

Komparasi Kombinasi *Pre-trained Model* dengan SVM pada Klasifikasi Kematangan Kopi Berbasis Citra

Aryo Michael^{1,*}

¹ Teknik Informatika, Universitas Kristen Indonesia Toraja, Jl, Nusantara No. 12 Tana Toraja, Indonesia

¹ aryomichael@ukitoraja.ac.id;

*corresponding author

INFORMASI ARTIKEL

ABSTRAK

Kata Kunci:

Machine Learning
Transfer Learning
Support Vector Machine
Klasifikasi Citra
Kopi

Harga kopi di pasar dunia dilihat dari kualitas kopi itu sendiri. Kualitas kopi sangat dipengaruhi oleh proses pengolahan kopi mulai dari proses taman hingga proses pasca panen. Salah satu proses pada tahapan pasca panen adalah melakukan penyortiran kopi yang matang. Identifikasi kematangan kopi pada dasarnya dilihat dari warna buah kopi. Perkembangan teknologi kecerdasan buatan secara khusus pembelajaran mendalam (*deep learning*) dapat digunakan untuk menyelesaikan permasalahan tersebut melalui klasifikasi. Salah satu metode yang dapat digunakan adalah *transfer learning* dengan menggunakan model yang telah dilatih sebelumnya untuk menyelesaikan tugas yang hampir sama. Tujuan penelitian ini adalah membandingkan pre-trained model yaitu VGG16, MobilnetV2 dan Inception yang dikombinasikan dengan *support vector machine* (SVM) pada lapisan *classifier* untuk melakukan klasifikasi kematangan buah kopi. Proses pelatihan model menggunakan *tuning hyperparameter GridsearchCV* dengan *10 fold cross validation* untuk mendapatkan kombinasi parameter terbaik dari SVM. Hasil penelitian memperlihatkan kombinasi model VGG16 dengan SVM dan MobileNetV2 dengan SVM memperlihatkan akurasi sebesar 0,96 atau 96%.

Keywords:

Machine Learning
Transfer Learning
Support Vector Machine
Images Classification
Coffee

ABSTRACT

The price of coffee on the world market is seen from the quality of the coffee itself. The quality of coffee is greatly influenced by the coffee processing process from the garden process to the post-harvest process. One of the processes in the post-harvest stage is to sort mature coffee. The identification of ripeness of the coffee is seen from the color of the coffee fruit. The development of artificial intelligence technology, especially deep learning, can be used to solve these problems through classification. One of the methods that can be used is transfer learning by using a pre-trained model to complete almost the same task. The purpose of this study was to compare pre-trained models VGG16, MobilnetV2, and InceptionV3 combined with a support vector machine (SVM) on the classifier layer to classify the ripeness of coffee fruit. The model training process uses GridsearchCV hyperparameter tuning with 10-fold cross-validation to get the best combination of parameters from SVM. The results showed that the combination of the VGG16 model with SVM and MobileNetV2 with SVM showed an accuracy of 0.96 or 96%.

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.



I. Pendahuluan (bold, 10 pt)


Identifikasi kematangan buah kopi dapat didasarkan pada warnanya yang dapat diekstraksi melalui citra. Citra buah kopi diproses dengan teknik pengolahan citra melalui proses ekstraksi fitur untuk mendapatkan data ciri-ciri dari buah kopi, kemudian algoritma *machine learning* akan mempelajari fitur tersebut untuk dilakukan proses pembelajaran, dan melakukan pengelompokan terhadap data yang telah dipelajari sebelumnya[1],[2],[3],[4],[5]. Pemilihan fitur yang tepat akan menghasilkan kinerja yang baik, akan tetapi pemilihan fitur yang kurang tepat akan menghasilkan kinerja yang kurang baik. Untuk mendapatkan model yang memiliki akurasi klasifikasi yang baik serta menghindari *overfitting* diperlukan dataset yang cukup banyak serta bervariasi untuk dilatih, sehingga model yang dihasilkan memiliki akurasi yang baik[6]. Hal ini

menyebabkan penggunaan besar-besaran dari *transfer learning* terutama dalam *deep learning*. *Transfer learning* memungkinkan untuk mentransfer pengetahuan dari model telah dilatih (*pre-trained*) dan menerapkan pada permasalahan lain yang serupa[7][8][9] sehingga dapat mengatasi permasalahan kurangnya dataset. Model *transfer learning* terdiri atas 2 lapisan utama yaitu lapisan ekstraksi fitur (*feature extractor*) yang terdiri atas lapisan konvolusi dan lapisan *polling* dan lapisan *fully conneted* yang merupakan lapisan *classifier*. Berbagai model *transfer learning* yang telah dilatih dengan dataset *imagenet* dapat diterapkan untuk melakukan klasifikasi seperti VGG16[10], ResNet[11], Inception[7], MobileNet[12] dengan menyesuaikan beberapa parameter algoritma yang digunakan serta jumlah *output* yang akan dihasilkan.

