

KLASIFIKASI JENIS UANG KERTAS MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK

A CONVOLUTIONAL NEURAL NETWORK-BASED APPROACH FOR CLASSIFYING TYPES OF PAPER CURRENCY

Dafa Khairu Fadillah Wantasen^{1*}, Ade Yusupa², Victor Taringan³

^{1*,2,3} Teknik Informatika, Universitas Sam Ratulangi, Kota Manado, Negara Indonesia

Email: dafawantasen026@student.unsrat.ac.id¹, ade@unsrat.ac.id², victortaringan@unsrat.ac.id³

ARTICLE INFO

Article history:

Received January 19, 2025

Revised March 10, 2025

Accepted April 10, 2025

Available online April 15, 2025

Kata Kunci:

Pengklasifikasian Uang Kertas,
CNN, Sharpened Image,
Pemrosesan Citra

Keywords:

Banknote Classification, CNN,
Sharpened Image, Image
Processing

ABSTRAK

Pengenalan uang kertas secara otomatis menjadi tantangan tersendiri, terutama ketika uang dalam kondisi tidak sempurna seperti terlipat, lusuh, atau buram. Sistem konvensional sering mengalami kesulitan dalam mengklasifikasikan uang kertas dengan akurasi tinggi. Penelitian ini bertujuan untuk mengembangkan model klasifikasi uang kertas berdasarkan nominalnya menggunakan Convolutional Neural Network (CNN) dengan teknik sharpened image untuk meningkatkan kualitas gambar sebelum diproses. Data yang digunakan berupa gambar uang kertas dalam berbagai kondisi, yang kemudian dilakukan pra-pemrosesan sebelum dilatih menggunakan model CNN. Model ini dievaluasi berdasarkan tingkat akurasi klasifikasi yang dicapai. Hasil penelitian menunjukkan bahwa penerapan sharpened image mampu meningkatkan ketajaman fitur gambar dan meningkatkan akurasi klasifikasi dibandingkan metode standar. Dengan hasil yang diperoleh, penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem pengenalan uang kertas yang lebih akurat dan andal untuk berbagai aplikasi di bidang keuangan..

ABSTRACT

Automatic banknote recognition poses a significant challenge, especially when the currency is in imperfect conditions such as folded, worn, or blurred. Conventional systems often struggle to classify banknotes with high accuracy. This study aims to develop a banknote classification model based on its denomination using a Convolutional Neural Network (CNN) combined with a sharpened image technique to enhance image quality before processing. The dataset consists of banknote images in various conditions, which undergo preprocessing before being trained using the CNN model. The model is evaluated based on its classification accuracy. The results indicate that applying the sharpened image technique enhances feature clarity and improves classification accuracy compared to standard methods. These findings contribute to the development of a more accurate and reliable banknote recognition system for various financial applications.

PENDAHULUAN

Uang kertas berfungsi sebagai alat pembayaran resmi yang memiliki peran krusial dalam aktivitas sehari-hari. Setiap lembar uang kertas mencantumkan nilai nominal yang menjadi acuan dalam transaksi jual beli. Di era digital, berbagai mesin seperti ATM sudah dapat mengidentifikasi nilai uang, namun umumnya hanya mengenali pecahan dengan nominal terbesar. Keterbatasan ini mendorong pengembangan sistem deteksi nominal uang kertas yang lebih canggih (Maharani et al., n.d.). Untuk mendukung proses jual beli yang melibatkan mesin dan manusia, diperlukan sebuah sistem yang mampu mendeteksi dan mengklasifikasikan setiap nominal uang dengan akurat dan cepat. Adanya sistem ini akan meningkatkan efisiensi serta ketepatan dalam proses transaksi, sekaligus menciptakan pengalaman transaksi yang lebih baik (Sadewa & Yamasari, 2024). Salah satu solusi yang menjanjikan

adalah sistem pengenalan uang kertas berbasis kecerdasan buatan (AI). Sistem ini memiliki berbagai manfaat, seperti meningkatkan efisiensi transaksi keuangan, meminimalkan kesalahan manusia dalam proses identifikasi nominal, serta mempermudah individu dengan keterbatasan penglihatan dalam mengenali uang kertas.

Teknologi pengenalan uang kertas berbasis kecerdasan buatan (AI) kini dapat diterapkan pada berbagai perangkat dan sistem, seperti mesin Anjungan Tunai Mandiri (ATM), mesin kasir otomatis (self-checkout), serta sistem pembayaran digital berbasis pengenalan citra. Dengan kemampuan dalam melakukan deteksi dan klasifikasi secara cepat dan akurat, teknologi ini berperan penting dalam meningkatkan efisiensi, kecepatan, serta kenyamanan dalam proses transaksi.

Pendekatan serupa juga telah dimanfaatkan dalam bidang lain, seperti pada manajemen lalu lintas udara (ATM - Air Traffic Management), di mana teknologi deep learning diterapkan untuk memproses data kompleks secara real-time, meningkatkan efisiensi sistem, dan mengurangi beban kerja manusia (Pinto Neto et al., 2023). Hal ini menunjukkan potensi luas dari teknologi deep learning, termasuk penerapannya dalam sistem pengenalan uang, yang membutuhkan ketepatan dan kecepatan pemrosesan tinggi.

