

## **Conv-Tire: Tire Feasibility Assessment using Convolutional Neural Networks**

Conv-Tire: Asesmen Kelayakan Ban berbasis Convolutional Neural Network

**Latifah Listyalina<sup>1</sup>, Irawadi Buyung<sup>2</sup>, Agus Qomaruddin Munir<sup>3</sup>, Ikhwan Mustiadi<sup>4</sup>,  
Dhimas Arief Dharmawan<sup>5</sup>**

<sup>1</sup> Program Studi Teknologi Pengolahan Karet dan Plastik, Politeknik Negeri ATK Yogyakarta, Indonesia

<sup>2,4</sup> Program Studi Teknik Elektro, Universitas Respati Yogyakarta, Indonesia

<sup>3</sup> Program Studi Teknologi Informasi, Universitas Respati Yogyakarta, Indonesia

<sup>5</sup> Program Studi Informatika, Universitas Pembangunan Nasional Veteran Yogyakarta, Indonesia

<sup>1</sup>latifah.listyalina@atk.ac.id, <sup>2</sup>buyungirawadi@gmail.com, <sup>3</sup>agusqmnr@respati.ac.id,

<sup>4</sup>ikhwan@respati.ac.id, <sup>5\*</sup>dhimas.arief@upnyk.ac.id

\*: Penulis korespondensi (corresponding author)

### **Article's Information / Informasi Artikel**

Received: August 2022

Revised: September 2022

Accepted: October 2022

Published: October 2022

### **Abstract**

*Purpose: In this study, the authors design a tire quality assessment method based on convolutional neural networks.*

*Design/methodology/approach: The proposed method is built through several stages as follows. In the first stage, the tire images, which are the input of the designed method, are acquired. Further, the acquired images are divided into two sets, namely training and testing sets. The training set contains tire images used in the training phase of several convolutional neural networks (CNN) architectures such as ResNet-50, MobileNetV2, Inception V3, and DenseNet-121. The training phase is carried out in a number of epochs, and at each epoch, the cross entropy loss function will be calculated which expresses the performance of the CNN architecture in classifying tire images. For this reason, the training stage requires a label or reference that shows the feasibility of the tires displayed in each image. Afterwards, the trained CNN architectures are used to classify tire images from the test set. The performance of the CNN architectures are further compared and analyzed.*

*Findings/result: Classification performance in the test set is also expressed in terms of cross-entropy loss function value. In addition, the accuracy value has also been calculated which shows the percentage of the number of tire images. The recapitulation of the results of five experiments on*

---

*several convolutional neural network (CNN) architectures that have been implemented shows a tendency that the DenseNet-121 model has the best performance, followed by MobileNetV2, InceptionV3, and finally ResNet-50. The best accuracy performance in question is owned by the DenseNet-121 model of 92.62%.*

*Originality/value/state of the art: Given the high accuracy achieved by our method, this work can be used as a reference by other researchers, specifically to benchmark their tire quality classification methods developed in the future.*

*Keywords: convolutional neural network; image; tire; tire quality*  
Kata kunci: ban; citra; convolutional neural network; kelayakan ban

---

### **Abstrak**

**Tujuan:** Pada penelitian ini, penulis mengaplikasikan sebuah metode berbasis convolutional neural network yang mampu melakukan klasifikasi kelayakan ban secara otomatis sesuai dengan penampakan ban pada citra ban.

**Perancangan/metode/pendekatan:** Metode yang diusulkan dibangun melalui beberapa tahap sebagai berikut. Pada tahap pertama, dilakukan akuisisi citra ban yang menjadi masukan dari metode yang dirancang. Selanjutnya, citra hasil akuisisi dibagi menjadi dua set, yaitu set pelatihan dan pengujian. Set pelatihan berisikan citra ban yang digunakan pada tahap pelatihan beberapa arsitektur convolutional neural network (CNN) seperti ResNet-50, MobileNetV2, Inception V3, dan DenseNet-121. Tahap pelatihan dijalankan dalam sejumlah epoch, dan pada setiap epoch, akan dihitung nilai fungsi rugi cross entropy yang menyatakan performa dari arsitektur CNN dalam mengklasifikasikan citra ban. Untuk itu, tahap pelatihan membutuhkan label atau acuan yang menunjukkan kelayakan ban yang ditampilkan oleh masing-masing citra. Tahap selanjutnya adalah tahap pengujian, di mana arsitektur-arsitektur CNN terlatih digunakan untuk mengklasifikasikan citra ban yang berasal dari set pengujian. Performa dari beberapa arsitektur CNN tersebut kemudian dibandingkan dan dianalisis.

**Hasil:** Performa klasifikasi pada set pengujian dinyatakan dalam bentuk nilai fungsi rugi cross entropy. Selain itu, telah dihitung pula nilai akurasi yang menunjukkan persentase jumlah citra ban yang berhasil diklasifikasikan dengan benar terhadap jumlah seluruh citra ban pada set pengujian. Rekapitulasi dari hasil lima percobaan beberapa arsitektur convolutional neural network (CNN) yang telah dilaksanakan terdapat kecenderungan bahwa model DenseNet-121 memiliki performa terbaik, diikuti oleh

---

---

MobileNetV2, InceptionV3, dan terakhir ResNet-50. Performa akurasi terbaik yang dimaksud dimiliki oleh model DenseNet-121 sebesar 92,62%.

Keaslian/*state of the art*: Dengan akurasi tinggi yang diperoleh, penelitian ini dapat digunakan oleh peneliti di bidang penilaian kelayakan ban sebagai referensi, dan tolok ukur performa metode klasifikasi kelayakan ban di masa mendatang.

