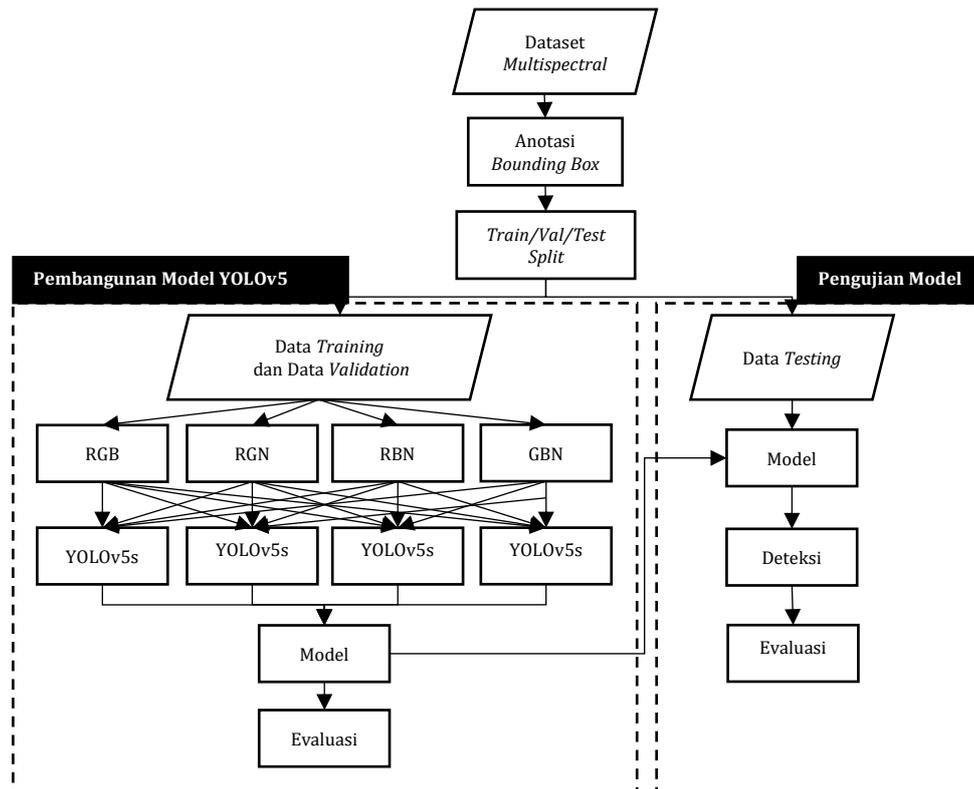
Dalam penelitian ini, terdapat tiga kontribusi utama, yaitu::

1. Penerapan metode *deep learning* pada citra *multispectral* untuk deteksi pohon kelapa sawit. Metode YOLOv5 digunakan sebagai pendekatan *deep learning* berbasis deteksi objek untuk membangun model deteksi pohon kelapa sawit.
2. Penggunaan data baru dari perkebunan kelapa sawit di Kalimantan Timur, Indonesia. Penelitian dilakukan pembuatan *dataset* citra *multispectral* RGBN (red, green, blue, dan *near-infrared*) untuk mendukung penelitian deteksi pohon kelapa sawit di Indonesia ke depan.

- Dilakukan percobaan kombinasi fitur *multispectral* RGBN, untuk mendapat model YOLOv5 terbaik dalam konteks deteksi pohon kelapa sawit.

B. Metode Penelitian

Terdapat empat tahapan yang dilakukan dalam membangun model deteksi pohon kelapa sawit berbasis *deep learning*, yaitu anotasi kotak pembatas (*bounding boxes*), pembagian data *training/validation/testing*, pembangunan model deteksi pohon kelapa sawit dengan YOLOv5, dan pengujian model. Gambar 1 menggambarkan tahapan metode penelitian.

