

Pemodelan Inspeksi Kerusakan Ban Mobil Menggunakan *Convolutional Neural Network* (Cnn)

Desmarita Leni^{1*}, Halga Yermadona²

¹⁾ Teknik Mesin, Fakultas Teknik, Universitas Muhammadiyah Sumatera Barat

²⁾ Teknik Sipil, Fakultas Teknik, Universitas Muhammadiyah Sumatera Barat

*Email :desmaritaleni@gmail.com

ABSTRACT

Tire damage inspection can be categorized as part of vehicle maintenance with the aim of ensuring that the tire condition is in good condition. Visual inspection using human observation has limitations, making it not always accurate and can result in errors in determining tire suitability. This research designs a machine learning modeling using Convolutional Neural Network (CNN) to detect damage to mobile tires. The parameters used in the CNN model training are the Adam optimizer, learning rate 0.0001, batch size 16, and using the Early Stopping function. In this study, the CNN modeling was tested with two treatments, namely using a dataset without data augmentation and a dataset using data augmentation, then the results were evaluated using a confusion matrix. The results showed that data augmentation treatment can significantly improve model performance, with an increase in accuracy of 20%, precision of 14%, recall of 22%, and f1-score of 19% compared to treatment without data augmentation.

Keywords: Inspection, Modeling, Data Augmentation, Convolutional Neural Network (CNN)

PENDAHULUAN

Deteksi kelayakan ban merupakan sebuah proses yang sangat penting dalam menjaga keamanan dan keselamatan berkendara. Kerusakan ban kendaraan merupakan salah satu faktor penyebab kecelakaan lalu lintas, menurut penelitian yang dilakukan oleh *National Highway Traffic Safety Administration* (NHTSA) pada tahun 2017, sekitar 9% kecelakaan lalu lintas di Amerika Serikat disebabkan oleh kerusakan ban atau kegagalan ban [1], sama halnya dengan di Indonesia menurut Kementerian Perhubungan RI pada tahun 2015, sekitar 22,5% kecelakaan lalu lintas di Indonesia disebabkan oleh faktor kendaraan, termasuk kerusakan ban [2]. Deteksi kerusakan ban dapat dikategorikan sebagai bagian dari maintenance atau perawatan kendaraan di bidang teknik mesin. Deteksi 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.


Machine learning adalah salah satu cabang dari *artificial intelligence* (AI) yang memungkinkan komputer atau mesin belajar dari data yang diberikan dan model ini dapat meningkatkan kinerjanya seiring bertambahnya data pelatihan pada dataset [4]. *Machine learning* mampu melakukan proses belajar secara otomatis melalui pengolahan data dan melakukan prediksi serta pengambilan keputusan berdasarkan pola data pelatihan. *Convolutional Neural Network* (CNN) merupakan salah satu algoritma *machine learning* yang populer dan sangat efektif dalam mengenali pola pada data visual seperti gambar dan video [5]. CNN dapat mengklasifikasikan foto dengan memecah foto menjadi bagian-bagian yang lebih kecil (*filter*) dan memeriksa setiap bagian untuk menentukan kategori yang diinginkan, hal ini memungkinkan pemodelan machine learning untuk melakukan pekerjaan yang berulang dan monoton seperti proses pemeriksaan kelayakan ban. Banyak penelitian dan penerapan CNN dalam industri manufaktur seperti pemeriksaan produk

pengecoran logam yang mampu mendeteksi berbagai jenis cacat seperti *blow hole*, *chipping*, *crack*, dan *wash* secara otomatis dengan tingkat akurasi yang sangat tinggi yaitu 98% [6], selain itu CNN juga digunakan dalam mendeteksi kerusakan produk elektronik dengan jumlah data yang terbatas dan memiliki akurasi yang cukup baik [7]. Penelitian lain yang dilakukan Park.et.al, untuk deteksi cacat pada permukaan transmisi mesin menggunakan metode berbasis CNN dengan menggunakan satu kamera RGB. Cacat yang dapat dideteksi mencakup *craters*, *pores*, *foreign substances*, dan *fissures*, hasil sistem yang diusulkan menunjukkan performa yang sangat baik pada semua eksperimen yang dilakukan. Berdasarkan hasil penelitian yang sudah diuraikan sebelumnya dapat memberikan gambaran bahwa CNN memiliki kinerja yang sangat baik dalam mengklasifikasikan data dalam bentuk visual seperti foto.

