



Klasifikasi Uang Kertas dan Logam Asia Tenggara Menggunakan CNN MobileNetV3 Berbasis Web

Bagas Edra Athallah Rafif¹, Bambang Krismono Triwijoyo², I Nyoman Switrayana³

^{1,2,3} Ilmu Komputer, Fakultas Teknik, Universitas Bumigora

Bagasedra07@gmail.com

Abstrak

Perbedaan karakteristik visual uang dari berbagai negara di Asia Tenggara menyebabkan proses identifikasi uang menjadi cukup sulit dilakukan secara manual, khususnya bagi masyarakat umum maupun wisatawan. Penelitian ini bertujuan mengembangkan sistem klasifikasi uang kertas dan logam Asia Tenggara berbasis web menggunakan Convolutional Neural Network (CNN) dengan arsitektur MobileNetV3 melalui pendekatan transfer learning. Dataset yang digunakan terdiri atas 1.610 citra yang terbagi ke dalam 21 kelas, meliputi uang kertas, uang logam dari sepuluh negara Asia Tenggara, serta satu kelas non-uang. Tahap penelitian meliputi preprocessing, augmentasi data, pelatihan model menggunakan Stratified K-Fold Cross Validation dengan variasi K=5, K=10, dan K=15, serta implementasi model ke dalam aplikasi web. Hasil penelitian menunjukkan bahwa konfigurasi K=10 memberikan performa terbaik dengan rata-rata accuracy sebesar 93,91%, precision sebesar 94,72%, recall sebesar 93,97%, dan F1-score sebesar 93,97%. Hasil tersebut menunjukkan bahwa MobileNetV3 mampu memberikan performa klasifikasi yang baik dan stabil sehingga layak diterapkan sebagai sistem identifikasi uang Asia Tenggara berbasis web.

Kata Kunci: CNN, Mobilenetv3, Stratified K-Fold Cross Validation, Transfer Learning, Klasifikasi Citra

1. Pendahuluan

Berdasarkan data United Nations World Tourism Organization (UN Tourism), jumlah kedatangan wisatawan internasional di kawasan ASEAN mencapai 125,1 juta kunjungan pada tahun 2025 (UN Tourism, 2025). Tingginya mobilitas masyarakat antarnegara menyebabkan interaksi dengan berbagai jenis mata uang semakin meningkat. Perbedaan desain, warna, simbol, serta karakteristik visual uang kertas dan logam dari setiap negara di Asia Tenggara sering menimbulkan kesulitan dalam proses identifikasi, terutama bagi wisatawan maupun masyarakat yang belum mengenali mata uang negara lain (Munir, 2024). Perkembangan *Artificial Intelligence* (AI), khususnya pada bidang *computer vision*, memungkinkan proses identifikasi objek dilakukan secara otomatis menggunakan *Convolutional Neural Network* (CNN) yang mampu mengekstraksi fitur visual secara efektif untuk berbagai tugas klasifikasi citra (Alzubaidi et al., 2021), (Chen et al., 2021).

Berbagai penelitian telah menerapkan CNN untuk klasifikasi mata uang. Penelitian sebelumnya menggunakan pendekatan *transfer learning* berbasis MobileNetV2 untuk mengklasifikasikan uang kertas Rupiah dan memperoleh akurasi sebesar 98% (Rissa Ilmia Agustin et al., 2024). Penelitian lain mengembangkan sistem klasifikasi uang Rupiah layak dan tidak layak edar berbasis web menggunakan *Xception Transfer Learning* dengan akurasi sebesar 93,75% (Albani & Andhi, 2023). Selain itu, perkembangan arsitektur CNN menunjukkan bahwa MobileNetV3 mampu memberikan keseimbangan antara akurasi dan efisiensi komputasi sehingga sesuai diterapkan pada sistem berbasis web maupun perangkat dengan sumber daya terbatas (Zhao et al., 2022), (Fauzan et al., 2026).


