

**KLASIFIKASI KERUSAKAN PADA BAN MENGGUNAKAN
CNN DENGAN ARSITEKTUR *MOBILENET***

SKIRPSI

NURUL ALMADINAH PANE

198160007



PROGRAM STUDI TEKNIK INFORMATIKA

FAKULTAS TEKNIK

UNIVERSITAS MEDAN AREA

2024

UNIVERSITAS MEDAN AREA

© Hak Cipta Di Lindungi Undang-Undang

1. Dilarang Mengutip sebagian atau seluruh dokumen ini tanpa mencantumkan sumber
2. Pengutipan hanya untuk keperluan pendidikan, penelitian dan penulisan karya ilmiah
3. Dilarang memperbanyak sebagian atau seluruh karya ini dalam bentuk apapun tanpa izin Universitas Medan Area

Document Accepted 2/1/25

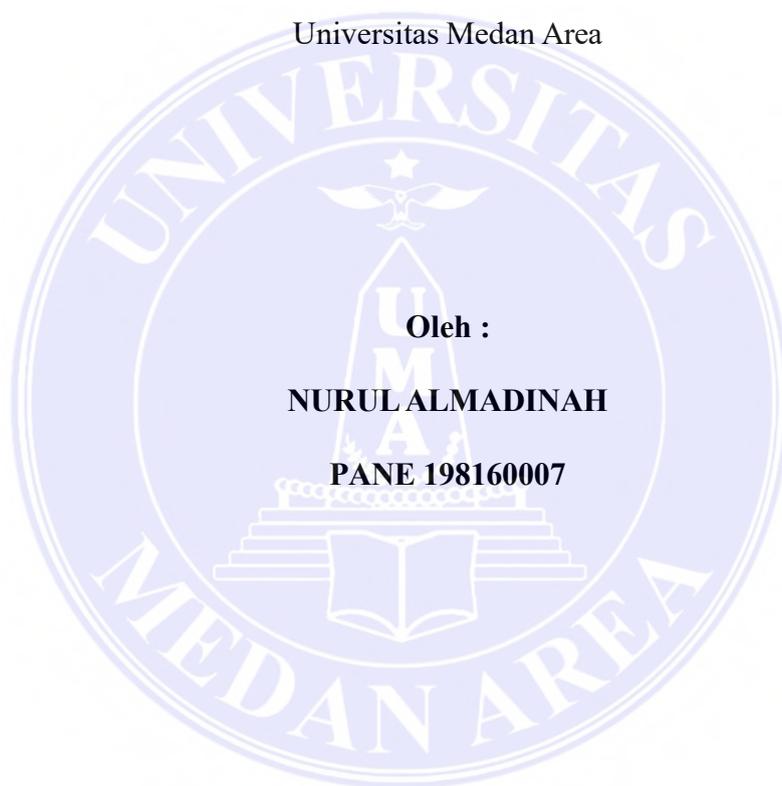
Access From (repository.uma.ac.id)2/1/25

**KLASIFIKASI KERUSAKAN PADA BAN MENGGUNAKAN CNN
DENGAN ARSITEKTUR *MOBILENET***

SKRIPSI

Diajukan Sebagai salah satu syarat untuk
memperoleh Gelar Sarjana di Fakultas Teknik

Universitas Medan Area



Oleh :

NURUL ALMADINAH

PANE 198160007

FAKULTAS TEKNIK

PROGRAM STUDI TEKNIK INFORMATIKA

UNIVERSITAS MEDAN AREA

2024

UNIVERSITAS MEDAN AREA

© Hak Cipta Di Lindungi Undang-Undang

1. Dilarang Mengutip sebagian atau seluruh dokumen ini tanpa mencantumkan sumber
2. Pengutipan hanya untuk keperluan pendidikan, penelitian dan penulisan karya ilmiah
3. Dilarang memperbanyak sebagian atau seluruh karya ini dalam bentuk apapun tanpa izin Universitas Medan Area

LEMBAR PENGESAHAN

Judul Skripsi : *Klasifikasi Kerusakan Pada Ban Menggunakan CNN Dengan Arsitektur MobileNet*
Nama Mahasiswa : Nurul Almadinah Pane
NPM : 198160007
Fakultas : Teknik Informatika

Disetujui Oleh
Komisi Pembimbing


Muhathir, ST., M.Kom

Pembimbing

Dekan Fakultas Teknik



Pratiyo, ST., M.T
NIDN : 0102027402

Ketua Prodi Teknik Informatika



Riki Muliono, S.Kom, M.Kom
NIDN : 0109038902

Tanggal Lulus : Agustus 2024

HALAMAN PERNYATAAN

Saya menyatakan bahwa skripsi yang saya susun, sebagai syarat memperoleh gelar sarjana merupakan hasil karya tulis saya sendiri. Adapun bagian-bagian tertentu dalam penulisan skripsi ini yang saya kutip dari hasil karya orang lain telah dituliskan sumbernya secara jelas sesuai dengan norma, kaidah, dan etika penulisan ilmiah.

Saya bersedia menerima sanksi pencabutan gelar akademik yang saya peroleh dan sanksi- sanksi lainnya dengan peraturan yang berlaku, apabila di kemudian hari ditemukan adanya plagiat dalam skripsi ini.

Medan, Agustus 2024



Nurul Almadinah Pane
198160007

HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS AKHIR/SKRIPSI/TESIS UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademik Universitas Medan Area, saya yang bertanda tangan di bawah ini:

Nama : Nurul Almadinah Pane
NPM : 198160007
Program Studi : Teknik Informatika
Fakultas : Teknik
Jenis karya : Tugas Akhir/Skripsi/Tesis

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Medan Area **Hak Bebas Royalti Noneksklusif (Non-exclusive Royalty-Free Right)** atas karya ilmiah saya yang berjudul : **“Klasifikasi Kerusakan Pada Ban Menggunakan CNN Dengan Arsitektur MobileNet”** Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Noneksklusif ini Universitas Medan Area berhak menyimpan, mengalihmedia/format-kan, mengelola dalam bentuk pangkalan data (*database*), merawat, dan memublikasikan tugas akhir/skripsi/tesis saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta. Demikian pernyataan ini saya buat dengan sebenarnya.

Dibuat di : Medan

Pada tanggal : Agustus 2024

Yang menyatakan

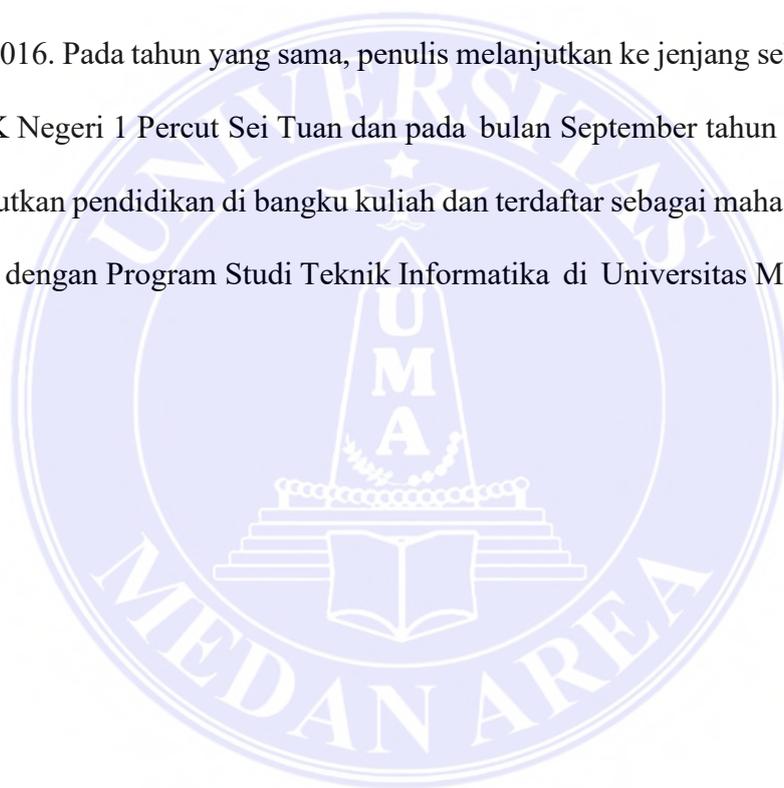


Nurul Almadinah Pane
198160007

 Dipindai dengan CamScanner

RIWAYAT HIDUP

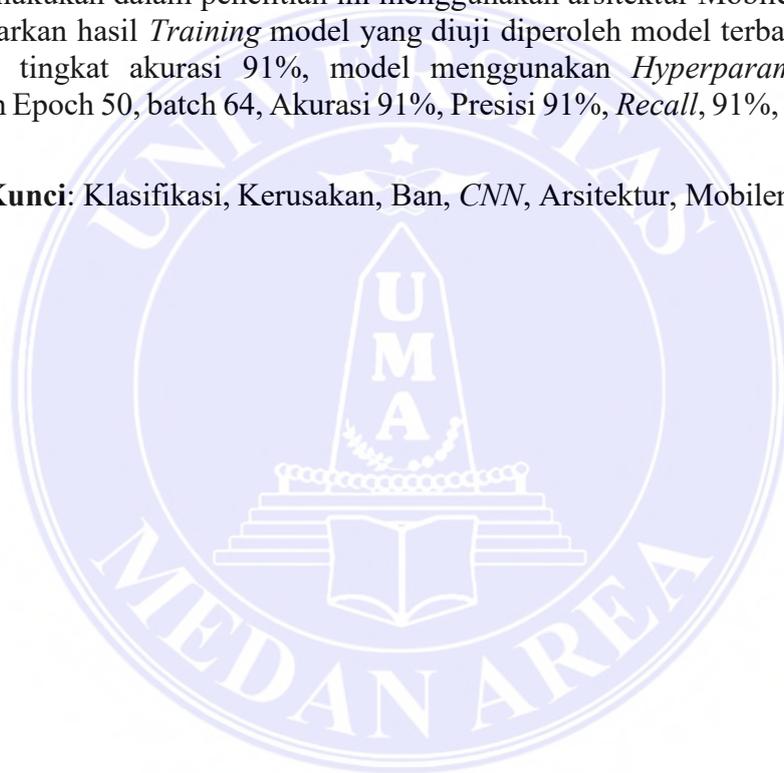
Penulis dilahirkan di Medan Pada tanggal 27 Januari 2001 dari ayah Rustam Pane dan ibu Yunidar. Penulis merupakan anak pertama dari tiga bersaudara. Penulis pertama kali mengenyam pendidikan di bangku SDS Pahlawan Nasional pada tahun 2007 dan lulus pada tahun 2013. Kemudian penulis melanjutkan pendidikan ke jenjang SMP pada tahun 2013 di SMP Negeri 11 Medan dan lulus pada tahun 2016. Pada tahun yang sama, penulis melanjutkan ke jenjang selanjutnya yaitu di SMK Negeri 1 Percut Sei Tuan dan pada bulan September tahun 2019, penulis melanjutkan pendidikan di bangku kuliah dan terdaftar sebagai mahasiswa Fakultas Teknik dengan Program Studi Teknik Informatika di Universitas Medan Area.



