

Kombinasi Arsitektur VGG16 dan DenseNet121 Untuk Klasifikasi Kualitas Biji Kopi Berdasarkan Tingkat Kematangan

ADZKIA FAJAR IHSANI^{1*}, MUHAMMAD ICHWAN¹,

¹Program Studi Informatika, Institut Teknologi Nasional Bandung
Email : adzkiafajar12@mhs.itenas.ac.id

Received 13 01 2023 | Revised 20 01 2023 | Accepted 20 01 2023

ABSTRAK

Kopi merupakan produk tanaman perkebunan yang dibutuhkan oleh masyarakat dunia. Di Indonesia kopi merupakan komoditas ekspor yang cukup tinggi. Indonesia menempati posisi ke empat dalam ekspor dan produsen kopi di dunia, setelah Brazil, Colombia, dan Vietnam. Tingkat kematangan atau tingkat sangrai kopi memiliki 4 tingkatan yaitu green bean, light roast, medium roast, dan dark roast. Dengan perkembangan kopi di Indonesia dibutuhkan perangkat lunak untuk membantu memberi informasi dan mengklasifikasi kualitas biji kopi. Penelitian ini mengkombinasikan arsitektur VGG16 dan DenseNet121 dengan memanfaatkan metode ensemble stacking pada klasifikasi kualitas biji kopi berdasarkan tingkat kematangannya. Hasil dari kombinasi arsitektur CNN diperoleh menunjukkan bahwa dengan menggunakan epoch 15 dan learning rate 0.0001 menghasilkan nilai rata-rata precision sebesar 98,5%, recall 98%, F1-Score 98,5% dan akurasi 98% dan nilai loss sebesar 27,4%.

Kata kunci: Kopi, CNN, VGG16, DenseNet121, Ensemble, Tingkat Kematangan Biji Kopi.

Abstract

Coffee is a plantation crop product that is needed by the world community. In Indonesia coffee is a fairly high export commodity. Indonesia ranks fourth in exports and coffee producers in the world, after Brazil, Colombia, and Vietnam. There are 4 levels of coffee maturity or roasting level, namely green bean, light roast, medium roast, and dark roast. With the development of coffee in Indonesia, software is needed to help provide information and classify the quality of coffee beans. This study combines the VGG16 and DenseNet121 architectures by utilizing the ensemble stacking method in classifying coffee beans' quality based on their maturity level. The results from the combination of CNN architectures show that using epoch 15 and a learning rate of 0.0001 produces an average value of precision of 98.5%, recall of 98 %, F1-Score 98.5%, the accuracy of 98%, and loss value of 27.4%.

Keywords: Coffee, CNN, VGG16, DenseNet121, Ensemble, Maturity Levels of Coffee Beans.

1. PENDAHULUAN

Kopi merupakan produk tanaman perkebunan yang dibutuhkan oleh masyarakat dunia. Di Indonesia kopi adalah komoditas ekspor yang cukup tinggi. Indonesia menempati posisi ke empat dalam ekspor dan produsen kopi di dunia, setelah Brazil, Colombia, dan Vietnam **(Rachmawanto et al., 2018)**. Perkembangan produksi kopi di Indonesia dari tahun 2018 sampai dengan 2020 mengalami fluktuasi. Pada tahun 2018 produksi kopi sebesar 756,05 ribu ton turun menjadi 752,51 ribu ton pada tahun 2019 atau turun sebesar 0.47 persen. Tahun 2020 produksi kopi naik menjadi 762,38 ribu ton atau meningkat sebesar 1,31 persen **(Badan Pusat Statistik, 2020)**.

Pengolahan kopi sangat berpengaruh dalam menentukan kualitas dan cita rasa kopi. Hal ini disebabkan, karena penanganan pasca panen yang tidak tepat salah satunya proses penyangraian. Tingkat sangrai biji kopi memiliki 3 tingkatan, yaitu light roast, medium roast, dan dark roast **(Hasiru et al., 2019)**. Metode deep learning sangat cocok digunakan saat memiliki jumlah data yang banyak. Deep learning adalah peningkatan jaringan syaraf tiruan, yang memiliki lapisan lebih banyak sehingga mendapatkan tingkat ekstraksi yang lebih tinggi dan lebih baik dalam prediksi **(Gunawan & Setiawan, 2022)**.

CNN memiliki fungsi untuk melakukan ekstraksi fitur. Fitur-fitur digunakan untuk proses atau tugas seperti klasifikasi, clustering ataupun regresi. CNN melakukan ekstraksi fitur secara otomatis pada convolutional layer, pooling layer dan juga aktivasi Rectified Linear Unit (ReLU) **(Setiawan, 2019)**.