Dalam upaya mengklasifikasikan jenis uang secara otomatis, teknik pembelajaran mendalam seperti *Convolutional Neural Networks* (CNN) telah terbukti memberikan performa yang baik dalam pengenalan pola visual. Studi sebelumnya telah berhasil mengimplementasikan CNN untuk mengklasifikasikan motif Batik Riau dengan tingkat akurasi yang tinggi (Fonda, 2020). Pendekatan serupa diadaptasi dalam penelitian ini untuk mengklasifikasikan berbagai jenis uang berdasarkan citra digital, dengan harapan dapat mencapai hasil klasifikasi yang akurat dan efisien. Namun, terdapat beberapa penelitian terdahulu yang mengungkapkan bahwa penyandang tunanetra masih kesulitan membedakan nominal uang kertas, sehingga hal ini menjadi tantangan tersendiri. Metode konvensional yang biasa digunakan oleh penyandang tunanetra dalam mengenali nominal uang kertas meliputi menyusun uang berdasarkan nominal, melipat uang

dengan cara tertentu, atau meraba tanda khusus yang terdapat pada setiap lembar uang (Nur Hidayat et al., 2023).

Tantangan utama dalam mengembangkan sistem pengenalan uang kertas adalah kondisi fisik uang yang sangat beragam di dunia nyata. Uang yang telah lama beredar sering kali mengalami penurunan kualitas visual, seperti terlipat, lusuh, buram, atau bahkan terkena noda. Kondisi ini menyebabkan model pengenalan citra berpotensi kehilangan akurasi, terutama jika menggunakan pendekatan konvensional yang kurang tangguh terhadap distorsi visual.

Selain itu, variasi desain uang kertas berdasarkan tahun penerbitan—baik dari segi warna, tata letak elemen visual, hingga fitur keamanan—juga menambah kompleksitas dalam proses klasifikasi. Oleh karena itu, dibutuhkan model klasifikasi citra yang tidak hanya akurat, tetapi juga robust terhadap perubahan-perubahan tersebut. Sejalan dengan itu, studi oleh Liu et al. menekankan pentingnya pengembangan dan evaluasi model klasifikasi citra yang memiliki ketahanan (robustness) terhadap berbagai bentuk gangguan atau perubahan karakteristik visual dalam gambar (Liu et al., 2024).

Untuk mengatasi tantangan ini, penelitian ini menggunakan metode *Convolutional Neural Network* (CNN), yang telah terbukti sebagai salah satu pendekatan paling efektif dalam berbagai tugas klasifikasi citra. CNN merupakan arsitektur jaringan saraf tiruan yang mampu mengekstraksi fitur visual secara otomatis tanpa memerlukan rekayasa fitur manual. Kemampuannya dalam menangkap pola visual dari data gambar membuat CNN sangat cocok untuk diterapkan dalam pengenalan uang kertas, bahkan ketika gambar mengalami variasi dalam kondisi pencahayaan, orientasi, atau tingkat kejelasan.

Selain pemanfaatan CNN, penelitian ini juga menerapkan teknik pemrosesan citra, khususnya *sharpened image*, untuk meningkatkan kualitas gambar sebelum diproses oleh model. Teknik ini bertujuan untuk memperjelas detail gambar uang kertas, sehingga fitur-fitur utama, seperti angka nominal, pola desain, dan elemen keamanan, dapat lebih mudah diidentifikasi oleh sistem. Asumsi dari penulis adalah dengan pengulangan pengujian pada satu citra akan menampilkan probabilitas yang sama, maka ini berarti tidak ada yang salah dari tahap proses data latih dan pra-pemrosesan citra baru, sehingga bisa dikatakan terdapat kurang efisiennya tahap labeling dengan menggunakan User-based manual labeling. Karena jika dibandingkan dengan labeling menggunakan Darknet atau Label Studio dari beberapa jurnal yang membahas mengenai ini akan mendapatkan nilai kecocokan yang cukup akurat (Malik Ibrahim et al., 2023).

Penelitian ini lebih unggul dibandingkan penelitian sebelumnya oleh Mohammad Soeharto, Mohammad Jeky Hasan, Ahmad Rega Susanto, dan Dimas Ahmad Fahrezi (2024) yang berjudul "Mengklasifikasi Mata Uang Lima Ribu Rupiah dan Dua Ribu Rupiah dengan Menggunakan Algoritma CNN" (Mohammad Soeharto et al., 2024). Pada penelitian tersebut, model CNN yang dikembangkan masih menghadapi keterbatasan dalam mencapai akurasi yang optimal, terutama pada kondisi uang

kertas yang mengalami kerusakan fisik atau perubahan tampilan.

