



Realtime Object Detection Masa Siap Panen Tanaman Sayuran Berbasis Mobile Android Dengan Deep Learning

Andri Heru Saputra¹, Dhomas Hatta Fudholi²

¹Program Studi Informatika Program Magister, Teknologi Industri, Universitas Islam Indonesia

²Jurusan Informatika, Teknologi Industri, Universitas Islam Indonesia

¹18917206@students.uui.ac.id, ²hatta.fudholi@uui.ac.id*

Abstract

Determining the harvesting period can be done visually, physically, computationally, and chemically. Since the harvesting process is crucial, late harvesting will affect post-harvest and production quality. Leafy vegetables have a relatively short ready-to-harvest period. Visual recognition of the harvesting period combined with image processing can recognize harvesting vegetables' visual characteristics. This study aims to build a deep learning-based mobile model to detect real-time vegetable plant objects such as bok choy, spinach, kale, and curly kale to determine whether these vegetables are ready for harvest. Mobile-based architecture is chosen due to latency, privacy, connectivity, and power consumption reason since there is no round-trip communication to the server. In this research, we use MobileNetV3 as the base architecture. To find the best model, we experiment using different image input size. We have obtained a maximum MAP score of 0.705510 using a 36,000 image dataset. Furthermore, after implementing the model into the Android mobile application, we analyze the best practice in using the application to capture distance. In real-time detection usage, the detection can be done with an ideal distance of 5 cm and 10 cm.

Keywords: real-time, object detection, vegetable, harvest, MobileNetV3

Abstrak

Penentuan masa panen dapat dilakukan secara visual, fisik, komputasi, dan kimiawi. Karena proses pemanenan sangat penting, pemanenan yang terlambat akan mempengaruhi pascapanen dan kualitas produksi. Sayuran berdaun memiliki masa siap panen yang relatif singkat. Pengenalan visual masa panen yang dikombinasikan dengan pengolahan citra dapat mengenali karakteristik visual panen sayuran. Penelitian ini bertujuan membangun model ponsel berbasis deep learning untuk mendeteksi objek tanaman sayuran secara *real-time* seperti pakcoy, bayam, kangkung, dan kale keriting untuk mengetahui apakah sayuran tersebut siap dipanen. Arsitektur berbasis seluler dipilih karena alasan latensi, privasi, konektivitas, dan konsumsi daya karena tidak ada komunikasi bolak-balik ke server. Dalam penelitian ini, kami menggunakan MobileNetV3 sebagai arsitektur dasarnya. Untuk menemukan model terbaik, kami bereksperimen menggunakan ukuran *input* gambar yang berbeda. Kami telah memperoleh skor MAP maksimum 0,705510 menggunakan 36.000 dataset gambar. Selanjutnya, setelah mengimplementasikan model ke dalam aplikasi seluler Android, kami menganalisis praktik terbaik dalam menggunakan aplikasi untuk menangkap jarak. Dalam penggunaan deteksi *real-time*, pendeteksian dapat dilakukan dengan jarak ideal 5 cm dan 10 cm.

Kata kunci: *real-time*, deteksi objek, sayuran, panen, MobileNetV3

1. Pendahuluan

Panen dan pasca panen merupakan proses yang tidak dapat dipisahkan dalam pertanian. Panen merupakan rangkaian kegiatan pengambilan hasil budidaya berdasarkan umur dan waktu, dengan cara yang sesuai sifat dan/atau karakter produk. Pasca panen adalah kegiatan yang dilakukan setelah pemanenan agar hasil pertanian siap dan aman untuk diolah oleh lembaga industri atau konsumen [1].

Menentukan waktu panen yang tepat, waktu menentukan “kematangan” yang tepat dan saat panen yang sesuai dapat dilakukan berbagai cara dan pendekatan, yaitu visual, fisik, analisis kimia, dan komputasi atau perhitungan. Secara umum, pertanian sayuran menggunakan komputasi, visual dan fisik dalam memanen sayuran dengan cara memberikan label tanggal pembibitan hingga waktu yang siap dipanen. Kriteria panen dengan cara visual biasanya melihat tanaman sayuran dari perubahan warna, perubahan

bentuk dan ukuran, daun-daun mulai mengering dan buah sudah berkembang penuh.

Tanaman sayuran daun yang ditanam dengan cara hidroponik memiliki waktu panen yang relatif singkat. Tanaman sayuran kale keriting (selanjutnya akan disebut dengan kale saja) memiliki masa panen 55 hari [2], tanaman sayuran kangkung memiliki masa panen 21–30 hari [3], tanaman sayuran bayam memiliki masa panen 25–30 hari [3], tanaman sayuran pakcoy memiliki masa panen 45 hari [3]. Masa panen dapat diperhatikan dari ciri visual perubahan bentuk, warna dan ukuran pada tanaman sayuran daun. Pakcoy memiliki ciri visual masa panen yaitu daun berwarna hijau segar, daun lebar memiliki ukuran 9–15 cm [6], dan batang tanaman keras atau tegak. Masa siap panen kangkung memiliki ciri visual daun sedikit lebar memanjang berwarna hijau segar dan batang tanaman memiliki panjang 20–25 cm [7]. Bayam memiliki ciri visual masa panen daun berwarna hijau segar, lebar daun sedikit besar, dan tinggi tanaman 15–20 cm serta belum berbunga [13]. Tanaman sayuran kale memiliki ciri visual masa panen seperti warna daun hijau segar dan dipinggir daun bergelombang banyak atau keriting, serta ukuran daun lebar memanjang.

Melihat ciri visual yang ada pada tanaman penelitian-penelitian *Artificial Intelligence* (AI) pada bidang pertanian yang membantu dalam proses pengelolaan pertanian. Pengolahan citra di bidang pertanian pada penelitian [4] mendeteksi tingkat kemanisan buah mangga dengan *K-Nearest Neighbor* (KNN) dan *Support Vector Machine* (SVM) berdasarkan data warna. Penelitian ini menggunakan 24 objek dan menghasilkan akurasi KNN dan SVM sebesar 83,3% dan 87,5%. Mendeteksi kecacatan pada buah manggis dengan CNN dilakukan pada [5] dengan hasil rata-rata akurasi yang diperoleh sebesar 98%. Penelitian berikutnya mengenai mengidentifikasi kematangan mentimun berdasarkan tekstur kulit [8]. Metode yang dipakai adalah metode statistik *Mean*, *Variance*, *Skewness*, *Kurtosis* dan *Entropy* yang menghasilkan akurasi prediksi 75% dengan 20 citra [8]. Penelitian yang dilakukan [9] mendeteksi tingkat kematangan tomat berdasarkan warna *Hue Intensity Saturation* (HIS) dan memperoleh akurasi sebesar 94,28%.