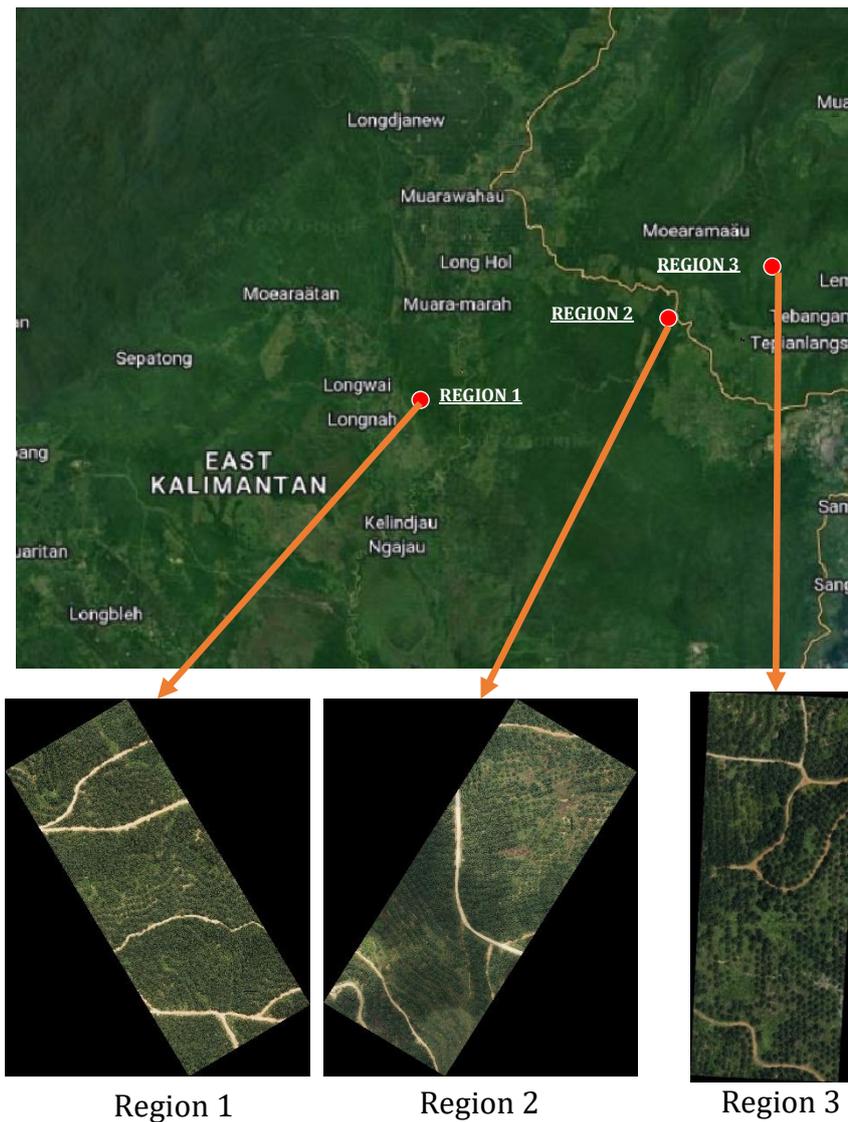


Gambar 1. Metode penelitian

1. Data

Data yang digunakan dalam penelitian ini diperoleh dari tiga wilayah perkebunan kelapa sawit di Kalimantan Timur, Indonesia. Lokasi Wilayah 1 terletak pada koordinat $0^{\circ}43'35.8''\text{LU } 116^{\circ}49'18.0''\text{BT}$, Wilayah 2 berada di koordinat $0^{\circ}47'06.7''\text{LU } 117^{\circ}20'07.6''\text{BT}$, dan Wilayah 3 terletak pada koordinat $0^{\circ}48'05.7''\text{LU } 117^{\circ}22'20.3''\text{BT}$. Setiap wilayah memiliki luas perkebunan sekitar 1 hektar. Lokasi data yang digunakan dapat dilihat pada Gambar 1.

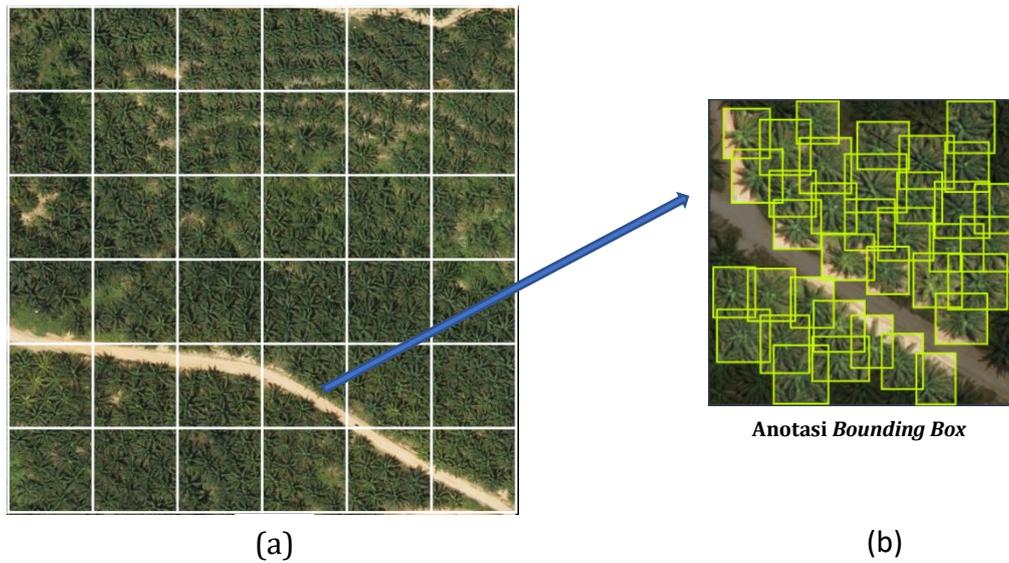
Sensor yang digunakan adalah RGBN *multispectral*. Sensor ini menyediakan pita, yaitu pita *red*, pita *green*, pita *blue*, dan pita *near-infrared* (NIR). Pita RGB memberikan informasi gelombang warna yang dapat ditangkap oleh mata manusia, yaitu antara 400 nm dan 750 nm. Sedangkan pita *near-infrared* menyediakan data gelombang cahaya yang tidak dapat ditangkap oleh mata manusia, yaitu antara 750 dan 2500 nm, di mana mata manusia tidak dapat menangkap gelombang tersebut.



Gambar 2. Lokasi Data yang Digunakan dalam Penelitian

2. Anotasi *Bounding Box* dan Pembagian Data Latih/Validasi/Uji

Pada proses anotasi *bounding boxes* dilakukan pemberian label pada gambar untuk mengidentifikasi objek pohon kelapa sawit, ditandai dengan pembuatan kotak yang membatasi area pohon tersebut. Pembuatan *bounding boxes* (kotak pembatas) dimulai dengan membagi data gambar menjadi n potongan gambar yang lebih kecil dengan ukuran yang sama, yaitu 416×416 piksel, seperti yang terlihat pada Gambar 3(a). Setiap Wilayah menghasilkan potongan gambar yang berbeda, Wilayah 1 menghasilkan 30 potongan gambar, Wilayah 2 menghasilkan 40 potongan gambar, dan Wilayah 3 menghasilkan 30 potongan gambar. Selanjutnya, setiap potongan gambar dilakukan anotasi *bounding boxes*. Proses anotasi dilakukan secara manual dengan bimbingan ahli pohon kelapa sawit, dan secara teknis dilakukan dengan menggunakan alat anotasi *online* Roboflow. Gambar 3(b) menunjukkan contoh hasil anotasi *bounding boxes*.



Gambar 3. Tahap Anotasi Bounding Boxes

Dari keseluruhan *dataset* diperoleh 3.300 anotasi *bounding boxes* pohon kelapa sawit. Tabel 2 berisi informasi dari masing-masing wilayah, jumlah potongan gambar dari masing-masing Wilayah, dan jumlah anotasi *bounding boxes* dari masing-masing Wilayah.