---

## 1. Pendahuluan

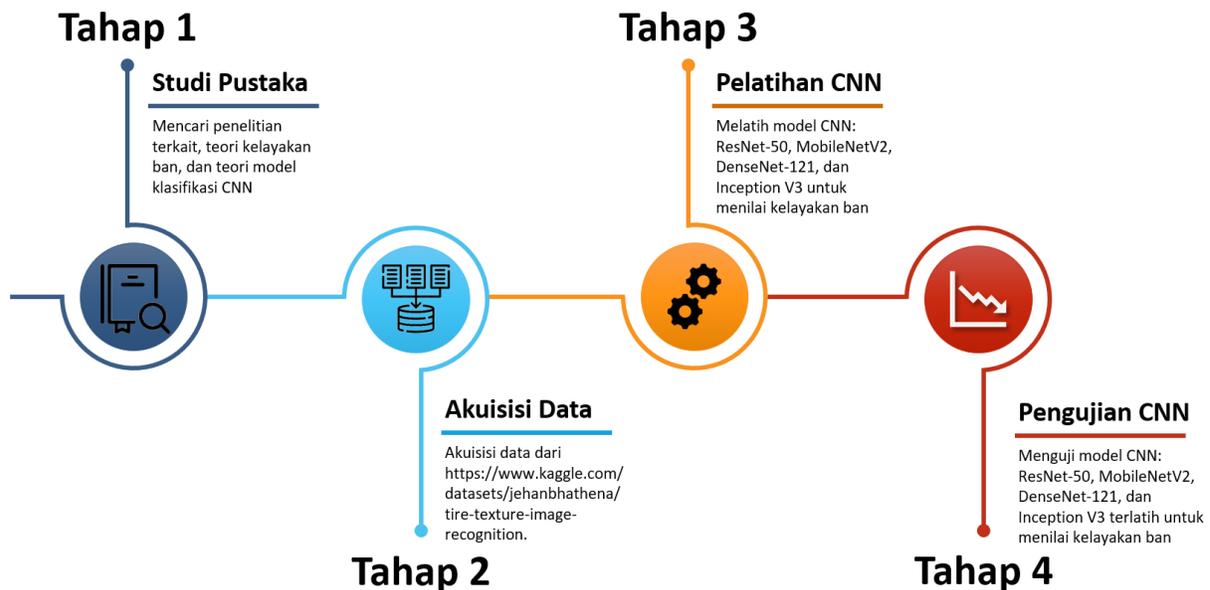
Menurut Organisasi Kesehatan Dunia, sekitar 1,3 juta orang meninggal dan 50 juta cacat akibat kecelakaan di jalan setiap tahun, di antaranya 40% disebabkan oleh kegagalan ban [1]. Di Indonesia sendiri, pada tahun 2019 misalnya, terdapat laporan bahwa 80% kecelakaan yang terjadi di jalan tol diakibatkan oleh permasalahan pada ban. Hal ini menunjukkan bahwa kondisi ban yang prima merupakan salah satu elemen penting yang menentukan keselamatan berkendara.

Sebagai respons kecelakaan yang sering terjadi akibat masalah ban, pemeriksaan visual ban memainkan peran penting yang luar biasa dalam memastikan kualitas ban dan keselamatan berkendara. Sayangnya, pemeriksaan kelayakan ban secara manual bukanlah hal yang sederhana. Beberapa aspek seperti gerigi yang tersisa pada ban, ketebalan ban, dan cacat-cacat halus pada ban seringkali meningkatkan subjektivitas pekerja inspeksi ban. Oleh karena itu, inspeksi kelayakan ban secara otomatis dengan bantuan komputer dapat menjadi salah satu solusi.

Berdasarkan permasalahan yang telah dipaparkan, penulis mengusulkan untuk dirancang sebuah metode komputer yang mampu mengklasifikasikan kelayakan ban. Demi mendapatkan hasil klasifikasi yang akurat, metode klasifikasi dirancang berbasis *convolutional neural network* (CNN) yang telah terbukti memiliki performa yang sangat baik pada sejumlah tugas klasifikasi citra.

## 2. Metode

Penelitian ini berjenis kuantitatif dan menggunakan data sekunder, yakni data citra ban yang diunduh dari <https://www.kaggle.com/datasets/jehanbhatena/tire-texture-image-recognition>. Citra akan diklasifikasikan ke jenis ban layak dan cacat dengan bantuan model *convolutional neural network*. Pengukuran yang dilakukan berupa pengukuran tingkat akurasi model *convolutional neural network* yang dirancang dalam mengklasifikasikan citra ban ke jenis-jenis ban yang sesuai. Adapun tahapan dalam penelitian ini diilustrasikan pada Gambar 1 di bawah dan diuraikan sebagai berikut.



Gambar 1. Tahapan Penelitian

## 2.1. Studi Pustaka

Studi pustaka dilakukan dengan mencari informasi dari buku dan penelitian-penelitian terlebih dahulu untuk meningkatkan penelitian sebelumnya. Selain itu, studi pustaka dimaksudkan untuk mengetahui teknologi terkini terkait *deep learning*. Berikut adalah beberapa informasi pendukung jalannya penelitian ini.

