

# Deteksi Kerusakan Ban Mobil Menggunakan Convolutional Neural Network dengan Arsitektur ResNet-34

Hendri candra mayana<sup>1</sup>, Desmarita Leni<sup>2\*</sup>

<sup>1</sup>Teknik Mesin, Politeknik Negeri Padang

<sup>2</sup>Teknik Mesin, Fakultas Teknik, Universitas Muhammadiyah Sumatera Barat

E-mail: desmaritaleni@gmail.com \*

## Abstract

The examination of tire damage can be categorized as part of vehicle maintenance with the aim of ensuring the tires are in good condition. Visual inspection using human observation has limitations, making it not always accurate and prone to errors in determining tire roadworthiness. This study designs a machine learning model using Convolutional Neural Network (CNN) with a ResNet-34 architecture to detect car tire damage. The parameters used in training this CNN model include the Adam optimizer, a learning rate of 0.0001, batch size 32, and 50 epochs. In this study, there are two predicted image classes: normal tires and damaged tires. The research results indicate that the CNN model with ResNet-34 architecture can predict both classes very well, as evidenced by the model evaluation results with an accuracy of 0.916, precision of 0.907, recall of 0.927, and an F1 score of 0.917. These results suggest that the CNN model with ResNet-34 architecture can be used as an effective tool for inspecting tire damage.

**Keywords:** Damage, Car Tires, CNN, Car Tire Damage, ResNet Architecture.

## Abstrak

Pemeriksaan kerusakan ban dapat dikategorikan sebagai bagian dari maintenance atau perawatan kendaraan dengan tujuan memastikan kondisi ban dalam keadaan baik. Pemeriksaan secara visual menggunakan pengamatan manusia memiliki keterbatasan sehingga tidak selalu akurat dan dapat mengakibatkan kesalahan dalam menentukan kelayakan ban. Penelitian ini merancang sebuah pemodelan machine learning menggunakan Convolutional Neural Network (CNN) dengan arsitektur ResNet-34 untuk mendeteksi kerusakan ban mobil. Parameter yang digunakan dalam pelatihan model CNN ini adalah optimizer Adam, learning rate 0.0001, batch size 32, dan epoch 50. Pada penelitian ini terdapat dua kelas citra yang diprediksi yaitu ban normal dan ban rusak. Hasil penelitian menunjukkan bahwa model CNN dengan arsitektur ResNet-34 mampu memprediksi kedua kelas dengan sangat baik, hal ini dapat dilihat dari hasil evaluasi model dengan nilai akurasi sebesar 0.916, presisi 0.907, recall 0.927, dan f1 score 0.917. Hasil ini mengindikasikan bahwa model CNN dengan arsitektur ResNet-34 dapat digunakan sebagai alat yang efektif dalam melakukan inspeksi kerusakan ban.

**Kata kunci :** Kerusakan, Ban Mobil, CNN, Kerusakan Ban Mobil, arsitektur ResNet

## 1. Pendahuluan

Inspeksi kelayakan ban merupakan sebuah proses yang sangat penting dalam menjaga keamanan dan keselamatan berkendara. Kerusakan ban pada kendaraan telah terbukti sebagai salah satu faktor utama penyebab kecelakaan lalu lintas. Menurut penelitian yang dilakukan oleh National Highway Traffic Safety Administration (NHTSA) pada tahun 2017, sekitar 9% dari total kecelakaan lalu lintas di

Amerika Serikat disebabkan oleh kerusakan ban atau kegagalan ban [1]. Fakta serupa juga terjadi di Indonesia, menurut Kementerian Perhubungan RI pada tahun 2015, sekitar 22,5% dari total kecelakaan lalu lintas di Indonesia disebabkan oleh faktor kendaraan, termasuk kerusakan ban [2]. Hal ini menunjukkan bahwa kondisi ban yang optimal merupakan salah satu elemen penting yang menentukan keselamatan berkendara. Inspeksi kerusakan ban dapat dikategorikan sebagai bagian dari *maintenance*

atau perawatan kendaraan di bidang teknik mesin. inspeksi kerusakan ban bertujuan untuk menjaga kondisi ban agar selalu dalam kondisi yang baik dan optimal, sehingga dapat meningkatkan performa kendaraan dan mencegah terjadinya kecelakaan yang disebabkan oleh kerusakan ban. Melakukan deteksi kelayakan ban secara teratur dapat membantu mengidentifikasi kerusakan ban sejak dini, sehingga dapat mengurangi kemungkinan terjadinya kerusakan pada bagian lain dari kendaraan serta meminimalisir biaya perawatan [3]. Pemeriksaan kelayakan ban pada umumnya masih dilakukan secara visual dengan pengamatan manusia untuk melihat apakah terdapat tanda-tanda keausan, kerusakan, atau cacat pada ban. Namun, deteksi visual masih terbatas oleh penglihatan manusia, sehingga tidak selalu akurat dan dapat mengakibatkan kesalahan dalam menentukan kelayakan ban. 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.

