

Klasifikasi Kerusakan Uang Rupiah Menggunakan CNN Dengan Arsitektur VGG16

Muhamad Rizvi Roshan¹, Hafiz Irsyad²

¹² Program Studi Informatika, Universitas Multi Data Palembang, Palembang, Indonesia

Email : rizviroshan10@mhs.mdp.ac.id , hafizirsyad@mdp.ac.id

Article Information

Article history

Received 12 August 2025

Revised 25 November 2025

Accepted 30 November 2025

Available 30 December 2025

Keywords

CNN

Deep Learning

Klasifikasi Kerusakan Uang

Rupiah

VGG16

Corresponding Author:

Muhamad Rizvi Roshan,

Universitas Multi Data Palembang,

Email:

rizviroshan10@mhs.mdp.ac.id

Abstract

This study developed a deep learning model using a Convolutional Neural Network (CNN) architecture with VGG16 to classify the level of damage to rupiah banknotes. Previous studies have focused more on recognizing denominations and detecting counterfeit money using CNN and transfer learning, while the classification of physical damage to rupiah banknotes is still limited, both locally and internationally, and often relies on special acquisition devices or template registration. The dataset used consists of images of rupiah banknotes grouped into three damage categories: >20%, >40%, and >50%. This dataset is divided into 80% for training data (537 images) and 20% for test data (135 images). To enrich the data variety, this study applied *on-the-fly* data augmentation techniques with rotation, zoom, and flipping during the training process. The experimental results show that this model achieves an accuracy of 93.33%, with excellent precision, recall, and F1-score values, especially in the >50% damage category. The use of the ADAM optimizer with a learning rate of 1e-3 proved to provide more stable and efficient training. Overall, this study shows that the application of CNN with the VGG16 architecture is effective in classifying rupiah currency damage and can contribute to the development of image processing technology, particularly for evaluating currency feasibility in real-world scenarios.

Keywords : *Banknote Damage Classification ,CNN, Deep Learning ,Rupiah ,VGG16*

Abstrak

Penelitian ini mengembangkan model deep learning menggunakan arsitektur Convolutional Neural Network (CNN) dengan VGG16 untuk mengklasifikasikan tingkat kerusakan pada uang rupiah. Penelitian sebelumnya lebih berfokus pada pengenalan nominal dan deteksi uang palsu menggunakan CNN dan transfer learning, sementara klasifikasi kerusakan fisik uang rupiah masih terbatas, baik di tingkat lokal maupun internasional, dan sering mengandalkan perangkat akuisisi khusus atau registrasi template. Dataset yang digunakan terdiri dari gambar uang rupiah yang dikelompokkan dalam tiga kategori kerusakan: >20%, >40%, dan >50%. Dataset ini dibagi menjadi 80% untuk data latih (537 citra) dan 20% untuk data uji (135 citra). Untuk memperkaya variasi data, penelitian ini menerapkan teknik augmentasi data *on-the-fly* dengan rotasi, zoom, dan flipping selama proses pelatihan. Hasil eksperimen menunjukkan model ini mencapai akurasi 93,33%, dengan nilai precision, recall, dan F1-score yang sangat baik, terutama pada kategori kerusakan >50%. Penggunaan optimizer ADAM dengan learning rate 1e-3 terbukti memberikan pelatihan yang lebih stabil dan efisien. Secara keseluruhan, penelitian ini menunjukkan bahwa penerapan CNN dengan arsitektur VGG16 efektif dalam mengklasifikasikan kerusakan uang rupiah dan dapat berkontribusi pada pengembangan teknologi pengolahan citra, khususnya untuk evaluasi kelayakan uang dalam skenario dunia nyata.

Kata Kunci : *CNN, Deep Learning, Klasifikasi Kerusakan Uang, Rupiah, VGG16.*

Copyright©2025 Muhamad Rizvi Roshan, Hafiz Irsyad

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



1. Pendahuluan

Uang merupakan alat tukar atau pembayaran yang sah dalam perekonomian suatu negara (Saputra et al., 2024). Sebagai media pertukaran, uang memiliki peran vital dalam transaksi jual beli barang dan jasa, yang mana fungsinya sebagai alat pembayaran yang sah diakui dalam setiap transaksi. Hal ini menunjukkan bahwa uang tidak hanya berfungsi sebagai alat tukar, tetapi juga sebagai sarana pembayaran yang diakui secara resmi oleh negara, dengan ketentuan bahwa uang tersebut dapat digunakan selama masih dalam masa berlaku (Nandika et al., 2025). Dengan demikian, uang memiliki nilai yang sah, diakui secara hukum, dan bentuk fisiknya pun bervariasi di setiap negara, termasuk Indonesia, yang juga mematuhi prinsip tersebut dalam sistem ekonominya (Ahnaf et al., 2024). Pada konteks Rupiah, mekanisme penukaran/penggantian uang rusak juga memiliki ketentuan tertentu sehingga diperlukan penilaian kondisi fisik yang konsisten dan dapat diaudit (Bank Indonesia, n.d.).

Di Indonesia, mata uang yang digunakan adalah rupiah, yang terbagi menjadi dua jenis berdasarkan bahan pembuatannya, yaitu uang kertas dan uang logam (Rewina et al., 2024). Perbedaan bahan pembuatan ini berpengaruh pada tingkat kerusakan atau kelayakan uang yang dapat dilihat dari kondisi fisiknya. Berdasarkan wawancara yang dilakukan oleh penulis (Ahnaf et al., 2024) uang kertas terbukti lebih rentan terhadap kerusakan fisik dibandingkan uang logam.

Kerusakan uang tidak hanya disebabkan oleh usia yang sudah lama, tetapi juga bisa terjadi karena sengaja dirusak. Uang yang mengalami kerusakan fisik, seperti, terbakar, berlubang, atau sebagian hilang, sering dianggap tidak layak edar oleh masyarakat. Meskipun demikian, uang tersebut tetap memiliki nilai tukar penuh jika ditukarkan di Bank Indonesia (Alfaruq et al., 2024). Dalam beberapa tahun terakhir nominal uang rusak berfluktuasi dari tahun ke tahun. Namun menurut data dari Bank Indonesia trennya terus meningkat dari tahun 2010 sampai dengan 2016 tercatat pemusnahan uang pada tahun 2010 Rp.137,5 Triliun, 2011 Rp.161,81 Triliun, 2012 Rp.47,56 Triliun, 2013 Rp.105,29 Triliun, 2014 Rp.111,57 Triliun, 2015 Rp.160,25 Triliun dan 2016 Rp.210,49 Triliun (Bareksa.com, 2017).

Praktik penilaian kondisi uang kertas di lapangan masih sering bersifat manual dan sangat bergantung pada persepsi petugas, sehingga berisiko memunculkan variabilitas keputusan, memerlukan waktu lebih lama ketika volume tinggi, dan sulit distandardisasi. Karena kerusakan uang kertas adalah fenomena visual, pendekatan computer vision berbasis deep learning relevan untuk membantu otomatisasi/standarisasi penilaian kondisi uang. Secara umum, Convolutional Neural Network (CNN) telah menjadi pendekatan dominan untuk klasifikasi citra dan pengenalan pola, termasuk pada domain uang kertas (Pamungkas et al., 2022; Saputra et al., 2024).

