

KLASIFIKASI BIJI KEDELAI MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) PADA MODEL EFFICIENTNET-B0

Reza Al Husna^{*1}, Tubagus Maulana Kusuma²

^{1,2}Universitas Gunadarma, Depok

Email: ¹rezaalhusna@staff.gunadarma.ac.id, ²mkusuma@staff.gunadarma.ac.id

^{*}Penulis Korespondensi

(Naskah masuk: 28 Agustus 2024, diterima untuk diterbitkan: 08 Desember 2025)

Abstrak

Produktivitas kedelai sangat dipengaruhi oleh kualitas dan kuantitas mutu fisik biji kedelai. Pemilihan biji kedelai biasanya dilakukan secara manual oleh petani, namun proses tersebut memakan waktu lama dan sering kali kurang optimal. Dalam bidang *Artificial Intelligence*, khususnya *deep learning*, terdapat metode yang dapat menjadi solusi efektif untuk mengenali biji kedelai berkualitas tanpa merusak sampel. Penelitian ini memanfaatkan *Convolutional Neural Network* (CNN) untuk melakukan klasifikasi guna meningkatkan efisiensi dan keberhasilan dalam pemilihan biji kedelai yang berkualitas. Selain itu, digunakan model *transfer learning* EfficientNet-B0 yang menggunakan *Hyperparameter optimizer* Adam, *learning rate* 0,001 serta ukuran *batch* 32 untuk memperkuat kinerja pada model. Pengujian dilakukan menggunakan dataset yang diambil dari Mendeley Data, terdiri dari 5 kelas biji kedelai: *broken soybean*, *immature soybean*, *intact soybean*, *skin damaged soybean*, dan *spotted soybean*, dengan total 5513 data. Dataset dibagi menjadi 80% untuk pelatihan, 10% data validasi, serta 10% untuk pengujian. Hasil penelitian menunjukkan bahwa CNN dengan model EfficientNet-B0 mampu mencapai akurasi sebesar 95%, yang menunjukkan efektivitas metode ini dalam membantu petani melakukan pemilihan biji kedelai secara lebih efisien dan akurat.

Kata kunci: *deep learning, convolutional neural network, transfer learning, efficientnet-b0, biji kedelai*

CLASSIFICATION OF SOYBEAN SEEDS USING CONVOLUTIONAL NEURAL NETWORK ON EFFICIENTNET-B0 MODEL

Abstract

Soybean productivity is strongly influenced by the quality and quantity of the physical qualities of soybean seeds. Soybean seed selection is usually done manually by farmers, but the process is time-consuming and often less than optimal. In the field of *Artificial Intelligence*, especially *deep learning*, there is a method that can be an effective solution to recognize quality soybean seeds without damaging the sample. This research utilizes *Convolutional Neural Network* (CNN) to perform classification to increase efficiency and success in selecting quality soybean seeds. In addition, the EfficientNet-B0 transfer learning model is used which uses the Adam hyperparameter optimizer, learning rate 0,001 and batch size 32 to strengthen the performance of the model. Testing was conducted using a dataset taken from Mendeley Data, consisting of 5 classes of soybean seeds: *broken soybean*, *immature soybean*, *intact soybean*, *skin damaged soybean*, and *spotted soybean*, with a total of 5513 data. The dataset is divided into 80% for training, 10% validation data, and 10% for testing. The results show that CNN with the EfficientNet-B0 model is able to achieve an accuracy of 95%, which shows the effectiveness of this method in helping farmers make soybean seed selection more efficiently and accurately.

Keywords: *deep learning, convolutional neural network, transfer learning, efficientnet-b0, soybean seeds*

1. PENDAHULUAN

Kedelai merupakan salah satu kacang-kacangan utama yang menghasilkan sumber protein nabati dan minyak nabati tertinggi dibandingkan dengan kacang-kacangan lain seperti kacang hijau, kacang merah, dan kacang tanah. Kedelai digunakan sebagai

bahan baku dalam berbagai produk olahan, seperti tahu, tempe, susu, kecap, dan produk-produk lainnya, karena kandungan protein, lemak, dan vitaminnya yang tinggi, yang disukai oleh masyarakat. Permintaan kedelai di Indonesia terus meningkat setiap tahun, seiring dengan meningkatnya kesadaran masyarakat akan manfaat kesehatan dari konsumsi

protein yang terkandung dalam kedelai. Berdasarkan data Badan Pusat Statistik (BPS) tahun 2022, kebutuhan tahunan kedelai mencapai 2,8 juta ton. Peningkatan produktivitas tanaman kedelai sangat dipengaruhi oleh kualitas dan kuantitas biji kedelai, yang menentukan keberhasilan usaha tani kedelai.

