

# Klasifikasi Kelayakan Ban Sepeda Motor Menggunakan Metode *Convolutional Neural Network*

DOI: <http://dx.doi.org/10.35889/progresif.v21i2.2917>

Creative Commons License 4.0 (CC BY – NC)



Azzar Rizky<sup>1\*</sup>, Wijang Widhiarso<sup>2</sup>, Abdul Rahman<sup>3</sup>

Informatika, Universitas Multi Data Palembang, Palembang, Indonesia

\*e-mail *Corresponding Author*: [azzar.arza@mhs.mdp.ac.id](mailto:azzar.arza@mhs.mdp.ac.id)

## Abstract

*Tires is a primary component in motorcycle that plays a crucial role in driving safety and comfort. Damage to tires, such as wear, cuts, or cracks, can reduce traction, disrupt stability, and increase the risk of traffic accidents. Generally, tire condition inspections are conducted conventionally by technicians who may have limitations in accurately detecting damage. This research aims to develop a tire damage classification system using the Convolutional Neural Network (CNN) method with the MobileNetV2 architecture and with transfer learning approach. The dataset used consists of motorcycle tire images categorized into four classes: normal, bald, cutburst, and spotwear. The training process was conducted using a grid search technique to determine the optimal hyperparameter configuration. The best results obtained with a combination of batch size 16, learning rate 0.001, and 43 epochs, yielding a test accuracy of 96.67%, precision of 95%, recall of 95%, and an F1-score of 95%.*

**Keywords:** *Tire; Convolutional Neural Network; MobileNetV2*

## Abstrak

Ban merupakan komponen utama pada kendaraan sepeda motor yang berperan penting dalam keselamatan dan kenyamanan berkendara. Kerusakan pada ban, seperti keausan, sobekan, atau retakan, dapat mengurangi traksi, mengganggu stabilitas, dan meningkatkan risiko kecelakaan lalu lintas. Pemeriksaan kondisi ban secara umum masih dilakukan secara manual oleh teknisi, yang memiliki keterbatasan dalam hal objektivitas dan akurasi. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi kerusakan ban sepeda motor secara otomatis menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur *MobileNetV2* dengan pendekatan *transfer learning*. Dataset terdiri dari citra ban sepeda motor yang diklasifikasikan ke dalam empat kelas, yaitu normal, *bald*, *cutburst*, dan *spotwear*. Proses pelatihan dilakukan melalui metode *grid search* untuk menentukan konfigurasi parameter terbaik. Hasil terbaik diperoleh pada kombinasi hyperparameter dengan batch size 16, learning rate 0.001, dan jumlah *epoch* 43, menghasilkan akurasi uji sebesar 96,67%, *precision* 95%, *recall* 95% dan *F1-score* 95%.

**Kata kunci:** *Ban; Convolutional Neural Network; MobileNetV2*

## 1. Pendahuluan

Ban merupakan komponen paling vital pada kendaraan bermotor, khususnya sepeda motor. Fungsi utama ban antara lain adalah menopang beban kendaraan, menyalurkan gaya gerak dan pengereman ke permukaan jalan[1]. Dengan peran tersebut, kondisi ban sangat memengaruhi performa kendaraan dan secara langsung berdampak pada aspek keselamatan dan kenyamanan pengendara. Berdasarkan data yang dirilis oleh Kementerian Perhubungan Republik Indonesia[2], tercatat bahwa sekitar 73% kecelakaan lalu lintas melibatkan sepeda motor, dan sekitar 9% dari kasus tersebut disebabkan oleh kerusakan atau kelalaian dalam perawatan ban. Kerusakan pada ban, seperti aus, gundul, retak, atau sobek, dapat menyebabkan penurunan daya cengkram, kestabilan, hingga kemampuan pengereman yang berdampak langsung pada keselamatan berkendara.

Inspeksi kelayakan ban idealnya dilakukan oleh orang yang ahli di bidangnya agar hasil pemeriksaan dapat lebih akurat dan dipercaya. Namun, ketergantungan pada pemeriksaan manual oleh teknisi memiliki keterbatasan, seperti keterbatasan waktu dan akses bagi pengguna. Dalam pemeriksaan kelayakan ban secara konvensional juga memiliki kekurangan, seperti potensi terjadinya *human error* akibat subjektivitas teknisi[3]. Hal ini dapat mengakibatkan kesalahan dalam mendiagnosis kondisi ban. Diagnosa yang keliru tidak hanya berpotensi meningkatkan biaya perawatan kendaraan, tetapi juga dapat menjadi faktor penyebab kecelakaan, sehingga membahayakan keselamatan pengendara dan pengguna jalan lainnya.