### 2.1.1. Penelitian Terkait

Beberapa upaya telah dilakukan untuk mengaplikasikan metode komputer guna klasifikasi kelayakan ban secara otomatis. Upaya klasifikasi kelayakan ban otomatis biasanya dilakukan pada citra hasil radiografi (X-Ray), salah satunya seperti yang diusulkan oleh [2]. Pada penelitian tersebut, dikembangkan metode rekonstruksi citra ini menggunakan transformasi terbalik (*inverse transform*) dari residu komponen utama untuk secara otomatis mendeteksi cacat ban pada gambar sinar-X. Gambar sinar-X ban yang akan diperiksa pertama-tama ditransformasikan ke sistem koordinat baru, yaitu ruang komponen utama, di mana  $k$  komponen utama dan vektor eigennya yang sesuai mewakili tekstur normal ban yang dominan. Tidak seperti analisis komponen utama tradisional,  $k$  nilai eigen komponen utama ditetapkan sebagai nol, kemudian matriks ruang komponen utama di atas disebut residu komponen utama, yang merupakan tekstur ban yang tidak dominan yang dianggap sebagai tekstur abnormal atau cacat. Transformasi terbalik dari residu komponen utama ini dilakukan dan citra yang hanya menyisakan komponen cacat direkonstruksi. Untuk melokalisasi bagian yang cacat, operasi binarisasi diproses pada gambar sisa yang diperoleh dengan ambang batas atas dan bawah secara statistik. Skema yang diusulkan dapat mengungkapkan lokasi cacat dan juga menyajikan bentuk tambalan cacat untuk identifikasi. Hasil eksperimen menunjukkan efektivitas tinggi skema yang diusulkan dalam mendeteksi cacat gambar sinar-X ban.

Pemanfaatan model pembelajaran mesin untuk klasifikasi kelayakan ban juga dilakukan oleh [3]. Disebutkan pada penelitian tersebut, dictionary learning dapat digunakan untuk mendeteksi

cacat pada ban. Kumpulan ciri yang dipelajari dari gambar normal efisien untuk mewakili gambar bebas cacat sementara kamus memiliki efisiensi rendah untuk mewakili gambar cacat karena kemampuannya menangkap informasi penting. Berbeda dengan solusi iteratif konvensional dengan perhitungan yang rumit, koefisien representasi diperoleh dengan mengalikan matriks pseudo-invers dari kamus yang dipelajari dan patch gambar. Selain itu, distribusi koefisien representasi sangat berbeda antara citra bebas cacat dan citra cacat. Oleh karena itu, perbedaan distribusi koefisien representasi dapat digunakan sebagai kriteria diskriminasi untuk mendeteksi daerah cacat. Hasil eksperimen menunjukkan bahwa metode yang diusulkan dapat secara akurat mendeteksi cacat.

Berkembangnya teknologi *convolutional neural network* (CNN) turut dimanfaatkan oleh beberapa peneliti untuk mengaplikasikan model klasifikasi kelayakan ban otomatis, salah satunya penelitian yang dilakukan oleh [4]. Penelitian tersebut mengusulkan metode deteksi cacat ban otomatis berdasarkan CNN yang sepenuhnya mempertimbangkan masalah dalam produksi ban. Penggunaan CNN ditujukan untuk mengekstrak fitur-fitur kecacatan ban secara otomatis, khususnya fitur-fitur kompleks yang tidak tertangkap metode ekstraksi fitur tradisional. Dengan begitu, dimungkinkan untuk mendapatkan performa yang tinggi dalam waktu yang singkat.

Pemanfaatan CNN untuk studi kelayakan ban juga dilakukan oleh [5]. Pada penelitian tersebut, metode end-to-end (TireNet) diusulkan untuk aplikasi praktis deteksi cacat ban otomatis dengan gambar sinar-X. Terinspirasi oleh fitur gambar sinar-X ban, yang periodik, Siamese network digunakan dalam model baru untuk menangkap fitur ban yang rusak. Hasil eksperimen dari metode ini mencapai tingkat recall yang lebih tinggi dibandingkan dengan Faster R-CNN, SSD, dan YOLO pada dataset berlabel, dengan kesalahan deteksi sebesar 0,17%.