Seiring dengan meningkatnya permintaan kedelai, peningkatan kualitas biji kedelai juga mendorong petani untuk mengoptimalkan budidaya secara lebih efisien. Oleh karena itu, Pemerintah, melalui Dewan Standardisasi Nasional (DSN), telah menetapkan standar mutu untuk biji kedelai berdasarkan kriteria warna, bentuk, dan jenis yang tercantum dalam SNI 01-3922-1995. Standar ini berfungsi sebagai pedoman utama dalam penerapan teknologi pascapanen di kalangan petani, guna memastikan kualitas biji kedelai yang dihasilkan memenuhi persyaratan yang telah ditentukan. Proses pemilihan biji kedelai berkualitas masih sering dilakukan secara manual oleh petani dengan pengamatan visual langsung (Idris, 2022). Namun, proses ini memakan waktu yang lama dan dapat menimbulkan perbedaan penilaian antarpetani, sehingga pemilihan biji kedelai berkualitas menjadi kurang optimal. Teknologi *deep learning* menawarkan solusi potensial dalam membantu petani mengenali biji kedelai berkualitas secara lebih akurat, yang pada gilirannya dapat meningkatkan keberhasilan usaha tani kedelai.

Dengan teknologi *deep learning* seperti *Convolutional Neural Network* (CNN) dapat membantu petani melakukan klasifikasi kualitas biji kedelai secara cepat dan otomatis berdasarkan visual melalui citra. CNN dirancang untuk memproses data seperti gambar yang berkerja dengan mengekstrak fitur-fitur penting dari gambar melalui lapisan konvolusi, Dimana filter atau kernel digunakan untuk mendeteksi elemen-elemen seperti tepi, tekstur, dan pola. Proses ini memungkinkan model mengenali struktur dasar yang terdapat dalam gambar. Selanjutnya, lapisan pooling digunakan untuk mengurangi dimensi peta fitur, sehingga kompleksitas komputasi dapat diminimalkan tanpa kehilangan informasi yang signifikan. Setelah melalui tahap tersebut, lapisan *fully-connected* mengintegrasikan semua fitur yang telah dipelajari untuk menghasilkan prediksi akhir, seperti mengklasifikasikan citra ke dalam kategori tertentu (Zafar et al., 2022).

Dalam situasi di mana dataset yang tersedia terbatas, penerapan teknik *transfer learning* menjadi solusi yang efektif untuk meningkatkan efisiensi dan akurasi model. *Transfer learning* pada CNN merupakan pendekatan *deep learning* memanfaatkan model yang telah dilatih sebelumnya pada tugas tertentu sebagai fondasi untuk menyelesaikan tugas baru yang serupa. Sebagai contoh, model CNN yang telah dilatih pada dataset besar seperti ImageNet dapat disesuaikan untuk tugas klasifikasi baru dengan melakukan modifikasi pada arsitektur yang ada.

Teknik ini memungkinkan model memanfaatkan pengetahuan yang telah diperoleh dari dataset berskala besar, sehingga kinerja klasifikasi pada dataset yang lebih kecil atau lebih spesifik dapat ditingkatkan. Pendekatan ini tidak hanya mempercepat proses pelatihan tetapi juga secara signifikan meningkatkan akurasi model dalam mengatasi kendala keterbatasan data yang tersedia (Zhang et al., 2020).


Beberapa penelitian sebelumnya telah melakukan pembahasan pada proses klasifikasi biji kedelai. Misalnya, (Waliyansyah, 2020) mengidentifikasi jenis biji kedelai menggunakan *Gray Level Co-occurrence Matrix* (GLCM) dan *K-Means Clustering* untuk dua kelas biji kedelai, yaitu biji kedelai hijau dan biji kedelai hitam, dengan ekstraksi fitur tekstur dan morfologi, menghasilkan akurasi 47%. Penelitian (Hendrawan et al., 2021) mengklasifikasikan tiga tingkat mutu tempe kedelai, yaitu segar, layak konsumsi, dan tidak layak konsumsi, menggunakan CNN dengan empat *pre-trained* model, yaitu SqueezeNet, GoogleNet, ResNet50, dan AlexNet, dengan hasil akurasi akhir 98,33%. (Pratap et al., 2024) melakukan penelitian terhadap klasifikasi kualitas biji kedelai menggunakan VGG16, AlexNet dan CNN, penelitian tersebut menghasilkan VGG16 mencapai akurasi sebesar 90%, AlexNet sebesar 78,49%, dan CNN sebesar 74,55%. (Ningrum et al., 2024) juga melakukan penelitian terhadap kualitas biji kedelai menggunakan MobileNetV2. Penelitian ini berhasil mencapai akurasi sebesar 91,11%.