Tabel 1. Hasil Anotasi *Bounding Box*

Region	Image Size	Number of Image Grids	Number of Trees
Region 1	1341x3382 pixels	30	1,168
Region 2	1379x3401 pixels	40	1,251
Region 3	3433x1342 pixels	30	881
Total		100	3,300

Selanjutnya, data dibagi menjadi tiga bagian yaitu data latih, data validasi, dan data uji. Pendistribusian data latih dan data validasi dilakukan secara acak yang diambil dari data Wilayah 2 dan Wilayah 3 dengan proporsi pembagian data sebesar 80% untuk data latih dan 20% untuk data validasi. Sedangkan data pada Wilayah 1 digunakan untuk menguji model yaitu sebagai data uji. Data latih dan data validasi digunakan untuk membangun model YOLOv5 yang dijalankan secara bersamaan selama proses pelatihan. Data latih merupakan data yang digunakan untuk membangun model deteksi pohon kelapa sawit, dan data validasi digunakan untuk menguji model yang dibangun pada setiap *epoch* dalam proses pelatihan. Selanjutnya model yang telah dibuat pada tahap pelatihan akan diuji menggunakan data uji yang menghasilkan metrik evaluasi.

3. Pelatihan Model Deteksi Pohon Kelapa Sawit dengan YOLOv5

Pada penelitian ini, metode YOLOv5 digunakan untuk membangun model deteksi pohon kelapa sawit. Pelatihan model YOLOv5 dilakukan dengan memanfaatkan *transfer learning* dari bobot *pre-trained model* yang dilatih pada kumpulan data besar *Common Objects in Context (COCO)*. *Pre-trained model* dilatih untuk mengenali 80 jenis objek. Pada penelitian ini, model tersebut harus dilatih

untuk mengenali objek dalam *dataset* yang lebih spesifik, yaitu untuk deteksi pohon kelapa sawit. Pelatihan *dataset* pohon kelapa sawit menggunakan 300 *epoch*. Ukuran gambar adalah 416 x 416 piksel, dengan ukuran *batch* 16. Validasi data dilakukan pada setiap *epoch* menggunakan nilai metrik evaluasi *recall*, *precision*, *mAP* dan *F1-score*.

Pengembangan model YOLOv5 untuk deteksi pohon kelapa sawit menggunakan data citra *multispectral* yang terdiri dari empat pita, yaitu *red*, *green*, *blue*, dan *near-infrared* (RGBN). Pada tahap ini dilakukan percobaan untuk menentukan kombinasi fitur terbaik pada bands RGBN dengan menggabungkan ketiga saluran. Penggabungannya dilakukan dengan memilih tiga dari empat saluran *multispectral* RGBN. Tiga saluran dipilih karena pada dasarnya, YOLOv5 hanya menerima input gambar tiga saluran. Ada empat kombinasi fitur untuk mendapatkan model terbaik: RGB, RGN, RBN, dan GBN.

Selain menggabungkan fitur gambar *multispectral*, penelitian ini melakukan eksperimen pada empat versi jaringan YOLOv5, yaitu YOLOv5s (*small*), YOLOv5m (*medium*), YOLOv5l (*large*), dan YOLOv5x (*extra-large*). Perbedaan utama keempat antara versi YOLOv5 adalah terletak pada jumlah modul ekstraksi fitur dan jumlah kernel pada lapisan konvolusi. YOLOv5s memiliki modul dan kernel ekstraksi fitur paling kecil, dan YOLO V5x memiliki modul ekstraksi fitur dan kernel yang paling besar.

Terdapat 16 model deteksi untuk menentukan kombinasi fitur *multispectral* dan jaringan YOLOv5. Tabel 2 menunjukkan 16 model YOLOv5 yang dibangun pada tahap eksperimen ini.

Tabel 2. Model Pembelajaran Mendalam Dibangun pada Tahap Eksperimental Ini

	RGB	RGN	RBN	GBN
YOLOv5s	RGB-YOLOv5s	RGN-YOLOv5s	RBN-YOLOv5s	GBN-YOLOv5s
YOLOv5m	RGB-YOLOv5m	RGN-YOLOv5m	RBN-YOLOv5m	GBN-YOLOv5m
YOLOv5l	RGB-YOLOv5l	RGN-YOLOv5l	RBN-YOLOv5l	GBN-YOLOv5l
YOLOv5x	RGB-YOLOv5x	RGN-YOLOv5x	RBN-YOLOv5x	GBN-YOLOv5x

4. Evaluasi

Data validasi dan data uji digunakan untuk menguji model. Selama proses pelatihan, setiap *epoch* diuji menggunakan data validasi. Setelah model YOLOv5 dibuat, model dievaluasi menggunakan data uji. Pengujian model deteksi objek dilakukan dengan menggunakan metrik evaluasi *Mean Average Precision (mAP)*. *mAP* adalah *Average Precision (AP)* di semua kelas yang terdeteksi. Nilai *AP* hanya untuk setiap kategori. Hitung rata-rata 11 titik interpolasi pada kurva *precision-recall* untuk mendapatkan nilai *AP*. Menurut evaluasi di *challenge COCO 2017*, *mAP* dihitung dengan *AP* rata-rata lebih dari 80 kelas objek dan semua *threshold* 10 IoU dari 0,5 hingga 0,95 dengan ukuran langkah 0,05, yaitu *mAP@[0.5,0.95]*. Perhitungan nilai *mAP* dapat dilihat pada Persamaan (1) dan Persamaan (2).

$$mAP = \frac{1}{n} \sum_{k=1}^n AP_k, \text{ where } n = \text{the number of classes} \quad (1)$$

$$AP_k = \text{the AP of class } k \quad (2)$$

Untuk mendapatkan nilai *AP* diperlukan nilai *precision* dan *recall* untuk membangun *precision-recall curve*. *Precision* adalah rasio prediksi yang benar untuk data positif dibandingkan dengan keseluruhan hasil prediksi positif. Nilai *precision*

dapat dihitung dengan menggunakan persamaan berikut: TP (*true positive*) adalah data positif yang diprediksi dengan benar ke kelas positif, dan FP (*false positive*) diprediksi sebagai objek tetapi salah. Nilai *precision* dapat diperoleh dengan menggunakan Persamaan (3).