Salah satu arsitektur CNN yang termasuk jaringan yang dalam yaitu *Visual Geometry Group* (VGG). Kelebihan dari arsitektur ini yaitu meskipun termasuk jaringan yang dalam, tetapi tidak akan mempengaruhi kompleksitas jaringan karena menggunakan filter konvolusi yang kecil pada data dengan jumlah besar. Sayangnya VGG tidak cocok digunakan pada data yang berukuran kecil karena menyebabkan jaringan mempelajari fitur-fitur secara berlebihan dan banyak digunakan dalam klasifikasi dibandingkan segmentasi. Arsitektur yang dapat mengurangi masalah mempelajari fitur yang berlebihan yaitu *Dense Connected* (*DenseNet*) **(Efriliyanti, 2021)**.

Teknik digunakan *Transfer Learning* agar mengoptimalkan kinerja model. Metode *transfer learning* merupakan metode yang menggunakan bobot dan fitur yang sudah dilatih menggunakan dataset yang besar, sehingga kaya akan fitur dan dapat mempercepat waktu komputasi **(Thiodorus et al., 2021)**.

Untuk lebih mengoptimalkan kinerja model dapat menggunakan Teknik *ensemble*. Metode *ensemble classifier* adalah penggunaan beberapa base classifier secara bersamaan dalam proses klasifikasi dengan tujuan untuk meningkatkan akurasi prediksi. Metode ensemble melakukan data preprocessing tanpa mereduksi baris data **(Fitriansyah, 2016)**

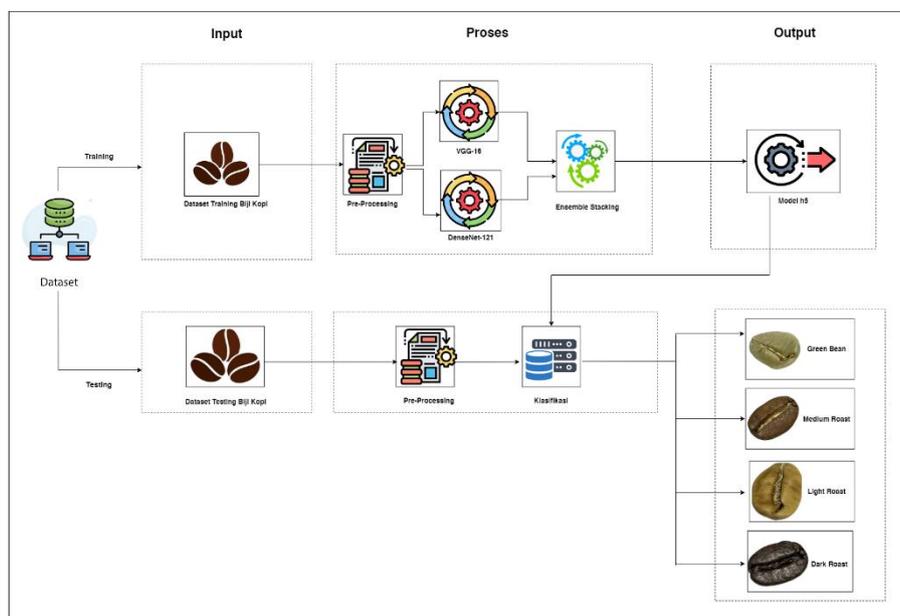
Melihat permasalahan yang telah dijelaskan diatas, maka pencipta melakukan penelitian terhadap hal-hal pendukung yang dapat mengatasi permasalahan tersebut, sehingga pencipta membangun sistem yang dapat mengklasifikasi kualitas biji kopi berdasarkan tingkat kematangan dengan memanfaatkan metode *ensemble stacking* dengan *base classifier* yaitu *Visual Geometry Group* dengan menggunakan *layer 16* (*VGG16*) dan *Dense Connected* dengan menggunakan 121 layer (*DenseNet-121*).

2. METODE PENELITIAN

Pada penelitian yang dilakukan oleh pencipta terdapat dua metode utama yaitu *VGG16* dan *DenseNet121*. Kedua metode tersebut dikombinasikan dengan menggunakan metode *Ensemble Stacking* dari model arsitektur yang sudah di buat.

2.2. Block Diagram

Pada penelitian yang dilakukan oleh pencipta terdapat beberapa tahapan dalam membangun sistem yang dapat melakukan klasifikasi kualitas biji kopi berdasarkan tingkat kematangannya yaitu terdapat proses input, proses, dan output, tahapan dalam membangun system yang dapat melakukan klasifikasi kualitas biji kopi berdasarkan tingkan kematangan akan digambarkan dalam bentuk block diagram seperti yang ditunjukkan pada Gambar 1.



Gambar 1. Block Diagram

2.3. Penggunaan Dataset

Dataset yang digunakan merupakan citra biji kopi dengan kategori *green bean*, *light roast*, *medium roast*, dan *dark roast*. Dataset diperoleh dari situs <https://www.kaggle.com/> dengan pemilik Pornphat Sroison, Sakdiat Ontoum, dan Thitaree K. Citra biji kopi diambil dengan iPhone12 Mini dengan kamera belakang 12 megapiksel, *Ultrawide*, dan *Wide Camera*. Citra dikumpulkan dan disimpan secara otomatis dalam format .png. Pada data yang di upload terdiri dari data *training* dan data *testing* tetapi pada penelitian yang dilakukan menambahkan data *validation* yang diperoleh dengan melakukan *split* dari data *training* sebesar 20%. Jumlah dataset sebelum dilakukan *split* akan ditunjukkan pada Tabel 1.