Berdasarkan tinjauan dari berbagai penelitian sebelumnya, hasil yang dicapai telah menunjukkan performa yang cukup optimal dalam menyelesaikan tugas klasifikasi. Namun demikian, masih terdapat potensi untuk lebih meningkatkan akurasi model, terutama dalam konteks pengelompokan citra yang lebih kompleks atau spesifik. Untuk mengatasi tantangan tersebut, penelitian ini mengadopsi model *transfer learning* dengan menggunakan arsitektur EfficientNet-B0. Model efficientNet-B0 dipilih karena kemampuannya dalam menggabungkan efisiensi komputasi dengan performa akurasi yang unggul, serta kemampuannya untuk memanfaatkan pengetahuan yang diperoleh dari dataset berskala besar seperti ImageNet guna meningkatkan kinerja pada dataset yang lebih kecil dan spesifik dalam penelitian ini.

Struktur penulisan penelitian ini disusun sebagai berikut: bagian pertama adalah pendahuluan yang mencakup latar belakang penelitian. Bagian kedua membahas terkait metode penelitian dijelaskan sebagai langkah-langkah penyelesaian permasalahan. Selanjutnya, bagian pembahasan menjelaskan hasil penelitian yang dicapai secara rinci. Terakhir, bagian penutup menyajikan kesimpulan.

2. METODE PENELITIAN

Perancangan pada penelitian ini terdiri dari *acquisition data*, *preprocessing data*, *splitting data*, klasifikasi, *training model* dan terakhir evaluasi model. Alur penelitian dapat dilihat pada Gambar 1.



Gambar. 1 Metode penelitian pada klasifikasi biji kedelai

2.1 Dataset

Dataset yang digunakan dalam penelitian ini merupakan dataset sekunder citra biji kedelai yang bersumber dari *Mendeley Data*. Jumlah keseluruhan dataset citra biji kedelai adalah 5513 dimana terbagi menjadi 5 kelas berbeda yaitu *Broken Soybean* dengan jumlah 1002 citra, *Immature Soybean* sebanyak 1125 citra, *Intact Soybean* sebanyak 1201 citra, *Skin Damaged Soybean* sebanyak 1127 citra, dan *Spotted Soybean* sebanyak 1058 citra. Berikut sample citra biji kedelai pada dataset sekunder pada Gambar 2.

2.2 Preprocessing Data

Pada tahapan *preprocessing data*, dilakukan perubahan ukuran citra menjadi resolusi yang relatif kecil. Dalam penelitian ini, citra diubah menjadi 224x224x3 piksel untuk mendapatkan citra yang lebih ideal, sehingga memudahkan dalam pengolahan citra.

Augmentasi data digunakan sebagai Upaya untuk mengurangi *overfitting*. *Overfitting* dapat terjadi karena data training yang terbatas (Pramudhita et al, 2023). Pada penelitian ini augmentasi yang dilakukan adalah rotasi sebesar 20 derajat, pergeseran secara horizontal dan vertical sebesar 20%, pergeseran atau miring hingga 20%, perbesar atau

diperkecil hingga 20%, serta citra dibalik secara horizontal seperti cermin secara acak. Augmentasi juga membantu dalam meningkatkan kemampuan generalisasi data melalui penyajian model (Sahu et al, 2021). Dan dilakukan *split* dengan rasio *train-val-test*: 80%, 10%, 10%.


Kelas	Sample Dataset			
Broken Soybean				
Immature Soybean				
Intact Soybean				
Skin damaged Soybean				
Spotted Soybean				

Gambar. 2 Citra biji kedelai


2.3 Klasifikasi

CNN pada dasarnya terdiri dari tiga blok utama yaitu pertama, lapisan konvolusi berfungsi untuk mengekstraksi fitur dari citra; kedua, blok yang terdiri dari lapisan pooling maksimum untuk melakukan subsampling piksel dan mengurangi dimensi, yang memungkinkan mengurangi biaya komputasi; dan ketiga, blok yang melibatkan lapisan *fully connected* yang memberikan kapasitas pada jaringan (Gu et al., 2018). Arsitektur CNN dapat dilihat pada Gambar 3.

