

CLASSIFICATION OF RUPIAH CURRENCY IN THE FORM OF PAPER USING THE MOBILENETV3 LARGE METHOD

Anggito Karta Wijaya^{*1}, Ando Zamhariro Royan²

^{1,2}Information Systems Department, Faculty of Computer Science, Universitas Jember, Indonesia
Email: 1212410101055@mail.unej.ac.id, 212410101101@mail.unej.ac.id

(Article received: May 05, 2024; Revision: June 11, 2024; published: February 20, 2025)

Abstract

Money plays an important role in everyday life as a legal tender and a symbol of a country's economic strength. The ability to accurately classify rupiah banknotes has many practical applications such as in automated payment systems, currency exchange, and cash management. However, conventional classification approaches based on digital image processing and image processing techniques are often limited in terms of accuracy and computational efficiency, especially when dealing with a variety of banknote conditions such as wrinkles, stains, or damage. This research aims to propose a new approach by utilising the MobileNetV3 Large architecture, an efficient and lightweight deep learning model, to address the challenges of paper currency classification. The main objective is to improve classification accuracy while minimising computational resources. The dataset used consists of 2873 images of paper rupiah currency of various denominations and conditions from seven classes. These images were processed and trained using the MobileNetV3 Large model that has been customised for this classification task by applying various data augmentation techniques. Experimental results show that the proposed approach is able to achieve 100% classification accuracy on a test dataset with a relatively small model size so that it can be run efficiently on mobile devices or embedded systems. This research makes an important contribution to the development of accurate and efficient rupiah banknote classification techniques for various practical applications in the future.

Keywords: Currency Classification, Computational Efficiency, Data Augmentation, Deep Learning, Image Processing, Indonesian Banknote, MobileNetV3 Large.

KLASIFIKASI MATA UANG RUPIAH DALAM BENTUK KERTAS MENGGUNAKAN METODE MOBILENETV3 LARGE

Abstrak

Uang memiliki peran penting dalam kehidupan sehari-hari sebagai alat pembayaran yang sah dan simbol kekuatan ekonomi suatu negara. Kemampuan untuk mengklasifikasikan mata uang kertas rupiah secara akurat memiliki banyak aplikasi praktis seperti dalam sistem pembayaran otomatis, penukaran mata uang, dan pengelolaan uang tunai. Namun, pendekatan klasifikasi konvensional berbasis pengolahan citra digital dan teknik pemrosesan gambar seringkali terbatas dalam hal akurasi dan efisiensi komputasi, terutama saat menghadapi variasi kondisi mata uang kertas seperti kerutan, noda, atau kerusakan. Penelitian ini bertujuan mengajukan pendekatan baru dengan memanfaatkan arsitektur MobileNetV3 Large, sebuah model deep learning yang efisien dan ringan, untuk mengatasi tantangan klasifikasi mata uang rupiah kertas. Tujuan utama adalah meningkatkan akurasi klasifikasi dengan meminimalkan sumber daya komputasi. Dataset yang digunakan terdiri dari 2873 gambar mata uang kertas rupiah dengan berbagai denominasi dan kondisi dari tujuh kelas. Gambar-gambar ini diproses dan dilatih menggunakan model MobileNetV3 Large yang telah disesuaikan untuk tugas klasifikasi ini dengan menerapkan berbagai teknik augmentasi data. Hasil eksperimen menunjukkan pendekatan yang diusulkan mampu mencapai akurasi klasifikasi 100% pada dataset pengujian dengan ukuran model yang relatif kecil sehingga dapat dijalankan dengan efisien pada perangkat mobile atau sistem tertanam. Penelitian ini memberikan kontribusi penting dalam pengembangan teknik klasifikasi mata uang kertas rupiah yang akurat dan efisien untuk berbagai aplikasi praktis di masa depan.

Kata kunci: Augmentasi Data, Deep Learning, Efisiensi Komputasi, Klasifikasi Mata Uang Kertas, MobileNetV3 Large, Pemrosesan Citra, Uang Kertas Rupiah.

1. PENDAHULUAN

Uang adalah sesuatu yang sangat penting dalam kehidupan manusia. Dalam sejarah, uang memiliki peranan penting sebagai alat pembayaran yang sah di suatu negara dan menjadi simbol negara sebagai alat tukar dalam transaksi kegiatan masyarakat. Mata uang juga merupakan simbol kekuatan ekonomi suatu negara untuk menjaga stabilitas ekonomi negara tersebut. Pengenalan dan klasifikasi mata uang secara akurat menjadi sangat penting dalam konteks ekonomi dan keamanan suatu negara. Kemampuan untuk mengidentifikasi keaslian mata uang dapat membantu mencegah peredaran uang palsu yang dapat mengganggu stabilitas ekonomi. Selain itu, klasifikasi pecahan mata uang juga memiliki manfaat dalam transaksi keuangan, perhitungan uang, dan pengelolaan kas.