Pemilihan parameter yang tepat untuk model yang diusulkan harus dilakukan sehingga model yang dihasilkan dapat meningkatkan hasil klasifikasi. Menetapkan parameter yang tepat untuk sebuah model klasifikasi memerlukan waktu yang cukup lama serta biaya komputasi yang tinggi karena jumlah parameter yang dilatih sangat banyak karna dilakukan berkali-kali. Pengembangan model klasifikasi juga membutuhkan orang yang ahli untuk mengambil keputusan yang tepat seperti fitur yang baik untuk digunakan pada proses klasifikasi serta arsitektur yang sesuai sehingga perlu *tuning hyperparameter* untuk mengoptimalkan pemilihan parameter yang tepat untuk model klasifikasi. *Tuning hyperparameter* memiliki peran penting dalam pembelajaran mesin dan algoritma *deep learning* karena parameter yang dihasilkan mempengaruhi kinerja model secara signifikan[13]. Oleh karena itu dalam penelitian ini akan membandingkan model *pre-trained VGG16*, *MobileNetV2* dan *InceptionV3* pada lapisan ekstraksi fitur yang dikombinasikan dengan algoritma klasifikasi SVM pada lapisan *classifier* dengan *tuning hyperparameter GridsearchCV* untuk mengoptimalkan pemilihan parameter yang tepat untuk model klasifikasi kematangan buah kopi menggunakan citra.

II. Metode

Penelitian ini merupakan penelitian eksperimen yang dilakukan dalam beberapa tahapan seperti pada Gambar 1.



Gambar 1. Alur Penelitian

A. Pengumpulan Dataset

Pengumpulan dataset diperoleh dengan cara mengambil citra buah kopi arabika pada daerah penghasil kopi arabika yang ada di Toraja Utara dan Tana Toraja yang terdiri dari 4 tingkat kematangan buah kopi yaitu buah kopi arabika yang mentah, matang setengah, matang sempurna dan matang tua dimana masing-masing tingkat kematangan terdiri atas 500 citra buah kopi sehingga total dataset yang digunakan pada penelitian ini sebanyak 2000 citra. Citra buah kopi diambil dalam resolusi yang berbeda-beda.



Gambar 2. Dataset Citra Buah Kopi (a) Matang Sempurna (b) Matang Setengah (c) Matang Tua (d) Mentah


Beberapa tahap seperti menyiapkan data gambar dengan pra proses sebagai tahapan mempersiapkan dataset agar dapat diolah pada model *transfer learning* seperti melakukan proses *resize* citra untuk menyamakan dimensi citra yang disesuaikan sesuai dengan inputan model, melakukan pelabelan *encoding* pada kelas citra. Dataset yang telah melewati tahapan pra proses dibagi ke dalam 2 bagian 70% data pelatihan dan 30% data pengujian secara acak.

TABEL 1.
PEMBAGIAN DATASET

Dataset	Jumlah Sampel
Pelatihan	1400
Pengujian	600

B. Rancangan Arsitektur Model

Arsitektur yang akan digunakan pada penelitian ini seperti pada Gambar 2. Model yang telah dilatih menggunakan dataset *imagenet* (*pre-trained*). Bobot di pada lapisan *feature extractor* tidak akan diperbarui saat proses pelatihan (*freeze*), atau dengan kata lain proses belajar hanya akan dilakukan di lapisan *classifier* untuk melakukan klasifikasi terhadap data. Pada penelitian ini akan dilakukan percobaan terhadap *pre-trained* model yang dijadikan sebagai lapisan ekstraksi fitur yaitu VGG-16, MobileNetV2, InceptionV3. VGG16 adalah model *deep learning* menggunakan 16 layer *convolutional* dengan input ke arsitektur adalah gambar $224 \times 224 \times 3$ piksel dan di lewatkan melalui tumpukan lapisan kovolusi dengan ukuran filter 3×3 [9]. Arsitektur *InceptionV3* adalah varian dari model *deep learning* yang dibangun oleh Google. Arsitektur ini memiliki parameter yang lebih sedikit dibanding arsitektur VGG16, arsitektur ini memiliki input $229 \times 229 \times 3$ sedangkan MobileNetV2 merupakan perbaikan dari *Inception*. Pada lapisan *classifier* akan digunakan algoritma klasifikasi *Support Vector Machine* (SVM).



