

KLASIFIKASI BAHAN BAKAR MINYAK OPLOSAN (PERTALITE, PERETAMAX, PERTAMAX TURBO) MENGGUNAKAN DENSENET121

Muhammad Kevin^{1*}, Supatman²

Universitas Mercu Buana Yogyakarta; Jl. Jembatan Merah No.84 C Gejayan Yogyakarta 55283, Telp. (0274) 563589, Faks. (0274) 550703

Keywords:

Bahan Bakar Minyak (BBM);
Image Classification;
DenseNet-121.

Correspondent Email:

muhammadkevin3387@gmail.com

Abstrak. Kebutuhan akan Bahan Bakar Minyak (BBM) di Indonesia terus meningkat seiring dengan pertumbuhan jumlah penduduk dan tingginya tingkat mobilitas transportasi. Jenis-jenis BBM seperti Pertalite, Pertamax, dan Pertamax Turbo menjadi komoditas utama yang mendukung aktivitas sehari-hari masyarakat. Namun, perbedaan harga antar jenis BBM ini menyebabkan beberapa konsumen memilih BBM yang lebih murah, yang pada gilirannya membuka peluang bagi praktik ilegal berupa pengoplosan BBM. Pengoplosan ini melibatkan pencampuran antara BBM berkualitas tinggi dan rendah, yang tidak hanya merugikan konsumen dari sisi ekonomi, tetapi juga dapat menurunkan performa kendaraan, merusak mesin, dan mencemari lingkungan. Deteksi BBM oplosan secara konvensional, seperti dengan menggunakan sensor warna, memiliki keterbatasan dalam hal akurasi dan keandalan. Oleh karena itu, penelitian ini mengusulkan penggunaan metode deep learning untuk klasifikasi BBM dengan model DenseNet121. DenseNet121 adalah arsitektur jaringan saraf konvolusional yang dapat mengekstraksi fitur visual dengan sangat efisien berkat koneksi antar lapisan yang padat, yang memungkinkan model untuk membedakan perbedaan visual yang sangat halus antara berbagai jenis BBM dan campuran-campurannya. Model ini dilatih menggunakan citra digital BBM untuk secara otomatis mengidentifikasi jenis BBM dan mendeteksi adanya campuran. Diharapkan, penelitian ini dapat menyediakan solusi yang praktis dan akurat dalam mendeteksi BBM oplosan, serta berkontribusi pada pengawasan distribusi BBM, meningkatkan kesadaran konsumen, dan mencegah penyalahgunaan BBM di masyarakat.

Abstract. The need for fuel in Indonesia continues to increase along with population growth and high levels of transportation mobility. Types of fuel such as Pertalite, Pertamax, and Pertamax Turbo are the main commodities that support people's daily activities. However, the price difference between these types of fuel causes some consumers to choose cheaper fuel, which in turn opens up opportunities for illegal practices in the form of fuel adulteration. This adulteration involves mixing high and low quality fuel, which not only harms consumers economically but can also reduce vehicle performance, damage engines, and pollute the environment. Conventional detection of adulterated fuel, such as using color sensors, has limitations in terms of accuracy and reliability. Therefore, this study proposes the use of deep learning methods for fuel classification with the DenseNet121 model.

DenseNet121 is a convolutional neural network architecture that can extract visual features very efficiently thanks to dense inter-layer connections, which allows the model to distinguish very subtle visual differences between different types of fuel and their mixtures. This model is trained using digital fuel images to automatically identify fuel types and detect mixtures. It is expected that this research can provide a practical and accurate solution in detecting mixed fuels, as well as contribute to monitoring fuel distribution, increasing consumer awareness, and preventing fuel misuse in the community.

1. PENDAHULUAN

Indonesia merupakan salah satu negara dengan jumlah penduduk terbesar di dunia. Besarnya populasi ini berdampak langsung pada meningkatnya aktivitas masyarakat, termasuk di sektor transportasi yang sangat bergantung pada penggunaan kendaraan bermotor [1]. Akibatnya, kebutuhan dan konsumsi bahan bakar minyak (BBM) terus meningkat setiap tahunnya. Menurut data Kementerian ESDM tahun 2022, sekitar 40% konsumsi energi nasional berasal dari sektor transportasi, dengan penggunaan BBM sebagai sumber energi utama [2].

