

IMAGE CLASSIFICATION OF HOUSEHOLD BENEFICIARIES OF DIRECT CASH ASSISTANCE USING EFFICIENTNET IN DKI JAKARTA PROVINCE

Dzikri Adam Insani^{*1}, Hadi Santoso²

^{1,2}Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Mercu Buana, Indonesia
Email: ¹41520010063@student.mercubuana.ac.id, ²hadi.santoso@mercubuana.ac.id

(Article received: May 22, 2024; Revision: June 19, 2024; published: August 30, 2024)

Abstract

This study investigates the application of the EfficientNet architecture for image classification to determine eligible recipients of direct cash assistance among households in Jakarta Province. As government efforts to provide aid to citizens increase, it becomes essential to have a system that can accurately recognize and classify eligible populations. Misallocation of aid remains a prevalent issue, often leading to undeserving individuals receiving assistance, which has detrimental consequences. The primary focus is on leveraging deep learning, specifically EfficientNet, to address these challenges. The dataset used consists of house images categorized into two classes: "Mampu" and "Tidak Mampu," which were collected through personal photography and web scraping from Google. The research aims to develop an algorithm that accurately classifies and analyzes the types and eligibility of residential buildings within the general population. Data collection and processing challenges are addressed to ensure the training of high-quality, representative image datasets. The model has demonstrated a high accuracy rate of approximately 95.03% on the validation data.

Keywords: Deep learning, EfficientNet, government aid, image classification, Jakarta Province, media bias.

KLASIFIKASI RUMAH WARGA PENERIMA BANTUAN TUNAI LANGSUNG MENGGUNAKAN EFFICIENTNET DI PROVINSI DKI JAKARTA

Abstrak

Studi ini menyelidiki penerapan arsitektur EfficientNet untuk klasifikasi gambar guna menentukan penerima yang layak mendapatkan bantuan tunai langsung di antara rumah tangga di Provinsi DKI Jakarta. Seiring dengan meningkatnya upaya pemerintah untuk memberikan bantuan kepada warga, sangat penting memiliki sistem yang dapat mengenali dan mengklasifikasikan populasi yang memenuhi syarat dengan akurat. Salah alokasi bantuan tetap menjadi masalah yang sering terjadi, sering kali mengakibatkan individu yang tidak layak menerima bantuan, yang berdampak merugikan. Fokus utama penelitian ini adalah memanfaatkan pembelajaran mendalam, khususnya EfficientNet, untuk mengatasi tantangan ini. Dataset yang digunakan terdiri dari gambar rumah yang dikategorikan menjadi dua kelas: "Mampu" dan "Tidak Mampu," yang dikumpulkan melalui fotografi pribadi dan scraping gambar dari Google. Penelitian ini bertujuan mengembangkan algoritma yang mampu mengklasifikasikan dan menganalisis jenis dan kelayakan bangunan tempat tinggal dalam populasi umum dengan akurat. Tantangan terkait pengumpulan dan pemrosesan data diatasi untuk memastikan pelatihan dataset gambar yang berkualitas tinggi dan representatif. Model ini telah menunjukkan tingkat akurasi tinggi sekitar 95,03% pada data validasi.

Kata kunci: Deep learning, EfficientNet, government aid, image classification, Jakarta Province, media bias.

1. PENDAHULUAN

Penelitian ini merupakan sebuah upaya yang mengkaji secara mendalam tentang penerapan arsitektur EfficientNet. Latar belakang penelitian ini muncul dari kebutuhan yang mendesak akan alokasi bantuan yang tepat guna tujuan menghindari kemungkinan penyalahgunaan bantuan yang dapat berpotensi merugikan masyarakat secara fatal. Terdapat kesadaran yang semakin meningkat akan

pentingnya penggunaan teknologi, terutama dalam bidang pembelajaran mendalam, sebagai upaya untuk mengatasi tantangan ini. Tujuan utama dari penelitian ini adalah untuk mengevaluasi potensi EfficientNet dalam mendukung analisis dan pengelolaan dana bantuan yang efektif dan tepat sasaran di Indonesia[1].

Penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam memperbaiki proses

pengelolaan dan distribusi bantuan pemerintah di Indonesia, dengan mengintegrasikan teknologi kecerdasan buatan dalam pengambilan keputusan terkait alokasi sumber daya. Selain itu, hasil penelitian ini juga diharapkan dapat menjadi landasan bagi pengembangan lebih lanjut dalam implementasi solusi teknologi untuk menangani masalah serupa di negara-negara berkembang lainnya. Dengan demikian, penelitian ini tidak hanya memiliki relevansi lokal dalam konteks Indonesia, tetapi juga potensi untuk memberikan dampak yang lebih luas dalam skala global dalam upaya meningkatkan efisiensi dan keadilan dalam distribusi bantuan pemerintah[2].