ABSTRAK

Ban merupakan komponen yang berbentuk wadah yang terbuat dari karet, kawat, banang, dan beberapa zat kimia lainnya yang akan diisi dengan udara. Ban berfungsi sebagai peran penopang utama seluruh beban kendaraan, meneruskan arah steering dan menjaga kestabilan kemudi, menahan dan meneruskan tenaga mesin, dan peredam getaran pada kendaraan. Maka diperkukan pendekatan digital agar dapat mengenali ban tersebut layak atau tidak secara cepat, tepat, efisien, dan akurat. Sehingga penelitian ini membuat suatu penelitian kerusakan pada ban agar dapat mengenali ban layak atau tidaknya secara cepat, tepat, efisien dan akurat. *Hyperparameter Epoch 50, Batch 64, Optimizer (Adam, NAdam, RMSprop, SGD, Adadelta)* dan *Learning Rate 0.001* dengan dasaet 1000 citra Ban. Klasifikasi yang dilakukan dalam penelitian ini menggunakan arsitektur Mobilenet dari CNN. Berdasarkan hasil *Training* model yang diuji diperoleh model terbaik pada model dengan tingkat akurasi 91%, model menggunakan *Hyperparameter NAdam*. Dengan Epoch 50, batch 64, Akurasi 91%, Presisi 91%, *Recall*, 91%, dan *F1-score* 91%.

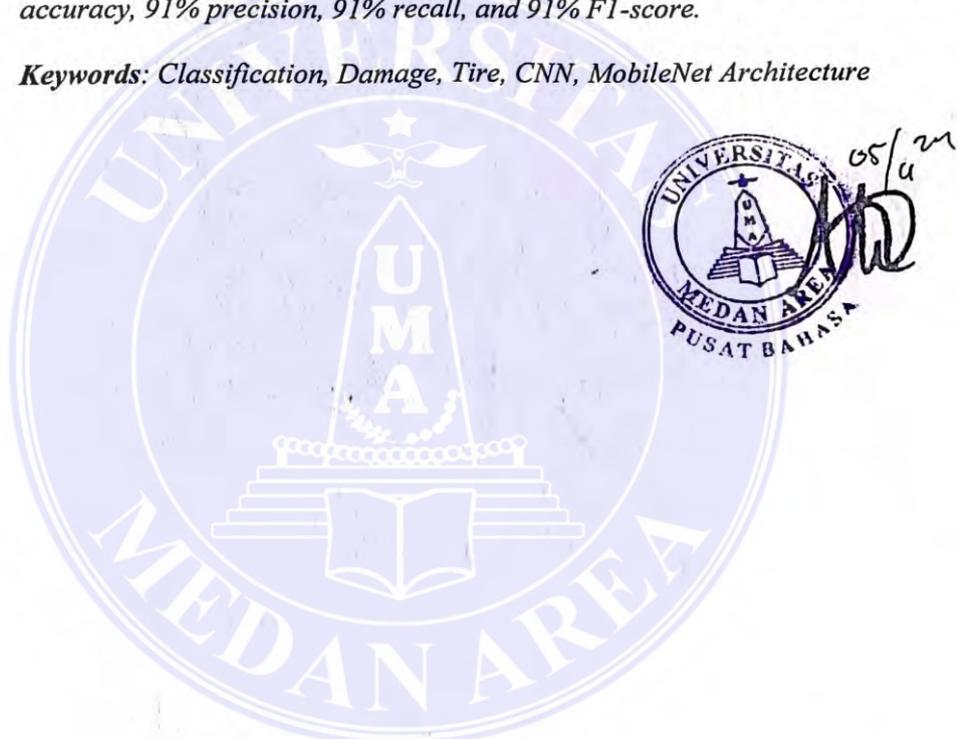
Kata Kunci: Klasifikasi, Kerusakan, Ban, CNN, Arsitektur, Mobilenet



ABSTRACT

Tires are components made of rubber, wire, yarn, and other chemicals and are filled with air. Tires function as the primary support for the entire vehicle load, transmit steering direction, maintain steering stability, transmit engine power, and dampen vehicle vibrations. Therefore, a digital approach is needed to quickly, accurately, efficiently, and precisely determine tire usability. This research aimed to develop a study on tire damage to quickly, accurately, efficiently, and precisely determine tire usability. Hyperparameters included Epoch 50, Batch 64, Optimizers (Adam, Nadam, RMSprop, SGD, AdaDelta), and a Learning Rate of 0.001 with a dataset of 1000 tire images. Classification in this research used the MobileNet architecture from CNN. Based on the model training results, the best model was obtained with an accuracy rate of 91%, using the Nadam hyperparameter. With Epoch 50, Batch 64, the model achieved 91% accuracy, 91% precision, 91% recall, and 91% F1-score.

Keywords: *Classification, Damage, Tire, CNN, MobileNet Architecture*



KATA PENGANTAR

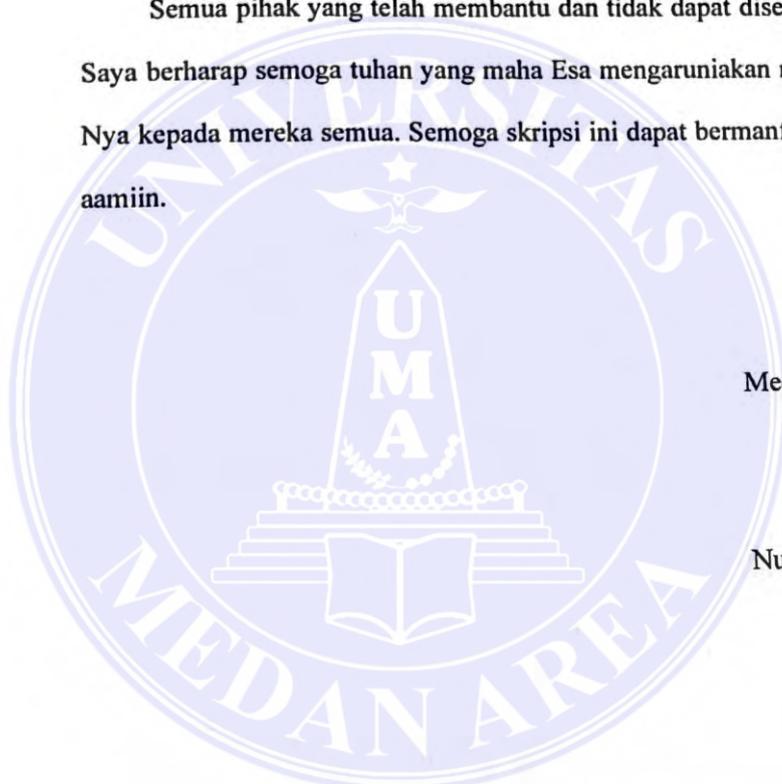
Puji dan syukur penulis haturkan kehadirat Allah SWT, karena berkat rahmat dan hidayah-Nya-lah saya dapat menyelesaikan skripsi yang berjudul “**Klasifikasi Kerusakan Pada Ban Menggunakan CNN Dengan Arsitektur MobileNet**”. Skripsi ini dibuat untuk memenuhi tugas akhir perkuliahan dan sebagai salah satu persyaratan untuk memperoleh gelar Sarjana Strata 1 di Program Studi Teknik Informatika Fakultas Teknik Universitas Medan Area. Selain itu, skripsi ini juga dibuat sebagai salah satu wujud implementasi dari ilmu yang didapatkan selama masa perkuliahan di Program Studi Teknik Informatika Fakultas Teknik Universitas Medan Area. Penulis menyadari bahwa skripsi masih jauh dari sempurna. Oleh karena itu, penulis berharap dapat belajar lebih banyak lagi dalam mengimplementasikan ilmu yang didapatkan. Skripsi ini tentunya tidak lepas dari bimbingan, masukan, dan arahan dari berbagai pihak. Oleh karena itu, pada kesempatan ini saya ingin mengucapkan terima kasih yang sebesar-besarnya kepada :

1. Bapak Dr. Eng. Supriatno, ST., M.T. sebagai Dekan Fakultas Teknik Universitas Medan Area.
2. Bapak Muhathir, ST., M.Kom. sebagai dosen pembimbing utama yang telah meluangkan waktu memberikan dukungan, bimbingan, dan motivasi dalam menyelesaikan skripsi ini.
3. Bapak Rizki Muliono, S.Kom, M.Kom. sebagai Ketua Program Studi Teknik Informatika yang telah memberikan dukungan selama masa perkuliahan di Teknik Informatika Universitas Medan Area.
4. Orangtua saya tercinta yang bernama Rustam Pane dan Yunidar serta

kedua adek saya yang bernama M. Rasyid Pane dan Imam Arsyad Pane yang telah mendoakan memberikan dukungan dan memotivasi saya dalam menyelesaikan skripsi ini.

5. Dan terimakasih kepada teman-teman saya khususnya anggota grup hihang hoheng yang selalu memotivasi saya untuk tetap semangat menyelesaikan tugas akhir ini.

Semua pihak yang telah membantu dan tidak dapat disebutkan satu persatu. Saya berharap semoga tuhan yang maha Esa mengaruniakan rahmat dan hidayah-Nya kepada mereka semua. Semoga skripsi ini dapat bermanfaat bagi kita semua, aamiin.



Medan, Agustus 2024

Nurul Almadinah Pane

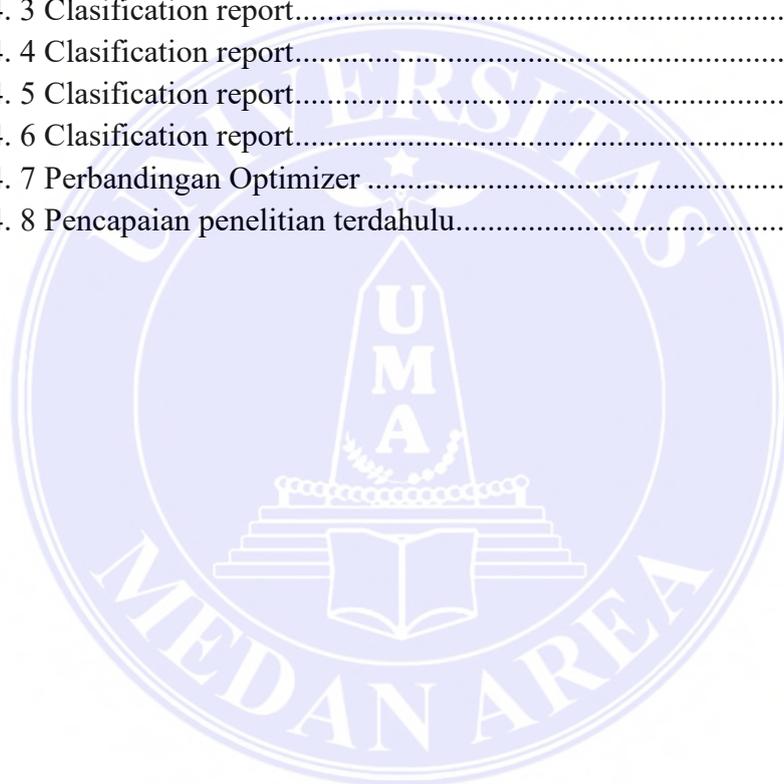
DAFTAR ISI

LEMBAR PENGESAHAN	ii
HALAMAN PERNYATAAN	iii
HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS	
AKHIR/SKRIPSI/TESIS UNTUK KEPENTINGAN AKADEMIS	iii
RIWAYAT HIDUP	iv
ABSTRAK	vi
ABSTRACT	vii
KATA PENGANTAR	viii
DAFTAR ISI	x
DAFTAR TABEL	xii
DAFTAR GAMBAR	xiii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	6
1.3 Batasan Masalah.....	6
1.4 Tujuan Penelitian	6
1.5 Manfaat Penelitian.....	7
BAB II TINJAUAN PUSTAKA	8
2.1 Klasifikasi.....	8
2.2 Convolution Neural Network (CNN)	9
2.3 Arsitektur MobileNet.....	11
2.4 Ban	13
2.5 Penelitian Terkait	17
BAB III METODE PENELITIAN	19
3.1 Metode Penelitian.....	19
3.3 Teknik Pengumpulan Data	20
3.4 Pembagian Data.....	21
3.5 Analisis kebutuhan perangkat	21