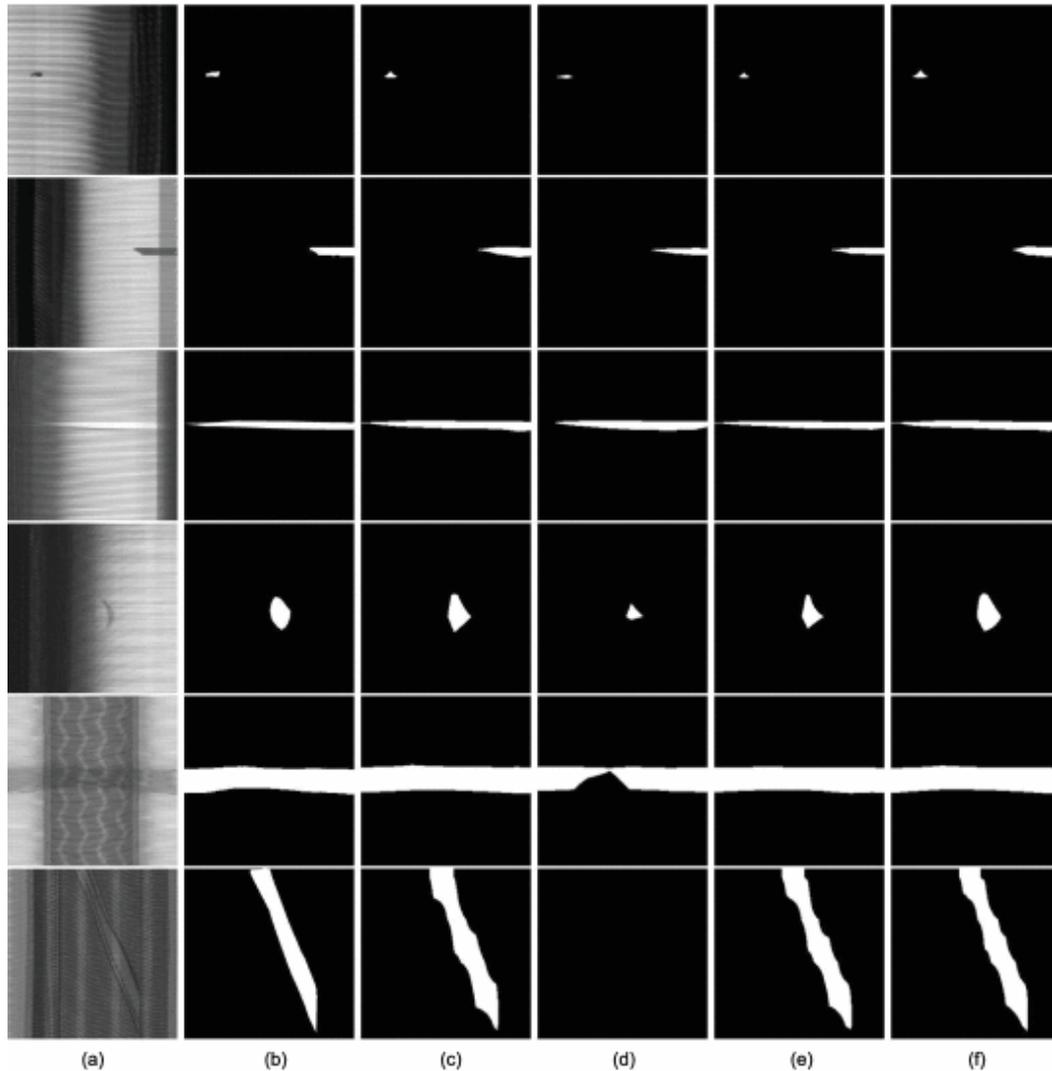
### 2.1.2. Kelayakan Ban

Menurut [6], inspeksi cacat pada ban merupakan hal yang menantang dikarenakan beberapa faktor sebagai berikut:

- 1) Kualitas visual yang rendah. Ada banyak ketidakpastian dalam perolehan citra ban, karena perbedaan jenis mesin dan perubahan lingkungan. Di sisi lain, gambar yang digunakan untuk deteksi otomatis berasal dari penyinaran sinar-X, dan memiliki beberapa karakteristik yang tidak diinginkan seperti kontras rendah dan kecerahan rendah.
- 2) Struktur tekstur yang berbeda. Umumnya, gambar ban terdiri dari gambar tapak dan gambar dinding samping. Tapak adalah bagian ban yang bersentuhan dengan permukaan jalan, yang terbuat dari karet tebal. Dinding samping sebagian besar terbuat dari karet tetapi diperkuat dengan kain atau kabel baja. Oleh karena itu, fitur tekstur sangat berbeda antara gambar tapak dan dinding samping. Karena kecerahan gambar tapak yang lebih rendah, cacat yang terjadi pada tapak lebih sulit untuk dideteksi.
- 3) Cacat yang beragam. Ada jenis cacat serupa yang didistribusikan pada tapak dan dinding samping, seperti kotoran logam dan gelembung, tetapi beberapa cacat hanya ada pada gambar tapak atau dinding samping. Karakteristik berbagai jenis cacat jelas dan ada kesenjangan besar antara teksturnya. Secara umum, kotoran memiliki tepi yang tajam dan lebih gelap dari tetangganya. Untuk gelembung, itu lebih terang dari tetangga mereka, meskipun teksturnya mirip dengan tekstur bagian bebas cacat. Perbedaan karakteristik ini

menimbulkan tantangan dalam pendeteksian cacat ban. Beberapa contoh cacat pada ban ditunjukkan pada Gambar 2.1.

Seperti disebutkan di atas, ada karakteristik unik dalam gambar ban. Dibandingkan dengan cacat pada kain, cacat pada gambar ban kurang dapat dibedakan dari suku cadang yang bebas cacat. Oleh karena itu, deteksi cacat ban lebih menantang.



Gambar 2. Contoh Cacat pada Ban

### 2.1.3. Model CNN untuk Klasifikasi Citra

*Convolutional neural networks* (CNN), sebagai salah satu metode deep learning telah menetapkan tolok ukur dalam banyak tugas pemrosesan citra yang mencakup klasifikasi citra [7][8][9], pengenalan objek [9][10], dan segmentasi citra [12][13][14]. Performa seperti itu terutama karena digunakannya beberapa lapisan tersembunyi di CNN untuk menangkap fitur-fitur penting. Oleh karena itu, banyak peneliti mencoba mengembangkan arsitektur yang lebih dalam untuk meningkatkan kinerja mereka dalam tugas-tugas di atas.

Meskipun kita mungkin mendapat manfaat dari menggunakan banyak lapisan di CNN, membangun CNN yang memiliki performa tinggi itu tidaklah mudah, misalnya, kita tidak bisa hanya sekadar menyematkan lapisan dengan jumlah besar ke jaringan, tanpa memikirkan tugas dan efek yang ditimbulkan oleh masing-masing lapisan tersebut. Seperti yang telah disoroti oleh beberapa karya sebelumnya, menanamkan banyak lapisan untuk membangun jaringan saraf yang lebih dalam tanpa mekanisme khusus dapat menyebabkan masalah hilangnya gradien (*vanishing gradient problem*). Pertambahan jumlah layer mau tidak mau akan membuat jalur transmisi untuk informasi dan gradien semakin panjang. Akibatnya, fitur dari sisi lapisan input atau gradien dari sisi yang berlawanan bisa hilang sebelum mencapai tujuan.

Baru-baru ini, *Densely Connected Convolutional Networks (DenseNets)* [15] dan *Residual Neural Networks (ResNets)* [16] adalah dua jaringan populer untuk mengatasi masalah gradien yang hilang. Jaringan ini menggunakan konfigurasi konektivitas tertentu untuk memastikan sirkulasi informasi dan gradien. Modul residual yang memuat *skip connection* di ResNets memungkinkan aliran data melewati beberapa lapisan sehingga tidak hilang sebelum mencapai sisi yang diinginkan. Di sisi lain, DenseNets menerapkan pola konektivitas padat untuk melakukan tugas yang sama, memungkinkan setiap lapisan yang terlibat untuk terhubung ke semua lapisan berikutnya.

