

Klasifikasi Tingkat Kematangan Buah Kopi Dari Pohon-nya Menggunakan InceptionResnetv2, dan MobileNetv2

Jodi Wijaya^{1*}, Kusri²

^{1,2}Universitas Amikom Yogyakarta, Indonesia

*Corresponding Author: jodijwiyaya@students.amikom.ac.id

ABSTRACT

Tanaman kopi adalah komoditas ekspor terbesar dalam peningkatan ekonomi negara berkembang. Kopi memiliki peran penting dalam budaya Indonesia, dengan sejarah panjang dan berbagai cita rasa yang kaya. Ada dua jenis utama kopi di Indonesia: Arabika dan Robusta. Kematangan dan pengolahan biji kopi menjadi salah satu pengaruh cita rasa kopi. Untuk menghasilkan biji kopi berkualitas tinggi, proses pemanenan biji kopi yang tepat pada tingkat kematangan yang ideal sangat penting. MobileNet adalah arsitektur jaringan saraf tiruan CNN yang menggunakan konvolusi yang dipisahkan secara kedalaman (depthwise separable convolutions), untuk membuat jaringan yang ringan yang memungkinkan penggunaan sumber daya komputasi yang efektif. Penelitian ini akan memanfaatkan keunggulan arsitektur InceptionResNetV2 dan MobileNetV2 untuk mengatasi masalah yang rumit dengan klasifikasi gambar. Ini juga akan memanfaatkan kemampuan arsitektur MobileNet dan InceptionResNet untuk melakukan transfer learning dari dataset yang lebih besar, seperti ImageNet. Perbandingan dari 2 model yang digunakan hasil performa akurasi yang paling tinggi model MobileNetV2 yang sebesar $\pm 99\%$, diikuti InceptionResNetV2 = 90%.

Keywords: klasifikasi, buah kopi, coffee fruit, coffee cherry, coffee berry, CNN, InceptionResnetV2, MobileNetV2.

Article history

Received:
30 December 2024

Revised:
2 January 2025

Accepted:
30 January 2025

Published:
31 January 2025

Citation (APA Style)

PENDAHULUAN

Tanaman kopi adalah komoditas ekspor terbesar dalam peningkatan ekonomi negara berkembang (Ardiansyah & Hasan, 2023). Kopi memiliki peran penting dalam budaya Indonesia, dengan sejarah panjang dan berbagai cita rasa yang kaya. Selama abad ke-17, kolonial Belanda menanamkan tanaman kopi di Indonesia. Ini membuka jalan bagi kekayaan varietas kopi di Sumatra, Jawa, Sulawesi, dan Bali (Gumulya & Helmi, 2017).

Ada dua jenis utama kopi di Indonesia: Arabika dan Robusta. Biasanya, biji kopi dikategorisasi dengan menggunakan teknik tradisional yang bergantung pada persepsi manusia. Karena metode ini hanya dapat memberikan penilaian kualitatif dan bergantung pada kondisi mental dan fisik individu saat itu, mungkin agak tidak konsisten (Waliyansyah & Umar Hafidz Asy'ari Hasbullah, 2021).

Kematangan dan pengolahan biji kopi menjadi salah satu pengaruh cita rasa kopi. Untuk menghasilkan biji kopi berkualitas tinggi, proses pemanenan biji kopi yang tepat pada tingkat kematangan yang ideal sangat penting (Rabbani et al., 2021). Menentukan secara akurat dan efektif tingkat kematangan buah kopi merupakan salah satu tantangan utama bagi industri kopi.

Beberapa penelitian telah mempelajari klasifikasi buah kopi. Mereka telah mencoba sejumlah metode pendekatan seperti Convolutional Neural Network (CNN) (Momeny et al., 2020), K-Nearest Neighbours (KNN) (Raysyah et al., 2021), dan Support Vector Machine (SVM) (Sihombing & Buulolo, 2021). SVM memiliki kelebihan dalam mengklasifikasi, seperti efektifitas dalam ruang berdimensi tinggi, yang mana ketika data klasifikasi buah kopi melibatkan banyak fitur atau atribut dari gambar buah kopi yang kompleks.