3.6	Hyperparameter	22
3.7	Metode Evaluasi.....	23
3.7.1	Parameter Performansi.....	23
BAB IV HASIL DAN PEMBAHASAN		26
4.1	Hasil	26
4.1.1	Visualisasi Ban	26
4.1.2	Augmentasi Dataset.....	26
4.1.3	Pemodelan Arsitektur <i>MobilNetv2</i>	26
4.1.4	Pengujian Model.....	31
4.1.5	Hasil <i>Training</i> Model dan Evaluasi <i>MobileNetv2</i> Dengan <i>Optimizer Adam</i>	32
4.1.6	Hasil <i>Training</i> Model dan Evaluasi <i>MobileNetv2</i> Dengan <i>Optimizer SGD</i>	34
4.1.7	Hasil <i>Training</i> Model dan Evaluasi <i>MobileNetv2</i> Dengan <i>Optimizer Nadam</i>	37
4.1.8	Hasil <i>Training</i> Model dan Evaluasi <i>MobileNetv2</i> Dengan <i>Optimizer RMSprop</i>	39
4.1.9	Hasil <i>Training</i> Model dan Evaluasi <i>MobileNetv2</i> Dengan <i>Optimizer Adadelata</i>	42
4.2	Pembahasan.....	44
4.2.1	Pencapaian Penelitian Terdahulu.....	45
BAB V KESIMPULAN DAN SARAN.....		46
5.1	Kesimpulan	46
5.2	Saran.....	46
DAFTAR PUSTAKA.....		48
LAMPIRAN.....		51

DAFTAR TABEL

Tabel 2. 1 Penelitian Terdahulu	17
Tabel 3. 1 Data Training Dan Data Testing	21
Tabel 3. 2 Perangkat Keras Yang Digunakan	21
Tabel 3. 3 Perangkat Lunak Yang Digunakan	22
Tabel 3. 4 Hyperparameter.....	22
Tabel 3. 5 Kelas Positive dan Negative	23
Tabel 4. 1 Pengujian Hyperparameter.....	31
Tabel 4. 2 Clasification report.....	34
Tabel 4. 3 Clasification report.....	36
Tabel 4. 4 Clasification report.....	39
Tabel 4. 5 Clasification report.....	41
Tabel 4. 6 Clasification report.....	43
Tabel 4. 7 Perbandingan Optimizer	44
Tabel 4. 8 Pencapaian penelitian terdahulu.....	45



DAFTAR GAMBAR

Gambar 2. 1 Struktur Dasar CNN (Herdianto & Nasution, 2023).....	9
Gambar 2. 2 Proses Konvolusi (Rohim, Tibyani, & Sari, 2019).....	10
Gambar 2. 3 Arsitektur MobileNetV2	13
Gambar 2. 4 Ban yang Keausan tidak teratur	15
Gambar 2. 5 Ban lobang paku.....	15
Gambar 2. 6 Ban yang Retak	16
Gambar 2. 7 Ban terkena benang	16
Gambar 2. 8 Ban terkena kawat	17
Gambar 3. 1 Kerangka Kerja Penelitian	19
Gambar 3. 2 Mobilenet Model	20
Gambar 4. 1 Visualisasi Kerusakan pada Ban	26
Gambar 4. 2 Hasil Augmentasi dengan Rotation.....	27
Gambar 4. 3 Hasil Augmentasi dengan Width Shift.....	28
Gambar 4. 4 Hasil Augmentasi dengan Zoom	28
Gambar 4. 5 Hasil Augmentasi dengan Horizontal Flip	28
Gambar 4. 6 Accuracy Dan Loss	32
Gambar 4. 7 Confusion Matrix	33
Gambar 4. 8 Accuracy Dan Loss	34
Gambar 4. 9 Confusion Matrix	35
Gambar 4. 10 Accuracy Dan Loss	37
Gambar 4. 11 Confusion Matrix	38
Gambar 4. 12 Accuracy Dan Loss	39
Gambar 4. 13 Confusion Matrix	40
Gambar 4. 14 Accuracy Dan Loss	42
Gambar 4. 15 Confusion Matrix	43

BAB I

PENDAHULUAN

1.1 Latar Belakang

Di Indonesia, kepemilikan kendaraan bermotor, terutama mobil, sudah menjadi hal yang lumrah. Mobilitas dan aktivitas masyarakat modern yang tinggi menjadikan kendaraan roda empat sebagai kebutuhan utama. Kini, hampir setiap keluarga di Indonesia memiliki setidaknya satu mobil untuk menunjang kegiatan sehari-hari (Pratama, 2022). Seperti yang diketahui, Ban adalah komponen utama pada kendaraan yang melakukan kontak langsung dengan permukaan jalan atau medan. Dengan begitu, tidak heran bahwa ban menjadi komponen terpenting yang harus diperhatikan jika sudah berurusan dengan perawatan kendaraan. Cakupan dari urusan ban tidak hanya berhenti pada urusan kenyamanan pengendalian kemudi oleh driver, tetapi juga mencakup keselamatan pengemudi serta seluruh pengemudi di jalanan. Seperti yang sudah dijelaskan sebelumnya bahwa ban adalah komponen yang bersentuhan langsung dengan permukaan jalan (Fehabutar, 2022). Ban sendiri merupakan komponen yang berbentuk wadah yang terbuat dari karet, kawat, dan beberapa zat kimia lain yang nantinya akan diisi dengan udara. Maka dari itu, ban juga memiliki spesifikasi yang berbeda-beda sesuai dengan fungsi penggunaannya. Ban berfungsi sebagai peran penopang utama seluruh beban kendaraan, Meneruskan arah steering dan menjaga kestabilan kemudi, Menahan dan meneruskan tenaga mesin, dan peredam getaran pada kendaraan (Fehabutar, 2022).

Ban memiliki karakteristik yang perlu diketahui seperti desain asimetris untuk memahami ban yang memiliki desain asimetris ini memberikan kombinasi antara kemampuan melaju dan nyaman berkendara di jalanan basah. Dengan itu

wajib tahu bahwa desain ban asimetris memiliki desain ulir yang terdiri dari dua bagian. Sedangkan, sisi lainnya dapat memberikan kenyamanan berkendara. Desain Simetris, untuk desain ini memiliki ulir yang simetris dan rapi. Desain ini memiliki ceruk-ceruk yang lebih kecil pada permukaan ban sehingga suaranya tidak bising, sehingga desain ini bagus untuk jalanan yang kering, sedang kurang aman jika di gunakan pada jalanan basah. Dan *directional design*, ban dengan *directional design* baik digunakan di jalan yang basah karena lebih efektif untuk menyibak air di jalanan. Desain nya yang memiliki ulir yang mengarah ke luar sehingga dapat mencengkeram jalan dengan lebih kuat, meskipun jalanan licin. Namun desain ban ini lebih berisik, sehingga kurang nyaman berkendara karena kau mungkin terganggu dengan getaran dan kebisingan ban (Petala, 2022). Maka untuk kualitas ban dilihat dari beberapa aspek salah satunya dari kode tread wear indicator dapat terlihat kualitas ban apa sisi ban dan tonjolan persegi di antara bunga atau alur ban mobil, fungsinya untuk mengetahui apakah ban sudah terlalu tergerus oleh aspal atau belum (Eka, 2023). Proses produksi ban tidak selalu menghasilkan ban dengan kualitas sempurna. Adanya ban yang cacat produksi dapat mempengaruhi usia pakai dan performanya. Hal ini menunjukkan bahwa meskipun telah melalui proses produksi, tidak semua ban yang dihasilkan memiliki kualitas yang sama. Beberapa faktor dapat menyebabkan ketidaksempurnaan ini, yang pada akhirnya berdampak pada daya tahan dan keamanan ban tersebut. (As Shidiq, Suhartono, & Sofia, 2022).

Dengan demikian, kelayak pakai pada ban harus dipastikan kondisi fisik terhadap ban yang sudah sesuai dengan standart kelayakan pada ban tersebut. Proses pemeriksaan ban di banyak pabrik ban masih mengandalkan mata dan tangan manusia. Cara ini punya beberapa kekurangan. Pertama, karena manusia

yang mengerjakan, kemungkinan terjadi kesalahan cukup besar. Bayangkan, memeriksa ban secara detail pasti melelahkan, dan konsentrasi bisa menurun. Akibatnya, ada cacat kecil yang mungkin terlewat. Selain itu, pemeriksaan manual butuh waktu lama. Setiap ban harus dicek satu per satu oleh pekerja, sehingga proses produksinya jadi kurang efisien. (As Shidiq, Suhartono, & Sofia, 2022). Penulis ingin menciptakan aplikasi di *smartphone* yang bisa membantu menilai kondisi ban. Aplikasi ini akan mengambil foto ban dan secara otomatis menganalisisnya. Hasilnya, pengguna bisa tahu apakah ban tersebut masih layak pakai atau tidak. Ide ini muncul karena penulis melihat perlunya sistem yang canggih dan praktis untuk memeriksa kondisi ban. Sistem ini menggabungkan teknologi pengenalan gambar dengan pengetahuan dari para ahli ban. Dengan begitu, penilaian kondisi ban bisa dilakukan dengan lebih mudah, cepat, dan akurat, sehingga pengguna bisa mengambil keputusan yang tepat tentang ban mereka. (Pratama, 2022). Penggunaan metode ini memiliki tujuan untuk meningkatkan efektivitas dan objektivitas dalam proses penilaian kelayakan ban.. Untuk dapat mengetahui kelayakan ban menggunakan teknik *Deep learning* dengan algoritma *Convolutional Neural Network* dan arsitektur *MobileNetV2*. Dan beberapa parameter optimasi sebagai model penentuan hasil *Training* terbaik (Fadlia & Kosasih, 2019).

Pada beberapa penelitian telah membahas klasifikasi kelayakan ban oleh para peneliti seperti yang membahas kerusakan dan kelayakan menggunakan *Gray Level Cooccurrence Matrix* dengan 100 data yang uji menunjukkan angka persentase sebesar 80%. Hasil akurasi tersebut tidak mencapai 100% (Febriyanto, Rahmad, & Vista, 2021) mengeksplorasi berbagai teknik deteksi cacat pada produk, khususnya

ban, dengan memanfaatkan teknologi terkini seperti *machine learning* dan *deep learning*. Fokus penelitian ini adalah penerapan *Convolutional Neural Network* (CNN) untuk mendeteksi cacat pada produk hasil pengelasan. Hasilnya menunjukkan bahwa sistem yang dikembangkan mampu mencapai akurasi yang tinggi, yaitu sebesar 88,31% dalam mengidentifikasi cacat pada produk tersebut. (Listyalina, 2022) membahas tentang pendeteksian ban ganda menggunakan fitur *Haar-Like* dan SVM sebagai pengklasifikasi dengan tingkat akurasi 99% (Yusf, MMSI, Wahyudi, & Nugraha, 2019) membahas klasifikasi produk ban menggunakan *Naive Bayes* dengan tingkat akurasi 96% (Maulana & Solikhun, 2018).