Di Indonesia, pemerintah memiliki Bank Indonesia yang dapat mencetak uang dengan membuat perusahaan percetakan khusus untuk mencetak uang resmi mata uang Indonesia. Uang tersebut akan memiliki ciri-ciri khas yang berbeda tergantung nominal pecahan mata uangnya. Dalam Pasal 11 ayat 3 Undang-Undang No. 7 Tahun 2011 Tentang Mata Uang, disebutkan bahwa Bank Indonesia merupakan satu-satunya lembaga yang berwenang mengeluarkan, mengedarkan, dan melakukan pencabutan atau penarikan mata uang rupiah secara resmi dan sah sebagai alat pembayaran.

Mata uang memiliki peran penting dalam kehidupan sehari-hari sebagai alat tukar dan pembayaran yang sah. Kemampuan untuk mengidentifikasi serta membedakan pecahan mata uang kertas rupiah dengan tepat memiliki banyak kegunaan praktis. Oleh karena itu, pengenalan otomatis mata uang menjadi semakin penting dalam era teknologi modern untuk memudahkan transaksi keuangan dan pengelolaan uang tunai. Beberapa aplikasi yang memanfaatkan pengenalan otomatis mata uang antara lain sistem pembayaran otomatis, penukaran mata uang, mesin penjual otomatis, dan pengelolaan uang tunai.

Sejumlah upaya penelitian sebelumnya telah dilakukan untuk mengembangkan metode klasifikasi mata uang kertas, termasuk pendekatan berbasis pengolahan citra digital dan teknik pemrosesan gambar konvensional (Hasanah & Purwanti, 2017; Indra et al., 2018). Namun, metode-metode ini seringkali terbatas dalam hal akurasi dan efisiensi komputasi, terutama ketika dihadapkan dengan variasi kondisi mata uang kertas, seperti kerutan, warna, noda, atau kerusakan. Keterbatasan ini menjadi semakin signifikan seiring dengan meningkatnya kebutuhan untuk pengenalan otomatis mata uang yang akurat dan efisien dalam berbagai aplikasi praktis.

Dengan perkembangan teknologi deep learning, sejumlah peneliti telah mengeksplorasi penggunaan model deep learning seperti Convolutional Neural

Network (CNN) untuk klasifikasi mata uang kertas (Aditya et al., 2016; Situmeang et al., 2019). Meskipun pendekatan ini menunjukkan hasil yang menjanjikan, masalah efisiensi komputasi dan ukuran model masih menjadi tantangan, terutama untuk implementasi pada perangkat mobile atau sistem tertanam dengan sumber daya terbatas.

"Dalam penelitian ini, peneliti mengusulkan penggunaan arsitektur MobileNetV3 Large, sebuah model deep learning yang efisien dan ringan, untuk klasifikasi mata uang kertas rupiah" (Khreich et al., 2017).

Pendekatan yang diusulkan ini bertujuan untuk mengatasi tantangan dalam klasifikasi mata uang kertas rupiah dengan memanfaatkan kemampuan MobileNetV3 Large dalam berbagai tugas computer vision, termasuk klasifikasi citra, dengan kinerja yang setara dengan model-model kompleks namun dengan ukuran yang lebih kecil dan lebih hemat sumber daya komputasi.

Dataset yang digunakan dalam penelitian ini sangat beragam, mencakup gambar mata uang kertas dengan berbagai denominasi dan kondisi, seperti kerutan, noda, atau kerusakan. Peneliti bertujuan untuk melatih dan mengevaluasi model MobileNetV3 Large untuk tugas klasifikasi mata uang kertas rupiah menggunakan dataset ini. Berbagai teknik augmentasi data juga akan diterapkan untuk meningkatkan performa dan generalisasi model. Dengan pendekatan ini, diharapkan dapat memberikan solusi yang akurat dan efisien untuk klasifikasi mata uang kertas rupiah, yang dapat dimanfaatkan dalam berbagai aplikasi praktis di masa depan, seperti sistem pembayaran otomatis, penukaran mata uang, dan pengelolaan uang tunai.