*Machine learning* merupakan salah satu aspek dalam Artificial Intelligence (AI) yang memungkinkan pembelajaran secara mandiri yang dilakukan oleh komputer. *Machine learning* mampu melakukan proses ekstraksi fitur dan klasifikasi pada suatu arsitektur yang sama. *Convolutional Neural Network (CNN)* merupakan salah satu metode machine learning yang dapat menyelesaikan permasalahan pengenalan pola dan klasifikasi pada objek citra [4],[5]. CNN memiliki beberapa jenis arsitektur, salah satunya adalah ResNet yang memiliki banyak layer dan menggunakan blok residu untuk mengatasi permasalahan *vanishing gradient* pada jaringan saraf yang sangat dalam. Blok residu pada ResNet terdiri dari dua lapisan konvolusi dengan ukuran filter 3x3 serta menggunakan shortcut connection untuk menghubungkan input dan output dengan adanya shortcut connection, ResNet dapat menghasilkan performa yang lebih baik dibandingkan dengan arsitektur jaringan saraf konvensional lainnya, terutama saat digunakan untuk *computer vision* seperti klasifikasi gambar atau deteksi objek. ResNet juga dapat dilatih dengan lebih mudah dan lebih

cepat dibandingkan dengan *deep neural networks* tanpa shortcut connection [6]. Hal ini memungkinkan pemodelan machine learning untuk melakukan pekerjaan yang berulang dan monoton seperti proses pemeriksaan kelayakan ban. Berbagai topik penelitian yang sudah dilakukan untuk mempermudah proses inspeksi kerusakan ban menggunakan CNN seperti melakukan deteksi cacat ban kendaraan menggunakan metode CNN yang menghasilkan akurasi sistem sebesar 91,39% [7]. Penelitian lain yang dilakukan White dkk [8]. membandingkan dua jenis arsitektur Convolutional Neural Network (CNN), yaitu Inception dan ResNet. Hasilnya menunjukkan bahwa meskipun bentuk arsitekturnya berbeda, kedua jenis arsitektur ini sangat mirip dalam mengekstrak informasi dari gambar. Namun, penelitian juga menemukan bahwa arsitektur ResNet lebih efektif dalam mendeteksi kerusakan ban. Berdasarkan hasil penelitian yang sudah diuraikan sebelumnya dapat memberikan gambaran bahwa arsitektur ResNet memiliki kinerja yang sangat baik dalam mengklasifikasikan data dalam bentuk visual seperti foto.

Berdasarkan permasalahan yang sudah diuraikan diatas maka, dirancang sebuah pemodelan machine learning untuk mendeteksi kelayakan ban kendaraan menggunakan algoritma *Convolutional Neural Network (CNN)* dengan arsitektur ResNet. Pemilihan algoritma CNN dengan arsitektur ResNet untuk mendeteksi kerusakan ban kendaraan pada penelitian ini, tidak terlepas dari performa ResNet yang sangat baik dalam klasifikasi citra. Pemodelan ini dilatih menggunakan data citra ban normal dan citra ban cacat (rusak), pencarian parameter terbaik digunakan *grid search*, kemudian model dievaluasi menggunakan metrik *accuracy*, *presisi*, *recall*, *f1-score* dan *confusion matrix*.

## 2. Methodologi

Penelitian ini bertujuan untuk merancang sebuah pemodelan Convolutional Neural Network (CNN) dengan arsitektur ResNet-34 untuk mendeteksi kelayakan ban dengan menggunakan data citra ban yang mengalami kerusakan serta ban yang dalam kondisi normal. Pada penelitian ini dilakukan pencarian parameter terbaik model dengan grid search dan model

dievaluasi menggunakan confusion matrix untuk menghitung akurasi, presisi, recall, dan F1-score. Model dibuat menggunakan bahasa pemrograman python dan dijalankan pada google colab. Adapun tahapan dalam penelitian ini dapat dilihat dilihat sebagai berikut :

### 1. Pengumpulan Data

Data untuk pelatihan dan pengujian model diperoleh langsung dari observasi lapangan seperti bengkel mobil khusus perbaikan ban, pusat service, tempat jual beli ban bekas, dan dealer mobil. Data yang diambil terdiri dari citra ban normal dan citra ban rusak, pengambilan data secara langsung dilapangan bertujuan untuk melatih model CNN yang mampu mendeteksi kerusakan ban sesuai kasus sebenarnya.