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

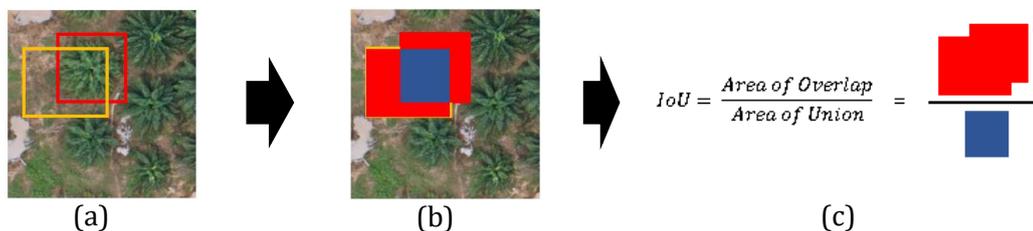
Recall adalah rasio prediksi positif yang benar dibandingkan dengan jumlah total data positif yang benar. Nilai *recall* dapat dihitung menggunakan persamaan berikut, dimana TP (*true positive*) adalah, dan FN (*false negative*) salah memprediksi objek disana. Nilai recall dapat diperoleh dengan menggunakan Persamaan (4).

$$Recall = \frac{TP}{TP+FN} \quad (4)$$

Dalam deteksi objek, nilai TP dan FP ditentukan menggunakan nilai IoU. Nilai IoU digunakan sebagai *threshold*. Jika nilai ambang batas IoU adalah 0,5, dan nilai IoU untuk suatu prediksi adalah 0,7, maka hasil prediksi dinyatakan sebagai TP. Sedangkan jika IoU *threshold* 0,3, untuk FP. Persamaan 4.5 untuk menghitung nilai IoU.

$$IoU = \frac{Area\ of\ Overlap}{Area\ of\ Union} \quad (5)$$

Ilustrasi perhitungan nilai IoU dapat dilihat pada Gambar 5. Gambar 5(a), kotak warna merah merupakan *ground truth* atau label sebenarnya, dan kotak warna kuning merupakan hasil deteksi. Gambar 5(b), area dengan warna merah merupakan *area of overlap*, dan area warna biru adalah *area of union*. Gambar 5(c) merupakan ilustrasi perhitungan nilai *IoU*.



Gambar 5. Ilustrasi perhitungan nilai IoU; (a) Ground Truth; (b) Warna biru merupakan *area of overlap*, dan warna merah merupakan *area of union*

Model yang diharapkan adalah model dengan nilai *precision* dan *recall* yang tinggi. Oleh karena itu, yang ideal untuk mengukur model adalah *F1-Score*. Secara matematis dapat dinyatakan dalam Persamaan (6).

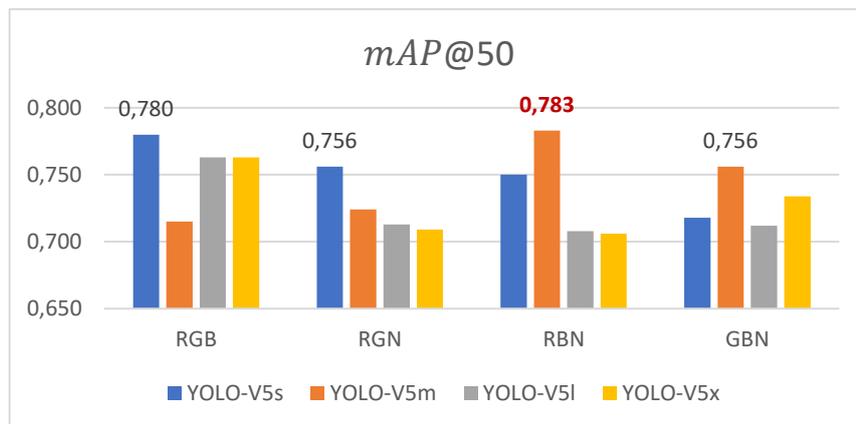
$$F_1 = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (6)$$

C. Hasil dan Pembahasan

Terdapat 16 model YOLOv5 yang dibuat untuk mendapatkan model terbaik untuk deteksi pohon kelapa sawit pada data citra *multispectral*. Model dievaluasi berdasarkan metrik evaluasi dan dari tampilan visual hasil deteksi. Berikut ini merupakan evaluasi model YOLOv5.

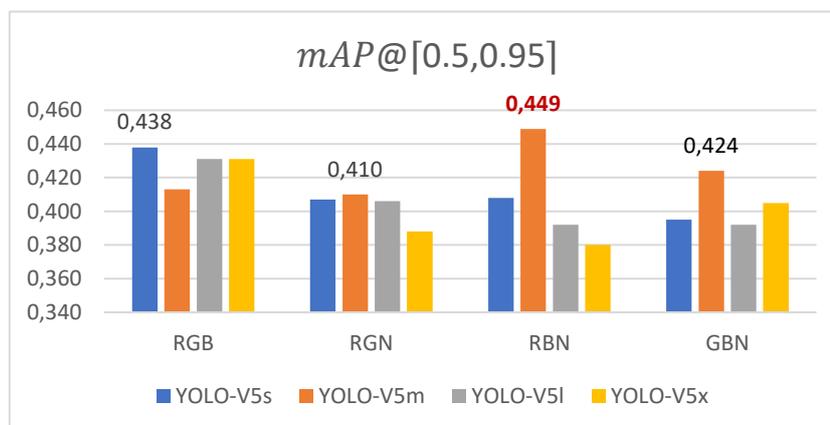
1. Evaluasi Model YOLOv5

Model YOLOv5 dievaluasi menggunakan metrik evaluasi yaitu $mAP@50$, $mAP@[0.5,0.95]$, $recall$, $precision$, $F1-Score$. Yang pertama adalah $mAP@50$, perbandingan $mAP@50$ untuk masing-masing model YOLOv5 dapat dilihat pada Gambar 6. Dari 16 model YOLOv5 yang dibangun, model dengan nilai evaluasi $mAP@50$ tertinggi yaitu dengan mengkombinasikan pita *red*, *blue*, dan *near-infrared* (RBN) pada YOLOv5m. Penggunaan kombinasi fitur RGN pada model YOLOv5 meningkatkan nilai $mAP@50$ dari model fitur RGB, menunjukkan peningkatan sebesar 0,3%. Jika dilihat dari jaringan YOLOv5, jaringan YOLOv5s menghasilkan nilai $mAP@50$ tertinggi untuk fitur RGB dan RGN. Sedangkan untuk fitur RBN dan GBN, jaringan YOLOv5m memiliki nilai $mAP@50$ tertinggi.