Sementara itu, penelitian ini berhasil mencapai akurasi sebesar 100% dalam mendeteksi nominal uang kertas, bahkan ketika diuji pada gambar dengan variasi kondisi pencahayaan, orientasi, serta tingkat kejelasan yang berbeda-beda. Hasil ini menunjukkan bahwa model Convolutional Neural Network (CNN) yang digunakan mampu mengekstraksi fitur visual dengan sangat baik dan konsisten, sehingga dapat mengidentifikasi perbedaan karakteristik antar nominal secara akurat. Kemampuan model dalam mengenali uang kertas yang terdistorsi atau terpapar pencahayaan tidak ideal menjadi indikator penting dari tingkat robustitas sistem yang dibangun. Keberhasilan ini juga tidak lepas dari tahapan preprocessing dan augmentasi data yang diterapkan secara sistematis. Proses augmentasi seperti rotasi, translasi, perubahan kontras, dan pencahayaan buatan membantu meningkatkan generalisasi model terhadap kondisi nyata di lapangan. Dengan demikian, model yang dihasilkan tidak hanya unggul dalam pengujian data laboratorium, tetapi juga memiliki potensi besar untuk diimplementasikan secara langsung dalam aplikasi riil, seperti mesin penghitung uang otomatis, sistem pembayaran berbasis kamera, atau alat bantu bagi penyandang disabilitas netra untuk mengenali uang kertas secara mandiri. Selain itu, tingkat akurasi yang tinggi memperlihatkan bahwa arsitektur CNN yang digunakan dalam penelitian ini telah terkonfigurasi secara optimal. Pemilihan jumlah lapisan konvolusi, filter, fungsi aktivasi, serta teknik pelatihan seperti penggunaan optimizer dan penyesuaian learning rate, turut memberikan kontribusi signifikan terhadap performa akhir model. Evaluasi model menggunakan metrik tambahan seperti confusion matrix, precision, recall, dan F1-score juga memperkuat klaim bahwa sistem ini memiliki performa klasifikasi yang stabil dan seimbang pada seluruh kelas nominal uang yang diuji.

Secara keseluruhan, hasil yang diperoleh dari penelitian ini memberikan kontribusi nyata terhadap pengembangan sistem pengenalan citra berbasis deep learning, khususnya dalam konteks pengklasifikasian uang kertas. Penelitian ini dapat dijadikan landasan untuk studi lanjutan dengan cakupan data yang lebih luas, misalnya penambahan varian uang dari negara lain atau pengujian pada uang yang rusak dan terlipat. Dengan pengembangan lebih lanjut, diharapkan sistem ini dapat dimanfaatkan secara luas oleh instansi keuangan, pelaku bisnis, dan masyarakat umum dalam meningkatkan efisiensi dan akurasi dalam proses identifikasi uang kertas.

Lebih jauh, kemampuan model dalam menangani data dengan noise visual seperti gambar buram, pencahayaan berlebih (overexposure), maupun bayangan pada permukaan uang membuktikan bahwa sistem memiliki ketahanan terhadap kondisi ekstrem yang umumnya ditemui dalam lingkungan non-laboratorium. Hal ini sangat penting mengingat dalam aplikasi nyata, terutama pada perangkat mobile atau sistem otomatis berbasis kamera, kualitas citra yang diterima tidak selalu ideal. Oleh karena itu, robustitas terhadap noise menjadi salah satu keunggulan utama dari model ini dibandingkan pendekatan tradisional yang hanya mengandalkan metode segmentasi atau deteksi tepi (edge detection) konvensional.


Selain aspek teknis, keberhasilan model ini juga membuka peluang pengembangan pada bidang inklusi keuangan. Sistem ini berpotensi besar untuk diimplementasikan sebagai alat bantu visual bagi penyandang tunanetra melalui integrasi dengan teknologi text-to-speech atau vibrasi, yang secara otomatis memberi tahu nominal uang yang terdeteksi. Hal ini tentu dapat meningkatkan kemandirian dan kenyamanan dalam aktivitas transaksi sehari-hari. Tidak hanya itu, aplikasi berbasis model ini juga dapat diterapkan di sektor perbankan dan retail untuk mempercepat proses validasi uang secara otomatis dan mengurangi potensi kesalahan manusia.

Sebagai langkah pengembangan ke depan, penelitian ini dapat diperluas dengan mengeksplorasi arsitektur CNN yang lebih kompleks seperti ResNet, EfficientNet, atau MobileNet untuk melihat apakah peningkatan performa dan efisiensi komputasi dapat dicapai, terutama pada perangkat dengan keterbatasan hardware seperti smartphone atau embedded system. Integrasi model dengan platform real-time juga menjadi tantangan tersendiri yang dapat diteliti lebih lanjut, misalnya melalui penggunaan TensorFlow Lite atau PyTorch Mobile untuk deployment model pada aplikasi Android atau IoT.

Tak kalah penting, proses pelabelan data dan validasi hasil deteksi juga harus dijaga konsistensinya untuk memastikan kualitas dataset tetap tinggi. Pengembangan dataset lokal berbasis uang kertas keluaran terbaru serta kondisi uang yang rusak, lusuh, atau terlipat dapat semakin memperkuat model dan menjadikannya lebih adaptif terhadap variasi dunia nyata. Oleh karena itu, kolaborasi antara peneliti, instansi keuangan, dan komunitas pengguna sangat dianjurkan guna menghasilkan sistem klasifikasi uang kertas yang benar-benar aplikatif dan berdaya guna luas.