Meskipun demikian, sebagian besar penelitian sebelumnya masih berfokus pada klasifikasi mata uang dari satu negara, khususnya Indonesia. Penelitian mengenai klasifikasi uang lintas negara di kawasan Asia Tenggara masih sangat terbatas, padahal karakteristik visual mata uang di kawasan tersebut jauh lebih beragam. Selain itu, evaluasi model pada penelitian terdahulu umumnya hanya menggunakan satu skema pembagian data sehingga kemampuan generalisasi model belum dianalisis secara komprehensif. Oleh karena itu, diperlukan penelitian yang mampu mengklasifikasikan mata uang dari berbagai negara di Asia Tenggara sekaligus mengevaluasi performa model menggunakan metode *Stratified K-Fold Cross Validation* agar diperoleh evaluasi performa model yang lebih objektif dan mampu menggambarkan kemampuan generalisasi model secara lebih baik (Widodo et al., 2022), (Prusty et al., 2022).

Berdasarkan permasalahan tersebut, penelitian ini mengembangkan sistem klasifikasi uang kertas dan logam dari sepuluh negara di Asia Tenggara menggunakan *MobileNetV3-Large* dengan pendekatan *transfer learning*. Berbeda dengan penelitian sebelumnya yang hanya berfokus pada mata uang dari satu negara, penelitian ini mengklasifikasikan mata uang dari sepuluh negara Asia Tenggara serta membandingkan performa model menggunakan tiga variasi *Stratified K-Fold Cross Validation* (K = 5, 10, dan 15). Evaluasi model dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* untuk memperoleh model dengan performa dan

kemampuan generalisasi terbaik. Model terbaik kemudian diimplementasikan ke dalam aplikasi berbasis web sehingga dapat dimanfaatkan sebagai media identifikasi uang secara otomatis.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk mengembangkan sistem klasifikasi uang kertas dan logam dari negara-negara Asia Tenggara menggunakan arsitektur *MobileNetV3-Large* dengan pendekatan *transfer learning*. Tahapan penelitian meliputi pengumpulan dataset, preprocessing citra, pengembangan model, evaluasi menggunakan *Stratified K-Fold Cross Validation*, serta implementasi model ke dalam aplikasi berbasis web. Alur penelitian secara keseluruhan ditunjukkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

Berdasarkan alur pada Gambar 1, proses penelitian diawali dengan pengumpulan dataset citra uang dari sepuluh negara di Asia Tenggara beserta citra non uang sebagai kelas tambahan. Dataset kemudian melalui tahap prapemrosesan yang meliputi perubahan ukuran citra, normalisasi, dan augmentasi data. Selanjutnya dilakukan pelatihan model menggunakan arsitektur *MobileNetV3-Large* dengan pendekatan *transfer learning* dan *fine-tuning*. Model dievaluasi menggunakan variasi *Stratified K-Fold Cross Validation* dengan nilai $K = 5, 10$, dan 15 menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Model terbaik kemudian diimplementasikan ke dalam aplikasi berbasis web untuk digunakan sebagai model klasifikasi citra uang secara otomatis.

2.1. Dataset

Penelitian ini menggunakan dataset citra uang yang terdiri atas 1.610 citra yang dikelompokkan ke dalam 21 kelas, yaitu 20 kelas yang merepresentasikan kombinasi asal negara dan jenis uang (kertas dan logam) dari sepuluh negara di kawasan Asia Tenggara serta satu kelas Non Uang. Dataset diperoleh dari berbagai sumber terbuka seperti Kaggle, Google Dataset Search, dan Pinterest. Seluruh citra memiliki variasi latar belakang, pencahayaan, sudut pengambilan gambar, serta kondisi visual yang berbeda untuk meningkatkan keragaman data dan kemampuan generalisasi model.

2.2. Preprocessing

Tahap preprocessing dilakukan untuk menyiapkan dataset agar sesuai dengan kebutuhan model sebelum proses pelatihan. Seluruh citra diubah ukurannya menjadi 224×224 piksel agar sesuai dengan ukuran masukan (*input size*) *MobileNetV3-Large*. Selanjutnya dilakukan normalisasi menggunakan fungsi *preprocess_input* sehingga distribusi nilai piksel sesuai dengan proses *pre-training* pada *MobileNetV3-Large*.



