

PENGEMBANGAN MODEL *MULTILAYER CLASSIFIER* MENGGUNAKAN METODE *ENSEMBLE LEARNING* UNTUK *GRADING BROKOLI*

Zaki Imaduddin¹, Yohanes Aris Purwanto*², Sony Hartono Wijaya³, Shelvie Nidya Neyman⁴

^{1,2,3,4}Institut Pertanian Bogor, Bogor

¹Sekolah Tinggi Teknologi Terpadu Nurul Fikri, Depok, Jawa Barat

Email: ¹assalamualaikumzaki@apps.ipb.ac.id, ²arispurwanto@apps.ipb.ac.id, ³sony@apps.ipb.ac.id,

⁴shelvie@apps.ipb.ac.id

*Penulis Korespondensi

(Naskah masuk: 28 Agustus 2024, diterima untuk diterbitkan: 28 Agustus 2025)

Abstrak

Permintaan brokoli di Indonesia terus meningkat 15% sampai dengan 20% per tahun. Sayangnya *supply* masih terbatas dan kualitas masih kurang. Untuk menentukan kualitas brokoli diperlukan adanya proses *grading* yaitu proses pemeringkat brokoli menjadi *grade A, B* dan *C* berdasarkan tiga parameter utama yaitu warna, ukuran, dan bentuk. Sayangnya, tidak semua petani memahami mengenai proses *grading* tersebut. Hal ini menyebabkan kerugian pada petani dan pengusaha brokoli. Penelitian ini bertujuan untuk mengembangkan algoritma *grading* menggunakan *Convolutional neural network* (CNN) berdasarkan 2 buah citra yaitu citra kepala brokoli dari tampak atas dan tampak samping. *Dataset* pada penelitian ini sebesar 600 data. Teknik yang digunakan ialah modifikasi beberapa model *deep learning* yaitu *ResNet50*, *EfficientNetB2*, *VGG16* pada bagian *layer* klasifikasinya, lalu dibandingkan dengan hasil akurasi dari masing-masing *outputnya*. Penelitian ini juga menggunakan metode *ensemble learning* dimana menggunakan kombinasi dari 3 fitur berbeda. Fitur warna, ukuran dan bentuk digabungkan pada proses *training* dan *testing* untuk melakukan klasifikasi *grade* brokoli. Pada fase *testing* digunakan teknik *voting* untuk pengambilan keputusan *grading*. Akurasi terbaik ada pada model *ResNet50* dengan hasil klasifikasi brokoli sebesar 90% yang didapatkan melalui penggunaan 5 *dense layer* pada *layer* klasifikasi, sehingga mampu melebihi hasil akurasi dari beberapa model *deep learning* lainnya. Algoritma dari penelitian ini menawarkan solusi *grading* yang lebih objektif dan konsisten dibandingkan sistem manual, sehingga petani dan pengusaha brokoli dalam meningkatkan efisiensi, mengurangi kerugian, dan memastikan kualitas produk yang lebih baik bagi konsumen.

Kata kunci: *Grading, Convolution Neural Network, Ensemble Learning, Voting*

DEVELOPMENT OF A MULTI-LAYER CLASSIFIER MODEL USING ENSEMBLE LEARNING METHOD FOR GRADING OF BROCCOLI

Abstract

The demand for broccoli in Indonesia has been increasing by 15% to 20% annually. However, supply remains limited, and quality control is inadequate. To assess broccoli quality, a grading process is required, classifying broccoli into Grades A, B, and C based on three primary parameters: color, size, and shape. Unfortunately, not all farmers possess sufficient knowledge of this grading process, leading to financial losses for both farmers and broccoli businesses. This study aims to develop a grading algorithm using a Convolutional Neural Network (CNN) based on two images, namely a top-view and a side-view image of a broccoli head. The dataset comprises 600 samples. The methodology involves modifying the classification layers of several deep learning models, namely ResNet50, EfficientNetB2, and VGG16, and comparing their classification accuracy. Additionally, an ensemble learning approach is employed, integrating three distinct features—color, size, and shape—into the training and testing phases for broccoli grading. The voting technique is utilized in the testing phase to enhance decision-making in the grading process. Experimental results indicate that the ResNet50 model achieves the highest classification accuracy at 90%, attributed to the incorporation of five dense layers in the classification stage. This performance surpasses that of other deep learning models. The proposed algorithm provides a more objective and consistent grading system compared to manual methods, enabling farmers and broccoli enterprises to enhance efficiency, reduce financial losses, and ensure higher product quality for consumers.

Keywords: *Grading, Convolution Neural Network, Ensemble Learning, Voting*

1. PENDAHULUAN

Brokoli (*Brassica oleracea L. var. italica*) merupakan salah satu tanaman dari genus *Brassica* atau kubis-kubisan. Tanaman ini memiliki bakal bunga mengembang menyerupai kubah berwarna hijau. Bagian atas krop brokoli tersusun dari kuntum-kuntum bunga dengan tangkai yang tebal. Bagian inilah yang dikonsumsi oleh manusia. Selain itu Brokoli mengandung glukosinolat yang sedang diselidiki secara ilmiah dapat mencegah kanker. Karena kandungan nutrisi dan manfaatnya, brokoli dianggap sebagai tanaman sayuran global yang penting dan memiliki permintaan ekspor yang tinggi. Permintaan pasar terhadap tanaman brokoli di USA, China, dan Eropa terus meningkat. Hal ini senada dengan pangsa pasar brokoli di Indonesia, yang meningkat 15-20% per tahun (Raleni, 2015). Permintaan terbesar adalah untuk keperluan restoran-restoran, hotel, pasar modern, dan pasar ekspor. Sayangnya *supply* masih terbatas dan kualitasnya masih kurang.

Untuk menjaga kualitas brokoli sampai kepada masyarakat, petani di Kabupaten Lembang, Bandung melakukan pengelompokan hasil panen brokoli. Pengelompokan dilakukan secara manual. Dalam hal ini mereka akan menyortir brokoli menjadi tingkatan *grade*. Yaitu *grade* A, B, C dan D dengan sejumlah kriteria. Sayangnya, pada prosesnya, hal ini hanya bisa dilakukan oleh petani dan bandar pasar saja, tidak bisa dilakukan oleh masyarakat pada umumnya. Bahkan beberapa petani pun ada masih belum bisa melakukan *grading*, hal ini mengakibatkan belum ada hasil standarisasi kualitas brokoli yang diketahui oleh masyarakat, sehingga menyebabkan kerugian yang bisa berdampak pada petani dikarenakan pemeringkatan atau *grading* brokoli banyak dilakukan di bandar pasar serta masyarakat pun juga akan kesulitan untuk berbisnis atau melakukan produksi brokoli, dikarenakan tidak ada sistem yang membantu dalam proses tersebut. Hal ini penting dikarenakan proses *grading* ini nantinya akan mempengaruhi tahapan selanjutnya yaitu penentuan harga. Penentuan harga didapatkan dari komponen penting dalam menentukan kualitas brokoli yaitu kepala brokoli (Guo et al., 2017). Selain itu kepala brokoli juga dapat memberikan informasi tentang ketahanan tanaman brokoli dalam menghadapi pengaruh lingkungan biotik dan abiotik (Guo et al., 2017). Sejumlah metode pengukuran telah coba dilakukan untuk mengukur kepala brokoli secara kuantitatif seperti dengan menggunakan parameter geometris kering dan berat, analisis spektrometri massa, dan teknik penggunaan sensor non-kontak (Zhou et al., 2020). Metode pengukuran dengan parameter geometris kering-berat tidak direkomendasikan karena dapat merusak kualitas brokoli (Guo et al., 2017).