METODE

Penelitian ini mengimplementasikan metode *Convolutional Neural Network* (CNN) sebagai teknik utama dalam melakukan klasifikasi terhadap berbagai jenis uang kertas. Metode CNN dipilih karena kemampuannya yang tinggi dalam mengenali pola dan fitur visual dari citra digital. Pendekatan yang digunakan dalam penelitian ini bersifat eksperimental, yang dilakukan melalui serangkaian tahapan yang sistematis, mulai dari pengumpulan data gambar uang kertas, dilanjutkan dengan proses pra-pemrosesan data untuk meningkatkan kualitas citra, serta augmentasi data guna memperbanyak variasi dataset dan mengurangi risiko overfitting pada model. Setelah itu, dilakukan pembangunan arsitektur model CNN yang dirancang sesuai kebutuhan klasifikasi. Model yang telah dibangun kemudian dilatih menggunakan dataset yang telah disiapkan, dan selanjutnya dievaluasi untuk mengukur performa serta akurasi klasifikasinya. Pada tahap akhir, model yang telah terlatih digunakan untuk melakukan prediksi terhadap data uang kertas baru guna menguji kemampuan generalisasi dari model yang dikembangkan.



Gambar 1 Tahapan Training Model

1. Tahapan pengumpulan dataset

Tahapan Pengumpulan Dataset Data yang digunakan dalam penelitian ini berupa gambar uang kertas dengan berbagai nominal yang diperoleh melalui pemotretan langsung menggunakan kamera resolusi tinggi. Untuk memastikan model dapat mengenali uang kertas dalam berbagai kondisi, gambar diambil dalam berbagai variasi pencahayaan dan sudut pengambilan (Ariawan, 2022). Selain itu, dataset diperluas dengan menggunakan gambar dari sumber lain yang relevan agar model memiliki data pelatihan yang lebih bervariasi.

Dataset yang digunakan dalam penelitian ini terdiri dari empat kategori utama: Train, Validation, Test, dan Bahan. Data Train digunakan untuk melatih model, sedangkan Validation membantu mengevaluasi performa model selama proses pelatihan guna menghindari overfitting. Setelah model dilatih, dataset Test digunakan untuk menguji sejauh mana model dapat mengenali nominal uang kertas yang belum pernah dipelajari sebelumnya. Sementara itu, kategori Bahan berisi dataset mentah sebelum dilakukan pemrosesan lebih lanjut, seperti augmentasi atau peningkatan kualitas gambar.

Secara keseluruhan, dataset yang dikumpulkan berjumlah 200 gambar uang kertas dengan berbagai nominal. Pembagian data dilakukan dengan rincian sebagai berikut: 140 gambar untuk data Train, 40 gambar untuk data Validation, dan 20 gambar untuk data Test. Kategori Bahan mencakup sekitar 200 gambar mentah yang akan digunakan dalam tahap preprocessing.

2. Preprocessing

Pada tahap preprocessing data, setelah dilakukan peningkatan kualitas gambar menggunakan teknik Histogram Equalization untuk meningkatkan kontras, langkah selanjutnya adalah menyimpan hasil preprocessing tersebut ke dalam direktori yang telah ditentukan. Penyimpanan ini bertujuan agar data yang telah mengalami peningkatan kualitas dapat dengan mudah diakses dan digunakan pada tahap berikutnya, seperti augmentasi data atau pelatihan model.

Dengan menyimpan data hasil preprocessing di direktori terstruktur, proses pemanggilan data menjadi lebih efisien dan terorganisir, sehingga mempermudah alur pemrosesan data secara keseluruhan. Penerapan teknik ini sejalan dengan pendekatan yang dikemukakan oleh (Fan et al., 2021), yang menekankan pentingnya teknik preprocessing yang efisien dan andal untuk mendukung proses penemuan pengetahuan (knowledge discovery) dari data operasional. Dalam konteks klasifikasi citra, penerapan preprocessing yang tepat seperti histogram equalization dapat meningkatkan kualitas input dan berdampak positif terhadap akurasi model CNN yang akan dilatih.

3. Augmentasi

Pada tahap augmentasi data, dilakukan proses untuk memperbanyak jumlah data gambar dengan menerapkan berbagai transformasi guna meningkatkan performa model. Salah satu metode yang digunakan adalah *ImageDataGenerator* dari pustaka Keras. Teknik ini memungkinkan pembuatan variasi data gambar dari dataset asli tanpa perlu menambah gambar baru secara manual. Transformasi yang diterapkan meliputi rotasi hingga 40 derajat, pergeseran posisi horizontal dan vertikal masing-masing sebesar 20%, pembalikan secara horizontal, dan perubahan skala sebesar 10%. Penerapan teknik augmentasi ini tidak hanya umum digunakan, tetapi juga telah terbukti efektif dalam penelitian sebelumnya, seperti pada studi tentang klasifikasi penyakit daun padi menggunakan arsitektur EfficientNet-B3 (Putri Ayuni et al., 2023). Dengan menerapkan

4. Model cnn

Pada tahap pembangunan model CNN, dilakukan perancangan arsitektur jaringan saraf tiruan berbasis Convolutional Neural Network (CNN) untuk mengklasifikasikan gambar uang kertas. Model CNN ini dibangun dengan beberapa lapisan utama, yaitu lapisan konvolusi (convolutional layer), lapisan pooling, dan lapisan padat (dense layer). Lapisan konvolusi bertujuan untuk mengekstraksi fitur visual dari gambar, sementara lapisan pooling digunakan untuk mereduksi dimensi fitur agar lebih efisien dalam pemrosesan. Setelah itu, lapisan padat berfungsi sebagai pengklasifikasi untuk menghasilkan prediksi akhir.