Di sisi lain, tidak semua pengguna kendaraan memiliki pengetahuan teknis atau kemampuan untuk menilai kelayakan ban secara visual[4]. Banyak pengendara yang tidak menyadari adanya kerusakan dini pada ban hingga terjadi insiden di jalan. Oleh karena itu, dibutuhkan sistem inspeksi otomatis yang mampu melakukan identifikasi kerusakan secara cepat, tepat, dan objektif. Sistem seperti ini diharapkan dapat mendukung proses inspeksi manual yang rawan kesalahan dengan pendekatan berbasis teknologi, yang lebih konsisten dan dapat diakses oleh pengguna umum. Salah satu pendekatan modern yang berkembang pesat dalam bidang ini adalah penerapan *Artificial Intelligence (AI)*, khususnya dalam bidang *deep learning*, untuk melakukan klasifikasi dan deteksi objek pada citra. Dalam industri manufaktur, Dalam bidang manufaktur, CNN mampu mengidentifikasi cacat pengecoran logam dengan akurasi hingga 99,42%, menjadikannya solusi efisien untuk inspeksi kualitas permukaan logam secara real-time[5]. Di bidang medis, studi oleh Liu et al. (2019) dalam *The Lancet Digital Health* mengungkapkan bahwa model CNN dapat menyamai dan bahkan melampaui performa tenaga medis dalam mendiagnosis penyakit melalui citra radiologi seperti CT-scan dan X-ray, dengan nilai AUC berkisar 0.86–0.99 pada berbagai kasus klinis[6]. Sementara itu, dalam konteks otomotif, penelitian oleh Sukmana et al. (2023) menunjukkan bahwa CNN berbasis *MobileNetV2* mampu mencapai akurasi hingga 96,48% dalam klasifikasi empat jenis kerusakan ban mobil[7]. Oleh sebab itu, penerapan *deep learning* dalam inspeksi visual ban dinilai memiliki potensial untuk menjawab tantangan dalam mendeteksi kerusakan ban sepeda motor secara lebih akurat, efisien, dan dapat diintegrasikan ke dalam perangkat lunak[8].

Tujuan dari penelitian ini adalah melakukan implementasi metode *Convolutional Neural Network* dengan arsitektur *MobileNetV2* dalam melakukan klasifikasi kerusakan pada ban sepeda motor. Penelitian ini dirancang untuk membedakan empat kategori kondisi ban secara visual, yaitu *normal*, *bald*, *cutburst*, dan *spotwear*, secara otomatis dan akurat. Adapun kontribusi utama dari penelitian ini terletak pada pengembangan model klasifikasi multi-kelas. Dengan demikian, model yang dikembangkan memiliki potensi untuk diterapkan dalam perangkat mobile dengan spesifikasi rendah, serta berperan sebagai solusi digital dalam mendukung pemeriksaan kondisi ban sepeda motor secara objektif dan konsisten.

## 2. Tinjauan Pustaka

Dalam penelitian yang dilakukan oleh N. Febriyanto et al[9]. Mengenai deteksi kerusakan dan kelayakan ban mobil, lima kategori kondisi ban yang umum terjadi pada ban mobil terdiri dari *Normal*, *Irregular Wear*, *Spot Wear*, *Tread Cut* dan *Cut Burst*. Kemudian beberapa penelitian klasifikasi kerusakan pada ban mobil dengan menggunakan metode *deep learning* telah dilakukan oleh Prayoga et al[10]. Dalam melakukan klasifikasi dua kategori ban mobil, hasil yang didapat *accuracy* 88% menggunakan metode CNN standar. Selanjutnya, penelitian yang dilakukan oleh Candra Mayana & Leni [11]. Menggunakan metode CNN dengan arsitektur *ResNet-34*. Menghasilkan *accuracy* 91.6%, *precision* 90.7%, *recall* 92.7, dan *f1-score* 91.7%. Selanjutnya, penelitian oleh Hendrawan et al[3]. Dengan menggunakan metode CNN dengan arsitektur *ResNet-50*, hasil yang didapat adalah *accuracy* 94%, *recall* 94% dan *precision* 94%. Kemudian, penelitian oleh S. E. Sukmana et al[7]. Penelitian tersebut menggunakan empat kategori pada ban mobil yang terdiri dari *Good*, *Worn*, *Cracked* & *Burst*. Hasil evaluasi menunjukkan performa model yang sangat baik dengan nilai *accuracy* 96.48%, *precision* 96.56%, *recall* 96.48% dan *f1-score* 96,48% dengan menggunakan arsitektur *MobileNetV2*.

Terdapat satu studi oleh Ebron et al[12]. yang meneliti ban sepeda motor menggunakan metode CNN, penelitian tersebut masih terbatas pada dua kelas, yaitu ban yang layak digunakan dan ban yang harus diganti. Dalam praktiknya, inspeksi kelayakan ban kendaraan

harus mempertimbangkan jenis kerusakan ban secara spesifik. Kerusakan pada ban bersifat lebih kompleks, seperti keausan merata (*bald*), retakan atau sobekan pada permukaan ban (*cutburst*), serta keausan titik (*spot wear*) yang sering dijumpai pada penggunaan harian sepeda motor. Jenis-jenis kerusakan tersebut memiliki kemiripan dengan jenis kerusakan pada ban mobil yang telah banyak dikaji dalam studi literatur terdahulu, sehingga pendekatan yang digunakan pada ban mobil sangat relevan untuk diterapkan dalam konteks ban sepeda motor.

Melihat kapabilitasnya, arsitektur *MobileNetV2* telah terbukti memiliki performa yang sangat baik mendeteksi kerusakan pada ban kendaraan roda empat. Oleh karena itu, penelitian ini menggunakan arsitektur *MobileNetV2* untuk membangun model klasifikasi kondisi kelayakan ban sepeda motor. Model ini dirancang untuk mengenali empat kategori kondisi ban, yaitu: ban normal, keausan merata (*bald*), retakan atau sobekan pada permukaan ban (*cutburst*), dan keausan titik (*spot wear*).

*State of the art* dari penelitian ini terletak pada perluasan skema klasifikasi kondisi ban sepeda motor yang sebelumnya masih terbatas pada pendekatan biner menjadi empat kelas kerusakan yang lebih representatif dan relevan dengan kondisi di lapangan, yaitu normal, bald, cutburst, dan spot wear. Selain itu, penelitian ini memanfaatkan pendekatan *transfer learning* menggunakan arsitektur *MobileNetV2*, yang belum banyak diterapkan secara optimal dalam domain klasifikasi ban sepeda motor. Penelitian ini juga menyertakan proses segmentasi citra manual dan validasi ahli untuk memastikan kualitas dataset.