Namun, mayoritas penelitian terkait Rupiah yang tersedia masih berfokus pada pengenalan nominal (misalnya untuk alat bantu tunanetra atau otomasi mesin) menggunakan CNN maupun transfer learning—misalnya klasifikasi nominal Rupiah dengan CNN pada berbagai skenario (Pamungkas et al., 2022; Hidayat et al., 2023; Saputra et al., 2024) dan implementasi deep transfer learning untuk klasifikasi nominal (Sadewa & Yamasari, 2024). Studi lain mengeksplorasi pengenalan/klasifikasi uang kertas dan logam menggunakan CNN (Rewina et al., 2024), serta deteksi nominal untuk kebutuhan otomasi perangkat (Aprillia et al., 2024). Pada ranah internasional, deep learning juga luas dipakai untuk deteksi uang palsu (Pachón et al., 2021) dan efisiensi model melalui teknik kompresi/pruning (Pachón et al., 2023).

Kesenjangan riset yang menonjol adalah masih terbatasnya studi yang secara spesifik menargetkan klasifikasi tingkat kerusakan/kelayakan uang Rupiah. Sementara itu, studi “defect detection” pada uang kertas sering mengandalkan registrasi citra global-lokal dan analisis perbedaan terhadap template referensi yang menuntut praproses tertentu (Gai et al., 2020). Kondisi ini membuka peluang penelitian yang lebih aplikatif untuk Rupiah: model klasifikasi tingkat kerusakan yang ringan, replikatif, dan konsisten.

Penelitian ini mengusulkan penerapan klasifikasi kerusakan uang Rupiah menggunakan Convolutional Neural Network (CNN) dengan arsitektur VGG16. Untuk meningkatkan variasi pada dataset yang terbatas, penelitian ini mengimplementasikan teknik augmentasi data *on the fly*, dengan fokus pada tiga jenis augmentasi, yaitu rotasi, zoom, dan flipping. Selain itu, teknik ini juga bertujuan untuk memperbaiki kemampuan generalisasi model. Data yang digunakan dalam penelitian ini terdiri dari 672 citra yang dikelompokkan menjadi tiga kelas berdasarkan tingkat kerusakan, dengan masing-masing kelas ditentukan oleh proporsi atau ambang batas tertentu. Augmentasi data dilakukan pada set data pelatihan untuk memperkaya variasi dan meningkatkan performa model dalam mengklasifikasikan kerusakan uang.

Kontribusi utama penelitian ini adalah perancangan pipeline klasifikasi tingkat kerusakan uang Rupiah berbasis CNN-VGG16, penerapan transfer learning dan augmentasi untuk meningkatkan performa pada data terbatas, serta penyediaan baseline evaluasi yang dapat menjadi rujukan untuk pengembangan sistem pendukung keputusan kelayakan uang di konteks operasional.

2. Kajian Terdahulu

Penelitian yang telah dilakukan, dapat disimpulkan bahwa beberapa pendekatan berbeda digunakan untuk klasifikasi nominal uang rupiah. (Pamungkas et al., 2022) mengembangkan sistem untuk membantu penyandang tunanetra mengenali nominal uang menggunakan CNN dengan akurasi mencapai 100%, menunjukkan efektivitas CNN dalam pengenalan gambar uang. Sementara itu, (Saputra et al., 2024)

membandingkan kinerja CNN dan VGG16 dalam klasifikasi uang rupiah edisi 2022, dimana VGG16 menunjukkan kinerja optimal dengan akurasi sempurna 100%, serta nilai presisi, *recall*, dan *F1-score* masing-masing 1,00. Hasil ini menunjukkan keunggulan transfer learning dalam meningkatkan akurasi klasifikasi dibandingkan dengan CNN standar. Penelitian lain yang dilakukan oleh (Gai et al., 2020) menggunakan algoritma *quaternion* untuk deteksi cacat pada mata uang asing, yang berhasil memberikan hasil lebih baik dibandingkan teknik deteksi cacat konvensional.

Untuk meningkatkan generalisasi dalam model deep learning, banyak studi yang memanfaatkan teknik augmentasi data, seperti rotasi, flipping, zoom, dan perubahan pencahayaan, yang memungkinkan model untuk belajar dari variasi yang lebih luas dalam data pelatihan. Sebuah tinjauan komprehensif oleh (Zeng, 2024) menekankan bahwa augmentasi data adalah praktik kunci dalam mengurangi overfitting, terutama ketika data pelatihan terbatas. Teknik-teknik augmentasi ini tidak hanya memperbesar dataset dengan menghasilkan sampel sintetis, tetapi juga meningkatkan kemampuan model untuk mengenali berbagai variasi dalam data, sehingga meningkatkan ketahanan model terhadap kesalahan dan memperbaiki kinerjanya dalam tugas-tugas pengenalan citra. Seiring dengan bertambahnya kompleksitas model, penerapan augmentasi citra yang tepat semakin penting untuk memastikan bahwa model dapat beradaptasi dengan data yang lebih beragam dan menghasilkan prediksi yang lebih akurat dalam skenario dunia nyata. (Zeng, 2024) Dengan demikian, kombinasi VGG16 + augmentasi merupakan pendekatan yang masuk akal sebagai baseline kuat untuk klasifikasi kondisi visual uang kertas.

Di Indonesia, penelitian terkait Rupiah berbasis CNN paling banyak diarahkan pada pengenalan nominal dan aplikasi asistif/otomasi. Pamungkas et al. (2022) mengusulkan pengenalan Rupiah untuk membantu penyandang tunanetra berbasis CNN. Hidayat et al. (2023) juga mengembangkan identifikasi nominal Rupiah berbasis Android untuk pengguna tunanetra. Saputra et al. (2024) menyajikan model klasifikasi nominal uang kertas Republik Indonesia menggunakan CNN. Sadewa dan Yamasari (2024) menekankan deep transfer learning untuk klasifikasi nominal uang kertas Rupiah, memperlihatkan tren adopsi transfer learning pada domain Rupiah. Studi lain membahas klasifikasi uang kertas dan uang logam menggunakan CNN (Rewina et al., 2024), serta perbandingan CNN dengan pendekatan jaringan saraf lain untuk deteksi nominal pada konteks otomasi mesin (Aprillia et al., 2024).

Di sisi lain, Gai et al. (2020) mengusulkan algoritma deteksi cacat uang kertas berbasis kerangka praproses, registrasi global-lokal, dan pengukuran perbedaan warna untuk menentukan derajat defect. Untuk autentikasi, Pachón et al. (2021) memanfaatkan deep learning untuk pengenalan uang palsu, dan Pachón et al. (2023) melanjutkan dengan pendekatan efisiensi model melalui network pruning.

Penelitian ini menempatkan CNN berbasis VGG16 sebagai backbone klasifikasi tingkat kerusakan uang Rupiah dengan bantuan augmentasi data *ont the fly*. Dibanding penelitian nasional yang dominan pada nominal, penelitian ini berkontribusi pada dimensi kualitas atau kelayakan fisik uang. Dibanding sebagian penelitian internasional yang memerlukan perangkat akuisisi khusus atau registrasi template, penelitian ini lebih replikatif pada skenario lapangan berbasis kamera.