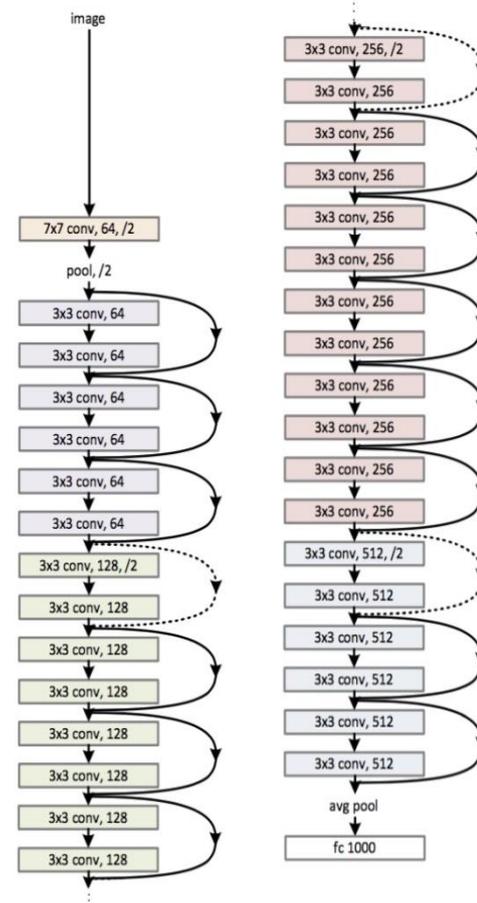
### 2. Preprocessing Data

Setelah data terkumpul, data citra ban disesuaikan ukurannya dengan menggunakan teknik preprocessing data sehingga sesuai dengan input model CNN yang akan dirancang. Proses preprocessing ini melibatkan beberapa tahapan, antara lain mengubah format gambar menjadi RGB, melakukan resizing gambar agar ukurannya sama, dan melakukan normalisasi intensitas piksel. Tahap ini juga dilakukan pembagian dataset menjadi data pelatihan dan data pengujian, dimana Data training digunakan untuk melatih model CNN dan data testing digunakan untuk menguji kinerja model CNN yang dihasilkan. Ukuran citra yang konsisten dapat memudahkan proses training dan pengolahan data, serta meningkatkan kinerja model CNN dalam mengenali citra ban yang normal dan rusak [9].

### 3. Pembuatan Model CNN

Setelah preprocessing data, selanjutnya adalah pembuatan model Convolutional Neural Network (CNN) menggunakan bahasa pemrograman Python dan framework TensorFlow. Arsitektur yang digunakan pada penelitian ini adalah ResNet-34, yang merupakan salah satu varian arsitektur ResNet dengan 34 layer, sama halnya dengan varian ResNet lainnya, ResNet-34 juga menggunakan blok residu untuk mengatasi permasalahan vanishing gradient pada jaringan saraf yang sangat dalam. Blok residu pada ResNet-34 terdiri dari dua lapisan konvolusi dengan ukuran filter 3x3 dan menggunakan shortcut connection untuk menghubungkan input dan output [10]. Gambar 1 menunjukkan arsitektur ResNet-34 yang akan digunakan untuk mendeteksi kerusakan ban mobil.

34-layer residual



Gambar 2. Ilustrasi arsitektur ResNet-34 [11]

Pada tugas klasifikasi ban rusak dan ban normal, ResNet-34 akan memproses citra ban menggunakan serangkaian layer konvolusi dan *max-pooling* untuk mengekstrak fitur-fitur penting dari citra ban. Kemudian, fitur-fitur tersebut akan disederhanakan dan diolah melalui beberapa *layer fully connected* (FC) untuk menghasilkan probabilitas kelas yang mungkin untuk citra tersebut.[12] Pada ResNet-34, terdapat 34 layer, termasuk layer konvolusi, *batch normalization*, dan *activation function* seperti ReLU (*Rectified Linear Unit*). Arsitektur ResNet-34 juga menggunakan konsep *skip connection* yang memungkinkan aliran informasi langsung dari layer input ke layer output pada blok konvolusi, sehingga dapat membantu mengatasi permasalahan degradasi performa pada model dengan banyak layer [13][14]. Parameter yang digunakan dalam pelatihan

model CNN ini adalah optimizer Adam, *learning rate* 0.0001, *batch size* 32, dan *epoch* 50.

#### 4. Pengujian dan Evaluasi Model

Tahap ini model yang sudah dilatih akan diuji dengan menggunakan data citra ban yang tidak ada pada data pelatihan. Evaluasi model dilakukan dengan menggunakan confusion matrix untuk menghitung akurasi, presisi, recall, dan F1-score [15].

- a. Accuracy : Merupakan rasio antara jumlah data yang terklasifikasi dengan benar (*true positive* dan *true negative*) dengan jumlah total data. *Accuracy* menggambarkan seberapa sering model dapat mengklasifikasikan data dengan benar. *Accuracy* dinyatakan dalam persentase dan semakin tinggi nilai *accuracy* semakin baik kinerja model, nilai *Accuracy* dapat dihitung menggunakan persamaan 1.

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

- b. Precision : Merupakan rasio antara jumlah data positif yang terklasifikasi benar (*true positive*) dengan jumlah data yang terklasifikasi positif oleh model (*true positive* dan *false positive*). Hal ini menggambarkan seberapa akurat model dalam mengklasifikasikan data sebagai positif, nilai *precision* dapat dihitung dengan persamaan 2.