Saat ini teknik penggunaan sensor non-kontak merupakan salah satu alternatif metode yang

menjanjikan. Sensor non-kontak, yang pada prinsipnya berbasis kamera digital RGB, cocok untuk digunakan di bidang pertanian karena tingginya resolusi, biaya rendah, dan ukuran kecil (Dell'Aquila, 2009). Oleh karena itu, dalam beberapa tahun terakhir ini para peneliti *computer science* mulai mengembangkan sejumlah metode segmentasi dan *grading* tanaman brokoli melalui sensor non-kontak.

Pendeteksian kepala brokoli dengan sensor non-kontak pertama kali dilakukan oleh Ramirez (Ramirez, n.d.). Ia menggunakan kamera RGB dan melakukan analisis berbasis tekstur. Sayangnya, kumpulan datanya dibatasi hingga 13 gambar RGB, yang terlalu kecil untuk mendapatkan kesimpulan apakah algoritma dapat diterapkan di kondisi lapangan terbuka. Penelitian lain yang dilakukan oleh Blok (Blok et al., 2021). adalah menggunakan algoritma *Mask R-CNN* yang mendeteksi 229 dari 232 kepala brokoli yang dapat dipanen dari tiga kultivar. Ia berkesimpulan bahwa algoritmanya dapat digeneralisasikan dengan lebih baik pada beberapa kultivar brokoli. Pada penelitian sebelumnya juga memiliki kontribusi bahwa kombinasi dari *Viewpoint Feature Histogram* (VFH) dan *Support Vector Machine* (SVM), dapat mendeteksi brokoli secara presisi sehingga mempermudah sistem dalam mendeteksi dan mengukur kepala brokoli secara otomatis, sehingga tujuan dalam penentuan waktu panen dapat tercapai (Kusumam et al., 2016). Penelitian terbaru dilakukan oleh Chengquan Zhou (Zhou et al., 2020). yang membuat kumpulan data 100 gambar kepala brokoli diperoleh menggunakan sistem pencitraan yang dikembangkan sendiri dalam kondisi terkontrol. Ia menggunakan algoritma CNN yang bernama *improved resnet* yang dilatih untuk mengekstrak piksel foto brokoli dari backgroundnya kemudian diperkirakan beratnya. Selain itu, *Particle Swarm Optimization Algorithm* (PSOA) dan metode *Otsu* diterapkan untuk menilai kualitas dari brokoli. Penelitian tersebut menghasilkan tingkat akurasi yang baik yaitu 0.896 (Zhou et al., 2020). Keterbatasan dari penelitian Zhou adalah karakteristik data pada penelitian hanya melibatkan kriteria warna saja. Penelitian terbaru lainnya yang dilakukan oleh (Ismail and Malik, 2022). membandingkan penggunaan *ResNet50*, *EfficientNetB2*, *VGG16* dan model *Improved CNN*, untuk menentukan model terbaik dalam menentukan *grading* buah apel dan pisang. Pada penelitian ini *EfficientNet* menghasilkan akurasi yang paling tinggi yaitu 99.2% pada data *training* dan 98.6% pada data *testing*. Keterbatasan dari penelitian ini adalah sistem yang diusulkan oleh peneliti. Kriteria hanya berdasarkan pada tampilan luar buah dan gambar diambil hanya dengan 1 sudut pandang yaitu tampak atas saja.

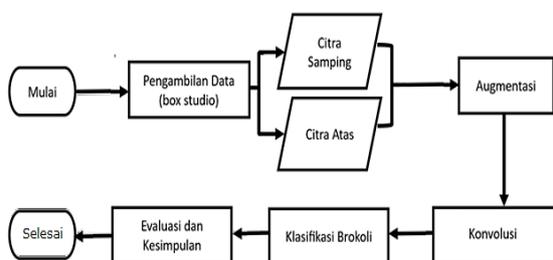
Oleh karena itu, pada penelitian ini akan dilakukan *grading* dengan sejumlah kriteria yang

berbeda dari penelitian sebelumnya. Hal ini dikarenakan adanya perbedaan ciri fisik brokoli produksi dalam negeri dan luar negeri. Kriteria *grading* dalam penelitian ini yaitu bentuk (tingkat kebulatan), warna, ukuran, dan kerapatan kembang (bunga). Selain itu, pengambilan gambar dilakukan dari 2 *view* yaitu tampak atas dan tampak samping. Teknik yang digunakan ialah melakukan modifikasi beberapa model *deep learning* yaitu *ResNet50*, *EfficientNetB2* dan *VGG16*.

Penelitian ini bertujuan untuk mengolah fitur yang berbeda dalam proses *grading* dengan mempertimbangkan tiga aspek utama, yaitu warna, ukuran, dan bentuk. Proses *grading* dilakukan berdasarkan dua citra brokoli, yaitu tampak atas dan tampak samping. Hingga saat ini, belum ada penelitian yang secara khusus menggunakan ketiga fitur tersebut secara bersamaan. Penelitian ini juga menerapkan teknik Ensemble Learning dalam proses pelatihan data. Beberapa model dilatih secara paralel dan bekerja secara independen satu sama lain, sehingga kesalahan yang terjadi pada satu model biasanya berbeda dengan kesalahan pada model lainnya. Dengan demikian, kelemahan atau keterbatasan pada satu model dapat diimbangi atau ditutupi oleh keunggulan model lainnya.

2. METODE PENELITIAN

Penelitian ini memerlukan beberapa tahapan metode untuk menghasilkan klasifikasi kualitas brokoli



Gambar 1. Tahapan Penelitian *Grading* Tanaman Brokoli

Gambar 1 merupakan tahapan penelitian yang akan dilakukan. Ada beberapa tahapan yang akan digunakan pada penelitian ini.

2.1 Akuisisi Data

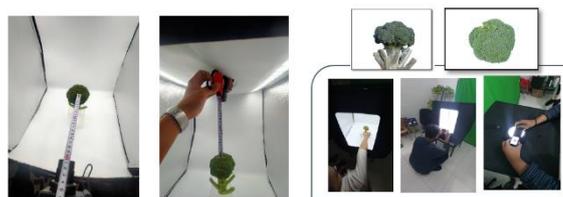
Tahap pertama dalam penelitian ini yaitu kita akan melakukan akuisisi data atau pengambilan *dataset*. *Dataset* ini akan kita ambil ialah berupa data gambar yang dipersiapkan untuk data *training*, data *training* ini kita persiapkan dengan baik untuk mendapatkan hasil *output* yang optimal. dimana kejelasan dan presisi gambar sangatlah dibutuhkan. Human *expert* juga dibutuhkan untuk proses labeling. Setelah data brokoli sudah dipilah atau di labelkan oleh *expert*, langkah selanjutnya ialah dilakukan pengambilan gambar, yaitu dengan

melakukan sesi foto tiap pohon brokoli dengan tampak atas dan tampak samping. Berdasarkan gambar 2, dataset gambar diambil pada waktu pasca panen menggunakan 1 kamera digital dengan pengaturan pencahayaan yang tepat agar brokoli dapat terlihat dan terfoto dengan jelas. Jarak antara kamera dan objek brokoli yaitu sebesar 20 cm dengan background warna putih dan pose yang sudah dikondisikan, hal ini dilakukan karena penelitian ini akan diterapkan pada proses pasca panen, dimana proses *grading* ini dilakukan di dalam ruangan. berdasarkan table 1, jumlah *dataset* yang diambil ialah masing-masing 200 *Grade A,B,C* dan di luar *grade*.