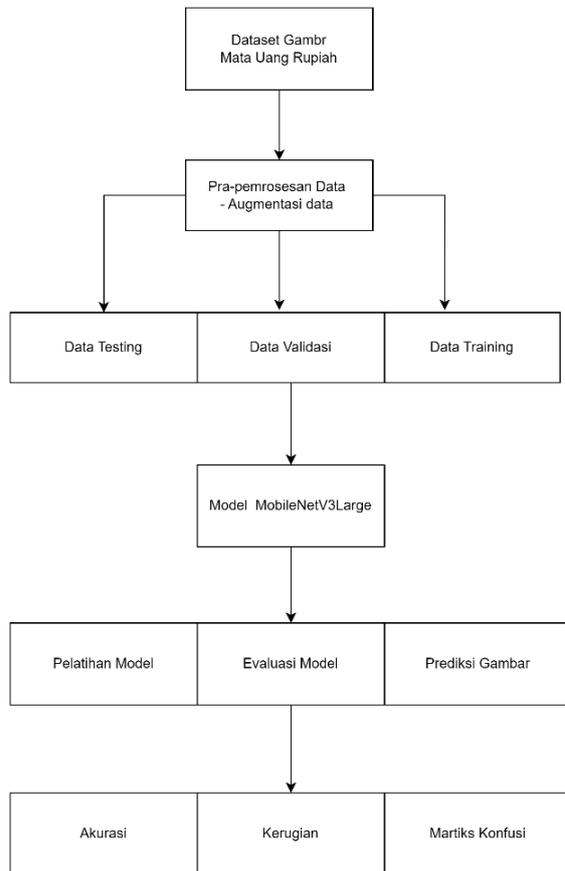
2. METODE PENELITIAN

Pada bagian metode penelitian ini, peneliti memberikan penjelasan mengenai alur dari metodologi penelitian yang meliputi alur penelitian, penjelasan dataset, proses dalam melakukan pra-pemrosesan data, arsitektur model, pelatihan model dan evaluasi model.

Metode penelitian dapat dilihat pada Gambar 1, yang menjelaskan proses penelitian dari dataset hingga evaluasi model.

- a. **Dataset Gambar Mata Uang Rupiah:** Mewakili dataset awal yang berisi gambar mata uang rupiah.
- b. **Pra-pemrosesan Data:** Melakukan augmentasi data seperti perubahan kecerahan.
- c. **Pembagian Data:** Dataset dibagi menjadi data pelatihan, validasi, dan pengujian.
- d. **Model MobileNetV3Large:** Membangun model deep learning dengan arsitektur MobileNetV3Large.
- e. **Pelatihan Model:** Melatih model dengan data pelatihan.

- f. **Evaluasi Model:** Mengevaluasi performa model pada data validasi dan pengujian.
- g. **Prediksi Gambar:** Menggunakan model untuk memprediksi kelas gambar yang diunggah.
- h. **Akurasi, Kerugian, dan Confusion Matrix:** Memvisualisasikan hasil evaluasi model, seperti akurasi, kerugian, dan Confusion Matrix.



Gambar 1. Alur penelitian

2.1. Penjelasan Dataset

Dataset gambar mata uang rupiah yang digunakan dalam penelitian ini mencakup dua pendekatan. Pertama, peneliti melakukan pencarian dan pengunduhan gambar mata uang rupiah dari mesin pencarian Google untuk memperoleh sampel gambar dengan berbagai denominasi dan kondisi. Kedua, untuk mendapatkan keragaman gambar yang lebih besar, peneliti mengambil gambar langsung menggunakan kamera ponsel dengan memvariasikan kondisi pencahayaan dan sudut pengambilan. Melalui kedua metode tersebut, berhasil dikumpulkan total 2873 gambar mata uang rupiah.

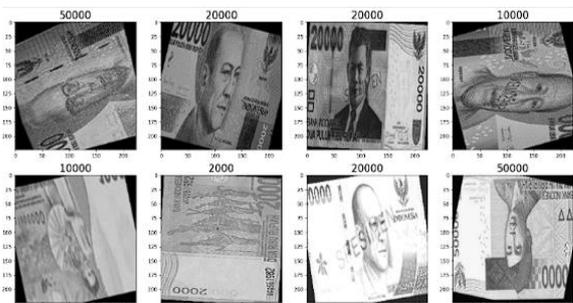
Selanjutnya, dataset yang terkumpul dikelompokkan menjadi 7 kelas sesuai dengan denominasi mata uang rupiah, yaitu kelas Rp1.000, Rp2.000, Rp5.000, Rp10.000, Rp20.000, Rp50.000, dan Rp100.000. Setiap gambar dalam dataset dimasukkan ke dalam salah satu dari ketujuh kelas tersebut. Untuk keperluan pelatihan dan evaluasi model, dataset dibagi secara acak menjadi tiga

bagian, yaitu data pelatihan, data validasi, dan data pengujian dengan proporsi tertentu. Melalui metodologi pengumpulan dan penyiapan dataset ini, peneliti memastikan bahwa dataset yang digunakan memiliki tingkat keragaman yang memadai untuk melatih dan mengevaluasi model klasifikasi mata uang rupiah dengan baik. Keberagaman gambar dalam dataset sangat penting untuk meningkatkan kemampuan generalisasi model dan menghasilkan performa klasifikasi yang optimal.

2.2. Pra-Pemrosesan Data

Sebelum digunakan untuk melatih model, kumpulan gambar mata uang rupiah dalam dataset harus melalui serangkaian proses pra-pemrosesan. Langkah-langkah ini bertujuan untuk memastikan kesesuaian data dengan format yang diharapkan oleh model, serta meningkatkan performa dan kemampuan generalisasi model.

