

BAB I PENDAHULUAN

A. Latar Belakang

Transaksi digital di Indonesia mengalami peningkatan yang signifikan dalam beberapa tahun terakhir. Di sisi lain, uang kertas Rupiah tetap menjadi salah satu alat pembayaran utama yang masih digunakan secara luas dalam aktivitas ekonomi masyarakat. Data Bank Indonesia menunjukkan bahwa jumlah uang beredar dalam arti luas (M2) mencapai Rp10.133,1 triliun pada Desember 2025 dengan pertumbuhan tahunan sebesar 9,6%[1]. Hal ini menunjukkan bahwa penggunaan uang tunai masih memegang peranan penting dalam sistem perekonomian nasional. Saat ini terdapat tujuh denominasi uang kertas Rupiah yang beredar, yaitu Rp1.000, Rp2.000, Rp5.000, Rp10.000, Rp20.000, Rp50.000, dan Rp100.000, setiap nominal memiliki karakteristik visual yang berbeda seperti warna dominan, gambar pahlawan nasional, motif batik, serta elemen pengaman khusus.

Pada tahun 2022, Bank Indonesia meluncurkan uang kertas Rupiah Tahun Emisi (TE) 2022 dengan berbagai penyempurnaan desain dan teknologi keamanan, termasuk penggunaan *microlenses* pada benang pengaman, *Optically Variable Magnetic Ink* (OVMI), serta peningkatan kualitas bahan uang [2]. Kompleksitas elemen visual tersebut menghasilkan karakteristik citra yang beragam pada setiap denominasi. Variasi warna dominan, pola, ilustrasi pahlawan nasional, serta detail keamanan pada setiap denominasi menjadikan uang kertas Rupiah sebagai objek yang relevan untuk menguji dan membandingkan kemampuan model *deep learning* dalam mengenali dan membedakan kategori citra secara otomatis. Kondisi ini menuntut adanya metode klasifikasi citra yang mampu mengekstraksi dan membedakan fitur-fitur tersebut secara akurat dan konsisten, pendekatan berbasis *Convolutional Neural Network* (CNN) telah terbukti efektif dalam melakukan ekstraksi fitur hierarkis dan meningkatkan performa klasifikasi citra pada berbagai domain visual [3], [4].

Perkembangan teknologi *Computer Vision* dan *Deep Learning* memberikan peluang besar dalam menyelesaikan permasalahan klasifikasi citra secara otomatis. Salah satu pendekatan yang dominan digunakan adalah *Convolutional Neural Network* (CNN), yang mampu mengekstraksi fitur visual secara hierarkis mulai dari fitur tingkat rendah seperti tepi dan tekstur hingga fitur tingkat tinggi seperti bentuk dan pola kompleks. Kemampuan ini menjadikan CNN efektif dalam berbagai tugas klasifikasi citra, termasuk objek dengan karakteristik visual yang kompleks. CNN telah menunjukkan performa klasifikasi yang tinggi dan konsisten pada berbagai domain citra[5].

Pengembangan model CNN untuk mengklasifikasi citra, memiliki dua pendekatan utama yang umum digunakan, yaitu membangun arsitektur CNN secara *custom* dari awal (*from scratch*) dan menggunakan teknik *transfer learning*. Pendekatan CNN yang dibangun dari awal memberikan fleksibilitas dalam perancangan arsitektur karena peneliti dapat menentukan jumlah lapisan, ukuran kernel, fungsi aktivasi, serta parameter pelatihan lainnya. Beberapa penelitian menunjukkan bahwa arsitektur CNN yang dibangun secara *custom* mampu menghasilkan performa yang baik dalam klasifikasi citra, terutama ketika arsitektur disesuaikan dengan karakteristik dataset yang digunakan. Namun di balik fleksibilitas tersebut, pelatihan model dari awal umumnya memerlukan jumlah data yang relatif besar dan waktu komputasi yang lebih lama, serta berpotensi mengalami *overfitting* apabila dataset yang tersedia terbatas[4]. Beberapa penelitian menunjukkan bahwa arsitektur *Convolutional Neural Network* (CNN) yang dibangun secara *custom* mampu menghasilkan performa yang baik dalam klasifikasi citra. Penelitian oleh Akbar *et al.* [6] menunjukkan bahwa model CNN sederhana mampu mencapai akurasi sebesar 90,6% dalam klasifikasi ekspresi wajah meskipun menggunakan dataset berukuran kecil yaitu 213 citra. Selain itu, penelitian oleh Nurtiwi *et al.* [7] yang mengkaji klasifikasi citra wajah berdasarkan kelompok usia menggunakan lebih dari 33.000 citra menunjukkan bahwa model CNN mampu mencapai akurasi sebesar 78,5% dengan pembagian data sebanyak 23.440 citra sebagai data *training* dan 10.046 citra sebagai data *testing* . Hasil tersebut menunjukkan bahwa CNN memiliki kemampuan yang baik dalam mengekstraksi fitur visual dari citra wajah serta mengelompokkan data ke dalam kategori usia secara efektif.