Gambar 3. Arsitektur Model

C. Grid Search CV

Tuning Hyperparameter merupakan metode untuk melakukan pemilihan *hyperparameter* yang optimal dalam algoritma *machine learning* [14][15]. Ada 2 metode yang digunakan pada optimasi *hyperparameter* yaitu *grid search* dan *randomized search* [11][16]. *Grid search* merupakan standar pemilihan kombinasi model dan *hyperparameter* yang merupakan standar pada *machine learning* [16]. *Grid search* menguji kombinasi *hyperparameter* satu per satu dan memvalidasi setiap kombinasi [17]. Pengaturan nilai *hyperparameter* pada *grid search* dilakukan dengan menentukan nilai parameter dari rentang nilai parameter tertentu. Peningkatan nilai akurasi dapat dioptimalkan dengan menggunakan *grid search CV* [13]. *Grid search CV* merupakan istilah yang digunakan untuk merujuk pada kombinasi teknik *Grid Search* dan *Cross-Validation* yang merupakan suatu metode pemilihan kombinasi *hyperparameter* pada model dengan cara menguji coba satu persatu kombinasi dan melakukan validasi untuk setiap kombinasi. *Grid search CV* dikombinasikan dengan *k-fold cross-validation*, untuk mendapatkan indeks evaluasi untuk model klasifikasi [13]. Akurasi model k dapat diperoleh, dan kinerja model klasifikasi validasi silang *k-fold* dievaluasi berdasarkan akurasi rata-rata model k. Model terbaik ditentukan berdasarkan rata-rata skor. *K-fold cross-validation* dapat mengulang data latih dan data uji sebanyak k repetisi dan pembagian $1/k$ dari dataset yang digunakan sebagai data uji. Selanjutnya, parameter lapisan *classifier* diubah berdasarkan pencarian grid, dan akurasi *classifier* dihitung ulang. Pada penelitian ini akan dilakukan optimasi kombinasi parameter pada SVM yaitu parameter “C” dengan nilai 0.001, 0.01, 0.1, 1, 10, dan 100 dengan parameter kernel “*linear*”.

D. Pengujian dan Evaluasi Model

Tahapan pengujian dilakukan untuk mengetahui performa model untuk melakukan klasifikasi dataset uji dengan menggunakan parameter terbaik hasil *tuning hyperparameter*. Salah satu metode yang digunakan untuk pengukuran kinerja dari model klasifikasi lebih dari 2 kelas (*multiclass*) adalah *confusion matrix*. *Confusion matrix* dapat digunakan untuk membantu perhitungan *accuracy*, *precision*, *recall* dan *f1-score* [18],[19].

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

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

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


$$f1 - score = \frac{2 * Precision * Recall}{Precision + Recall} \quad (4)$$

III. Hasil dan Pembahasan


3.1 Tahapan Pelatihan Model

Model *transfers learning* yang telah dilatih menggunakan dataset *imagenet* kemudian bobot dan arsitekturnya dilatih kembali dengan cara membekukan lapisan ekstraksi fitur, menambahkan lapisan klasifikasi baru pada citra yang akan dilakukan klasifikasi. konfigurasi *hyperparameter tuning Grid search CV* dengan 10


fold validasi silang dilakukan sebelum pelatihan model dilakukan. Gambar 3-5 menunjukkan hasil pelatihan model dengan grid search CV.



Gambar 3. Grafik Means Test Score VGG16 + SVM



Gambar 4. Grafik Means Test Score MobileNetV2 + SVM



Gambar 5. (a) Grafik Means Test Score InceptionV3 + SVM

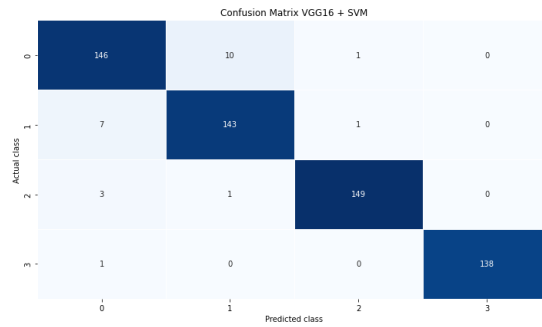
Parameter terbaik untuk setiap model yang dihasilkan pada tahapan pelatihan model disajikan pada Tabel 2.