EfficientNet merupakan salah satu arsitektur CNN yang menggunakan metode *compound scaling* untuk meningkatkan akurasi. Metode *compound scaling* melakukan penskalaan pada 3 dimensi yakni kedalaman (*depth*), lebar (*width*), dan resolusi (*resolution*) (Pramudhita et al, 2023). Beberapa model EfficientNet, diantaranya adalah EfficientNet-B0 hingga B7. *Reverse bottleneck MBConv* pertama kali diperkenalkan dalam MobileNetV2 dan merupakan struktur dasar dari EfficientNet. Blok MBConv terdiri dari lapisan yang memperluas dan kemudian memadatkan saluran, menciptakan koneksi langsung antara bagian yang sempit dan bagian yang jauh lebih sedikit salurannya dibandingkan dengan lapisan yang diperluas. Arsitektur EfficientNet-B0 dapat dilihat pada Gambar 4.



Gambar. 3 Arsitektur CNN



Gambar. 4 Arsitektur EfficientNet-B0

Tabel 1. Rincian Informasi EfficientNet-B0

Stage	Operator	Resolusi	Channel	Layer
1	Conv 3x3	224x224	3	1
2	MBConv1 3x3	112x112	32	1
3	MBConv6 3x3	112x112	16	2
4	MBConv6 5x5	56x56	24	2
5	MBConv6 3x3	28x28	40	3
6	MBConv6 5x5	28x28	80	3
7	MBConv6 5x5	14x14	112	4
8	MBConv6 3x3	7x7	320	1
9	Conv1x1 & Pooling & FC	224x224	1280	1

Pada arsitektur EfficientNet-B0, blok MBConv diterapkan pada setiap level atau blok yang tersusun dari beberapa blok MBConv yang diatur secara bertahap. Setiap level atau blok memiliki kedalaman dan lebar yang bervariasi, bergantung pada skala keseluruhan arsitektur CNN. Dalam keseluruhan struktur EfficientNet-B0, blok MBConv digunakan

secara berulang dan dikombinasikan dengan blok lain, seperti yang terlihat pada Gambar 5. Arsitektur EfficientNet-B0 terdiri atas beberapa komponen utama yang mendukung strukturnya secara keseluruhan, termasuk lapisan konvolusi 3x3, blok MBConv1, dan blok MBConv6. Setiap blok memiliki parameter, saluran, dan lapisan yang spesifik (Taruno et al., 2023), dengan informasi lebih rinci mengenai parameter tersebut tercantum di Tabel 1.

2.4 Training Model

Pada Tabel 2 menunjukkan konfigurasi parameter model yang diusulkan dibuat dalam system *deep learning*. EfficientNet-B0 dipilih sebagai arsitektur CNN untuk klasifikasi citra biji kedelai. Model ini memiliki ukuran *default* 224x224 dengan 3 saluran citra RGB. *ImageNet* merupakan database berskala besar yang sangat berguna dalam pengenalan objek. Dalam penelitian ini, database ImageNet melalui library keras digunakan dalam *pre-trained* model dan menggunakan *optimizer Adam* yang secara komputasi lebih efisien, kebutuhan memori rendah, serta mudah untuk diimplementasi serta menggunakan *Categorical Crossentropy* untuk melatih *output* probabilitas CNN pada citra biji kedelai.

Tabel 2. Parameter CNN

Parameter	Type
Arsitektur	EfficientNet-B0
Database Transfer Learning	ImageNet
Kernel (filter)	3x3
Loss Function	Categorical Crossentropy

Output dari blok EfficientNet-B0 kemudian dikonvolusi dengan filter 3x3 dan menambahkan fungsi aktivasi ReLU. Kemudian menambahkan *global average pooling* dan *flatten* untuk mengubah citra ke dalam bentuk matriks menjadi lapisan *fully connected*. Setelah itu, *dropout* digunakan bertujuan menghindari *overfitting* dengan menghapus beberapa node secara acak dari lapisan *fully connected*. Sebelum menambahkan lapisan *output*, terdapat lapisan *dense* bernilai 5, dimana lima merupakan total kelas klasifikasi. Fungsi aktivasi yang digunakan lapisan *output* yakni softmax.

Setelah itu, melakukan proses training untuk mengetahui performa model dari arsitektur EfficientNet. *Hyperparameter setting* yang digunakan dalam proses training meliputi ukuran batch (32), epoch (20), learning rate (0,001), dan optimizer yang digunakan untuk klasifikasi citra (Adam).

Tabel 3. Hyperparameter Setting Training

Parameter	Value
Image Size	224x224
Batch Size	32
Learning Rate	0.001
Optimizer	Adam
Epoch	20

2.5 Evaluasi Model

Pada tahapan ini dilakukan perhitungan pada performa model dari EfficientNet-B0. Performa yang dihitung meliputi *accuracy*, *precision*, *recall*, dan F1-Score. Persamaan (1) menunjukkan rumus perhitungan *accuracy*

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

Persamaan (2) menunjukkan rumus perhitungan *precision*.