Berdasarkan beberapa pencapaian peneliti terdahulu mengenai klasifikasi pada ban maka telah dilakukan berbagai macam cara dan metode dalam menyelesaikan masalah, seperti menggunakan *Gray Level Cooccurrence Matrix* dengan data Gambar, membahas tentang deteksi kecatatan ban menggunakan VGG-16 dengan menggunakan data Gambar, membahas tentang pendeteksian ban ganda menggunakan fitur *Haar-Like* dan SVM menggunakan data Gambar, dan membahas klasifikasi produk ban menggunakan *Naive Bayes* menggunakan data Huruf. Oleh karena itu, dalam penelitian ini mencoba melakukan tindak lanjut dengan memodelkan klasifikasi teknologi terkini dengan memanfaatkan metode *Deep learning*, pada *Deep learning* sudah banyak dikembangkan oleh beberapa ahli seperti *VGG*, *GoogleNet*, *Inception*, *Xception*, *MobileNet*, *Swin Transform*, *Vision Transform*, *EfficientNet*, Dan *ResNet*.

Penelitian ini memanfaatkan *MobileNet* sebagai arsitektur *deep learning* untuk mengklasifikasikan kerusakan pada ban. Pilihan ini didasarkan pada kinerja

MobileNetV2 yang terbukti unggul dalam berbagai tugas klasifikasi gambar. Kemampuan *MobileNetV2* dalam mengenali pola dan fitur visual secara akurat menjadikannya rujukan yang tepat untuk mendeteksi dan mengkategorikan berbagai jenis kerusakan pada ban. Implementasi arsitektur ini diharapkan dapat menghasilkan sistem klasifikasi kerusakan ban yang efektif dan efisien. Namun, meskipun arsitektur *MobileNet* telah banyak digunakan dalam berbagai aplikasi klasifikasi gambar, penggunaannya dalam mengklasifikasikan kerusakan pada ban masih jarang dan terbatas. Permasalahan ini muncul karena keterbatasan data pelatihan yang spesifik untuk kerusakan pada ban serta perbedaan dalam visual antara ban yang masih layak digunakan dan yang sudah tidak layak digunakan. Oleh karena itu, perlu dilakukan analisis arsitektur *Deep learning MobileNet* dalam konteks klasifikasi kerusakan pada ban. Analisis ini diharapkan dapat memberikan pemahaman lebih dalam tentang keunggulan dan keterbatasan *MobileNet* dalam mengenali dan mengklasifikasikan ban yang tidak layak digunakan atau masih layak digunakan.

Berdasarkan keunggulan arsitektur *MobileNetV2* dalam menyelesaikan permasalahan yang beragam kasus serta penelitian/identifikasi kerusakan pada ban belum memanfaatkan metode terkini maka dari itu penelitian ini akan mencoba membangun model *Deep learning* dalam menyelesaikan kasus klasifikasi pada ban dengan judul **“Klasifikasi Kerusakan pada Ban Menggunakan CNN dengan Arsitektur *MobileNet*”**.

1.2 Rumusan Masalah

Berdasarkan penjelasan dari masalah yang telah di paparkan pada latar belakang, berikut ini merupakan rumusan masalah dalam penelitian yaitu:

1. Bagaimana mengklasifikasi kerusakan pada ban menggunakan metode *CNN* dengan Arsitektur *MobileNet*?
2. Bagaimana menerapkan *MobileNet* untuk mengklasifikasi kerusakan pada ban?
3. Bagaimana menghasilkan sebuah sistem yang dapat mengenali kerusakan pada ban agar mengetahui layak atau tidak nya ban tersebut.

1.3 Batasan Masalah

Adapun batasan masalah dalam penelitian ini yaitu sebagai berikut:

1. Adapun laporan sistem yang dihasilkan berupa hasil klasifikasi kerusakan pada ban agar mengetahui layak atau tidak layak pakai.
2. Adapun sumber data yang diperoleh pada penelitian ini di ambil dari usaha dari keluarga orangtua saya berupa data kerusakan pada ban.
3. Sistem dibangun dalam mengklasifikasi kerusakan pada ban menggunakan metode *CNN* dengan Arsitektur *MobileNet*.

1.4 Tujuan Penelitian

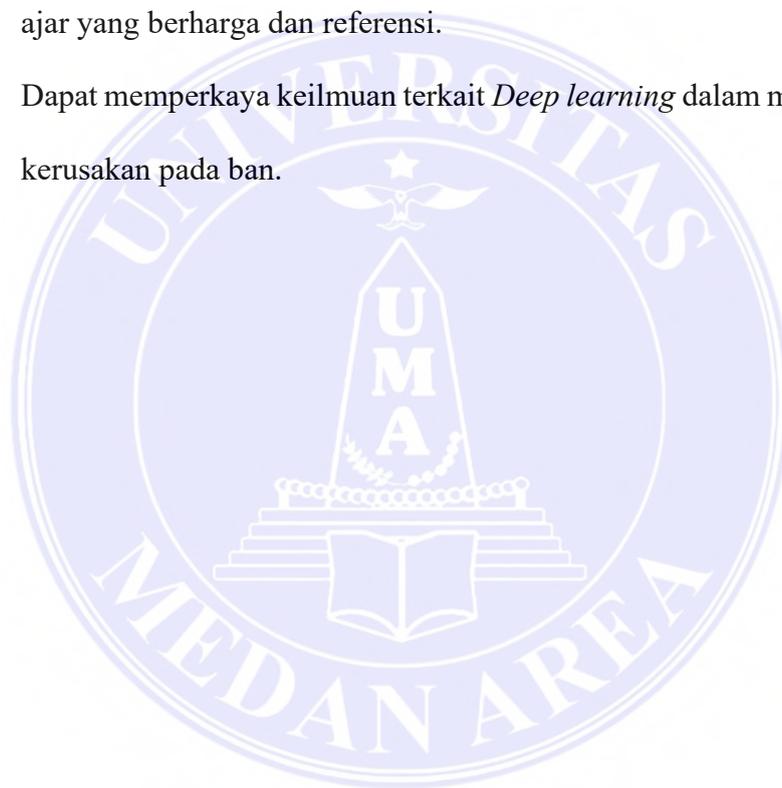
Adapun tujuan dalam penelitian yaitu sebagai berikut:

1. Untuk mengklasifikasi kerusakan pada ban menggunakan citra ban.
2. Untuk menerapkan metode *CNN* dengan arsitektur *MobileNet* dalam mengklasifikasi kerusakan pada ban.

1.5 Manfaat Penelitian

Adapun manfaat dalam penelitian ini yaitu sebagai berikut:

1. Mengetahui Tingkat akurasi yang diperoleh dengan menggunakan metode mobilenet
2. Penelitian ini bertujuan untuk memberikan kontribusi pada pengembangan ilmu pengetahuan dibidang pengolahan citra, khususnya terkait dengan arsitektur mobilenet. Hasil penelitian ini diharapkan dapat menjadi bahan ajar yang berharga dan referensi.
3. Dapat memperkaya keilmuan terkait *Deep learning* dalam mengklasifikasi kerusakan pada ban.



BAB II

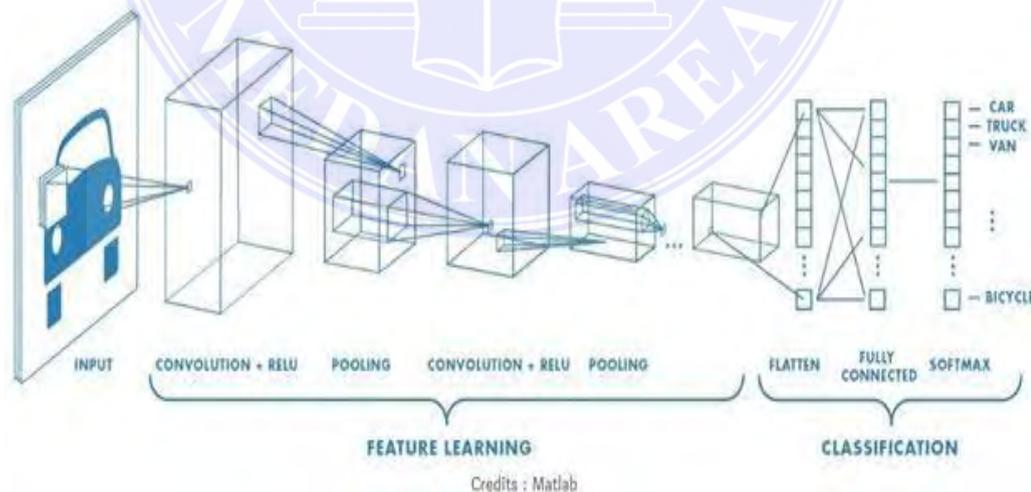
TINJAUAN PUSTAKA

2.1 Klasifikasi

Klasifikasi dapat diibaratkan sebagai sebuah perjalanan untuk menemukan pola tersembunyi di dalam data. (Mubarog, Setyanto, & Sismoro, 2019) dengan tujuan untuk dapat memperkirakan kelas dari suatu objek yang labelnya tidak diketahui (Fadlan, Ningsih, & Windarto, 2018). Klasifikasi data bertujuan untuk mengelompokkan data ke dalam kelas-kelas tertentu melalui dua tahapan utama. Tahap pertama adalah fase *training*, di mana model klasifikasi dibentuk dengan mempelajari pola dari data yang kelasnya telah diketahui. Selanjutnya, pada fase *testing*, model yang telah dilatih diuji menggunakan data baru untuk memprediksi kelas dari data tersebut. Kedua fase ini yaitu *training* dan *testing* dijalankan berdasarkan algoritma klasifikasi yang dipilih. Hasil akhir dari proses ini adalah penentuan kelas untuk setiap data yang sebelumnya belum diketahui kelasnya. (Mubarog, Setyanto, & Sismoro, 2019). Pada fase pengujian model, data baru diintroduksi untuk mengevaluasi performanya. Hasil evaluasi ini akan menunjukkan tingkat akurasi atau kemampuan model dalam memprediksi data kategori yang sebelumnya tidak diketahui. (Radikto, Mulyana, Rofik, & Zakaria, 2022). Algoritma klasifikasi yang banyak digunakan secara luas, yaitu *Decision classification trees*, *Bayesian classifiers/Naive Bayes classifiers*, *Neural networks*, *Analisa Statistik*, *Algoritma Genetika*, *Rough sets*, *k-nearest neighbor*, *Metode Rule Based*, *Memory based reasoning*, dan *Support vector machines (SVM)* (Annur, 2018).

2.2 Convolution Neural Network (CNN)

Convolution Neural Network atau *CNN* merupakan suatu metode yang paling banyak untuk mengolah citra (Prasetyo, M. Irfansyah, Exaudi, Septian, & Rendyansyah, 2023). *Convolution Neural Networks (CNNs)* merupakan arsitektur jaringan saraf tiruan yang terinspirasi dari cara kerja *Multi Layer Perceptron*. CNNs banyak diaplikasikan dalam bidang visi komputer, terutama untuk tugas-tugas seperti klasifikasi gambar, karena kemampuannya dalam mengekstrak fitur-fitur penting dari data visual. (Radikto, Mulyana, Rofik, & Zakaria, 2022). *CNN* metode *machine learning* yang dikembangkan dari *MultiLayer Perception (MLP)* yang dirancang dapat mengolah data 2D. (Yohannes & Al Rivian, 2022) dan *CNN* juga merupakan suatu *Layer* yang memiliki susunan *neuron* 3D. (lebar, tinggi, dan kedalaman) Lebar dan tinggi merupakan ukuran *Layer* sedangkan kedalaman merupakan mengacu pada jumlah *Layer* (Prasetyo, M. Irfansyah, Exaudi, Septian, & Rendyansyah, 2023).