Tabel 1. Jumlah Dataset Awal

Kelas	Training	Testing
Green Bean	300	100
Light Roast	300	100
Medium Roast	300	100
Dark Roast	300	100

Jumlah dataset awal ditunjukkan melalui grafik seperti pada Gambar 2.



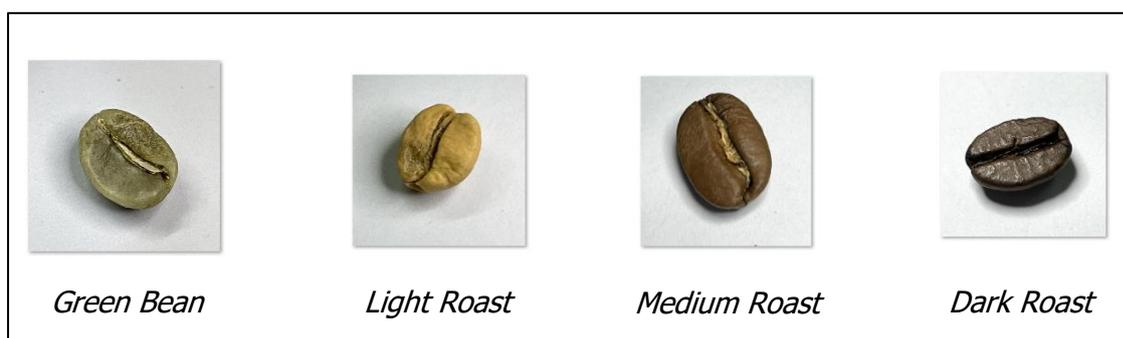
Gambar 2. Grafik Jumlah Dataset Awal

Jumlah dataset setelah dilakukan split data untuk kebutuhan data validation dapat dilihat pada Tabel 2.

Tabel 2. Jumlah Dataset Final

Kelas	Training	Validation	Testing
Green Bean	240	60	100
Light Roast	240	60	100
Medium Roast	240	60	100
Dark Roast	240	60	100

Pada dataset terdapat empat kelas yaitu green bean, light roast, medium roast, dan dark roast. Berikut adalah contoh dataset dari empat kelas tersebut yang ditunjukkan pada Gambar dibawah ini.



Gambar 4. Contoh Dataset

2.4 Preprocessing

Preprocessing citra merupakan tahapan yang bertujuan untuk perbaikan kualitas citra dan normalisasi data citra (**Fitri et al., 2021**). Pada tahapan pre-processing ini dilakukan beberapa tahapan terdiri dari resize ukuran dataset, dan augmentasi citra pada dataset.

2.3.1 *Resize*

Citra yang telah di input masuk ke proses *resize*. Pada proses *resize* ini data diubah ukuran setiap gambar sehingga memiliki jumlah piksel yang sama. Pada penelitian ini, citra diubah menjadi ukuran 224x224 piksel sebagai input untuk arsitektur *VGG16* dan *DenseNet121*.

2.3.2 *Augmentasi*

Augmentasi adalah proses yang digunakan untuk memperkaya citra dengan cara membuat citra baru dari citra yang sudah ada (**Mega Pradnya & Putri Kusumaningtyas, 2022**). Teknik augmentasi ini sering dilakukan terutama pada pengujian yang jumlah ditanya terbatas (**Rochmawanti et al., 2021**). Proses augmentasi yang dilakukan pada penelitian ini adalah membalikan citra secara horizontal, merotasi dan melakukan pembesaran (*zoom*) gambar secara acak.

2.4. *Convolutional Neural Network (CNN)*

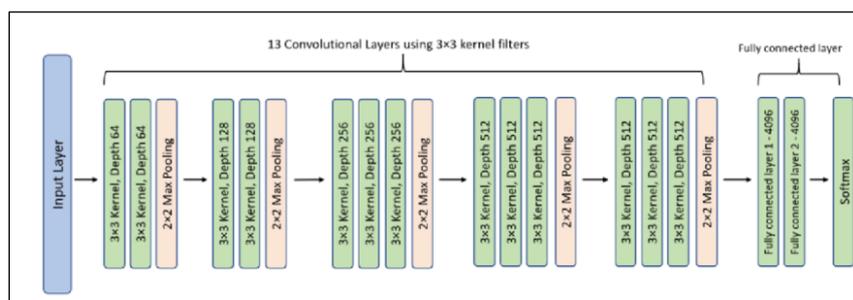
Convolutional Neural Network (CNN) merupakan salah satu metode *machine learning* dari pengembangan *Multi-Layer Perceptron (MLP)* untuk mengolah data dua dimensi. CNN termasuk dalam jenis *Deep Neural Network* karena memiliki banyak tingkat jaringan dan banyak di implementasikan dalam data citra (**Kusuma Putra et al., 2020**). Arsitektur CNN umumnya memiliki tiga tipe *layer* yang menjadi inti yaitu *convolution layer*, *pooling layer*, dan *fully connected layer* (**Rochmawanti et al., 2021**). Beberapa penelitian sebelumnya sudah melakukan untuk mengembangkan metode CNN yaitu dengan membuat beberapa model arsitektur yang diharapkan mampu meningkatkan nilai akurasi dan mengurangi nilai *error*.