Gambar 2. Hasil Resize Citra

Gambar 2 menunjukkan contoh hasil perubahan ukuran citra uang kertas dan uang logam dari ukuran asli menjadi 224×224 piksel. Proses ini dilakukan agar seluruh citra memiliki dimensi yang seragam sehingga dapat diproses oleh arsitektur *MobileNetV3-Large* tanpa mengubah karakteristik visual utama dari objek (Rizky et al., 2025). Untuk meningkatkan kemampuan generalisasi model, diterapkan teknik data augmentation pada data latih yang meliputi horizontal flip, random rotation sebesar 0,12, random zoom sebesar 0,12, dan random contrast sebesar 0,12.



Gambar 3. Hasil Augmentasi Data

Gambar 3 memperlihatkan contoh hasil augmentasi berupa pembalikan horizontal (*flip*), rotasi, zoom, dan penyesuaian kontras terhadap citra uang kertas maupun uang logam. Teknik data augmentation menghasilkan variasi citra secara otomatis selama proses pelatihan sehingga meningkatkan kemampuan generalisasi model dan mengurangi risiko overfitting (Nanni et al., 2021). Variasi tersebut memungkinkan model mempelajari karakteristik objek pada berbagai kondisi sehingga membantu mengurangi risiko *overfitting*. Selanjutnya, dataset dibagi menggunakan metode *Stratified K-Fold Cross Validation* dengan variasi nilai K = 5, 10, dan 15. Pendekatan stratified digunakan untuk mempertahankan proporsi setiap kelas pada setiap fold sehingga distribusi data pelatihan dan data validasi tetap seimbang. Pada setiap iterasi, satu fold digunakan sebagai data validasi sedangkan fold lainnya digunakan sebagai data pelatihan hingga seluruh fold memperoleh giliran sebagai data validasi.

2.3. Pengembangan Model

Model klasifikasi dibangun menggunakan arsitektur *MobileNetV3-Large* dengan pendekatan *transfer learning*. Bobot awal (*pre-trained weights*) yang digunakan berasal dari dataset ImageNet, sedangkan lapisan klasifikasi akhir dimodifikasi agar sesuai dengan jumlah kelas pada penelitian, yaitu 21 kelas. Proses pelatihan dilakukan dalam dua tahap. Tahap pertama dilakukan dengan membekukan (*freeze*) seluruh lapisan backbone *MobileNetV3-Large* sehingga hanya lapisan klasifikasi yang dilatih. Setelah model mencapai performa yang stabil, tahap kedua dilakukan melalui proses *fine-tuning* dengan membuka sepuluh lapisan terakhir pada backbone untuk meningkatkan kemampuan model dalam mempelajari karakteristik visual citra uang yang lebih spesifik.

Lapisan klasifikasi terdiri atas Global Average Pooling, Dropout, Dense dengan fungsi aktivasi ReLU, serta lapisan keluaran menggunakan fungsi aktivasi Softmax untuk menghasilkan probabilitas pada setiap kelas. Proses pelatihan menggunakan optimizer Adam dengan learning rate 0,001 pada tahap *transfer learning* dan 0,00001 pada tahap *fine-tuning*. Fungsi kerugian (*loss function*) yang digunakan adalah *categorical crossentropy*, sedangkan evaluasi performa model dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan F1-score.

2.4. Evaluasi Model

Evaluasi model dilakukan menggunakan metode *Stratified K-Fold Cross Validation* dengan variasi nilai K = 5, K = 10, dan K = 15. Pada setiap variasi, dataset dibagi menjadi beberapa fold dengan proporsi kelas yang tetap seimbang. Setiap fold secara bergantian digunakan sebagai data validasi, sedangkan fold lainnya digunakan sebagai data pelatihan hingga seluruh fold memperoleh kesempatan sebagai data validasi.

Kinerja model diukur menggunakan metrik *accuracy*, *precision*, *recall*, dan F1-score. Nilai rata-rata (*mean*) dan standar deviasi (*standard deviation*) dari setiap metrik dihitung untuk membandingkan performa serta kestabilan

model pada masing-masing variasi K. Selain itu dilakukan analisis menggunakan confusion matrix dan classification report untuk mengevaluasi kemampuan model dalam mengklasifikasikan setiap kelas secara lebih rinci. Model dengan performa terbaik dipilih berdasarkan nilai F1-score tertinggi yang disertai tingkat kestabilan yang baik antar fold.