Uang Rupiah

Mata uang berfungsi sebagai simbol negara yang mencerminkan kemerdekaan dan kedaulatan, di mana negara memiliki hak monopoli atas pembuatan, peredaran, penarikan, serta penghancuran mata uang tersebut sebagai alat pembayaran yang sah di wilayahnya. (Rewina et al., 2024)

Di Indonesia, mata uang yang digunakan adalah Rupiah, yang dikeluarkan oleh Bank Indonesia. Berdasarkan Pasal 11 Undang-Undang Nomor 7 Tahun 2011, Bank Indonesia memiliki kewenangan penuh untuk mencetak, mengedarkan, serta menarik kembali Rupiah. Sebagai otoritas yang bertanggung jawab, Bank Indonesia mengelola mata uang negara Indonesia. Setiap uang yang beredar memiliki nilai nominal yang digunakan untuk menentukan harga barang atau jasa yang diperdagangkan, mempermudah masyarakat dalam bertransaksi ekonomi karena harga barang dan jasa dapat dihitung dengan angka yang jelas. (Studi et al., 2025)

Uang Rusak

Uang rusak adalah uang yang mengalami kerusakan fisik signifikan, seperti terbakar, berlubang, atau hilang sebagian, sehingga tidak memenuhi standar kualitas Bank Indonesia dan dikategorikan sebagai Rupiah Tidak Layak Edar. Ciri-ciri uang rusak meliputi perubahan bentuk, seperti sobek atau mengerut, serta hilangnya sebagian $>50\text{mm}^2$, lubang $>10\text{mm}^2$, coretan, sobek $>8\text{mm}^2$, selotip $>225\text{mm}^2$. Bank Indonesia mengganti uang rusak dengan nilai nominal yang sama jika ciri keasliannya masih bisa dikenali dan uang tersebut utuh sebagai satu kesatuan. Uang rusak yang memenuhi kriteria seperti ukuran lebih dari $\frac{2}{3}$ dari ukuran asli dan nomor seri lengkap bisa diganti, namun jika uang terbagi lebih dari dua bagian atau kerusakan diduga sengaja, penggantian tidak diberikan. Misalnya, kerusakan akibat alat tajam atau pola kerusakan yang seragam. Penukaran uang rusak dapat dilakukan di Bank Indonesia atau bank yang bekerja sama (Bank Indonesia, 2011).

Teknik Augmentasi Data

Pada tahap augmentasi data, dilakukan proses untuk memperbanyak jumlah data gambar dengan menerapkan berbagai transformasi untuk meningkatkan performa model (Khairu et al., 2025). Tujuannya agar model dapat menyesuaikan diri dengan

berbagai macam bentuk data baru yang diberikan dan menghindari resiko *underfitting* atau *overfitting* (Ricky Putra Sardika & Widhiarso, 2025). Berikut adalah berbagai jenis augmentasi data yang akan diterapkan dalam penelitian ini:

1. Rotasi adalah teknik untuk memutar gambar secara acak dalam rentang 0 hingga 360 derajat searah jarum jam, dengan tujuan membantu model untuk mengenali objek meskipun dalam orientasi yang berbeda.
2. Zoom adalah teknik untuk memperbesar atau memperkecil gambar tanpa mengubah ukuran keseluruhan gambar, yang bertujuan agar model dapat mengenali objek dalam berbagai skala.
3. Flip atau pembalikan adalah teknik untuk membalik gambar baik secara vertikal maupun horizontal, dengan tujuan membuat data gambar bervariasi dalam orientasinya.



Gambar 1. Contoh Hasil Augmentasi

Pengolahan Citra Digital

Pengolahan Citra Digital (*Digital Image Processing*) adalah bidang studi yang fokus pada berbagai teknik untuk mengolah citra. Citra tersebut merujuk pada gambar atau foto. Pengolahan citra dapat dianggap sebagai dasar utama dalam sistem pengenalan gambar. Fungsi utamanya adalah untuk meningkatkan kualitas citra dan mempersiapkannya agar dapat diproses lebih lanjut. Hal ini seperti menyiapkan bahan

baku yang berkualitas tinggi untuk memastikan hasil akhir yang optimal. (Nandika et al., 2025)

Optimizer Adam

Optimizer Adam merupakan algoritma optimasi yang banyak digunakan dalam pelatihan model *deep learning*. Algoritma ini menggabungkan keunggulan dari *adaptive gradient* (*AdaGrad*) dan *RMSProp* dengan menyesuaikan secara dinamis laju eksponensial untuk estimasi momen pertama (rerata) dan kedua (varians) dari gradien, yang digunakan untuk memperbarui parameter model. Dibandingkan dengan algoritma optimasi lainnya, Adam memberikan kinerja unggul dalam hal konvergensi yang cepat dan stabilitas yang terjaga selama pelatihan, terutama pada masalah dengan banyak parameter dan fungsi *loss* yang mungkin non-konveks. (Dede Kurniadi et al., 2025). Rumus perhitungan *Optimizer Adam* dapat ditemukan pada persamaan (2) hingga (6).

Estimasi momen pertama (rata-rata):

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (2)$$

estimasi momen kedua (varians tidak terpusat):

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (3)$$

estimasi momen pertama yang telah dikoreksi bias:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (4)$$

estimasi momen kedua yang telah dikoreksi bias:

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (5)$$

pembaruan parameter:

$$\hat{\theta}_t = \theta_{t-1} - a \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \quad (6)$$

Dimana a merupakan tingkat pembelajaran, β_1 dan β_2 menyatakan laju peluruhan untuk estimasi momen, serta ϵ adalah konstanta kecil yang digunakan untuk menjaga stabilitas numerik. (Dede Kurniadi et al., 2025).

Deep Learning


Deep Learning merupakan salah satu cabang dari *machine learning* yang berfokus pada pengembangan jaringan saraf tiruan (ANN). Jaringan saraf tiruan bertujuan untuk meniru struktur dan fungsi jaringan saraf biologis, meskipun pada dasarnya masih cukup sederhana. Algoritma ini berusaha untuk meniru cara kerja otak manusia. *Deep Learning* dikembangkan agar komputer dapat mengidentifikasi gambar visual (dalam bidang penglihatan komputer), mengenali suara (pengenalan suara), berinteraksi dengan

manusia (pemrosesan bahasa alami), serta berbagai kemampuan lainnya (Pamungkas et al., 2022).

Convolutional Neural Network (CNN)

Convolutional Neural Network adalah metode *Deep Learning* yang banyak digunakan dalam pengenalan objek, dan pada dasarnya merupakan pengembangan dari jaringan saraf tiruan dengan struktur yang lebih kompleks. Metode ini dikenal lebih efektif dalam mengenali citra objek dibandingkan dengan metode lainnya (Nur Hidayat et al., 2023). CNN, sebagai bagian dari *Deep Neural Network*, terinspirasi oleh cara kerja saraf *neuron* otak manusia, di mana setiap objek *visual* yang diterima disimpan dalam bentuk peta topografis memori di otak, dengan setiap lapisan jaringan berfokus pada pengenalan karakteristik spesifik (Malik Ibrahim et al., 2023).