Berdasarkan permasalahan yang telah diuraikan sebelumnya dan hasil penelitian yang memuaskan menggunakan CNN maka, penelitian ini bertujuan untuk merancang sebuah pemodelan Convolutional Neural Network (CNN) untuk mendeteksi kelayakan ban dengan menggunakan data citra ban yang mengalami kerusakan serta ban yang dalam kondisi normal. Evaluasi penelitian ini dilakukan menggunakan confusion matrix, dengan menganalisis perbandingan performa model CNN yang dilatih dengan penerapan augmentasi data dan model CNN tanpa augmentasi pada data pelatihan. Augmentasi data merupakan teknik untuk menghasilkan variasi data baru dari data asli dengan mengubah sedikit fitur-fitur pada gambar, seperti rotasi, pergeseran, perubahan ukuran, dan sebagainya. Tujuan dari augmentasi data adalah untuk meningkatkan jumlah sampel dalam dataset dan menciptakan variasi data yang lebih banyak sehingga dapat meningkatkan kemampuan model dalam mengenali data yang belum pernah dilihat sebelumnya.

METODE PENELITIAN

Penelitian ini bertujuan untuk merancang sebuah pemodelan *Convolutional Neural Network* (CNN) untuk mendeteksi kelayakan ban dengan menggunakan data citra ban yang mengalami kerusakan serta ban yang dalam kondisi normal. Penelitian ini di evaluasi menggunakan *confusion matrix* dan dianalisis perbandingan performa model CNN dengan penerapan augmentasi data pada saat pelatihan, dan tanpa augmentasi pada data pelatihan. Adapun tahapan dalam penelitian ini dapat dilihat pada Gambar 1.



Gambar 1. Tahapan penelitian

Data preparation

Tahap data preparation adalah tahap penting dalam membangun model CNN, karena kualitas data yang digunakan pada tahap training akan sangat mempengaruhi kinerja model CNN yang dihasilkan. Pada penelitian ini, data yang digunakan diperoleh dari situs kaggle.com. dimana total jumlah citra ban yang digunakan dalam penelitian ini adalah 1039, terdiri dari 500 citra ban normal dan 539 citra ban yang mengalami kerusakan. Dataset diperiksa secara menyeluruh untuk memastikan bahwa tidak ada citra duplikat atau citra yang tidak valid. Setelah dataset diperiksa secara menyeluruh kemudian dilakukan labeling, dimana dataset dikelompokkan kedalam dua kategori yaitu *cracked* untuk ban yang mengalami kerusakan dan *normal* untuk ban dalam kondisi normal.


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. 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 [9].

Augmentasi data

Augmentasi data adalah proses menghasilkan variasi data baru dari data yang sudah ada dengan melakukan transformasi pada data tersebut, seperti rotasi, pergeseran, perubahan ukuran, dan distorsi lainnya. Tujuan dari augmentasi data adalah untuk meningkatkan jumlah sampel dalam dataset dan menciptakan variasi data yang lebih banyak sehingga dapat meningkatkan kemampuan model dalam mengenali data yang belum pernah dilihat sebelumnya. Pemodelan menggunakan Convolutional Neural Network (CNN), augmentasi data dapat membantu meningkatkan akurasi model dan menghindari overfitting pada dataset [10]. Penelitian ini menggunakan 5 jenis transformasi yang diterapkan kedalam dataset pelatihan yang terdiri dari rotasi 10 derajat, flip horizontal, flip vertikal, blur, noise dan crop. Hasil augmentasi ini dapat memperbanyak jumlah dataset pelatihan, dimana satu citra ban dapat menghasilkan 5 citra ban baru.