TABEL 2.
MODEL DENGAN OPTIMASI HYPERPARAMETER TUNING


Model	Parameter Terbaik
VGG16 + SVM	C = 0,001 Kernel =”Linear
MobileNetV2 + SVM	C = 0,001 Kernel =”Linear
InceptionV3 + SVM	C = 0,001 Kernel =”Linear

3.2 Tahapan Pengujian Model


Pengujian model dilakukan menggunakan parameter terbaik yang dihasilkan dari *tuning hyperparameter* terbaik dari tahapan pelatihan model. Hasil pengujian masing-masing model dalam melakukan klasifikasi terhadap dataset uji ditunjukkan menggunakan *confusion matrix* seperti pada Gambar 7-9.



Gambar 7. Tabel *Confusion Matrix* VGG16 + SVM



Gambar 8. Tabel *Confusion Matrix* MobileNetV2 + SVM



Gambar 9. Tabel *Confusion Matrix* InceptionV3 + SVM

Dari tabel *confusion matriks* hasil pengujian, selanjutnya dilakukan evaluasi terhadap kinerja dari setiap model dengan mengukur *accuracy*, *precision*, *recall* dan *f1-score*. Hasil pengukuran kinerja dari setiap model disajikan pada Tabel

TABEL 3.
PERFORMA MODEL VGG16 + SVM

	precision	recall	f1-score	support
Matang Sempurna	0.93	0.93	0.93	157
Matang Setengah	0.93	0.95	0.94	151
Matang Tua	0.99	0.97	0.98	153
Mentah	1.00	0.99	1.00	139
accuracy			0.96	600
macro avg	0.96	0.96	0.96	600
weighted avg	0.96	0.96	0.96	600

TABEL 4.
PERFORMA MODEL MOBILENETV2 + SVM

	precision	recall	f1-score	support
Matang Sempurna	0.94	0.94	0.94	157
Matang Setengah	0.93	0.95	0.94	151
Matang Tua	0.98	0.97	0.98	153
Mentah	0.99	0.99	0.99	139
accuracy			0.96	600
macro avg	0.96	0.96	0.96	600
weighted avg	0.96	0.96	0.96	600

TABEL 4.
PERFORMA MODEL INCEPTIONV3 + SVM

	precision	recall	f1-score	support
Matang Sempurna	0.81	0.81	0.81	157
Matang Setengah	0.83	0.83	0.83	151
Matang Tua	0.87	0.91	0.89	153
Mentah	0.93	0.89	0.91	139
accuracy			0.86	600
macro avg	0.86	0.86	0.86	600
weighted avg	0.86	0.86	0.86	600

Dari perhitungan performa dari model memperlihatkan nilai *accuracy*, *precision*, *recall* dan *f1-score* yang dihasilkan oleh VGG16 + SVM dan MobileNetV2 + SVM hampir sama dimana hasil perhitungan *accuracy* sebesar 0,96. Sementara akurasi model inceptionV3 + SVM sebesar 86%.

IV. Kesimpulan dan Saran

Penelitian ini menunjukkan bahwa klasifikasi gambar dapat dicapai dengan model pembelajaran mesin menggunakan citra hsv dengan *transfer learning*. Dari percobaan yang kami lakukan, Kombinasi model VGG16 dan MobileNetV2 sebagai lapisan *feature extractor* memiliki kinerja yang lebih baik mengungguli model Inceptionv3. Penelitian selanjutnya kami berencana untuk melakukan percobaan dengan seluruh dataset dengan inputan citra yang memiliki informasi yang lebih detail seperti HSV dengan berbagai *pre-trained model* dan algoritma klasifikasi yang lain.

Daftar Pustaka

- [1] H. Syahputra, F. Arnia, and K. Munadi, "Karakterisasi Kematangan Buah Kopi Berdasarkan Warna Kulit Kopi Menggunakan Histogram dan Momen Warna," *J. Nas. Tek. Elektro*, vol. 8, no. 1, p. 42, 2019, doi: 10.25077/jnte.v8n1.615.2019.
- [2] Widyaningsih, I. I. Tritosa, and N. C. Kumalasari, "Perbandingan Klasifikasi Tingkat Kematangan Buah Kopi Menggunakan Metode Fuzzy Logic Dan K-Nearest Neighbor Dengan Ekstraksi Ciri Gray Level Co-Occurrence Matrix," in *e-Proceeding of Engineering*, 2020, vol. 7, no. 2, pp. 4060–4073, [Online]. Available: <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/13016/12684>.
- [3] E. H. Rachmawanto and A. Salam, "Pengukuran Tingkat Kematangan Kopi Robusta menggunakan Algoritma K-Nearest Neighbor," in *Prosiding SENDI_U*, 2018, pp. 978–979.