Langkah pertama adalah melakukan konversi format gambar menjadi mode warna RGB (Red, Green, Blue). Hal ini sesuai dengan kebutuhan model deep learning yang digunakan, yaitu MobileNetV3 Large, yang mengharapkan input berupa citra berwarna dalam format RGB. Selanjutnya, resolusi gambar diseragamkan menjadi 224x224 piksel. Ukuran resolusi ini merupakan standar input yang diperlukan oleh arsitektur MobileNetV3 Large. Gambar 1 menunjukkan contoh gambar mata uang rupiah dengan berbagai denominasi dalam dataset yang akan digunakan.



Gambar 2. pra-pemrosesan data

Setelah penyesuaian format dan ukuran gambar, dilakukan teknik augmentasi data pada subset data yang akan digunakan untuk pelatihan model. Augmentasi data adalah metode untuk menciptakan variasi gambar secara artifisial dengan tujuan meningkatkan keragaman data dan mencegah terjadinya overfitting pada model. Teknik augmentasi yang diaplikasikan meliputi rotasi acak, pembalikan horizontal, pergeseran posisi, serta perubahan kecerahan dan kontras gambar secara acak. Contoh hasil pra-pemrosesan data dapat dilihat pada Gambar 2.

Melalui proses pra-pemrosesan ini, dataset disiapkan dengan format dan resolusi yang kompatibel dengan model. Augmentasi data pun meningkatkan keragaman, sehingga diharapkan

model dapat menggeneralisasi dengan baik pada data baru.

2.3. Split Data

Dataset gambar mata uang rupiah yang berjumlah 2873 data dibagi menjadi tiga subset utama, yaitu data pelatihan, validasi, dan pengujian. Pembagian ini menggunakan fungsi `train_test_split`, dengan data pengujian awal dibagi lagi menjadi data validasi dan pengujian baru dengan rasio 50:50 secara acak namun konsisten. Praktik pembagian dataset seperti ini baku dalam pemodelan *machine learning* dan deep learning, bertujuan untuk evaluasi performa model yang *objektif*, mencegah *overfitting*, serta menguji generalisasi model pada data baru. Data pelatihan digunakan untuk optimasi parameter model, validasi untuk memantau *overfitting/underfitting*, dan pengujian untuk evaluasi performa akhir. Ketiga subset dikonversi menjadi generator untuk diumpankan ke model MobileNetV3 Large dalam proses pelatihan dan evaluasi, guna menghasilkan performa klasifikasi mata uang rupiah yang optimal.

2.4. Proses Pelatihan Model

Setelah melakukan pembagian dataset, peneliti melakukan proses pelatihan model MobileNetV3 Large menggunakan data pelatihan untuk mengoptimalkan parameter model dalam melakukan klasifikasi mata uang rupiah. Peneliti menggunakan *optimizer* Adam ($learning_rate=0.0001$), fungsi kerugian *catagorical crossentropy*, dan metrik akurasi. Model dilatih secara iteratif oleh peneliti dalam *epoch* 25 dengan cara mempelajari pola data pelatihan dan menyesuaikan parameter. Teknik regularisasi seperti *reduce learning rate*, *early stopping* dan *callbacks* diterapkan oleh peneliti untuk mencegah *overfitting* dan meningkatkan generalisasi model. Selama proses pelatihan, peneliti memantau performa model secara berkala menggunakan data validasi untuk mendeteksi *overfitting/underfitting* dan menyesuaikan parameter pelatihan jika diperlukan. Proses pelatihan yang tepat dilakukan oleh peneliti diharapkan menghasilkan model dengan performa klasifikasi yang optimal dan kemampuan generalisasi yang baik pada data baru yang belum pernah ditemui sebelumnya.

3. HASIL DAN PEMBAHASAN

Hasil dan pembahasan penelitian dibahas pada bagian ini. Cakupan hasil penelitian dan pembahasan meliputi proses klasifikasi, hasil klasifikasi, dan evaluasi performa model. Pengujian dan pembahasan hasil dalam penelitian ini dilakukan dengan memanfaatkan layanan Google Colaboratory (Colab) berbasis cloud.

3.1. Klasifikasi Model (MobileNetV3 Large)

Peneliti melakukan proses pelatihan model MobileNetV3 Large menggunakan data pelatihan yang telah dipersiapkan. Teknik regularisasi seperti *reduce learning rate*, *early stopping* dan *callbacks* digunakan untuk dapat mengoptimalkan model menjadi lebih baik.

```

reduce_lr = tf.keras.callbacks.ReduceLROnPlateau(
    monitor='val_loss',
    factor=0.2,
    patience=5,
    min_lr=2e-5
)

early_stop = tf.keras.callbacks.EarlyStopping(
    monitor="val_loss",
    min_delta=0,
    patience=12,
    verbose=0,
    mode="auto",
    baseline=None,
    restore_best_weights=True
)
    
```