SVM tahan terhadap overfitting, dan berguna untuk memisahkan data berukuran besar untuk menghindari masalah model yang terlalu menyesuaikan diri dengan data latih. SVM biasanya tahan terhadap overfitting pada dataset yang lebih kecil (Rusman & Pasae, 2023). SVM juga memiliki kekurangan seperti sensitif terhadap pemilihan parameter, dan kinerja yang kurang baik pada dataset besar (Raysyah et al., 2021).

KNN memiliki kelebihan yaitu sederhana dan mudah dimengerti, dan efektif pada data non-linear, tetapi memiliki kelemahan pada outlier yang sangat sensitif, dan perhitungan yang berat (Raysyah et al., 2021). CNN memiliki kemampuan generalisasi yang lebih baik dan pemrosesan data yang lebih baik, terutama untuk dataset citra besar dengan kerumitan yang tinggi (Myagila & Kilavo, 2022). Tetapi CNN memiliki kelemahan pada waktu pelatihan yang lama dan memori komputer yang besar (Ajib Susanto et al., 2022).

MobileNet adalah arsitektur jaringan saraf tiruan CNN yang menggunakan konvolusi yang dipisahkan secara kedalaman (depthwise separable convolutions), untuk membuat jaringan yang ringan yang memungkinkan penggunaan sumber daya komputasi yang efektif pada perangkat mobile (Khasoggi et al., 2019). Inception-ResNet adalah arsitektur jaringan saraf imitasi yang menggabungkan Inception dari Google dengan koneksi residual ResNet dari Microsoft. Arsitektur ini, yang dikembangkan oleh Christian Szegedy, Sergey Ioffe, Vincent Vanhoucke, dan lainnya, memadukan fitur-fitur Inception dengan konsep hubungan residual yang diperkenalkan dalam ResNet. Metode ini digunakan untuk mencapai keseimbangan antara kinerja yang tepat dan kecepatan pelatihan dalam jaringan saraf konvolusional yang lebih dalam (Szegedy et al., 2017).

Penelitian yang dilakukan oleh (Michael & Garonga, 2021) ini membahas tentang penerapan Convolutional Neural Network (CNN) untuk mengklasifikasi gambar tingkat kematangan buah kopi toraja. Penelitian ini menggunakan dataset gambar buah kopi sebanyak 4000 gambar dengan 4 kategori. Akurasi terbaik yang diperoleh mencapai 98,75% pada salah satu modelnya dengan epochs 100 dan batch size = 10. Penelitian selanjutnya (Momeny et al., 2020) ini membahas penggunaan deep learning. Khususnya pada metode Convolutional Neural Network (CNN) untuk mendeteksi penampilan buah ceri dan menyediakan sistem yang efisien untuk penilaiannya. Studi ini menggunakan metode HOG dan LBP. Penelitian ini menggunakan dataset gambar cherry sebanyak 719 gambar, dengan 2 variasi yaitu merah dan hitam. properti gambar yang diekstraksi dengan algoritma KNN, ANN, Fuzzy dan Ensemble Decision Trees (EDT). Tingkat akurasi pelatihan sebesar 99.4%.


Penelitian selanjutnya (Khasoggi et al., 2019) Penelitian ini menggunakan metode Convolutional Neural Networks (CNN). Menggunakan arsitektur MobileNet untuk pengenalan gambar pada perangkat seluler. Perangkat yang digunakan yaitu perangkat tertanam dengan sumber daya terbatas dengan CPU berbasis ARM dan bekerja dengan data pelatihan dalam jumlah sedang (ribuan gambar berlabel). Hasilnya, arsitektur MobileNet v1 pada perangkat ms8pro dapat mengklasifikasikan dataset caltech101 dengan tingkat akurasi 92,4% dan konsumsi daya 2,1 Watt. Penelitian selanjutnya (Tamayo-Monsalve et al., 2022) membahas tentang penerapan jaringan syaraf konvolusional (CNN) untuk mengklasifikasi Tingkat kemaatan buah kopi. Metode yang digunakan melibatkan penggunaan CNN dengan arsitektur VGG16, VGG19, Inception-ResNet-V2, Inception-V3, and DenseNet201.