Penelitian [10] mendeteksi kematangan buah salak pondoh yang di pohon dengan menggunakan *backpropagation* dan algoritma KNN. Sistem yang dibangun dapat mendeteksi kematangan salak pondoh di pohon berdasarkan warna *Red Green Blue* (RGB) dan *Hue Saturation Value* (HSV) dengan tingkat akurasi sebesar 93%. Penelitian [11] mendeteksi buah yaitu buah paprika dengan menggunakan *faster R-CNN*. Data multi-modal (RGB dan *Near-Infrared* (NIR) digunakan pada penelitian ini yang dapat menghasilkan skor F1 0,838.

Penelitian [12] mengenal kematangan daun selada menggunakan OpenCV berbasis Android berdasarkan warna RGB. Penelitian mengenai deteksi vegetasi dan diskriminasi dalam sayuran *plasticulture row - middles* menggunakan CNN [14] menghasilkan penemuan yang biasa ditemukan di tengah-tengah baris plastik budidaya tanaman Florida (jaringan kelas 3). Vegetasi dibedakan menjadi tiga kategori: daun lebar, alang-alang dan rerumputan. Jaringan 3-kelas ($Fscore = 0,95$) mengungguli jaringan 1-kelas ($Fscore = 0,93$) secara keseluruhan deteksi vegetasi. Penelitian selanjutnya mengenai penggunaan Algoritma YOLOv3 dengan Pre- dan Pasca-Pemrosesan untuk deteksi buah apel di robot pemetik buah [15] waktu mendeteksi 19ms dengan kesalahan obyek yang dianggap apel 7,8 % dan bagian apel yang tidak dikenali 9,8 %.

Penelitian deteksi buah menggunakan peningkatan algoritma K-Means [16] mengidentifikasi buah matang berdasarkan segmentasi warna. Penelitian berikutnya menggunakan Red Green Blue - Depth (RGB-D) dan CNN untuk menilai buah dan sayuran berdasarkan ukuran objek [17].

Penelitian [18] mengembangkan metode deteksi penyakit tomat berbasis jaringan saraf konvolusional dalam dan model deteksi objek. Dua model berbeda, *Faster R-CNN* dan *Mask R-CNN*, digunakan dalam metode ini, dimana *Faster R-CNN* digunakan untuk mengidentifikasi jenis penyakit tomat dan *Mask R-CNN* digunakan untuk mendeteksi dan mensegmentasi lokasi dan bentuk tomat. daerah yang terinfeksi. Untuk memilih model yang paling sesuai dengan tugas deteksi penyakit tomat, empat jaringan *neural* konvolusional dalam yang berbeda digabungkan dengan dua model deteksi objek. Hasil percobaan menunjukkan bahwa model yang diusulkan dapat secara akurat dan cepat mengidentifikasi sebelas jenis penyakit tomat dan menyegmentasikan lokasi dan bentuk daerah yang terinfeksi [18].

Penelitian [19] menggunakan *deep learning* CNN dalam mengklasifikasikan sayuran, dengan hasil akurasi 98,1%. Penelitian [20] mengenai kondisi kematangan buah jeruk berdasarkan kemiripan warna pada ruang warna RGB berbasis android, aplikasi mampu mengenali kondisi kematangan buah jeruk keprok. Masing-masing 2 buah jeruk pada kondisi matang dengan nilai kesesuaian antara 72,94% sampai 82,68%. Selanjutnya 4 buah jeruk pada kondisi mengkal dengan nilai kesesuaian antara 59,09% sampai 81,20% serta 4 buah jeruk pada kondisi mentah dengan nilai kesesuaian antara 69,02% sampai 77,60% [20].

Penelitian mengenai aplikasi deteksi kematangan buah sawit menggunakan metode perbandingan histogram citra, dengan *file* ekstensi gambar buah sawit berupa *bitmap* dan aplikasi Matlab R2010a sebagai *imageprocessing* [21]. Hasil eksperimen dari pengujian aplikasi menunjukkan tingkat akurasi yang baik yaitu

80% untuk pengujian pada buah sawit belum siap panen sedangkan pada buah sawit siap panen juga menunjukkan tingkat akurasi sama yaitu 80% [21].

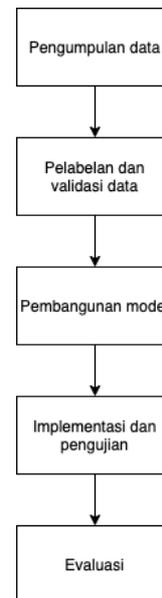
Penelitian selanjutnya mengenai deteksi kematangan buah pisang berdasarkan fitur warna citra kulit pisang ambon menggunakan metode transformasi ruang warna HIS, dalam penelitiannya membahas transformasi dari warna RGB menjadi HIS sehingga hasil penelitian dengan pengujian 20 sampel buah dimana 10 buah pisang ambon mentah dan 10 buah pisang ambon matang dengan dihitung nilai rata-rata maksimal dan minimal H dan S diperoleh akurasi kesesuaian sebesar 85% [22]. Penelitian mengenai deteksi kematangan buah semangka berbasis nilai RGB menggunakan metode *thresholding* [23].

Penelitian mengenai deteksi tanaman tebu pada lahan pertanian menggunakan metode CNN [24] dengan menggunakan *drone* dan menggunakan YOLO mampu menghasilkan penelitian menunjukkan bahwa metode CNN berhasil untuk mendeteksi tebu dengan baik dengan menghasilkan rata-rata nilai *confidence* sebesar 95% pada pengujian video. Pengujian menggunakan pada nilai *threshold* 0.1, menghasilkan skor *precision* sebesar 1.00, skor *recall* sebesar 0.95 dan skor *accuracy* sebesar 0.95 pada tebu [24]. Penelitian dengan klasifikasi citra buah menggunakan CNN dengan menggunakan dataset Fruit-360 [25]. Hasil dari proses *learning* didapatkan model CNN dengan akurasi 100% dan *loss* sebesar 0,012. Pada proses pengujian model CNN yang menggunakan 45 sampel citra buah didapatkan akurasi sebesar 91,42%. Sehingga dapat disimpulkan bahwa metode CNN yang dirancang pada penelitian ini dapat mengklasifikasi citra dengan baik [25].