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

Persamaan (3) menunjukkan rumus perhitungan *recall*.

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

Persamaan (4) menunjukkan rumus perhitungan F1-Score.

$$F1 - Score = \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

Keterangan:

TP = True Positive

TN = True Negative

FP = False Positive


FN = False Negative

Perhitungan *accuracy* dilakukan dengan membagi jumlah prediksi benar (TP+TN) dengan total data (TP+FP+TN+FN). Metode ini digunakan untuk mengevaluasi kinerja keseluruhan system secara keseluruhan dalam memprediksi dengan benar. *Precision*, disisi lain, digunakan untuk mengukur seberapa baik sistem memberikan label positif secara akurat, yang dihitung dengan membagi True Positive (TP) dengan jumlah True Positive dan False Positive (TP+FP). *Recall* bertujuan untuk mengukur sejauh mana system mampu menilai kemampuan sistem dalam mengidentifikasi data dengan label positif, diperoleh dengan membagi True Positive (TP) dengan jumlah True Positive dan False Negative (TP+FN). *F1-Score* digunakan untuk mengevaluasi keseimbangan antara *Precision* dan *Recall*, terutama dalam konteks data yang tidak seimbang, dengan memberikan gambaran hubungan antara data berlabel positif yang sebenarnya dan data yang diidentifikasi positif oleh system (Grandini et al., 2020).

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pengujian

Berdasarkan hasil pelatihan model yang dilakukan, analisis grafik akurasi menunjukkan bahwa akurasi model mengalami peningkatan secara signifikan pada setiap epoch. Tiga fungsi *callback* diterapkan dalam proses pelatihan model menggunakan TensorFlow, yaitu *TensorBoard*, *ModelCheckpoint*, dan *ReduceROnPlateau*. Fungsi *TensorBoard* memvisualisasikan metrik pelatihan untuk analisis terhadap performa model secara real-time. Fungsi *ModelCheckpoint* hanya menyimpan model jika terjadi peningkatan nilai akurasi pada validasi. Sementara itu, fungsi *ReduceROnPlateau* secara adaptif menyesuaikan learning rate dengan mengurangi 30% jika tidak terjadi peningkatan akurasi validasi dalam 2 epoch berturut-turut. Penerapan 3 *callback* bertujuan memastikan model mencapai Tingkat konvergensi yang optimal. Hal ini mengindikasikan bahwa model secara progresif belajar mengenali pola dari data pelatihan dengan lebih baik seiring bertambahnya iterasi. Di sisi lain, grafik validation loss menunjukkan penurunan yang konsisten, yang mencerminkan kemampuan model untuk menggeneralisasi data secara efektif tanpa mengalami *overfitting*. Setelah menyelesaikan seluruh proses pelatihan, model mencapai akurasi akhir sebesar 95%, yang menunjukkan performa yang sangat baik dalam tugas klasifikasi biji kedelai. Hasil ini menggambarkan bahwa pendekatan yang diusulkan berhasil meningkatkan efisiensi dan akurasi dalam klasifikasi biji kedelai.



Gambar. 5 Hasil klasifikasi. (a) accuracy (b) training & validation loss

Gambar 5 menyajikan representasi grafis dari performa model EfficientNet-B0 berdasarkan metrik akurasi dan loss selama proses pelatihan. Dalam grafik training dan validasi pada awal pelatihan akurasi model masih relative rendah, namun pada epoch ke 2 dan seterusnya akurasi model meningkat yang menandakan bahwa model berhasil mempelajari pola pada data pelatihan dengan baik. Akurasi pada data validasi stabil di nilai tertentu yaitu sekitar 90%. Sekaligus, *Generalization gap* data training terhadap data validasi berapa pada kisaran 0,05-0,1.

Sementara itu, grafik training dan validasi loss menunjukkan pada awal pelatihan berada pada nilai menengah namun seiring dengan meningkatnya kemampuan model mengenali pola terjadi penurunan setelah beberapa epoch, loss semakin rendah dan mendatar menunjukkan bahwa model mencapai kondisi stabil dalam meminimalkan error pada data pelatihan. Perbedaan antara *training loss* dan *validation loss* menunjukkan model lebih mengenal

data pelatihan, namun masih mampu melakukan generalisasi dengan cukup baik. rata-rata waktu komputasi yang diperlukan oleh model untuk memproses data pengujian dihitung berdasarkan hasil dari proses pelatihan. Dari pengukuran yang dilakukan, waktu rata-rata yang dibutuhkan oleh model untuk menyelesaikan pengujian pada satu langkah (step) adalah sekitar 37 detik, dengan durasi rata-rata per langkah sebesar 2 detik. Data ini menggambarkan tingkat efisiensi model dalam hal waktu komputasi, yang menjadi salah satu indikator utama untuk mengevaluasi kelayakan model efficientNet-B0 untuk diterapkan pada skala yang lebih besar atau dalam kondisi nyata.