Penelitian yang dilakukan (Bazame et al., 2021) mengimplementasikan suatu algoritma dengan model computer vision untuk mendeteksi dan mengklasifikasikan buah kopi serta memetakan tahap pematangan buah pada saat panen. Model yang digunakan untuk mendeteksi dan mengklasifikasikan buah kopi diimplementasikan menggunakan Darknet, Deteksi dan klasifikasi buah kopi dilakukan menggunakan sistem deteksi objek bernama YOLOv3-tiny. penelitian ini menggunakan 90 video yang direkam di ujung konveyor pelepasan pemanen kopi selama panen kopi arabika tahun 2020 (Catuaí 144) di area komersial di wilayah Patos de Minas, di negara bagian Minas Gerais, Brasil. Model tersebut menyajikan mAP sebesar 84%, F1-Score sebesar 82%, presisi sebesar 83%, dan recall sebesar 82% untuk set validasi. Rata-rata presisi pada kelas buah kopi mentah, matang, dan terlalu matang masing-masing sebesar 86%, 85%, dan 80%.

Penelitian yang dilakukan (Saragih & Emanuel, 2021) Penelitian ini menerapkan Convolutional Neural Network untuk mengklasifikasikan kematangan buah pisang. Dua model terlatih digunakan, yaitu MobileNet V2 dan NASNetMobile. Eksperimen dilakukan menggunakan Google Colab dan beberapa perpustakaan seperti OpenCV, Tensorflow, dan scikit-learn. Hasilnya menunjukkan bahwa MobileNet V2 mencapai akurasi tertinggi dan waktu eksekusi lebih cepat dibandingkan NASNetMobile. Akurasi tertinggi yang dicapai adalah 96,18%.

Berdasarkan beberapa penelitian yang menjadi rujukan, penelitian ini bertujuan untuk mengetahui apakah model dapat bekerja jika buah kopi masih berada pada pohonnya atau sebelum dipetik dan akan dilakukan klasifikasi pada Tingkat kematangan buah kopi dengan kelas: Over Ripe, Ripe, Semi-ripe, dan Unripe. Penelitian akan dilakukan dengan metode jaringan syaraf konvolusional (CNN), menggunakan arsitektur MobileNetV2 dan InceptionResnetV2.

METODE PENELITIAN




Gambar 1. Metode Penelitian

Gambar 1 menggambarkan urutan langkah-langkah dalam penelitian ini, dimulai dari pengumpulan data. Langkah selanjutnya adalah pra-pemrosesan data, yang mencakup pembagian data menjadi dataset latih, tes, dan validasi, diikuti oleh proses augmentasi citra. Setelah selesai dengan proses augmentasi, langkah berikutnya adalah pembuatan serta pelatihan model, yang kemudian dievaluasi untuk menilai kinerjanya. Augmentasi dilakukan dalam penelitian ini untuk meningkatkan informasi yang terdapat pada dataset latih, dengan menghasilkan data latih tambahan dan menerapkan penyesuaian pada model, sehingga model dapat mengenali citra dalam berbagai kondisi yang berbeda.


A. Dataset

Dataset yang digunakan kali ini memiliki jumlah sebanyak 800 gambar dengan 4 kelas yaitu: *overripe*, *ripe*, *semi-ripe* dan *unripe*.



Gambar 2. Gambar Tingkat kematangan buah kopi (1) overripe (2) ripe (3) semi-ripe (4) unripe


Data gambar memiliki ukuran pixel yang beragam dengan mayoritas ukuran 640x640 pixel. Grafik yang menunjukkan distribusi data untuk setiap kelas dapat ditemukan dalam Gambar 3.



Gambar 3. distribusi data

B. Arsitektur Model

Penelitian ini menggunakan pendekatan transfer learning untuk membuat modelnya. Model yang telah disiapkan atau yang telah dilatih sebelumnya (pretrained model) adalah sequential convolution, yaitu MobileNetV2 dan InceptionResNetV2. Model-model ini akan ditambahkan dengan lapisan-lapisan baru pada bagian Fully Connected Layer. Lapisan-lapisan tambahan ini mencakup: (1) Conv2d 32 dengan aktivasi relu, (2) Dense layer 9/128 dengan aktivasi relu/softmax, (3) flatten layer, dan (4) maxpool2d layer.



Gambar 4. Arsitektur model sequential

C. Augmentasi Data

Dalam penelitian ini, parameter augmentasi yang digunakan meliputi `preprocessing_function` yang nilainya diambil dari pustaka yang disediakan oleh Tensorflow,

yaitu `tensorflow.keras.preprocessing.image.ImageDataGenerator`. Selain itu, parameter lain yang digunakan adalah `target_size` dengan nilai (224, 224) dan `color_mode` dengan nilai 'rgb'.