BBM merupakan komoditas vital dalam menunjang mobilitas dan kegiatan ekonomi masyarakat, baik di perkotaan maupun pedesaan. Namun, perbedaan harga antar jenis BBM seperti Pertalite, Pertamax, dan Pertamax Turbo memicu pergeseran pola konsumsi masyarakat, terutama ke BBM yang lebih murah [3]. Hal ini menciptakan celah bagi oknum tidak bertanggung jawab untuk melakukan praktik pengoplosan BBM yakni mencampurkan BBM berkualitas tinggi dengan BBM kualitas lebih rendah dengan tujuan memperoleh keuntungan lebih besar secara ilegal [4].

Praktik pengoplosan BBM ini tidak hanya merugikan konsumen secara ekonomi, tetapi juga berdampak buruk pada kinerja mesin kendaraan serta berisiko menimbulkan kecelakaan dan pencemaran lingkungan [5]. Selain itu, keterbatasan metode identifikasi visual oleh konsumen awam terhadap BBM oplosan menyebabkan praktik ini semakin sulit dikendalikan.

Berbagai upaya telah dilakukan untuk mendeteksi BBM oplosan, salah satunya menggunakan sensor warna untuk mengamati perubahan fisik pada bahan bakar [3]. Namun, pendekatan tersebut masih memiliki keterbatasan dalam accuracy dan keandalan. S

eiring berkembangnya teknologi kecerdasan buatan, metode berbasis pengolahan citra dan pembelajaran mesin mulai dilirik sebagai solusi alternatif yang lebih efektif.

Dalam penelitian ini, penulis melakukan klasifikasi BBM menggunakan model deep learning **DenseNet121**. DenseNet121 dipilih karena kemampuannya dalam mengekstraksi fitur visual secara efisien melalui arsitektur jaringan yang padat (dense connections), sehingga mampu mengenali perbedaan visual halus antara jenis BBM maupun campurannya. Model ini diharapkan dapat membantu mengidentifikasi dan mengklasifikasikan bahan bakar oplosan secara otomatis dan akurat berdasarkan citra digital, yang nantinya dapat diterapkan dalam sistem deteksi BBM oplosan secara praktis.

2. TINJAUAN PUSTAKA


2.1. Bahan Bakar Minyak BBM

Bahan Bakar Minyak (BBM) adalah bahan bakar cair yang digunakan sebagai sumber energi utama pada kendaraan bermotor. BBM dihasilkan melalui proses penyulingan minyak bumi, yang terbentuk dari pelapukan hewan dan tumbuhan selama ribuan hingga jutaan tahun. BBM memiliki berbagai jenis yang dibedakan berdasarkan nilai oktan atau Research Octane Number (RON), yang menunjukkan kemampuan bahan bakar untuk menahan tekanan sebelum terbakar secara spontan. Nilai RON yang lebih tinggi berarti bahan bakar tersebut lebih tahan terhadap tekanan tinggi dalam mesin, sehingga mengurangi risiko terjadinya knocking atau mesin ngelitik yang dapat merusak mesin. Oleh karena itu, pemilihan BBM dengan RON sesuai spesifikasi mesin sangat penting untuk menjaga performa dan keawetan kendaraan [6].

2.2. Klasifikasi dalam Data Mining dan Computer Vision

Klasifikasi adalah proses untuk mengelompokkan data berdasarkan atribut atau karakteristik tertentu. Dalam konteks computer vision, klasifikasi gambar dilakukan dengan menganalisis ciri-ciri objek dalam gambar untuk mengelompokkan gambar berdasarkan kategori yang telah ditentukan sebelumnya. Dalam penelitian ini, klasifikasi gambar bahan bakar minyak oplosan bertujuan untuk mengidentifikasi berbagai jenis bahan bakar minyak oplosan berdasarkan citra visualnya menggunakan teknologi deep learning, khususnya Convolutional Neural Network [7].

2.3. Convolutional Neural Network (CNN)



Gambar 1. Arsitektur CNN [8]

Convolutional Neural Network (CNN) adalah tipe neural network yang umumnya diterapkan pada data gambar. CNN berguna untuk mengenali dan mendeteksi objek dalam sebuah gambar. Dalam strukturnya yang kompleks, Convolutional Neural Network (CNN) terdiri dari banyak lapisan representasi. Oleh karena itu, CNN dapat secara otomatis memperoleh atribut representasi dari data melalui perkiraan fungsi nonlinier dan transformasi nonlinier [9].


Convolutional Neural Network (CNN) adalah jaringan saraf yang sangat baik dalam memproses dan mengekstraksi karakteristik penting dari data visual seperti gambar dan video, yang dirancang khusus untuk menangkap pola lokal dan ketergantungan spasial dalam jenis data ini. Terinspirasi oleh korteks visual otak manusia, CNN menggunakan lapisan dan operasi khusus untuk melakukan banyak hal, seperti mengidentifikasi objek, mengklasifikasi gambar, dan segmentasi gambar [10].