2.5. Implementasi Sistem

Model terbaik hasil proses evaluasi kemudian diimplementasikan ke dalam aplikasi berbasis web menggunakan framework Flask (Bota & Setiyawati, 2022). Sistem memungkinkan pengguna mengunggah citra uang melalui antarmuka web, kemudian citra diproses menggunakan model *MobileNetV3-Large* untuk menghasilkan prediksi kelas beserta nilai *confidence score*. Implementasi berbasis web dilakukan agar sistem dapat digunakan secara praktis tanpa memerlukan perangkat lunak khusus pada sisi pengguna.

3. Hasil dan Pembahasan

3.1. Hasil Pelatihan Model

Pada penelitian ini dilakukan pelatihan model menggunakan arsitektur *MobileNetV3-Large* dengan pendekatan *transfer learning*. Proses evaluasi dilakukan menggunakan *Stratified K-Fold Cross Validation* dengan variasi nilai K = 5, K = 10, dan K = 15. Berdasarkan hasil evaluasi, konfigurasi K = 10 pada Fold 7 dipilih sebagai model terbaik karena memperoleh nilai F1-score tertinggi serta menunjukkan performa yang paling stabil dibandingkan konfigurasi lainnya.



Gambar 4. Kurva Accuracy dan Loss Model Terbaik (K = 10 Fold 7)


Gambar 4 memperlihatkan perkembangan *training accuracy*, *validation accuracy*, *training loss*, dan *validation loss* selama proses pelatihan model terbaik. Kurva *training accuracy* dan *validation accuracy* mengalami peningkatan secara bertahap sejak epoch awal hingga mencapai kondisi yang relatif konvergen pada epoch-epoch akhir. Jarak antara kedua kurva relatif kecil sehingga menunjukkan bahwa model mampu mempelajari karakteristik citra uang dengan baik tanpa mengalami *overfitting* yang signifikan. Kondisi tersebut mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya. Selain itu, kurva *training loss* dan *validation loss* menunjukkan penurunan yang konsisten selama proses pelatihan. Penurunan nilai *loss* yang stabil menunjukkan bahwa proses optimasi berlangsung secara efektif hingga model mencapai kondisi konvergen. Tidak terlihat adanya peningkatan *validation loss* yang signifikan pada akhir pelatihan, sehingga dapat disimpulkan bahwa model mampu mempertahankan performa yang baik pada data validasi dan tidak menunjukkan gejala *overfitting*.

3.2. Hasil Evaluasi Model

Tabel 1 menunjukkan rata-rata hasil evaluasi pada masing-masing variasi K.

Tabel 1 Perbandingan Performa Model Variasi K-Fold

Variasi K	Accuracy	Precision	Recall	F1-Score	Std. Dev
K= 5	0,929814	0,933957	0,929592	0,929595	0.026610
K= 10	0,939130	0,947205	0,939711	0,939747	0.021883
K= 15	0,937268	0,947430	0,937566	0,936329	0.031794




Gambar 5. Grafik Perbandingan Variasi K-Fold

Berdasarkan Tabel 1 dan Gambar 5, seluruh variasi *Stratified K-Fold Cross Validation* menghasilkan performa klasifikasi yang tinggi. Konfigurasi K = 10 memberikan performa terbaik dengan nilai accuracy sebesar 93,91%, precision sebesar 94,72%, recall sebesar 93,97%, dan F1-score sebesar 93,97%. Selain memperoleh nilai F1-score tertinggi, konfigurasi ini juga memiliki standar deviasi paling rendah, yaitu 0,021883, yang menunjukkan bahwa performa model lebih konsisten dibandingkan variasi K lainnya. Sebaliknya, konfigurasi K = 5 menghasilkan performa yang sedikit lebih rendah karena jumlah data pelatihan pada setiap iterasi relatif lebih sedikit sehingga variasi performa antar fold masih cukup besar. Sementara itu, pada K = 15, ukuran data validasi yang lebih kecil menyebabkan hasil evaluasi lebih sensitif terhadap distribusi data. Hasil tersebut menunjukkan bahwa peningkatan jumlah fold tidak selalu menghasilkan performa terbaik. Konfigurasi K = 10 memberikan keseimbangan yang optimal antara jumlah data pelatihan dan data validasi sehingga menghasilkan model dengan performa dan kemampuan generalisasi yang paling baik.