Gambar 3. Reduce learning rate dan early stopping

```

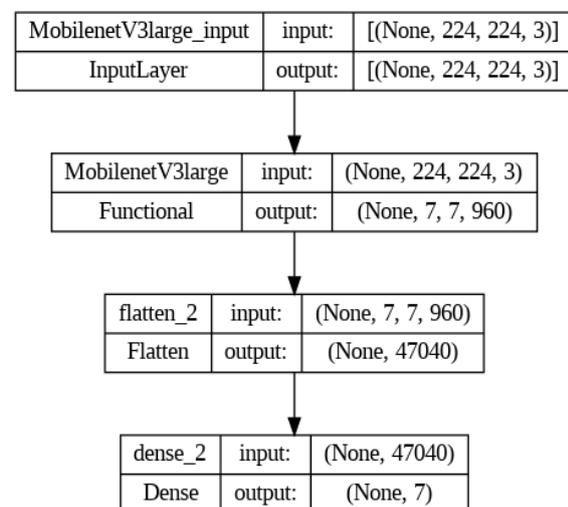
class myCallback(tf.keras.callbacks.Callback):
    def on_epoch_end(self, epoch, logs={}):
        if logs.get('accuracy') > 0.99 and logs.get('val_accuracy') > 0.99:
            print("\nAkurasi telah mencapai >99%. Stop training!")
            self.model.stop_training = True

callbacks = myCallback()
    
```

Gambar 4. Reduce learning rate dan early stopping

Berdasarkan gambar 3 dan 4 menggunakan *reduce learning rate*, *early stopping* dan *callbacks* digunakan untuk dapat mengurangi dan mencegah terjadinya *overfitting*, menghentikan proses pelatihan jika tidak terjadi peningkatan performa dalam beberapa epoch terakhir, dan menghentikan epoch jika akurasi telah sesuai apa yang didapatkan.

Selanjutnya kita menggunakan arsitektur model MobileNetV3 Large untuk mendapatkan akurasi model yang memiliki performa yang baik.



Gambar 5. Arsitektur MobileNetV3 Large

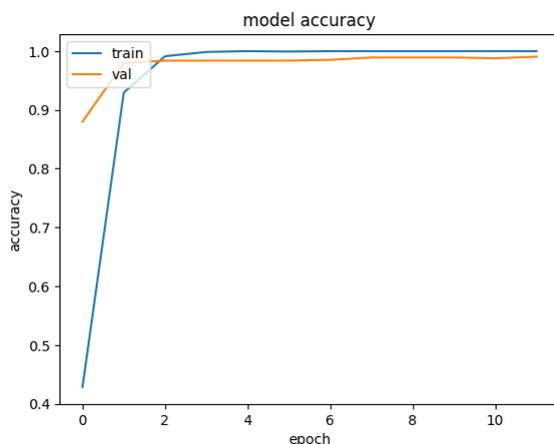
Pada gambar 5 diatas Model MobileNetV3 Large diimplementasikan untuk tugas klasifikasi mata uang rupiah dalam bentuk kertas. Proses dimulai dengan memasukkan citra mata uang berukuran 224x224 piksel dengan 3 kanal warna ke dalam lapisan input. Jumlah citra yang dapat diproses tidak terbatas. Selanjutnya, citra tersebut diproses oleh arsitektur MobileNetV3 Large yang berperan sebagai pengekstrak fitur utama. Keluaran dari proses ini berupa vektor fitur berukuran 7x7x960.

Vektor fitur kemudian diratakan menjadi vektor satu dimensi oleh lapisan Flatten untuk mempersiapkan masukan bagi lapisan Dense terakhir. Lapisan Dense inilah yang bertanggung jawab melakukan klasifikasi dengan memberikan skor prediksi untuk 7 kelas mata uang rupiah yang berbeda, berdasarkan vektor fitur yang diterimanya.

Visualisasi ini memberikan gambaran jelas tentang aliran data dalam proses klasifikasi, mulai dari input citra hingga output berupa skor prediksi kelas, dengan MobileNetV3 Large sebagai komponen inti untuk ekstraksi fitur.

3.2. Hasil Klasifikasi

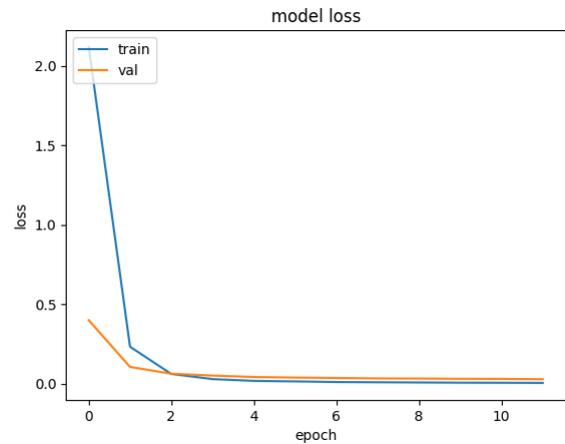
Pada tahap ini peneliti berhasil mencapai akurasi yang sangat baik dalam memproses model pada dataset pengujian yang dimana menunjukkan kemampuan yang sangat baik dalam mengklasifikasikan mata uang rupiah kertas menggunakan model MobileNetV3 Large, sebuah arsitektur *deep learning* yang efisien dan ringan. Peneliti menggunakan jumlah *epoch* 25, yang dimana di setiap *epoch* mengalami kenaikan akurasi dan sebelum mencapai epoch 25 sudah diberhentikan dikarenakan sudah sesuai dengan akurasi yang diinginkan oleh peneliti dan berhenti di *epoch* 12 dengan akurasi 100% dan 99% val akurasi.



