

KLASIFIKASI ENGINE FAILURE BERDASARKAN BUNYI MOBIL MENGGUNAKAN MFCC DAN STFT DENGAN MACHINE LEARNING

Bhustomy Hakim¹⁾, Fergie Joanda Kaunang²⁾, Angelina Praman Thenata³⁾, Ranny⁴⁾

^{1,2,3,4}Fakultas Teknologi dan Desain, Universitas Bunda Mulia, Jakarta

email: bhustomy.hakim@gmail.com, fkaunang@bundamulia.ac.id, athenata@bundamulia.ac.id,
ranny@bundamulia.ac.id

Abstract

Engine failure classification is very important to improve driving safety and reduce repair costs. One method commonly used by mechanics is to diagnose damage through the sound produced by vehicle components. However, this process still relies on manual expertise and can cause errors or delays in diagnosis. Therefore, this study aims to develop a sound-based car damage classification model using data science techniques, especially machine learning. Sound data was collected from various sources from collaboration between workshops in Indonesia in the form of engine sound files in wav format with different labels, then processed using the Mel Frequency Cepstral Coefficients (MFCC) and Short-Time Fourier Transformation (STFT) method to extract important features from sound signals. Furthermore, the Multilayer Perceptron algorithm is implemented to build a damage prediction model. This study evaluates the model based on accuracy score of confusion matrix to find the best model in detecting damage types based on sound. The model with MFCC for its feature extracting is proven to have higher accuracy of 83,25% than STFT that has 78,82% with model configuration of ReLU activation function and 512 neurons layer.

Keywords: Klasifikasi Bunyi, Engine Failure, MFCC, STFT, Machine Learning

Abstrak

Deteksi kerusakan mobil sangat penting untuk meningkatkan keselamatan berkendara dan mengurangi biaya perbaikan. Salah satu metode yang umum digunakan oleh mekanik adalah mendiagnosis kerusakan melalui suara yang dihasilkan oleh komponen kendaraan. Namun, proses ini masih bergantung pada keahlian manual dan dapat menyebabkan kesalahan atau keterlambatan diagnosa. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan model klasifikasi kerusakan mobil berbasis suara menggunakan teknik data science, terutama machine learning. Data suara dikumpulkan dari berbagai sumber dari kerjasama bengkel-bengkel di Indonesia berupa file suara mesin dengan format wav dengan label berbeda, kemudian diolah menggunakan metode Mel Frequency Cepstral Coefficients (MFCC) dan Short-Time Fourier Transformation (STFT) untuk mengekstrak fitur penting dari sinyal suara. Selanjutnya, dengan algoritma Multilayer Perceptron diimplementasikan untuk membangun model prediksi kerusakan. Penelitian ini mengevaluasi model berdasarkan nilai akurasi dari confusion matrix untuk menemukan model terbaik dalam mendeteksi jenis kerusakan berdasarkan suara. Model dengan MFCC sebagai metode ekstraksi fitur terbukti menghasilkan akurasi tertinggi sebesar 83,35% ketimbang STFT yang hanya memiliki akurasi sebesar 78,82% dengan konfigurasi fungsi aktivasi ReLU dan layer dengan 512 neuron.

1. PENDAHULUAN

Perkembangan teknologi pada dunia otomotif sangatlah pesat, seperti adanya mobil listrik dan *autonomous cars*. Indonesia tidak luput dari tren otomotif tersebut yang mengakibatkan adanya peningkatan jumlah kendaraan bermotor dari tahun ke tahun (Ahmad B., 2024). Meningkatnya jumlah kendaraan bermotor maka kebutuhan jasa reparasi juga meningkat. Kerusakan pada kendaraan bermotor, khususnya mobil memerlukan diagnosa yang memakan waktu, biaya, dan keahlian khusus (Karaman E., et al, 2021). Salah satu metode tradisional yang sering digunakan oleh mekanik adalah mendengarkan suara yang dihasilkan oleh mesin atau bagian mobil lainnya yang seringkali mengeluarkan suara spesifik (Xu L., et al, 2022).