Pada penelitian ini, kami bertujuan memanfaatkan AI lebih jauh lagi pada bidang pertanian dengan membangun sebuah model *object detection* untuk deteksi masa panen (siap panen atau belum siap panen) tanaman sayuran. Model dibangun dengan arsitektur *mobile* yang mengedepankan faktor *latency*, *privacy*, *connectivity*, dan *power consumption*, karena model berjalan pada perangkat bergerak tanpa harus ada komunikasi dengan server. Penelitian ini menggunakan data tanaman sayuran kangkung, bayam, kale, dan pakcoy. Sumber data tanaman sayuran diperoleh dari PT. Indmira. Basis arsitektur yang dipakai pada pengembangan model ini adalah SSD MobileNetV3. Evaluasi dari model yang dibangun adalah dengan menggunakan skor *Mean Average Precision* (MAP) yang mengukur tingkat akurasi prediksi mengenai deteksi objek kemudian model diimplementasikan ke dalam *mobile*. *Mobile* yang digunakan adalah berbasis android, pemilihan android dikarenakan android merupakan sistem operasi yang mampu berjalan secara *mobile*, alasan lain karena sistem operasi android banyak digemari oleh masyarakat karena sifatnya yang *open source*.

2. Metode Penelitian

Metodologi penelitian yang digunakan untuk penelitian *realtime object detection* masa siap panen tanaman sayuran meliputi pengumpulan data berupa gambar tanaman sayuran, pelabelan dan validasi data, pembangunan model, implementasi dan pengujian serta evaluasi. Alur dalam metode penelitian *realtime object detection* masa siap panen tanaman sayuran seperti Gambar 1.



Gambar 1. Diagram alir metode penelitian

Pengumpulan data gambar adalah gambar tanaman sayuran dengan resolusi 2304 x 4608 dan ekstensi jpg kemudian dilakukan *preprocessing* data seperti menyortir gambar yang tidak sesuai dalam penelitian dan mengubah ukuran resolusi gambar menjadi 512 x 1024. Dari hasil *preprocessing*, data gambar diberi label dengan *tools* LabelImg. Data gambar yang sudah diberikan label kemudian divalidasi oleh ahli pertanian tanaman sayuran, yaitu praktisi tenaga pengajar yang mempelajari tanaman sayuran selama 6 tahun terakhir.

Dalam pembangunan model, pada penelitian objek deteksi masa siap panen tanaman sayuran diperlukan pelatihan model yaitu menggunakan Tensorflow 1.15 GPU dengan konfigurasi SSD Mobilenet v3 large untuk paket *object detection*. Pelatihan model dilakukan dengan membandingkan *input* dengan *image resizer* 320 x 320, 512 x 512, 640 x 640 dan 1024 x 1024, dan evaluasi model untuk mengetahui skor MAP yang menunjukkan tingkat akurasi dalam memprediksi objek. Nilai MAP menunjukkan tingkat akurasi deteksi objek dan letaknya. Nilai ini menjadi parameter utama untuk mengukur akurasi suatu model yang diaplikasikan dan seberapa bagus model tersebut untuk menangani objek tanpa ada kesalahan. Semakin tinggi nilai MAP, semakin tinggi pula akurasi yang didapat, namun sebagai konsekuensinya, kecepatan komputasi menjadi lebih

rendah [20]. Perhitungan akurasi untuk mengetahui nilai tingkat akurasi dalam mendeteksi tanaman sayuran dengan menggunakan persamaan (1).

$$mAP = \frac{1}{N} \sum_{j=1}^N \frac{1}{Q_j} \sum_{i=1}^{Q_j} P(doc_i) \quad (1)$$

dengan Q_j adalah banyaknya dokumen relevan untuk *query* j , N adalah banyaknya *query*, dan $P(doc_i)$ adalah *precision* pada dokumen relevan ke- i .

Setelah melakukan evaluasi model adalah mengimplementasikan model tersebut ke dalam aplikasi android. Aplikasi yang sudah terbangun diuji dengan cara *realtime*. Skenario pengujian aplikasi deteksi masa siap panen pada tanaman sayuran dengan skenario jarak antara ponsel android dan gambar tanaman sayuran, jarak yang digunakan adalah 5 cm, 10 cm, 15 cm, dan 20 cm di mana dari jarak tersebut mendeteksi gambar tanaman sayuran dengan cara *realtime*. Setelah pengujian selesai dilakukan perhitungan mengenai tingkat akurasi dalam mendeteksi masa siap panen (belum atau siap panen) tanaman sayuran. Dalam menghitung tingkat akurasi menggunakan persamaan (2).

$$akurasi = \frac{(TP+TN)}{TP+TN+FP+FN} \quad (2)$$

Keterangan:

True Positive (TP) = Keterangan hasil prediksi tanaman sesuai dengan keterangan tanaman informasi gambar dan keterangan masa siap panen sesuai dengan keterangan masa siap panen informasi gambar.

True Negative (TN) = Keterangan hasil prediksi tanaman tidak sesuai dengan keterangan tanaman informasi gambar dan keterangan masa siap panen tidak sesuai dengan keterangan masa siap panen informasi gambar.

False Positive (FP) = Keterangan hasil prediksi tanaman sesuai dengan keterangan tanaman informasi gambar dan keterangan masa siap panen tidak sesuai dengan keterangan masa siap panen informasi gambar.

False Negative (FN) = Keterangan hasil prediksi tanaman tidak sesuai dengan keterangan tanaman informasi gambar dan keterangan hasil prediksi masa panen sesuai dengan keterangan masa siap panen informasi gambar.

3. Hasil dan Pembahasan

Bagian ini akan dijelaskan hasil dan pembahasan dari proses penelitian yang sudah dilakukan melalui tahapan demi tahapan.