Tabel 1. Jumlah *dataset*

<i>Grade</i>	Tampak Atas	Tampak Samping
<i>Grade A</i>	150	50
<i>Grade B</i>	150	50
<i>Grade C</i>	150	50

Berdasarkan gambar 3, Setiap data gambar memiliki ciri khas dan variasi tertentu, mulai dari warna, ukuran dan bentuk. Dari ciri berdasarkan warna yang ada pada kelas memiliki range tertentu, dimana *grade A, B* dan *C* memiliki variasi tertentu.



Gambar 2. Pengambilan gambar dengan kamera digital menggunakan *box studio*



Gambar 3. Model citra brokoli dari warna, bentuk tampak atas dan samping

Perubahan kelas juga bisa terjadi, dimana, yang seharusnya berdasarkan ukuran dia berada di kelas A, namun karena warnanya agak ke kuningan atau berada di range kelas B maka perubahan kelas itu bisa terjadi. Selain itu bentuk tampak samping juga memegang peranan penting, dimana apabila tampak atas ukurannya dan tingkat kehijauannya berada pada *grade* tertentu, namun apabila dilihat dari tampak samping bentuk *dome* atau kulupnya miring atau tidak rapih, maka *grade* brokoli tersebut akan berubah atau turun tingkat. Berdasarkan penelitian sebelumnya juga dikatakan bahwa bentuk kepala bunga merupakan salah satu kriteria yang sangat penting karena yang diinginkan pasar harus mempunyai kepala bunga yang kompak dan bulat seperti kubah. Massa bunga brokoli harus berbentuk

kubah dan berat saat dewasa, seperti karakteristik brokoli yang diinginkan oleh pasar. Hal ini perlu kita ketahui terlebih dahulu berdasarkan wawancara dengan *expert* dan juga informasi diatas akan kita gunakan pada proses pengumpulan data dan labeling, sehingga data bisa diolah ke tahap selanjutnya. Kemudian dilakukan anotasi data sebelum masuk ke proses augmentasi. Anotasi data yang dilakukan yaitu dengan menginisialisasi objek yang nantinya akan dideteksi dan di segmentasi. Data kemudian di-augmentasi agar data dapat mewakili banyak objek. Proses selanjutnya yaitu konvolusi dan *training* untuk mendapatkan fitur terbaik dengan metode *deep learning*. Selanjutnya hasil dari data *training* akan divalidasi untuk menguji keakuratan model. Setelah itu dilakukan proses *testing* dimana gambar yang *diinput* berupa gambar tampak atas dan tampak samping. Setelah itu dilakukan *filtering* untuk memaksimalkan kualitas gambar. Kemudian dilakukan proses *testing* menggunakan model dari *training* sebelumnya.

2.2 Augmentasi Data

Proses ini digunakan untuk memperkuat proses *training* dengan memperbaiki kualitas gambar dan memfokuskan data objek dari *dataset* dengan proses denoising, kemudian dilakukan metode *augmentation* dimana dalam penelitian brokoli ini, tidak mungkin mengambil cukup banyak gambar karena keterbatasan lahan. Oleh karena itu, untuk meningkatkan kuantitas dan kualitas citra latih, dibutuhkan metode peningkatan jumlah data (Zhou et al., 2020). Metode ini juga digunakan untuk mengurangi *overfitting* yaitu dengan memperbesar *dataset* secara artifisial (Cireşan, Meier and Schmidhuber, 2012). Augmentasi melakukan teknik data warping atau oversampling, dimana data warping ini mengacu pada transformasi data seperti rotasi, pergeseran, *flipping*, perubahan skala, dan lainnya untuk menciptakan variasi *dataset* (Shorten and Khoshgoftaar, 2019).

2.3 Metode Convolutional Neural Network

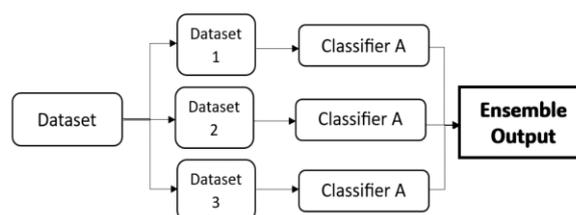
Convolutional Neural Network (CNN) merupakan salah satu variasi *deep learning* yang umum digunakan untuk mengenali objek atau melakukan klasifikasi. Konsep dasar dari CNN adalah mengimplementasikan *convolution* untuk mengekstraksi fitur. Pada Olimpiade *ImageNet* Competition di *Stanford University* tahun 2012, Alex Krizhevsky menemukan bahwa CNN dapat menurunkan kesalahan dalam klasifikasi dari 26,3% menjadi 15,3% (Krizhevsky and Hinton, n.d.). Secara umum CNN terdiri dari dua bagian besar yaitu *Feature Extraction Network* dan *Classifier Network* (*Deep Neural Network*). CNN melakukan konvolusi menggunakan *kernel*, *Relu*, dan *maxpooling* untuk mendapatkan fitur terbaik dari gambar *inputan* yang dilakukan beberapa kali.

Setelah dilakukan konvolusi, hasil dari matriks fitur dijadikan vector vertikal lalu masuk kedalam *fullyconnected layer*. *Fullyconnected layer* terdiri dari beberapa *layer* yang bertujuan untuk menghasilkan *output* untuk kelas-kelas yang dimaksud. Setiap fitur diberikan bobot untuk mendapatkan hasil yang lebih optimal sesuai dengan kelas yang dituju. Penelitian ini menggunakan CNN untuk melakukan klasifikasi mencari hasil *grading* yang paling optimal.

Untuk *grading* brokoli, digunakan metode *Ensemble Learning*, yaitu sebuah metode yang menggabungkan beberapa model prediksi dan melakukan modifikasi jumlah *dense layer*, dimana dari hasil penelitian sebelumnya menyimpulkan bahwa semakin banyak lapisan *dense layer*, maka kinerja klasifikasi akan semakin baik. Model klasifikasi dengan beberapa *dense layer* lebih baik daripada model-model dengan jumlah *dense layer* yang lebih sedikit (Helen Josephine, Nirmala and Alluri, 2021). Untuk menghasilkan klasifikasi yang lebih optimal. penelitian ini mengadopsi teknik *Ensemble Learning* dengan menyertai metode *deep learning* yaitu CNN untuk mendapatkan beberapa model prediksi dari 3 parameter untuk gradig brokoli, yaitu warna, ukuran dan bentuk. Hasil prediksi dari beberapa parameter tersebut nantinya akan dijadikan model klasifikasi untuk proses *testing*.