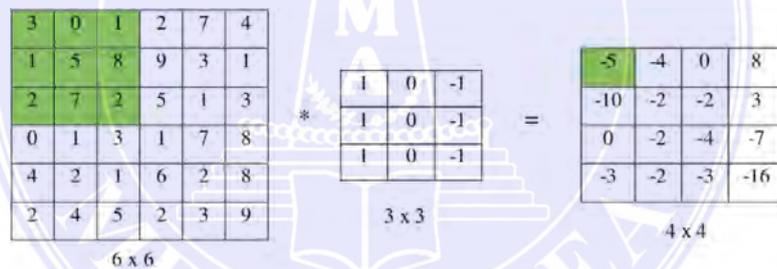
Gambar 2. 1 Struktur Dasar CNN (Herdianto & Nasution, 2023)

CNN memiliki dua bagian utama. Pertama, *feature extraction* yang bertugas mengidentifikasi ciri-ciri unik setiap objek. Kedua, klasifikasi yang terdiri dari

flatten, *Fully Connected*, dan *softmax* untuk menentukan kelas dari objek input.. Dalam pengembangan banyak arsitektur dari *CNN* yang banyak digunakan seperti *faster r-CNN*, *alexnet*, *vggnet*, *googlenet*, *resnet* dan lainnya. Secara umum ada 3 *Layer* pada *CNN*, yaitu *convolusi Layers*, *Pooling Layers*, dan *fulli connected Layers*.

A. Konvolusi Layer (CNN)

Konvolusi *layer* merupakan komponen utama dalam *CNN* yang berperan sebagai pusat pemrosesan. Di sinilah perhitungan perkalian antara dimensi gambar (lebar, tinggi, dan kedalaman) dengan kernel dilakukan. Lapisan ini bertugas untuk menerapkan filter dan menghasilkan *feature map* dari gambar masukan. (Rohim, Tibyani, & Sari, 2019).



Gambar 2. 2 Proses Konvolusi (Rohim, Tibyani, & Sari, 2019)

B. Pooling Layer

Pooling layer adalah sebuah lapisan dimana proses pengurangan ukuran citra terjadi setelah terjadinya kontaminasi lapisan (Husna, Ulum, Saputro, Laksono, & Purnamasari, 2022). *Pooling layer* berperan krusial dalam mengelola dimensi data selama proses konvolusi. Dengan melakukan *downsampling*, lapisan ini meringkas informasi penting, membuat data lebih mudah diolah dan dipecah menjadi elemen-elemen terkecil untuk analisis lebih lanjut. (Yohannes & Al Rivan, 2022). Pada *Layer Pooling* terdapat dua jenis

yaitu *maximum Pooling Layer* dan *average Pooling Layer*. *Maximum Pooling Layer* mengambil nilai maksimum pada daerah tertentu, sedangkan *average pooling layer* mengambil nilai rata-rata (Hariyani, Hadiyoso, & Siadari, 2020).

C. *Fully Connected Layer*

Dalam arsitektur neural network, terdapat struktur yang disebut *Fully Connected Layer*. Pada lapisan ini, seluruh neuron di suatu lapisan terhubung secara lengkap dengan semua neuron pada lapisan sebelumnya dan sesudahnya. Citra yang telah diproses menjadi bentuk satu dimensi akan diumpangkan sebagai input pada lapisan ini untuk kemudian dilakukan prediksi. (Herdianto & Nasution, 2023) (Hariyani, Hadiyoso, & Siadari, 2020).

2.3 Arsitektur MobileNet

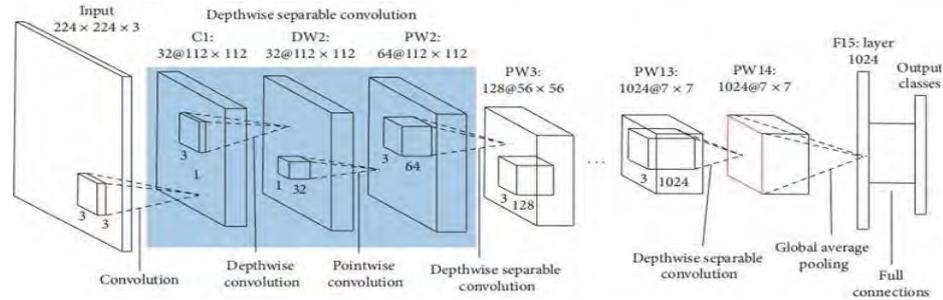
Arsitektur *MobileNet* adalah salah satu arsitektur *Convolutional Neural Network (CNN)* yang dirancang khusus untuk perangkat mobile dan embedded vision applications. Keunggulan utama *MobileNet* adalah efisiensinya, yang berarti ia membutuhkan daya komputasi dan memori yang lebih sedikit dibandingkan arsitektur CNN tradisional seperti VGG atau *ResNet*. Hal ini dicapai dengan menggunakan *depthwise separable convolutions*, yaitu teknik yang memecah proses konvolusi standar menjadi dua langkah: *depthwise convolution* dan *pointwise convolution*. (Fuadi & Suharso, 2022).

Pada arsitektur *MobileNetV2* memiliki 2 fitur antarlain *Linear Bottleneck* dan *Shortcut Connection* antar *Bottleneck*. Kedua fitur tersebut menjadikan proses *Training* pada *neural network* bisa berjalan secara lebih efisien dan mendapatkan akurasi yang lebih baik. *MobileNetV2* merupakan *pre-trained* model (model yang sudah dilatih) dalam mengklasifikasikan gambar dengan menggunakan *dataset*

yang besar. Dengan menggunakan *pre-trained* model, maka pengembang tidak perlu membangun atau melatih model dari awal sehingga tidak memakan waktu.

Berikut adalah perhitungan manual sederhana untuk model *MobileNetV2*:

1. **Input Layer:** Gambar input memiliki ukuran 224x224x3 (panjang, lebar, dan saluran warna).
2. **Convolutional Layer:** Pada *Layer* pertama, setiap filter 3x3 memiliki total 3x3x3 (ukuran kernel x jumlah saluran input x jumlah filter) bobot yang harus dipelajari, ditambah satu bias untuk setiap filter. Oleh karena itu, ada total $3 \times 3 \times 3 \times 32 + 32 = 8963$ parameter pada *layer* ini.
3. **Bottleneck Residual Block:** Perhitungan parameter untuk setiap blok bergantung pada jumlah filter yang digunakan pada setiap langkah konvolusi. Misalkan setiap langkah konvolusi dalam blok memiliki t dan c masing-masing untuk ukuran filter dan jumlah saluran output. Sebagai contoh, jika kita memiliki $t=6$ dan $c=64$ pada blok tersebut, maka jumlah parameter akan menjadi $1 \times 1 \times 32 \times 6 + 3 \times 3 \times 6 \times 64 + 1 \times 1 \times 6 \times 64 = 3,840$ di setiap blok.
4. **Linear Classifier:** Setelah sejumlah blok, fitur yang dihasilkan diteruskan ke lapisan pengklasifikasi linear. Jumlah parameter pada lapisan ini tergantung pada ukuran output dari blok sebelumnya dan jumlah kelas dalam dataset. Misalkan jumlah kelasnya adalah N , maka jumlah parameter akan menjadi $1 \times 1 \times \text{jumlah_saluran_terakhir} \times N$.



Gambar 2.3 Arsitektur MobileNetV2

Terdapat dua operasi di dalam *MobileNet*, yaitu *Depthwise Convolution* (DW) dan *Pointwise Convolution* (PW) (Hostomo, 2021), Yang pertama digunakan untuk *residual block* dan yang kedua digunakan untuk *down sizing*. Pada intinya model *MobileNetV2* pada setiap *block* terdapat *layer*, jika ditotal kan terdapat ± 150 *Layer* (Juliando, 2021).

2.4 Ban

Ban adalah komponen penting pada kendaraan yang berbentuk lingkaran dan terbuat dari karet atau bahan sejenis. Ban berfungsi untuk membungkus pelek roda agar kendaraan dapat berjalan di atas permukaan jalan dengan aman dan nyaman. (Hendrawan, Adam, & Rozikin, 2022). Pemilihan ban yang benar sangat menentukan keselamatan pengemudi dari bahaya *slide* pada jalan-jalan tertentu, dapat menurunkan biaya *operasional* kendaraan, *performance* meningkat dan *maintenance* mudah. Untuk ukuran standar nya ban 7.50-15, 7.50- 16 (750 16) (Ufriandi, 2021).

Ban merupakan bagian yang melapisi velg roda. Fungsi utama ban adalah sebagai pelindung roda dari kerusakan. Selain itu, ban juga berperan dalam meredam getaran akibat kondisi jalan yang tidak rata, serta menjaga kestabilan kendaraan saat bergerak sehingga akselerasi dan pengendaliannya menjadi lebih baik. Ban dibuat dengan memanfaatkan material elastis seperti karet atau polimer.

Material ini diperkuat dengan serat sintetik dan baja berkekuatan tinggi untuk menciptakan kombinasi unik sifat-sifat seperti daya tahan tarik tinggi, fleksibilitas, dan ketahanan geser yang luar biasa. Ban kendaraan, baik truk maupun mobil penumpang, umumnya menggunakan material komposit berbahan dasar karet alam atau karet isoprena. Material ini diaplikasikan pada berbagai bagian ban, seperti sabuk tapak, dinding ban (*sidewall*), lapisan karkas (*carcass ply*), dan lapisan dalam (*inner liner*). (Krisbianto & Silalahi, 2022).

Munculnya retakan pada ban menandakan adanya kerusakan yang perlu diperhatikan. Retakan tersebut mengindikasikan ban mulai kehilangan kelenturan alaminya, yang berdampak pada berkurangnya daya cengkeram ban terhadap permukaan jalan. Kondisi ini dapat membahayakan pengemudi karena mengurangi traksi dan kontrol kendaraan, terutama saat mengerem atau bermanuver. Jika diabaikan, retakan pada ban dapat meningkatkan risiko kecelakaan. Oleh karena itu, penting untuk selalu memeriksa kondisi ban dan menggantinya jika ditemukan tanda-tanda kerusakan seperti retakan. (Hendrawan, Adam, & Rozikin, 2022).

Berikut adalah macam macam kerusakan yang terdapat pada ban:

1. Keausan tidak teratur (*Irregular Wear*)

Aus tidak teratur adalah salah satu jenis kerusakan yang sering terjadi pada ban. Biasanya penyebab aus tidak merata terjadi karena tekanan angin ban yang kurang atau lebih.



Gambar 2. 4 Ban yang Keausan tidak teratur

2. Terkena paku (*Tread Cut Penetration*)

Terkena paku atau retak pada ban dapat di sebabkan karena usia ban yang sudah terkaku tua sehingga getas. Jika sudah getas, maka tapak pada ban akan mengalami retak-retak. Usia ban yang ideal sekitar lima tahun dengan syarat penyimpanan yang baik di suhu ruangan 25-35 derajat celcius.



Gambar 2. 5 Ban lobang paku

3. Retak

Retak adalah jenis kerusakan ban yang paling parah, kerusakan ini terjadi akibat ban yang melindas benda tajam atau mendapatkan tekanan paling tinggi hingga meletus.



Gambar 2. 6 Ban yang Retak

4. Terkena benang

Ban yang terkena benang ban yang tersusun dari beberapa lapisan nilon yang tersusun bersilang yang membentuk 40 hingga 65 derajat terhadap arah melingkar ban. Ban yang terkena benang tidak layak pakai dan segera diganti untuk menghindari bahaya di jalan.



Gambar 2. 7 Ban terkena benang

5. Terkena Kawat

Ban yang terkena kawat memiliki struktur jalinan benang kawat yang tegak lurus dan membentang secara melingkar. Struktur ini membuat toroida dengan satu lapis benang kawat.