3.1. Data Collection dan Preparation

Data yang diperoleh dari PT. Indmira dengan cara mengambil gambar tanaman sayuran dengan kamera ponsel android VIVO v7 sebanyak 44.000 gambar dengan resolusi 2304 x 4608. Gambar tanaman sayuran yang dikumpulkan adalah tanaman bayam yang belum an yang siap panen, tanaman kale yang belum dan yang

siap panen, tanaman kangkung yang belum dan yang siap panen, dan tanaman kangkung yang belum dan yang siap panen (kalau dari ukuran mulai dari kecil hingga besar). Waktu pengambilan gambar dilakukan pagi hari pukul 08:00 hingga pukul 10:00 supaya gambar tanaman yang diambil adalah tanaman sayuran yang segar bukan yang layu.

Data yang terkumpul sebanyak 44.000 gambar kemudian dilakukan *preprocessing* data dengan cara yaitu menyortir gambar dan mengubah ukuran resolusi gambar. *Preprocessing* data dilakukan supaya data yang digunakan sesuai dengan yang akan diteliti. Penyortiran gambar, gambar yang tidak sesuai dengan kebutuhan maka gambar tidak digunakan dengan cara dihapus. Data gambar yang telah disortir menjadi 40.000 gambar. Langkah selanjutnya adalah mengubah ukuran resolusi gambar. Perubahan ukuran resolusi yang semula dari 2304 x 46308 menjadi 512 x 1024 supaya dalam proses pelatihan model tidak memakan waktu lama. Hasil dari *preprocessing* data kemudian diberikan label dengan *tools* LabelImg. LabelImg adalah *tools* yang digunakan untuk melabel sebuah gambar dengan cara memberikan kotak ke daerah atau area yang akan ditandai sebagai temapt label. Format penyimpanan dari labelImg adalah xml. Pada pelabelan gambar terhadap gambar yang dikumpulkan ada gambar yang memiliki informasi sesuai ciri visual masa panen belum siap panen dan siap panen, ada juga dalam satu gambar itu berisikan belum siap panen saja atau siap panen saja. Format penulisan label yang digunakan adalah nama objek_jenis masa siap panen contoh bayam_belum_siap_panen. Proses pelabelan ini dibantu oleh ahli dalam tanaman sayuran untuk memvalidasi apakah hasil pelabelan sudah sesuai atau belum. Data gambar yang sudah tervaliadiasi dibagi menjadi data latih dan data uji. Total data yang sudah dibersihkan dan terlabel adalah 40.000, data latih 36.000 data dan data uji 4.000 data.

3.2. Pelatihan Model dan Evaluasi Model

Pelatihan model digunakan untuk melakukan ekstrak fitur sehingga komputer mampu mengenali setiap fitur gambar yang sudah terlabeli sebelumnya. Pelatihan model, peneliti menggunakan laptop HP Pavilion dengan spesifikasi core i7 9750h, RAM 16 GB dan GPU NVIDIA GTX-1660Ti 6 GB DDR6 dan framework tensorflow dengan versi 1.15 gpu. Dengan SSD Mobilenet v3 large konfigurasi dalam penelitian ini sebagai berikut:

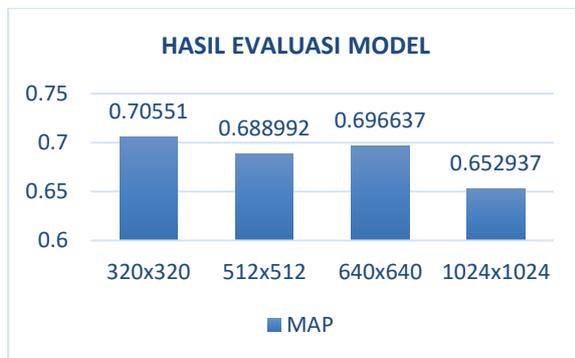
Tabel 2. Konfigurasi SSD Mobilenet v3 Large

No	Image resizer	Num class	Batch size	Num step
1	320 x 320	8	16	50.000
2	512 x 512	8	16	50.000
3	640 x 640	8	16	50.000
4	1024 x 1024	8	16	50.000

Tabel 2 terdapat informasi yaitu *image resizer*, *num class*, *batch size*, dan *num step*. *Image resizer* merupakan yang memiliki ukuran gambar yang akan dirubah

menjadi ukuran 320 x 320, 512 x 512, 640 x 640 dan 1024 x 1024, jadi dari ukuran gambar 512 x 1024 menjadi 320 x 320, 512 x 512, 640 x 640 dan 1024 x 1024 sebagai *input* dalam ekstrak fitur. *Num class* adalah jumlah kelas atau kategori yang akan diteliti, dalam kasus ini peneliti menggunakan delapan kategori yaitu bayam belum siap panen, bayam siap panen, kangkung belum siap panen, kangkung siap panen, pakcoy belum siap panen, pakcoy siap panen, kale belum siap panen, dan kale siap panen. *Batch size* merupakan jumlah sampel data yang disebarkan ke *neural network*, peneliti menggunakan 16 dengan jumlah data 36.000 gambar maka algoritma ini akan menggunakan 16 sampel data pertama dari 36.000 data yang dimiliki kemudian disebarkan atau dilatih oleh *neural network* sampai selesai kemudian mengambil kembali 16 sampel data kedua dari 36.000 data, dan begitu seterusnya sampai 16 sampel data ke 2.250 (36.000 / 16 = 2250). *Num step* adalah jumlah *step* yang dilakukan dalam pelatihan model, jumlah yang digunakan untuk penelitian ini adalah 50.000. Dengan perangkat tersebut untuk melakukan pelatihan model dengan 4 konfigurasi tersebut dibutuhkan waktu 25 hari.

Hal selanjutnya yang dilakukan setelah melakukan pelatihan model adalah melakukan evaluasi model. Evaluasi model ini bertujuan untuk mengetahui jumlah keakuratan prediksi dalam deteksi objek. Hasil evaluasi dari pelatihan model digunakan ke tahap selanjutnya yaitu ekspor model dan konversi ke tflite. Gambar 2 merupakan hasil dari evaluasi dengan menjelaskan mAP untuk mengetahui akurasi dalam pendeteksian objek dengan data uji 4.000 data.