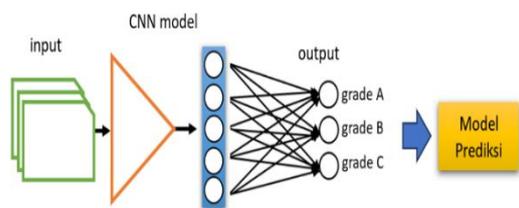
2.4 Metode Ensemble Learning

Metode beberapa model dasar dari hasil klasifikasi digabungkan untuk bekerja bersama dalam mencapai hasil yang lebih baik daripada yang dapat dicapai oleh masing-masing model dasar secara individu. Pendekatan ini bertujuan untuk menggabungkan kekuatan dari berbagai model dan mengurangi kelemahan masing-masing model sehingga dapat menghasilkan prediksi atau hasil yang lebih akurat dan kuat (Kumar et al., 2022). Gambar 4 merupakan sebuah metode *Ensemble Learning* untuk pengolahan sampling data dengan menggunakan beberapa klasifier. Hal mendasar yang perlu diketahui bahwa pemilihan metode pengambilan sampel data adalah salah satu faktor terpenting yang memengaruhi kinerja sistem *Ensemble*. Pada teknik *Ensemble* ini, kita memerlukan keberagaman dalam keputusan pengambilan sampel data dari klasifikasi dasar.



Gambar 4. Homogeneous Ensemble

Ada dua strategi untuk pengambilan sampel *dataset* untuk pelatihan dalam sistem *Ensemble*, yaitu strategi *dataset* independen dan strategi *dataset* dependen (Sagi dan Rokach, 2018). Pada kasus dalam penelitian ini kita menggunakan model *homogeneous Ensemble*, dimana *dataset* yang ada di bagi menjadi 3 bagian, hal tersebut dilakukan untuk menyesuaikan karakteristik data dari penelitian ini, yaitu *grading* brokoli menggunakan 3 parameter, dimana penilaian kualitas brokoli berdasarkan ukuran, warna, bentuk, dan kesegarannya. *Grading* brokoli dilakukan untuk memastikan bahwa brokoli yang dijual ke konsumen memenuhi standar kualitas yang ditetapkan. Berdasarkan penelitian sebelumnya juga di katakan bahwa bentuk kepala bunga merupakan salah satu kriteria yang sangat penting karena yang diinginkan pasar harus mempunyai kepala bunga yang kompak dan bulat seperti kubah (Puji Astutik and Respatijarti, n.d.). Massa bunga brokoli harus berbentuk kubah dan berat saat dewasa, seperti karakteristik brokoli yang diinginkan oleh pasar.



Gambar 5. Model Asitektur CNN

Gambar 5 merupakan model arsitektur yang akan diterapkan pada sistem *grading* ini. dimana pada fase *training* kita mencari model prediksi terbaik dari tiap-tiap parameter berdasarkan fitur warna, ukuran dan bentuk yang datanya diambil dari tampak samping. Kemudian hasil prediksi terbaik dari fase *training* tersebut disimpan untuk dijadikan model klasifikasi untuk proses *testing*.

2.5 Metode Voting

Metode *voting* digunakan untuk menggabungkan hasil dari beberapa model dengan tujuan meningkatkan kualitas prediksi, metode ini memanfaatkan keragaman hasil prediksi untuk memaksimalkan model klasifikasi agar dapat bekerja lebih optimal. dan metode ini memiliki berbagai varian, termasuk *max voting*, *averaging voting* dan *weighted average voting*. Teknik *voting* dipilih untuk menyesuaikan dengan metode *grading* manual yang selama ini dilakukan di lokasi penelitian.

2.6 Evaluation Model

Nilai akurasi tidak cukup sebagai bukti bahwa model yang dirancang sudah cukup baik untuk membuat prediksi yang andal. Alasannya adalah akurasi tidak mampu membedakan jenis-jenis kesalahan klasifikasi yang beragam.

Untuk itu pada klasifikasi multi kelas dengan tiga kelas yang berbeda dilakukan perhitungan presisi, *Recall* dan *F1-score* untuk setiap kelas secara terpisah dengan memperhatikan *true negative* (TN), *true positive* (TP), *false positive* (FP), dan *false negative* (FN) untuk masing-masing kelas.

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

Rumus Akurasi (Acc) ialah menghitung jumlah elemen dari *True positive* dan *True Negative* sebagai pembilang, dan jumlah semua kolom pada *Confusion matrix* sebagai penyebut. True Positives dan *True Negatives* adalah elemen yang diklasifikasikan dengan benar oleh model dan terletak di diagonal utama matriks kebingungan, sedangkan penyebut juga mempertimbangkan semua elemen di luar diagonal utama yang salah diklasifikasikan oleh model. Dengan kata lain, Akurasi mengukur sejauh mana model mampu mengklasifikasikan dengan benar baik kasus positif maupun kasus negatif, dibandingkan dengan seluruh pengamatan yang ada. (Grandini, Bagli and Visani, 2020)

$$Precision = \frac{TP}{(TP + FP)} \quad (2)$$

Precision mengukur seberapa akurat model dalam mengidentifikasi kasus positif. Semakin tinggi *Precision*, semakin sedikit kasus negatif yang salah diklasifikasikan sebagai positif oleh model. *Precision* membantu kita memahami sejauh mana model kita dapat menghindari memberi label positif pada hal-hal yang sebenarnya negatif.

$$Recall = \frac{TP}{(TP + FN)} \quad (3)$$

Recall (*Recall* atau *Sensitivitas*) adalah seberapa baik model mampu mengidentifikasi semua kasus positif yang sebenarnya ada dalam data. Dalam kata lain, *Recall* mengukur sejauh mana model dapat "mengingat" atau "mengenali" semua kasus positif yang sebenarnya ada. Ini adalah metrik yang penting karena kita ingin memastikan bahwa model tidak melewatkan kasus positif yang penting. Semakin tinggi nilai *Recall*, semakin baik model dalam menangkap semua kasus positif yang ada.

$$F1 - score = 2 \cdot \frac{(precision \times recall)}{precision + recall} \quad (4)$$

Nilai *F1-score* mencapai yang terbaik ketika model memiliki Presisi dan *Recall* yang tinggi. Ini mengindikasikan bahwa model secara baik mengidentifikasi kasus positif dan mengenali semua kasus positif yang ada dalam data. Sebaliknya, *F1-score* mencapai yang terburuk ketika baik Presisi maupun *Recall* rendah, menunjukkan kinerja model yang buruk. Dengan demikian, *F1-score*

memberikan gambaran tentang sejauh mana model dapat mencapai keseimbangan antara Presisi dan Recall, di mana nilai 1 adalah yang terbaik, dan nilai 0 adalah yang terburuk.

Confusion matrix adalah alat yang sangat penting dalam evaluasi performa model klasifikasi karena itu memberikan informasi yang jelas tentang sejauh mana model berhasil atau gagal dalam membedakan antara kelas-kelas yang berbeda. Ini memungkinkan kita untuk mengukur akurasi, kemampuan model dalam menghindari *false positive* dan *false negative*, serta memberikan wawasan yang berguna dalam peningkatan model. Dengan kata lain, matriks kebingungan adalah langkah awal dalam menganalisis dan memahami kinerja model klasifikasi.