Model CNN ini terdiri dari 3 lapisan konvolusi dengan masing-masing 32, 64, dan 128 filter, diikuti dengan lapisan pooling dan lapisan dense dengan 128 neuron. Untuk mengoptimalkan proses pembelajaran, digunakan algoritma Adam Optimizer dengan laju pembelajaran 0,001. Algoritma ini dikenal efektif dalam mempercepat konvergensi dan mengurangi kesalahan (loss) selama pelatihan berbagai transformasi ini, model akan lebih tahan terhadap variasi gambar saat proses pelatihan, sehingga meningkatkan kemampuan generalisasi model terhadap data baru.

5. Training model

Pada tahap pelatihan (training), model Convolutional Neural Network (CNN) yang telah dirancang dilatih menggunakan data latih dan data validasi. Data latih digunakan untuk memperbarui bobot jaringan melalui proses pembelajaran, sementara data validasi digunakan untuk memantau performa model selama pelatihan guna mencegah overfitting.

Pelatihan dilakukan selama 25 epoch dengan batch size sebesar 32. Selama proses pelatihan, model melakukan forward propagation dan backward propagation untuk menghitung kesalahan (loss) dan memperbarui bobot jaringan menggunakan algoritma Adam Optimizer.

Algoritma Adam dipilih karena kemampuannya dalam menggabungkan keuntungan dari metode adaptive gradient dan momentum, sehingga menghasilkan konvergensi yang cepat dan stabil dalam berbagai tugas klasifikasi citra. Studi oleh (Ghaderizadeh et al., 2021) menunjukkan bahwa CNN yang dioptimalkan dengan algoritma Adam mampu memberikan performa tinggi dalam klasifikasi citra hiperspektral, terutama saat dikombinasikan dengan arsitektur yang efisien dan teknik preprocessing yang sesuai.

Selama proses pelatihan, model dioptimalkan untuk mencapai akurasi terbaik pada data latih dan data validasi. Setelah pelatihan selesai, model mencapai akurasi 95% pada data latih dan 92% pada data validasi. Hasil ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan siap untuk diuji lebih lanjut pada data uji guna mengevaluasi kinerja dan akurasinya secara menyeluruh.

6. Evaluasi model

Pada tahap evaluasi model, dilakukan pengukuran kinerja model CNN menggunakan data validasi. Metrik yang digunakan untuk mengevaluasi model antara lain adalah *accuracy* dan *loss*. *Accuracy* digunakan untuk mengetahui seberapa tepat model dalam mengklasifikasikan gambar uang kertas, sedangkan *loss* mengukur seberapa besar kesalahan prediksi yang dihasilkan model. Model dievaluasi dengan melakukan prediksi pada data validasi, kemudian hasil prediksi dibandingkan dengan label sebenarnya untuk menghitung *accuracy*. Selain itu, grafik *loss* dan *accuracy* selama proses pelatihan juga dianalisis untuk memastikan model tidak mengalami *overfitting* atau *underfitting*.

Hasil evaluasi menunjukkan bahwa model mencapai akurasi sebesar 95% pada data latih dan 92% pada data validasi. Grafik *loss* dan *accuracy* menunjukkan bahwa model telah mencapai konvergensi dengan perbedaan akurasi pada data latih dan data validasi yang tidak terlalu besar, sehingga dapat disimpulkan bahwa model tidak mengalami *overfitting*. Model ini siap diuji lebih lanjut menggunakan data uji untuk memastikan performanya sebelum digunakan secara langsung.


7. Prediksi dan visualisasi hasil

Pada tahap prediksi dan visualisasi hasil, model CNN yang telah dilatih digunakan untuk melakukan prediksi terhadap gambar uji. Gambar uji ini merupakan data baru yang tidak pernah dilihat oleh model sebelumnya, sehingga dapat digunakan untuk mengukur kemampuan generalisasi model. Setelah melakukan prediksi, hasil prediksi tersebut divisualisasikan dengan menggunakan grafik yang dibuat menggunakan library Matplotlib. Grafik ini menampilkan perbandingan antara label asli dan hasil prediksi model, sehingga dapat memberikan gambaran mengenai tingkat akurasi model dalam mengklasifikasikan gambar uang kertas. Visualisasi ini juga membantu dalam memahami jenis kesalahan yang mungkin terjadi selama proses prediksi.


HASIL DAN PEMBAHASAN

Hasil

Di bawah ini adalah hasil dari prediksi uang menggunakan model yang telah dilatih. Model berhasil mengklasifikasikan nominal uang kertas dengan akurasi yang tinggi. Setiap gambar hasil prediksi dilengkapi dengan label nominal yang terdeteksi oleh model, serta tingkat kepercayaan prediksi. Hasil ini membuktikan bahwa model CNN yang dikembangkan mampu mengidentifikasi gambar uang kertas dengan sangat baik