Kebaruan (*novelty*) dalam studi ini terletak pada usulan pendekatan klasifikasi kerusakan ban sepeda motor dengan mengatasi kompleksitas kerusakan visual yang beragam melalui pemanfaatan *Convolutional Neural Network* berbasis *MobileNetV2*. Model yang dihasilkan dirancang untuk mampu melakukan klasifikasi multi-kelas secara akurat, ringan, dan dapat diimplementasikan pada perangkat dengan daya komputasi yang rendah.

### 3. Metodologi

Penelitian ini dilakukan melalui beberapa tahap, dimulai dari identifikasi masalah, dilanjutkan dengan analisis solusi, kemudian pengumpulan data, perancangan, pengembangan model klasifikasi menggunakan CNN, serta diakhiri dengan evaluasi model untuk mengukur performa model yang dilatih.

#### 1) Identifikasi Masalah

Pada tahap ini, masalah terkait dengan pentingnya pemeliharaan kondisi ban sepeda motor dikemukakan dengan merujuk pada informasi yang didapatkan melalui media sosial dan studi literatur yang menganalisa fungsi dan dampak ban terhadap keselamatan berkendara. Proses identifikasi diperkuat melalui kegiatan wawancara dengan beberapa pemangku kepentingan, yaitu Dinas Perhubungan Kota Palembang, PT Thamrin Brothers Palembang, CV Kencana Motor Sport dan Bengkel Dom Maker Palembang untuk memperoleh informasi mendalam mengenai kondisi lapangan.

#### 2) Analisis Solusi

Tahap ini dilakukan dengan pemilihan arsitektur yang akan digunakan, dengan melalui analisis mendalam terhadap berbagai alternatif dari studi literatur. Metode *Convolutional Neural Network* (CNN) dengan arsitektur *MobileNetV2* ditetapkan sebagai solusi terbaik karena kombinasi kelebihan yang dimiliki dalam menghadapi tantangan penggunaan di perangkat dengan sumber daya terbatas.

Arsitektur *MobileNetV2* merupakan arsitektur *Convolutional Neural Network* (CNN) versi kedua setelah arsitektur *MobileNet*. *MobileNetV2* memiliki 53 layer dengan total 3.4 Juta Parameter[13]. *MobileNetV2* menerapkan teknik *Depthwise Separable Convolutions* (DSC) untuk meningkatkan portabilitas serta mengatasi hilangnya informasi pada lapisan non-linear dalam blok konvolusi dengan menggunakan *Linear Bottlenecks*. Selain itu, *MobileNetV2* juga menggunakan struktur *Inverted Residual Blocks* yang mempertahankan informasi dan memberikan peningkatan signifikan dalam penggunaan memori[14]. Struktur arsitektur *MobileNetV2* dapat dilihat pada Gambar 1.

Input	Operator	$t$	$c$	$n$	$s$
$224^2 \times 3$	conv2d	-	32	1	2
$112^2 \times 32$	bottleneck	1	16	1	1
$112^2 \times 16$	bottleneck	6	24	2	2
$56^2 \times 24$	bottleneck	6	32	3	2
$28^2 \times 32$	bottleneck	6	64	4	2
$14^2 \times 64$	bottleneck	6	96	3	1
$14^2 \times 96$	bottleneck	6	160	3	2
$7^2 \times 160$	bottleneck	6	320	1	1
$7^2 \times 320$	conv2d 1x1	-	1280	1	1
$7^2 \times 1280$	avgpool 7x7	-	-	1	-
$1 \times 1 \times 1280$	conv2d 1x1	-	k	-	-

Gambar 1. Struktur Arsitektur *MobileNetV2*[15]

Arsitektur ini tidak hanya menjawab kebutuhan performa, tetapi juga mendukung pengembangan pada smartphone dengan dengan spesifikasi rendah[16].

### 3) Pengumpulan Data

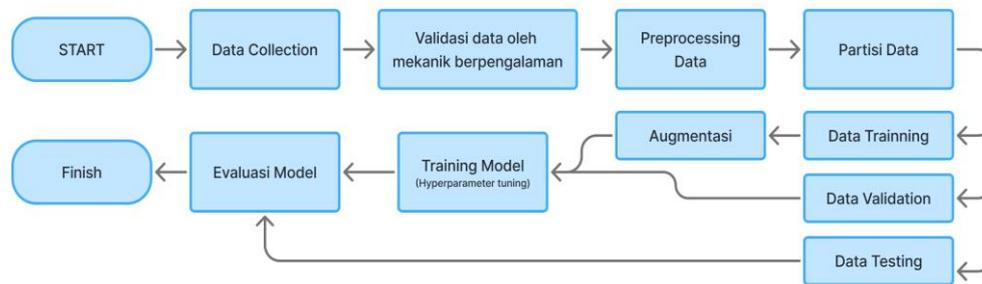
Karena ketidakterdediaan dataset publik tentang ban sepeda motor, data harus dikumpulkan secara mandiri diberbagai tempat di Kota Palembang. Dataset dikumpulkan pada kondisi siang hari dengan pencahayaan yang bervariasi, dan jarak pengambilan gambar antara 25 cm hingga 50 cm menggunakan kamera ponsel yang memiliki spesifikasi kamera utama 48 MP dengan resolusi gambar 4284 x 4284 piksel. Jenis dan kategori dataset yang diambil dapat dilihat pada Tabel 1.