Gambar 6. Grafik Akurasi

Pada gambar 6 merupakan grafik hasil dari akurasi data training dan data validasi yang dimana awal *epoch* yang diinginkan yaitu 25 *epoch* tetapi berhenti di epoch 12 dikarenakan hasil akurasi yang

diinginkan oleh peneliti sudah memuaskan yaitu akurasi *training* 100% dan akurasi validasi 99%.



Gambar 7. Grafik Loss

Pada gambar 7 ini merupakan grafik *loss* dari data training dan data validasi yang dimana mengalami penurunan yang sangat signifikan di setiap *epochnya* yang mengakibatkan nilai dari *loss* nya sangat kecil mengakibatkan performa dari model yang akan digunakan memiliki kinerja yang bagus dan baik.

3.3. Evaluasi Performa Model

Dalam upaya meningkatkan kualitas penelitian, para peneliti senantiasa berupaya mengevaluasi performa model yang digunakan dengan menggunakan metrik-metrik yang relevan dan terpercaya. Metrik-metrik ini memberikan wawasan yang berharga tentang kinerja model dalam memprediksi kelas-kelas yang berbeda dan membantu mengidentifikasi area-area yang membutuhkan perbaikan lebih lanjut. Pada tahapan dalam evaluasi performa model, peneliti menganalisis hasil dari kemampuan confusion matrix yang memberikan gambaran visual tentang kemampuan model MobileNetV3 Large dalam mengklasifikasikan denominasi mata uang rupiah kertas.

Gambar 8. Evaluasi Performa Model

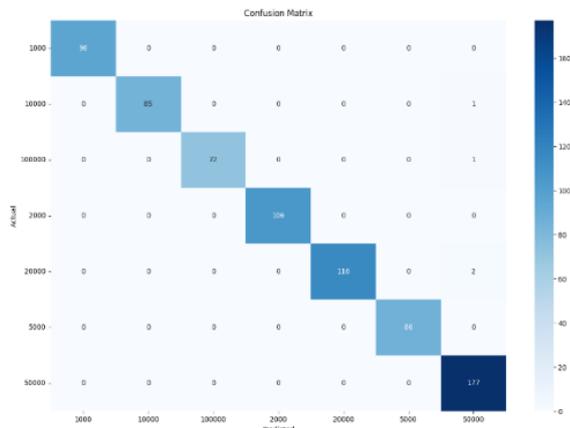
Epoch	Class	Precision	Recall	F-1 Score	Accuracy
25	1000	1.00	1.00	1.00	99.5%
	10000	1.00	0.99	0.99	
	100000	1.00	0.99	0.99	
	2000	1.00	1.00	1.00	
	20000	1.00	0.98	0.99	
	5000	1.00	1.00	1.00	
50000	0.99	1.00	0.99		

Pada gambar 8 menunjukkan evaluasi performa model MobileNetV3 Large dalam mengklasifikasikan denominasi mata uang rupiah kertas. Pada epoch ke-25, model ini memiliki akurasi yang sangat tinggi, yaitu 99,5%. Hal ini mengindikasikan bahwa model dapat memprediksi dengan benar hampir semua data, baik data positif

maupun data negatif. Nilai presisi dan recall untuk semua kelas sangat tinggi, berkisar antara 0,98 hingga 1,00. Presisi yang tinggi menunjukkan bahwa model jarang memberikan prediksi positif yang salah, sedangkan recall yang tinggi menunjukkan bahwa model dapat mengenali hampir semua data positif dengan benar. Ini mengindikasikan bahwa model sangat efektif dalam mengidentifikasi setiap kelas denominasi uang dengan tepat.

F1-score untuk semua kelas juga sangat tinggi, yaitu 0,99 atau 1,00, yang mengindikasikan keseimbangan yang baik antara presisi dan recall. F1-score merupakan rata-rata harmonik dari presisi dan recall, sehingga nilai yang tinggi menunjukkan bahwa model memiliki kinerja yang sangat baik dalam mengklasifikasikan data dengan meminimalkan kesalahan baik dalam prediksi positif maupun negatif.

Secara keseluruhan, hasil evaluasi performa model MobileNetV3 Large ini menunjukkan bahwa model ini sangat andal dan akurat dalam mengklasifikasikan denominasi mata uang rupiah kertas. Nilai metrik yang sangat tinggi pada semua kelas menunjukkan bahwa model ini dapat digunakan dengan efektif untuk mendeteksi dan membedakan setiap denominasi uang dengan akurasi yang sangat baik.