		Prediksi		
		A	B	C
Aktual	A	TPA	EBA	ECA
	B	EAB	TPB	ECB
	C	EAC	EBC	TPC

Gambar 6. Hasil evaluasi performa klasifikasi

Gambar 6 merupakan contoh *Confusion matrix* untuk 3 kelas, dimana diagonal biru merepresentasikan prediksi yang benar, sementara yang berwarna merah mewakili prediksi yang salah. Jika data sampel dinyatakan positif dan diprediksi hasilnya positif maka hal itu dinyatakan sebagai *true positif* (TP), namun apabila prediksi negatif maka disebut sebagai *false negatif* (FN). Jika sampel datanya sebenarnya negatif dan di prediksi hasilnya negatif maka hal tersebut dinyatakan *true negatif* (TN), jika sample tersebut negatif tapi diprediksi hasilnya positif, maka hal tersebut dinyatakan sebagai (FP) (Tharwat, 2018).

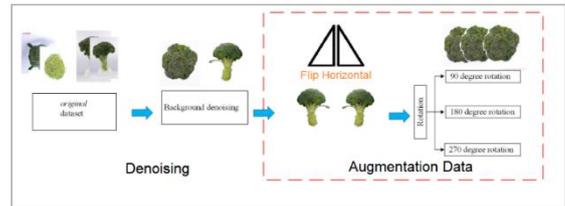
Gambar diatas merupakan contoh matriks multi class, yang terdiri dari kelas A, B dan C. pada gambar kolom TPA diartikan sebagai true positif, dimana kelas yang diprediksikan sesuai dengan kelas sebenarnya (aktual). Sedangkan untuk mengetahui *false negatif* pada kelas A ialah $FN_A = (E_{BA} + E_{CA})$ dan false positif dihitung berdasarkan $FP_A = (E_{AB} + E_{AC})$.

3. HASIL DAN PEMBAHASAN

3.1 Augmentasi Data

Seluruh *dataset* yang sudah diklasifikasikan secara manual oleh petani brokoli (*expert*) dan dilakukan pengambilan gambar satu persatu di dalam *photobox*, selanjutnya dikumpulkan dalam folder dan folder tersebut dikelompokkan gambarnya berdasarkan *grade* A, B dan C, lalu dilakukan *denoising* atau dibersihkan gambarnya

dan dilakukan Augmentasi seperti yang terlihat pada gambar di bawah ini.



Gambar 7. Augmentasi Data

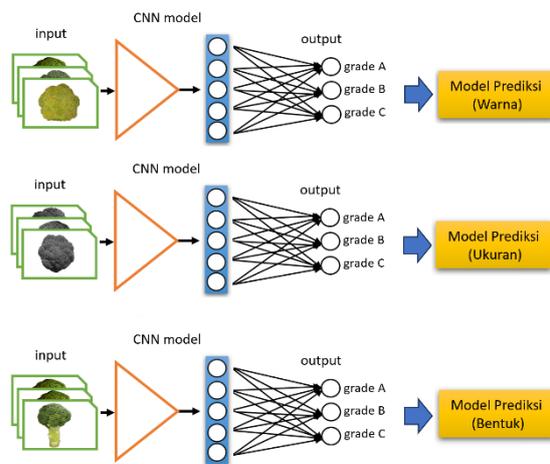
Gambar 7 menunjukkan beberapa teknik augmentasi data, dimana data tersebut akan dilakukan beberapa pemodelan diantaranya ialah dengan melakukan *flip horizontal* dan sistem rotasi. Seperti yang sudah dijelaskan sebelumnya metode ini digunakan untuk memperbanyak jumlah data karena dalam hal ini juga metode CNN cukup optimal bekerja dalam *dataset* yang besar, selain itu juga metode ini juga digunakan untuk mengurangi *overfitting* pada proses *training*. Untuk teknik *flipping* dilakukan rekayasa data dengan cara yang sederhana seperti menduplikat dengan metode pencerminan gambar (*flipping horizontal*). Dengan cara ini, kita dapat menghasilkan versi baru dari data yang awalnya ada, sehingga dapat membangun model data yang baru dan optimalisasi dalam analisis atau pelatihan model (Alomar, Aysel and Cai, 2023). Setelah data di augmentasi kemudian dilakukan *splitting* data dimana data training dibagi menjadi sebesar 80% dan data testing sebesar 20%.

3.2 Ensemble Deep learning

Penelitian ini menggunakan metode *Ensemble Deep learning*, dimana *dataset* dibagi menjadi 3 kategori yaitu warna, ukuran dan bentuk. dan pada kategori warna dibagi lagi menjadi 3 kelas berupa *grade A*, *grade B* dan *grade C*. menggunakan hasil foto dari tampak atas. Kemudian *inputan* kedua yaitu gambar brokoli yang juga dari tampak atas, yang juga dibagi menjadi 3 kelas, mulai dari *grade A*, yang memiliki ukuran paling besar hingga *grade C* yang memiliki ukuran paling kecil. dan pada *grade B* ini ada juga data brokoli yang turun kelas, dimana semula adalah *grade A* menjadi *grade B*, dikarenakan warnanya sudah tidak memenuhi kategori warna dari *grade A*, atau dengan kata lain warnanya sudah agak menguning, namun untuk ukuran sudah sesuai *gradenya*. demikian juga di *grade C*, bisa saja ada penurunan kelas dari sebelumnya *grade B* dikarenakan ada faktor warna yang menguning, walaupun secara ukuran dia berada pada besaran *grade B*. Untuk *inputan* ketiga ialah *inputan* gambar brokoli dari tampak samping, dimana gambar dari tampak samping ini dilihat dari bentuk *dome* atau kubahnya, apabila bentuk kubahnya bagus atau simetris maka dia berada di *grade* paling atas, namun apabila bentuk kubahnya kurang bagus atau tidak simetris maka akan turun

kelas. Model *Ensemble* ini digunakan karena tiap kategori memiliki unsur independen, yaitu di setiap kategorinya bisa mempengaruhi *grade* dari brokoli.

Penelitian ini menggunakan model konvolusi dan klasifikasi secara paralel dengan masing masing *inputan* menggunakan model *deep learning* yang sama, namun hasil akhirnya adalah berupa perbandingan dimana pada fase *training* ini akan menggunakan model *Resnet*, *VGG* dan *EfficientNet* yang pada fase *testingnya* semua model prediksi akan dibandingkan hasilnya. Dalam hal ini tidak hanya dibandingkan dari sisi akurasi saja, tapi juga dibandingkan hasil klasifikasi beberapa *layer* prediksinya seperti yang terlihat pada table hasil akurasi.