Tabel 4. Hasil Classification Report

Kelas	Presisi	Recall	F1-Score	Support
Broken Soybean	0,93	0,92	0,92	213
Immature Soybean	0,98	0,96	0,97	230
Intact Soybean	0,95	1,00	0,97	237
Skin Damaged Soybean	0,95	0,96	0,95	203
Spotted Soybean	0,96	0,94	0,95	220
Accuracy			0,95	1103
Macro avg	0,95	0,95	0,95	1103
Weighted avg	0,95	0,95	0,95	1103

Tabel 4 menampilkan hasil evaluasi performa model yang diperoleh melalui penggunaan laporan klasifikasi (*classification report*). Berdasarkan evaluasi tersebut, model menunjukkan akurasi keseluruhan sebesar 95%, yang mencerminkan kemampuan model untuk melakukan klasifikasi data secara efektif. Selain itu, metrik evaluasi seperti precision, recall, dan F1-Score mencatatkan nilai tertinggi pada kelas *Intact Soybeans*, dengan masing-masing nilai sebesar 0,95, 1,00, dan 0,97. Pencapaian ini menunjukkan bahwa model memiliki tingkat presisi yang tinggi dalam mengidentifikasi data yang benar-benar berasal dari kelas tersebut, sekaligus mampu mendeteksi sebagian besar data yang relevan, serta menjaga keseimbangan antara precision dan recall pada tingkat yang optimal. Hasil ini menggambarkan efisiensi dan keandalan model dalam klasifikasi kelas tertentu, sekaligus memberikan wawasan lebih mendalam terhadap kinerja model pada setiap kategori data.

3.2 Pengujian Hyperparameter

Pengujian hyperparameter dilakukan dengan menetapkan konfigurasi yang mampu menghasilkan performa terbaik. Model yang digunakan untuk pengujian adalah EfficientNet-B0, dengan tujuan menemukan kombinasi hyperparameter yang optimal. Jumlah epoch ditetapkan sebanyak 20, dan learning rate yang digunakan adalah 0,001. Pengujian terhadap optimizer dilakukan dengan menguji masing-masing pilihan secara terpisah. Optimizer

yang dicoba meliputi Adam, SGD, dan RMSProp. Hasil dari pengujian disajikan pada tabel 5.

Tabel. 5 Hasil Pengujian Optimizer

Optimizer	Akurasi		Waktu training
	Train	Test	
Adam	0,998	0.958	3672s
SGD	0,948	0,904	3127s
RMSProp	0,998	0,953	4949s

Hasil evaluasi terhadap tiga jenis optimizer, yaitu Adam, SGD, dan RMSProp, menunjukkan bahwa pemilihan algoritma optimisasi memberikan dampak yang nyata terhadap performa model dalam pengklasifikasian. Di antara ketiganya, Adam menunjukkan hasil yang paling unggul, dengan akurasi pelatihan mencapai 99,8% dan akurasi pengujian sebesar 95,8%. Kinerja ini menunjukkan bahwa Adam tidak hanya efisien dalam mempercepat proses pelatihan, tetapi juga mampu mempertahankan generalisasi yang baik pada data uji. Sebaliknya, penggunaan Stochastic Gradient Descent (SGD) menghasilkan akurasi pelatihan 94,8% dan akurasi pengujian 92,5%, namun kurang efektif dalam mencapai performa optimal, kemungkinan karena sifat stokastiknya yang menyebabkan pembaruan bobot menjadi lebih tidak stabil. Di sisi lain, RMSProp menghasilkan akurasi pelatihan yang setara dengan Adam. Meskipun RMSProp menunjukkan kemampuan pelatihan yang kuat, kemampuannya dalam generalisasi masih berada di bawah Adam. Oleh karena itu, dapat disimpulkan bahwa Adam merupakan pilihan optimizer yang paling tepat dalam konteks penelitian ini, karena menawarkan keseimbangan antara akurasi yang tinggi dan efisiensi waktu pelatihan.