D. Skenario Pengujian

Penelitian ini mengklasifikasikan citra ke dalam 4 kelas yang berbeda: overripe, ripe, semi-ripe, dan unripe, dengan masing-masing kelas memiliki 200 gambar. Total data yang digunakan adalah 800 gambar untuk keempat kelas tersebut.

Data ini kemudian dibagi menjadi tiga bagian, yaitu data latih (train), data tes (test), dan data validasi (validation), dengan pembagian proporsional masing-masing sebesar 80% untuk data latih, 10% untuk data tes, dan 10% untuk data validasi. Dengan pembagian ini, jumlah data latih adalah 640, data tes sebanyak 80, dan data validasi sebanyak 80. Setiap kelas memiliki 200 gambar yang dibagi ke dalam ketiga set data tersebut.

Dalam penelitian ini, diterapkan satu fungsi callback yang berperan saat pelatihan model. Salah satunya adalah callback Early Stopping, yang bertujuan untuk menghentikan proses pelatihan jika terdeteksi adanya potensi overfitting. Model akan dihentikan setiap iterasi pelatihan jika terjadi penurunan matriks `val_accuracy`. Callback ini merupakan metode yang tersedia dalam FastAI untuk memonitor nilai metrik loss validation dengan learning rate yang telah ditetapkan selama proses pelatihan.

HASIL DAN PEMBAHASAN

Langkah awal dalam mendapatkan hasil dari arsitektur model yang telah dibangun dalam penelitian ini, berfokus pada klasifikasi tingkat kematangan buah kopi dari batangnya. Proses ini dilakukan melalui platform Jupyter Notebook dengan menggunakan CPU.

Tahap pertama melibatkan pengambilan data dari situs yang telah disebutkan dalam metode penelitian. Kemudian, dilakukan pembagian data menjadi tiga bagian, yaitu data latih (train), data tes (test), dan data validasi (validation). Pembagian dilakukan dengan rasio 80% untuk data latih, 10% untuk data tes, dan 10% untuk data validasi. Sehingga, jumlah data untuk masing-masing adalah 480 data train, 160 data tes, dan 160 data validasi.

Kemudian, dilakukan proses augmentasi (augmentation) pada data latih, tes, dan validasi. Parameter yang digunakan untuk augmentasi termasuk `preprocessing_function` yang nilainya berupa fungsi `preprocess_input` dari library Tensorflow di modul keras – application – resnet. Selain itu, parameter lain yang digunakan adalah `target_size` dengan nilai 224x224 dan `color_mode` dengan nilai 'rgb'.

Model dilatih dengan 100 iterasi pelatihan (epoch). Dua layer dense ditambahkan dengan 256 neuron dan dropout sebesar 0.3 yang menggunakan aktivasi relu. Optimasi dilakukan dengan optimizer 'Adam' yang memiliki learning rate sebesar 0,0001. Setiap epoch melibatkan 20 langkah, dan fungsi callback early stopping diaktifkan untuk mencegah overfitting.

Setelah proses iterasi selesai, arsitektur mobilenetv2 berhenti pada epoch ke-48, dan inceptionresnetv2 berhenti di epoch ke-46 setelah digunakannya fungsi early stopping. Kemudian diproses lagi dengan menggunakan data tes, dan menghasilkan nilai yang berbeda.

Nilai data tes model InceptionResNetV2 dan MobileNetV2 dapat dilihat pada Gambar 5 dan Gambar 6:

Model InceptionResNetV2 menghasilkan Test Loss sebesar 0,32715 dan Test Accuracy sebesar 90,00%.

Test Loss: 0.32715
Test Accuracy: 90.00%


Gambar 5. Nilai Test akurasi InceptionResNetV2

Model MobileNetV2 menghasilkan Test Loss sebesar 0,08254 dan Test Accuracy sebesar 98,75%.

Test Loss: 0.08254
Test Accuracy: 98.75%


Gambar 6. Nilai Test akurasi MobileNetV2

Grafik akurasi:
Model InceptionResNetV2.



Gambar 7. Grafik akurasi InceptionResNetV2


Model MobileNetV2.



Gambar 8. Grafik akurasi MobileNetV2


Grafik menunjukkan akurasi pelatihan (training accuracy) dan akurasi validasi (validation accuracy) setelah penyelesaian proses iterasi pelatihan. Sumbu X menunjukkan jumlah iterasi pelatihan yang telah dilakukan selama proses pelatihan model, sedangkan sumbu Y menunjukkan nilai akurasi yang berkisar antara 0 hingga 1.