2.5. *Transfer Learning*

Transfer learning adalah Teknik memanfaatkan model yang sudah dilakukan proses *training* pada data sebelumnya, proses ini digunakan untuk klasifikasi dataset baru sehingga tidak lagi diperlukan proses *training* dari awal hanya dilakukan penyesuaian pada bagian model akhir (**Amrulloh et al., 2022**).

2.6. *Visual Geometry Group (VGG)*

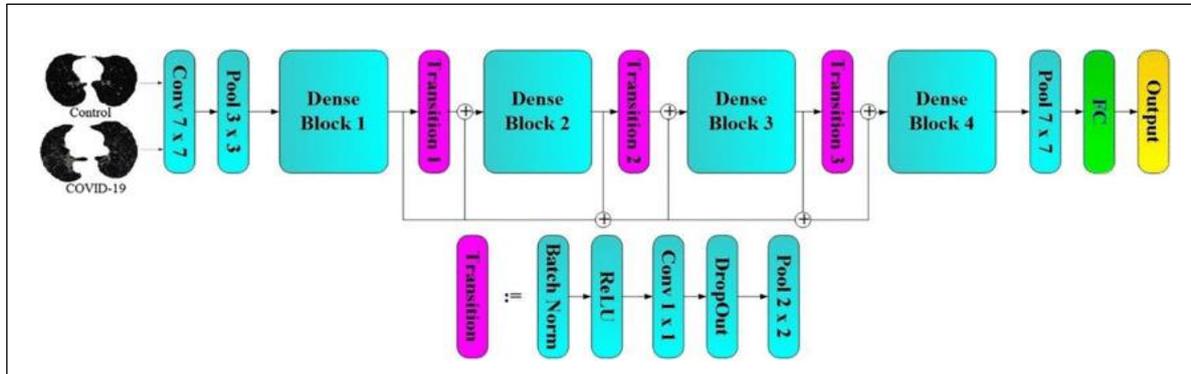
VGG16 merupakan model *convolutional neural network*. VGG16 adalah penyempurnaan dari model AlexNet. VGG16 menggunakan ukuran kernel 3x3. Arsitektur VGG16 memiliki 16 layer yang terdiri dari 13 *convolutional layer* dan 3 *fully connected layer*. (**Suryaman et al., 2021**). Arsitektur VGG16 dapat dilihat pada Gambar 6.



Gambar 6. Arsitektur VGG16

2.7. *Densely Connected Convolutional Network (DenseNet)*

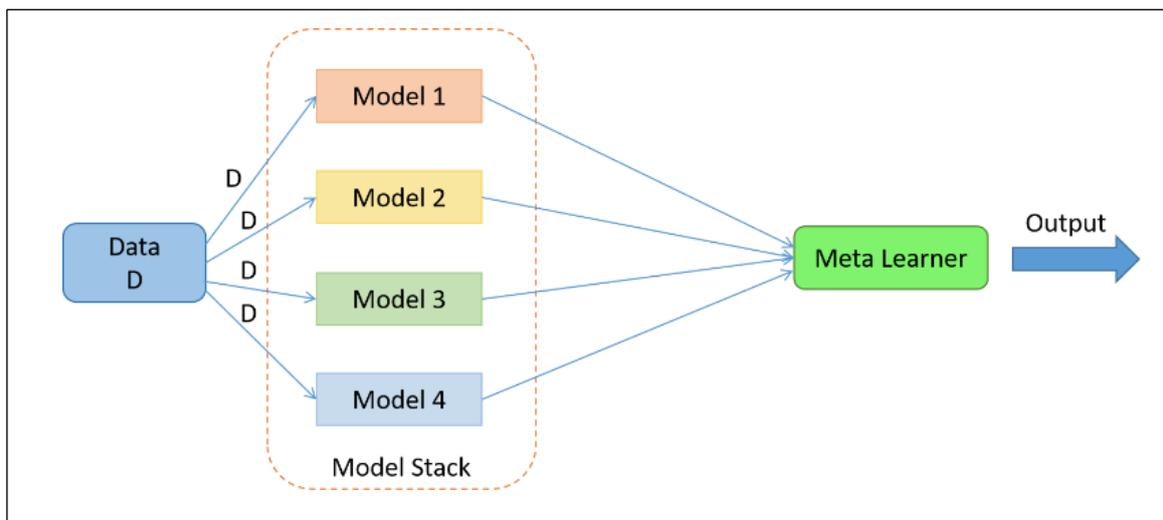
Densely Connected Convolutional Network (DenseNet) struktur ini dibangun dari masing-masing layer yang terhubung dengan layer lainnya. Dense connection merupakan bagian dari arsitektur DenseNet dan fungsinya untuk mengurangi terjadinya overfitting ketika jumlah data dalam skala besar. Pada penelitian yang dilakukan kali ini menggunakan ada model DenseNet121. Arsitektur DenseNet121 dapat dilihat pada Gambar 7.