Pemodelan Convolutional Neural Network (CNN)

Arsitektur pemodelan yang diusulkan pada penelitian ini dapat dilihat pada Gambar 2, dimana arsitektur CCN terdiri dari convolutional layer, pooling layer, Fully Connected Layer dan activation softmax.



Gambar 2. Arsitektur model CNN

Convolutional Layer digunakan untuk membuat fitur-fitur yang dapat membedakan antara gambar-gambar kerusakan dan gambar-gambar normal sedangkan pooling layer digunakan untuk membuat gambar menjadi lebih kecil dan membuat jaringan agar menghilangkan detail yang tidak perlu [11]. Setelah melalui beberapa layer convolutional dan pooling layer, model akan memasuki Fully Connected Layer yang bertujuan untuk menggabungkan fitur-fitur yang ada pada layer sebelumnya menjadi fitur-fitur yang lebih kompleks. Activation softmax adalah jenis fungsi aktivasi yang digunakan pada pemodelan ini, dimana fungsi ini digunakan pada output layer pada neural network yang melakukan klasifikasi multi-kelas. Fungsi softmax adalah mengubah nilai numerik pada setiap neuron pada output layer menjadi nilai probabilitas, sehingga total probabilitas dari semua kelas menjadi 1 [12].

Setelah arsitektur model CNN dibuat maka langkah selanjutnya adalah melakukan pelatihan model, tujuan dari pelatihan model adalah untuk menghasilkan model yang dapat digunakan untuk memprediksi hasil yang diinginkan berdasarkan input yang diberikan. Proses pelatihan model melibatkan pengoptimalan parameter-model agar dapat meminimalkan

kesalahan dalam prediksi dan meningkatkan kemampuan model dalam mengenali pola dari data. Pada penelitian ini menerapkan *grid search* untuk mencari parameter terbaik pada model, serta menggunakan 80% data *training* dan 20% data *testing*.

Pengujian dan evaluasi model

Setelah pemodelan CNN diperoleh, maka langkah selanjutnya mencari parameter terbaik menggunakan *grid search* parameter seperti *optimizer*, *learning rate*, dan *batch size*. Selanjutnya dilakukan pengujian model dengan parameter yang sudah didapatkan dengan *grid search*, kemudian dibandingkan hasil evaluasi model klasifikasi kelayakan ban menggunakan CNN dengan data asli dan data yang diaugmentasi. Evaluasi model dilakukan dengan menggunakan confusion matrix untuk menghitung akurasi, presisi, recall, dan F1-score [13]

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.

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

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.

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

c. Recall

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.

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

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.

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

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

HASIL DAN PEMBAHASAN

Penelitian ini bertujuan membuat sebuah pemodelan machine learning dengan CNN 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 [14]. 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.

Data preparation

Dataset yang digunakan dalam penelitian ini berjumlah 1039, terdiri dari 500 citra ban normal dan 539 citra ban yang mengalami kerusakan, kemudian citra ini diberi label sesuai

kategori dan disimpan kedalam 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 3. 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 3. Sampel dataset yang terdiri dari Cracked dan Normal


Augmentasi data

Augmentasi data merupakan sebuah metode yang digunakan untuk membuat data baru dari data yang sudah ada dengan cara melakukan transformasi data. Pada penelitian ini dataset yang sudah ada ditransformasi menjadi 6 jenis data baru yaitu, rotasi, flip vertikal, flip horizontal, crop, effect blur, dan effect noise. Hasil transformasi data menggunakan augmentasi data dapat digunakan untuk menambah jumlah dataset pelatihan, hal ini memungkinkan untuk meningkatkan performa model dalam mengklasifikasikan citra ban sesuai kategori. Banyak keuntungan menggunakan augmentasi data seperti [15] :

- Meningkatkan variasi data: dengan melakukan augmentasi pada data, variasi data yang ada menjadi lebih banyak. Hal ini penting karena semakin banyak variasi data yang ada, semakin baik kemampuan model dalam mengenali pola dan memprediksi data baru.
- Meningkatkan generalisasi model: dengan menggunakan augmentasi, model menjadi lebih tahan terhadap variasi data dan memiliki kemampuan yang lebih baik dalam mengenali objek yang berbeda dalam posisi, rotasi, dan ukuran yang berbeda. Hal ini juga membantu dalam menghindari overfitting.