3. METODE PENELITIAN

Tiga jenis bahan bakar minyak (BBM) yang sering digunakan di Indonesia Peralite, P

ertamax, dan Pertamina Turbo diklasifikasikan dalam penelitian ini menggunakan arsitektur DenseNet121. DenseNet121, yang dirancang khusus untuk membedakan pola visual seperti warna, kejernihan, dan sifat visual lainnya dari setiap jenis BBM dengan accuracy tinggi, digunakan untuk mengumpulkan, memproses, dan melatih data gambar BBM. Akuisisi Data, Preprocessing, Pelatihan Model, dan Evaluasi kinerja klasifikasi menggunakan confusion matrix dan ukuran accuracy merupakan bagian dari alur penelitian.

3.1. Alur Penelitian



Gambar 2. Diagram alur Penelitian

3.2. Pencampuran Bahan Bakar

Penelitian ini melibatkan tiga jenis bahan bakar minyak, yaitu Peralite (berwarna hijau), Pertamina (biru), dan Pertamina Turbo (merah). Eksperimen dilakukan dengan mencampurkan dua jenis bahan bakar dalam berbagai kombinasi arah dan variasi volume, seperti: Peralite dengan Pertamina, Peralite dengan Pertamina Turbo, Pertamina dengan Peralite, Pertamina dengan Pertamina Turbo, Pertamina Turbo dengan Peralite, dan Pertamina Turbo dengan Pertamina. Masing-masing kombinasi campuran dibuat dengan takaran volume yang bervariasi, mulai dari 10 ml + 10 ml hingga 110 ml + 100 ml.

Proses pencampuran dilakukan menggunakan peralatan laboratorium sederhana, seperti pipet kaca untuk pengambilan cairan, gelas ukur 10 ml untuk mengukur volume bahan bakar secara precision, dan gelas kimia berkapasitas 250 ml sebagai wadah pencampuran. Setelah kedua jenis bahan bakar dicampurkan dalam takaran tertentu dan diaduk hingga merata, campuran tersebut ditetaskan ke dalam wadah kecil bekas tablet obat yang digunakan sebagai tempat sampel visual. Sampel inilah

yang kemudian difoto untuk keperluan pembuatan dataset citra.[6]

3.3. Akuisisi Citra BBM

Pengambilan citra campuran bahan bakar dilakukan menggunakan kamera ponsel iPhone 7. Proses pengambilan gambar dilakukan setiap kali bahan bakar dicampur, dengan variasi perbandingan volume mulai dari 10 ml + 10 ml, 20 ml + 10 ml, hingga 110 ml + 90 ml dan 110 ml + 100 ml. Setiap kombinasi campuran menghasilkan sebanyak 200 gambar. Dengan total enam kombinasi jenis campuran bahan bakar, jumlah keseluruhan citra yang diperoleh adalah 1.200 gambar.

No	jenis BBM			Total	BBM	Warna
	Pertalite	Pertamax	Pertamax Turbo			
1	10ml	10ml	0ml	20ml	Pertalite 10% vs Pertamax 10%	
2	110ml	50ml	0ml	160ml	Pertalite 110% vs Pertamax 50%	
3	110ml	100ml	0ml	210ml	Pertalite 110% vs Pertamax 100%	
4	10ml	10ml	0ml	20ml	Pertamax 10% vs Pertalite 10%	
5	50ml	110ml	0ml	160ml	Pertamax 110% vs Pertalite 50%	
6	100ml	110ml	0ml	210ml	Pertamax 110% vs Pertalite 100%	
7	10ml	0ml	10ml	20ml	Pertalite 10% vs Pertamax Turbo 10%	
8	110ml	0ml	50ml	160ml	Pertalite 110% vs Pertamax Turbo 50%	
9	110ml	0ml	100ml	210ml	Pertalite 110% vs Pertamax Turbo 100%	
10	10ml	0ml	10ml	20ml	Pertamax Turbo 10% vs Pertalite 10%	
11	50ml	0ml	110ml	160ml	Pertamax Turbo 110% vs Pertalite 50%	
12	100ml	0ml	110ml	210ml	Pertamax Turbo 110% vs Pertalite 100%	
13	0ml	10ml	10ml	20ml	Pertamax Turbo 10% vs Pertamax 10%	
14	0ml	50ml	110ml	160ml	Pertamax Turbo 110% vs Pertamax 50%	
15	0ml	100ml	110ml	210ml	Pertamax Turbo 110% vs Pertamax 100%	
16	0ml	10ml	10ml	20ml	Pertamax 10% vs Pertamax Turbo 10%	
17	0ml	110ml	50ml	160ml	Pertamax 110% vs Pertamax Turbo 50%	
18	0ml	110ml	100ml	210ml	Pertamax 110% vs Pertamax Turbo 100%	