Keberhasilan penggunaan modul residual di ResNet menginspirasi modifikasi modul tersebut di model-model CNN terkini. Sebagai contoh, arsitektur *MobileNetV2* [17] didasarkan pada struktur residual terbalik di mana input dan output dari blok residual adalah lapisan bottleneck tipis yang berlawanan dengan model residual tradisional yang menggunakan representasi yang diperluas dalam input. *MobileNetV2* menggunakan konvolusi mendalam yang ringan untuk menyaring fitur di lapisan ekspansi menengah. Selain itu, telah diteliti bahwa penting untuk menghilangkan non-linearitas di lapisan sempit untuk mempertahankan kekuatan representasional. Hal ini mampu meningkatkan kinerja dan memberikan intuisi yang mengarah pada desain ini. Akhirnya, pendekatan ini memungkinkan pemisahan domain input/output dari ekspresi transformasi, yang menyediakan kerangka kerja yang nyaman untuk analisis lebih lanjut. Kinerja model *MobileNetV2* diukur pada klasifikasi Imagenet, deteksi objek COCO, segmentasi gambar VOC. Pengukuran mencakup evaluasi trade-off antara akurasi, dan jumlah operasi yang diukur dengan perkalian-tambahan (MDad), serta jumlah parameter.

Selain ResNet, DenseNet, dan *MobileNetV2*, terdapat pula model CNN *InceptionV3* [18], yang merupakan pengembangan dari model *GoogleNet* [7]. Desainer *InceptionV3* mengeksplorasi cara untuk meningkatkan jaringan dengan cara yang bertujuan memanfaatkan komputasi tambahan seefisien mungkin dengan konvolusi terfaktor yang sesuai dan regularisasi agresif. Mereka membandingkan metode yang dikembangkan pada set validasi tantangan klasifikasi ILSVRC 2012 menunjukkan keuntungan substansial atas keadaan seni: 21,2% kesalahan teratas-1 dan 5,6% teratas-5 untuk evaluasi bingkai tunggal menggunakan jaringan dengan biaya komputasi 5 miliar pengali- menambahkan per inferensi dan dengan menggunakan kurang dari 25 juta parameter. Dengan ansambel 4 model dan evaluasi multi-tanaman, mereka melaporkan kesalahan 3,5% teratas-5 pada set validasi (kesalahan 3,6% pada set pengujian) dan 17,3% kesalahan teratas-1 pada set validasi.

## 2.2. Akuisisi Data

Pengambilan data dilakukan dengan mengunduh citra ban dari <https://www.kaggle.com/datasets/jehanbhathe/tire-texture-image-recognition>. Ukuran setiap

citra pada dataset tersebut berukuran  $748 \times 748$  piksel dengan format JPG. Masing-masing citra dilengkapi dengan label normal atau cacat. Label ini diperlukan untuk melatih model CNN agar mampu membedakan ban normal dan cacat serta untuk mengukur performa model pada tahap pengujian. Rincian data penelitian disajikan pada Tabel 1.

**Tabel 1.** Rincian Data Penelitian

Kelas	Set	Jenis Ban	Jumlah Citra
0	Pelatihan	Normal	376
	Pengujian		115
1	Pelatihan	Cacat	327
	Pengujian		210

Set pelatihan berisikan citra ban yang digunakan pada tahap pelatihan beberapa arsitektur CNN seperti ResNet-50, MobileNetV2, InceptionV3, dan DenseNet-121 agar mampu membedakan kondisi ban normal dari kondisi ban cacat. Arsitektur-arsitektur tersebut dipilih oleh sebab mereka memiliki struktur-struktur khusus yang berguna untuk mencapai performa klasifikasi citra yang optimal. Adapun set pengujian berisikan citra ban yang digunakan pada untuk menguji arsitektur CNN terlatih.

### 2.3. Pelatihan Model CNN untuk Penilaian Kelayakan Ban

Sebagaimana telah dijelaskan sebelumnya, penelitian ini menggunakan beberapa arsitektur CNN untuk mengklasifikasikan ban ke kelas yang sesuai. Tahap pelatihan akan dijalankan dalam sejumlah epoch, dan pada setiap epoch, akan dihitung nilai fungsi rugi *cross entropy* yang menyatakan performa dari arsitektur CNN dalam mengklasifikasikan citra ban. Tahap pelatihan dijalankan sesuai dengan parameter pada Tabel 2.

**Tabel 2.** Parameter pelatihan arsitektur CNN

Parameter	Nilai
Ukuran citra	224×224 piksel
Epoch	100
Batchsize	32
Learning rate	$10^{-4}$
Optimizer	Adam
Loss function	Cross Entropy
Arsitektur	ResNet-50
	MobileNetV2
	InceptionV3
	DenseNet-121

### 2.4. Pengujian Model *Deep Learning* untuk Penilaian Kelayakan Ban

Pada tahap ini, arsitektur CNN terlatih digunakan untuk mengklasifikasikan citra ban yang berasal dari set pengujian. Performa klasifikasi pada set pengujian juga dinyatakan dalam bentuk nilai fungsi rugi *cross entropy*. Selain itu, dihitung pula nilai akurasi dan F-1 *score* yang menunjukkan persentase jumlah citra ban yang berhasil diklasifikasikan dengan benar terhadap jumlah seluruh citra ban pada set pengujian dan perbandingan jumlah citra ban cacat yang berhasil diklasifikasikan dengan benar terhadap jumlah prediksi positif (cacat). Akurasi dan F1-*score* dapat dihitung sesuai persamaan berikut.