2. METODE PENELITIAN

2.1. EfficientNet

EfficientNet adalah keluarga model jaringan saraf dalam (neural network) yang dirancang oleh tim riset Google AI untuk melakukan tugas klasifikasi gambar. Efisiensi dan kinerja tinggi dari model ini dicapai melalui pendekatan yang inovatif dalam scaling atau penskalaan jaringan saraf. Salah satu inovasi utama dari EfficientNet adalah penggunaan teknik compound scaling. Teknik ini memungkinkan model untuk meningkatkan dimensi kedalaman, lebar, dan resolusi gambar secara bersamaan dan proporsional berdasarkan suatu formula atau koefisien tertentu.

Compound scaling memastikan bahwa setiap peningkatan skala dilakukan secara seimbang, yang berkontribusi pada efisiensi dan kinerja tinggi model. EfficientNet didasarkan pada model dasar yang disebut EfficientNet-B0, yang kemudian di-scale menjadi beberapa varian dari EfficientNet-B1 hingga EfficientNet-B7, dengan masing-masing varian memiliki ukuran dan kapasitas yang lebih besar. Model dasar ini dioptimalkan menggunakan teknik yang disebut Neural Architecture Search (NAS) yang mencari arsitektur terbaik secara otomatis. Pada (1) berikut adalah rumus compound scaling

$$depth = \alpha\phi, width = \beta\phi, resolution = \gamma\phi \quad (1)$$

Dengan penjelasan:

- α, β, γ adalah koefisien yang ditentukan secara empiris.
- ϕ adalah faktor penskalaan yang mengatur seberapa besar model diperbesar.

Stage i	Operator \mathcal{F}_i	Resolution $\hat{H}_i \times \hat{W}_i$	#Channels \hat{C}_i	#Layers \hat{L}_i
1	Conv3x3	224 × 224	32	1
2	MBConv1, k3x3	112 × 112	16	1
3	MBConv6, k3x3	112 × 112	24	2
4	MBConv6, k5x5	56 × 56	40	2
5	MBConv6, k3x3	28 × 28	80	3
6	MBConv6, k5x5	14 × 14	112	3
7	MBConv6, k5x5	14 × 14	192	4
8	MBConv6, k3x3	7 × 7	320	1
9	Conv1x1 & Pooling & FC	7 × 7	1280	1

Gambar 1 Struktur Blok EfficientNet B0

Setiap model EfficientNet terdiri dari beberapa blok MBConv yang diatur dalam berbagai tahap dengan jumlah filter yang berbeda. Berikut adalah contoh konfigurasi arsitektur EfficientNet-B0 pada Gambar 1.

Penjelasan mengenai struktur blok pada Gambar 1 dimana Blok MBConv terdiri dari beberapa operasi utama

- Depthwise Convolution: Melakukan convolusi terpisah pada setiap saluran (channel) input.
- Pointwise Convolution: Menggabungkan hasil depthwise convolutions menjadi saluran keluaran.
- Expansion Phase: Menggunakan convolusi 1x1 untuk memperluas dimensi input.
- Projection Phase: Menggunakan convolusi 1x1 untuk mengurangi dimensi output.
- Skip Connection: Menghubungkan input langsung ke output jika dimensi cocok.

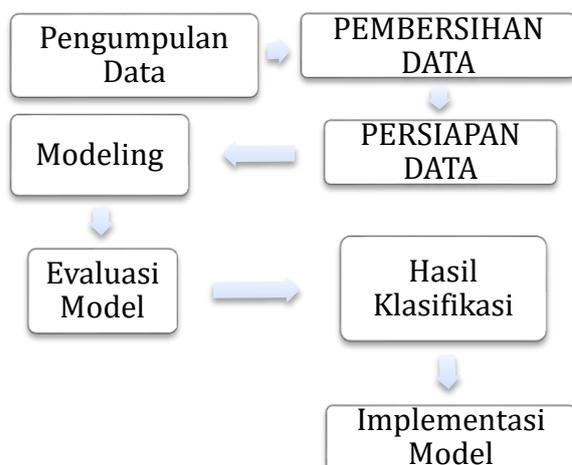
2.2. Jenis Penelitian

Penelitian ini menitikberatkan pada penerapan arsitektur EfficientNet dalam klasifikasi citra. Inspirasi untuk mengeksplorasi topik ini muncul setelah mengamati dampak signifikan penggunaan teknologi dalam pengenalan gambar yang dapat dilakukan menggunakan metode deep learning. Dalam konteks ini, EfficientNet dianggap relevan karena kemampuannya yang efisien dan akurat dalam memproses data citra bangunan, memungkinkan identifikasi dan analisis berbagai jenis bangunan rumah serta kondisinya. Teknologi deep learning, khususnya dalam konteks klasifikasi citra, telah membuka banyak peluang baru dalam berbagai bidang, termasuk pemetaan wilayah, pengawasan lingkungan, dan penilaian properti[3].