Algoritma CNN memanfaatkan konvolusi untuk mengenali karakteristik tertentu dalam data pelatihan, yang kemudian digunakan sebagai input untuk melatih jaringan saraf atau *neural network* untuk meningkatkan kemampuan pengenalan objek (Sadewa & Yamasari, 2024).. Arsitektur CNN terdiri dari beberapa komponen penting, termasuk lapisan konvolusi, lapisan masukan, lapisan keluaran, serta lapisan-lapisan tersembunyi seperti lapisan *pooling*, normalisasi, *ReLU*, *fully connected layer*, dan *loss layer*. Setiap lapisan ini memiliki fungsi spesifik yang mendukung kinerja keseluruhan jaringan dalam mengenali dan mengklasifikasikan fitur-fitur citra yang diberikan. Berikut gambar dari arsitektur CNN (Dede Husen, 2024).




Gambar 2. Arsitektur CNN

VGG16

VGG16 adalah salah satu arsitektur *Convolutional Neural Network* (CNN) yang dikembangkan oleh *Visual Geometry Group* di *University of Oxford*. Model ini pertama kali diperkenalkan oleh Simonyan dan Zisserman dalam kompetisi ILSVRC (*ImageNet Large*

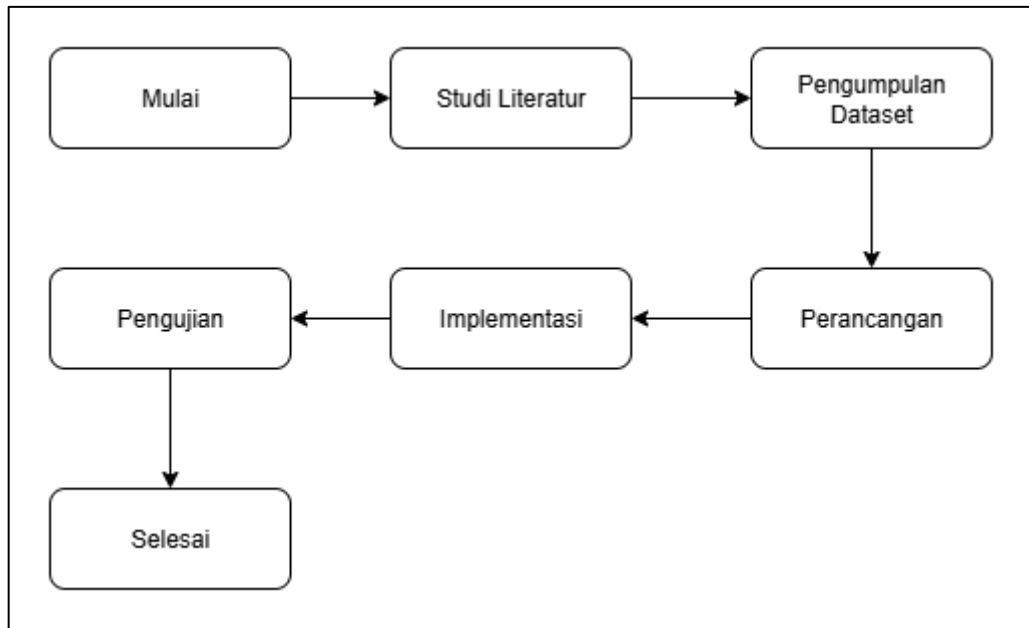
Scale Visual Recognition Challenge) pada tahun 2014. VGG16 memiliki total 16 lapisan yang dapat dilatih, terdiri dari 13 lapisan konvolusi dan 3 lapisan *fully connected*. Ciri khas dari VGG16 adalah penggunaan *filter* konvolusi kecil berukuran 3x3 yang diterapkan berulang kali, serta penggunaan *max pooling* 2x2 untuk mengurangi dimensi ruang. Model ini dirancang dengan tiga saluran warna (RGB) dan input berukuran 224x224 piksel. VGG16 dirancang untuk mengekstraksi fitur dari citra, mulai dari fitur yang sederhana hingga pola yang lebih kompleks. Arsitektur ini sering digunakan dalam tugas transfer learning karena kesederhanaan dan konsistensinya (Ismiaty et al., 2025).



Gambar 3. Arsitektur VGG16

3. Metodologi Penelitian

Pada bagian ini membahas tentang langkah-langkah yang akan dilakukan dalam melakukan penelitian dimulai dari perumusan masalah hingga pengambilan kesimpulan. Diagram alir proses penelitian yang akan dilakukan telah dirancang kedalam bentuk *flowchart* seperti pada gambar 4.



Gambar 4. Tahapan Metodologi Penelitian

Berdasarkan dari gambar 4 dapat dijelaskan dibawah ini:

1. *Studi Literatur*




Tahapan ini dimulai dengan melakukan pembelajaran literatur berupa jurnal dan buku terkait topik penelitian ini,

2. *Pengumpulan Dataset*

Pada tahap ini, dilakukan observasi pada proses pengumpulan *dataset* yang terdiri dari gambar-gambar uang rupiah yang mengalami kerusakan. *Dataset* ini diperoleh secara *primer*, yaitu secara langsung dari Bank Indonesia sebagai sumber utama data. Pengambilan gambar dilakukan menggunakan kamera dari *smartphone* iPhone 11 dengan pengaturan standar, yang menghasilkan gambar berformat HEIC dan memiliki resolusi sebesar 4032 x 3024 piksel. Proses pemotretan dilakukan pada pukul 09.00 WIB dengan menggunakan pencahayaan tambahan untuk memastikan hasil gambar memiliki kualitas yang *optimal*.

Pada penelitian ini, *dataset* yang digunakan adalah *dataset* kerusakan uang rupiah yang terdiri dari 3 jenis kelas. *Dataset* Keusakan Uang yang digunakan dapat dilihat pada Tabel 1.

Tabel 1. Dataset Kerusakan Uang Rupiah.

Gambar	Jumlah Gambar	Tingkat Kerusakan
	224	>20%
	224	>40%
	224	>50%

Tabel 1 berisi gambar *dataset* dari kerusakan uang rupiah dengan jumlah total data yaitu 672 gambar dengan 3 kelas tingkat kerusakan > 20 %, > 40 %, > 50 % setiap kelas masing-masing memiliki 224 gambar kerusakan uang rupiah yang mana terdiri dari 7 nominal uang yang digunakan yaitu Rp.1000 , Rp.2000, Rp.5000, Rp.10.000, Rp.20.000, Rp.50.000 Rp.100.000.

Pada tabel 2. menjelaskan mengenai pembagian *dataset* kerusakan uang rupiah menunjukkan bagaimana dataset dibagi untuk keperluan penelitian ini dalam mengklasifikasikan kerusakan uang rupiah. Dataset tersebut dibagi menjadi dua bagian, yaitu data *training* yang digunakan untuk melatih model, dan data *testing* yang digunakan untuk menguji kinerja model setelah dilatih. Pembagian dilakukan dengan 80% untuk data *training* dan 20% untuk data *testing*.