3.3 Analisis Perbandingan Kinerja Model

Tabel. 6 Perbandingan *accuracy* antara model klasifikasi lainnya

Referensi	Classification Model	Accuracy Score (%)
Waliyansyah et al., 2020	GLCM & K-Means Clustering	47,00
Hendrawan et al., 2021	SqueezeNet, GoogleNet, ResNet50, dan AlexNet	98,33
Pratap et al., 2024	VGG16, AlexNet, CNN	90,00, 78,49, dan 74,55.
Ningrum et al., 2024	MobileNetV2	91,11
Model yang diusulkan	EfficientNet-B0	95,00

Tabel 5 menunjukkan bahwa model EfficientNet-B0 yang diusulkan berhasil mencapai tingkat akurasi yang lebih tinggi secara signifikan dibandingkan dengan model-model lain yang telah diterapkan dalam penelitian sebelumnya. Pendekatan berbasis *transfer learning* yang diterapkan dalam penelitian

ini mampu meningkatkan performa dari model sebelumnya, sehingga memberikan kontribusi yang lebih besar terhadap kemajuan di bidang klasifikasi citra pertanian.

4. KESIMPULAN

Proses klasifikasi citra biji kedelai berhasil dilakukan dengan memanfaatkan arsitektur Convolutional Neural Network (CNN) yang dikombinasikan dengan teknik transfer learning. Penelitian ini berfokus pada klasifikasi citra biji kedelai ke dalam lima kelas berbeda, yaitu *Broken Soybean*, *Immature Soybean*, *Intact Soybean*, *Skin Damaged Soybean*, dan *Spotted Soybean*. Berdasarkan dari penelitian yang telah dilakukan, model menunjukkan kinerja yang optimal dengan menggunakan ukuran citra (image size) sebesar 224x224 piksel dan jumlah iterasi pelatihan sebanyak 20 epoch. Hasil akhir menunjukkan bahwa model mampu mencapai akurasi keseluruhan sebesar 95%, dengan metrik evaluasi lainnya, seperti precision mencapai 0,95. Recall sebesar 1,00. dan F1-Score sebesar 0,97. Mengindikasikan performa yang sangat baik dalam tugas klasifikasi.

Penelitian lanjutan dapat mengeksplorasi penggunaan arsitektur CNN lainnya sebagai alternatif dari EfficientNet-B0, seperti ResNet, atau DenseNet, untuk membandingkan kinerja dan efisiensi masing-masing model. Eksperimen ini dapat memberikan wawasan tambahan mengenai keunggulan dan kekurangan berbagai arsitektur, serta membantu mengidentifikasi model yang paling cocok untuk klasifikasi citra biji kedelai berdasarkan kompleksitas dataset dan kebutuhan komputasi. Optimalisasi hyperparameter dan pengujian teknik augmentasi data yang lebih beragam juga dapat dipertimbangkan untuk meningkatkan akurasi dan stabilitas model dalam klasifikasi biji kedelai.

DAFTAR PUSTAKA

- ABD EL-GHANY, S., MAHMOOD, M.A. AND ABD EL-AZIZ, A.A., 2024. "Adaptive dynamic learning rate optimization technique for colorectal cancer diagnosis based on histopathological image using EfficientNet-B0 deep learning model". *Electronics*, 13(16), p.3126.
- EKO NITI TARUNO, P., SATYA NUGRAHA, G., DWIYANSAPUTRA, R. AND BIMANTORO, F., 2023. "Monkeypox classification based on skin images using CNN: EfficientNet-B0". *E3S Web of Conferences*, 465, p.02031.
- GRANDINI, M., BAGLI, E. AND VISANI, G., 2020. "Metrics for multi-class classification: an overview". *arXiv preprint arXiv:2008.05756*.
- GU, J., WANG, Z., KUEN, J., MA, L., SHAHROUDY, A., SHUAI, B., LIU, T.,