Keunggulan EfficientNet dalam mengatasi tantangan klasifikasi citra, seperti variabilitas dalam pencahayaan, skala, dan orientasi, membuatnya menjadi pilihan yang tepat untuk digunakan dalam penelitian ini. Dengan kemampuannya yang efisien, EfficientNet memungkinkan pengolahan data yang cepat dan akurat, yang sangat diperlukan dalam analisis kelayakan bangunan rumah yang melibatkan sejumlah besar data citra[4].

Penelitian ini bersifat kuantitatif, Penelitian kuantitatif adalah suatu pendekatan penelitian yang bertujuan untuk mengumpulkan data yang dapat diukur secara numerik, serta menganalisis data tersebut dengan menggunakan metode statistik. Tujuan utama dari penelitian kuantitatif adalah untuk menyusun generalisasi atau membuat prediksi yang dapat diterapkan pada populasi lebih besar[5].

2.3. Tahapan Penelitian



Gambar 2 Tahapan Penelitian

1. Pengumpulan Data

Proses pengumpulan data dilakukan melalui teknik crawling pada Google Image, dengan memanfaatkan library BeautifulSoup4, serta memanfaatkan data yang telah terkumpul sebelumnya. Total 565 data berhasil dikumpulkan untuk digunakan dalam penelitian ini.

2. Pembersihan Data

Proses pembersihan data dilakukan untuk memastikan bahwa data yang akan digunakan dalam analisis memiliki kualitas yang baik. Langkah-langkah yang diambil termasuk:

- Identifikasi Format Tidak Sesuai: Setiap gambar dicek untuk memastikan bahwa ekstensinya sesuai dengan format yang diharapkan. Jika sebuah gambar memiliki format yang tidak valid, misalnya tidak termasuk dalam daftar ekstensi yang diharapkan, gambar tersebut dipindahkan ke direktori 'unwanted' untuk dihapus atau diperiksa lebih lanjut.
- Penanganan Gambar Palet dengan Transparansi: Beberapa gambar mungkin memiliki palet warna dengan transparansi. Untuk memastikan konsistensi, gambar-gambar ini dikonversi ke format RGBA.
- Deteksi dan Penghapusan Duplikat: Setiap gambar dimodifikasi dan dihitung hash-nya. Hal ini membantu mendeteksi duplikat berdasarkan konten gambar. Jika dua gambar memiliki konten yang sama, yang kedua akan dihapus[6].

3. Persiapan Data

Data yang tersedia dibagi ke dalam folder raw data, di mana setiap jenis sampah atau objek yang ingin diklasifikasikan memiliki sub-folder tersendiri. Selanjutnya, data dibagi menjadi dua bagian utama: data latih (training) dan data validasi (validation). Proses pembagian ini dilakukan dengan menggunakan perbandingan tertentu, yang dalam

kasus ini ditetapkan sebagai 80% untuk data latih dan 20% untuk data validasi. Langkah selanjutnya adalah melakukan augmentasi data[7]. Augmentasi data adalah teknik yang penting dalam pelatihan model yang melibatkan perubahan data yang ada menjadi berbagai bentuk baru dengan cara yang realistis. Hal ini membantu model untuk lebih baik dalam memahami variasi yang mungkin terjadi dalam data sebenarnya. Langkah-langkah ini merupakan bagian integral dari persiapan data untuk pelatihan model. Dengan memastikan bahwa data telah dibagi dengan benar dan diperkaya dengan variasi tambahan melalui augmentasi, maka data siap untuk melatih model untuk mengklasifikasikan sampah dengan akurasi dan keandalan yang tinggi[8]. Pada Gambar 3 berikut adalah data yang telah diberi label dan melalui preprocessing.



Gambar 3 Visualisasi data

4. Modeling

Setelah data dipersiapkan, langkah selanjutnya adalah pembentukan model. Arsitektur EfficientNet digunakan sebagai model ekstraksi fitur yang telah terlatih pada dataset ImageNet. Model yang dikembangkan terdiri dari lapisan ekstraktor fitur, lapisan Dense, ReLU, BatchNormalization, Dropout, dan lapisan Dense terakhir dengan aktivasi softmax[9].