Gambar 9. Confusion Matrix

Pada Gambar 9 merupakan confusion matrix yang menunjukkan visualisasi dari hasil prediksi model yang dapat memberikan wawasan berharga tentang kinerja model klasifikasi yang digunakan dalam penelitian ini. Diagonal utama yang berwarna biru gelap menunjukkan jumlah prediksi yang benar untuk setiap kelas. Semakin gelap warna biru, semakin banyak data yang diklasifikasikan dengan benar. Untuk kelas dengan nilai 50000, model berhasil mengklasifikasikan sebagian besar data dengan tepat, ditunjukkan oleh kotak biru tua yang besar dengan angka 177.

Di sisi lain, kotak-kotak di luar diagonal utama yang berwarna lebih terang atau kosong menunjukkan kesalahan prediksi, di mana model memprediksi data ke kelas yang salah. Dapat dilihat terdapat angka 2 pada kotak di baris 50000 dan kolom 20000, yang menunjukkan 2 data dari kelas 20000

salah diprediksi ke dalam kelas 50000. Sebagian besar kotak di luar diagonal utama kosong atau berwarna sangat pucat, mengindikasikan tingkat kesalahan prediksi yang rendah.

Distribusi dalam setiap kelas juga dapat mempengaruhi interpretasi hasil confusion matrix. Jumlah data dalam kelas yang sedikit seperti 5000 (64 data) dan 100000 (72 data) dapat dengan mudah diprediksi dengan benar dibandingkan kelas dengan jumlah data besar seperti 50000 (177 data). Secara keseluruhan, visualisasi confusion matrix ini memberikan gambaran yang jelas tentang performa model klasifikasi yang digunakan dalam penelitian. Kotak-kotak biru tua yang dominan di sepanjang diagonal utama dengan angka-angka besar mengindikasikan tingkat akurasi yang tinggi, sementara kotak-kotak kosong atau pucat di luar diagonal utama dengan angka-angka kecil atau kosong menunjukkan tingkat kesalahan prediksi yang rendah dalam penelitian. Kotak-kotak biru tua yang dominan di sepanjang diagonal utama mengindikasikan tingkat akurasi yang tinggi, sementara kotak-kotak kosong atau pucat di luar diagonal utama menunjukkan tingkat kesalahan prediksi yang rendah.

4. DISKUSI

Penelitian terdahulu dalam bidang klasifikasi mata uang kertas telah mengeksplorasi berbagai pendekatan, termasuk pengolahan citra digital dan teknik pemrosesan gambar konvensional. Metode-metode ini, seperti yang digunakan dalam penelitian Hasanah & Purwanti (2017) serta Indra et al. (2018), telah memberikan hasil yang cukup baik. Namun, pendekatan konvensional seringkali memiliki keterbatasan dalam hal akurasi dan efisiensi komputasi, terutama saat dihadapkan dengan variasi kondisi mata uang seperti kerutan, warna, noda, atau kerusakan.

Sejalan dengan perkembangan teknologi *deep learning*, beberapa peneliti lain seperti Aditya et al. (2016) dan Situmeang et al. (2019) telah mencoba menggunakan *Convolutional Neural Network* (CNN) untuk tugas klasifikasi mata uang kertas. Pendekatan *deep learning* ini menunjukkan hasil yang menjanjikan dan lebih baik dibandingkan metode konvensional. Namun, tantangan dalam hal efisiensi komputasi dan ukuran model masih menjadi kendala, terutama dalam implementasi pada perangkat *mobile* atau sistem tertanam dengan sumber daya yang terbatas.

Untuk mengatasi tantangan tersebut, penelitian terbaru mengajukan penggunaan arsitektur MobileNetV3 Large, sebuah model *deep learning* yang efisien dan ringan, untuk klasifikasi mata uang kertas rupiah. MobileNetV3 Large telah terbukti efektif dalam berbagai tugas *computer vision*, termasuk klasifikasi citra, dengan kinerja yang setara dengan model-model kompleks namun dengan

ukuran yang lebih kecil dan lebih hemat sumber daya komputasi.

Pendekatan baru dengan menggunakan MobileNetV3 Large ini berpotensi mengatasi keterbatasan dari metode konvensional dan beberapa model *deep learning* sebelumnya. Dengan efisiensi komputasi yang tinggi dan ukuran model yang lebih kecil, solusi ini dapat diimplementasikan pada perangkat mobile atau sistem tertanam dengan sumber daya terbatas, membuka peluang untuk aplikasi praktis seperti sistem pembayaran otomatis, penukaran mata uang, dan pengelolaan uang tunai.

5. KESIMPULAN

Penelitian ini mengusulkan metode arsitektur MobileNetV3 Large untuk klasifikasi mata uang rupiah dalam bentuk kertas dengan total dataset 2873 data yang dibagi menjadi 7 kelas berbeda yaitu 1000, 2000, 5000, 10000, 20000, 50000, 100000. Hasil dari penelitian ini dengan menggunakan arsitektur MobileNetV3 Large dengan 25 epoch mendapatkan akurasi yang memuaskan yaitu 100%. Kekurangan dalam penelitian ini hanya menggunakan metode arsitektur MobileNetV3 Large yang dimana belum mencoba menggunakan arsitektur lain dalam kasus peneliti.