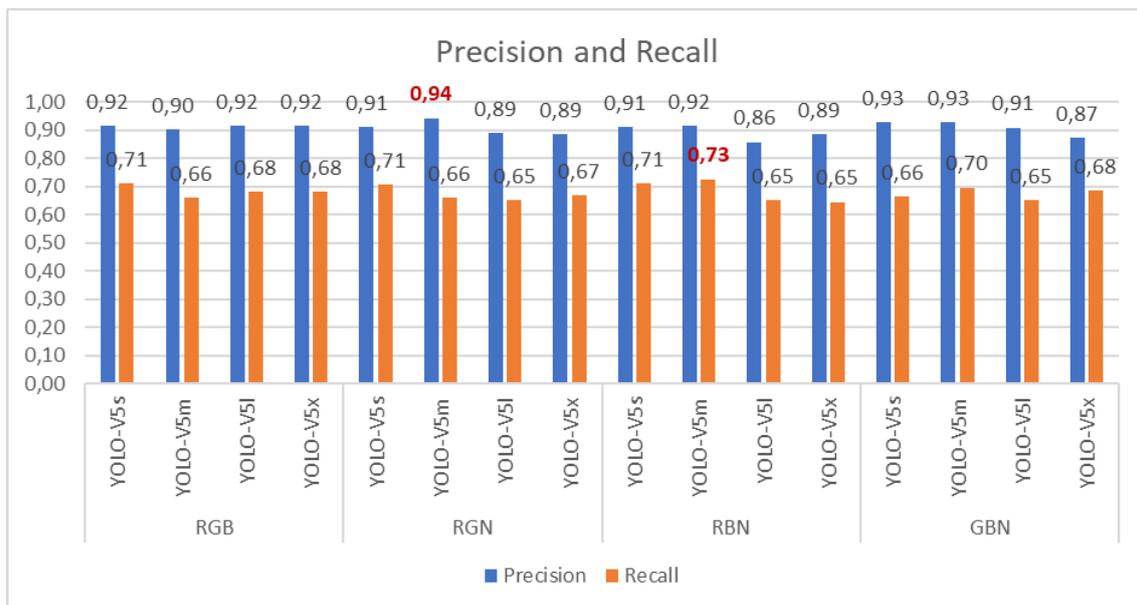
Gambar 6. Perbandingan nilai $mAP@50$ untuk setiap YOLOv5

Perbandingan nilai matriks evaluasi $mAP@[0.5,0.95]$ untuk setiap model YOLOv5 dapat dilihat pada Gambar 7. Pada jaringan YOLOv5s, nilai $mAP@[0.5,0.95]$ tertinggi diperoleh dengan menggunakan fitur RGB, sedangkan pada jaringan YOLOv5m, fitur RBN memberikan nilai tertinggi. Dari semua model deteksi YOLOv5, nilai $mAP@[0.5,0.95]$ tertinggi adalah dengan kombinasi fitur *multispectral* RBN di jaringan YOLOv5m. Penggunaan model dengan fitur RBN meningkatkan nilai $mAP@[0.5,0.95]$ dari model dengan fitur RGB sebesar 1,1%.

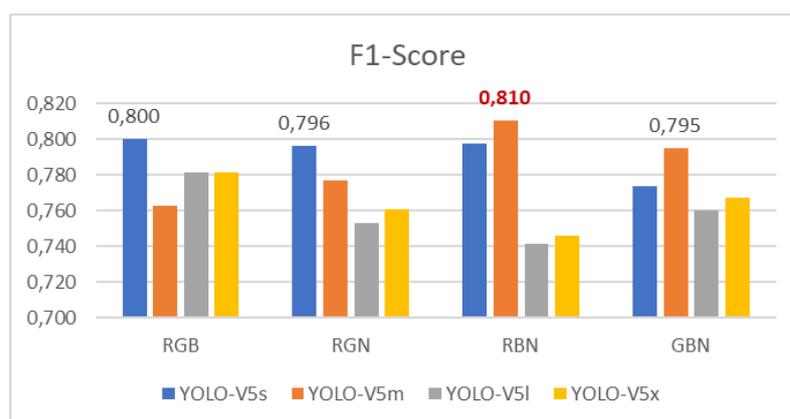


Gambar 7. Perbandingan nilai $mAP@[0.5,0.95]$ untuk setiap YOLOv5

Selain evaluasi nilai *mAP*, juga dilakukan evaluasi nilai *recall* dan *precision* pada model YOLOv5, dapat dilihat pada Gambar 8. Nilai *precision* tertinggi adalah dengan kombinasi fitur *multispectral* RGN dengan jaringan YOLOv5m sebesar 0,94. Sedangkan nilai *recall* tertinggi adalah dengan kombinasi fitur RBN dan jaringan YOLOv5m sebesar 0,73. Namun pada kombinasi fitur *multispectral*, RGN memiliki nilai *recall* yang rendah yaitu 0,66 yang berarti kesalahan deteksi *False Negative* (FN) lebih banyak. Sedangkan kombinasi fitur RBN dengan *recall* yang lebih tinggi mempunyai kesalahan FN yang lebih rendah. Dari hasil ini, dapat dianalisis bahwa kombinasi fitur dengan komponen pita *red* dan pita *near-infrared* (RGN dan RBN), yang menyediakan indeks vegetasi, menghasilkan deteksi yang lebih baik dibandingkan dengan fitur warna RGB.



Gambar 8. Perbandingan nilai Recall dan Precision untuk setiap YOLOv5



Gambar 9. Perbandingan nilai Skor F1 untuk setiap YOLOv5

Selanjutnya adalah evaluasi dengan metrik evaluasi *F1-score*. Pada jaringan YOLOv5s, nilai *F1-score* tertinggi adalah dengan menggunakan fitur RGB, sedangkan pada jaringan YOLOv5m nilai *F1-score* tertinggi adalah dengan menggunakan fitur RBN. Kombinasi fitur *multispectral* RBN memperoleh *F1-score* tertinggi yaitu