Tabel 2. Pembagian Dataset Kerusakan Uang Rupiah.

NO	Pembagian <i>Dataset</i>	
	Data Training	Data Testing
1	80 %	20 %
2	537	135
Total Citra Asli	672	
Total Epoch	537 * 50	
Total Keseluruhan Data Setelah Augmentsai	26.850	

Pada Tabel 2, terlihat bahwa 80% dari total *dataset* yang berjumlah 672 citra asli digunakan sebagai data *training*, yaitu sebanyak 537 citra. Data ini digunakan untuk melatih model agar dapat mengenali berbagai jenis kerusakan uang. Sedangkan 20% sisanya, yaitu 135 citra, digunakan untuk data *testing*, yang berfungsi untuk mengukur kemampuan model dalam mengklasifikasikan kerusakan uang.

Selain itu, setelah melalui proses augmentasi data, jumlah citra yang digunakan untuk pelatihan dan pengujian meningkat secara signifikan, mencapai 26.850 citra. Augmentasi data ini bertujuan untuk menambah variasi data latih sehingga model dapat belajar lebih banyak dari contoh data augmentasi dan dapat menggeneralisasi dengan lebih baik pada data yang belum pernah dilihat. Pengambilan gambar dilakukan dengan jarak kamera sekitar 24 cm dari objek, dengan posisi kamera diarahkan tegak lurus dari atas terhadap uang yang difoto. Untuk memastikan latar belakang tampak bersih dan seragam selama proses pengambilan gambar, digunakan kertas putih berukuran A4 sebagai alas atau latar belakang pada setiap pemotretan. Untuk gambar uang hasil pemeriksaan dapat dilihat pada gambar 5.



Gambar 5. Contoh Hasil Pemeriksaan Uang > 20% , > 40%, > 50 %.

Sumber : Bank Indonesia

Dari proses pengumpulan data ini, berhasil diperoleh total sebanyak 672 gambar. Gambar-gambar tersebut dibagi secara merata ke dalam tiga kategori tingkat kerusakan uang rupiah, yaitu masing-masing sebanyak 224 gambar untuk setiap kategori tingkat kerusakan. Format gambar yang dihasilkan dari pemotretan awal berupa HEIC kemudian dikonversi ke format JPG dengan menggunakan layanan konversi *online* dari situs *iLoveIMG*. Proses konversi ini dilakukan karena format HEIC tidak didukung oleh model yang akan digunakan dalam penelitian ini.

Setelah melalui proses konversi, *dataset* yang telah siap digunakan kemudian dibagi ke dalam dua bagian, yaitu 80% dari total gambar digunakan sebagai data latih, sedangkan 20% sisanya digunakan sebagai data uji. Pada tahap pelatihan model, diterapkan teknik augmentasi data *on the fly* untuk meningkatkan variasi dan keragaman data yang digunakan dalam pelatihan model, sehingga diharapkan model dapat melakukan generalisasi yang lebih baik.

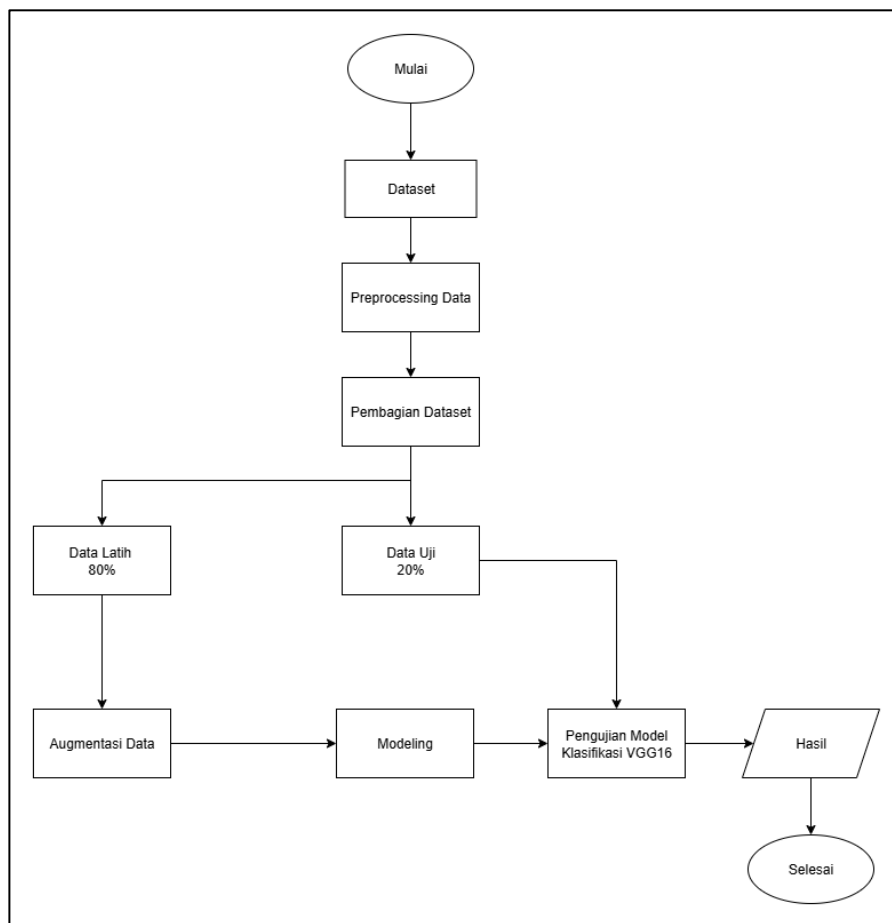
Model arsitektur yang digunakan dalam penelitian ini adalah VGG16. Model ini berfungsi untuk mengklasifikasikan terhadap gambar uang rupiah yang telah dikategorikan berdasarkan tingkat kerusakannya. Untuk gambar alat pemeriksaan uang rusak dapat di lihat pada gambar 6.



Gambar 6. Gambar Alat Pemeriksaan Uang
Sumber : Bank Indonesia

3. Perancangan

Pada tahapan ini dilakukan perancangan mengenai cara *dataset* diolah hingga terbentuknya model VGG16 agar dapat mengklasifikasikan jenis kerusakan uang rupiah berdasarkan tingkat kerusakannya. Skema perancangan yang telah dibuat dapat dilihat pada Gambar 7.



Gambar 7. Skema Perancangan VGG16

Pada tahap awal, sebanyak 672 citra uang rusak yang telah difoto diunggah dan dikelompokkan ke dalam tiga *folder* berdasarkan tingkat kerusakannya, yaitu $>20\%$, $>40\%$, dan $>50\%$. *Dataset* tersebut kemudian melalui dua proses preprocessing, yaitu mengubah ukuran (*resize*) citra menjadi 224×224 piksel serta rescaling untuk menormalkan nilai piksel ke dalam rentang $[0, 1]$. Setelah itu, data dibagi menjadi dua bagian, yakni data latih dan data uji. Untuk meningkatkan keragaman dan membantu model, diterapkan teknik augmentasi secara *on the fly* pada data latih. Tahap selanjutnya adalah pelatihan model menggunakan arsitektur VGG16 dengan data yang telah diperluas melalui augmentasi. Setelah model selesai dilatih, dilakukan tahap pengujian menggunakan data uji untuk mengevaluasi performa model dalam mengklasifikasikan tingkat kerusakan uang rupiah. Hasil dari pengujian ini menunjukkan sejauh mana kemampuan model dalam mengenali dan membedakan tingkat kerusakan uang, menandai berakhirnya proses pelatihan dan pengujian.