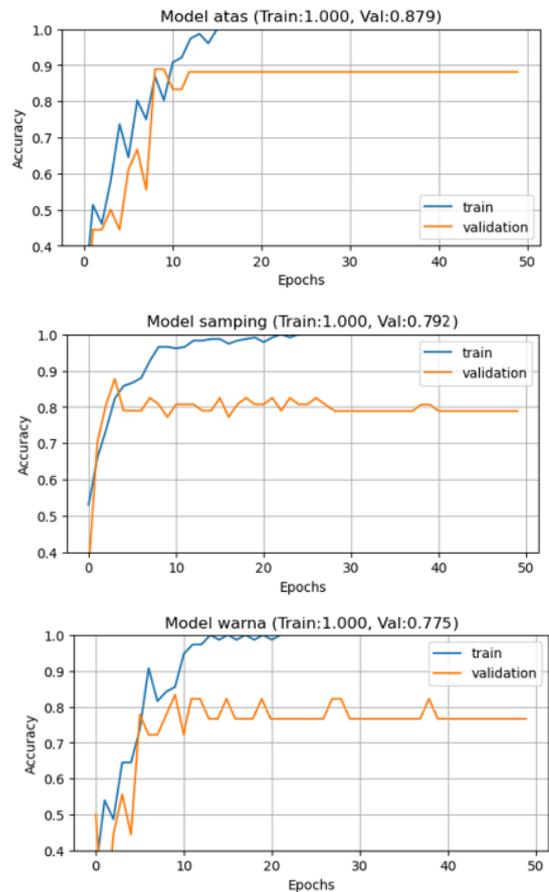
Gambar 8. Arsitektur CNN pada Fase *Training*

Gambar 8 diatas merupakan arsitektur model untuk konvolusi dan klasifikasi menggunakan *ResNet50*, *EfficientNetB2*, dan *VGG16*. Secara garis besar *input* yang digunakan sebagai citra masukan ialah di *resize* menjadi 224x224, sedangkan saya memasukan chanel 3 sebagai pertanda bahwa yang diolah adalah *layer RGB*. menggunakan 3 kelas dan parameter *pooling average*, artinya mengambil rata-rata dari setiap sub-regional dalam feature map yang lebih besar dan menggantinya dengan nilai rata-rata tersebut. nilai bobot secara default saya menggunakan *ImageNet*. Bobot *ImageNet* ini sudah dikenali dan dilatih menggunakan *dataset ImageNet*. *ImageNet* adalah *dataset* yang sangat besar dan mencakup jutaan gambar dari berbagai kategori, seperti hewan, tanaman, manusia, dan lain-lain. Bobot ini sangat berguna untuk transfer learning, yaitu proses memanfaatkan jaringan yang sudah terlatih pada *dataset* besar dan dapat diterapkan pada *dataset* yang lebih kecil dan spesifik. Proses ini mempercepat waktu pelatihan dan memperbaiki hasil akhir karena jaringan sudah memiliki informasi tentang pola dan fitur pada gambar dari *dataset ImageNet*. Kemudian dilanjutkan dengan proses *Flatten* yaitu mengubah representasi data dari bentuk matriks multi dimensi menjadi vektor tunggal. Ini dilakukan sebelum data diteruskan ke *layer fully connected (dense)* pada jaringan. *Flatten*

membuat data lebih mudah diproses oleh *layer dense* dan memastikan bahwa semua fitur pada data terintegrasikan dengan baik. Proses ini penting karena *layer dense* hanya dapat memproses vektor sebagai *input* dan memastikan bahwa semua informasi pada data tidak hilang selama proses pengolahan. Pada *layer* klasifikasi, *dense layer* akan dibandingkan dan dilihat hasil akhirnya menggunakan metode *voting*, dimana hasilnya akan terlihat jumlah *layer dense* yang mana yang menunjukkan performa terbaik.

$$E(S, D, M, R) = \min(\sum_1^n G_n(D_n, M_n, R)) \quad (5)$$

Persamaan 5 diatas merupakan metode yang digunakan untuk memprediksi kualitas brokoli adalah metode *Ensemble*, yang menggabungkan beberapa model. Setiap model (M_n) menggunakan data yang berbeda (D_n) untuk menghasilkan prediksi kualitas yang berbeda dalam penelitian ini. Jumlah model yang dibuat (n) adalah tiga model yang digunakan untuk fitur warna, bentuk, dan ukuran. Hasil prediksi kualitas adalah kualitas terendah yang dihasilkan oleh masing-masing model (G).



Gambar 9. Perbandingan grafik hasil klasifikasi

Gambar 9 merupakan hasil klasifikasi pada fase *training*, dimana masing masing *classifier* berhasil mendapatkan model klasifikasi terbaik yaitu diatas 75%, dimana hasil tersebut diambil dari satu model terbaik yaitu *ResNet50* dengan 5 *dense layer*.

Pada prinsipnya, gabungan kekuatan dari tiga model prediksi diatas dapat mengurangi kelemahan masing-masing model sehingga dapat menghasilkan prediksi atau hasil yang lebih akurat (Kumar et al., 2022). Untuk arsitektur model *Resnet* yang diusulkan, peneliti menggunakan beberapa pengaturan *Hyperparameter* diantaranya sebagai berikut

Table 2. Hperparameter Model CNN

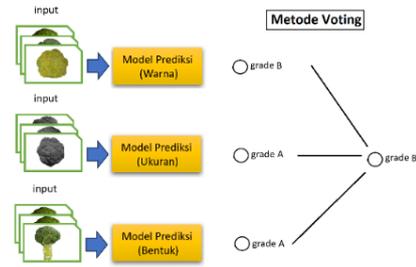
Layer	Pengaturan Hyperparameter		
	<i>ResNet50</i>	<i>VGG16</i>	<i>EfficientNetB2</i>
Model	Weights: <i>ImageNet</i>	Weights: <i>ImageNet</i>	Weights: <i>ImageNet</i>
Fungsi aktivasi	ReLU	ReLU	ReLU
Layer Pooling	<i>Average-pooling</i>	<i>Average-pooling</i>	<i>Average-pooling</i>
	256	512	256
	128		128
Layer Dense	64		64
	32		
	3 kelas	3 kelas	3 kelas
Optimizer	Adam	Adam	Adam
Fungsi aktivasi	ReLU dan Softmax	ReLU dan Softmax	ReLU dan Softmax
Epoch	50	50	50

Tabel 2 menunjukkan arsitektur dari beberapa model CNN yaitu *ResNet50*, *VGG16* dan *EfficientNetB2*. Nilai *hyperparameter* dari tiap-tiap model yang ditampilkan pada table 2 tersebut merupakan nilai yang mendapatkan hasil akurasi terbaik. pengaturan *hyperparameter* yang digunakan sangat berperan penting. Semua model menggunakan *pretrained ImageNet*, yang dapat membantu dalam meningkatkan kinerja model. Fungsi aktivasi yang digunakan adalah ReLU (*Rectified Linear Unit*). Selain itu, lapisan *pooling* dalam model ini menggunakan metode *average-pooling*, yang menghitung nilai rata-rata dari fitur dalam area *pooling*. Dalam hal arsitektur lapisan, model *ResNet50* menjadi model dengan hasil yang paling optimal dengan memiliki beberapa lapisan Dense (lapisan yang sepenuhnya terhubung) dengan berbagai jumlah unit, yaitu 256,128, 64, dan 32, sebelum mencapai lapisan *output* dengan 3 unit, yang sesuai dengan jumlah kelas yang akan diprediksi. Untuk mengoptimalkan model selama proses pelatihan, *optimizer* Adam digunakan, yang dikenal sebagai algoritma optimasi yang efisien dan sering digunakan dalam *deep learning*. Selain itu, fungsi aktivasi *ReLU* digunakan pada sebagian besar lapisan, sedangkan pada lapisan *output*, digunakan fungsi *Softmax* untuk menghasilkan probabilitas yang dibutuhkan untuk klasifikasi. Proses pelatihan model berlangsung selama 50 *epoch*, yang merupakan jumlah iterasi atau siklus pelatihan yang

akan memungkinkan model untuk belajar dengan data latihan.