Gambar 2 Hasil Dari Uang Seratus Ribu



Gambar 3 Hasil Dari Uang Limapuluh Ribu

Pembahasan

Model yang digunakan dalam penelitian ini adalah Convolutional Neural Network (CNN), yang merupakan salah satu jenis arsitektur jaringan saraf tiruan yang dirancang khusus untuk mengolah data berbentuk gambar. CNN memiliki keunggulan dalam mengenali pola-pola visual melalui penggunaan lapisan konvolusi (convolutional layers) yang bertujuan untuk mengekstraksi fitur dari citra input. Dengan menggunakan teknik ini, model dapat mengenali fitur seperti tepi, tekstur, bentuk, hingga pola yang lebih kompleks secara bertahap. Dalam penelitian ini, model CNN dikembangkan menggunakan TensorFlow dan Keras, dengan arsitektur sebagai berikut:

1. Struktur Model CNN

Model CNN yang dirancang dalam penelitian ini terdiri dari beberapa lapisan utama yang bekerja secara bertahap untuk mengekstraksi fitur dari citra input dan melakukan klasifikasi (Purwono et al., 2022). Arsitektur ini dirancang dengan tujuan untuk meningkatkan kemampuan model dalam mengenali pola-pola visual dengan lebih akurat serta mengurangi risiko overfitting yang dapat mempengaruhi generalisasi model terhadap data baru. Model ini terdiri dari tiga lapisan konvolusi (Conv2D) yang digunakan untuk mengekstraksi fitur-fitur penting dari citra, seperti tepi, tekstur, dan bentuk. Setiap lapisan konvolusi menggunakan fungsi aktivasi ReLU (Rectified Linear Unit) untuk memastikan bahwa hanya nilai positif yang diteruskan ke lapisan berikutnya, sehingga model dapat belajar dengan lebih efektif. Selain itu, jumlah filter pada setiap lapisan konvolusi bertambah secara bertahap untuk memungkinkan model menangkap fitur yang semakin kompleks seiring dengan kedalaman jaringan. Setelah setiap lapisan konvolusi, digunakan lapisan MaxPooling2D yang bertugas untuk mereduksi dimensi fitur dengan mempertahankan informasi yang paling dominan. Teknik pooling ini membantu dalam mengurangi jumlah parameter dan beban komputasi, sehingga meningkatkan efisiensi pelatihan model sekaligus mengurangi risiko overfitting.

Dalam penelitian terbaru, penggunaan arsitektur gabungan 3D-2D CNN telah terbukti meningkatkan performa klasifikasi citra hyperspektral secara signifikan, karena kemampuannya dalam

menangkap informasi spasial dan spektral secara bersamaan. Meskipun penelitian tersebut difokuskan pada citra hyperspektral, pendekatan serupa dapat diadopsi dalam klasifikasi citra uang kertas, terutama untuk menangkap detail spasial halus dan perbedaan warna pada berbagai jenis uang. Kombinasi CNN dalam dua dimensi dan tiga dimensi menunjukkan bahwa pengolahan fitur yang lebih kompleks dapat memberikan hasil klasifikasi yang lebih akurat dalam berbagai domain visual.

Setelah melewati beberapa lapisan konvolusi dan pooling, model kemudian menggunakan lapisan Lapisan Flatten berperan penting dalam proses klasifikasi uang kertas dengan CNN, yaitu dengan mengubah tensor multidimensi hasil ekstraksi fitur menjadi vektor satu dimensi. Proses ini diperlukan agar fitur visual yang telah dipelajari oleh lapisan konvolusi dapat diteruskan ke lapisan Dense (*Fully Connected Layer*), yang bertugas untuk melakukan klasifikasi berdasarkan pola-pola yang dikenali. Lapisan Dense pertama menggunakan fungsi aktivasi ReLU guna memperkuat proses pembelajaran terhadap fitur kompleks pada gambar uang kertas. Untuk meningkatkan kemampuan generalisasi dan mencegah *overfitting*, diterapkan lapisan Dropout setelah Dense layer, yang secara acak menonaktifkan sejumlah neuron selama pelatihan. Teknik ini sejalan dengan pendekatan yang digunakan dalam penelitian sebelumnya pada bidang biometrik, di mana struktur CNN yang padat dan kompleks dioptimalkan menggunakan algoritma genetika untuk mendeteksi keaslian sidik jari. Studi tersebut menunjukkan bahwa arsitektur CNN yang efisien dan pengaturan hyperparameter yang tepat dapat meningkatkan performa klasifikasi pada data citra, termasuk pada tugas-tugas seperti klasifikasi uang kertas.

Selanjutnya, model dilengkapi dengan lapisan Dense terakhir yang berisi sejumlah neuron sesuai dengan jumlah kelas yang ingin diklasifikasikan. Fungsi aktivasi yang digunakan pada lapisan ini adalah Softmax, yang berfungsi untuk mengubah output menjadi probabilitas dari masing-masing kelas, sehingga model dapat menentukan prediksi dengan nilai probabilitas yang sesuai. Dengan arsitektur ini, model CNN yang dikembangkan dalam penelitian ini diharapkan mampu melakukan klasifikasi citra dengan akurasi yang tinggi, serta memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya. Ke dalam ruang kelas yang spesifik. Fungsi aktivasi yang digunakan pada lapisan ini adalah **Softmax**, yang merupakan fungsi aktivasi standar dalam masalah klasifikasi multikelas. Fungsi ini mengubah output dari neuron-neuron terakhir menjadi nilai probabilitas, di mana setiap nilai menunjukkan kemungkinan bahwa input citra termasuk ke dalam masing-masing kelas. Output dari fungsi Softmax selalu berjumlah 1 jika dijumlahkan, sehingga memudahkan model dalam menentukan keputusan prediksi akhir berdasarkan probabilitas tertinggi.