Gambar 7. Arsitektur DenseNet121

2.7. *Ensemble Learning*

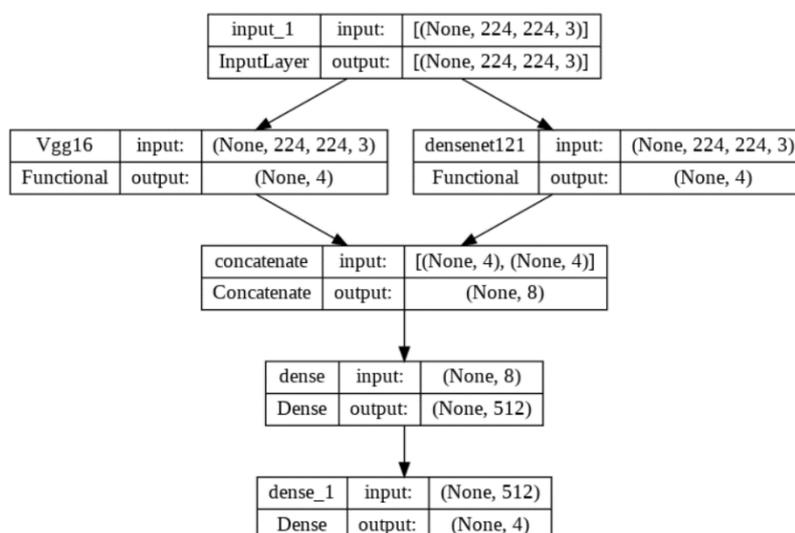
Ensemble learning merupakan metode yang mencari model terbaik dengan cara mengkombinasikan beberapa model. Model dilatih dengan sendiri-sendiri kemudian mengkombinasikan model tersebut (**Wahid, 2022**). Salah satu metode *ensemble* yaitu *stacking*. *Stacking* adalah sebuah metode dimana sebuah *learner* ditraining untuk menggabungkan beberapa *individual learner* yang disebut *first-level learner*, sedangkan yang digabungkan disebut *second-level-learner* atau *meta-learner*. Model yang berbeda digunakan oleh *base learner* untuk belajar dari suatu dataset. *Output* dari masing-masing model dikumpulkan untuk membuat dataset baru. Didalam dataset yang baru, setiap sampel berhubungan dengan nilai sesungguhnya yang seharusnya diklasifikasi (**Karomah, 2022**). Berikut ini adalah tahapan metode *stacking* yang ditunjukkan pada Gambar 8.



Gambar 8. Tahapan Metode Ensemble Stacking

2.5 Pelatihan Model

Pada penelitian ini setelah dilakukan preprocessing maka akan dilakukan pelatihan model menggunakan arsitektur VGG16 dan DenseNet121. Setelah mendapatkan model terbaik dari dua arsitektur tersebut maka akan dilakukan kombinasi dengan memanfaatkan metode ensemble stacking. Hasil model setelah dilakukan kombinasi dapat dilihat pada Gambar 9.



Gambar 9. Model *Ensemble Stacking*

2.6 Evaluasi Model

Tahap evaluasi dilakukan untuk mengetahui kinerja model yang sudah dihasilkan. Tahap ini dapat diukur menggunakan nilai *accuracy*, *precision*, *f1-score*, dan *recall* (Awalia & Primajaya, 2022). Dalam mengestimasi eksekusi dengan menggunakan *confusion matrix*, terdapat 4 (empat) istilah dari sistem pengelompokan. Nilai *True Negative* (TN) adalah jumlah informasi *negative* yang dapat dibedakan secara akurat, sedangkan *False Positive* (FP) adalah informasi *negative* tetapi diidentifikasi sebagai informasi yang pasti. Terdapat juga istilah *True Positive* (TP) adalah informasi positif yang dibedakan secara akurat. *False Negative* (FN) adalah sesuatu yang bertentangan dengan *True Positive*, sehingga informasi yang positif, namun diakui sebagai informasi yang negatif (Saputro et al., 2022).

Dimana rumus perhitungan seperti pada Persamaan (1),(2),(3),dan (4).