Layer (type)	Output Shape	Param #
keras_layer (KerasLayer)	(None, 1280)	4049564
dense (Dense)	(None, 150)	192150
batch_normalization (Batch Normalization)	(None, 150)	600
dropout (Dropout)	(None, 150)	0
dense_1 (Dense)	(None, 150)	22650
dropout_1 (Dropout)	(None, 150)	0
batch_normalization_1 (Batch Normalization)	(None, 150)	600
dense_2 (Dense)	(None, 2)	302

Total params: 4265866 (16.27 MB)
 Trainable params: 215702 (842.59 KB)
 Non-trainable params: 4050164 (15.45 MB)

Gambar 4 Model yang dibuat

5. Evaluasi Model

Evaluasi Dalam laporan penelitian ini mengimplementasikan metrik *accuracy* dan juga evaluasi kinerja model klasifikasi Precision, Recall, dan F1-Score:

- Precision: Mengukur proporsi positif yang benar-benar positif dari semua hasil yang diberi label sebagai positif oleh model.

- Recall: Mengukur proporsi positif yang benar-benar positif dari semua item yang sebenarnya positif dalam dataset.
- F1-Score adalah ukuran gabungan dari Precision dan Recall, yang menyediakan metrik tunggal untuk mengevaluasi kinerja model secara keseluruhan

Dalam implementasi metrik Precision, perhitungan jumlah true positives (TP) dan false positives (FP) dari prediksi model. True positives adalah jumlah item yang diprediksi positif yang benar-benar positif, sedangkan false positives adalah jumlah item yang diprediksi positif tetapi sebenarnya negatif. Metrik ini kemudian menghitung precision sebagai rasio TP dibagi dengan jumlah TP ditambah FP.

$$\text{Precision} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Positives}}$$

Gambar 5 rumus evaluasi presisi

Metrik Recall menghitung jumlah TP dan false negatives (FN) dari prediksi model. True positives adalah jumlah item yang diprediksi positif yang benar-benar positif, sedangkan false negatives adalah jumlah item yang sebenarnya positif tetapi diprediksi negatif oleh model. Recall kemudian dihitung sebagai rasio TP dibagi dengan jumlah TP ditambah FN

$$\text{Recall} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Negatives}}$$

Gambar 6 Rumus evaluasi recall

F1-Score menggunakan Precision dan Recall yang dihitung sebelumnya untuk menghitung skor F1. Skor F1 adalah rata-rata harmonik dari Precision dan Recall, yang memberikan gambaran menyeluruh tentang kinerja model dalam mengklasifikasikan kelas positif dan negatif.

$$\text{F1 Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Gambar 7 rumus evaluasi f1 score

Melalui implementasi metrik evaluasi ini, kinerja model klasifikasi dapat diukur dengan lebih baik dan membuat penilaian yang lebih akurat tentang efektivitasnya dalam menangani dataset sampah yang saya gunakan dalam penelitian ini[10].

6. Hasil Klasifikasi

Hasil klasifikasi yang diperoleh dari penelitian ini akan menjadi subjek analisis yang cermat untuk mengevaluasi kehandalan dan akurasi model dalam membedakan kualitas bangunan. Analisis mendalam

ini bertujuan untuk memastikan bahwa model yang dikembangkan mampu memberikan hasil yang memuaskan dan dapat diandalkan dalam praktiknya. Dengan demikian, penelitian ini tidak hanya berkontribusi dalam pengembangan teknologi klasifikasi citra menggunakan Deep Learning, tetapi juga memberikan wawasan yang berharga dalam konteks penanganan bantuan pemerintah bagi masyarakat yang membutuhkan, dengan memastikan bahwa keputusan alokasi sumber daya didasarkan pada informasi yang akurat dan dapat dipercaya.[11].

Metode penelitian yang digunakan dalam penelitian ini terfokus pada penerapan arsitektur EfficientNet dalam klasifikasi citra bangunan untuk menentukan kelayakan menerima bantuan pemerintah. Penelitian ini bersifat kuantitatif, dengan tujuan untuk mengumpulkan data yang dapat diukur secara numerik dan menganalisisnya dengan metode statistik, sehingga menghasilkan generalisasi atau prediksi yang dapat diterapkan pada populasi yang lebih besar. Tahapan penelitian dimulai dengan pengumpulan data, di mana teknik crawling digunakan untuk mengambil gambar dari Google Image dan data dari penelitian sebelumnya. Selanjutnya, dilakukan pembersihan data untuk memastikan kualitas yang baik, termasuk identifikasi format tidak sesuai, penanganan gambar palet dengan transparansi, dan deteksi serta penghapusan duplikat. Proses ini bertujuan untuk menghasilkan dataset yang bebas dari masalah yang dapat memengaruhi hasil analisis[12].