Sebagai alternatif dari pendekatan pelatihan dari awal (*from scratch*), teknik *transfer learning* menawarkan solusi yang lebih efisien, khususnya ketika dataset yang tersedia terbatas. *Transfer learning* bekerja dengan memanfaatkan model yang telah dilatih sebelumnya pada dataset berskala besar, sehingga model tersebut sudah memiliki kemampuan mengenali berbagai fitur visual umum seperti tepi, tekstur, dan pola bentuk objek. Kemampuan inilah yang dimaksud dengan representasi fitur yang lebih matang, yaitu model tidak perlu membangun kemampuan pengenalan fitur dari nol, melainkan langsung dapat menyesuaikan diri dengan dataset baru secara lebih efisien. Salah satu arsitektur yang banyak digunakan dalam pendekatan ini adalah MobileNetV2, yang dikenal sebagai CNN ringan dengan jumlah parameter yang efisien namun tetap mampu menghasilkan performa klasifikasi yang kompetitif.

Penelitian oleh Syakuroh *et al.* [8] pada klasifikasi citra X-ray paru-paru menunjukkan bahwa MobileNetV2 mampu mencapai akurasi sebesar 99,42% dengan *precision* 98,87%, *recall* 98,88%, dan *F1-score* 98,86%. Selanjutnya, Hartono dan Muslikh [9] dalam studi klasifikasi 20 jenis buah menggunakan 4.000 citra melaporkan bahwa MobileNetV2 mencapai akurasi sebesar 94% dengan rata-

rata *precision*, *recall*, dan *F1-score* pada rentang 0,93–0,94. Pada penelitian identifikasi tumor otak berbasis citra MRI dengan 20.000 data, Somoal dan Dzikirollah [10] menunjukkan bahwa pendekatan *transfer learning* MobileNetV2 menghasilkan akurasi 98%, *precision* 98%, *recall* 97,75%, dan *F1-score* 97,75%.

Meskipun berbagai penelitian telah menerapkan CNN maupun *transfer learning* dalam berbagai tugas klasifikasi citra, kajian yang secara khusus membandingkan performa antara arsitektur CNN *custom* dan pendekatan *transfer learning* berbasis MobileNetV2 pada klasifikasi citra uang kertas Rupiah Tahun Emisi 2022 masih terbatas. Padahal, penentuan arsitektur model yang tepat merupakan langkah penting dalam pengembangan model klasifikasi citra, terutama jika mempertimbangkan keterbatasan sumber daya komputasi. Tanpa adanya analisis komparatif yang mendalam mengenai keseimbangan antara akurasi, ukuran model, dan kecepatan komputasi (*inference time*), sulit untuk menentukan pendekatan yang paling efisien dalam menangani karakteristik visual uang Rupiah yang kompleks.

Berdasarkan perbedaan tersebut, penelitian ini bertujuan untuk membandingkan performa antara arsitektur *Convolutional Neural Network custom* dan MobileNetV2 berbasis *Transfer Learning* dalam mengklasifikasi citra uang kertas Rupiah Tahun Emisi 2022. Evaluasi dilakukan dengan mengukur akurasi, *precision*, *recall*, *F1-score*, ukuran model, serta kecepatan inferensi guna memperoleh rekomendasi pendekatan yang lebih optimal dan efisien. Secara ilmiah, penelitian ini diharapkan dapat memberikan kontribusi berupa evaluasi komprehensif terhadap efektivitas dua pendekatan arsitektur CNN pada domain klasifikasi uang kertas Rupiah serta menjadi referensi bagi penelitian lanjutan dalam bidang klasifikasi citra berbasis *deep learning*. Hingga saat ini, kajian yang secara khusus membandingkan CNN *Custom* dan MobileNetV2 pada citra uang kertas Rupiah TE 2022 dengan turut mempertimbangkan efisiensi komputasi masih sangat terbatas. Oleh karena itu, penelitian ini penting dilakukan untuk mengisi kekosongan tersebut sekaligus menghasilkan rekomendasi yang dapat dijadikan pijakan bagi pengembang dalam memilih pendekatan yang paling tepat saat merancang sistem klasifikasi citra uang kertas ke depannya.