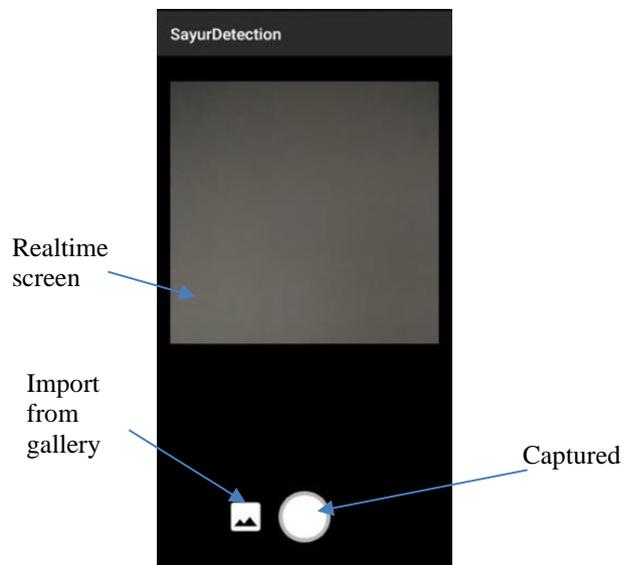
Gambar 2. Grafik MAP Hasil Evaluasi Model

Gambar 2 menunjukkan MAP yang tertinggi adalah dengan *image resizer* 320 x 320 sedangkan MAP paling rendah dari keempat dalam pelatihan model adalah dengan *image resizer* 1024 x 1024. Semakin MAP tinggi maka semakin bagus dalam memprediksi deteksi objek.

3.3. Pengembangan Aplikasi Android

Pengembangan aplikasi android dilakukan setelah melakukan pelatihan model dan evaluasi model. Evaluasi model yang telah dilakukan jadi tahu tingkat keakuratan yang ditunjukkan dengan MAP *score*.

Model yang sudah dilatih di *generate* ke dalam tflite. Hasil *generate* tersebut digunakan dalam pengembangan aplikasi android. Metode perancangan aplikasi android yang digunakan adalah metode *prototype*, metode tersebut sangat cocok dikarenakan aplikasi mengadopsi dari TensorFlow Lite dan lebih cepat penyelesaiannya tinggal uji dengan model sesuai kebutuhan dan apabila pengujiannya kurang sesuai bisa melakukan evaluasi dengan cara mengganti model yang sudah dilatih terlebih dulu kemudian dilakukan pengujian ulang untuk mendapatkan hasil yang sesuai. Dengan mengadopsi Tensorflow lite, *file* hasil *generate* tersebut dimasukkan atau sebagai pengganti *file* bawaan dari tensorflow lite. Pengembangan dari TensorFlow Lite sesuai dengan kebutuhan penelitian ini seperti *realtime detection*, *import from gallery*, dan *captured*. Berikut Gambar 3 tampilan *interface* aplikasi *object detection* masa siap panen tanaman sayuran dan Gambar 4 merupakan hasil mendeteksi objek tanaman sayuran secara *realtime*.



Gambar 3. Interface Aplikasi Android

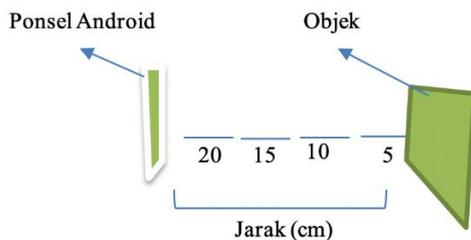


Gambar 4. Hasil Deteksi Tanaman Sayuran Dengan Aplikasi

Cara kerja aplikasi android deteksi siap panen yaitu dengan cara memindai dengan kamera ponsel android melalui aplikasi yang dibangun dengan langsung didapatkan keterangan prediksi hasil pindai selain itu bisa melakukan dengan melakukan ambil dari galeri foto (*import from gallery*) kemudian keterangan prediksi akan muncul dan apabila ingin mengambil gambar hasil deteksi dengan cara *capture*. Gambar 4 menjelaskan hasil deteksi tanaman yang memberikan keterangan jenis tanamannya dan prediksi siap panen beserta presentase tingkat akurasi. Dengan keterangan tersebut bisa diketahui tanaman belum atau siap panen sehingga petani atau pemakai aplikasi ini dapat mengambil tindakan selanjutnya jika sudah siap panen maka hal yang dilakukan adalah persiapan pasca panen sedangkan kalau belum siap panen berarti masih menunggu menuju siap panen. Aplikasi yang sudah siap kemudian dilakukan pengujian untuk memastikan yang terdeteksi itu sesuai atau belum sesuai dengan kenyataan di lapangan. Apabila belum sesuai dilakukan pengecekan terhadap data yang sudah diberikan label dan mengulangi pelatihan model hingga pembangunan aplikasi, jika sudah sesuai maka dilakukan mem-*publish* aplikasi.

3.4. Pengujian

Dalam pengujian ini, peneliti memiliki skenario pengujian yaitu menguji objek dari beberapa jarak antara objek dengan kamera *handphone* android dengan aplikasi deteksi masa siap panen seperti 5 cm, 10 cm, 15 cm, dan 20 cm mengamati langsung dari aplikasi android dengan kamera atau bisa disebut secara *realtime*. Pengujian aplikasi menggunakan *handphone* POCO M3. Dengan menguji berdasarkan jarak dapat diketahui jarak ideal dalam mendeteksi secara *realtime* itu dapat diketahui apakah dalam mendeteksi tanaman sayuran secara *realtime* dari berbagai jarak antara objek dengan kamera ponsel android bisa terdeteksi tanamannya dan keterangan masa panen. Gambar 5 merupakan ilustrasi pengujian aplikasi dalam mendeteksi masa siap panen pada tanaman sayuran.



Gambar 5. Ilustrasi Pengujian Aplikasi

Ilustrasi yang tergambar Gambar 5 terdiri dari objek, jarak dan *handphone* android. Objek yang Gambar 5 berupa gambar tanaman sayuran yang akan dideteksi, jarak pengujian adalah 5 cm, 10 cm, 15 cm dan 20 cm, *handphone* yang digunakan adalah POCO M3. Setelah

melakukan pengujian aplikasi android kemudian menghitung tingkat akurasi.

Tabel 3 merupakan referensi keterangan kelas untuk klasifikasi yang terdiri dari kode dan keterangan. Kode pada Tabel 3 berupa huruf A sampai H yang akan digunakan Tabel 4 dan Tabel 5.