2. Implementasi

Pada tahapan ini dilakukan implementasi dari sistem yang telah dirancang sebelumnya agar sistem dapat mengenali dan melakukan klasifikasi terhadap klasifikasi kerusakan uang rupiah yang menjadi data *training*, data *Testing* yang telah diolah sebelumnya dengan model dari CNN yaitu VGG16.

3. Pengujian

Setelah tahap pengujian dilakukan, hasil evaluasi digunakan untuk menilai tingkat keberhasilan metode yang diterapkan dengan memanfaatkan *Confusion Matrix*. Dari matriks ini, dihitung beberapa metrik evaluasi, yaitu: (1) *Precision*, yang menunjukkan proporsi prediksi positif yang benar-benar tepat; (2) *Recall*, yang mengukur sejauh mana model mampu mengenali seluruh kelas positif dengan benar; (3) *F1-Score*, yaitu rata-rata harmonis antara nilai *Precision* dan *Recall*; serta (4) *Accuracy*, yang menggambarkan persentase keseluruhan prediksi yang benar dibandingkan dengan total prediksi yang dilakukan.

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (2)$$

$$F1\ Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (3)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (4)$$

Keterangan:

TP: Jumlah data positif yang terklasifikasi dengan benar oleh sistem

TN: Jumlah data negatif yang terklasifikasi dengan benar oleh sistem

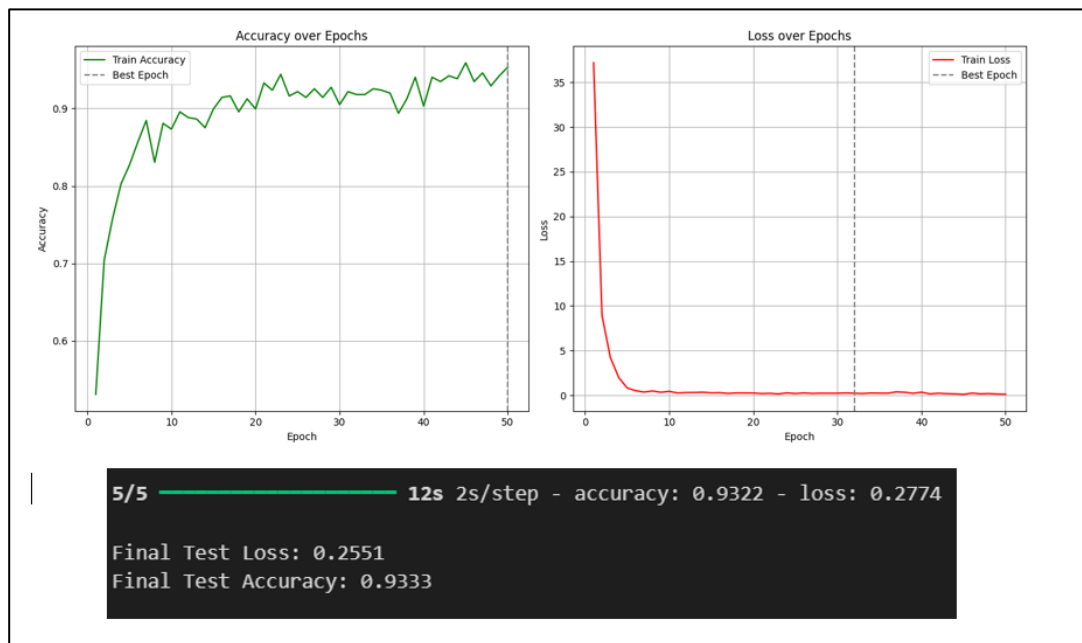
FN: Jumlah data negatif yang terklasifikasi dengan salah oleh sistem

FP: Jumlah data positif yang terklasifikasi dengan salah oleh Sistem.

4. Hasil dan Pembahasan

Pada bagian ini dijelaskan hasil penelitian dan sekaligus diberikan pembahasan yang komprehensif mengenai penerapan augmentasi data *On-The-Fly* didalam model arsitektur VGG16 untuk mengklasifikasikan tingkat kerusakan uang rupiah dengan

menggunakan *Optimizer ADAM*, *Learning Rate*, *Drop out* dan *Epoch*. untuk hasil penelitian ini dapat dilihat pada gambar 8,9 dan 10.



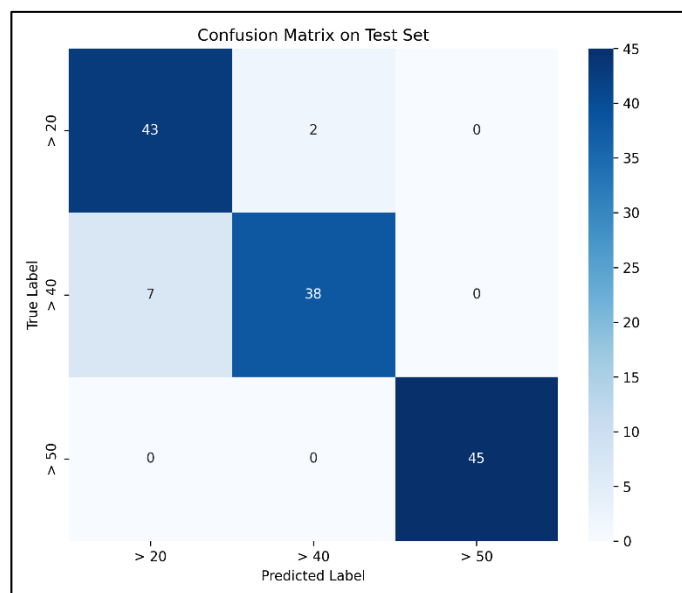
Gambar 8 . Grafik Hasil *Accuracy Epoch* dan *Loss epoch*

Pada gambar 8, grafik menunjukkan perkembangan *train accuracy* dan *train loss* selama proses pelatihan model. Dapat dilihat bahwa *epoch* terbaik untuk *train accuracy* tercapai pada epoch ke-50, yang menunjukkan bahwa model semakin mampu mengenali pola dalam data latih seiring berjalannya waktu. Sedangkan untuk *train loss*, *epoch* terbaik terjadi pada *epoch* ke-32, di mana *loss* menurun drastis, menunjukan bahwa model mampu meminimalisasikan kesalahan prediksi selama pelatihan. Proses pelatihan ini dilakukan dengan *learning rate* sebesar $1e-3$, yang membantu memastikan proses pelatihan berjalan stabil dan efisien. Penggunaan *optimizer ADAM* yang dikombinasikan dengan teknik augmentasi data *On-The-Fly* terbukti efektif dalam meningkatkan performa model serta membantu model untuk mengenali data dengan variasi yang lebih luas.