Gambar 3 Tabel. Pengumpulan Data Citra Penelitian BBM [3]

3.4. Pelabelan Citra BBM

Pelabelan citra bahan bakar dilakukan dengan mengklasifikasikan setiap gambar ke dalam enam kategori kelas yang merepresentasikan kombinasi dua jenis bahan bakar yang dicampurkan. Kategori tersebut mencakup : pertalite vs pertamax, pertalite vs pertamaxturbo, pertamax vs pertalite, pertamax vs pertamax turbo, pertamaxturbo vs pertalite, dan pertama x turbo vs pertamax.

Setiap label diberikan secara manual dan disesuaikan dengan jenis bahan bakar yang digunakan serta urutan pencampuran pada saat eksperimen. Proses pelabelan ini bertujuan untuk memastikan bahwa model klasifikasi dapat dilatih secara tepat berdasarkan identitas

dan karakteristik visual dari masing-masing campuran bahan bakar. Dengan pelabelan yang akurat, model deep learning akan mampu mengenali pola spesifik dari setiap kombinasi bahan bakar selama proses pelatihan dan pengujian.


3.5. Resize

Resize Gambar yang telah dikumpulkan akan diubah ukurannya menjadi dimensi tetap sebesar 110x110 piksel. Langkah ini dilakukan untuk memastikan konsistensi dalam dimensi input model CNN dan mengurangi beban memori pada proses pelatihan model[11].

3.6. Dataset

Dataset dibagi menjadi dua bagian, yaitu 80% digunakan untuk proses pelatihan dan 20% sisanya untuk pengujian.

3.7. Arsitektur Densenet121



Gambar 4. Arsitektur DenseNet-121 [12]

DenseNet memanfaatkan koneksi padat antar lapisan yang tidak hanya mengurangi jumlah parameter, tetapi juga memperkuat aliran informasi di dalam jaringan. Dengan menghubungkan setiap layer ke semua layer sebelumnya, DenseNet dirancang untuk mendorong pemanfaatan kembali fitur yang telah dipelajari[13]. Arsitektur DenseNet-121, seperti yang ditunjukkan pada Gambar 4 [12], terdiri dari beberapa komponen utama, termasuk lapisan konvolusi awal, dense block, transition layer, dan lapisan klasifikasi. DenseNet telah terbukti efektif dalam berbagai aplikasi deep

learning, seperti klasifikasi gambar, deteksi objek, dan segmentasi[13].

Layers	Output Size	DenseNet-121
Convolution	112×112	
Pooling	56×56	
Dense Block (1)	56×56	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$
Transition Layer (1)	56×56	
	28×28	
Dense Block (2)	28×28	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$
Transition Layer (2)	28×28	
	14×14	
Dense Block (3)	14×14	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 24$
Transition Layer (3)	14×14	
	7×7	
Dense Block (4)	7×7	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 16$
Classification Layer	1×1	

Gambar 5. DenseNet Menggunakan 4 Blok[12]

Pada gambar 5 diberikan rincian struktur DenseNet-121[12], termasuk ukuran output dari setiap layer utama. Arsitektur ini dimulai dengan lapisan konvolusi awal yang menggunakan kernel berukuran 7×7 dan stride 2, diikuti oleh lapisan pooling untuk mengurangi dimensi data. Selanjutnya, terdapat empat dense block yang diakhiri dengan transition layer untuk menurunkan dimensi fitur. Di bagian akhir jaringan, terdapat lapisan klasifikasi yang memanfaatkan global average pooling dan fungsi aktivasi softmax untuk menghasilkan prediksi multi-kelas.[14]

3.8. Membedakan Jenis Bahan Bakar Minyak

Setelah model CNN selesai dilatih, model diuji untuk membedakan citra bahan bakar minyak berdasarkan kategori yang telah ditentukan. Hasil prediksi dibandingkan dengan label yang sebenarnya untuk mengevaluasi matrix seperti Accuracy, Precision, Recall, dan F1-score. Matrix - matrix ini dihitung dengan menggunakan confusion matrix, dengan rumus yang sesuai :

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Accuracy adalah teknik evaluasi yang digunakan untuk mengukur sejauh mana model dapat memprediksi hasil yang benar dan salah.