Jenis	Gambar	Kategori	Jumlah
Normal		Layak	150
Bald		Tidak Layak	150
Cutburst		Tidak Layak	150
Spot Wear		Setengah Layak	150
<b>Total</b>			<b>600</b>

Ban Normal dianggap layak karena kondisi fisiknya yang baik, kemampuannya dalam memberikan traksi optimal, dan mendukung kinerja kendaraan yang aman. Sementara itu, ban aus merata (*bald*) dan retak (*cutburst*) dikategorikan sebagai tidak layak karena adanya keausan yang berlebih dan kerusakan struktural, yang dapat meningkatkan risiko kecelakaan. Ban Keausan titik (*spot wear*) berada dalam kategori setengah layak, karena menunjukkan tanda-tanda keausan pada sebagian titik ban, dan dapat memengaruhi kinerja namun belum sepenuhnya kritis, sehingga memerlukan perhatian lebih.

### 4) Perancangan

Alur tahap perancangan dapat dilihat pada Gambar 2.



Gambar 2. Skema Perancangan Klasifikasi Kelayakan Ban Sepeda Motor

Tahap ini dimulai dengan mengumpulkan empat kelas data kerusakan ban yang umum terjadi pada kendaraan sepeda motor. Setelah dataset terkumpul, dilakukan proses validasi dan verifikasi label oleh mekanik berpengalaman dari PT Thamrin Brothers Palembang dan Bengkel Dom Maker Palembang, guna memastikan bahwa setiap citra telah diklasifikasikan ke dalam kelas yang sesuai berdasarkan kondisi ban yang sebenarnya.

Selanjutnya, dilakukan tahapan *preprocessing* pada data citra yang meliputi proses segmentasi manual, yaitu dengan menghapus latar belakang gambar agar objek ban menjadi fokus utama. Selain itu, dilakukan pembersihan terhadap citra yang duplikat dan buram (*blur*), pemotongan area citra yang tidak relevan (*cropping*), serta penyesuaian ukuran citra (*resize*) agar sesuai dengan dimensi input arsitektur MobileNetV2.

Setelah itu dilakukan augmentasi pada dataset untuk menambahkan variasi pada data agar model dapat mengenali objek dengan lebih baik meskipun dalam orientasi atau posisi yang berbeda. Teknik pada augmentasi terdiri dari *rotation*, *flipping horizontal*, *zooming*, serta perubahan *brightness*. Kemudian dilakukan partisi data dengan membagi data menjadi *data training*, *data validation*, dan *data testing* dengan rasio 80:10:10 yang dapat dilihat pada Tabel 2.

Tabel 2. Pembagian data

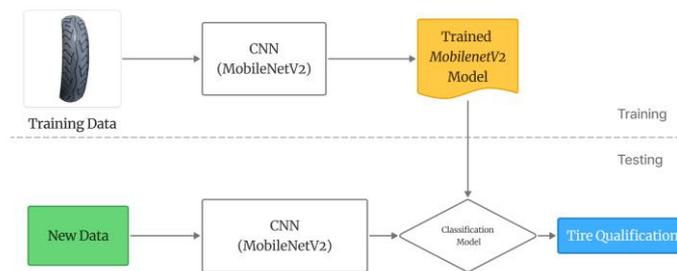
Kategori	Presentase	Jumlah
Data Training	80%	480
Data Validation	10%	60
Data Testing	10%	60

### 5) Pengembangan Model

Pada tahap ini, model dikembangkan menggunakan platform *Jupyter Notebook* dan mengimplementasikan metode *Convolutional Neural Network* (CNN) menggunakan arsitektur *MobileNetV2*. Arsitektur ini menggunakan pendekatan supervised learning sebagai metode pelatihan. Tahap pengembangan model dengan arsitektur *MobileNetV2* dapat dilihat pada Gambar 3.

Dataset citra ban yang telah diklasifikasikan berdasarkan empat kondisi diproses dalam tahap *feature extraction*, di mana karakteristik visual penting seperti pola tapak, retakan, dan tingkat keausan diekstraksi dan dikonversi menjadi representasi numerik (*feature matrix*). *Feature matrix* ini menjadi input utama dalam proses pelatihan model.

Penelitian ini menggunakan pendekatan *transfer learning* yaitu dengan memanfaatkan keseluruhan bobot dari arsitektur *MobileNetV2* yang telah dilatih pada ImageNet. Tidak hanya pada *base model*, seluruh lapisan model *pre-trained* digunakan secara utuh tanpa dilakukan *fine-tuning*. Model ini kemudian diadaptasi untuk tugas klasifikasi empat kelas dengan menambahkan lapisan output (*dense layer*) berukuran 4 unit, yang dilengkapi dengan fungsi aktivasi *softmax* untuk menghasilkan distribusi probabilitas dari masing-masing kelas[16].



Gambar 3. Tahap Pengembangan Model dengan Arsitektur *MobileNetV2*

Tahap pelatihan model dilakukan melalui proses *hyperparameter tuning* dalam memperoleh konfigurasi parameter terbaik guna menghasilkan performa optimal[17]. Proses ini dilakukan dengan menggunakan metode *grid search*. Metode ini merupakan metode *exhaustive search*, di mana nilai-nilai *hyperparameter* ditentukan menggunakan batas bawah, batas atas, dan jumlah steps tertentu. Metode ini akan mencari semua kemungkinan dengan menyusun sebuah grid dan kemudian akan dievaluasi untuk mendapatkan hasil terbaik dari kombinasi yang ada secara sistematis[18]. *Hyperparameter* yang di tuning dapat dilihat pada Tabel 3.