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

- c. Recall : Adalah rasio antara jumlah data positif yang terklasifikasi benar (*true positive*) dengan jumlah data positif yang sebenarnya (*true positive* dan *false negative*). *Recall* menggambarkan seberapa sensitif model dalam mengklasifikasikan data yang sebenarnya positif, nilai *precision* dapat dihitung dengan persamaan 3.

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

- d. F1-score : Merupakan rata-rata harmonik antara *precision* dan *recall*, indikator ini menggambarkan keseimbangan antara *precision* dan *recall*, nilai F1-score dapat dihitung dengan persamaan 4.

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

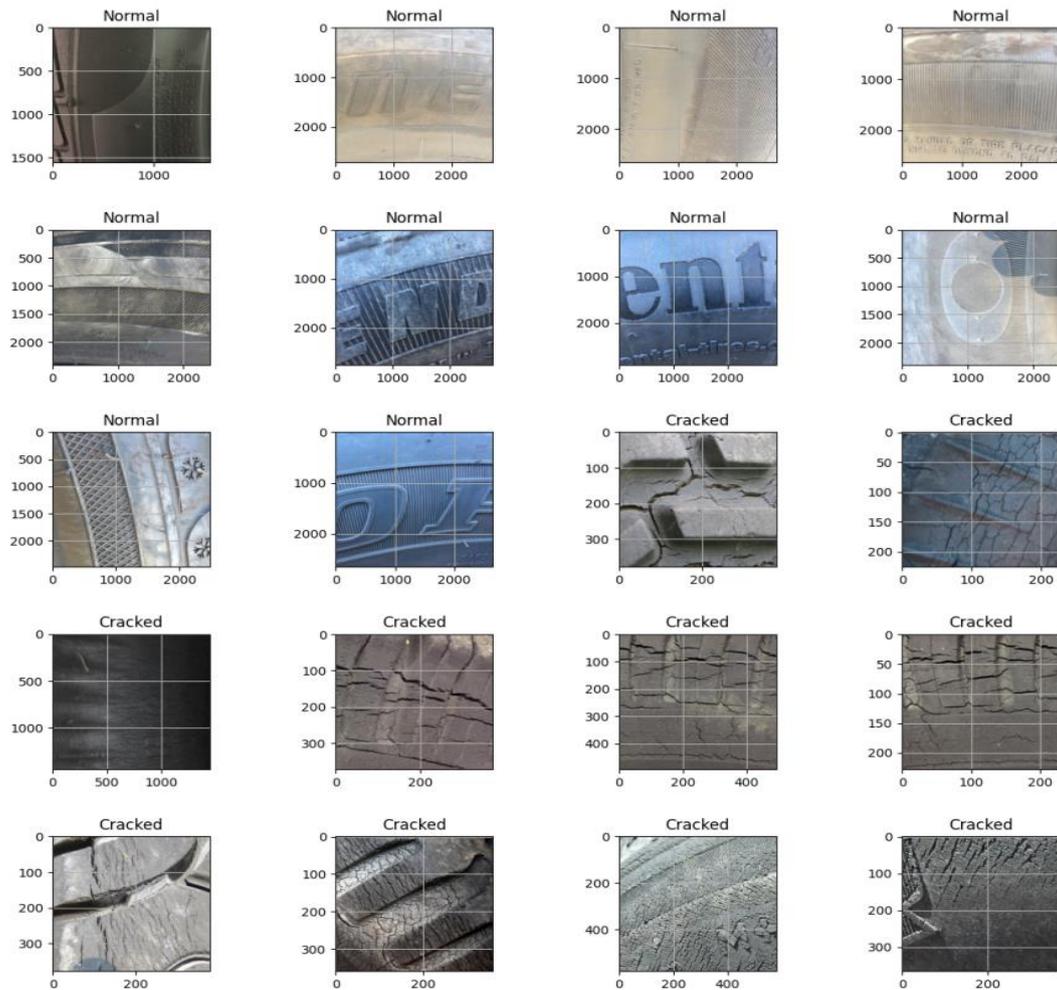
dengan TP, TN, FP, dan FN menunjukkan *true positive*, *true negative*, *false positive*, dan *false negative*.

### 3. Hasil dan Pembahasan

Penelitian ini bertujuan membuat sebuah pemodelan machine learning menggunakan CNN dengan arsitektur ResNet-34 untuk mendeteksi kelayakan ban, pemodelan ini dibuat dengan bahasa pemrograman python dan dijalankan dengan google colab (Colab). Colab adalah platform untuk melakukan pengembangan dan penelitian di lingkungan pemrograman Python yang disediakan oleh Google. Colab memungkinkan pengguna untuk menulis dan mengeksekusi kode Python di browser web tanpa harus menginstal atau mengonfigurasi lingkungan pemrograman di komputer pengguna [16]. Kelebihan menggunakan google colab dalam penelitian CNN ini adalah dapat mengakses dan menggunakan sumber daya yang mahal dan kompleks seperti mesin virtual yang kuat, tanpa harus mengeluarkan biaya besar untuk infrastruktur komputer.