Classification Report:				
	precision	recall	f1-score	support
> 20	0.8600	0.9556	0.9053	45
> 40	0.9500	0.8444	0.8941	45
> 50	1.0000	1.0000	1.0000	45
accuracy			0.9333	135
macro avg	0.9367	0.9333	0.9331	135
weighted avg	0.9367	0.9333	0.9331	135

Gambar 9 . Hasil *Classification Report*.

Pada gambar 9, terdapat hasil *classification report* yang memberikan metrik evaluasi model berdasarkan precision, recall, dan f1-score untuk setiap kelas kerusakan uang. Dapat dilihat bahwa untuk kategori kerusakan >50%, model mencapai nilai *precision*, *recall*, dan *f1-score* yang sempurna yaitu 1.0000, menunjukkan bahwa model sangat akurat dalam mengklasifikasikan uang dengan kerusakan lebih dari 50%. Sedangkan untuk kategori >40%, model menunjukkan hasil yang baik dengan precision 0.9500 dan recall 0.8444, sementara untuk kategori >20%, meskipun *precision* sedikit lebih rendah (0.8600), model tetap menunjukkan *recall* yang tinggi (0.9556), yang mana menunjukkan kemampuan model dalam mengidentifikasi sebagian besar data kerusakan uang pada kategori ini. Akurasi keseluruhan model adalah 93.33%, yang menunjukkan kinerja model yang sangat baik dalam klasifikasi uang rupiah yang rusak.

Gambar 13 . Tampilan Hasil *Confusion Matrix*.

Confusion matrix pada Gambar 13 memperlihatkan bahwa kesalahan prediksi hampir seluruhnya terjadi antara kelas yang “berdekatan”, yaitu $>20\%$ dan $>40\%$. Secara rinci, dari 45 citra kelas $>20\%$, sebanyak 43 diprediksi benar dan 2 salah diprediksi sebagai $>40\%$. Dari 45 citra kelas $>40\%$, sebanyak 38 diprediksi benar dan 7 salah diprediksi sebagai $>20\%$. Tidak ditemukan kesalahan pada kelas $>50\%$ (45/45 benar). Pola *adjacent-class confusion* ini mengindikasikan bahwa batas visual antara kerusakan sedang ($>40\%$) dan kerusakan ringan-menengah ($>20\%$) kemungkinan memiliki area ambiguitas (misalnya sobekan/lubang yang berada dekat ambang), sehingga model cenderung salah pada sampel borderline. Temuan ini juga menunjukkan bahwa ketika kerusakan sangat jelas ($>50\%$), fitur yang dipelajari model cukup diskriminatif sehingga klasifikasi menjadi nyaris tanpa kesalahan.

Secara praktis, performa sempurna pada kelas $>50\%$ berpotensi mendukung skenario pemilahan awal (screening) uang rusak berat, misalnya untuk prioritas penggantian/penanganan. Secara metodologis, hasil ini menegaskan bahwa transfer learning berbasis VGG16 efektif untuk tugas klasifikasi kerusakan berbasis citra. Namun, untuk penerapan dunia nyata, kelas borderline ($>20\%$ vs $>40\%$) perlu diperkuat melalui peningkatan kualitas pelabelan (standar penentuan tingkat kerusakan yang lebih konsisten), penambahan sampel di rentang ambang, dan pengujian pada kondisi pengambilan gambar yang lebih bervariasi (cahaya, sudut, latar, jenis kamera).

Penelitian ini masih terbatas pada ukuran dataset sehingga generalisasi pada kondisi lapangan belum sepenuhnya terukur. Studi lanjutan disarankan memperbanyak dataset dan melaporkan kurva validasi serta *early stopping* berbasis validasi, melakukan ablation study (tanpa augmentasi vs dengan augmentasi, variasi learning rate, dan perbandingan *optimizer*) mengevaluasi robustnes pada variasi pencahayaan/latar/kamera; serta mempertimbangkan pendekatan ordinal classification atau regresi tingkat kerusakan untuk mengurangi ambiguitas antar kelas yang berdekatan.

5. Kesimpulan

Penelitian ini bertujuan untuk mengembangkan model deep learning menggunakan arsitektur *Convolutional Neural Network* (CNN) dengan VGG16 untuk klasifikasi kerusakan pada uang rupiah. Berdasarkan hasil eksperimen, model yang diterapkan menunjukkan hasil yang memuaskan dalam mengklasifikasikan tingkat kerusakan uang, dengan akurasi mencapai 93.33%. Penggunaan teknik augmentasi data *on-the-fly* terbukti efektif dalam meningkatkan keragaman data latih dan membantu model untuk lebih baik dalam mengenali berbagai variasi kerusakan uang.

Pada tahap pengujian model ini menunjukkan kemampuan yang sangat baik dalam membedakan tingkat kerusakan uang, yang terbagi dalam 3 kategori tingkat

kerusakan uang $>20\%$, $>40\%$, dan $>50\%$. Implementasi *optimizer ADAM* dan *learning rate* $1e-3$ memberikan hasil yang optimal, dalam penelitian ini berperan penting dalam memastikan berjalan lebih cepat dan stabil dengan pengaturan *learning rate* yang tepat dan penerapan *dropout* yang memadai untuk mencegah *overfitting*.

Secara keseluruhan penelitian ini menunjukkan bahwa *deep learning* khususnya CNN dapat digunakan secara efektif dalam klasifikasi kerusakan uang rupiah dan memberikan wawasan lebih lanjut mengenai penerapan teknik pengolahan citra dalam bidang ekonomi. Hasil penelitian ini diharapkan dapat memberikan kontribusi bagi pengembangan metode klasifikasi citra lebih lanjut khususnya dalam konteks pengelolaan uang yang rusak.

Keterbatasan penelitian ini terletak pada ukuran dataset yang terbatas dan kondisi akuisisi citra yang terkontrol, serta belum adanya evaluasi terhadap generalisasi model pada variasi perangkat kamera, pencahayaan, latar belakang, dan kondisi lapangan. Selain itu, prosedur penentuan label persentase kerusakan perlu dijelaskan secara lebih rinci agar hasil penelitian dapat direplikasi dan divalidasi dengan baik.

Untuk penelitian selanjutnya, disarankan untuk menambahkan validation set atau menerapkan k-fold cross-validation, serta melakukan ablation study (misalnya, perbandingan antara dengan dan tanpa augmentasi, variasi learning rate/optimizer, dan strategi fine-tuning). Selain itu, perlu memperluas dataset pada sampel borderline antar kelas untuk mengurangi ambiguitas, serta mengeksplorasi pendekatan ordinal classification atau regresi tingkat kerusakan untuk memodelkan kerusakan sebagai skala berurutan. Percobaan juga dapat dilakukan pada arsitektur lain untuk mengevaluasi performa yang lebih baik.