Penggunaan Softmax sangat krusial karena memungkinkan interpretasi yang jelas terhadap hasil klasifikasi. Misalnya, jika model memberikan output [0.05, 0.90, 0.05] untuk tiga kelas berbeda, maka jelas terlihat bahwa model sangat yakin bahwa input termasuk dalam kelas kedua. Probabilitas ini tidak hanya berguna untuk pengambilan keputusan, tetapi juga dapat digunakan dalam proses evaluasi lebih lanjut seperti perhitungan metrik **cross-entropy loss**, **confidence score**, dan analisis **uncertainty**.

Untuk mencapai tujuan tersebut, berbagai teknik seperti **regularisasi**, **dropout**, dan **normalisasi batch** juga dapat diterapkan untuk meningkatkan kinerja generalisasi model. Dengan demikian, sistem klasifikasi berbasis CNN ini diharapkan tidak hanya berhasil dalam lingkungan laboratorium yang terkontrol, tetapi juga tetap andal dan akurat saat diimplementasikan dalam kondisi nyata yang lebih kompleks dan penuh variasi. Tabel yang menunjukkan detail arsitektur model dapat dilihat pada [table 1](#)

Table 1 Detail Arsitektur Model

No	Layer	Output Shape	Jumlah Parameter
1	Conv2D (16 filters, 3×3)	(148, 148, 16)	448
2	MaxPooling2D (2×2)	(74, 74, 16)	0
3	Conv2D (32 filters, 3×3)	(72, 72, 32)	4,640


4	MaxPooling2D (2×2)	(36, 36, 32)	0
5	Conv2D (64 filters, 3×3)	(34, 34, 64)	18,496
6	MaxPooling2D (2×2)	(17, 17, 64)	0
7	Flatten	(18496)	0
8	Dense (200 neurons, ReLU)	(200)	3,699,400
9	Dropout (30%)	(200)	0
10	Dense (500 neurons, ReLU)	(500)	100,500
11	Dropout (50%)	(500)	0
12	Dense (2 neurons, Softmax)	(2)	1,002

Tabel di atas menyajikan rincian arsitektur model Convolutional Neural Network (CNN) yang dirancang dan digunakan dalam penelitian ini untuk melakukan klasifikasi citra uang kertas. Model terdiri dari tiga lapisan konvolusi berturut-turut dengan jumlah filter yang meningkat (16, 32, dan 64) dan ukuran kernel 3×3, yang bertujuan untuk mengekstraksi fitur spasial penting dari citra input. Setiap lapisan konvolusi diikuti oleh lapisan MaxPooling2D dengan ukuran 2×2 untuk mengurangi dimensi fitur dan mencegah overfitting dengan menyaring informasi yang paling relevan. Setelah proses ekstraksi fitur selesai, data diratakan menggunakan lapisan Flatten sebelum diteruskan ke beberapa lapisan Dense (fully connected) yang berfungsi untuk proses klasifikasi.

Lapisan Dense pertama memiliki 200 neuron dan diikuti oleh dropout sebesar 30%, sedangkan Dense kedua memiliki 500 neuron dengan dropout sebesar 50%. Dropout digunakan untuk meningkatkan generalisasi model dan mencegah overfitting selama pelatihan. Lapisan output terdiri dari dua neuron dengan fungsi aktivasi Softmax, yang berfungsi untuk menghasilkan probabilitas dari masing-masing kelas target. Jumlah parameter pada setiap lapisan juga dicantumkan untuk menggambarkan kompleksitas dan kapasitas pembelajaran dari setiap bagian model.

Arsitektur ini secara keseluruhan dirancang untuk mencapai keseimbangan antara akurasi klasifikasi yang tinggi dan efisiensi komputasi, sehingga dapat diterapkan secara efektif dalam sistem klasifikasi uang kertas berbasis deep learning.

Pada penelitian ini, dilakukan proses pelatihan model dengan menggunakan dataset yang telah melalui tahap preprocessing untuk memastikan kualitas data yang optimal. Evaluasi performa model dilakukan dengan mengukur akurasi dan loss pada data pelatihan serta validasi guna menilai sejauh mana model mampu mengenali pola dan melakukan generalisasi terhadap data baru. Hasil dari evaluasi ini ditampilkan dalam bentuk grafik yang menunjukkan perubahan nilai akurasi dan loss seiring bertambahnya jumlah epoch selama pelatihan. Grafik yang menggambarkan perbandingan antara data pelatihan dan validasi dapat dilihat pada Gambar 2 di bawah ini.



Gambar 4 Grafik Akurasi Selama Proses Training Dan Validation

Pada grafik di atas, terlihat bahwa akurasi model mencapai 100% pada epoch ke-13. Hal ini menunjukkan bahwa model mampu mengklasifikasikan data dengan sangat baik tanpa mengalami overfitting, karena akurasi pada data validasi juga mencapai 100%. Selain itu, nilai loss terus menurun hingga mencapai titik terendah, menunjukkan bahwa model belajar secara efektif dan akurat dalam mengenali pola pada data pelatihan.