#### 3.1 Data preparation

Dataset yang digunakan dalam penelitian ini berjumlah 762, terdiri dari 381 citra ban normal dan 381 citra ban yang mengalami kerusakan, kemudian citra ini diberi label sesuai kategori dan disimpan ke dalam folder google drive dengan nama *Cracked* untuk ban yang mengalami kerusakan dan *Normal* untuk ban normal. Sampel dataset pelatihan yang digunakan pada penelitian ini dapat dilihat pada Gambar 2. Tahap ini juga dilakukan pembagian dataset menjadi data pelatihan dan data pengujian, dimana Data training digunakan untuk melatih model dan data testing digunakan untuk menguji kinerja model. Resolusi citra yang digunakan pada penelitian ini adalah 256 x 256 piksel agar ukuran citra konsisten dan sesuai dengan kebutuhan model *Convolutional Neural Network* (CNN) yang akan dibangun. Ukuran citra yang konsisten dapat memudahkan proses training dan pengolahan data, serta meningkatkan kinerja model CNN dalam mengenali citra ban yang normal dan rusak.

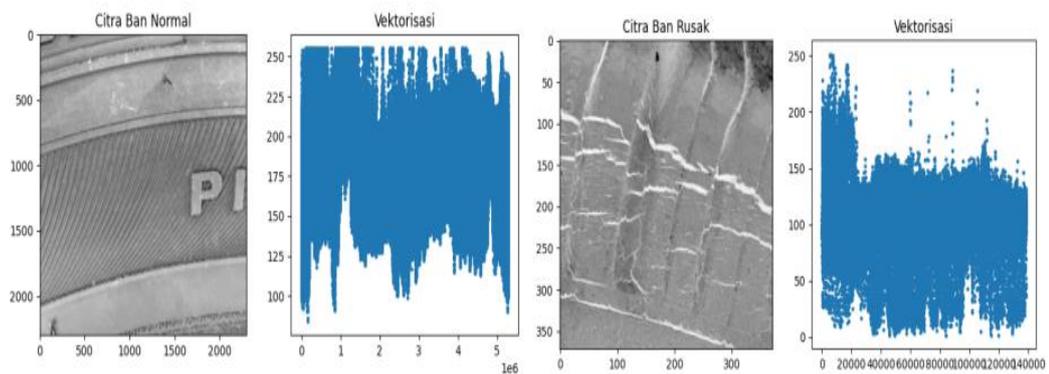


**Gambar 2.** Dataset ban normal dan rusak

### 3.2 Preprocessing data

Pada tahap ini, dataset dibagi menjadi data pelatihan dan data pengujian, yaitu 381 sampel untuk masing-masing kelas yang akan digunakan pada saat pelatihan model. Pada model klasifikasi menggunakan CNN dengan ResNet-34, citra digital diubah menjadi bentuk vektor sebelum digunakan sebagai input untuk model. Proses ini dikenal sebagai flattening atau vektorisasi dari citra. Setiap piksel dalam citra memiliki nilai intensitas yang merepresentasikan tingkat

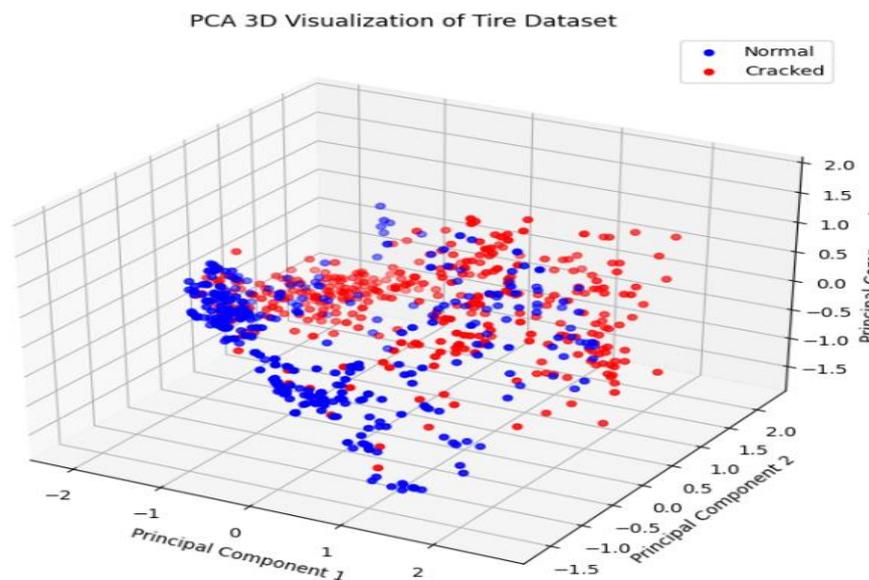
kecerahan pada lokasi tertentu [17]. Pada saat vektorisasi, setiap piksel dianggap sebagai fitur, dan nilai intensitas piksel tersebut diambil sebagai nilai fitur seperti yang dapat dilihat pada Gambar 3. Vektorisasi memungkinkan SVM, untuk mengambil representasi numerik dari citra dan bekerja dengan matriks atau vektor sebagai input. Hal ini mempermudah penggunaan algoritma machine learning yang umumnya dirancang untuk mengelola data dalam format vektor atau matriks.