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN}, \quad (1)$$

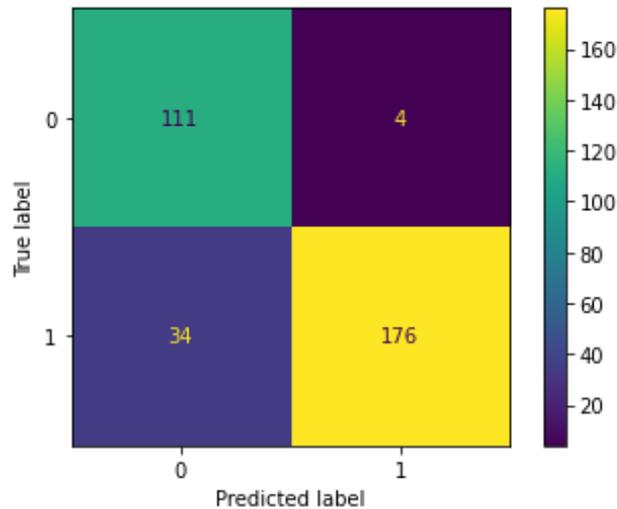
$$\text{F1 - score} = \frac{2 \times TP}{2 \times TP + FP + FN}, \quad (2)$$

dengan TP, TN, FP, dan FN menunjukkan true positive, true negative, false positive, dan false negative.

### 3. Hasil dan Pembahasan

#### 3.1. Model CNN ResNet-50

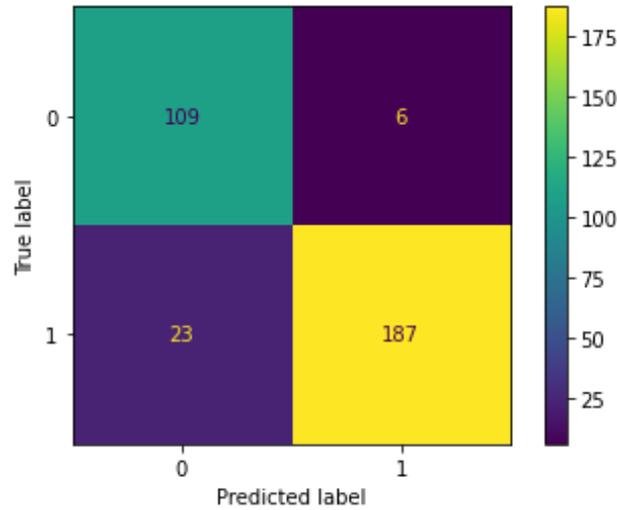
Gambar 3 menunjukkan *confusion matrix* hasil percobaan menggunakan model CNN ResNet-50, di mana '0' adalah kelas normal dan '1' adalah kelas cacat. Dari data yang ditampilkan oleh *confusion matrix* tersebut, model ResNet-50 telah berhasil mengklasifikasikan citra ban dengan akurasi 88,31% dan F-1 *score* 90,26%. Dari hasil yang diperoleh, dapat disimpulkan bahwa model ResNet-50 memiliki performa yang cukup baik, namun masih banyak ruang yang perlu diisi guna peningkatan performa.



Gambar 3. *Confusion Matrix* Hasil Percobaan menggunakan Model CNN ResNet-50.

#### 3.2. Model CNN MobileNetV2

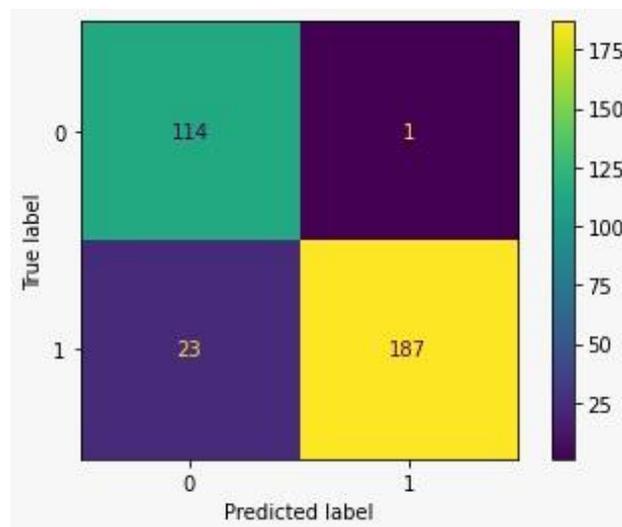
Gambar 4 menunjukkan *confusion matrix* hasil percobaan menggunakan model CNN MobileNetV2, di mana '0' adalah kelas normal dan '1' adalah kelas cacat. Dari data yang ditampilkan oleh *confusion matrix* tersebut, model MobileNetV2 telah berhasil mengklasifikasikan citra ban dengan akurasi 91,08% dan F-1 *score* 92,80%. Dari hasil yang diperoleh, dapat disimpulkan bahwa model MobileNetV2 memiliki performa lebih baik dibandingkan dengan model ResNet-50, terbukti dengan lebih tingginya nilai Akurasi dan F-1 *score* yang diperoleh. Padahal, model MobileNetV2 memiliki jumlah layer yang lebih sedikit (105 dibandingkan 107). Efektivitas MobileNetV2 utamanya dipengaruhi oleh pola koneksi residual terbalik (*inverted residual block*) yang dimilikinya.



Gambar 4. Confusion Matrix Hasil Percobaan menggunakan Model CNN MobileNetV2.