Tabel 3. Singkatan Keterangan Gambar

kode	Keterangan
A	Bayam_belum_siap_panen
B	Bayam_siap_panen
C	Kangkung_belum_siap_panen
D	Kangkung_siap_panen
E	Kale_belum_siap_panen
F	Kale_siap_panen
G	Pakcoy_belum_siap_panen
H	Pakcoy_siap_panen

Pengujian dengan 20 gambar terdiri dari keempat jenis tanaman sayuran yaitu bayam, kale, kangkung, dan pakcoy yang akan diuji dengan aplikasi android deteksi masa siap panen. Data pengujian 20 gambar tersaji pada Tabel 4 yang memberikan informasi dengan kode sesuai dengan Tabel 3. Gambar yang digunakan untuk pengujian ini belum terlabel sehingga dalam pengujian aplikasi android diharapkan mampu mendeteksi masa siap panen pada gambar tersebut.

Tabel 4. Data Pengujian

No.	Gambar	Informasi gambar (kode)
1	Bayam 1	A
2	Bayam 2	A
3	Bayam 3	A
4	Bayam 4	B
5	Bayam 5	B
6	Kangkung 1	D
7	Kangkung 2	C
8	Kangkung 3	C
9	Kangkung 4	C
10	Kangkung 5	D
11	Pakcoy 1	H
12	Pakcoy 2	G
13	Pakcoy 3	G
14	Pakcoy 4	H
15	Pakcoy 5	H
16	Kale 1	F
17	Kale 2	E
18	Kale 3	F
19	Kale 4	F
20	Kale 5	E

Tabel 5 merupakan hasil pengujian dengan berbagai input *image resizer* dan berbagai jarak antara objek dengan *handphone* yang diambil secara *realtime*. Input *image* yang dimaksud di sini adalah saat men-*generate* model ke *tflite*. Keterangan kolom pada tabel hasil pengujian Tabel 5 untuk hasil *realtime* adalah sebagai berikut:

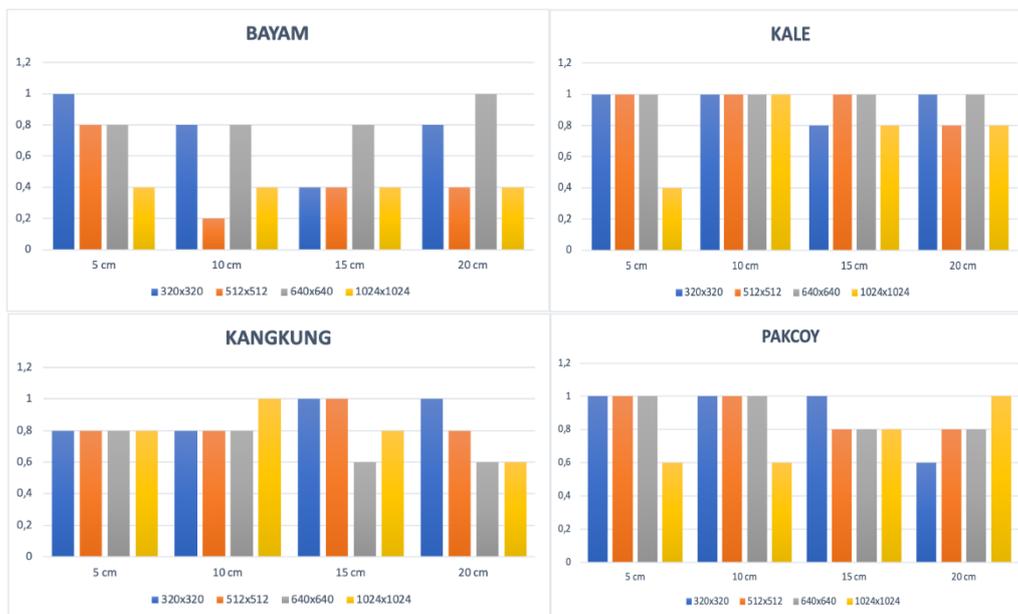
- 5 = Jarak 5 cm
- 10 = Jarak 10 cm
- 15 = Jarak 15 cm
- 20 = Jarak 20 cm

Tabel 5. Hasil Pengujian Aplikasi

Gambar	Pengujian 320 x 320				512 x 512				640 x 640				1024 x 1024			
	5	10	15	20	5	10	15	20	5	10	15	20	5	10	15	20
1	A	A	A	A	A	G	G	A	A	A	A	A	B	A	B	B
2	A	A	B	A	A	G	G	G	A	A	A	A	B	G	G	A
3	A	A	A	A	A	A	A	A	A	A	A	A	A	B	B	B
4	B	A	A	A	A	A	G	H	A	A	A	G	F	F	B	B
5	B	B	A	B	G	H	H	H	B	B	B	B	B	B	G	G
6	C	C	D	D	D	D	D	D	D	D	D	D	D	D	D	D
7	C	C	C	C	C	C	C	C	C	C	C	C	D	C	D	D
8	C	C	C	C	C	C	C	C	C	C	C	C	C	C	C	C
9	C	C	C	C	C	C	C	C	C	C	D	C	D	D	D	D
10	D	D	D	D	C	C	D	C	C	C	C	C	D	D	D	D
11	H	H	H	H	H	H	H	H	H	H	G	G	H	H	H	H
12	G	G	G	G	G	H	G	G	G	G	G	G	G	H	H	G
13	G	G	G	H	G	G	H	D	G	G	G	G	G	G	G	G
14	H	H	H	G	H	H	H	E	H	H	H	H	G	H	H	H
15	H	H	H	H	H	H	H	H	H	H	H	H	G	H	H	H
16	F	F	E	F	F	F	F	F	F	F	F	F	E	F	F	F
17	E	E	E	E	E	E	E	E	E	E	E	E	F	E	E	E
18	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F
19	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F	F
20	E	E	E	E	E	E	E	F	E	E	E	E	F	E	F	F

Dari Tabel 5 hasil uji kemudian dihitung nilai akurasi menggunakan persamaan (2). Dengan memperhatikan keterangan yang ada persamaan (2), dapat membandingkan antara Tabel 4 dan Tabel 5 untuk mengetahui TP, TN, FP, dan FN. Setelah perbandingan

selesai dan didapatkan nilai dari TP, TN, FP, dan FN maka dilakukan perhitungan akurasi dengan persamaan (2). Hasil dari perhitungan akurasi dapat digambarkan dalam grafik yang tersaji Gambar 6.