Dalam proses pengembangan model klasifikasi, fokus diberikan pada pengoptimalan parameter untuk meningkatkan akurasi dan efisiensi dalam membedakan bangunan-bangunan yang memenuhi syarat untuk bantuan pemerintah dari yang tidak memenuhi. Metode yang digunakan mencakup analisis mendalam terhadap fitur-fitur citra, seperti tekstur, warna, dan bentuk, untuk memastikan bahwa model dapat mengenali karakteristik-karakteristik kunci yang relevan dengan kriteria penilaian kelayakan. Dengan demikian, keterkaitan antara metode penelitian dan tujuan akhir penelitian untuk memberikan kontribusi pada pemecahan masalah sosial yang lebih luas menjadi semakin jelas[13].

Setelah itu, dilakukan persiapan data dengan membagi data menjadi data latih (80%) dan data validasi (20%) serta melakukan augmentasi data untuk memperkaya variasi. Tahap modeling dilakukan dengan menggunakan arsitektur EfficientNet sebagai model ekstraksi fitur yang telah terlatih pada dataset ImageNet. Model ini dilengkapi dengan beberapa lapisan Dense, aktivasi ReLU, BatchNormalization, Dropout, dan lapisan Dense terakhir dengan aktivasi softmax. Evaluasi model dilakukan menggunakan metrik accuracy, Precision, Recall, dan F1-Score untuk mengukur kinerja model dalam mengklasifikasikan kelayakan bangunan rumah[14]. Melalui implementasi metode evaluasi ini, kinerja model dapat diukur secara komprehensif.

Hasil klasifikasi menunjukkan bahwa model yang dikembangkan mampu membedakan kualitas bangunan dengan akurasi yang memuaskan, memberikan kontribusi yang signifikan terhadap efektivitas dalam mengidentifikasi dan mengklasifikasikan kelayakan penerima bantuan. Tahapan-tahapan ini diilustrasikan dalam diagram alur penelitian yang memudahkan pemahaman tentang proses yang dilakukan dalam penelitian ini[15].

3. HASIL DAN PEMBAHASAN

Pada bagian Analisis Algoritma/Model, penelitian ini menggunakan EfficientNet sebagai keluarga model Convolutional Neural Networks (CNN) yang dirancang untuk mencapai akurasi tinggi dengan efisiensi komputasi dan parameter yang lebih baik. Dibandingkan dengan model CNN lainnya, EfficientNet menawarkan akurasi yang lebih tinggi dengan jumlah parameter yang lebih sedikit, menjadikannya lebih efisien. EfficientNet-B0, sebagai model baseline, berhasil mencapai akurasi top-1 sebesar 77.1% dengan hanya menggunakan 5.3 juta parameter dan 0.39 miliar operasi floating-point (FLOPs). Dalam prakteknya, berbagai varian EfficientNet, seperti EfficientNet-B1 hingga EfficientNet-B7, menunjukkan peningkatan akurasi dengan tambahan parameter dan FLOPs yang berbeda. Dibandingkan dengan model-model lain seperti ResNet-50, DenseNet-169, dan NASNet-A juga menunjukkan keunggulan EfficientNet-B0 dalam hal efisiensi sumber daya.

Model	Top-1 Acc.	Top-5 Acc.	#Params	Ratio-to-EfficientNet	#FLOPs	Ratio-to-EfficientNet
EfficientNet-B0	77.1%	93.3%	5.3M	1x	0.39B	1x
ResNet-50 (He et al., 2016)	76.0%	93.0%	26M	4.9x	4.1B	11x
DenseNet-169 (Huang et al., 2017)	76.2%	93.2%	14M	2.6x	3.5B	8.9x
EfficientNet-B1	79.1%	94.4%	7.8M	1x	0.70B	1x
ResNet-152 (He et al., 2016)	77.8%	93.8%	60M	7.6x	11B	16x
DenseNet-204 (Huang et al., 2017)	77.9%	93.9%	34M	4.3x	6.0B	8.6x
Inception-v3 (Szegedy et al., 2016)	78.8%	94.4%	24M	3.0x	5.7B	8.1x
Xception (Chollet, 2017)	79.0%	94.5%	23M	3.0x	8.4B	12x
EfficientNet-B2	80.1%	94.9%	9.2M	1x	1.0B	1x
Inception-v4 (Szegedy et al., 2017)	80.0%	95.0%	48M	5.2x	13B	13x
Inception-resnet-v2 (Szegedy et al., 2017)	80.1%	95.1%	56M	6.1x	13B	13x
EfficientNet-B3	81.6%	95.7%	12M	1x	1.8B	1x
ResNeXt-101 (Xie et al., 2017)	80.9%	95.6%	84M	7.0x	32B	18x
PolyNet (Zhang et al., 2017)	81.3%	95.8%	92M	7.7x	35B	19x
EfficientNet-B4	82.9%	96.4%	19M	1x	4.2B	1x
SENet (Hu et al., 2018)	82.7%	96.2%	146M	7.7x	42B	10x
NASNet-A (Zoph et al., 2018)	82.7%	96.2%	89M	4.7x	24B	5.7x
AmoebaNet-A (Real et al., 2019)	82.8%	96.1%	87M	4.6x	23B	5.5x
PNASNet (Liu et al., 2018)	82.9%	96.2%	86M	4.5x	23B	6.0x
EfficientNet-B5	83.6%	96.7%	30M	1x	9.0B	1x
AmoebaNet-C (Cubuk et al., 2019)	83.5%	96.5%	155M	5.2x	41B	4.1x
EfficientNet-B6	84.0%	96.8%	43M	1x	19B	1x
EfficientNet-B7	84.3%	97.0%	66M	1x	37B	1x
GPipe (Huang et al., 2018)	84.3%	97.0%	557M	8.4x	-	-