Berikut adalah rumus untuk menghitung akurasi.[15]

$$Precision = \frac{TP}{TP + FP}$$

Precision adalah salah satu teknik evaluasi yang digunakan untuk mengukur seberapa tepat model dalam memprediksi kelas yang benar. Berikut adalah rumus untuk menghitung precision.[15]

$$Recall = \frac{TP}{TP + FN}$$

Recall adalah teknik evaluasi yang digunakan untuk mengukur sejauh mana model dapat mendeteksi nilai positif yang sesuai dengan data yang sebenarnya. Berikut adalah rumus untuk menghitung recall. [15]

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

F1-Score adalah teknik evaluasi yang digunakan untuk mengukur kinerja klasifikasi model dengan menggabungkan skor rata-rata precision dan recall yang telah dibobotkan.[15]

Keterangan:

TP (True Positive): adalah jumlah data positif pada citra bahan bakar minyak (BBM) yang berhasil diklasifikasikan dengan benar.

TN (True Negative): adalah jumlah data negatif pada citra bahan bakar minyak (BBM) yang berhasil dikenali sebagai negatif.

FP (False Positive): adalah jumlah data negatif pada citra bahan bakar minyak (BBM) yang salah diklasifikasikan sebagai positif.

FN (False Negative): adalah jumlah data positif pada citra bahan bakar minyak (BBM) yang tidak terdeteksi dengan benar. [14].

4. HASIL DAN PEMBAHASAN

Studi ini mengevaluasi kemampuan model DenseNet-121 dalam mengklasifikasikan tiga jenis bahan bakar minyak, yaitu Pertalite, Pertamax, dan Pertamax Turbo. Model ini dikategorikan ke dalam enam kelompok berdasarkan kombinasi bahan bakar yang diuji: pertalite vs pertamax, pertalite vs pertamaxturbo, pertamax vs pertalite, pertamax vs pertamaxturbo, pertamaxturbo vs pertalite, dan pertamaxturbo vs pertamax. Setiap kelompok mewakili campuran dua jenis bahan bakar dengan variasi volume yang berbeda. Dataset yang digunakan terdiri dari 1.200 gambar, yang dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian. Model dilatih dengan menggunakan optimizer Adam, dan performanya dievaluasi dengan mengukur accuracy, losses, recall, dan precision. Pengujian dilakukan pada gambar berukuran 110×110 piksel selama 20 epoch. Tabel berikut menyajikan ringkasan parameter yang digunakan dalam pengujian :

No	Parameter	Nilai/Uraian
1	Jumlah Epoch	20
2	Optimizer	Adam
3	Tingkat Pembelajaran Awal	0.001
4	Ukuran Citra Input	$110 \times 110 \times 3$ (RGB)
5	Jumlah Kelas Output	5
6	Batch Size	16
7	Matrix Evaluasi	Accuracy, Precision, Recall, F1-score

Tabel 1. Ringkasan Parameter pada Skenario Pengujian


Arsitektur DenseNet-121 memungkinkan penyebaran informasi yang lebih efisien berkat keunggulannya dalam penggunaan parameter dan konektivitas antar lapisan di dalam Dense Blocks. Pengujian dilakukan menggunakan Optimizer Adam dengan laju pembelajaran awal sebesar 0,001, selama 20 epoch, untuk mengoptimalkan kinerja model. Citra input berukuran 110×110 piksel dengan tiga saluran warna RGB digunakan dalam pengujian. Selama pelatihan, ukuran batch yang digunakan adalah 16, dan matrix yang digunakan untuk

evaluasi mencakup accuracy, recall, precision, serta losses.

Hasil pengujian menunjukkan bahwa model DenseNet-121 mampu mengklasifikasikan citra bahan bakar minyak (BBM) dengan tingkat accuracy yang sangat baik. Model ini efektif dalam mengenali pola visual terkait tekstur dan warna bahan bakar minyak, berkat penggunaan parameter pelatihan yang optimal, seperti ukuran citra input yang tepat dan jumlah epoch yang cukup. Untuk menilai kinerja model, confusion matrix digunakan untuk mengukur matrix seperti accuracy, recall, dan precision pada setiap kelas bahan bakar minyak. Temuan ini menunjukkan bahwa arsitektur DenseNet-121 efektif dalam menyelesaikan masalah klasifikasi BBM, dengan tingkat accuracy yang dapat diandalkan, menjadikannya pilihan yang efektif untuk aplikasi pengolahan citra bahan bakar minyak.