Gambar 2. 8 Ban terkena kawat

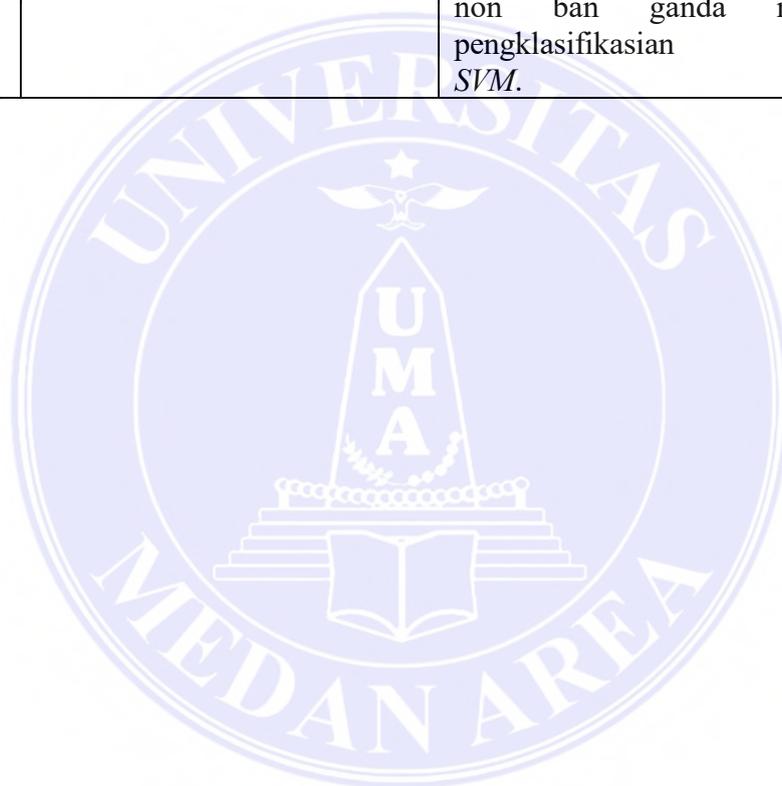
2.5 Penelitian Terkait

Untuk melakukan penelitian harus adanya sebuah referensi dari penelitian sebelumnya agar bisa diketahui apa saja yang dari penelitian tersebut. Berikut penelitian-penelitian terdahulu yang terkait pada penelitian penulis.

Tabel 2. 1 Penelitian Terdahulu

No.	Referensi	Temuan
1.	(Febriyanto, Rahmad, & Vista, 2021)	Hasil akurasi sebesar 80% dari 100 data citra berdasarkan ekstraksi tekstur menggunakan <i>gray level cooccurrence matrix</i> untuk ekstraksi tekstur dan metode <i>backpropagation</i> untuk mengidentifikasi kerusakan ban.
2.	(As Shidiq, Suhartono, & Sofia, 2022)	Sistem mencapai performa terbaiknya dalam mengenali gambar ketika dikonfigurasi dengan ukuran citra 224x224 piksel, menggunakan algoritma optimasi Stochastic Gradient Descent (SGD), melalui 70 kali pelatihan (epoch) dengan ukuran batch 16, dan laju pembelajaran (learning rate) 0,0001. Konfigurasi parameter ini menghasilkan tingkat akurasi yang tinggi, mencapai 87% dalam mengklasifikasikan gambar secara tepat.
3.	(Maulana & Solikhun, 2018)	Dari pengujian yang dilakukan klasifikasi ban OK atau Scrap dengan membandingkan hasil analisa sistem dengan data <i>Training</i> pada tools rasis <i>miner</i> menghasilkan

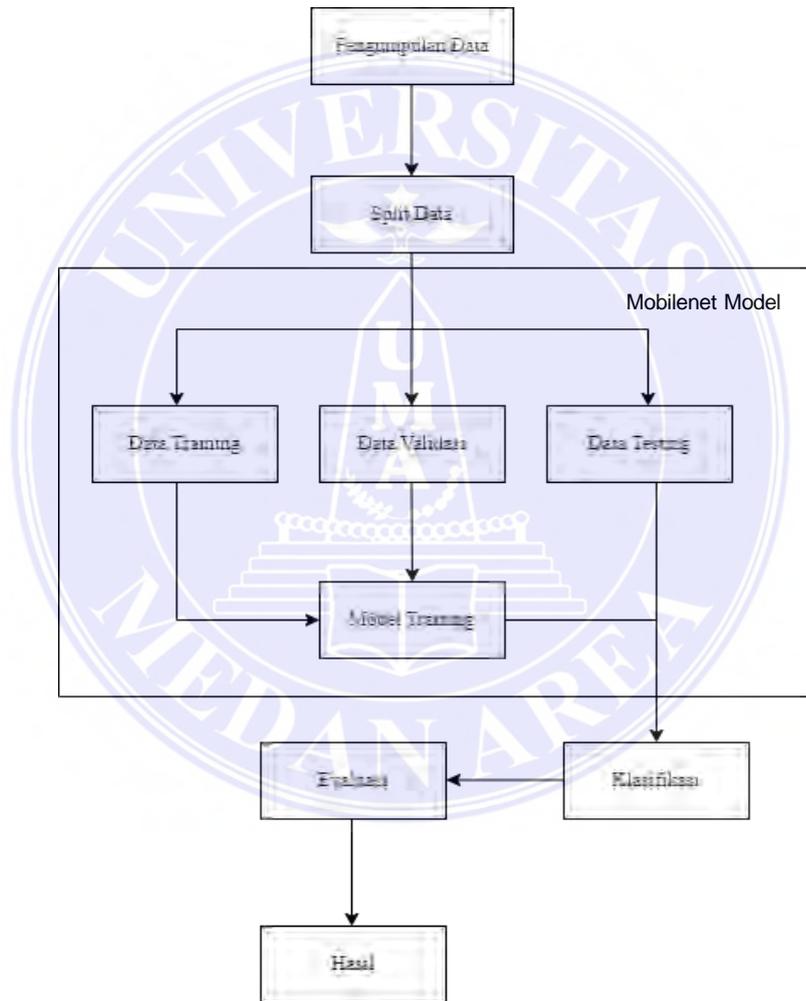
		tingkat akurasi sebesar 96%
4.	(Yusf, Wahyudi, & Nugraha, 2019)	Hasil pengujian tahap pertama terlihat bahwa basis fitur yang digunakan dapat mengambil fitur yang digunakan dapat mengambil fitur ban ganda dengan baik dengan capaian akurasi 99%. Uji tahap pertama juga menunjukkan bahwa kernel <i>RBF</i> memberikan kinerja paling baik untuk klasifikasi ban ganda dan non ban ganda menggunakan pengklasifikasian <i>SVM</i> .



BAB III METODE PENELITIAN

3.1 Metode Penelitian

Dalam klasifikasi kerusakan pada ban akan dibuat beberapa tahapan dalam bentuk diagram alur guna mempermudah dalam penyusunan penelitian ini dapat di lihat dari gambar 3.1 sebagai berikut :

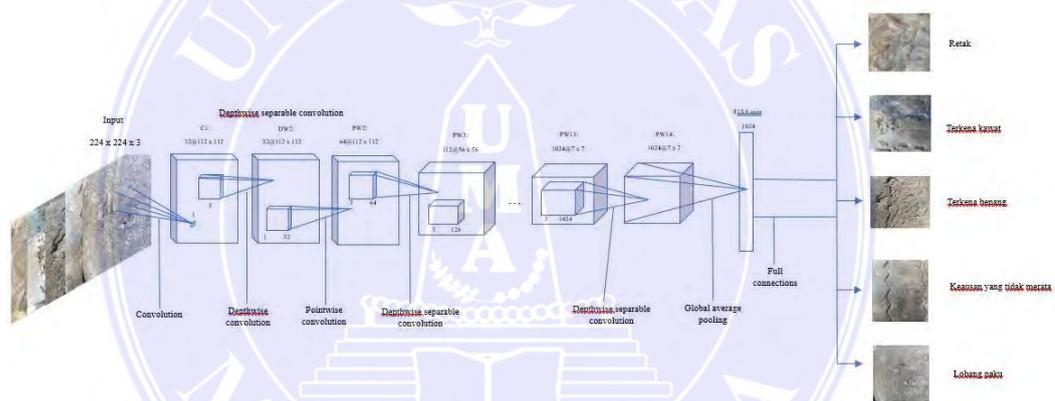


Gambar 3. 1 Kerangka Kerja Penelitian

Pada Gambar 3.1 langkah pertama yaitu mengumpulkan data yang akan di klasifikasi. Setelah data dikumpulkan akan dibagi menjadi tiga bagian yaitu *training*, *testing*, dan *validasi*. Pada tahap ini, model *deep learning*, seperti

Mobilenet, akan dilatih menggunakan data *training*. Setelah model dilatih, dilakukan evaluasi menggunakan data validasi. Pada tahap ini, metrik seperti akurasi, *precision*, *recall*, dan *F1-score* dihitung untuk mengevaluasi performa model. Setelah model dilatih dan dievaluasi, model ini siap digunakan untuk klasifikasi gambar ban baru. Pada tahap ini, model mengambil gambar ban sebagai input dan mengklasifikasikannya ke dalam kategori ban yang sesuai berdasarkan pola yang dipelajari selama pelatihan. Tahap akhir adalah menghasilkan output klasifikasi untuk mengetahui jenis-jenis kerusakan pada ban.

3.2 Mobilenet Model



Gambar 3. 2 Mobilenet Model

3.3 Teknik Pengumpulan Data

Pada penelitian ini data masukan di peroleh dari citra yang diambil dari gudang ban yang di jalan belat, medan tembung. Pada pengambilan data ini dilakukan secara langsung dengan cara menggambar dengan camera minimum 10 MP pada IOS. Gambar yang diambil dengan jarak sekitar 5-10 cm dengan fokus dekat dengan ban, pencahayaan di siang hari kemudian hasil dari gambar disimpan dalam bentuk *IMG*. Kemudian dalam pengujian ini digunakan kelas diantaranya kelas positif dan negatif. Dan menggunakan studi literatur untuk mendukung

penelitian ini.

3.4 Pembagian Data

Sampel gambar yang digunakan dalam model uji coba sebanyak 1000 sampel model evaluasi yang digunakan sebagai penelitian ini membagi data menjadi dua bagian yaitu data *Training* dan data *Testing*, data yang digunakan sebagai data *Training* sebanyak 80%, data *Testing* sebanyak 10%, validasi 10%. Data uji digunakan untuk mengevaluasi kinerja model pada data yang belum pernah dilihat sebelumnya, sedangkan data validasi digunakan untuk fine-tuning *Hyperparameter* model.

Tabel 3. 1 Data Training Dan Data Testing

No.	Kelas	Dataset		
		<i>Training</i> (80%)	<i>Testing</i> (100%)	Validation (10%)
1.	Kerusakan tidak teratur	160	20	20
2.	Terkena paku	160	20	20
3.	Retak	160	20	20
4.	Terkena kawat	160	20	20
5.	Terkena benang	160	20	20

3.5 Analisis kebutuhan perangkat

Untuk menganalisis langkah awal yang di perlukan adalah perangkat keras (hardware) dan perangkat lunak (*software*). Alat perangkat keras seperti pada tabel berikut.