Gambar 6. Grafik Hasil Akurasi

Gambar 6 terlihat grafik hasil perhitungan akurasi di setiap tanaman sayuran yaitu bayam, kale, kangkung, dan pakcoy, hasil uji coba aplikasi android *object detection realtime* atau mengambil gambar secara langsung melalui kamera ponsel android dengan jarak 5 cm, 10 cm, 15 cm, dan 20 cm serta input 320 x 320, 512 x 512, 640 x 640 dan 1024 x 1024 sesuai dengan pelatihan model. Setelah mengetahui nilai akurasi dari tiap tanaman

seperti Gambar 6 kemudian dicari total akurasi dengan menjumlahkan akurasi di tiap tanaman dengan input yang sama dan jarak pengujian yang sama. Misalkan untuk *input* 320 x 320 dengan jarak pengujian 5 cm adalah akurasi bayam + akurasi kale + akurasi kangkung + akurasi kangkung + akurasi pakcoy = 1 + 1 + 0,8 + 1 = 3,8. Hasil perhitungan dari keseluruhan tersaji dalam Tabel 6. Tabel 6 merupakan hasil dari penjumlahan akurasi keempat tanaman sayuran di tiap *input* dan jarak

pengujian, jumlah akurasi keseluruhan, jumlah pembagian dari jumlah akurasi keseluruhan dengan jumlah data dan total akurasi tiap jarak pengujian.

Tabel 6. Total Akurasi

Input	5 cm	10 cm	15 cm	20 cm	Jumlah akurasi	Jumlah akurasi / jumlah data
320	3,8	3,6	3,2	3,4	14	0,7
512	3,6	3	3,2	2,8	12,6	0,63
640	3,6	3,6	3,2	3,4	13,8	0,69
1024	2,2	3	2,8	2,8	10,8	0,54
Total	13,2	13,2	12,4	12,4		

Tabel 6 terdapat kolom jumlah akurasi/ jumlah data, jumlah data yang dimaksud adalah 20 data pengujian. Dari kolom tersebut dapat diketahui *input* yang bagus dalam mendeteksi masa siap panen pada tanaman sayuran secara *realtime* adalah 320 x320 dengan nilai akhir adalah 0,7 sedangkan *input* yang kurang bagus dalam mendeteksi masa siap panen adalah 1024 x1024 memiliki nilai akhir adalah 0,54.

Dalam menentukan jarak ideal dapat merujuk Tabel 6 yang disajikan pada total. Total yang ada pada Tabel 6 merupakan hasil penjumlahan setiap *input*, dengan nilai yang tertinggi pada total dapat dijadikan sebagai jarak ideal yaitu nilai 13, 2 yang terdapat pada jarak 5 cm dan 10 cm sehingga jarak ideal dalam mendeteksi masa siap panen pada tanaman sayuran adalah jarak 5 cm dan 10 cm.

4. Kesimpulan

Kesimpulan yang dapat diperoleh dari hasil penelitian mengenai deteksi objek untuk masa siap panen pada tanaman sayuran dengan data 36.000 data latih dan 4.000 data uji, pelatihan model dengan konfigurasi SSD Mobilenet v3 large dengan *image resizer* 320 x 320, 512 x 512, 640 x 640, dan 1024 x 1024 menghasilkan nilai MAP tertinggi adalah 0,705510 evaluasi dengan *image resizer* 320 x 320, dan MAP terendah adalah 0,652937 evaluasi dengan *image resizer* 1024 x 1024. Pengujian 20 gambar dengan aplikasi android yang dibangun diperoleh nilai akurasi tertinggi adalah 0,7 pada pengujian *input* 320 x 320, yang menandakan bahwa aplikasi android yang dikembangkan dapat mendeteksi dengan baik sedangkan nilai terendah akurasi adalah 0,54 pada pengujian dengan *input* 1024 x 1024 yang berarti kurang baik dalam mendeteksi masa siap panen pada tanaman sayuran. Hasil evaluasi dan hasil pengujian aplikasi android yang dikembangkan memiliki kesamaan tingkat tinggi rendahnya nilai MAP hasil evaluasi dan nilai akurasi diperoleh dari pengujian aplikasi yaitu 0,7 atau 70 %.

Dari pengujian 20 gambar, jarak ideal untuk mendapatkan hasil yang bagus dalam mendeteksi masa siap panen pada tanaman sayuran khususnya bayam, kale, kangkung dan pakcoy dengan menggunakan aplikasi yang dikembangkan adalah jarak 5 cm dan 10

cm dengan skor 13,2 dari hasil perhitungan total akurasi di tiap *input*.

Pengembangan lebih lanjut dalam aplikasi deteksi objek untuk masa siap panen pada tanaman sayuran, perlu memperhatikan ukuran gambar dan gambar hanya memiliki satu objek saja misalkan tanaman bayam yang belum siap panen saja atau tanaman bayam siap panen saja agar hasil yang didapatkan sesuai dan lebih tepat. Penelitian selanjutnya dapat menggunakan arsitektur lain untuk membandingkan dengan hasil yang peneliti kembangkan.