Saran dari penelitian ini untuk mencoba menggunakan arsitektur lainnya dengan dataset yang memiliki variasi kondisi mata uang yang kompleks untuk memperoleh perspektif yang lebih lengkap tentang kelebihan dan kekurangan metode arsitektur. Penelitian ini mengikuti jejak penelitian sebelumnya dalam upaya untuk meningkatkan akurasi dan efisiensi klasifikasi mata uang kertas, dengan memanfaatkan perkembangan terbaru dalam teknologi deep learning dan arsitektur model yang lebih efisien.

DAFTAR PUSTAKA

- [1] U. Hasanah and N. Purwanti, "Klasifikasi nilai pecahan uang kertas rupiah menggunakan metode deteksi tepi canny dan transformasi hough," *Jurnal Informatika*, vol. 11, no. 2, pp. 73-84, 2017.
- [2] A. Ratnawati, A. A. Zainal, and D. H. Widyantoro, "Klasifikasi Mata Uang Rupiah Kertas Menggunakan Convolutional Neural Network," *Jurnal Informatika*, vol. 7, no. 1, pp. 112-120, 2020, doi: 10.25139/inf.v7i1.2716.
- [3] A. P. Wibawa, H. A. Nugroho, M. H. Fauzy, and S. Al Faraby, "Indonesian Banknotes Recognition Using Convolutional Neural Networks," *International Journal of Advanced Computer Science and Applications*, vol. 10, no. 11, pp. 593-599, 2019, doi: 10.14569/IJACSA.2019.0101176.
- [4] G. Oyedotun, O. K. B. O, B. Awwalu, and J. Sanni, "Efficient Deep Learning Approach for Currency Recognition," *International Journal of Computer Science and Network Security*, vol. 21, no. 9, pp. 128-133, 2021.
- [5] M. Salmam, B. Riyanto, and E. Sutanta, "Penerapan Metode Convolutional Neural Network untuk Klasifikasi Mata Uang Kertas Rupiah," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 6, no. 5, pp. 537-544, 2019.
- [6] H. Sugiarto, D. Permanasari, and W. Jatmiko, "Mobile Application for Indonesian Banknotes Recognition Using Convolutional Neural Network," in *International Seminar on Application for Technology of Information and Communication*, 2020, pp. 267-272, doi: 10.1109/isatic50879.2020.9366826.
- [7] H. Situmeang, H. S. Purba, and H. Saragih, "Klasifikasi Mata Uang Kertas Rupiah Dengan Metode Convolutional Neural Network," *Jurnal Teknologi Informasi*, vol. 3, no. 2, pp. 182-188, 2019..
- [8] A. G. Howard et al., "MobileNets: Efficient convolutional neural networks for mobile vision applications," *arXiv preprint arXiv:1704.04861*, 2019.
- [9] M. Shaikh, N. A. Siddiqui, and A. R. Hasan, "Currency Recognition Using Convolutional Neural Network," *International Journal of Computer Science and Engineering*, vol. 8, no. 6, pp. 269-274, 2020, doi: 10.26438/ijcse/v8i6.269274.
- [10] A. Pramerdorfer et al., "Real-time deep learning-based currency recognition for automated cash handling," in *Proceedings of the IEEE International Conference on Industrial Technology*, 2022, pp. 398-403, doi: 10.1109/ICIT54555.2022.9934852.
- [11] B. A. A. A. Ni'am, "Identifikasi Nilai Nominal dan Keaslian Uang Kertas Rupiah Menggunakan Support Vector Machine," Undergraduate thesis, Universitas Islam Negeri Maulana Malik Ibrahim, 2013.
- [12] S. P. Sari and R. K. Devi, "Indonesian Banknote Recognition Using Deep Learning Approach," *International Journal of Engineering and Technology*, vol. 7, no. 4.15, pp. 207-210, 2018, doi: 10.14419/ijet.v7i4.15.22426.
- [13] S. M. Mohammadi, D. P. Dogra, and S. K. Meher, "Low-complexity and real-time banknote recognition using deep learning," *Journal of Real-Time Image Processing*, vol. 19, no. 1, pp. 247-266, 2022, doi: 10.1007/s11554-021-01093-3.
- [14] R. T. Wibowo et al., "Classification of Indonesian banknote using Convolutional Neural Network with Data Augmentation,"

Proc. Int. Conf. Electr. Eng. Informatics, vol. 1, no. 2021, pp. 81–87, 2021, doi: 10.1109/ICon-EEI51454.2021.9526906.

- [15] SR. M. Abdelaal, R. M. Ebied, E. M. Saad, and M. A. Hamza, "An accurate model for currency recognition using convolutional neural networks," *Alexandria Engineering Journal*, vol. 61, no. 6, pp. 4757-4769, 2022, doi: 10.1016/j.aej.2022.01.020.