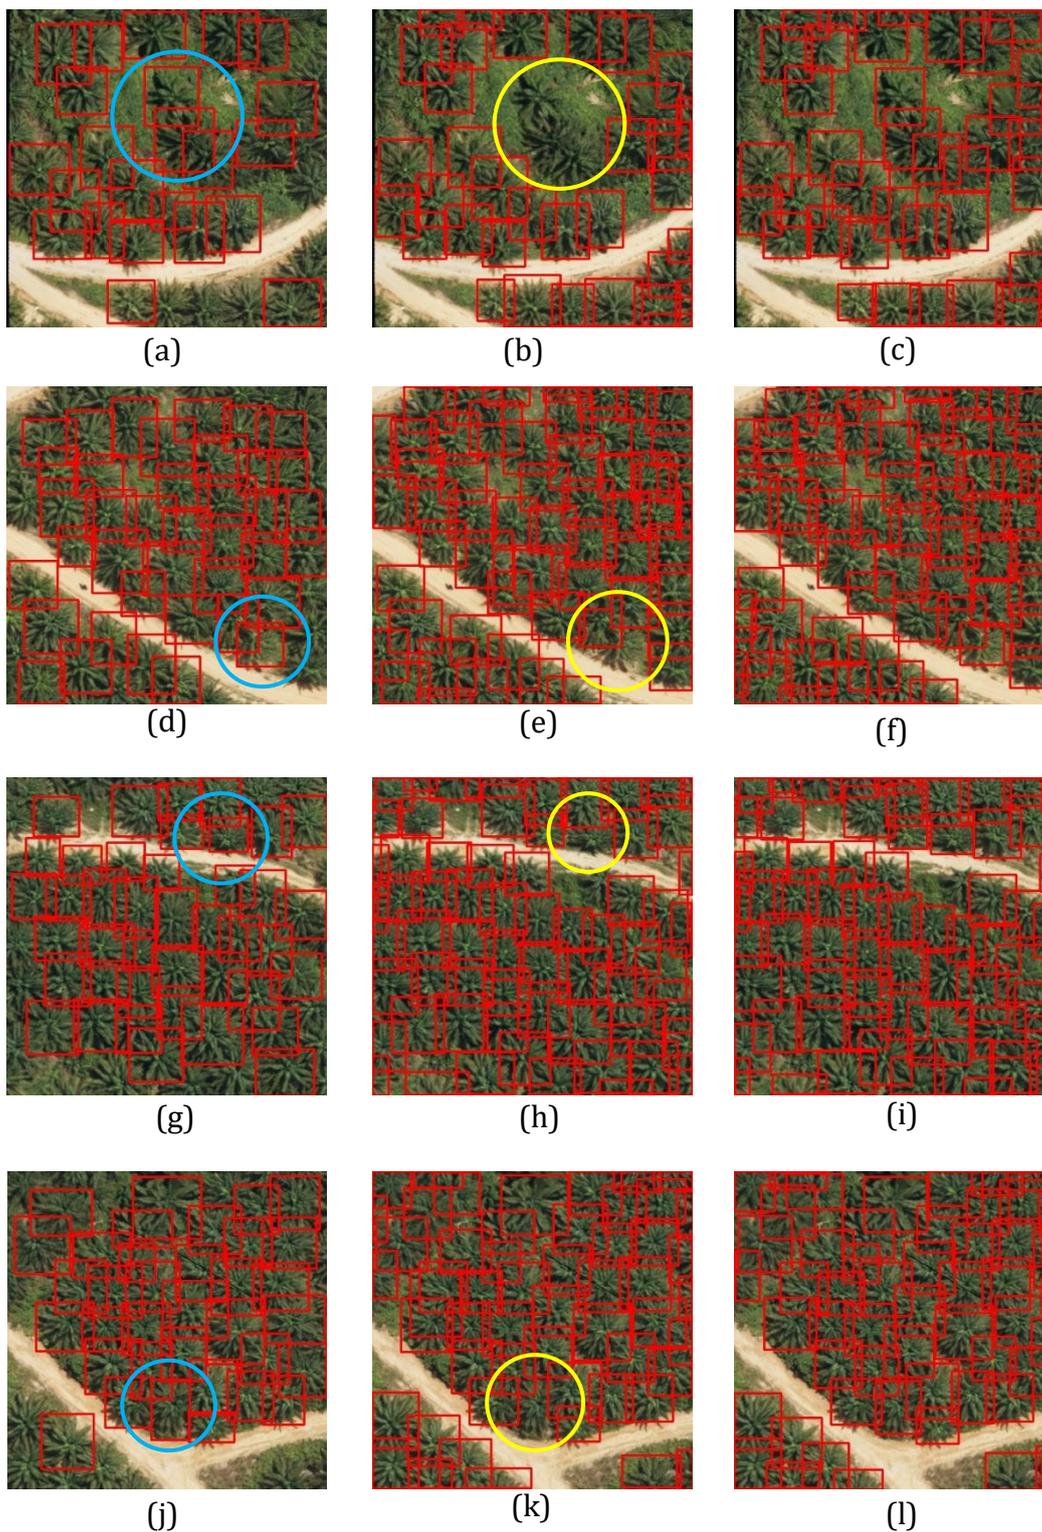
sebesar 0,81. Model kombinasi fitur RBN meningkatkan *F1-score* model fitur RGB sebesar 1% dibandingkan fitur RGB. Sejalan dengan analisis metrik evaluasi sebelumnya, ditegaskan kembali bahwa, berdasarkan *F1-score*, kombinasi fitur pita *red* dan pita *near-infrared* menunjukkan hasil deteksi yang lebih baik dibandingkan dengan fitur warna RGB. Matriks perbandingan *F1-score* untuk masing-masing model YOLOv5 dapat dilihat pada Gambar 9.

Dari kelima nilai pada matriks evaluasi *mAP@50*, *mAP@[0.5,0.95]*, *recall*, *precision*, dan *F1-Score*, kombinasi fitur terbaik adalah dengan komponen *red* dan *near-infrared* yaitu RBN. Meskipun tidak banyak peningkatan nilai matriks evaluasi, namun terlihat bahwa kombinasi fitur *multispectral* dapat meningkatkan hasil evaluasi fitur RGB. Hal ini juga menunjukkan bahwa kombinasi fitur yang memberikan indeks vegetasi (pita *red* dan pita *near-infrared*) mempengaruhi kinerja deteksi pohon kelapa sawit.