3.3 Metode Voting

Gambar 10 merupakan model arsitektur pada fase *testing*, dimana tiap model prediksi yang dihasilkan pada saat fase *training* digabungkan kembali, dan dijadikan model klasifikasi data baru.



Gambar 10. Arsitektur CNN pada Fase Testing

Data baru dibagi menjadi 3 bagian seperti model *inputan* pada saat *training*, namun untuk data *testing* semua data *inputan* diatur secara berpasangan, sesuai dengan proses *grading* di lapangan yang mengandalkan visualisasi *grading* dari tampak atas dan samping. Dari citra brokoli yang berpasangan tersebut kemudian dimasukan ke dalam model prediksi, diset sesuai dengan gambar diatas. hasil luaran dari masing-masing model ialah berupa klasifikasi *grading*, dimana data *inputan* gambar masuk kedalam kelas *Grade A*, *B* atau *C*, dan dari informasi tersebut dilakukan teknik *voting* untuk menentukan hasil akhirnya, dimana metode *voting* ini menggunakan metode *min. voting*, atau mengambil nilai terendah untuk membangun hasil keputusan. Misalkan dari 3 kelas, kelas warna masuk ke dalam kelas *A*, kelas ukuran masuk ke dalam kelas *A* dan bentuk tampak samping masuk kedalam kelas *B*, maka hasil *voting* di arahkan ke dalam kelas terendah, yaitu brokoli berada di *Grade B*.

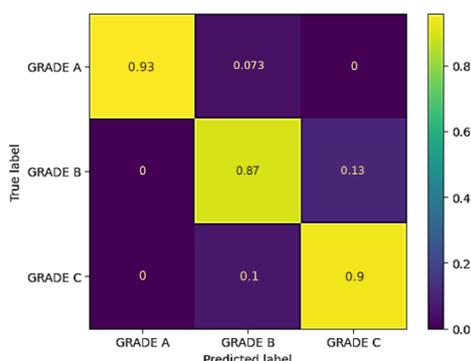
Table 3. Hasil perbandingan akurasi terhadap jumlah *dense layer*

Dense Layer (Σ)	Akurasi		
	<i>ResNet50</i>	<i>VGG16</i>	<i>EfficientNetB2</i>
2	0.84	0.88	0.88
3	0.85	0.86	0.83
4	0.85	0.79	0.89
5	0.90	0.84	0.85

Tabel 3 Pada eksperimen ini, *ResNet50* menunjukkan akurasi tertinggi sebesar 90% ketika jumlah lapisan dense mencapai 5. Hal ini menunjukkan bahwa arsitektur *ResNet50*, yang lebih kompleks dengan residual connections, dapat menangkap pola yang lebih baik seiring dengan peningkatan kedalaman lapisan dense. hasil penelitian juga terlihat model *ResNet50* lebih baik dalam memprediksi *Grade A* dibandingkan untuk *Grade B* dan *C*, hal ini dikarenakan pada *Grade A* semua datanya sesuai dengan gradenya, maka data tersebut lebih konsisten dan lebih mudah dikenali

oleh model. Sementara itu, Grade B dan C memiliki data yang turun grade, sehingga terdapat lebih banyak variasi fitur. Hal ini membuat batas antar kelas menjadi kurang jelas, sehingga model kesulitan membedakan apakah suatu sampel masih termasuk Grade A atau sudah turun ke Grade B, begitu juga dari Grade B ke Grade C.

Di sisi yang lain, *VGG16* dan *EfficientNetB2* menunjukkan hasil yang bervariasi tergantung pada jumlah layer dense nya. *VGG16* mencapai akurasi tertinggi (88%) pada 2 layer dense tetapi mengalami penurunan saat jumlah layer meningkat, ini menunjukkan terjadi *overfitting*. Sedangkan *EfficientNetB2* menunjukkan akurasi tertinggi (89%) pada 4 layer dense, yang menunjukkan bahwa model ini lebih optimal pada layer klasifikasi dengan kedalaman tertentu



Gambar 11. Hasil confusion matrix

Gambar 11 menjelaskan kinerja model klasifikasi dalam mengategorikan *grade* brokoli menjadi tiga kelas berbeda: *Grade A*, *Grade B*, dan *Grade C*. Dari total 600 sampel dalam *dataset*, masing-masing kelas *Grade A*, *Grade B*, dan *Grade C* memiliki 200 sampel. Hasil matriks diatas menunjukkan bahwa model klasifikasi mampu memprediksi dengan tingkat akurasi yang cukup baik. Sebanyak 93% dari sampel *Grade A* diprediksi dengan benar sebagai *Grade A*, sementara 87% dari sampel *Grade B* juga diprediksi dengan tepat sebagai *Grade B*. Model tersebut juga berhasil memprediksi sekitar 90% dari sampel *Grade C* sebagai *Grade C*. Meskipun ada beberapa prediksi yang salah, terutama dalam mengklasifikasikan sampel *Grade B* sebagai *Grade C*, model ini dapat dianggap cukup berhasil dalam tugas klasifikasi *grade* brokoli

Tabel 4. Evaluasi performa menggunakan *Improved ResNet50*

	<i>Precision</i>	<i>Recall</i>	<i>f1-score</i>
GRADE A	1.00	0.93	0.96
GRADE B	0.83	0.99	0.90
GRADE C	0.87	0.90	0.89
accuracy			0.90

Hasil matrik evaluasi untuk model klasifikasi menggunakan *Improved ResNet50* dengan tiga kelas: *GRADE A*, *GRADE B*, dan *GRADE C*. Penggunaan kedua metrik presisi dan recall

digunakan untuk melihat performa model yang lebih seimbang antara true positif dan false positif. Dalam hal ini, kita melihat bahwa model memiliki tingkat presisi yang sangat tinggi untuk *GRADE A*, dengan 100% prediksi *GRADE A* yang benar. Namun, presisi lebih rendah untuk *GRADE B* (83%) dan *GRADE C* (87%). Selanjutnya, *Recall* mengukur seberapa baik model dalam mengidentifikasi kasus positif secara keseluruhan. Model ini memiliki tingkat *Recall* yang baik, terutama untuk *GRADE A* (93%) dan *GRADE C* (99%), tetapi *Recall* *GRADE B* sedikit lebih rendah (90%). Selain itu, *F1-Score* adalah nilai yang mencerminkan seimbang antara presisi dan *Recall*. Dalam kasus ini, *GRADE A* memiliki skor F1 tertinggi (0.98), sedangkan *GRADE B* dan *GRADE C* memiliki skor F1 yang sama (0.91). Akhirnya, akurasi secara keseluruhan adalah 90%, yang menunjukkan seberapa baik model ini dalam membuat prediksi yang benar di semua kelas.