- WANG, X., WANG, G., CAI, J. AND CHEN, T., 2018. "Recent advances in Convolutional Neural Networks". *Pattern Recognition*, 77, (pp.354–377).
- HENDRAWAN, Y., ROHMATULLOH, B., PRAKOSO, I., LIANA, V., FAUZY, M.R., DAMAYANTI, R., HERMANTO, M.B., AL RIZA, D.F. AND SANDRA, 2021. "Classification of soybean Tempe Quality Using Deep Learning". *IOP Conference Series: Earth and Environmental Science*, 924(1), p.012022.
- IDRIS, F, 2022. "Strategi Pengembangan Usahatani Kedelai Di Kecamatan Bontoramba, Kabupaten Jeneponto, Provinsi Sulawesi Selatan (Doctoral dissertation, Universitas Hasanuddin)".
- JUBA, B. AND LE, H. S. (2019) "Precision-Recall versus Accuracy and the Role of Large Data Sets", *Proceedings of the AAAI Conference on Artificial Intelligence*, 33(01), pp. 4039-4048. doi: 10.1609/aaai.v33i01.33014039.
- KARLEKAR, A. AND SEAL, A., 2020. "SoyNet: Soybean Leaf Diseases Classification". *Computers and Electronics in Agriculture*, 172, p.105342.
- LIN, WEI., FU, YOUHAO., XU, PEIQUAN., LIU, SHUO., MA, DAOYI., JIANG, ZITIAN., ZANG, SIYANG., YAO, HEYANG., SU, QIN (2023), "Soybean Seeds", Mendeley Data, V6, doi: 10.17632/v6vzvfzsj6.6 [diakses 5 juli 2023]
- LIU, J., WANG, M., BAO, L. AND LI, X., 2020, December. "EfficientNet based recognition of maize diseases by leaf image classification". In *Journal of Physics: Conference Series* (Vol. 1693, No. 1, p. 012148). IOP Publishing.
- MALIK, M., SHARMA, S., UDDIN, M., CHEN, C.L., WU, C.M., SONI, P. AND CHAUDHARY, S., 2022. "Waste classification for sustainable development using image recognition with deep learning neural network models". *Sustainability*, 14(12), p.7222.
- MINARNO, A.E., WANDANI, L.R. AND AZHAR, Y., 2022. "Classification of breast cancer based on histopathological image using EfficientNet-B0 on Convolutional Neural Network". *International Journal of Emerging Technology and Advanced Engineering*, 12(8), pp.70–77.
- NINGRUM, A.P., WINARNO, S.T., AND PRASKATAMA, V. 2024. "Klasifikasi Kualitas Biji Kedelai Menggunakan Transfer Learning Convolutional Neural Network Dan SMOTE". *Journal of Applied Computer Science and Technology*.
- PERDANI, W.R., MAGDALENA, R. and CAECAR PRATIWI, N.K., 2022. "Deep learning Untuk Klasifikasi Glaukoma dengan menggunakan Arsitektur EfficientNet". *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 10(2), p.322.
- PRAMUDHITA, D.A., AZZAHRA, F., ARFAT, I.K., MAGDALENA, R. AND SAIDAH, S., 2023. "Strawberry Plant Diseases Classification using CNN based on Mobilenetv3-large and EfficientNet-B0 architecture". *Jurnal Ilmiah Teknik Elektro Komputer dan Informatika*, 9(3), pp.522–534.
- PRATAP, H., GURU PRASAD, M.S., AGARWAL, P., BHARDWAJ, A., MEHRA, A. AND MATHPATI, S., 2024. "SoyNet: Deep Learning Approaches for automated soybean seed Quality Assessment". *2024 2nd International Conference on Advancement in Computation & Computer Technologies (InCACCT)*, pp.613–617.
- RIZAL, S., IBRAHIM, N., PRATIWI, N.K.C., SAIDAH, S. AND FUÂ, R.Y.N., 2020. "Deep learning untuk klasifikasi diabetic retinopathy menggunakan model efficientnet". *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 8(3), p.693.
- SAHU, P., CHUG, A. AND SINGH, A.P., 2023. "Crop leaf disease detection for beans using ensemble-convolutional neural networks". *International Journal of Food Engineering*, 19(11), pp.521–537.
- TIARASARI, A. AND HARYATMI, E., 2021. "Penerapan convolutional neural network deep learning Dalam Pendeteksian Citra Biji Jagung Kering". *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 5(2), pp.265–271.
- WALIYANSYAH, R.R. 2020. "Identifikasi Jenis Biji Kedelai (Glycine Max L) Menggunakan Gray Level Coocurance Matrix (GLCM) dan K-Means Clustering" (2020) *Jurnal Teknologi Informasi dan Ilmu Komputer*, 7(1), pp. 17–26.
- ZAFAR, A., AAMIR, M., MOHD NAWI, N., ARSHAD, A., RIAZ, S., ALRUBAN, A., DUTTA, A.K. AND ALMOTAIRI, S., 2022. "A comparison of pooling methods for Convolutional Neural Networks". *Applied Sciences*, 12(17), p.8643.
- ZHU, S., ZHOU, L., ZHANG, C., BAO, Y., WU, B., CHU, H., YU, Y., HE, Y. AND FENG, L., 2019. "Identification of soybean varieties using hyperspectral imaging coupled with

Convolutional Neural Network”. *Sensors*, 19(19), p.4065.

Halaman ini sengaja dikosongkan