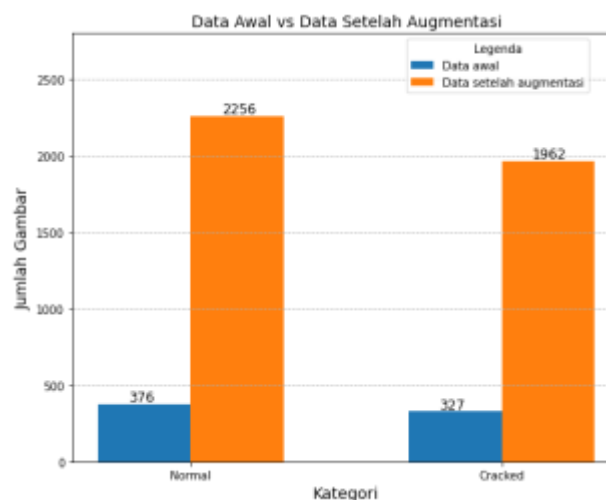
- c. Efisiensi waktu dan biaya: menggunakan augmentasi, dapat memperoleh lebih banyak data tanpa harus mengumpulkan data yang baru. Hal ini menghemat waktu dan biaya yang diperlukan untuk mengumpulkan data baru.
- d. Mengatasi ketidakhomogenan dataset: dataset yang tidak homogen dapat menyebabkan masalah pada model, seperti overfitting, dengan menggunakan augmentasi, dapat menghasilkan data baru yang homogen dan seimbang.

Berdasarkan kelebihan tersebut menggunakan jenis augmentasi seperti rotasi, flip vertikal, flip horizontal, crop, effect blur, dan effect noise dapat membantu dalam meningkatkan variasi data, meningkatkan generalisasi model, efisiensi waktu dan biaya, serta mengatasi ketidakhomogenan dataset. Penerapan augmentasi pada dataset pelatihan dapat diilustrasikan pada Gambar 4.



Gambar 4. Ilustrasi penerapan Augmentasi data

Augmentasi data ini hanya dilakukan terhadap data pelatihan saja sedangkan data pengujian menggunakan data asli yang tidak ada pada data pelatihan. Jumlah dataset pelatihan awal adalah 703 citra yang terdiri dari 376 citra ban dalam keadaan normal dan 327 citra ban dalam keadaan rusak, setelah dilakukan teknik augmentasi data terhadap dataset maka jumlah dataset pelatihan bertambah menjadi 2256 untuk ban normal dan 1962 untuk ban rusak seperti yang terlihat pada Gambar 5.



Gambar 5. Perbandingan dataset awal dan dataset setelah augmentasi

Pemodelan Convolutional Neural Network (CNN)

Model dibuat dengan arsitektur CNN menggunakan keras sequential, model ini terdiri dari beberapa lapisan layer, untuk melakukan klasifikasi gambar pada dataset citra ban yang telah diaugmentasi. Model ini menggunakan *optimizer* Adam dengan *learning rate* sebesar 0,0001, *batch size* 16 dan fungsi *loss mean squared error* untuk mengukur kesalahan prediksi model. Selain itu, model ini juga menggunakan beberapa teknik augmentasi gambar seperti *rotasi*, pergeseran, dan *flipping*, yang diimplementasikan melalui *ImageDataGenerator*. Model dilatih menggunakan *learning rate scheduler* dan *callbacks* seperti *EarlyStopping*, yang akan menghentikan pelatihan jika tidak ada peningkatan pada akurasi validasi. Arsitektur model CNN yang digunakan pada percobaan ini dapat dilihat pada tabel 1.