3.3. Confusion Matrix Model Terbaik

Gambar 6 menunjukkan confusion matrix dari model terbaik pada konfigurasi K = 10. Sebagian besar prediksi berada pada diagonal utama matriks yang menunjukkan bahwa mayoritas citra berhasil diklasifikasikan sesuai dengan kelas sebenarnya. Untuk memberikan informasi yang lebih rinci mengenai performa setiap kelas, disajikan classification report pada Tabel 2.



Gambar 6. Confusion Matrix Model Terbaik

Tabel 2 menyajikan hasil classification report dari model terbaik yang diperoleh pada konfigurasi K = 10 Fold 7. Oleh karena itu, nilai accuracy pada tabel ini berbeda dengan nilai rata-rata pada Tabel 1 yang merupakan hasil agregasi seluruh fold.

Tabel 2. Classification Report (K=10 Fold 7)

	Precision	Recall	F1-Score	Support
Brunei_kertas	1.0000	1.0000	1.0000	7
Brunei_logam	0.8750	0.8750	0.8750	8
Indonesia_kertas	1.0000	1.0000	1.0000	8
Indonesia_logam	0.8750	0.8750	0.8750	8

DOI: <https://doi.org/10.69693/ijmst.v4i2.13030>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)


Kamboja_kertas	1.0000	0.8750	0.9333	8
Kamboja_logam	1.0000	1.0000	1.0000	8
Laos_kertas	1.0000	1.0000	1.0000	7
Laos_logam	1.0000	1.0000	1.0000	8
Malaysia_kertas	1.0000	1.0000	1.0000	7
Malaysia_logam	1.0000	1.0000	1.0000	8
Non Uang	1.0000	1.0000	1.0000	8
Philipina_kertas	1.0000	1.0000	1.0000	7
Philipina_logam	1.0000	1.0000	1.0000	8
Singapura_kertas	1.0000	1.0000	1.0000	7
Singapura_logam	0.8750	0.8750	0.8750	8
Thailand_kertas	1.0000	1.0000	1.0000	7
Thailand_logam	1.0000	1.0000	1.0000	8
Timor Leste_kertas	1.0000	1.0000	1.0000	7
Timor Leste_logam	0.8750	0.8750	0.8750	8
Vietnam_kertas	1.0000	1.0000	1.0000	8
Vietnam_logam	0.8889	1.0000	0.9412	8
accuracy			0.9689	161
macro Avg	0.9709	0.9702	0.9702	161
Weighted avg	0.9696	0.9689	0.9689	161

Berdasarkan Tabel 2, sebagian besar kelas memperoleh nilai precision, recall, dan F1-score sebesar 1,0000 sehingga menunjukkan bahwa model mampu mengklasifikasikan mayoritas citra dengan sangat baik. Beberapa kelas seperti Brunei_logam, Indonesia_logam, Singapura_logam, dan Timor Leste_logam memperoleh nilai F1-score sebesar 0,8750, sedangkan kelas Vietnam_logam memperoleh F1-score sebesar 0,9412. Hasil tersebut menunjukkan bahwa kesalahan klasifikasi lebih banyak terjadi pada kelompok uang logam yang memiliki karakteristik visual seperti warna, bentuk, dan tekstur yang relatif mirip antarnegara.

Secara keseluruhan model memperoleh nilai *accuracy* sebesar 96,89%, *macro average* F1-score sebesar 97,02%, dan *weighted average F1-score* sebesar 96,89%. Nilai tersebut menunjukkan bahwa model memiliki kemampuan klasifikasi yang sangat baik pada seluruh kelas dengan tingkat kesalahan yang relatif rendah. Nilai *accuracy* sebesar 96,89% pada Tabel 2 merupakan hasil evaluasi satu model terbaik (Fold 7), sedangkan nilai 93,91% pada Tabel 1 merupakan rata-rata *accuracy* dari seluruh fold pada konfigurasi K = 10.