-
- [4] W. A. Pulungan, Y. Mulyani, and W. E. Sulistiono, "Identifikasi Kematangan Buah Kopi Menggunakan Jaringan Syaraf Tiruan Learning Vector Quantization," *Barometer*, vol. 4, no. 2, p. 217, 2019, doi: 10.35261/barometer.v4i2.1834.
- [5] M. Rioarda, B. Fatkhurrozi, and I. Setyowati, "Klasifikasi Tingkat Kematangan Buah Kopi Menggunakan Algoritma Fuzzy C – Means," *THETA OMEGA J. Electr. Eng. Comput. Inf. Technol.*, vol. 2, no. 1, 2021, [Online]. Available: <https://jurnal.untidar.ac.id/index.php/thetaomega/article/view/3913/1895>.
- [6] F. Rochman and H. Junaedi, "IMPLEMENTASI TRANSFER LEARNING UNTUK IDENTIFIKASI ORDO TUMBUHAN MELALUI DAUN," *J. Syntax Admiration*, vol. 1, no. 6, pp. 672–679, 2020.
- [7] R. Siddiqi, "Effectiveness of Transfer Learning and Fine Tuning in Automated Fruit Image Classification," in *Proceedings of the 2019 3rd International Conference on Deep Learning Technologies*, 2019, pp. 91–100, doi: 10.1145/3342999.3343002.
- [8] K. Weiss, T. M. Khoshgoftaar, and D. Wang, "A survey of transfer learning," in *Journal of Big Data*, Springer International Publishing, 2016, pp. 2–40.
- [9] L. Alzubaidi *et al.*, *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions*, vol. 8, no. 1. Springer International Publishing, 2021.
- [10] W. Swastika, "Studi Awal Deteksi Covid-19 Menggunakan Citra Ct Berbasis Deep Learning," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 7, no. 3, pp. 629–634, 2020, doi: 10.25126/jtiik.202073399.
- [11] R. Artikel and D. Udjulawa, "Klasifikasi Lukisan Karya Van Gogh Menggunakan Convolutional Neural Network- Support Vector Machine," *J. Tek. Inform. dan Sist. Inf.*, vol. 7, no. April, pp. 192–205, 2021, doi: <http://dx.doi.org/10.28932/jutisi.v7i1.3399>.
- [12] A. G. Howard *et al.*, "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," 2017, [Online]. Available: <http://arxiv.org/abs/1704.04861>.
- [13] T. Yan, S.-L. Shen, A. Zhou, and X.-S. Chen, "Prediction of geological characteristics from shield operational parameters using integrating grid search and K-fold cross validation into stacking classification algorithm," *J. Rock Mech. Geotech. Eng.*, vol. 14, no. 3, 2022, doi: 10.1016/j.jrmge.2022.03.002.
- [14] A. E. Minarno, M. H. C. Mandiri, and M. R. Alfarizy, "Klasifikasi COVID-19 menggunakan Filter Gabor dan CNN dengan Hyperparameter Tuning," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 9, no. 3, pp. 493–504, 2021, doi: DOI : <http://dx.doi.org/10.26760/elkomika.v9i3.493>.
- [15] K. Shankar, Y. Zhang, Y. Liu, C. Chen, and S. Member, "Hyperparameter Tuning Deep Learning for Diabetic Retinopathy Fundus Image Classification," *IEEE Access*, vol. 8, pp. 118164–118173, 2020, doi: 10.1109/ACCESS.2020.3005152.
- [16] D. M. Belete and M. D. Huchaiah, "Grid search in hyperparameter optimization of machine learning models for prediction of HIV / AIDS test results," *Int. J. Comput. Appl.*, no. September, 2021, doi: 10.1080/1206212X.2021.1974663.
- [17] W. Nugraha and A. Sasongko, "Hyperparameter Tuning pada Algoritma Klasifikasi dengan Grid Search," *Sist. J. Sist. Inf.*, vol. 11, no. 2, pp. 391–401, 2022.
- [18] Y. Baştanlar and M. Ozuysal, *Introduction to Machine Learning Second Edition*, vol. 1107. 2014.
- [19] A. Tharwat, "Classification Assessment Methods," *Appl. Comput. Informatics*, vol. 17, no. 1, pp. 168–192, 2018, doi: 10.1016/j.aci.2018.08.003.
-