Tabel 1. arsitektur model cnn yang digunakan

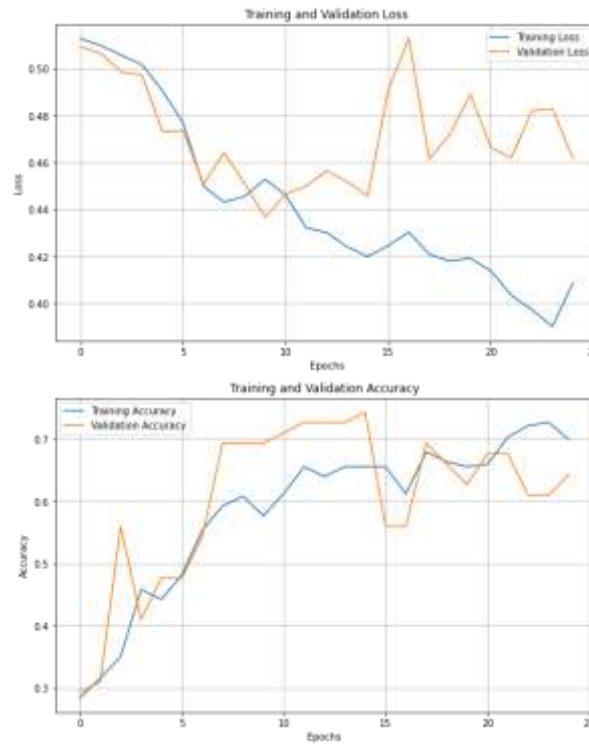
Layer Type	Output Shape
Input Layer	(256, 256, 2)
Convolutional Layer 1	(256, 256, 25)
MaxPooling Layer 1	(128, 128, 25)
Convolutional Layer 2	(128, 128, 32)
MaxPooling Layer 2	(64, 64, 32)
Convolutional Layer 3	(64, 64, 32)
MaxPooling Layer 3	(32, 32, 32)
Flatten Layer	32768
Dense Layer 1	512
Dense Layer 2	2

Tabel 1. menunjukkan arsitektur CNN yang digunakan untuk mengklasifikasikan citra ban menjadi dua kategori, yaitu normal dan rusak. Arsitektur CNN ini terdiri dari beberapa jenis layer dengan masing-masing output shape atau bentuk keluaran yang berbeda. Pertama data masukan diolah melalui Input Layer dengan ukuran 256x256 piksel dan 2 channel (karena hanya terdapat 2 kategori). Kemudian, data masukan diproses melalui tiga Convolutional Layer dengan masing-masing menghasilkan output shape 256x256x25, 128x128x32, dan 64x64x32. Selanjutnya, setiap output layer dari Convolutional Layer diolah melalui MaxPooling Layer dengan masing-masing menghasilkan output shape 128x128x25, 64x64x32, dan 32x32x32. Setelah itu, data masukan melalui Flatten Layer untuk mengubah output dari MaxPooling Layer menjadi sebuah vektor 1 dimensi dengan ukuran 32768. Kemudian, vektor tersebut diproses melalui Dense Layer 1 yang menghasilkan output dengan ukuran 512. Terakhir, data masukan melalui Dense Layer 2 yang memiliki 2 unit (karena hanya terdapat 2 kategori) dan menggunakan fungsi aktivasi softmax untuk menghasilkan probabilitas kelas untuk setiap citra yang diklasifikasikan.