3.4. Implementasi Sistem

Model terbaik hasil pelatihan diimplementasikan ke dalam aplikasi berbasis web. Sistem mampu melakukan klasifikasi citra uang secara otomatis dengan menyediakan fitur unggah citra, proses klasifikasi, serta menampilkan hasil prediksi beserta nilai *confidence score*. Implementasi berbasis web memungkinkan sistem digunakan secara praktis melalui peramban (*browser*) tanpa memerlukan instalasi perangkat lunak tambahan pada sisi pengguna.



Gambar 7. Hasil Implementasi Sistem

Berdasarkan Gambar 7, sistem mampu melakukan klasifikasi citra uang dengan menampilkan label prediksi beserta nilai *confidence score* secara otomatis sesuai model terbaik yang diperoleh pada tahap pelatihan. Pada proses implementasi, pengguna cukup mengunggah citra uang melalui halaman utama sistem. Setelah citra dipilih, sistem secara otomatis melakukan preprocessing berupa *resize* citra menjadi 224×224 piksel serta normalisasi menggunakan fungsi *preprocess_input*, kemudian citra diteruskan ke model *MobileNetV3-Large* untuk menghasilkan prediksi. Hasil klasifikasi kemudian ditampilkan dalam bentuk nama kelas beserta nilai *confidence score*, sehingga pengguna dapat mengetahui tingkat keyakinan model terhadap hasil prediksi yang diberikan. Implementasi ini menunjukkan bahwa model yang telah dikembangkan dapat diterapkan dengan baik pada aplikasi berbasis web dan digunakan sebagai media identifikasi uang secara praktis.

DOI: <https://doi.org/10.69693/ijmst.v4i2.13030>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

3.5. Pengujian Sistem

Pengujian black box menunjukkan bahwa seluruh fungsi utama sistem berjalan sesuai dengan kebutuhan, mulai dari proses unggah gambar, klasifikasi, hingga penampilan hasil prediksi.

Tabel 3. Pengujian Sistem (Black Box)

No	Skenario Pengujian	Hasil Diharapkan	Hasil Pengujian	Status
1	Upload file JPG/PNG	Sistem Menerima dan Memproses File	Sesuai	Berhasil
2	Upload file selain JPG/PNG	Sistem Menolak File	Sesuai	Berhasil
3	Klik Analisa Tanpa Upload Citra	Muncul Peringatan	Sesuai	Berhasil
4	Proses Klasifikasi	Sistem Menampilkan Label dan Confidence	Sesuai	Berhasil
5	Tampilkan Confidence Score	Progress Bar Muncul Sesuai Probabilitas	Sesuai	Berhasil
6	Klik "Coba Lagi"	Kembali Ke Halaman Upload	Sesuai	Berhasil

Berdasarkan hasil pengujian Black Box, seluruh fungsi sistem berjalan sesuai dengan rancangan. Proses unggah citra berhasil menerima file berekstensi JPG maupun PNG. Sistem juga mampu menolak format file yang tidak sesuai sehingga validasi input berjalan dengan baik. Selain itu, proses klasifikasi mampu menghasilkan prediksi beserta confidence score tanpa ditemukan kesalahan fungsi selama pengujian. Hasil tersebut menunjukkan bahwa implementasi sistem telah memenuhi kebutuhan fungsional.

4. Kesimpulan

Penelitian ini berhasil mengembangkan sistem klasifikasi uang kertas dan logam dari sepuluh negara di Asia Tenggara menggunakan arsitektur *MobileNetV3-Large* dengan pendekatan transfer learning. Evaluasi menggunakan *Stratified K-Fold Cross Validation* menunjukkan bahwa konfigurasi K = 10 memberikan performa terbaik dengan nilai *accuracy* sebesar 93,91%, *precision* sebesar 94,72%, *recall* sebesar 93,97%, dan F1-score sebesar 93,97%, serta memiliki standar deviasi terendah yang menunjukkan kemampuan generalisasi model yang baik. Model terbaik berhasil diimplementasikan ke dalam aplikasi berbasis web dan mampu melakukan klasifikasi citra uang secara otomatis. Pada penelitian selanjutnya, dataset dapat diperluas dengan menambahkan variasi nominal, tahun emisi, maupun kondisi fisik uang sehingga performa dan kemampuan generalisasi model dapat semakin ditingkatkan.