### 3.3. Model CNN DenseNet-121

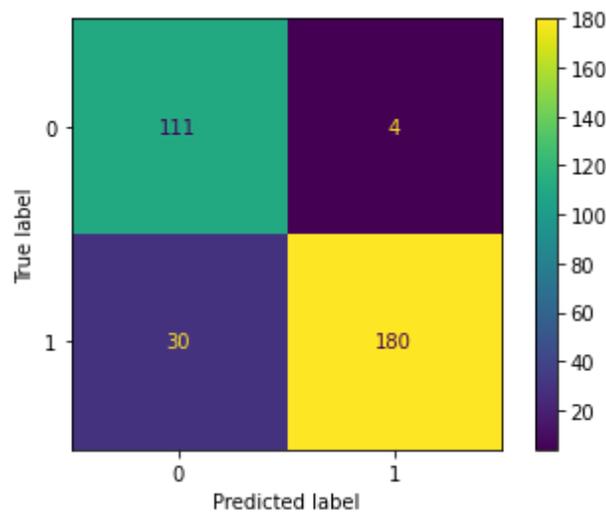
Gambar 5 menunjukkan *confusion matrix* yang memuat hasil pengujian pada percobaan menggunakan model CNN DenseNet-121, di mana '0' adalah kelas normal dan '1' adalah kelas cacat. Dari data yang ditampilkan oleh *confusion matrix* tersebut, model DenseNet-121 telah berhasil mengklasifikasikan citra ban dengan akurasi 92,62% dan F-1 score 93,97%. Dari hasil yang diperoleh, dapat disimpulkan bahwa model DenseNet-121 memiliki performa lebih baik dibandingkan dengan model ResNet-50 dan MobileNetV2, terbukti dengan lebih tingginya nilai Akurasi dan F-1 score yang diperoleh. Hal ini dikarenakan model DenseNet-121 memiliki jumlah layer yang lebih banyak (242 dibandingkan 105 dan 107). Meskipun begitu, DenseNet-121 membutuhkan waktu pelatihan yang sama setiap epohnya dibandingkan dengan model ResNet-50 dan MobileNetV2 (15 detik). Efektivitas DenseNet-121 utamanya dipengaruhi oleh pola koneksi padat (*Dense connection*) yang dimilikinya.



Gambar 5. Confusion Matrix Hasil Percobaan menggunakan Model CNN DenseNet-121.

### 3.4. Model CNN InceptionV3

Gambar 6 menunjukkan *confusion matrix* yang memuat hasil pengujian pada percobaan menggunakan model CNN InceptionV3, di mana '0' adalah kelas normal dan '1' adalah kelas cacat. Dari data yang ditampilkan oleh *confusion matrix* tersebut, model InceptionV3 telah berhasil mengklasifikasikan citra ban dengan akurasi 89,54% dan F-1 score 91,37%. Dari hasil yang diperoleh, dapat disimpulkan bahwa model InceptionV3 memiliki performa lebih baik dibandingkan dengan model ResNet-50, namun tidak lebih baik dari MobileNetV2 dan DenseNet-121. Hal ini menunjukkan bahwa arsitektur dasar InceptionV3 tidak sebaik koneksi residual terbalik pada MobileNetV2 dan koneksi padat pada DenseNet-121. Oleh sebab itu, keunggulan jumlah layer pada InceptionV3 tidak berpengaruh besar jika tidak diimbangi dengan struktur koneksi yang mumpuni, terbukti dari performanya yang lebih rendah dari MobileNetV2.



**Gambar 6.** *Confusion Matrix* Hasil Percobaan menggunakan Model CNN InceptionV3.

### 3.5. Rekapitulasi Hasil Percobaan

Hasil empat percobaan yang telah dilakukan menarik untuk dianalisis lebih lanjut. Analisis dalam hal ini mencakup observasi efek yang ditimbulkan variasi model CNN yang menghasilkan performa model terbaik. Tabel 3 menunjukkan rekapitulasi dari hasil lima percobaan yang telah dilaksanakan. Menurut Tabel 3, terdapat kecenderungan bahwa model DenseNet-121 memiliki performa terbaik, diikuti oleh MobileNetV2, InceptionV3, dan terakhir ResNet-50. Hal ini dapat dipahami sebab model DenseNet-121 memiliki keunggulan dalam hal jumlah layer, dibandingkan dengan model lainnya dan menjawab alasan DenseNet-21 memiliki akurasi lebih baik dari 3 model lainnya. Meskipun begitu, menarik untuk diperhatikan bahwa performa yang dimiliki MobileNetV2 mampu melampaui yang dicapai oleh ResNet50 dan InceptionV3, meskipun jumlahnya lebih sedikit. Hal ini mengindikasikan bahwa ada faktor selain jumlah layer yang menentukan performa suatu model CNN. Dalam hal ini, struktur koneksi residual terbalik pada MobileNetV2 tampaknya lebih unggul dari struktur koneksi residual biasa pada ResNet-50 dan struktur koneksi inception pada InceptionV3. Sejalan dengan hal ini, tampak bahwa struktur koneksi padat pada DenseNet-121 turut memengaruhi performa yang dihasilkan. Hal ini dikarenakan koneksi padat memungkinkan arsitektur DenseNet-121 untuk kembali mengakses informasi atau fitur pada lapisan-lapisan awal secara utuh yang bisa

jadi justru lebih bermanfaat bagi pembuatan keputusan akhir terkait kelayakan ban dibandingkan dengan fitur-fitur pada lapisan selanjutnya. Keunggulan DenseNet-121 atas ketiga arsitektur lainnya juga tercermin oleh penerapan keempat arsitektur tersebut pada basis data ImageNet<sup>1</sup>.