Pengujian dan evaluasi model

Model CNN untuk deteksi kelayakan ban pada penelitian ini memiliki arsitektur seperti pada tabel 1. dengan parameter optimizer Adam, learning rate 0.0001, dan batch size 32. Pengujian terdiri dari dua percobaan yaitu pengujian model menggunakan data asli dan pengujian menggunakan data yang sudah diaugmentasi. Hasil yang diperoleh dapat dilihat bahwa model CNN dengan data asli, didapatkan nilai loss training sebesar 0.408 dan loss validation sebesar 0.461. Nilai akurasi training pada model ini sebesar 0.699, dan nilai akurasi validation sebesar 0.643. Sedangkan pada model CNN dengan data augmentasi, didapatkan nilai loss training sebesar 0.245 dan loss validation sebesar 0.267. Nilai akurasi training pada model ini sebesar 0.836,

sedangkan nilai akurasi validation sebesar 0.75. Hasil accuracy dan loss model menggunakan CNN dengan data asli dan data augmentasi dapat dilihat pada Gambar 6 dan Gambar 7.

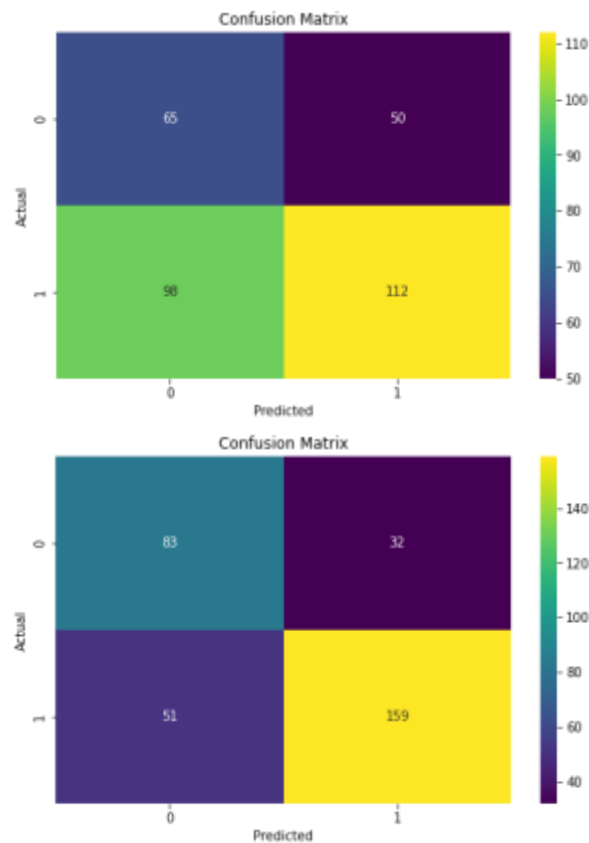


Gambar 6. Accuracy dan loss menggunakan data asli



Gambar 7. Accuracy dan loss menggunakan augmentasi data

Berdasarkan hasil yang diperoleh, dapat dilihat bahwa penggunaan data augmentasi pada pelatihan model CNN berhasil meningkatkan performa model secara signifikan. Nilai loss training menggunakan data augmentasi dapat ditekan hingga 40%, dan loss validasi sebesar 42% dibandingkan dengan data asli. Sedangkan untuk accuracy, pada data pelatihan model dengan data augmentasi berhasil meningkatkan accuracy sebesar 19,6% dan pada data testing sebesar 16,% dibandingkan model dengan data asli. Peningkatan performa tersebut terjadi karena penggunaan data augmentasi membantu model untuk lebih baik dalam mempelajari pola-pola dalam data, karena data yang sudah di augmentasi memiliki variasi yang lebih tinggi dan berbeda-beda. Selain itu, dengan menggunakan data augmentasi, model juga mampu mengurangi overfitting pada data training dan dapat meningkatkan generalisasi model pada data testing [16]. Hasil ini menunjukkan bahwa penggunaan data augmentasi pada CNN untuk mendeteksi kelayakan ban dapat meningkatkan performa model, dengan menurunkan loss dan meningkatkan akurasi. Penggunaan data augmentasi dapat dianggap sebagai teknik yang efektif untuk mengatasi masalah kurangnya jumlah data atau variasi dalam data pada suatu tugas klasifikasi Gambar 8 [17].