4.1. Hasil Pengujian Model CNN

Pengujian dengan Optimizer Adam menghasilkan accuracy tertinggi. Grafik yang ditunjukkan pada Gambar 4 menggambarkan perkembangan accuracy dan nilai losses untuk setiap Optimizer pada setiap periode.



Gambar 6. Grafik Evaluasi Performa Model CNN

Model CNN yang dilatih dengan Optimizer Adam menunjukkan kinerja yang baik, sebagaimana tercermin pada grafik yang disajikan. Kemampuan model dalam mengklasifikasikan data secara akurat tercermin pada accuracy

yang tinggi dan losses yang rendah. Namun, terdapat potensi *overfitting*, yang terlihat dari perbedaan kecil antara kinerja pada data pelatihan dan data validasi. Perbedaan pada matrix *recall* dan *precision* mengindikasikan adanya ketidakseimbangan dalam data atau tantangan dalam penyelesaian masalah ini. Untuk meningkatkan performa model, penggunaan teknik seperti *regularization*, *early stopping*, atau *data augmentation* disarankan. Selain itu, penyesuaian hiperparameter seperti *learning rate* dan jumlah lapisan dapat memberikan kontribusi positif. Pemahaman yang lebih dalam mengenai kelebihan dan kelemahan model dapat diperoleh melalui analisis lebih lanjut dengan menggunakan *confusion matrix* dan visualisasi fitur.

4.2. Adam

Grafik berikut menunjukkan kurva *accuracy* model untuk masing-masing Optimizer selama proses pelatihan dan pengujian.

No	Kelas	Precision	recall	f1-score
1	Pertalite vs pertamax	1.00	0.70	0.82
2	Pertalite vs pertamax turbo	0.44	1.00	0.62
3	Pertamax vs pertalite	1.00	0.88	0.93
4	Pertamax vs pertamax turbo	0.90	1.00	0.95
5	Pertamax turbo vs pertalite	1.00	1.00	1.00
6	Pertamax turbo vs pertamax	1.00	0.75	0.86
7	accuracy			0.88
8	macro avg	0.89	0.89	0.86
9	weighted avg	0.93	0.88	0.89

Tabel 2. menunjukkan hasil dari pengujian yang dilakukan.

Model klasifikasi yang dilatih untuk membedakan berbagai pasangan bahan bakar, yaitu pertalite vs pertamax, pertalite vs pertamax turbo, pertamax vs pertalite, pertamax vs pertamax turbo, pertamax turbo vs pertalite, dan pertamax turbo vs pertamax, disajikan dalam tabel bersama hasil evaluasi kinerjanya. Evaluasi dilakukan dengan mengukur matrix seperti precision, recall, F1-score, accuracy, dan rata-rata tertimbang.

Analisis data menunjukkan bahwa model yang dikembangkan efektif dalam mengklasifikasi berbagai jenis bahan bakar minyak (BBM). Berdasarkan matrix evaluasi, model ini menunjukkan nilai precision, recall, dan F1-score yang tinggi untuk sebagian besar kelas BBM yang diuji.

Precision, yang tinggi menunjukkan bahwa model jarang membuat kesalahan dalam mengklasifikasikan sampel sebagai kelas positif. Matrix ini mengukur persentase prediksi positif yang benar di antara semua prediksi positif yang dihasilkan oleh model.

Recall, yang mengukur sejauh mana sampel positif dapat dikenali dengan tepat, mengindikasikan bahwa model ini mampu mengidentifikasi sebagian besar sampel positif dengan akurat.

F1-score, yang merupakan kombinasi antara precision dan recall, memberikan gambaran menyeluruh mengenai kinerja model secara keseluruhan.


Model berhasil mengklasifikasikan 94% sampel dengan accuracy yang tinggi, seperti yang ditunjukkan oleh nilai accuracy keseluruhan sebesar 94%. Beberapa pasangan kelas, seperti pertalite vs pertamax, pertamax vs pertalite, pertamax vs pertamax turbo, pertamax turbo vs pertalite, dan pertamax turbo vs pertamax, menunjukkan kinerja yang sangat baik, mengindikasikan kemampuan model untuk membedakan dengan jelas antar kelas bahan bakar minyak (BBM). Meskipun demikian, peningkatan nilai losses pada salah satu pasangan ini menunjukkan adanya tantangan dalam mengklasifikasikan kelas pertalite vs pertamax turbo.