Grafik loss :
Model InceptionResNetV2.



Gambar 9. Nilai loss InceptionResNetV2

Model MobileNetV2.




Gambar 10. Nilai Test akurasi MobileNetV2

Grafik untuk loss pada pelatihan model terdapat pada Gambar 9 dan 10. Pada sumbu X, terdapat iterasi pelatihan yang telah dilakukan oleh model, sementara pada sumbu Y, terdapat nilai loss model selama proses pelatihan yang berada dalam rentang nilai 0.


Confision Matrix:

Model InceptionResNetV2.



Gambar 11. Confusion matrik InceptionResNetV2

Model MobileNetV2.



Gambar 12. Confusion matrik MobileNetV2

Selain itu, evaluasi terhadap model dapat dipahami melalui tabel confusion matrix, yang digunakan untuk mengukur kinerja metode pembelajaran mesin dalam memprediksi secara akurat atau salah jumlah keseluruhan data. Hasil tabel confusion matrix dapat dilihat pada Gambar di atas. Data uji gambar yang digunakan menunjukkan bahwa prediksi yang tepat dari setiap data dengan kelasnya menghasilkan prediksi yang sesuai dengan kelas asli data.

Classification Report & Sensitivity:

Model InceptionResNetV2.

	precision	recall	f1-score	support
overripe	1.00	0.84	0.91	37
ripe	0.78	0.93	0.85	42
semi_ripe	0.89	0.85	0.87	39
unripe	0.98	0.98	0.98	42
accuracy			0.90	160
macro avg	0.91	0.90	0.90	160
weighted avg	0.91	0.90	0.90	160

Gambar 13. Classification Report & Sensitivity InceptionResNetV2

Model MobileNetV2.

	precision	recall	f1-score	support
overripe	1.00	0.95	0.97	37
ripe	0.98	1.00	0.99	42
semi_ripe	1.00	1.00	1.00	39
unripe	0.98	1.00	0.99	42
accuracy			0.99	160
macro avg	0.99	0.99	0.99	160
weighted avg	0.99	0.99	0.99	160

Gambar 14. Classification Report & Sensitivity MobileNetV2

Hasil evaluasi menggunakan classification report dapat dilihat pada Gambar di atas. Akurasi mengindikasikan jumlah prediksi yang benar dari keseluruhan citra dalam dataset. Ketika nilai akurasi mendekati 1, itu menunjukkan bahwa model memiliki kinerja yang baik, sedangkan nilai 0 menunjukkan sebaliknya.

Selain akurasi, terdapat metrik lain seperti precision, recall, dan f1-score yang mampu mengukur performa model.

KESIMPULAN

Penggunaan Machine Learning dengan menggunakan CNN InceptionResNetV2, dan MobileNetV2 memiliki kelebihan dan kekurangannya sendiri pada klasifikasi Tingkat kematangan buah kopi dari batangnya. Seperti model InceptionResnetV2 yang semakin banyak iterasi yang dilakukan akan semakin tinggi akurasi dan konvergen, tapi validasi akurasi yang lebih rendah.

Perbandingan dari 2 model yang digunakan hasil performa akurasi yang paling tinggi model MobileNetV2 yang sebesar $\pm 99\%$. Diikuti InceptionResNetV2 = 90%.