B. Rumusan Masalah

Rumusan masalah pada penelitian ini sebagai berikut :

1. Bagaimana membangun model klasifikasi citra uang kertas Rupiah Tahun Emisi 2022 menggunakan arsitektur Convolutional Neural Network (CNN) Custom dan MobileNetV2 berbasis *Transfer Learning*?
2. Bagaimana hasil analisis perbandingan performa model CNN Custom dan MobileNetV2 berbasis *Transfer Learning* dalam klasifikasi citra uang

kertas Rupiah Tahun Emisi 2022 berdasarkan metrik *accuracy*, *precision*, *recall*, *F1-score*, ukuran model, dan waktu inferensi?

C. Batasan Masalah

Batasan masalah membahas mengenai :

1. Penelitian difokuskan pada klasifikasi citra uang kertas Rupiah Tahun Emisi (TE) 2022 untuk tujuh denominasi yang beredar.
2. Metode yang dibandingkan terbatas pada dua pendekatan, yaitu algoritma CNN *custom (from scratch)* dan MobileNetV2 dengan pendekatan *transfer learning*.
3. Evaluasi performa model dibatasi pada metrik akurasi, *precision*, *recall*, *F1-score*, ukuran model, dan kecepatan inferensi.
4. Penelitian ini berfokus pada analisis komparatif performa model dan tidak membahas pengembangan sistem atau aplikasi implementatif.
5. Penelitian dilakukan menggunakan perangkat komputer dengan spesifikasi minimal prosesor Intel Core i3 atau setara, RAM 8 GB, penyimpanan SSD, dan sistem operasi 64-bit.

D. Tujuan Penelitian

Tujuan penelitian yang diinginkan peneliti dalam penelitian yaitu sebagai berikut:

1. Menganalisis dan membandingkan performa arsitektur CNN *custom* dan MobileNetV2 berbasis *Transfer Learning* dalam klasifikasi citra uang kertas Rupiah Tahun Emisi 2022 berdasarkan metrik akurasi, *precision*, *recall*, dan *F1-score*.
2. Mengevaluasi perbedaan kedua pendekatan tersebut yang meliputi ukuran model, dan kecepatan inferensi untuk menentukan model yang lebih optimal.

E. Manfaat Penelitian

1. Manfaat Teoritis

Penelitian ini memberikan kontribusi dalam pengembangan kajian *Deep Learning* dan *Computer Vision*, khususnya terkait analisis komparatif performa antara arsitektur CNN *custom* dan MobileNetV2 berbasis *Transfer Learning* pada tugas klasifikasi citra. Hasil penelitian ini memperkaya referensi ilmiah mengenai perbandingan tingkat akurasi dan efisiensi komputasi kedua pendekatan tersebut, serta dapat menjadi rujukan bagi penelitian lanjutan yang berfokus pada optimasi model jaringan saraf tiruan untuk klasifikasi citra.

2. Manfaat Praktis

a. Bagi Institusi Pendidikan

Menjadi tambahan literatur akademik dalam bidang Kecerdasan Buatan (*Artificial Intelligence*) dan Pengolahan Citra Digital, serta referensi bagi mahasiswa atau peneliti dalam pengembangan penelitian terkait klasifikasi citra berbasis *deep learning*.

b. Bagi Peneliti dan Pengembang

Memberikan gambaran komparatif mengenai performa arsitektur CNN *custom* dan MobileNetV2, sehingga dapat menjadi bahan pertimbangan dalam pemilihan model yang sesuai untuk kebutuhan klasifikasi citra dengan mempertimbangkan aspek akurasi dan efisiensi komputasi.