**Gambar 3.** Hasil vektorisasi citra ban dalam kondisi normal dan rusak.

Berdasarkan gambar 3 dapat dilihat perbedaan bentuk vektor untuk setiap kelas, vektor ini nantinya akan digunakan sebagai fitur input dalam model CNN dengan ResNet-34. Hasil vektorisasi menunjukkan bahwa ketika resolusi gambar lebih tinggi, vektor yang dihasilkan dari gambar tersebut akan memiliki lebih banyak elemen, sehingga vektor menjadi lebih padat. Ini karena setiap piksel pada gambar akan diwakili oleh elemen di dalam vektor, dan semakin tinggi resolusinya, semakin banyak piksel yang ada. Pada beberapa kasus [18][19], terutama ketika dimensi vektor sangat tinggi, mengakibatkan proses analisis dan pemodelan menggunakan

seluruh dimensi menjadi terkendala. Pada kasus ini, teknik reduksi dimensi seperti Principal Component Analysis (PCA) dapat menjadi berguna. PCA adalah metode yang digunakan untuk mengurangi dimensi data dengan memproyeksikan data ke dalam ruang dimensi yang lebih rendah, yang disebut sebagai principal components. Principal components adalah kombinasi linear dari fitur-fitur asli yang memiliki varian yang maksimum [12]. Dengan menggunakan PCA, dapat mengurangi dimensi vektor gambar tanpa kehilangan informasi yang signifikan. Hasil reduksi dimensi ke kedua kelas menggunakan PCA dapat dilihat pada Gambar 4.



**Gambar 4.** Reduksi dimensi menggunakan PCA

### 3.3 Pengujian dan evaluasi model

Model ResNet-34 yang digunakan dalam penelitian ini menerapkan konsep blok residual untuk mengatasi potensi kendala degradasi yang timbul pada model. Proses ekstraksi fitur dimulai dengan penggunaan blok residual, kemudian diikuti oleh lapisan Global Average Pooling, yang menghasilkan representasi global dari gambar yang diberikan. Pada tahap terakhir, lapisan Dense bertanggung jawab untuk menghasilkan

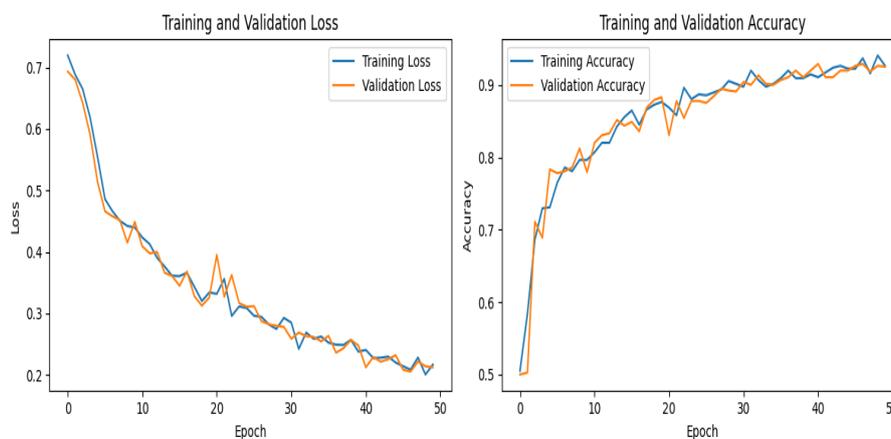
output klasifikasi, menunjukkan probabilitas terhadap setiap kelas. Detail parameter dan arsitektur yang digunakan selama pelatihan model dapat ditemukan dalam Tabel 1. Pendekatan ini dirancang untuk mengoptimalkan representasi fitur dan kemudahan pelatihan pada model ResNet-34, menjadikannya lebih mampu untuk menangani kompleksitas visual dari dataset yang dihadapi dalam konteks penelitian ini.

**Tabel 1.**  
Arsitektur model

Layer Type	Output Shape	Parameters	Function
Input	(32, 32, 3)	0	Lapisan input menerima gambar 32x32 piksel dengan 3 saluran RGB.
Convolution + MaxPooling	(16, 16, 64)	Conv: 9472, Pool: 0	Konvolusi dengan 64 filter (7x7) dan MaxPooling (3x3, stride 2).
Residual Blocks (x3)	(8, 8, 512)	Varied	Tiga set blok residual dengan lapisan konvolusi dan shortcut.
Global Average Pooling	(512,)	0	Mengurangkan dimensi spasial dan menghasilkan representasi global.
Fully Connected (Dense)	(10,)	5130	Lapisan output dengan fungsi aktivasi softmax untuk 10 kelas.