REFERENCES

- Ajib Susanto, Yupie Kusumawati, Ericsson Dhimas Niagara, & Christy Atika Sari. (2022). Convolutional Neural Network Dalam Sistem Deteksi Helm Pada Pengendara Motor. *Seminar Nasional Teknologi Dan Multidisiplin Ilmu (SEMNASTEKMU)*, 2(1), 91–99. <https://doi.org/10.51903/semnastekmu.v2i1.158>
- Ardiansyah, A., & Hasan, N. F. (2023). Deteksi dan Klasifikasi Penyakit Pada Daun Kopi Menggunakan YOLOv7. *Jurnal Sisfokom (Sistem Informasi Dan Komputer)*, 12(1), 30–35. <https://doi.org/10.32736/sisfokom.v12i1.1545>
- Bazame, H. C., Molin, J. P., Althoff, D., & Martello, M. (2021). Detection, classification, and mapping of coffee fruits during harvest with computer vision. *Computers and Electronics in Agriculture*, 183(October 2020). <https://doi.org/10.1016/j.compag.2021.106066>
- Gumulya, D., & Helmi, I. S. (2017). Kajian Budaya Minum Kopi Indonesia. *Jurnal Dimensi Seni Rupa Dan Desain*, 13(2), 153–172. <https://doi.org/10.25105/dim.v13i2.1785>
- Khasoggi, B., Ermatita, & Samsuryadi. (2019). Efficient mobilenet architecture as image recognition on mobile and embedded devices. *Indonesian Journal of Electrical Engineering and Computer Science*, 16(1), 389–394. <https://doi.org/10.11591/ijeecs.v16.i1.pp389-394>
- Michael, A., & Garonga, M. (2021). Classification model of ‘Toraja’ arabica coffee fruit ripeness levels using convolution neural network approach. *ILKOM Jurnal Ilmiah*, 13(3), 226–234. <https://doi.org/10.33096/ilkom.v13i3.861.226-234>
- Momeny, M., Jahanbakhshi, A., Jafarnezhad, K., & Zhang, Y. D. (2020). Accurate classification of cherry fruit using deep CNN based on hybrid pooling approach. *Postharvest Biology and Technology*, 166(April), 111204. <https://doi.org/10.1016/j.postharvbio.2020.111204>
- Myagila, K., & Kilavo, H. (2022). A Comparative Study on Performance of SVM and CNN in Tanzania Sign Language Translation Using Image Recognition. *Applied Artificial Intelligence*, 36(1). <https://doi.org/10.1080/08839514.2021.2005297>
- Rabbani, H. A., Rahman, M. A., & Rahayudi, B. (2021). Perbandingan Ruang Warna RGB dan HSV dalam Klasifikasi Kematangan Biji Kopi. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 5(6), 2243–2248. <http://j-ptiik.ub.ac.id>

- Raysyah, S., Arinal, V., & Mulyana, D. I. (2021). KLASIFIKASI TINGKAT KEMATANGAN BUAH KOPI BERDASARKAN DETEKSI WARNA MENGGUNAKAN METODE KNN DAN PCA. *Sistem Informasi* |, 8(2), 88–95.
- Rusman, J., & Pasae, N. (2023). Prototype Sistem Penyortir Buah Kopi Arabika Berdasarkan Tingkat Kematangan Menggunakan Metode Support Vector Machine. *Teknika*, 12(1), 65–72. <https://doi.org/10.34148/teknika.v12i1.602>
- Saragih, R. E., & Emanuel, A. W. R. (2021). Banana Ripeness Classification Based on Deep Learning using Convolutional Neural Network. *3rd 2021 East Indonesia Conference on Computer and Information Technology, EIconCIT 2021*, 85–89. <https://doi.org/10.1109/EIconCIT50028.2021.9431928>
- Sihombing, H. A., & Buulolo, I. C. (2021). Pengenalan Buah Kopi Berdasarkan Parameter Warna Menggunakan Algoritma Backpropagation Dan Algoritma Support Vector Machine (Svm). *Seminastika*, 3(1), 26–32. <https://doi.org/10.47002/seminastika.v3i1.234>
- Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. A. (2017). Inception-v4, inception-ResNet and the impact of residual connections on learning. *31st AAAI Conference on Artificial Intelligence, AAAI 2017*, 4278–4284. <https://doi.org/10.1609/aaai.v31i1.11231>
- Tamayo-Monsalve, M. A., Ruiz, E. M., Pulgarin, J. P. V., Ortiz, M. A. B., Arteaga, H. B. A., Rubio, A. M., Alzate-Grisales, J. A., Garzon, D. A., Cano, V. R., Arias, S. O., Osorio, G., & Soto, R. T. (2022). Coffee Maturity Classification Using Convolutional Neural Networks and Transfer Learning. *IEEE Access*, 10, 42971–42982. <https://doi.org/10.1109/ACCESS.2022.3166515>
- Waliyansyah, R. R., & Umar Hafidz Asy'ari Hasbullah. (2021). Comparison of Tree Method, Support Vector Machine, Naïve Bayes, and Logistic Regression on Coffee Bean Image. *EMITTER International Journal of Engineering Technology*, 9(1), 126–136. <https://doi.org/10.24003/emitter.v9i1.536>