Gambar 8. hasil pelatihan variasi model EfficientNet

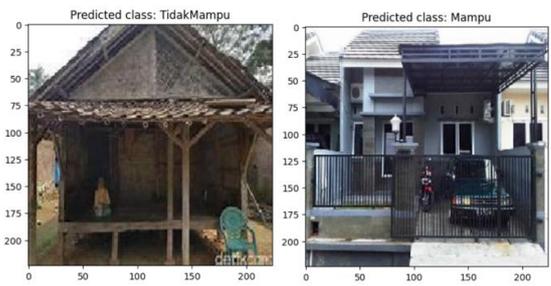
Model EfficientNet memberikan solusi yang mengesankan untuk meningkatkan kinerja dan efisiensi dalam tugas-tugas klasifikasi citra. Pendekatan yang digunakan dalam merancang model ini mempertimbangkan trade-off antara akurasi dan efisiensi, sehingga menghasilkan model yang mampu mencapai performa yang optimal dengan penggunaan sumber daya yang minimal. Kelebihan utama dari EfficientNet adalah kemampuannya untuk mencapai tingkat akurasi yang tinggi dengan jumlah parameter yang relatif rendah. Hal ini sangat bermanfaat dalam aplikasi praktis di mana sumber daya komputasi terbatas, seperti pada perangkat mobile atau edge devices. Dengan demikian, EfficientNet menjadi

pilihan yang menarik untuk berbagai kasus penggunaan di mana keterbatasan sumber daya menjadi pertimbangan utama.

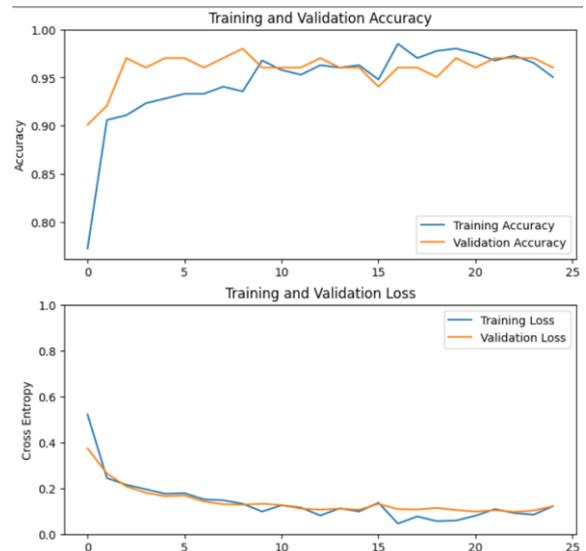
Analisis Penerapan Model pada Penelitian dilakukan menggunakan TensorFlow Keras menggunakan EfficientNet-B0 sebagai ekstraktor fitur untuk klasifikasi gambar. Pemilihan EfficientNet-B0 sebagai ekstraktor fitur memberikan keunggulan dalam hal efisiensi dan akurasi. Dengan jumlah parameter yang relatif rendah, model ini tetap mampu memberikan hasil klasifikasi yang andal. Penggunaan TensorFlow Keras sebagai framework pengembangan mempermudah proses implementasi dan eksperimen dengan model. Kemudahan dalam mengakses berbagai fungsi dan alat bantu analisis memungkinkan untuk menjalankan serangkaian uji coba dan memperoleh wawasan yang mendalam dari data yang ada.