2. Evaluasi Hasil Deteksi

Selain evaluasi dengan menggunakan metrik evaluasi, juga dilakukan evaluasi terhadap hasil deteksi. Evaluasi hasil deteksi dilakukan dengan membandingkan tampilan visual dari hasil deteksi. Gambar 10 adalah empat dari tiga puluh gambar pada data uji yang diambil secara acak untuk dievaluasi secara visual. Model jaringan YOLOv5 yang dievaluasi pada tahap ini adalah model jaringan YOLOv5m dengan nilai metrik evaluasi tertinggi, yaitu jaringan YOLOv5m. Hasil deteksi dengan model YOLOv5m dengan fitur RGB (pada posisi tengah pada gambar, Gambar 10(b)(e)(h)(k)) dibandingkan dengan kombinasi fitur RBN (pada posisi kanan pada gambar, Gambar 10(c)(f)(i)(l)), dengan *ground truth* (di posisi kiri pada gambar, Gambar 10(a)(d)(g)(j)).

Hasil deteksi dengan fitur RGB menunjukkan kesalahan *False Negative* (FN) lebih banyak dibandingkan model dengan fitur RBN. Dimana kesalahan FN adalah yang seharusnya terdeteksi sebagai objek pohon kelapa sawit namun terdeteksi sebagai *background*. Seperti terlihat pada Gambar 10, kesalahan deteksi FN ditunjukkan dengan lingkaran kuning. Pada Gambar 10(a), *ground truth* dari salah satu data uji, yang ditandai dengan lingkaran biru, terdapat tiga *bounding boxes* kelapa sawit yang saling tumpang tindih. Hasil deteksi model RGB-YOLOv5m yang ditandai dengan lingkaran warna kuning pada Gambar 10(b), merupakan kesalahan deteksi FN pada model tersebut. Namun pada hasil deteksi model RBN-YOLOv5m, ketiga pohon yang tumpang tindih dapat dideteksi secara tepat. Jadi, dalam kasus objek pohon yang tumpang tindih, menggunakan kombinasi fitur RBN lebih baik daripada kombinasi fitur RGB. Kasus objek pohon yang tumpang tindih juga dapat dilihat pada Gambar 10(j) sebagai *ground truth*, Gambar 10(k) dideteksi menggunakan model RGB-YOLOv5m, dan Gambar 10(l) dideteksi menggunakan model RBN-YOLOv5m.



Gambar 10. Hasil deteksi dari empat sampel data Uji; (a)(d)(g)(j) Kebenaran Dasar; (b)(e)(h)(k) Hasil Deteksi dengan RGB-YOLOv5m; dan (c)(f)(i)(l) Hasil Deteksi dengan RBN-YOLOv5m

Hasil evaluasi lainnya, pada Gambar 10(d) sebagai *ground truth*, yang ditandai dengan lingkaran biru, kelapa sawit pada *bounding boxes* memiliki warna yang agak samar. Dengan menggunakan model RGB-YOLOv5m, pada Gambar 10(e), objek pohon berwarna samar tidak dapat dideteksi, sehingga mengakibatkan kesalahan pendeteksian FN. Namun pada hasil deteksi model RBN-YOLOv5m, pohon dengan warna samar dapat dideteksi secara tepat, seperti terlihat pada Gambar 10(f). Hal tersebut dikarenakan fitur RGB hanya memiliki informasi tekstur dan warna saja. Sedangkan untuk fitur RBN, selain informasi tekstur dan warna, juga terdapat informasi indeks vegetasi suatu objek di permukaan bumi, yaitu gabungan fitur pita *red* dan pita *near-inframerah*. Selain itu, pita *near-infrared* juga memberikan informasi gelombang warna yang tidak dapat ditangkap oleh mata manusia.

Kasus lainnya adalah objek pohon dengan ukuran pohon kelapa sawit yang lebih kecil dibandingkan dengan objek lainnya. Seperti terlihat pada Gambar 10(g) sebagai *ground truth*, terdapat objek pohon kelapa sawit yang ditandai dengan lingkaran biru dengan ukuran pohon lebih kecil. Kesalahan pendeteksian menggunakan model RGB-YOLOv5m, seperti ditunjukkan pada Gambar 10(h), adalah kesalahan FN. Namun pada hasil deteksi model RBN-YOLOv5m, pohon-pohon tersebut dapat terdeteksi secara tepat, seperti terlihat pada Gambar 10(i).

Hasil evaluasi pada tahap ini merupakan penyempurnaan dari hasil evaluasi dengan metrik evaluasi model YOLOv5. Kesalahan deteksi FN pada model YOLOv5 dengan kombinasi fitur RGB menyebabkan nilai *recall* lebih rendah dibandingkan kombinasi fitur RBN. Kombinasi fitur RBN memberikan informasi yang lebih lengkap dibandingkan fitur RGB yaitu warna, indeks vegetasi, dan gelombang warna tak kasat mata. Menggunakan kombinasi fitur RBN lebih baik dalam mendeteksi pohon berwarna samar, pohon yang tumpang tindih, dan objek yang lebih kecil.

D. Simpulan

Hasil percobaan pengembangan model deteksi YOLOv5 menggunakan data *multispectral* menunjukkan bahwa penggunaan data gambar *multispectral* dapat meningkatkan hasil deteksi individu pohon kelapa sawit dengan YOLOv5. Dari hasil percobaan terbukti bahwa kombinasi fitur pada citra *multispectral* RGBN dapat meningkatkan kinerja deteksi. Diperoleh model YOLOv5 terbaik yaitu RBN_YOLOv5m. Model RBN_YOLOv5m memperoleh $mAP@50$, $mAP@[0.5,0.95]$, dan $F1$ -score sebesar 0.783, 0.449, dan 0.810 sehingga meningkatkan nilai $mAP@50$ fitur RGB sebesar 1.1%. Peningkatan kinerja deteksi tersebut dikarenakan pita *near-infrared* dan pita *red* pada sensor *multispectral* dapat memberikan informasi terkait vegetasi.