Model CNN dengan Resnet-34 untuk deteksi kelayakan ban pada penelitian ini memiliki arsitektur seperti pada tabel 1. dengan parameter optimizer Adam, learning rate 0.0001, batch size 32, dan epoch 50. Hasil pelatihan menggunakan CNN dengan ResNet-34 diperoleh training loss sebesar 0.18 dan validasi loss sebesar 0.19. Sedangkan akurasi pelatihan diperoleh sebesar 0.931 dan akurasi pelatihan sebesar 0.939. Hasil

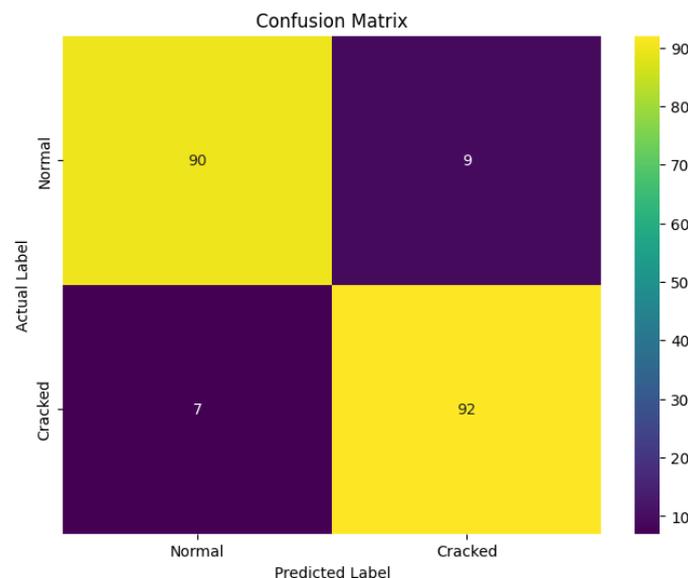
pelatihan model dapat dilihat pada gambar 5. Hasil evaluasi ini mencerminkan kinerja model yang baik dalam menyesuaikan diri dengan data latih, dengan tingkat keakuratan yang signifikan. Dengan demikian, model CNN dengan ResNet-34 ini menunjukkan potensi untuk menjadi solusi yang handal dalam mendeteksi kelayakan ban, sesuai dengan parameternya yang telah diatur sebelumnya.



**Gambar 5.** Accuracy dan loss ResNet-34.

Selanjutnya dilakukan uji dengan sampel data yang seimbang antar kelas, karena membantu mencegah bias evaluasi, memastikan relevansi model pada kasus penggunaan sebenarnya, meningkatkan deteksi ketidakseimbangan, mencegah overfitting pada kelas mayoritas, dan meningkatkan robustness model terhadap semua kelas. Dengan melakukan pengujian seimbang, dapat memastikan bahwa model memiliki kemampuan yang baik untuk mengenali dan mengklasifikasikan setiap kelas dengan adil, tanpa memihak pada kelas-kelas yang mungkin lebih banyak atau lebih sedikit dalam dataset. Model diuji dengan masing - masing 99 sampel untuk ban normal dan ban rusak, dimana model CNN dengan ResNet-34 mampu memprediksi

ban normal sebanyak 90 sampel dan memprediksi 9 sampel sebagai ban rusak. Sedangkan pada ban rusak model mampu memprediksi dengan lebih baik yaitu sebanyak 92 sampel di prediksi secara benar dan hanya 7 sampel yang di prediksi sebagai ban normal, seperti yang dapat dilihat pada gambar 6. Hasil evaluasi model menghasilkan nilai akurasi sebesar 0.916, presisi sebesar 0.907, recall sebesar 0.927, dan f1 score sebesar 0.917. Nilai-nilai tersebut mencerminkan kinerja model yang baik dalam memberikan prediksi yang akurat dan seimbang antara presisi dan recall. Dengan demikian, model ini dapat dianggap sebagai solusi yang andal untuk mengatasi tantangan klasifikasi gambar padasjenis kerusakan ban kendaraan.



**Gambar 6.** Confusion matrix

#### 4. Simpulan

Berdasarkan hasil penelitian tentang deteksi kerusakan ban mobil menggunakan convolutional neural network (CNN) dengan arsitektur ResNet-34 dapat disimpulkan bahwa ketika digunakan resolusi citra digital yang tinggi, hasil vektorisasi data cenderung lebih padat. Konsekuensinya, dimensi data menjadi lebih kompleks, yang pada gilirannya dapat memengaruhi waktu komputasi dan akurasi model. Untuk mengatasi permasalahan ini, penerapan metode Principal

Component Analysis (PCA) menjadi solusi yang efektif. PCA memungkinkan pengurangan dimensi pada data citra digital, sehingga model CNN dengan arsitektur ResNet-34 mampu membuat keputusan klasifikasi yang lebih optimal dan akurat dalam menentukan kelas ban normal dan ban rusak. Hal ini dapat dilihat dari nilai metrik evaluasi model, yang mampu memperoleh tingkat akurasi model yang cukup baik. Implementasi model ini dalam lingkungan manufaktur dapat mempercepat proses identifikasi kualitas ban, meminimalkan

kesalahan, dan secara keseluruhan meningkatkan efisiensi produksi dan keselamatan.