Daftar Rujukan

- [1] Supristiwendi and M.Azizah, "Pengaruh Penerapan Sistem Agribisnis Terhadap Pendapatan Usahatani Mentimun (cucumis sativus L.) Di Kecamatan Rantau Kabupaten Aceh Tamiang", *J. Penelitian Agrisamudra*, vol. 6, no. 2, pp. 95-103, 2019, doi: 10.33059/jpas.v6i2.244.
- [2] Anonim, "Hidroponik Sayuran Ningrat", *www.trubus-online.co.id*, 2016, [Online]. Available: <https://www.trubus-online.co.id/hidroponik-sayuran-ningrat/>.
- [3] Anonim, "Berapa Umur Sayuran Siap Panen? 10 Jenis Sayuran Ini Paling Cepat Panen!", *klikhijau.com*, 2020, [Online]. Available: <https://klikhijau.com/read/berapa-umur-sayuran-siap-panen-10-jenis-sayuran-ini-paling-cepat-panen/>.
- [4] Ichwan, M., Dewi, I. A., and S. Zeni, M., "Klasifikasi Support Vector Machine (SVM) Untuk Menentukan Tingkat Kemanisan Mangga Berdasarkan Fitur Warna", *MIND Journal*, vol. 3 no. 2, pp. 16-23, 2019, doi: 10.26760/mindjournal.v3i2.
- [5] Marifatul Azizah, L., Fadillah Umayah, S., and Fajar, F., "Deteksi Kecacatan Permukaan Buah Manggis Menggunakan Metode Deep Learning dengan Konvolusi Multilayer", *Semesta Teknika*, vol. 21 no. 2, pp. 230-236, 2018, doi: 10.18196/st.212229
- [6] Marlinda, R., "Cara Panen Pakcoy", *riska2011611048.blogspot.com*, 2018, [Online]. Available: <http://riska2011611048.blogspot.com/2018/03/cara-panen-pakcoy.html#:~:text=Syarat Panen Pakcoy %3A,ketinggian tanaman seragam dan merata.>
- [7] Nofita, V., "Panen Kangkung Lama? Kata Siapa Siihhhh...", *www.pulokambing.com*, 2018, [Online]. Available: <https://www.pulokambing.com/panen-kangkung-lama-kata-siapa-siihhhh/>.
- [8] Permadi, Y., and Murinto, "Aplikasi Pengolahan Citra Untuk Identifikasi Kematangan Mentimun Berdasarkan Tekstur Kulit Buah Menggunakan Metode Ekstraksi Ciri Statistik", *J. Informatika*, vol. 9 no. 1, pp. 1028-1038, 2015, doi: 10.26555/jifo.v9i1.a2044.
- [9] Pratama, R., Assagaf, A. F., and Tempola, F., "Menggunakan Metode Transformasi Ruang Warna His Tomato Fruit Detection Detection Based On Color Features Using His Color Space Transformation Method", *JIKO (Jurnal Informatika dan Ilmu Komputer)*, vol. 2 no. 2, pp. 81-86, 2019, doi: 10.33387/jiko.
- [10] Rianto, P., and Harjoko, A., "Penentuan Kematangan Buah Salak Pondoh Di Pohon Berbasis Pengolahan Citra Digital", *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, vol. 11 no. 2, pp. 143-154, 2017, doi: 10.22146/ijccs.17416.
- [11] Sa, I., Ge, Z., Dayoub, F., Upcroft, B., Perez, T., and McCool, C., "Deepfruits: A fruit detection system using deep neural networks", *Sensors*, vol. 16 no. 8, pp. 1222, 2016, doi: 10.3390/s16081222.
- [12] Septiaji, K. D., and Firdausy, K., "Deteksi Kematangan Daun Selada (*Lactuca Sativa L*) Berbasis Android Menggunakan Nilai RGB Citra", *J. Ilmiah Teknik Elektro Komputer Dan Informatika*, vol. 4 no. 1, pp. 20-27, 2018, doi: 10.26555/jiteki.v4i1.8994.

- [13] Widito, Y, "Cara Menanam Bayam Yang Benar", *kutanam.com*, 2020, [Online]. Available: <https://kutanam.com/cara-menanam-bayam-yang-benar/>.
- [14] Sharpe, Shaun and Schumann, Arnold and Yu, Jialin and Boyd, Nathan, "Vegetation detection and discrimination within vegetable plasticulture row-middles using a convolutional neural network", *Precision Agriculture*, vol. 21, pp. 264–277, 2020, doi: 10.1007/s11119-019-09666-6.
- [15] Kuznetsova, A., Maleva, T., and Soloviev, V, "Using YOLOv3 Algorithm with Pre- and Post-Processing for Apple Detection in Fruit-Harvesting Robot", *Agronomy*, vol. 10 no. 7, pp. 1016, 2020, doi: 10.3390/agronomy10071016.
- [16] Sreekanth, G., Thangaraj, P., and Kirubakaran, S, "Fruit Detection Using Improved K-Means Algorithm", *Journal of Critical Reviews*, vol. 7 no. 12, pp. 5-6, 2020, doi: 10.31838/jcr.07.12.02
- [17] Nishi, T., Kurogi, S., and Matsuo K, "Grading Fruits and Vegetables Using RGB-D Images and Convolutional Neural Network", *IEEE SSCI (Symposium Series on Computational Intelligence)*, pp. 1-6, 2017, doi: 10.1109/SSCI.2017.8285278.
- [18] Qimei Wang, Feng Qi, Minghe Sun, Jianhua Qu, and Jie Xue, "Identification of Tomato Disease Types and Detection of Infected Areas Based on Deep Convolutional Neural Networks and Object Detection Techniques", *Computational Intelligence and Neuroscience*, vol. 2019, pp. 1-15, 2019. doi: 10.1155/2019/9142753.
- [19] Akbar, M., Sardjono, M., Cahyanti, M., and Swedia, E, "Perancangan Aplikasi *Mobile* Untuk Klasifikasi Sayuran Menggunakan *Deep Learning Convolutional Neural Network*", *SEBATIK*, vol. 24 no. 2, pp. 300-306, 2020, doi: 10.46984/sebatik.v24i2.1134.
- [20] Prabowo, H, "Deteksi Kondisi Kematangan Buah Jeruk Berdasarkan Kemiripan Warna Pada Ruang Warna RGB Berbasis Android", *JESIK (Jurnal Elektronik Sistem Informasi dan Komputer)*, vol. 3 No. 2, 2017.
- [21] Yesiansyah, and Murinto, "Aplikasi Deteksi Kematangan Buah Sawit Menggunakan Metode Perbandingan Histogram Citra", *JSTIF (Jurnal Sarjana Teknik Informatika)*, vol. 4 no. 3, 2016, doi: 10.12928/jstie.v4i3.10796.
- [22] Indarto and Murinto, "Deteksi Kematangan Buah Pisang Berdasarkan Fitur Warna Citra Kulit Pisang Menggunakan Metode Transformasi Ruang Warna HIS", *JUITA*, vol. 5 no. 1, pp.15-21, 2017, doi: 10.30595/juita.v5i1.1461.
- [23] Yogi, M., "Aplikasi Deteksi Kematangan Buah Semangka Berbasis Nilai RGB Menggunakan Metode Thresholding", *JURIKOM*, vol. 3 no. 6, pp. 84-89, 2016, doi: 10.30865/jurikom.v3i6.179.
- [24] Asshiddiqie, M., Rahmat, B. and Anggraeny, F., "Deteksi Tanaman Tebu Pada Lahan Pertanian Menggunakan Metode Convolutional Neural Network", *JIFoSi*, vol. 1 no. 1, pp. 229-237, 2020.
- [25] Maulana, F., and Rochmawati, N., "Klasifikasi Citra Buah Menggunakan Convolutional Neural Network", *JINACS*, vol. 01 no. 02, pp. 104-108, 2019.