Tabel 3. *Hyperparameter* Tuning Klasifikasi Kelayakan Ban Sepeda Motor

Parameter	Keterangan
Optimizer	Adam Optimizer
Learning Rate	(0.1, 0.01, 0.001, dan 0.0001)
Batch Size	(16, 32, 64, dan 128)
Epoch	(10, 25, 50, 75 dan 100)

Proses pelatihan model dilakukan menggunakan Adam Optimizer karena kemampuannya dalam menyesuaikan *learning rate* secara adaptif selama pelatihan. Jumlah *epoch* ditetapkan dalam rentang 10 hingga 100, dengan penerapan teknik *early stopping* (*patience* = 5) untuk mencegah *overfitting* dan menghentikan pelatihan secara otomatis saat model tidak menunjukkan peningkatan performa pada data validasi[19].

#### 6) Evaluasi Model

Evaluasi model dilakukan menggunakan *confusion matrix* dengan metrik *accuracy*, *precision*, *recall* dan *f1-score*. Penggunaan metrik ini didasarkan pada empat komponen utama dalam klasifikasi, yaitu *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN).

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

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

$$F1\ score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (4)$$

TP mengacu pada sampel yang diklasifikasikan sebagai positif dan memang benar berasal dari kelas positif. TN adalah sampel dari kelas negatif yang berhasil diprediksi dengan benar. Sebaliknya, FP merupakan sampel dari kelas negatif yang keliru diprediksi sebagai kelas positif, sementara FN adalah sampel dari kelas positif yang salah diprediksi sebagai negatif [20]. Nilai

*accuracy* dihitung berdasarkan Persamaan (1), *recall* menggunakan Persamaan (2), *precision* menggunakan persamaan (3), dan F1 score menggunakan persamaan (4).

#### 4. Hasil dan Pembahasan

##### 4.1. Hasil

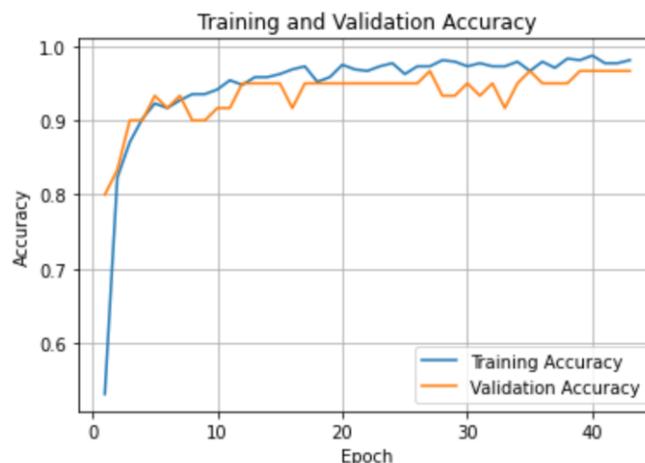
Model klasifikasi citra ban sepeda motor dikembangkan menggunakan arsitektur *MobileNetV2* telah berhasil dilatih dengan melibatkan pencarian *hyperparameter* terbaik menggunakan metode *grid search*, dengan konfigurasi optimal *batch size* 16, *epoch* 43 dan *learning rate* 0,001.

Performa model dalam melakukan klasifikasi citra ban dievaluasi menggunakan *data validation* dan *data testing*. Evaluasi dilakukan untuk mengetahui kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya. Tabel 4 merangkum hasil evaluasi dari model terhadap akurasi, loss, dan waktu pelatihan.

Tabel 4. Hasil Evaluasi Model CNN *MobileNetV2*

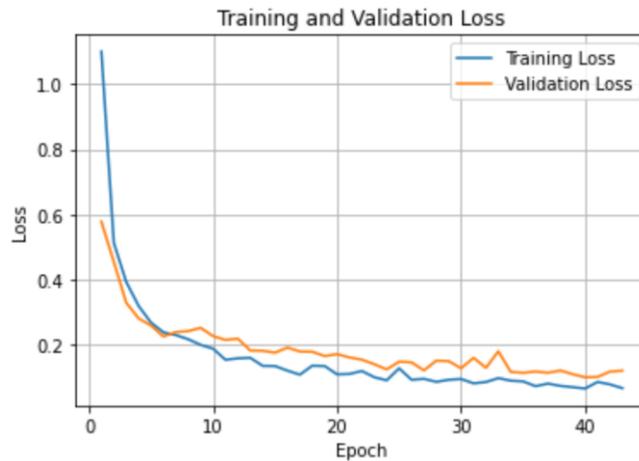
Parameter	Nilai
Validation Accuracy	96,67%
Validation Loss	0.1051
Test Accuracy	96,67%
Test Loss	0.0983
Training Time	1152.61 Second

Dari tabel hasil dapat dilihat bahwa nilai akurasi model sangat tinggi, baik pada data validasi maupun data uji, dengan nilai yang identik yaitu 96,67%. Hal ini menunjukkan bahwa model memiliki kemampuan generalisasi yang sangat baik, karena mampu mempertahankan performa yang konsisten meskipun diuji pada data yang belum pernah dilihat sebelumnya.