Tabel ini mengindikasikan bahwa model menunjukkan kinerja yang baik dalam mengklasifikasikan berbagai jenis bahan bakar minyak (BBM), dengan nilai accuracy keseluruhan sebesar 0,94 yang berarti 94% sampel berhasil diklasifikasikan dengan benar.

Nilai precision, recall, dan fl-score untuk setiap kelas menunjukkan kinerja yang baik, mengindikasikan bahwa model mampu membedakan dengan efektif antara berbagai kelas bahan bakar minyak (BBM). Hal ini terutama terlihat pada kelas dengan nilai matrix tinggi, seperti pertalite vs pertamax, pertamax vs pertalite, pertamax vs pertamaxturbo, pertamaxturbo vs pertalite, dan pertamaxturbo vs pertamax.

4.3. Analisis Confusion Matrix

Confusion matrix digunakan untuk menjelaskan kinerja model dalam mengklasifikasikan berbagai jenis bahan bakar minyak (BBM). Secara keseluruhan, Optimizer Adam memberikan hasil terbaik dengan klasifikasi yang akurat untuk semua kelas bahan bakar minyak. Ringkasan hasil dari confusion matrix disajikan sebagai berikut:



Gambar 7. Tabel Confusion Matrix untuk Optimizer Adam.

Confusion matrix adalah tabel yang digunakan untuk membandingkan label yang sebenarnya dengan hasil prediksi model, yang bertujuan untuk menilai efektivitas klasifikasi yang dilakukan. Setiap sel dalam matrix ini menunjukkan jumlah sampel yang berhasil atau gagal dikategorikan ke dalam kelas tertentu. Model yang dilatih menggunakan Optimizer Adam menunjukkan performa yang sangat baik dalam mengklasifikasikan berbagai jenis bahan bakar minyak (BBM), sebagaimana tercermin dalam confusion matrix. Angka pada diagonal utama confusion matrix mencerminkan jumlah

sampel yang diklasifikasikan dengan benar oleh model. Semakin tinggi angka pada diagonal utama, semakin baik accuracy model dalam mengklasifikasikan sampel. Nilai pada diagonal utama cukup tinggi untuk semua kelas BBM, yang menunjukkan bahwa model dapat mengklasifikasikan sebagian besar sampel dengan tepat. Sebaliknya, nilai di luar diagonal utama menunjukkan sampel yang dikategorikan secara salah. Model ini jarang melakukan kesalahan dalam mengklasifikasikan sampel ke dalam kategori yang salah, terlihat dari rendahnya nilai pada sel-sel di luar diagonal utama. Model juga menunjukkan kinerja yang sangat baik ketika dievaluasi berdasarkan masing-masing kelas, dengan tingkat prediksi yang akurat untuk jenis BBM seperti pertalite vs pertamax, pertamax vs pertalite, pertamax vs pertamaxturbo, dan pertamaxturbo vs pertalite. Namun, beberapa kesalahan klasifikasi pada kelas pertalite vs pertamaxturbo, di mana sampel salah dikelompokkan ke kelas BBM lain, menunjukkan bahwa model masih mengalami kesulitan dalam membedakan kelas ini. Hal ini mengindikasikan bahwa model perlu ditingkatkan lebih lanjut, terutama dalam menangani kelas-kelas BBM yang memiliki kesamaan visual yang lebih besar.

5. KESIMPULAN

Hasil penelitian menunjukkan bahwa model DenseNet121 memiliki kinerja yang sangat baik, dengan tingkat akurasi keseluruhan mencapai 94% dalam mengklasifikasikan tiga jenis Bahan Bakar Minyak (BBM), yaitu Pertalite, Pertamax, dan Pertamax Turbo. Kemampuan model dalam mengenali pola visual, seperti tekstur, warna, dan karakteristik masing-masing jenis BBM, terbukti dari nilai presisi, recall, dan F1-score yang tinggi pada sebagian besar kategori. Meskipun demikian, terdapat kesalahan kecil dalam mengklasifikasikan kelas pertalite vs pertamaxturbo, yang mengindikasikan adanya potensi perbaikan lebih lanjut. Perbaikan tersebut dapat dilakukan melalui teknik augmentasi data, perbaikan ketidakseimbangan data, atau penyesuaian hyperparameter. Untuk meningkatkan kemampuan generalisasi model dan mengurangi risiko overfitting, penelitian selanjutnya disarankan untuk menggunakan dataset yang lebih besar dan lebih beragam, serta menerapkan strategi regulasi seperti dropout atau early stopping.