Model ini telah dilatih sebelumnya menggunakan data ImageNet sebagai pre-train. Dengan total parameter sebesar 4,2 juta, model ini mampu menghasilkan probabilitas untuk 2 kelas yang berbeda. Training model dilakukan selama 25 epoch dengan durasi sekitar 3 sampai 3.5 detik per langkah, sehingga total waktu pelatihan adalah sekitar 31.25 hingga 36.46 menit untuk seluruh pelatihan.

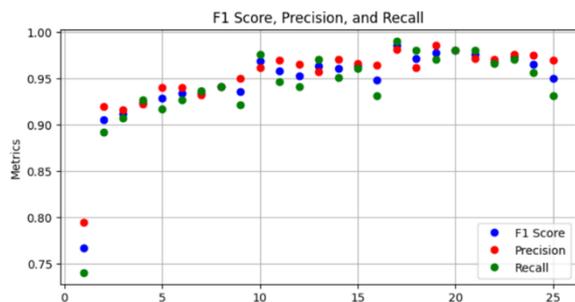
Pada Gambar 9. adalah contoh hasil dari prediksi model yang telah di training



Gambar 9. Hasil Test Model



Gambar 10. hasil pelatihan matriks accuracy dan loss



Gambar 11. Hasil pelatihan matriks evaluasi f1 score, precision, recall

4. DISKUSI

Penelitian terdahulu menggunakan model CNN seperti EfficientNet-B0 dan ResNet-50 untuk mengklasifikasikan penyakit daun jagung dari dataset yang mencakup empat kelas: Blight, Common Rust, Grey leaf spot, dan Sehat. Penelitian ini menunjukkan hasil akurasi yang tinggi dengan model EfficientNet-B0 mencapai akurasi 94% dan ResNet-50 dengan akurasi 93%. Evaluasi model dilakukan dengan membagi dataset menjadi 70% untuk pelatihan dan 30% untuk validasi, metode yang lazim digunakan dalam pengembangan model CNN untuk memastikan kinerja yang solid. [16] Apabila dibandingkan dengan penelitian lain menggunakan CNN dengan Judul "Implementation Of Deep Learning On Flower Classification Using CNN Method" akurasi yang dihasilkan mencapai 84%

Pemodelan yang kami lakukan mendapatkan akurasi yang lebih tinggi kemungkinan karena lebih sedikit nya variabel yang digunakan Setelah melalui proses training yang, evaluasi terhadap hasil Algoritma/Model mengungkapkan pencapaian yang baik. Model berhasil mencapai tingkat akurasi yang baik pada data validasi, dengan akurasi mencapai sekitar 95.03% setelah 25 epoch. Analisis precision, recall, dan F1 score turut menegaskan kualitas model ini.

5. KESIMPULAN

Penelitian ini mengkaji efektivitas arsitektur EfficientNet untuk klasifikasi gambar dalam konteks penentuan penerima yang layak menerima bantuan tunai langsung di Provinsi DKI Jakarta. Berdasarkan hasil analisis, EfficientNet terbukti unggul dalam hal efisiensi sumber daya komputasi sekaligus mempertahankan tingkat akurasi yang tinggi. EfficientNet-B0, sebagai model dasar, mampu mencapai akurasi top-1 sebesar 77.1% dengan hanya menggunakan 5.3 juta parameter dan 0.39 miliar operasi floating-point (FLOPS), menunjukkan kemampuannya untuk mengimbangi model-model lain seperti ResNet-50, DenseNet-169, dan NASNet-A dengan penggunaan sumber daya yang lebih rendah.

Penggunaan EfficientNet dalam penelitian ini berfokus pada varian EfficientNet-B0 yang digunakan sebagai ekstraktor fitur untuk tugas

klasifikasi gambar. Pendekatan ini menghasilkan model yang mampu memberikan hasil klasifikasi yang andal meskipun memiliki jumlah parameter yang relatif rendah. Model dilatih menggunakan data dari ImageNet sebagai pre-train, dengan total parameter sebesar 4,2 juta, dan pelatihan dilakukan selama 25 epoch dengan total waktu sekitar 31.25 hingga 36.46 menit. Hasilnya, model ini menghasilkan akurasi klasifikasi sekitar 95,03% pada data validasi.