Gambar 4. Grafik *Tranining and Validation Accuracy*

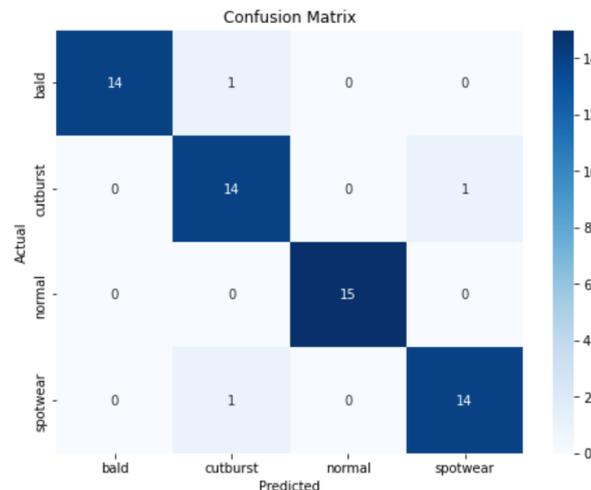
Gambar 4 merupakan grafik *training and validation accuracy* yang menunjukkan peningkatan performa model yang signifikan sejak epoch pertama. Akurasi pelatihan meningkat secara konsisten dan stabil setelah sekitar epoch ke-10, hingga mencapai nilai mendekati 100%. Sementara itu, akurasi validasi juga mengalami peningkatan pesat dan stabil di angka sekitar 96–97% mulai dari epoch ke-15 hingga akhir pelatihan. Perbedaan antara kedua kurva relatif kecil, yang mengindikasikan bahwa model mampu melakukan generalisasi dengan baik tanpa *overfitting* yang signifikan. Konsistensi antara akurasi pelatihan dan validasi ini menunjukkan bahwa model dapat mengenali pola-pola penting dari citra ban secara efektif di semua kelas.



Gambar 5. Grafik *Training and Validation Loss*

Gambar 5 merupakan grafik *training and validation loss* yang menunjukkan bahwa nilai loss pada data pelatihan mengalami penurunan tajam di awal epoch dan terus menurun hingga mencapai nilai rendah ( $< 0.1$ ) mendekati akhir pelatihan. Pola serupa juga terlihat pada loss validasi, meskipun fluktuasi kecil masih terjadi, perbedaan antara loss pelatihan dan validasi sangat kecil, mengindikasikan bahwa tidak memiliki gap besar antara kemampuan belajar dan kemampuan generalisasi model. Hal ini membuktikan bahwa model belajar secara efisien tanpa overfitting, dan bahwa pendekatan *early stopping* yang digunakan berhasil menghentikan pelatihan pada saat performa optimal telah dicapai.

Untuk mengukur performa model secara lebih rinci, dilakukan evaluasi menggunakan *Confusion Matrix*. Evaluasi ini tidak hanya melihat akurasi keseluruhan, tetapi juga bagaimana model memprediksi masing-masing kelas secara spesifik melalui metrik *precision*, *recall*, dan *F1-score*. Hasil dari *Confusion Matrix* di tunjukkan pada Gambar 6.



Gambar 6. *Confusion Matrix* Klasifikasi Kelayakan Ban Sepeda Motor

Berdasarkan hasil yang diperoleh, sebanyak 57 dari 60 citra berhasil diklasifikasikan dengan benar oleh model, dengan hanya tiga kesalahan klasifikasi minor yang terjadi antara kelas *cutburst*, *spotwear*, dan *bald*. Hal ini menunjukkan bahwa kebingungan antar kelas sangat minim, dan model memiliki ketajaman klasifikasi yang baik, bahkan terhadap jenis kerusakan yang memiliki kemiripan secara tekstur.

Tabel 5. *Classification Report*

Kelas	Precision	Recall	F1-Score	Support
Normal	1.00	1.00	1.00	15
Bald	1.00	0.93	0.97	15
Cutburst	0.88	0.93	0.90	15
Spot Wear	0.93	0.93	0.93	15
Accuracy			0.95	<b>60</b>
Macro avg	0.95	0.95	0.95	<b>60</b>
Weighted avg	0.95	0.95	0.95	<b>60</b>

Hasil *classification report* pada Tabel 5 menunjukkan bahwa model klasifikasi yang dibangun mampu menghasilkan nilai *precision*, *recall*, dan *F1-score* yang tinggi dan seimbang di keempat kelas. Dengan akurasi keseluruhan sebesar 95%, serta *F1-score* mencapai 1.00 pada kelas *normal* dan di atas 0.90 untuk kelas lainnya, model terbukti efektif dalam mengenali karakteristik visual masing-masing jenis kerusakan ban.

#### 4.2. Pembahasan

Hasil pelatihan dan pengujian menunjukkan bahwa model CNN dengan arsitektur *MobileNetV2* yang dibangun dalam penelitian ini mampu mengklasifikasikan kondisi ban sepeda motor secara akurat. Berdasarkan hasil evaluasi menggunakan data uji, model mencapai akurasi sebesar 96,67%, dengan nilai *precision*, *recall*, dan *F1-score* sebesar 95%. Angka ini menunjukkan bahwa model tidak hanya mampu mengenali setiap kategori kerusakan dengan baik, tetapi juga mempertahankan kinerja yang seimbang di keempat kelas, yaitu *normal*, *bald*, *cutburst*, dan *spotwear*.

Kinerja ini juga tercermin dari kurva pelatihan yang stabil dan konvergen, di mana kurva akurasi dan loss pada data pelatihan serta validasi menunjukkan perbedaan yang minimal. Stabilitas tersebut menandakan bahwa model tidak mengalami *overfitting*, dan mampu melakukan generalisasi terhadap data yang belum pernah dilihat sebelumnya. Pelatihan dihentikan secara otomatis pada *epoch* ke-43 melalui penerapan teknik *early stopping* dengan *patience* = 5. Hal ini menjadi bukti bahwa model dapat mencapai performa terbaiknya tanpa harus menjalani pelatihan hingga 100 *epoch*, sehingga waktu pelatihan dapat dioptimalkan.