Accuracy merupakan hasil prediksi benar dari semua dataset. perhitungan *accuracy* dapat dilihat pada persamaan (1)

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

Precision merupakan suatu informasi yang diambil pada salah satu bagian data. perhitungan *precision* dapat dilihat pada persamaan (2)

$$Precision = \left(\frac{TP}{TP+FP} \right) \times 100\% \quad (2)$$

Recall merupakan seberapa akurat kinerja suatu model untuk mengklasifikasi benar atau menghitung banyaknya kekeliruan klasifikasi *false negative* pada model. Perhitungan *recall* dapat dilihat pada persamaan (3)

$$Recall = \left(\frac{TP}{TP+FP+FN+FP} \right) \times 100\% \quad (3)$$

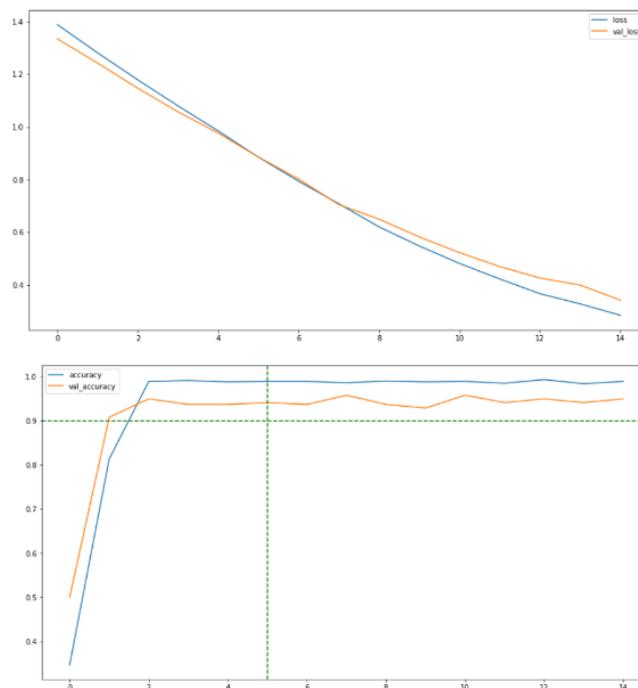
F1-Score merupakan perbandingan rata-rata harmonic antara nilai *precision* dan nilai *recall*. Perhitungan *f1-score* dapat dilihat pada persamaan (4)

$$F1 - Score = \frac{2x(Precision \times Recall)}{Precision + Recall} \times 100\% \quad (4)$$

3. HASIL DAN PEMBAHASAN

3.1 Pengujian Kinerja Sistem

Pengujian kinerja sistem dilakukan untuk melihat confusion matrix dan mengukur *accuracy*, *precision*, *recall*, dan *f1-score*. Pada pengujian kinerja sistem ini menggunakan data testing yang terdapat pada dataset dimana terdapat 4 kelas yaitu *green bean*, *light roast*, *medium roast*, dan *dark roast*. Pada penelitian terdapat beberapa *hyperparameter*, salah satu yang digunakan pada penelitian ini menggunakan *epoch* 15 dengan *learning rate* 0.0001 dan menggunakan *optimizer Adaptive Moment Estimation (ADAM)*. Berikut ini adalah hasil dari penelitian menggunakan *hyperparameter* yaitu *epoch* 15, *learning rate* 0.0001, dan menggunakan *optimizer ADAM*. Pada pengujian ini menggunakan arsitektur pada *convolutional neural network* yaitu *Visual Geometry Group (VGG)* dengan menggunakan 16 layer dan *Dense Connected (DenseNet)* dengan menggunakan 121 layer yang dimanaa dikombinasikan dengan menggunakan metode *ensemble stacking*. Pengujian ini dapat dilihat pada Gambar dibawah ini.



Gambar 9. Grafik Pengujian Metode *Ensemble Stacking*

Pengujian kinerja sistem merupakan pelatihan data dengan menggunakan hyperparameter epoch 15 dengan learning rate 0.0001 dengan menggunakan optimizer ADAM. Pada Tabel 6 akurasi dari tiap model arsitektur yang dibuat sudah cukup baik, dimana model yang digunakan arsitektur VGG16 dan DenseNet121 memiliki akurasi diatas 80%. Kemudian untuk implementasi ensemble stacking transfer learning CNN dimana akurasi training mencapai 98%. Nilai akurasi training yang tidak jauh menandakan tidak terjadi *overfitting*.