DAFTAR PUSTAKA

- [1] M. I. Al-Amin, F. N. Sidiq, D. R. Ramdania, N. Fajar, Y. A. Gerhana, and M. Harika, "Spices Image Classification Using Support Vector Machine," *2022 10th International Conference on Cyber and IT Service Management, CITSM 2022*, vol. 647, pp. 990–993, 2022, doi: 10.1109/CITSM56380.2022.9935856.
- [2] Q. Xie, M. T. Luong, E. Hovy, and Q. V. Le, "Self-training with noisy student improves imagenet classification," *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 10684–10695, 2020, doi: 10.1109/CVPR42600.2020.01070.
- [3] H. Phan, D. Huynh, Y. He, M. Savvides, and Z. Shen, "MoBiNet: A mobile binary network for image classification," *Proceedings - 2020 IEEE Winter Conference on Applications of Computer Vision, WACV 2020*, pp. 3442–3451, 2020, doi: 10.1109/WACV45572.2020.9093444.
- [4] H. Abdu and M. H. Mohd Noor, "A Survey on Waste Detection and Classification Using Deep Learning," *IEEE Access*, vol. 10, no. December, pp. 128151–128165, 2022, doi: 10.1109/ACCESS.2022.3226682.
- [5] H. Pan, Z. Pang, Y. Wang, Y. Wang, and L. Chen, "A New Image Recognition and Classification Method Combining Transfer Learning Algorithm and MobileNet Model for Welding Defects," *IEEE Access*, vol. 8, pp. 119951–119960, 2020, doi: 10.1109/ACCESS.2020.3005450.
- [6] E. Elfatimi, R. Eryigit, and L. Elfatimi, "Beans Leaf Diseases Classification Using MobileNet Models," *IEEE Access*, vol. 10, pp. 9471–9482, 2022, doi: 10.1109/ACCESS.2022.3142817.
- [7] R. H. Chan and R. Li, "A 3-Stage Spectral-Spatial Method for Hyperspectral Image Classification," *Remote Sensing*, vol. 14, no. 16, pp. 1–22, 2022, doi: 10.3390/rs14163998.
- [8] B. Zheng, A. Gao, X. Huang, Y. Li, D. Liang, and X. Long, "A modified 3D EfficientNet for the classification of Alzheimer's disease

- using structural magnetic resonance images,” *IET Image Processing*, vol. 17, no. 1, pp. 77–87, 2023, doi: 10.1049/ipr2.12618.
- [9] A. Dzieniszewska, P. Garbat, and R. Piramidowicz, “Improving Skin Lesion Segmentation with Self-Training,” *Cancers*, vol. 16, no. 6, 2024, doi: 10.3390/cancers16061120.
- [10] Y. Kaya and E. Gürsoy, “A MobileNet-based CNN model with a novel fine-tuning mechanism for COVID-19 infection detection,” *Soft Computing*, vol. 27, no. 9, pp. 5521–5535, 2023, doi: 10.1007/s00500-022-07798-y.
- [11] J. Huang *et al.*, “BM-Net: CNN-Based MobileNet-V3 and Bilinear Structure for Breast Cancer Detection in Whole Slide Images,” *Bioengineering*, vol. 9, no. 6, pp. 1–16, 2022, doi: 10.3390/bioengineering9060261.
- [12] T. Sanida, I. M. Tabakis, M. V. Sanida, A. Sideris, and M. Dasygenis, “A Robust Hybrid Deep Convolutional Neural Network for COVID-19 Disease Identification from Chest X-ray Images,” *Information (Switzerland)*, vol. 14, no. 6, pp. 1–16, 2023, doi: 10.3390/info14060310.
- [13] K. Sabanci, “Benchmarking of CNN Models and MobileNet-BiLSTM Approach to Classification of Tomato Seed Cultivars,” *Sustainability (Switzerland)*, vol. 15, no. 5, 2023, doi: 10.3390/su15054443.
- [14] K. Munadi *et al.*, “A Deep Learning Method for Early Detection of Diabetic Foot Using Decision Fusion and Thermal Images,” *Applied Sciences (Switzerland)*, vol. 12, no. 15, 2022, doi: 10.3390/app12157524.
- [15] Darmatasia and S. A. Muhammad, “Implementasi Convolutional Neural Network Untuk Klasifikasi Tanaman Rimpang Secara Virtual,” *Jurnal INSTEK (Informatika Sains dan Teknologi)*, vol. 8, no. 1, pp. 122–131, 2023.
- [16] W. G. Pamungkas, M. I. P. Wardhana, Z. Sari, and Y. Azhar, “Leaf Image Identification: CNN with EfficientNet-B0 and ResNet-50 Used to Classified Corn Disease,” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 7, no. 2, pp. 326–333, Mar. 2023, doi: 10.29207/resti.v7i2.4736.
- [17] A. Pratiwi, and A. Fauzi, "Implementation Of Deep Learning On Flower Classification Using Cnn Method", *Jurnal Teknik Informatika (JUTIF)*, vol. 5, no. 2, pp. 487–495, 2024 DOI: <https://doi.org/10.52436/1.jutif.2024.5.2.1674>.