**Tabel 3.** Rekapitulasi Hasil Percobaan

<b>Model CNN</b>	<b>Jumlah Layer*</b>	<b>Akurasi (%)</b>	<b>F-1 Score (%)</b>
ResNet-50	107	88,31	90,26
MobileNetV2	105	91,08	92,80
DenseNet-121	242	<b>92,62</b>	<b>93,97</b>
InceptionV3	189	89,54	91,37

\* Jumlah layer meliputi banyaknya layer konvolusi, batch normalization, dan lain sebagainya.

#### **4. Kesimpulan dan Saran**

Pada penelitian ini, penulis telah mengaplikasikan sebuah metode berbasis deep learning yang mampu melakukan klasifikasi kelayakan ban secara otomatis. Metode yang diusulkan telah dibangun melalui beberapa tahap seperti akuisisi citra ban, pelatihan beberapa model CNN yang meliputi ResNet-50, MobileNetV2, InceptionV3, dan DenseNet-121, pengujian arsitektur CNN terlatih untuk mengklasifikasikan citra ban yang berasal dari set pengujian, dan penilaian performa dinyatakan dalam bentuk nilai fungsi rugi cross entropy. Selain itu, telah dihitung pula nilai akurasi yang menunjukkan persentase jumlah citra ban yang berhasil diklasifikasikan dengan benar terhadap jumlah seluruh citra ban pada set pengujian. Rekapitulasi dari hasil lima percobaan beberapa arsitektur convolutional neural network (CNN) yang telah dilaksanakan terdapat kecenderungan bahwa model DenseNet-121 memiliki performa terbaik, diikuti oleh EfficientNet-B0, MobileNetV2, InceptionV3, dan terakhir ResNet-50. Performa akurasi terbaik yang dimaksud dimiliki oleh model DenseNet-121 sebesar 92,62%. Untuk performa yang lebih baik, peneliti di masa mendatang dapat menerapkan tahap augmentasi seperti penskalaan acak, pergeseran acak, dan lain sebagainya pada data pelatihan.

<sup>1</sup> <https://keras.io/api/applications/>

## Daftar Pustaka

- [1] S. Erdogan, “Explorative spatial analysis of traffic accident statistics and road mortality among the provinces of Turkey,” *Journal of Safety Research*, vol. 40, no. 5, pp. 341–351, 2009.
- [2] X. Cui, Y. Liu, and C. Wang, “Defect automatic detection for tire X-ray images using inverse transformation of principal component residual,” in *2016 Third International Conference on Artificial Intelligence and Pattern Recognition (AIPR)*, 2016, pp. 1–8.
- [3] Y. Xiang, C. Zhang, and Q. Guo, “A dictionary-based method for tire defect detection,” in *2014 IEEE International Conference on Information and Automation (ICIA)*, 2014, pp. 519–523.
- [4] Q. Zhu and X. Ai, “The Defect Detection Method for Tire X-Ray Images Based on Deep Learning,” in *2018 IEEE 3rd International Conference on Image, Vision and Computing (ICIVC)*, 2018, pp. 138–142.
- [5] Y. Li, B. Fan, W. Zhang, and Z. Jiang, “TireNet : A high recall rate method for practical application of tire defect type classification,” *Future Generation Computer Systems*, vol. 125, pp. 1–9, 2021.
- [6] R. Wang, Q. Guo, S. Lu, and C. Zhang, “Tire Defect Detection Using Fully Convolutional Network,” *IEEE Access*, vol. 7, pp. 43502–43510, 2019.
- [7] C. Szegedy *et al.*, “Going deeper with convolutions,” in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2015, vol. 07-12-June, pp. 1–9.
- [8] Y. Jusman, I. M. Firdiantika, D. A. Dharmawan, and K. Purwanto, “Performance of multi layer perceptron and deep neural networks in skin cancer classification,” in *2021 IEEE 3rd Global Conference on Life Sciences and Technologies (LifeTech)*, 2021, pp. 534–538.
- [9] L. Listyalina and I. Mustiadi, “Accurate and Low-cost Fingerprint Classification via Transfer Learning,” in *2019 5th International Conference on Science in Information Technology: Embracing Industry 4.0: Towards Innovation in Cyber Physical System, ICSITech 2019*, 2019, pp. 27–32.
- [10] R. B. Girshick, J. Donahue, T. Darrell, and J. Malik, “Rich feature hierarchies for accurate object detection and semantic segmentation,” *CoRR*, vol. abs/1311.2, 2013.
- [11] J. Redmon, S. K. Divvala, R. B. Girshick, and A. Farhadi, “You Only Look Once: Unified, Real-Time Object Detection,” *CoRR*, vol. abs/1506.0, 2015.
- [12] L. Listyalina, I. Mustiadi, and D. A. Dharmawan, “Joint Dice and Intersection over Union Losses for Deep Optical Disc Segmentation,” in *2020 3rd International Conference on Biomedical Engineering (IBIOMED)*, 2020, pp. 49–54.
- [13] D. A. Dharmawan, D. Li, B. P. Ng, and S. Rahardja, “A New Hybrid Method for Retinal Vessels Segmentation on Fundus Images,” *IEEE Access*, vol. 7, pp. 41885–41896, 2019.
- [14] D. Li, D. A. Dharmawan, B. P. Ng, and S. Rahardja, “Residual U-Net for Retinal Vessel Segmentation,” in *2019 IEEE International Conference on Image Processing (ICIP)*,

2019, pp. 1425–1429.

- [15] G. Huang, Z. Liu, and K. Q. Weinberger, “Densely Connected Convolutional Networks,” *CoRR*, vol. abs/1608.0, 2016.
- [16] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 770–778.
- [17] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, “MobileNetV2: Inverted Residuals and Linear Bottlenecks,” *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 4510–4520, 2018.
- [18] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the Inception Architecture for Computer Vision.” arXiv, 2015.