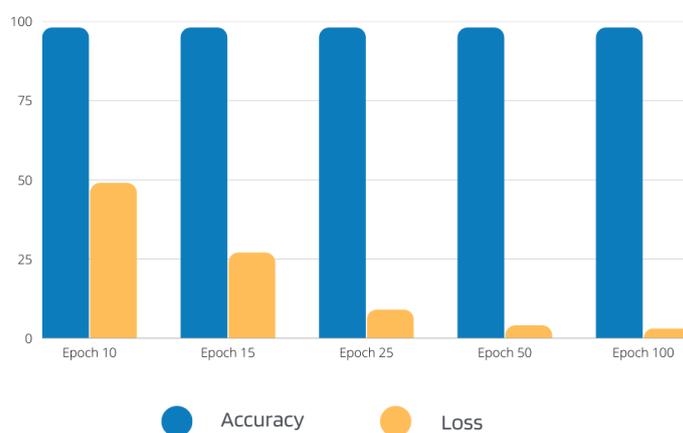
3.2 Perbandingan Hyperparameter

Pada penelitian ini dengan menggunakan metode ensemble stacking tidak menggunakan satu nilai hyperparameter terdapat juga beberapa nilai yang bertujuan menghasilkan model terbaik. Berikut beberapa perbandingan hyperparameter dengan menggunakan optimizer ADAM dapat dilihat pada Tabel 9.

Tabel 9. Perbandingan Hyperparameter

Epoch	Learning Rate	Accuracy	Loss
10	0.0001	98%	49,1%
15	0.0001	98,7%	27,4%
25	0.0001	98,7%	9%
50	0.0001	98,7%	4%
100	0.0001	98,7%	3%

Pada penelitian ini membandingkan nilai rata-rata dari hyperparameter dengan epoch yang berbeda pada optimizer ADAM. Pada epoch 100 dengan learning rate 0.0001 memiliki akurasi tertinggi yaitu 98,7% dengan nilai loss yang paling rendah yaitu 3%. Perbandingan nilai rata rata dapat dilihat dalam bentuk grafik yang dapat



Gambar 11. Grafik perbandingan Hyperparameter

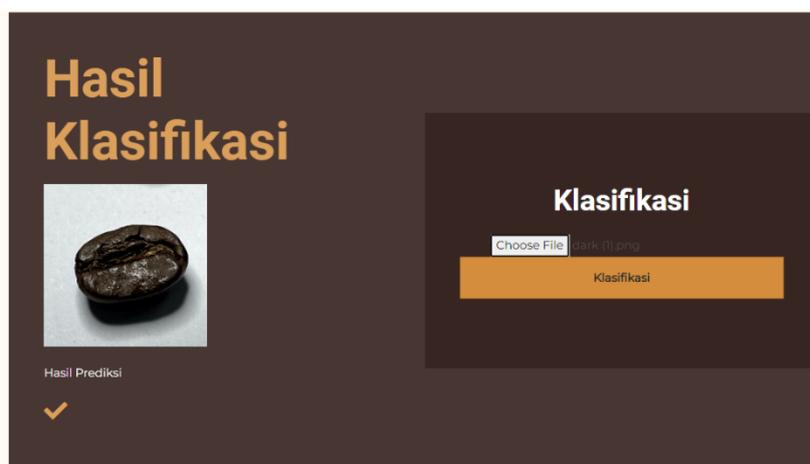
3.2 Implementasi *User Interface*

Setelah dilakukan pengujian model, implementasi dilakukan dengan pembuatan *user interface* berbasis *website* dengan menggunakan *flask*. Tampilan user face dapat dilihat pada Gambar 12.



Gambar 21. Tampilan *User Interface*

Untuk melakukan klasifikasi terdapat section klasifikasi, yang dimana user diminta untuk memasukan citra yang akan diklasifikasi, setelah diklasifikasi sistem akan memberikan output berupa hasil dari klasifikasi. Berikut ini adalah gambar dari tampilan klasifikasi yang ditunjukkan oleh gambar dibawah ini.



Gambar 31. Tampilan *User Interface* Klasifikasi



Gambar 41. Output Klasifikasi

4. KESIMPULAN

Hasil Penelitian yang dilakukan menunjukkan bahwa kombinasi arsitektur CNN yaitu Visual Geometry Group (VGG) menggunakan 16 layer dan Dense Connected (DenseNet) menggunakan 121 layer dengan memanfaatkan metode ensemble stacking untuk mengklasifikasi kualitas biji kopi berdasarkan tingkat kematangannya. Hasil dari kombinasi arsitektur CNN diperoleh menunjukkan bahwa dengan menggunakan epoch 15 dan learning rate 0.0001 menghasilkan nilai rata rata precision sebesar 98,5%, recall 98%, F1-Score 98,5% dan akurasi 98% dan nilai loss sebesar 27,4%.