Penelitian ini masih dalam tahap awal dan perlu pengembangan lebih lanjut. Hasil deteksi pohon kelapa sawit dengan model YOLOv5 masih rendah, dengan nilai $mAP@50$ tertinggi sebesar 0.783 dan $mAP@[0.5,0.95]$ sebesar 0.449. Salah satu caranya untuk meningkatkan kinerja deteksi pohon kelapa sawit adalah dengan menambah *dataset* penelitian dengan kondisi hutan yang lebih bervariasi. Peningkatan hasil evaluasi antar model deteksi YOLOv5 juga tidak terlalu tinggi. Yakni penggunaan fitur RGB dengan fitur RBN meningkatkan $mAP@50$ sebesar 0,3 dan $mAP@[0.5,0.95]$ sebesar 1,1. Pengembangan model yang digunakan adalah model *pre-trained* yang telah dilatih pada dataset COCO yang besar di 80 kelas. Oleh

karena itu, disarankan agar dilakukan upaya optimasi *hyperparameter* YOLOv5 agar 17 model yang digunakan lebih sesuai dengan datasetnya.

E. Ucapan Terima Kasih

Terima kasih kepada UPN Veteran Jakarta atas dukungannya melalui dana hibah penelitian internal. Kontribusi UPN Veteran Jakarta menjadi pondasi penting dalam kemajuan dan kelancaran penelitian ini.

F. Referensi

- [1] Kementerian Perindustrian RI, *Tantangan dan Prospek Hilirisasi Sawit Nasional Analisis Pembangunan Industri*. 2021. Accessed: Jul. 20, 2023. [Online]. Available: <https://kemenperin.go.id/download/28310>
- [2] USDA Foreign Agricultural Service, "Palm Oil Explorer."
- [3] E. Meijaard *et al.*, "Kelapa sawit dan keanekaragaman hayati Analisis situasi oleh Satuan Tugas Kelapa Sawit IUCN," 2018. [Online]. Available: <https://www.iucn-optf.org/>
- [4] E. N. Ginting and D. Wiratmoko, "Potensi dan Tantangan Penerapan Precision Farming dalam Upaya Membangun Perkebunan Kelapa Sawit yang Berkelanjutan," *Warta PPKS*, vol. 26, no. 2, pp. 55–66, 2021, doi: <https://doi.org/10.22302/iopri.war.warta.v26i2.47>.
- [5] N. A. Mubin, E. Nadarajoo, H. Z. M. Shafri, and A. Hamedianfar, "Young and mature oil palm tree detection and counting using convolutional neural network deep learning method," *Int J Remote Sens*, vol. 40, no. 19, pp. 7500–7515, Oct. 2019, doi: [10.1080/01431161.2019.1569282](https://doi.org/10.1080/01431161.2019.1569282).
- [6] T. Jintasuttisak, E. Edirisinghe, and A. Elbattay, "Deep neural network based date palm tree detection in drone imagery," *Comput Electron Agric*, vol. 192, Jan. 2022, doi: [10.1016/j.compag.2021.106560](https://doi.org/10.1016/j.compag.2021.106560).
- [7] Y. C. Putra, A. W. Wijayanto, and G. A. Chulafak, "Oil palm trees detection and counting on Microsoft Bing Maps Very High Resolution (VHR) satellite imagery and Unmanned Aerial Vehicles (UAV) data using image processing thresholding approach," *Ecol Inform*, vol. 72, Dec. 2022, doi: [10.1016/j.ecoinf.2022.101878](https://doi.org/10.1016/j.ecoinf.2022.101878).
- [8] Y. C. Putra and A. W. Wijayanto, "Automatic detection and counting of oil palm trees using remote sensing and object-based deep learning," *Remote Sens Appl*, vol. 29, Jan. 2023, doi: [10.1016/j.rsase.2022.100914](https://doi.org/10.1016/j.rsase.2022.100914).
- [9] J. Martins *et al.*, "SEGMENTATION OF TREE CANOPIES IN URBAN ENVIRONMENTS USING DILATED CONVOLUTIONAL NEURAL NETWORK," in *International Geoscience and Remote Sensing Symposium (IGARSS)*, Institute of Electrical and Electronics Engineers Inc., 2021, pp. 6932–6935. doi: [10.1109/IGARSS47720.2021.9553218](https://doi.org/10.1109/IGARSS47720.2021.9553218).
- [10] J. Zheng, W. Li, M. Xia, R. Dong, H. Fu, and S. Yuan, "LARGE-SCALE OIL PALM TREE DETECTION FROM HIGH-RESOLUTION REMOTE SENSING IMAGES USING FASTER-RCNN," in *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium*, 2019, pp. 1422–1425. doi: [10.1109/IGARSS.2019.8898360](https://doi.org/10.1109/IGARSS.2019.8898360).

-
- [11] Y.-L. Hou, Y. Song, X. Hao, Y. Shen, and M. Qian, "Multispectral pedestrian detection based on deep convolutional neural networks," in *2017 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC)*, 2017.
- [12] Z. Hao *et al.*, "Automated tree-crown and height detection in a young forest plantation using mask region-based convolutional neural network (Mask R-CNN)," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 178, pp. 112–123, Aug. 2021, doi: 10.1016/j.isprsjprs.2021.06.003.
- [13] A. Harikumar, P. D'Odorico, and I. Ensminger, "A Fuzzy Approach to Individual Tree Crown Delineation in Uav Based Photogrammetric Multispectral Data," in *International Geoscience and Remote Sensing Symposium (IGARSS)*, Institute of Electrical and Electronics Engineers Inc., Sep. 2020, pp. 4132–4135. doi: 10.1109/IGARSS39084.2020.9324303.
- [14] R. Girshick, J. Donahue, T. Darrell, and J. Malik, "Rich feature hierarchies for accurate object detection and semantic segmentation," in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, IEEE Computer Society, Sep. 2014, pp. 580–587. doi: 10.1109/CVPR.2014.81.
- [15] R. Girshick, "Fast R-CNN," in *2015 IEEE International Conference on Computer Vision (ICCV)*, IEEE, Dec. 2015, pp. 1440–1448. doi: 10.1109/ICCV.2015.169.
- [16] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," *IEEE Trans Pattern Anal Mach Intell*, vol. 39, no. 6, pp. 1137–1149, Jun. 2017, doi: 10.1109/TPAMI.2016.2577031.
- [17] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection," in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, IEEE Computer Society, Dec. 2016, pp. 779–788. doi: 10.1109/CVPR.2016.91.
- [18] S. Puliti and R. Astrup, "Automatic detection of snow breakage at single tree level using YOLOv5 applied to UAV imagery," *International Journal of Applied Earth Observation and Geoinformation*, vol. 112, Aug. 2022, doi: 10.1016/j.jag.2022.102946.