Reference

- Albani, M., & Andhi, R. R. (2023). *Klasifikasi Uang Rupiah Kertas Tidak Layak Edar Menggunakan Cnn Xception Transfer Learning Berbasis Website*. September, 394–406.
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Dujaili, A. Al, Duan, Y., Shamma, O. Al, Santamaria, J., Fadhel, M. A., Amidie, M. Al, & Farhan, L. (2021). Review Of Deep Learning : Concepts , Cnn Architectures , Challenges , Applications , Future Directions. In *Journal Of Big Data*. Springer International Publishing. <https://doi.org/10.1186/S40537-021-00444-8>
- Bota, Y. T., & Setiyawati, N. (2022). *Pengembangan Sistem Informasi Perantara Bisnis Menggunakan Framework Flask*. 3(2), 79–93.
- Chen, L., Li, S., Bai, Q., Yang, J., Jiang, S., & Miao, Y. (2021). *Review Of Image Classification Algorithms Based On Convolutional Neural Networks*. 1–51.
- Fauzan, M. R., Nadhif, N., Iskandar, R., & Fauzi, R. Z. (2026). *Rethinking Efficiency : A Comparative Study Of Lightweight Cnn Architectures For Image Classification*. 2(1), 13–21. <https://doi.org/10.64878/Jistics.V2i1.167>
- Munir, A. . (2024). Futures Of Money - Monies Of The Future. Introduction. *Accounting, Economics And Law: A Convivium*, 14(2), 165–172. <https://doi.org/10.1515/Ael-2022-0116>
- Nanni, L., Paci, M., & Brahnam, S. (2021). *Comparison Of Different Image Data Augmentation Approaches*. <https://doi.org/10.3390/Jimaging7120254>
- Prusty, S., Patnaik, S., & Dash, S. K. (2022). *Skev : Strati Fi Ed K-Fold Cross-Validation On MI Classi Fi Ers For Predicting Cervical Cancer*. August, 1–12. <https://doi.org/10.3389/Fnano.2022.972421>
- Rissa Ilmia Agustin, Jamaludin Indra, Sutan Faisal, Ahmad Fauzi, & Rija Nur Hijriyya. (2024). Klasifikasi Pecahan Uang Kertas Rupiah Menggunakan Transfer Learning Dengan Model Mobilenetv2. *Jurnal Instek (Informatika Sains Dan Teknologi)*, 9(2), 242–250. <https://doi.org/10.24252/Instek.V9i2.49123>
- Sugiyono. (2020). *Metode Penelitian Manajemen*. Alfabeta.
- Sugiyono. (2021). *Metode Penelitian Pendidikan (Kuantitatif, Kualitatif, Kombinasi, R&D dan Penelitian Pendidikan)*. Alfabeta.
- Sugiyono. (2022). *Metode Penelitian Kualitatif: Untuk Penelitian yang Bersifat Eksploratif, Enterpretif, Interaktif dan Konstruktif*. Alfabeta.
- Un Tourism. (2025). *United Nations World Tourism Organization (Unwto)*. <https://www.untourism.int/Tourism-Data/Un-Tourism-Tourism-Dashboard>
- Widodo, S., Brawijaya, H., Bina, U., Informatika, S., & Mandiri, U. N. (2022). *Stratified K-Fold Cross Validation Optimization On Machine Learning For Prediction*. 6(4), 2407–2414. <https://doi.org/10.33395/Sinkron.V7i4.11792>
- Zhao, Y., Huang, H., Li, Z., Yiwang, H., & Lu, M. (2022). *Intelligent Garbage Classification System Based On Improve Mobilenetv3-Large*. 0091. <https://doi.org/10.1080/09540091.2022.2067127>

DOI: <https://doi.org/10.69693/ijmst.v4i2.13030>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