Gambar 8. Confusion Maxtrix

Hasil pengujian citra ban dengan total 325, yang terdiri dari 115 citra Normal dan 210 citra Cracked, diperoleh nilai confusion matrix dengan menggunakan data asli sebesar 0.54 untuk accuracy, 0.69 untuk presisi, 0.53 untuk recall, dan 0.60 untuk f1-score. Sedangkan, dengan menggunakan data augmentasi diperoleh nilai confusion matrix sebesar 0.74 untuk accuracy, 0.83 untuk presisi, 0.75 untuk recall, dan 0.79 untuk f1-score. Berdasarkan hasil tersebut dapat disimpulkan bahwa penggunaan data augmentasi dalam pelatihan model CNN pada dataset citra ban dapat meningkatkan performa model secara signifikan. Terlihat dari peningkatan nilai accuracy sebesar 37%, presisi sebesar 20%, recall sebesar 41%, dan f1-score sebesar 32% pada data

augmentasi dibandingkan dengan data asli. Hal ini menunjukkan bahwa data augmentasi dapat membantu model dalam mempelajari fitur-fitur penting pada citra dan meningkatkan kemampuan model dalam mengenali kondisi Normal atau Cracked pada ban.

Hasil confusion matrix menunjukkan bahwa terdapat perbedaan yang signifikan pada nilai true positive dan false positive pada kedua metode tersebut. Pada penelitian ini, penggunaan data augmentasi mampu menurunkan nilai false positive sebesar 18 citra dan meningkatkan nilai true positive sebesar 47 citra dibandingkan dengan penggunaan data asli. Hal ini dapat membantu mengurangi kemungkinan kesalahan diagnosis pada citra yang sebenarnya Normal namun terdeteksi sebagai Cracked (false positive) dan meningkatkan akurasi diagnosis kondisi ban yang sebenarnya Cracked (true positive). Secara keseluruhan, penggunaan data augmentasi pada pelatihan model CNN dapat membantu meningkatkan performa model dalam mempelajari fitur-fitur pada citra dan meningkatkan akurasi diagnosis kondisi Normal atau Cracked pada citra ban. Namun, penggunaan data augmentasi juga dapat mempengaruhi kecepatan pelatihan dan membutuhkan sumber daya komputasi yang lebih besar.

KESIMPULAN

Berdasarkan hasil pengujian pemodelan machine learning untuk deteksi kelayakan ban menggunakan Convolutional Neural Network (CNN) dengan data asli dan data augmentasi, didapatkan kesimpulan sebagai berikut: (1) Data augmentasi mampu meningkatkan kinerja model dengan signifikan. Hal ini dapat dilihat dari peningkatan nilai akurasi, presisi, recall, dan f1-score pada pengujian dengan data augmentasi dibandingkan dengan pengujian menggunakan data asli. Nilai akurasi pada pengujian dengan data augmentasi meningkat sebesar 20% dibandingkan dengan pengujian menggunakan data asli. Selain itu, nilai presisi pada pengujian dengan data augmentasi meningkat sebesar 14%, recall meningkat sebesar 22%, dan f1-score meningkat sebesar 19% dibandingkan dengan pengujian menggunakan data asli. (2) Hasil dari pengujian Confusion Matrix menunjukkan bahwa dengan menggunakan data augmentasi, model mampu lebih akurat memprediksi kondisi ban yang normal dan ban dalam keadaan rusak. Hal ini ditunjukkan dari nilai confusion matrix yang lebih baik pada pengujian dengan data augmentasi, di mana nilai true positive (TP) pada kelas Normal meningkat sebesar 18%, dan pada kelas Cracked meningkat sebesar 26% dibandingkan dengan pengujian menggunakan data asli. Ini menunjukkan secara jelas bahwa, penggunaan data augmentasi pada training model CNN dapat meningkatkan kinerja model secara signifikan dalam melakukan deteksi kelayakan ban.