Tabel 3. 2 Perangkat Keras Yang Digunakan

No.	Perangkat Keras	Deskripsi
1.	Kamera	Iphone Xr

2.	Device	Laptop Asus
3.	Processor	Intel n2840
4.	SSD	128 GB
5.	Ram	4,00 GB

Sedangkan perangkat lunak yang dibutuhkan seperti pada tabel berikut:

Tabel 3. 3 Perangkat Lunak Yang Digunakan

No.	Perangkat Lunak	Deskripsi
1.	Sistem Operasi	Windows 8
2.	Tools	Google Colab
3.	Phyton	Bahasa Pemograman

3.6 *Hyperparameter*

Adapun parameter yang digunakan dalam melakukan kalsifikasi dalam melakukan klasifikasi kerusakan pada ban sebagai berikut :

Tabel 3. 4 *Hyperparameter*

No.	Parameter	Value
1.	Epoch	{ 50 }
2.	Batch	{ 64 }
3.	<i>Optimizer</i>	{ <i>Adam, NAdam, RMSprop, SGD, Adadelta</i> }
4.	<i>Learning Rate</i>	{0.001}

3.7 Metode Evaluasi

Kinerja model pada tahap pengujian dievaluasi dengan memanfaatkan metrik yang berasal dari *Confusion Matrix*, yaitu akurasi, presisi, recall, dan F1-score. Metrik-metrik ini kemudian dihitung untuk mendapatkan nilai masing-masing, yang akan memberikan gambaran komprehensif tentang kemampuan model dalam melakukan klasifikasi.

3.7.1 Parameter Performansi

Parameter performansi berperan sebagai standar dalam evaluasi kinerja dan kualitas suatu sistem. Melalui parameter ini, kita dapat menilai kemampuan sistem dalam mempelajari data dari setiap kelasnya. Kualitas sistem tercermin dalam nilai confusion matrix yang menunjukkan tingkat akurasi, presisi, *recall*, dan *F1-score*.

1. *Confusion Matrix*

Confusion Matrix adalah parameter yang digunakan untuk mengevaluasi kualitas dan kerja dari model yang ada nilai dari *confusion* ini menghitung akurasi, presisi, *recall* dan *F1-score*.

Tabel 3. 5 Kelas Positive dan Negative

<i>Confusion Matrix</i>		Kelas Aktual	
		Positif	Negatif
Kelas Prediksi	Positif	TP	FP
	Negatif	FN	TN

Keterangan :

True *Positive* (TP) : Data hasil aktual positif, mengidentifikasi dengan benar positif

True *Negative* (TN) : Data hasil aktual negatif, mengidentifikasi

False *Positive* (FP) : dengan benar negatif
 : Data hasil aktual negatif, salah
 Mengidentifikasi dengan positif

False *Negative* (FN) : Data hasil aktual positif, salah
 Mengidentifikasi dengan *Negative*.

2. Akurasi

Akurasi dapat diartikan sebagai ukuran yang membandingkan jumlah prediksi kelas yang tepat dengan keseluruhan data. Nilai ini menunjukkan seberapa efektif suatu kelas dalam proses klasifikasi. Menghitung nilai akurasi rumusnya sebagai berikut :

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots (3.1)$$

3. Presisi

Presisi menjadi tolok ukur seberapa akurat informasi yang diberikan kepada pengguna sesuai dengan permintaan mereka, diukur dalam persentase. Bagaimana klasifikasi kelas yang benar terhadap data prediksi benar. Rumus menghitung persen sebagai berikut :

$$\text{Presisi} = \frac{TP}{TP+FP} \dots\dots\dots (3.2)$$

4. Recall

Recall merupakan metrik yang digunakan untuk mengukur kemampuan suatu model dalam mengidentifikasi seluruh kasus positif yang sebenarnya. Nilai *recall* didapatkan dengan membandingkan jumlah data yang terprediksi positif dengan jumlah seluruh data yang seharusnya bernilai positif. . Rumus mencari *Recall* sebagai berikut :

$$\text{Recall} = \frac{\text{TP}}{\text{FN}+\text{TP}} \dots\dots\dots (3.3)$$

5. *F1-score*

F1-score adalah nilai rata-rata presisi dan Recall. Rumus menghitungnya sebagai berikut :

$$\text{F1} = 2 \cdot \frac{\text{precision} \cdot \text{recall}}{\text{precision}+\text{recall}} = \frac{\text{TP}}{\text{TP}+\frac{1}{2}(\text{FP}+\text{FN})} \dots\dots\dots (3.4)$$



BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Kesimpulan yang dapat diambil dari hasil pengujian dalam melakukan klasifikasi Kerusakan ban dengan menggunakan arsitektur *MobileNetV2* adalah sebagai berikut:

1. Dengan menggunakan arsitektur jaringan saraf tiruan *MobileNet*, kita berhasil mendapatkan hasil yang sangat baik dalam mengklasifikasikan kerusakan pada ban. Model ini terbukti efektif untuk semua kumpulan data yang kami uji, menunjukkan akurasi yang tinggi dalam mengidentifikasi kerusakan pada ban tersebut. Model menggunakan *Hyperparameter NAdam*.
2. Berdasarkan hasil klasifikasi menggunakan 5 *Optimizer*, *NAdam* menjadi *Optimizer* terbaik yang memperoleh nilai akurasi sebesar 91%. Pengujian model menggunakan *Hyperparameter* dengan jumlah *epoch* 50, *batch size* 64.
3. Beberapa keterbatasan dalam penelitian ini termasuk ukuran dataset yang relatif kecil yang mungkin belum memberikan hasil maksimal. Selain itu, keterbatasan waktu dan sumber daya komputasi menghalangi eksplorasi lebih lanjut pada model-model lain atau teknik-teknik fine-tuning yang lebih mendalam.

5.2 Saran

Saran yang dapat penulis berikan untuk pengembangan selanjutnya adalah sebagai berikut:

1. Untuk penelitian selanjutnya bisa menerapkan *Few Shot* dengan cara diintegrasikan ke dalam model meta-learning atau *fine-tuning* menggunakan dataset yang kecil.

2. Dapat menggunakan attention modul untuk meningkatkan fokus model pada bagian-bagian tertentu dari data input yang lebih penting.
3. Dapat memperluas penelitian ini dengan mengaplikasikan model dalam situasi dunia nyata untuk mengevaluasi bagaimana model performa ketika dihadapkan pada gambar dengan kualitas dan kondisi pencahayaan yang beragam.



DAFTAR PUSTAKA

- Agustina, R., Magdalena, R., & Pratiwi, N. C. (2022). Klasifikasi Kanker Kulit menggunakan Metode Convolutional Neural Network dengan Arsitektur VGG-16. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 446-457.
- Annur, H. (2018). Klasifikasi Masyarakat Miskin Menggunakan Metode. *Ilkom Jurnal Ilmiah*, 160-165.
- As Shidiq, A. L., Suhartono, E., & Sofia, S. (2022). Klasifikasi Kecacatan Ban Untuk Mengendalikan Kualitas Produk Menggunakan Model CNN Dengan Arsitektur VGG-16. *e-Proceeding of Engineering*, 3216.
- Eka, S. (2023, Mei 24). Arti kode ban mobil dan cara bacanya yang benar. *Lipepal*.
- Erwandi, R., & Suyanto. (2020). Klasifikasi Kanker Payudara Menggunakan Residual Neural Network. *Ind. Journal on Computing*, 45-52.
- Fadlan, C., Ningsih, S., & Windarto, A. P. (2018). Penerapan Metode Naïve Bayes Dalam Klasifikasi Kelayakan Keluarga Penerima Beras Rastra. *Jutim*, 1-8.
- Fadlia, N., & Kosasih, R. (2019). Klasifikasi Jenis Kendaraan Menggunakan Metode Convolutional Neural Network (CNN). *Jurnal Ilmiah Teknologi dan Rekayasa*, 207-215.
- Febriyanto, N., Rahmad, C., & Vista, C. B. (2021). Deteksi Kerusakan Dan Kelayakan Ban Mobil Berdasarkan Ekstraksi Tekstur EKSTUR Menggunakan Gray Level Cooccurrence Matrix Dengan Metode Jaringan Syaraf Tiruan. *JIP (Jurnal Informatika Polinema)*, 27-32.
- Fehabutar, D. (2022, Desember 8). Pengertian Ban, Fungsi, dan Jenisnya. *Tiberman*.
- Hariyani, Y. S., Hadiyoso, S., & Siadari, T. S. (2020). Deteksi Penyakit Covid-19 Berdasarkan Citra X-Ray Menggunakan Deep Residual Network. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 443-453.
- Hendrawan, I. E., Adam, R. I., & Rozikin, C. (2022). Klasifikasi Retak Ban Kendaraan Menggunakan Arsitektur ResNet50. *SATIN – Sains dan Teknologi Informasi*, 22-32.
- Herdianto, & Nasution, D. (2023). Implementasi Metode CNN Untuk Klasifikasi Objek. *Jurnal Manajemen Informatika & Komputerisasi Akuntansi*, 54-60.
- Husna, I. N., Ulum, M., Saputro, A. K., Laksono, D. T., & Purnamasari, D. N. (2022). Rancang Bangun Sistem Deteksi Dan Perhitungan Jumlah Orang .

Seminar Nasional Fortei Regional 7, 1-6.

- Krisbianto, D., & Silalahi, A. H. (2022). Analisis Ketahanan Umur Pemakaian Ban Pada Mobil Penumpang Jenis Sedan Tipe F30 Dengan Mesin Berkapasitas 1998CC. *JURNAL KALPIKA*, 1-18.
- Listyalina, L. (2022). Identifikasi Kelayakan Ban Dengan Model *CNN* Resnet-50. *Berkala Penelitian Teknologi Kulit, Sepatu, Dan Produk Kulit Politeknik ATK*, 212-219.
- Maulana, D., & Solikhun, Y. (2018). Penerapan Data Mining Untuk Klasifikasi Produk (OK dan Scrap) Pada Industri Ban Menggunakan Metode Naïve Bayes. *Jurnal Teknologi Pelita Bangsa*, 115-118.
- Mousav, S. M., Zhu, W., Sheng, Y., & C. Beroza, G. (2019). CRED: A Deep Residual Network of Convolutional and Recurrent Units for Earthquake Signal Detection. *Scientific reports*, 1-14.
- Mubarog, I., Setyanto, A., & Sismoro, H. (2019). Sistem Klasifikasi pada Penyakit Breast Cancer dengan Menggunakan Metode Naïve Bayes . *Citec Journal*, 109-118.
- Prasetyo, A. P., M. Irfansyah, Exaudi, K., Septian, T. W., & Rendyansyah. (2023). Sistem Pemilah Sampah Organik Berbasis Raspberry Pi Menggunakan Klasifikasi *CNN* . *JURNAL SISFOTENIKA*, 76-90.
- Pratama, D. A. (2022). Klasifikasi Citra Tingkat Kelayakan Ban Motor Menggunakan Metode Convolutional Neural Network. *UISI*, 10-13.
- Radikto, Mulyana, D. I., Rofik, M., & Zakaria, M. Z. (2022). Klasifikasi Kendaraan pada Jalan Raya menggunakan Algoritma Convolutional Neural Network (*CNN*). *Jurnal Pendidikan Tambusai*, 1668-1679.
- Ridhovan, A., & Suharso, A. (2022). Penerapan Metode Residual Network (Resnet) Dalam Klasifikasi Penyakit Pada Daun Gandum. *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, 58-65.
- Ristiawanto, S. P., Irawan, B., & Setianingsih, C. (2021). FACIAL EXPRESSION RECOGNITION BASED ON CONVOLUTIONAL NEURAL NETWORK USING RESIDUAL NETWORK 50 ARCHITECTURE. *e- Proceeding of Engineering*, 6455-6469.
- Riyadi, A. S., Wardhani, I. P., Wulandari, M. S., & Widayati, S. (2022). Perbandingan Metode ResNet, YoloV3, dan TinyYoloV3 pada Deteksi Citra dengan Pemrograman Python. *PETIR: Jurnal Pengkajian dan Penerapan Teknik Informatika*, 135-144.
- Rohim, A., Tibyani, T., & Sari, Y. A. (2019). *Convolution Neural Network (CNN)* Untuk Pengklasifikasian Citra Makanan Tradisional. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 7037-7042.