6. Ucapan Terima Kasih

Saya mengucapkan rasa syukur kepada Tuhan Yang Maha Esa, serta terimakasih kepada semua pihak yang terlibat pada penelitian ini terutama co-author dari Universitas Multi Data Palembang karena telah mendukung dan membimbing dalam penelitian ini serta terimakasih kepada pihak Bank Indonesia yang telah memberikan izin untuk pengambilan data dalam penelitian ini terutama kepada mas Ade Budiman yang telah membantu saya banyak dalam pengambilan data di Bank Indonesia dan UP Bagian Unit Pengelolaan Uang Rupiah Bpk. Sukarman serta rekan-rekan dibidang Pengelolaan Uang Rupiah (PUR) Bank Indonesia Sumatera Selatan.

7. Pernyataan Penulis

Penulis menyatakan bahwa tidak ada konflik kepentingan terkait publikasi artikel ini. Penulis menyatakan bahwa data dan makalah bebas dari plagiarisme serta penulis bertanggung jawab secara penuh atas keaslian artikel.

Bibliografi

- Ahnaf, M. B., Rizal, A., & Prihatiningrum, N. (2024). Sistem pendeteksi kelayakan uang kertas rupiah metode Canny berbasis OpenCV. *E-Proceeding of Engineering*, 11(1), 468.
- Alfaruq, M., Harun, H., & Fitri Habi, N. (2024). Jual beli uang rusak perspektif hukum bisnis syariah. *Journal of Comprehensive Islamic Studies*, 2(2), 221–236. <https://doi.org/10.56436/jocis.v2i2.282>
- Aprillia, D., Rohana, T., Al Mudzakir, T., & Wahiddin, D. (2024). Deteksi nominal mata uang rupiah menggunakan metode convolutional neural network dan feedforward neural network. *KLJK: Kajian Ilmiah Informatika dan Komputer*, 4(4).
- Bank Indonesia. (2011). *Buku panduan uang rupiah: Ciri-ciri keaslian, standar visual kualitas rupiah dan daftar rupiah yang dicabut dan ditarik dari peredaran*. Bank Indonesia.
- Bank Indonesia. (n.d.). *Informasi/ ketentuan penukaran uang tidak layak edar/ uang rusak*.
- Bareksa.com. (2017, February 15). BI musnahkan Rp210,49 triliun uang rusak. *Bareksa.com*. <https://www.bareksa.com/berita/berita-ekonomi-terkini/2017-02-15/bi-musnahkan-rp21049-triliun-uang-rusak?>
- Gai, S., Xu, X., & Xiong, B. (2020). Paper currency defect detection algorithm using quaternion uniform strength. *Neural Computing and Applications*, 32(16), 12999–13016. <https://doi.org/10.1007/s00521-020-04745-6>
- Hidayat, A. M. N., Antamil, A., & Zakiyah M, I. (2023). Identifikasi nominal mata uang rupiah bagi penyandang tunanetra dengan algoritma convolutional neural network berbasis Android. *Journal Software, Hardware and Information Technology*, 3(2), 60–65. <https://doi.org/10.24252/shift.v3i2.102>

- Husen, D. (2024). Evaluasi teknik augmentasi data untuk klasifikasi tumor otak menggunakan CNN pada citra MRI. *TEKNIMEDIA: Teknologi Informasi dan Multimedia*, 5(2). <https://doi.org/10.46764/teknimedia.v5i2.220>
- Ibrahim, M. M., Rahmadewi, R., & Nurpulaela, L. (2023). Pendeteksian nominal uang pada gambar menggunakan convolutional neural network: Integrasi metode pra-pemrosesan citra dan klasifikasi berbasis CNN. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(2), 1394–1400. <https://doi.org/10.36040/jati.v7i2.6863>
- Ismiaty, A., Ht, R., Astuti, W. S., Wanto, A., & Solikhun, S. (2025). Optimisasi VGG16 dengan transfer learning dalam mendeteksi penyakit pada daun jagung. *Bulletin of Computer Science Research*, 5(5), 1049–1058. <https://doi.org/10.47065/bulletincsr.v5i5.631>
- Khairu, D., Wantasen, F., Yusupa, A., & Taringan, V. (2025). Klasifikasi jenis uang kertas menggunakan convolutional neural network: A convolutional neural network-based approach for classifying types of paper currency, 2(2), 658–668.*
- Kurniadi, D., Shidiq, R. M., & Mulyani, A. (2025). Perbandingan penggunaan optimizer dalam klasifikasi sel darah putih menggunakan convolutional neural network. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, 14(1), 77–86. <https://doi.org/10.22146/jnteti.v14i1.17162>
- Nandika, A. P., Imanullah, M., Wijaya, A., & Sunardi, D. (2025). Deteksi kondisi uang bagus dan rusak dengan pengolahan citra digital berbasis convolutional neural network (CNN). *Jurnal Media Infotama*, 21(1), 340–348.
- Pachon, C. G., Ballesteros, D. M., & Renza, D. (2021). Fake banknote recognition using deep learning. *Applied Sciences*, 11(3), 1281. <https://doi.org/10.3390/app11031281>
- Pachon, C. G., Ballesteros, D. M., & Renza, D. (2023). An efficient deep learning model using network pruning for fake banknote recognition. *Expert Systems with Applications*, 233, 120961. <https://doi.org/10.1016/j.eswa.2023.120961>
- Pamungkas, O. E., Rahmawati, P., Supriadi, D. M., Khalika, N. N., Maliyano, T., Pangestu, D. R., Nugraha, E. S., Afandi, M. A., Wulandari, N., Goran, P. K., & Wicaksono, A. (2022). Classification of Rupiah to help blind with the convolutional neural network method. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 6(2), 259–268. <https://doi.org/10.29207/resti.v6i2.3852>

- Rewina, A. E., Sulistyowati, S., Kurniawan, M., N, M. D., & Yunanda, S. F. (2024). Penerapan metode CNN (convolutional neural network) dalam mengklasifikasi uang kertas dan uang logam. *TIN: Terapan Informatika Nusantara*, 4(12), 778–785. <https://doi.org/10.47065/tin.v4i12.5128>
- Sardika, R. P., & Widhiarso, W. (2025). Klasifikasi otomatis tingkat kerusakan retak bangunan pada citra digital menggunakan MobileNetV2 dan augmentasi data. *Arcitech: Journal of Computer Science and Artificial Intelligence*, 5(1), 108–124. <https://doi.org/10.29240/arcitech.v5i1.13938>
- Sadewa, B. A., & Yamasari, Y. (2024). Implementasi deep transfer learning untuk klasifikasi nominal uang kertas rupiah. *Journal of Informatics and Computer Science (JINACS)*, 5(04), 543–551. <https://doi.org/10.26740/jinacs.v5n04.p543-551>
- Saputra, A. N., Handayani, H. H., Sukmawati, C. E., & Siregar, A. M. (2024). Model klasifikasi nominal mata uang kertas Republik Indonesia menggunakan convolutional neural network. *Journal of Information System Research (JOSH)*, 6(1), 176–184. <https://doi.org/10.47065/josh.v6i1.5927>
- Studi, P., Terapan, S., Rekayasa, T., Lunak, P., Informasi, J. T., & Bali, P. N. (2025). Perhitungan nominal uang secara cepat menggunakan metode You Only Look Once (YOLO). *[Sumber publikasi tidak tersedia]*.
- Zeng, W. (2024). *Image data augmentation techniques based on deep learning: A survey*. 21(February), 6190–6224.