KESIMPULAN

Berdasarkan penelitian yang telah dilakukan, dapat disimpulkan bahwa model Convolutional Neural Network (CNN) yang dikembangkan mampu melakukan klasifikasi nominal uang kertas dengan tingkat akurasi yang sangat tinggi. Arsitektur model yang dibangun terdiri dari beberapa lapisan konvolusi dan pooling, dilengkapi dengan lapisan Dense dan Dropout untuk meningkatkan kemampuan klasifikasi sekaligus mengurangi risiko overfitting.

Pada proses pelatihan, model CNN berhasil mencapai akurasi 100% pada epoch ke-13, baik pada data pelatihan maupun validasi. Hal ini menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam mengenali pola visual secara akurat. Selain itu, nilai loss yang terus mengalami penurunan hingga mencapai titik terendah menggambarkan bahwa model mampu belajar secara optimal tanpa mengalami overfitting.

Hasil prediksi menunjukkan bahwa model dapat mengidentifikasi gambar uang kertas dengan tingkat kepercayaan yang tinggi, sehingga membuktikan bahwa model memiliki kemampuan generalisasi yang baik terhadap data baru. Keberhasilan pengembangan model ini dapat menjadi landasan bagi pembuatan aplikasi pengenalan uang berbasis citra, baik untuk mendukung sistem pembayaran digital maupun aplikasi edukasi terkait pengenalan mata uang. Meskipun demikian, pengujian lebih lanjut perlu dilakukan dengan mempertimbangkan berbagai variasi gambar dan kondisi pencahayaan yang lebih beragam agar model lebih andal dalam berbagai situasi nyata.

DAFTAR PUSTAKA

- Ariawan, I. (2022). Klasifikasi Tiga Genus Ikan Karang Menggunakan Convolution Neural Network. *Jurnal Ilmu Dan Teknologi Kelautan Tropis*, 14(2), 205–216. <https://doi.org/10.29244/jitkt.v14i2.33633>
- Fan, C., Chen, M., Wang, X., Wang, J., & Huang, B. (2021). A Review on Data Preprocessing Techniques Toward Efficient and Reliable Knowledge Discovery From Building Operational Data. *Frontiers in Energy Research*, 9(March), 1–17. <https://doi.org/10.3389/fenrg.2021.652801>
- Fonda, H. (2020). Klasifikasi Batik Riau Dengan Menggunakan Convolutional Neural Networks (Cnn). *Jurnal Ilmu Komputer*, 9(1), 7–10. <https://doi.org/10.33060/jik/2020/vol9.iss1.144>
- Ghaderizadeh, S., Abbasi-Moghadam, D., Sharifi, A., Zhao, N., & Tariq, A. (2021). Hyperspectral Image Classification Using a Hybrid 3D-2D Convolutional Neural Networks. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 7570–7588. <https://doi.org/10.1109/JSTARS.2021.3099118>
- Liu, C., Dong, Y., Xiang, W., Yang, X., Su, H., Zhu, J., Chen, Y., He, Y., Xue, H., & Zheng, S. (2024). A Comprehensive Study on Robustness of Image Classification Models: Benchmarking and Rethinking. *International Journal of Computer Vision*. <https://doi.org/10.1007/s11263-024-02196-3>
- Maharani, D., Septyana, D., Elizabeth, C., Pramudhita, S., & Sari, A. P. (n.d.). *Journal of Multidisciplinary Inquiry in Science Technology and Educational Research Analisis Perbandingan Klasifikasi Obesitas Menggunakan Metode K-Nearest Neighbor dan Ensemble Learning*.
- Malik Ibrahim, 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>
- Mohammad Soeharto, Mohammad Jeky Hasan, Ahmad Rega Susanto, & Dimas Ahmad Fahrezi. (2024). Mengklasifikasi Mata Uang Lima Ribu Rupiah dan Dua Ribu Rupiah dengan Menggunakan Algoritma CNN. *SABER : Jurnal Teknik Informatika, Sains Dan Ilmu Komunikasi*, 2(3), 163–170. <https://doi.org/10.59841/saber.v2i3.1407>
- Nur Hidayat, A. M., 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>
- Pinto Neto, E. C., Baum, D. M., Almeida, J. R. de, Camargo, J. B., & Cugnasca, P. S. (2023). Deep Learning in Air Traffic Management (ATM): A Survey on Applications, Opportunities, and Open Challenges. *Aerospace*, 10(4). <https://doi.org/10.3390/aerospace10040358>
- Purwono, Ma'arif, A., Rahmانيar, W., Fathurrahman, H. I. K., Frisky, A. Z. K., & Haq, Q. M. U. (2022). Understanding of Convolutional Neural Network (CNN): A Review. *International Journal of Robotics and Control Systems*, 2(4), 739–748. <https://doi.org/10.31763/ijrcs.v2i4.888>
- Putri Ayuni, D., Jasril, Irsyad, M., Yanto, F., & Sanjaya, S. (2023). Augmentasi Data Pada Implementasi Convolutional Neural Network Arsitektur Efficientnet-B3 Untuk Klasifikasi Penyakit Daun Padi. *ZONAsi: Jurnal Sistem Informasi*, 5(2), 239–249. <https://doi.org/10.31849/zn.v5i2.13874>
- 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>