Evaluasi lebih lanjut menggunakan *classification report* memperlihatkan bahwa kelas *normal* diklasifikasikan dengan sempurna (*precision* dan *recall* = 1.00), sedangkan kelas *cutburst* dan *spotwear* memiliki nilai *recall* dan *precision* yang sedikit lebih rendah, namun masih dalam kategori tinggi. Hal ini wajar mengingat karakteristik visual dari beberapa kelas memiliki kemiripan tekstur atau pola, seperti antara *cutburst* dan *spotwear*, yang berpotensi menyebabkan kebingungan model dalam proses prediksi.

Selain itu, *confusion matrix* menguatkan analisis performa model. Dari 60 data uji, hanya terjadi 3 kesalahan klasifikasi. Sebagian besar kesalahan merupakan misprediksi antar kelas minor, dan tidak menunjukkan kecenderungan berat sebelah pada kelas tertentu. Artinya, model tidak bias terhadap tiga kategori kerusakan ban dan mampu mengenali setiap kelas secara proporsional.

Pencapaian ini didukung oleh penggunaan transfer learning, yang memanfaatkan bobot pretrained dari *MobileNetV2* yang dilatih pada dataset *ImageNet*. Dengan memanfaatkan kemampuan fitur generalisasi awal dari model tersebut dan menambahkan *dense layer* dengan aktivasi *softmax* untuk klasifikasi empat kelas, pelatihan dapat dilakukan lebih efisien dan tetap menghasilkan performa tinggi meskipun dengan dataset terbatas. Pendekatan ini terbukti efektif untuk tugas klasifikasi citra spesifik seperti kondisi kerusakan ban sepeda motor.

Jika dibandingkan dengan penelitian terdahulu, kontribusi penelitian ini memberikan penguatan terhadap temuan oleh Sukmana et al[7], yang menunjukkan bahwa *MobileNetV2* dapat mencapai akurasi tinggi (96,48%) pada klasifikasi empat kondisi ban mobil. Penelitian ini berhasil memperluas penerapan arsitektur tersebut ke ranah sepeda motor dengan kompleksitas kerusakan yang mirip, namun belum banyak diteliti secara spesifik. Selain itu, penelitian ini juga melengkapi studi oleh Ebron et al[12], dengan menambahkan dimensi klasifikasi multi-kelas yang lebih representatif terhadap realitas di lapangan.

## 5. Simpulan

Penelitian ini berhasil membuktikan bahwa metode *Convolutional Neural Network* (CNN) dengan arsitektur *MobileNetV2* dan pendekatan *transfer learning* mampu mengklasifikasikan kerusakan ban sepeda motor secara otomatis dan akurat. Model yang dikembangkan mampu mengenali empat kategori kondisi ban normal, bald, cutburst, dan *spotwear* dengan performa sangat tinggi, ditunjukkan oleh akurasi uji sebesar 96,67%, serta nilai *precision*, *recall*, dan *F1-score* rata-rata sebesar 95%. Hasil ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan mampu melakukan klasifikasi secara seimbang pada tiap kelas. Temuan ini menjawab permasalahan yang diangkat dalam penelitian, yaitu perlunya sistem yang dapat melakukan pemeriksaan kelayakan ban secara objektif, efisien, dan dapat diandalkan tanpa bergantung sepenuhnya pada inspeksi manual.

Evaluasi melalui *classification report* dan *confusion matrix* mengindikasikan bahwa model menunjukkan distribusi prediksi yang proporsional serta kesalahan klasifikasi yang minimal. Penggunaan *transfer learning* dari model *pretrained ImageNet* memungkinkan pelatihan dilakukan secara lebih efisien tanpa memerlukan dataset berukuran besar. Ke depan, pengembangan lebih lanjut dapat diarahkan pada peningkatan variasi dan volume dataset, baik dari segi jenis kerusakan, kondisi pencahayaan, maupun sudut pengambilan gambar, agar model semakin robust dalam menghadapi kondisi nyata di lapangan. Selain itu, model ini memiliki prospek implementasi luas dan berpotensi diterapkan dalam sistem bantu inspeksi berbasis perangkat lunak, baik di lingkungan bengkel maupun aplikasi mobile untuk pengguna individu, sehingga dapat berkontribusi pada peningkatan keselamatan berkendara secara lebih luas.