DAFTAR PUSTAKA

- Amrulloh, M. F., Lutfi, M., & Nurcahyo, W. A. (2022). Deep Pre-Trained Multi Model Convolution Neural Network Untuk Diagnosa Covid 19 Pada Citra Rontgen Dada. *Jurnal Mahasiswa Teknik Informatika*, 6(2), 649–654.
- Awalia, N., & Primajaya, A. (2022). IDENTIFIKASI PENYAKIT LEAF MOLD DAUN TOMAT MENGGUNAKAN MODEL DENSENET121 BERBASIS TRANSFER LEARNING. 8(1). <http://ejournal.fikom-unasman.ac.id>
- Badan Pusat Statistik. (2020). Statistik Kopi Indonesia. *Badan Pusat Statistik (BPS-Statistics Indonesia)*, 4(1), 88–100.
- Efriliyanti, F. (2021). KOMBINASI ARSITEKTUR VGG DAN DENSE CONNECTED (DENSENET) PADA MODEL CONVOLUTIONAL NEURAL NETWORK UNTUK SEGMENTASI PEMBULUH DARAH CITRA RETINA SKRIPSI.
- Fitri, Z. E., Syahbana, B. A., Madjid, A., Mujibtamala, A., Imron, N., Informatika, T., Informasi, J. T., Jember, P. N., Perkebunan, B. T., & Pertanian, J. P. (2021). Penerapan Fitur Warna dan Tekstur untuk Identifikasi Kerusakan Mutu Biji Kopi Arabika (Coffea Arabica) di Kabupaten Bondowoso. *Jurnal Ilmiah Teknologi Informasi Asia*, 15(2).
- Fitriansyah, R. A. (2016). Penerapan Ensemble Stacking Untuk Klasifikasi Multi Kelas. [Http://Ars.Iikom.Unsri.Ac.Id](http://Ars.Iikom.Unsri.Ac.Id), 2(1), 240–243.
- Gunawan, D., & Setiawan, H. (2022). *Convolutional Neural Network dalam Analisis Citra Medis* (Vol. 2, Issue 2).

- Hasiru, M. I. U., Raharjo, D. I. jangkun., & Ibrahim, N. (2019). *KLASIFIKASI TINGKAT SANGRAI BIJI KOPI BERBASISKAN PENGOLAHAN CITRA DIGITAL DENGAN MENGGUNAKAN SINGULAR VALUE DECOMPOSITION DAN LEARNING VECTOR QUANTIZATION*. *44*(12), 2–8.
- Karomah, B. M. (2022). Penerapan Metode Stacking Dalam Mengklasifikasikan Penderita Penyakit Diabetes. *Jupikom*, *1*(3). <http://ejurnal.stie-trianandra.ac.id/index.php/jupkom>HalamanUTAMAJurnal:<http://ejurnal.stie-trianandra.ac.id/index.php>
- Kusuma Putra, A., Bunyamin, H., & Maranatha JI drg Surya Sumantri No, K. (2020). *Pengenalan Simbol Matematika dengan Metode Convolutional Neural Network (CNN)* (Vol. 2).
- Mega Pradnya, W. D., & Putri Kusumaningtyas, A. (2022). Analisis Pengaruh Data Augmentasi Pada Klasifikasi Bumbu Dapur Menggunakan Convolutional Neural Network. *Jurnal Media Informatika Budidarma*, *6*(4), 2022–2031. <https://doi.org/10.30865/mib.v6i4.4201>
- Rachmawanto, E. H., Salam, A., Kunci, K., & Robusta, K. (2018). *PENGUKURAN TINGKAT KEMATANGAN KOPI ROBUSTA MENGGUNAKAN ALGORITMA K-NEAREST NEIGHBOR*.
- Rochmawanti, O., Utaminingrum, F., & Bachtiar, F. A. (2021). ANALISIS PERFORMA PRE-TRAINED MODEL CONVOLUTIONAL NEURAL NETWORK DALAM MENDETEKSI PENYAKIT TUBERKULOSIS. *Jurnal Teknologi Informasi Dan Ilmu Komputer (JTIK)*, 805–813. <https://doi.org/10.25126/jtiik.202184441>
- Saputro, A., Mu'min, S., Lutfi, M., & Putri, H. (2022). DEEP TRANSFER LEARNING DENGAN MODEL ARSITEKTUR VGG16 UNTUK KLASIFIKASI JENIS VARIETAS TANAMAN LENGKENG BERDASARKAN CITRA DAUN. In *Jurnal Mahasiswa Teknik Informatika* (Vol. 6, Issue 2).
- Setiawan, W. (2019). *PERBANDINGAN ARSITEKTUR CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI FUNDUS*. *7*(2).
- Suryaman, S. A., Magdalena, R., & Sa'idah, S. (2021). Klasifikasi Cuaca Menggunakan Metode VGG-16, Principal Component Analysis Dan K-Nearest Neighbor. *Jurnal Ilmu Komputer Dan Informatika*, *1*(1), 1–8. <https://doi.org/10.54082/jiki.1>
- Thiodorus, G., Prasetya, A., Afrizal, L., & Yudistira, N. (2021). *Klasifikasi citra makanan / nonmakanan menggunakan metode Transfer Learning dengan model Residual Network Classification of food / non-food images using Transfer Learning method with Residual Network model*. *11*(2), 74–83.
- Wahid, M. I. (2022). *Perbandingan Kinerja Model Ensemble Transfer Learning Pada Klasifikasi Penyakit Daun Tomat*.