UCAPAN TERIMAKASIH

Terimakasih kepada LPPM Universitas Muhammadiyah Sumatera Barat dan Pimpinan Pusat Muhammadiyah dalam Pelaksanaan Hibah Internal Tahun 2023 yang telah mendanai penelitian ini nomor: 08/LPPM.UMSB/K.P-HBI/08/2023. 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. Traffic Safety Facts 2017 Data Older Population. 2019.
- [2] Kementerian Perhubungan RI. (2015). Analisis Kecelakaan Lalu Lintas Tahun 2015. Jakarta: Direktorat Jenderal Perhubungan Darat.
- [3] SARI, Laura Puspita. ANALISA PERFORMANCE BAN PADA UNIT PRODUKSI OVERBURDEN HD-785 TERHADAP PRODUKTIVITAS TAMBANG BATUBARA. *KURVATEK*, 2020, 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] NGUYEN, Thong Phi, et al. Inspecting method for defective casting products with convolutional neural network (CNN). *International Journal of Precision Engineering and Manufacturing-Green Technology*, 2021, 8: 583-594.
- [7] ZHANG, Mei, et al. The application of one-class classifier based on CNN in image defect detection. *Procedia computer science*, 2017, 114: 341-348.
- [8] PARK, Je-Kang; AN, Woo-Hyun; KANG, Dong-Joong. Convolutional neural network based surface inspection system for non-patterned welding defects. *International Journal of Precision Engineering and Manufacturing*, 2019, 20: 363-374.
- [9] SULTANA, Farhana; SUFIAN, Abu; DUTTA, Paramartha. Advancements in image classification using convolutional neural network. In: *2018 Fourth International Conference on Research in Computational Intelligence and Communication Networks (ICRCICN)*. IEEE, 2018. p. 122-129.
- [10] SANJAYA, Joseph; AYUB, Mewati. Augmentasi Data Pengenalan Citra Mobil Menggunakan Pendekatan Random Crop, Rotate, dan Mixup. *Jurnal Teknik Informatika dan Sistem Informasi*, 2020, 6.2.
- [11] Zhang, R., Zheng, Y., Mak, T. W. C., Yu, R., Wong, S. H., Lau, J. Y., & Poon, C. C. (2016). Automatic detection and classification of colorectal polyps by transferring low-level CNN features from nonmedical domain. *IEEE journal of biomedical and health informatics*, 21(1), 41-47.
- [12] Peng, H., Li, J., Song, Y., & Liu, Y. (2017, February). Incrementally learning the hierarchical softmax function for neural language models. In *Proceedings of the AAAI Conference on Artificial Intelligence* (Vol. 31, No. 1).
- [13] Kareem, S., Hamad, Z. J., & Askar, S. (2021). An evaluation of CNN and ANN in prediction weather forecasting: A review. *Sustainable Engineering and Innovation*, 3(2), 148.
- [14] HANDAYANI, Anik Nur, et al. Development of e-collab classroom for cnn practice on electrical engineering, universitas negeri malang. In: *2020 4th International Conference on Vocational Education and Training (ICOVET)*. IEEE, 2020. p. 47-51.
- [15] HERNÁNDEZ-GARCÍA, Alex; KÖNIG, Peter. Further advantages of data augmentation on convolutional neural networks. In: *Artificial Neural Networks and Machine Learning–ICANN 2018: 27th International Conference on Artificial Neural Networks*, Rhodes, Greece, October 4-7, 2018, Proceedings, Part I 27. Springer International Publishing, 2018. p. 95-103.
- [16] KHOSLA, Cherry; SAINI, Baljit Singh. Enhancing performance of deep learning models with different data augmentation techniques: A survey. In: *2020 International Conference on Intelligent Engineering and Management (ICIEM)*. IEEE, 2020. p. 79-85.
- [17] PEREZ, Luis; WANG, Jason. The effectiveness of data augmentation in image classification using deep learning. *arXiv preprint arXiv:1712.04621*, 2017.