### Ucapan Terimakasih

Terimakasih kepada P3M Politeknik Negeri Padang Dana DIPA PNP Tahun 2023 yang telah mendanai penelitian ini dengan nomor kontrak: 142/PL9.15/PG/2023 tanggal 12 April 2023. Serta tidak lupa juga kepada semua pihak yang telah membantu penelitian ini bisa berlangsung dan berjalan dengan lancar.

### Daftar Pustaka

- [1] National Highway Traffic Safety Administration, et al. (2019). Traffic Safety Facts 2017 Data Older Population.
- [2] Kementerian Perhubungan RI. (2015). Analisis Kecelakaan Lalu Lintas Tahun 2015. Jakarta: Direktorat Jenderal Perhubungan Darat.
- [3] Sari, L. P. (2020). Analisa Performance Ban Pada Unit Produksi Overburden Hd-785 Terhadap Produktivitas Tambang Batubara. *KURVATEK*, 5(1), 69-79.
- [4] Xu, C., & Zhu, G. (2021). Intelligent manufacturing lie group machine learning: Real-time and efficient inspection system based on fog computing. *Journal of Intelligent Manufacturing*, 32(1), 237-249.
- [5] Oh, S., Cha, J., Kim, D., & Jeong, J. (2020, October). Quality inspection of casting product using CAE and CNN. In 2020 4th International Conference on Imaging, Signal Processing and Communications (ICISPC) (pp. 34-38). IEEE.
- [6] Targ, S., Almeida, D., & Lyman, K. (2016). Resnet in resnet: Generalizing residual architectures. arXiv preprint arXiv:1603.08029.
- [7] Li, Y., Fan, B., Zhang, W., & Jiang, Z. (2021). TireNet: A high recall rate method for practical application of tire defect type classification. *Future Generation Computer Systems*, 125, 1-9.
- [8] McNeely-White, D., Beveridge, J. R., & Draper, B. A. (2020). Inception and ResNet features are (almost) equivalent. *Cognitive Systems Research*, 59, 312-318.
- [9] Stojek, R., Pastuszczyk, A., Wróbel, P., & Kotyński, R. (2022). Single pixel imaging at high pixel resolutions. *Optics Express*, 30(13), 22730-22745.
- [10] Korfiatis, P., Kline, T. L., Lachance, D. H., Parney, I. F., Buckner, J. C., & Erickson, B. J. (2017). Residual deep convolutional neural network predicts MGMT methylation status. *Journal of digital imaging*, 30, 622-628.
- [11] Ilustrasi arsitektur resNet-34, <https://www.geeksforgeeks.org/introduction-to-residual-networks/?ref=rp>
- [12] Mhapsekar, M., Mhapsekar, P., Mhatre, A., & Sawant, V. (2020). Implementation of residual network (ResNet) for devanagari handwritten character recognition. In *Advanced Computing Technologies and Applications: Proceedings of 2nd International Conference on Advanced Computing Technologies and Applications—ICACTA 2020* (pp. 137-148). Springer Singapore.
- [13] Ibrahim, A., Peter, S., and Yuntong, S. (2018). Comparison of a vertically-averaged and a vertically-resolved model for hyporheic flow beneath a pool-riffle bedform. *J. Hydrol.* 557, 688–698. doi: 10.1016/j.jhydrol.2017.12.063
- [14] Targ, S., Almeida, D., & Lyman, K. (2016). Resnet in resnet: Generalizing residual architectures. arXiv preprint arXiv:1603.08029.
- [15] Leni, D., & Yermadona, H. (2023). Pemodelan Inspeksi Kerusakan Ban Mobil Menggunakan Convolutional Neural Network (CNN). *Jurnal Rekayasa Material, Manufaktur dan Energi*, 6(2), 176-186.
- [16] Gupta, A., Gupta, M., & Chaturvedi, P. (2020). Investing Data with Machine Learning Using Python. *Strategic System Assurance and Business Analytics*, 1-9.
- [17] Chan, L., Hosseini, M. S., & Plataniotis, K. N. (2021). A comprehensive analysis of weakly-supervised semantic segmentation in different image domains. *International Journal of Computer Vision*, 129, 361-384.

- [18] Clement, D., Agu, E., Suleiman, M. A., Obayemi, J., Adeshina, S., & Soboyejo, W. (2023). Multi-class breast cancer histopathological image classification using multi-scale pooled image feature representation (mpifr) and one-versus-one support vector machines. *Applied Sciences*, 13(1), 156.
- [19] Zhang, K., Zuo, W., Gu, S., & Zhang, L. (2017). Learning deep CNN denoiser prior for image restoration. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3929-3938).
- [20] Ma, J., & Yuan, Y. (2019). Dimension reduction of image deep feature using PCA. *Journal of Visual Communication and Image Representation*, 63, 102578.