- Saputra, A. E., & Mahbubah, N. A. (2021). Analisis Seven Tools Pada Pengendalian Kualitas Proses Vulkanisir Ban 1000 Ring 20 Di CV Citra Buana Mandiri Mandiri Suarabaya. *STRING (Satuan Tulisan Riset dan Inovasi Teknologi)*, 252-262.
- Saputra, F. B., Kallista, M., & Setianingsih, C. (2023). Deteksi Social Distancing Dan Penggunaan Masker Di Restoran Menggunakan Algoritma Residual Network (RESNET) . *e-Proceeding of Engineering*, 284-295.
- Suryaman, S. A., Magdalena, R., & Sa'idah, S. (2021). Klasifikasi Cuaca Menggunakan Metode VGG-16, Principal Component Analysis Dan K-Nearest Neighbor. *Jurnal Ilmu Komputer dan Informatika (JIKI)*, 1-8.
- Ufriandi, A. (2021). Analisis Tingkat Keausan Terhadap pemakaian Ban Merek A, B, dan C Menggunakan Ban Standar 90/90-14 46 P. *Surya Teknika*, 282- 288.
- Wu, Z., Nagarajan, T., Kumar, A., Rennie, S., Davis, L., Grauman, K., & Feris, R. (2018). BlockDrop: Dynamic Inference Paths in Residual Network. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 8817-8826.
- Yohannes, R., & Al Rivan, M. E. (2022). Klasifikasi Jenis Kanker Kulit Menggunakan CNN -SVM. *Jurnal Algoritme*, 133-144.
- Yusf, F., Wahyudi, B., & Nugraha, F. (2019). Pengembangan Model Pendeteksian Ban Ganda (Dual Tires) Menggunakan Fitur Haar-Like dan SVM sebagai Pengklasifikasi.
- Zayd, M., Oktavian, M. W., Meranggi, D. G., Figo, J., & Yudistira, N. (2022). Perbaikan klasifikasi sampah menggunakan pretrained Convolutional Neural Network. *Teknologi: Jurnal Ilmiah Sistem Informasi*, 1-8.
- Zhang, Y., Tian, Y., Kong, Y., Zhong, B., & Fu, Y. (2018). Residual Dense Network for Image Super-Resolution. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2472-2481

LAMPIRAN



**UNIVERSITAS MEDAN AREA**
FAKULTAS TEKNIK

Kampus I : Jalan Kolam Nomor 1 Medan Estate/Jalan PBSI Nomor 1 (061) 7366878, 7360168, 7364348, 7366781, Fax.(061) 7366998 Medan 20223
Kampus II : Jalan Setiabudi Nomor 79 / Jalan Sei Serayu Nomor 70 A, (061) 8225602, Fax. (061) 8226531 Medan 20122
Website: www.teknik.uma.ac.id E-mail: univ_medanarea@uma.ac.id

Nomor : 826/FT.6/01.10/XII/2023
Lamp : -
Hal : **Perubahan Judul Tugas Akhir** 21 Desember 2023

Yth, Pembimbing Tugas Akhir
Muhathir, ST, M. Kom
di
Tempat

Dengan hormat, Sehubungan dengan adanya perubahan judul tugas akhir maka perlu diterbitkan kembali SK Pembimbing Skripsi baru atas nama mahasiswa tersebut :

Nama : Nurul Almadinah Pane
NPM : 198160007
Jurusan : Teknik Informatika

Maka dengan hormat kami mengharapkan kesediaan saudara :

Muhathir, ST, M. Kom (Sebagai Pembimbing)

Adapun Tugas Akhir Skripsi berjudul :

"Klasifikasi Kerusakan pada Ban menggunakan CNN dengan Arsitektur MobileNet".

SK Pembimbing ini berlaku selama enam bulan terhitung sejak SK ini diterbitkan. Jika proses pembimbing melebihi batas waktu yang telah ditetapkan, SK ini dapat ditinjau ulang.

Demikian kami sampaikan, atas kesediaan saudara diucapkan terima kasih.


Dekan,
Dr. Eng. Supriatno, ST, MT
FAKULTAS TEKNIK

 **RASYID BAN**
Jl. Belat No.76 Medan

SURAT KETERANGAN SELESAI PENELITIAN

Yang bertanda tangan dibawah ini :

Nama : Rustam Pane
Jabatan : Pemilik/Owner Rasyid Ban

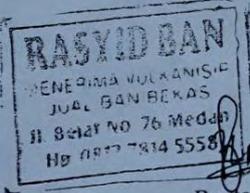
Dengan ini menerangkan bahwa dibawah ini :

Nama : Nurul Almadinah Pane
NIM : 198160007
Jurusan : Teknik Informatika
Fakultas : Teknik
Universitas : Universitas Medan Area

Telah selesai melakukan penelitian di Rasyid Ban untuk memperoleh data dalam rangka penyusunan tugas akhir yang berjudul "KLASIFIKASI KERUSAKAN PADA BAN MENGGUNAKAN CNN DENGAN ARSITEKTUR MOBILENET"

Dengan surat keterangan ini dibuat dan diberikan kepada yang bersangkutan untuk digunakan seperlunya.

Medan, 08 Februari 2024


Rustam Pane

Sourch Code

a) Import Pustaka

```
port random
port os
port numpy as np
port pandas as pd
port matplotlib.pyplot as plt
port tensorflow as tf
m tensorflow import keras
m sklearn.preprocessing import LabelBinarizer
m tensorflow.keras.preprocessing.image import ImageDataGenerator
m tensorflow.keras.preprocessing.image import ImageDataGenerator
m tensorflow.keras.layers import Input, Conv2D,
  MaxPooling2D, BatchNormalization, GlobalAveragePooling2D, Flatten, Dense,
  Dropout, Concatenate, AveragePooling2D, concatenate
m tensorflow.keras.models import Model
m tensorflow.keras.models import load_model
m tensorflow.keras.losses import CategoricalCrossentropy
m tensorflow.keras.optimizers import Nadam
m sklearn.metrics import classification_report
m tensorflow.keras.applications.mobilenet_v2 import MobileNetV2
m tensorflow.keras.callbacks import (Callback, CSVLogger, EarlyStopping,
  LearningRateScheduler, ModelCheckpoint, ReduceLROnPlateau)
m sklearn.metrics import accuracy_score, precision_score, recall_score,
  f1_score, fbeta_score, confusion_matrix
port cv2
port seaborn as sns
```

b) Pemanggilan dataset

```
aset_path = 'D:/nurulData'
listdir(dataset_path)
```

c) Pemanggilan data set

```
in_data = "D:/nurulData/training"
t_data = "D:/nurulData/testing"
l_data = "D:/nurulData/validation"
alue yang akan di perlukan sebelum running
age_size = (224, 224)
tch_size = 32
```

d) Menampilkan image masing-masing class

```
sses = ['kehausan tidak merata', 'lobang paku', 'retak', 'terkena benang', 'terkena
kawat'] # isi dengan klas yang kamu punya
, axes = plt.subplots(1, len(classes), figsize=(12, 4))
i, cls in enumerate(classes):
mg_path = os.path.join(train_data, cls,
random.choice(os.listdir(os.path.join(train_data, cls))))
```

```
img = plt.imread(img_path)
axes[i].imshow(img)
axes[i].set_title(cls)
axes[i].axis('off')
show()
```

e) Augumentasi data

```
in_datagen = ImageDataGenerator(
    rescale=1.0/255.0,
    shear_range=0.2,
    zoom_range=0.2,
    horizontal_flip=True )

val_datagen = ImageDataGenerator(
    rescale=1.0/255.0,
    shear_range=0.2,
    zoom_range=0.2,
    horizontal_flip=True)

train_generator = train_datagen.flow_from_directory(
    train_data,
    target_size = (224, 224),
    batch_size = batch_size,
    class_mode = 'categorical')

val_generator = val_datagen.flow_from_directory(
    test_data,
    target_size = (224, 224),
    batch_size = batch_size,
    class_mode = 'categorical')

validation_generator = val_test_datagen.flow_from_directory(
    val_data,
    target_size = (224, 224),
    batch_size = batch_size,
    class_mode = 'categorical')
```

f) Parameter yang digunakan pada model

```
Load MobileNetV2 with pretrained weights, excluding the top layers
base_model = MobileNetV2(weights='imagenet', include_top=False,
    input_shape=(224, 224, 3))

x = base_model.output
x = GlobalAveragePooling2D()(x)
x = Dense(1024, activation='relu')(x)
predictions = Dense(5, activation='softmax')(x)

# Construct the full model
```

```

model = Model(inputs=base_model.input, outputs=predictions)

# Freeze the base model layers (optional, depending on fine-tuning needs)
for layer in base_model.layers:
    layer.trainable = False

# Compile the model
model.compile(optimizer=Nadam(), loss=CategoricalCrossentropy(),
metrics=['accuracy'])
    
```

g) Training Data

```

history = model.fit(
    train_generator,
    steps_per_epoch=train_generator.samples // 64,
    epochs=50,
    validation_data=validation_generator,
    validation_steps=validation_generator.samples // 64,
)
    
```

h) Kompilasi model

```

optimizer = Nadam (learning_rate=0.001)
model.compile ( optimizer=optimizer,
loss='categorical_crossentropy', metrics=['accuracy'] )
model.save('nuruNadam.keras')
model = keras.models.load_model('nuruNadam.keras')
    
```

i) Grafik akurasi dan loss training dan validasi

```

figure(figsize=(12, 6))

subplot(1, 2, 1)
plot(history.history['accuracy'], label='MobilenetV2 Training Accuracy')
plot(history.history['val_accuracy'], label='MobilenetV2 Validation Accuracy')
title('Training and Validation Accuracy')
xlabel('Epoch')
ylabel('Accuracy')
legend()

subplot(1, 2, 2)
plot(history.history['loss'], label='MobilenetV2 Training Loss')
plot(history.history['val_loss'], label='MobilenetV2 Validation Loss')
title('Training and Validation Loss')
xlabel('Epoch')
ylabel('Loss')
legend()

tight_layout()
show()
    
```

j) Clasification report dan confusion matrix

```

batch_size=32
target_size=(224,224)
test_path = "D:/nurulData/testing"

test_generator = val_test_datagen.flow_from_directory(
    test_data,
    target_size=(224, 224),
    batch_size=batch_size,
    class_mode=None,
    shuffle=False)
test_generator.reset()

Calling the saved model for making predictions
model_klasifikasi = load_model('nuruNadam.keras')
test_labels = test_generator.classes
pred = model_klasifikasi.predict(test_generator, verbose=1)
predictions=np.argmax(pred,axis=1)

cm = confusion_matrix(test_labels, predictions)
plt.figure(figsize=(8, 6))
plt.imshow(cm, annot=True, fmt='d', cmap='Blues', xticklabels=classes,
           yticklabels=classes)
plt.xlabel('Predicted Labels')
plt.ylabel('True Labels')
plt.title('Confusion Matrix')
plt.show()

print(classification_report(test_labels, predictions, digits=4))
print(cr)

```