Berdasarkan hasil diatas tentunya penelitian ini masih memerlukan penambahan jumlah dataset serta melakukan *tunning hyperparameter* untuk mendapatkan kombinasi nilai terbaik agar hasil akurasi yang didapatkan bisa lebih optimal.

4. KESIMPULAN

Penelitian ini sangat penting dalam mengatasi permasalahan yang ada di industri brokoli di Indonesia. Pasar untuk brokoli terus berkembang baik di dalam negeri maupun di pasar internasional seperti USA, China, dan Eropa. Namun, terdapat kendala dalam pasokan dan kualitas produk brokoli, serta kurangnya pemahaman tentang proses *grading* di kalangan petani dan masyarakat umum. Hal ini dapat berdampak pada kerugian bagi petani dan pengusaha brokoli, karena proses *grading* brokoli saat ini masih dilakukan oleh pihak tertentu saja.

Penelitian ini melakukan pengembangan model *Ensemble Learning* utk multi fitur, dimana ada dua data yang dipecah menjadi 3 buah fitur, yaitu warna, ukuran and bentuk dan setiap datanya independen, dimana tiap fitur tersebut tidak saling bergantung terhadap fitur lainnya. Metode ini juga membangun teknik penggabungan hasil prediksi dari *inputan* yang bersifat independen menjadi model keputusan. Tiap *layer* klasifikasi dari seluruh model *deep learning* seperti *ResNet50*, *VGG16*, *EfficientNet* telah dimodifikasi dan diuji, dengan hasil akurasi terbaik berasal dari *ResNet50* yang mencapai akurasi 90%, dengan menggunakan 5 *layer dense*. Dalam matriks evaluasi, model ini menunjukkan tingkat presisi yang tinggi untuk *GRADE A*, tetapi presisi lebih rendah untuk *GRADE B* dan C. Meskipun demikian, tingkat *Recall* secara keseluruhan cukup baik, dengan skor F1 yang seimbang antara presisi dan *Recall*.

Penerapan algoritma *grading* berbasis citra ini akan membantu meningkatkan kualitas dan standarisasi brokoli pasca-panen. Harapan kedepan

penelitian ini dapat dikembangkan dengan mengombinasikan berbagai model CNN menggunakan teknik paralel ensemble learning. Selain itu, penelitian ini juga dapat diperluas dengan menggunakan teknik pencahayaan berbeda saat pengambilan gambar, seperti dengan kamera ponsel atau perangkat lainnya. Hasil penelitian ini juga berpotensi untuk diintegrasikan ke dalam ponsel dan sistem Arduino, terutama jika akan digunakan untuk grading massal dengan alat berat seperti mesin konveyor.

5. UCAPAN TERIMAKASIH

Ucapan terima kasih disampaikan kepada Kementerian Riset, Teknologi, dan Pendidikan melalui program Penelitian Disertasi Doktor (PDD) dengan judul Pengembangan Model *Multi layer Classifier* menggunakan Metode *Ensemble Learning* untuk *Grading* Brokoli dengan nomor 18869/IT3.D10/PT.01.03/P/B/2023. sehingga hasil penelitian ini dapat dipublikasikan.

DAFTAR PUSTAKA

- ALOMAR, K., AYSEL, H.I. & CAI, X., 2023. Data Augmentation in classification and segmentation: A survey and new strategies. *Journal of Imaging*, 9(2), p.46.
- BLOK, P.M., VANEVERT, F.K., TIELEN, A.P.M., VAN HENTEN, E.J. & KOOSTRA, G., 2021. The effect of data augmentation and Network simplification on the image-based detection of broccoli heads with Mask R-CNN. *Journal of Field Robotics*, 38(1), pp.85–104.
- CIREŞAN, D., MEIER, U. & SCHMIDHUBER, J., 2012. Multi-column Deep Neural Networks for Image Classification. [online] Available at: <<http://arxiv.org/abs/1202.2745>>.
- DELL'AQUILA, A., 2009. Digital imaging information technology applied to seed germination testing. A review. *Agronomy for Sustainable Development*, 29 (1), p.213-221
- GRANDINI, M., BAGLI, E. & VISANI, G., 2020 'Metrics for Multi-Class Classification: an Overview', pp. 1–17. Available at: <http://arxiv.org/abs/2008.05756>.
- GUO, L., WANG, P., GU, Z., JIN, X. & YANG, R., 2017. Proteomic analysis of broccoli sprouts by iTRAQ in response to jasmonic acid. *Journal of Plant Physiology*, 218, pp.16–25.
- HELEN JOSEPHINE, V.L., NIRMALA, A.P. , ALLURI, V.L., 2021. Impact of Hidden Dense layers in Convolutional Neural Network to enhance Performance of Classification Model. *IOP Conference Series: Materials Science and Engineering*, 1131(1), p.012007.
- ISMAIL, N. & MALIK, O.A., 2022. Real-time visual inspection system for grading fruits using computer vision and deep learning techniques. *Information Processing in Agriculture*, [online] 9(1), pp.24–37.
- KRIZHEVSKY, A. & HINTON, G.E., 2017. ImageNet Classification with Deep Convolutional Neural Networks, 60(6), p.84-90.
- KUMAR, V., SINGH AYDAV, P.S. & MINZ, S., 2022. Multi-view Ensemble Learning using multi-objective particle swarm optimization for high dimensional data classification. *Journal of King Saud University - Computer and Information Sciences*, 34(10), pp.8523–8537. *Min. Knowledge Discov.* 8 (4), e1249.
- KUSUMAM, K., KRAJNÍK, T., PEARSON, S., CIELNIAK, G. DUCKETT, T., 2016. Can you pick a broccoli? 3D-vision based detection and localisation of broccoli heads in the field. In: *IEEE International Conference on Intelligent Robots and Systems*. Institute of Electrical and Electronics Engineers Inc. <https://doi.org/doi:10.1109/IROS.2016.7759121> pp.646–651.
- PUJI ASTUTIK, M. & RESPATIARTI, 2019. Uji Daya Hasil Beberapa Genotipe Brokoli (*Brassica oleracea* var. *italica* L.) di Dataran Tinggi Potential Yeild Trial Several Genotype of Broccoli (*Brassica oleracea* var. *italica* L.) in The Highlands. *Jurnal Produksi Tanaman*, 7(3), pp.480–487.
- RAMIREZ, R.A., 2006. Computer Vision Based Analysis of Broccoli for Application in a Selective Autonomous Harvester. Master of Science Thesis. Virginia Polytechnic Institute and State University
- SAGI, O., ROKACH, L., 2018. Ensemble Learning: A survey. *Wiley Interdiscip. Rev.: Data*, 8, 10.1002/widm.1249
- SHORTEN, C. and KHOSHGOFTAAR, T.M., 2019. A survey on image data augmentation for Deep learning. *Journal of Big Data*, 6(1).
- THARWAT, A., 2020. Classification assessment methods. *Applied Computing and Informatics*, 17(1), pp.168–192.
- ZHOU, C., HU, J., XU, Z., YUE, J., YE, H. & YANG, G., 2020. A monitoring system for the segmentation and grading of Broccoli head based on Deep learning and Neural Networks. *Frontiers in Plant Science*, 11, p.402