Selain itu, eksplorasi terhadap arsitektur model alternatif juga perlu dipertimbangkan.

UCAPAN TERIMA KASIH

Penulis menyampaikan apresiasi kepada semua pihak yang telah memberikan dukungan dan kontribusi dalam pelaksanaan penelitian ini

DAFTAR PUSTAKA

- [1]. Deannisa, S., Fauzi, A., Yulius Caesar, L. A., Al Mahdini, A. S., Arya, R. A., Hasanah, N., ... & Anjani Widadari, A. N. (2023). Analisis Pengaruh Kebijakan Pemerintah Indonesia Dengan Menyesuaikan Harga Dan Menjamin Kualitas Bahan Bakar Minyak (Bbm) Terhadap Keputusan Pembelian: Studi Kasus Nahasiswa Universitas Bina Nusantara (Literature Review Manajemen Pemasaran). *Jurnal Ilmu Manajemen Terapan (Jimt)*, 4(4).
- [2]. <https://Data.Goodstats.Id/Statistic/Konsumsi-Bbm-Di-Indonesia-Meningkat-Pada-2022-Esja8>
- [3]. Latuihamallo, M. R., Tentua, B. G., & Simanjuntak, A. (2023). Identifikasi Campuran Bbm Menggunakan Sensor Warna Tcs3200.
- [4]. Silbaqolbina Zahra Y, F Ulfatun Najicha, (2022) Kebijakan Pemerintah Dalam Menaikkan Harga Bahan Bakar Minyak Serta Dampaknya Bagi Masyarakat.
- [5]. Syafa Ikhwanus M, (2020). Identifikasi Campuran Bahan Bakar Minyak Menggunakan Sensor Warna
- [6]. Setiawan, J. & Ghofur, A. (2022). *Pengaruh Bahan Bakar Pertalite Murni Dengan Campuran Bahan Bakar Premium Dan Pertamina Terhadap Performance Emisi Gas Buang Pada Motor Honda Beat 2017*. Rotary, 4(1), 41-50.
- [7]. Fadillah, C., & Supatman, S. (2025). Klasifikasi Jenis Rempah Rempah Alami Untuk Kecantikan Menggunakan Densenet 121. *Jati (Jurnal Mahasiswa Teknik Informatika)*, 9(1), 923-929.
- [8]. <https://www.researchgate.net/profile/Hayati-Cavus/publication/341196554/figure/fig2/asset:888374894264320@1588816488080/The-Logic-Of-Convolutional-Neural-Network.png>
- [9]. Firmansyah, R. (2021). Implementasi Deep Learning Menggunakan Convolutional Neural Network Untuk Klasifikasi Bunga (Bachelor's Thesis, Fakultas Sains Dan Teknologi Uin Hidayatullah Jakarta).
- [10]. Fatoni, H., Maulana, D. A., & Adam, R. I. (2024). Deteksi Dan Klasifikasi Kendaraan Ringan Dan Berat Untuk Jalan Tol Menggunakan Cnn. *Jati (Jurnal Mahasiswa Teknik Informatika)*, 8(6), 11252-11259.
- [11]. Saputra, T., & Al-Rivan, M. E. (2023). Analisis Performa Resnet-152 Dan Alexnet Dalam Klasifikasi Jenis Kanker Kulit. *String (Satuan Tulisan Riset Dan Inovasi Teknologi)*, 8(1), 75-84.
- [12]. Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2018). Densely Connected Convolutional Networks. *Arxiv Preprint Arxiv:1608.06993*.
<https://doi.org/10.48550/Arxiv.1608.06993>
- [13]. Agustina, A. (2024). Klasifikasi Jitet (Jurnal Informatika Dan Teknik Elektro Terapan) Pissn: 2303-0577 Eissn: 2830-7062 Lisa Dkk 681 Penyakit Tanaman Padi Menggunakan Metode Cnn Arsitektur Densenet121 Dan Augmentasi Data. *Klasifikasi Penyakit Tanaman Padi Menggunakan Metode Cnn Arsitektur Densenet121 Dan Augmentasi Data*, 8(1)
- [14]. Putri, D. L. R. (2025). Klasifikasi Citra Jenis Hijab Menggunakan Densenet-121. *Jurnal Informatika Dan Teknik Elektro Terapan*, 13(1).
- [15]. Ripa'i, A., Santoso, F., & Lazim, F. (2024). Deteksi Berita Hoax Dengan Perbandingan Website Menggunakan Pendekatan Deep Learning Algoritma Bert. *G-Tech: Jurnal Teknologi Terapan*, 8(3), 1749-1758.