## Daftar Referensi

- [1] H. Ponda, N. F. Fatma, dan I. Siswanto, "Usulan Penerapan Lean Manufacturing Dengan Metode Value Stream Mapping (VSM) Dalam Meminimalkan Waste Pada Proses Produksi Ban Motor Pada Industri Pembuat Ban," *Heuristic*, vol. 19, no. 1, pp. 23–42, 2022, doi: 10.30996/heuristic.v19i1.6568.
- [2] K. P. RI, "Tekan Angka Kecelakaan Lalu Lintas, Kemenhub Ajak Masyarakat Beralih ke Transportasi Umum dan Utamakan Keselamatan Berkendara," Kementerian Perhubungan Republik Indonesia. Accessed: Oct. 07, 2024. [Online]. Available: <https://dephub.go.id/post/read/tekan-angka-kecelakaan-lalu-lintas,-kemenhub-ajak-masyarakat-beralih-ke-transportasi-umum-dan-utamakan-keselamatan-berkendara#> [Diakses: 07 Oktober 2024]
- [3] I. E. Hendrawan, R. I. Adam, dan C. Rozikin, "Klasifikasi Retak Ban Kendaraan Menggunakan Arsitektur ResNet50," *SATIN - Sains dan Teknologi Informasi*, vol. 9, no. 1, pp. 23–32, 2023, doi: 10.33372/stn.v9i1.902.
- [4] Z. M. Jawi dan A. Hamzah, *Car Users' Knowledge and Practices on Tyre Maintenance in Malaysia*, MRR No. 337, Malaysian Institute of Road Safety Research (MIROS), pp. 1–34 Jan. 2020.
- [5] D. Ekambaram and V. Ponnusamy, "Identification of Defects in Casting Products by using a Convolutional Neural Network," *IEE Trans. Smart Process. Comput.*, vol. 11, no. 3, pp. 149–155, 2022, doi: 10.5573/IEIESPC.2022.11.3.149.
- [6] X. Liu, L. Faes, A. U. Kale, et al., "A comparison of deep learning performance against health-care professionals in detecting diseases from medical imaging: a systematic review and meta-analysis," *Lancet Digital Health*, vol. 1, no. 6, pp. e271–e297, 2019, doi: 10.1016/S2589-7500(19)30123-2.
- [7] S. E. Sukmana, C. Rahmad, M. S. Khairy, R. Ariyanto, dan R. Andhani, "Classification of Damage to Car Tires Using Mobile-Based Deep Learning," *Prosiding IEIT 2024 - Int. Conf. on Electrical and Information Technology*, Surabaya, pp. 176–181, 10 Januari 2024, doi: 10.1109/IEIT64341.2024.10763133.
- [8] N. Sharma, R. Sharma, dan N. Jindal, "Machine Learning and Deep Learning Applications- A Vision," *Global Transitions Proceedings*, vol. 2, no. 1, pp. 24–28, 2021, doi: 10.1016/j.gltp.2021.01.004.
- [9] N. Febriyanto, C. Rahmad, dan C. B. Vista, "Klasifikasi Kelayakan Ban Mobil dengan Deep Learning," *Jurnal Informatika Polinema*, vol. 7, no. 4, pp. 58–64, 2021.
- [10] K. Prayoga, R. Magdalena, dan S. Saidah, "Sistem Deteksi Kecacatan Ban Dengan Convolutional Neural Network," *e-Proceeding of Engineering*, vol. 10, no. 3, pp. 2229–

- 2234, 2023.
- [11] H. C. Mayana dan D. Leni, "Deteksi Kerusakan Ban Mobil Menggunakan Convolutional Neural Network dengan Arsitektur ResNet-34," *Surya Teknik*, vol. 10, pp. 45–50, 2023.
- [12] J. G. Ebron, K. M. Paliso, G. A. C. Reyes, S. P. Tongol, J. R. Clavillas, dan D. Ortega, "Predicting Motorcycle Tire Failure with Deep Learning," *Proc. Int. Conf. on ICT and Knowledge Engineering (ICTKE)*, Bangkok, pp. 1–6, 15 Maret 2024, doi: 10.1109/ICTKE62841.2024.10787193.
- [13] C. Luo, X. He, J. Zhan, L. Wang, W. Gao, dan J. Dai, "Comparison and Benchmarking of AI Models and Frameworks on Mobile Devices," *arXiv preprint*, arXiv:2005.05085, 2020. [Online]. Available: <http://arxiv.org/abs/2005.05085> [Diakses: 01 Desember 2024].
- [14] D. Nguyen, C. Nguyen, T. Duong-Ba, H. Nguyen, A. Nguyen, dan T. Tran, "Joint network coding and machine learning for error-prone wireless broadcast," *Proc. IEEE 7th Annu. Comput. Commun. Work. Conf. (CCWC)*, Las Vegas, pp. 1–6, 9 Januari 2017, doi: 10.1109/CCWC.2017.7868415.
- [15] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, dan L. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," *Proc. IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, Salt Lake City, pp. 4510–4520, 2018.
- [16] B. Khasoggi, Ermatita, dan Samsuryadi, "Efficient MobileNet Architecture as Image Recognition on Mobile and Embedded Devices," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 16, no. 1, pp. 389–394, 2019, doi: 10.11591/ijeecs.v16.i1.pp389-394.
- [17] B. H. Shekar, "Optimizing CNN Training using Batch Normalization and Dropout: A Case Study," *Lect. Notes Networks Syst.*, vol. 535, pp. 1–8, 2019.
- [18] D. A. Anggoro dan S. S. Mukti, "Performance Comparison of Grid Search and Random Search Methods for Hyperparameter Tuning in Extreme Gradient Boosting Algorithm to Predict Chronic Kidney Failure," *Int. J. Intell. Eng. Syst.*, vol. 14, no. 6, pp. 198–207, 2021, doi: 10.22266/ijies2021.1231.19.
- [19] J. Turihohabwe, S. Richard, dan W. William, "Hyperparameter Optimization Through Transfer Learning for Classification Tasks," *Indonesian Journal of Computer Science*, vol. 14, no. 1, pp. 1–13, 2025.
- [20] S. Sharma dan K. Guleria, "A Deep Learning based Model for the Detection of Pneumonia from Chest X-Ray Images using VGG-16 and Neural Networks," *Procedia Computer Science*, vol. 218, pp. 357–366, 2022, doi: 10.1016/j.procs.2023.01.018.