Sebagai contoh, kerusakan sistem rem menghasilkan suara gesekan atau derit, sementara kerusakan mesin menghasilkan suara ketukan atau dengung (Halderman J. D., 2022). Namun, pendekatan ini sangat bergantung pada intuisi dan pengalaman manusia dalam mengumpulkan data dengan menggunakan panca inderanya (Liu Y., et al, 2024)). Cara kerja manusia dalam mengolah data gambar dan bunyi melalui serangkaian proses yang rumit, bukan hanya bergantung dari mata dan telinga, tapi juga rangkaian organ dalam yang saling berkaitan,

<https://doi.org/10.35145/joisie.v9i1.4936>


JOISIE licensed under a Creative Commons Attribution-ShareAlike 4.0 International License (CC BY-SA 4.0)

seperti otak manusia yang mampu melakukan proses yang kompleks untuk mengolah data tersebut. Dengan mengadopsi cara kerja otak manusia, teknologi menerapkan konsep Convolutional Neural Network yang dapat mendeteksi mulai dari gambar, suara, maupun video (Taye M. M., 20023). Pada penelitian tentang *stereo audio* membuktikan bahwa akurasi model dengan CNN lebih baik ketimbang model sederhana dari SVM yaitu peningkatan akurasi hampir sempurna 99% (Liu T., et al, 2021).

Dengan kemajuan teknologi *data science* dan *machine learning* memungkinkan potensi untuk mengembangkan sistem otomatis yang dapat mendeteksi dan mengklasifikasikan jenis kerusakan mobil berdasarkan suara yang dihasilkan. Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengembangkan sistem klasifikasi otomatis yang dapat mendiagnosa jenis kerusakan mobil melalui analisis suara yang dihasilkan dengan memanfaatkan teknik machine learning untuk menganalisis sinyal suara. Adapun metode identifikasi suara dalam penelitian ini diawali dengan melakukan ekstraksi cirinya menggunakan *Mel Frequency Cepstrum Coefficients* (MFCC) dan akan dibandingkan dengan *Short-Time Fourier Transformation* (STFT) (Abdul Z. K and Al-Tabani A. K, 2022). Selanjutnya, identifikasi dengan ekstrasi ciri tersebut menggunakan *Multilayer Perceptron Neural Network* (Murtagh F., 2021). Dengan demikian penelitian ini diharapkan mampu memberikan solusi otomatis untuk diagnosa kerusakan mobil secara lebih cepat, akurat, dan efisien yang dapat digunakan baik oleh bengkel maupun pemilik kendaraan.

2. METODE PENELITIAN

Penelitian ini menggunakan alur penelitian yang ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian

2.1 Data Collection

Tahap *data collection* dalam penelitian ini bersumber dari salah satu bengkel besar di Indonesia yang memiliki beberapa cabang di Jakarta dan Tangerang. Data yang kumpulkan berupa suara dari kerusakan kendaraan mobil yang pernah ditemukan oleh bengkel-bengkel tersebut. Dataset bunyi mobil diambil dari sebelum didiagnosa kerusakannya untuk label engine failure, serta setelah proses perbaikan pada mobil tersebut untuk label normal.

2.2 Data Preprocessing

<https://doi.org/10.35145/joisie.v9i1.4936>

JOISIE licensed under a Creative Commons Attribution-ShareAlike 4.0 International License (CC BY-SA 4.0)

Tahap *data preprocessing* merupakan langkah awal yang penting dalam setiap penelitian berbasis data dengan mengubah data mentah ke dalam bentuk yang lebih mudah dipahami. Tahap ini bertujuan untuk menyiapkan dan mengolah data agar dapat digunakan pada tahap *Building Model* (Dimitrov G. T., 2023). Berikut ini adalah tahapan-tahapan pada *Data Preprocessing* yaitu:

2.2.1 EDA (*Exploratory Data Analysis*)

EDA adalah langkah awal yang memungkinkan untuk menjelajahi dan memahami data yang sudah dimiliki sebelum memulai analisis yang lebih mendalam. Proses ini melakukan sejumlah aktivitas, seperti membuat visualisasi, mengidentifikasi pola atau trend dalam data, dan mengecek apakah ada data yang hilang (NaN, string yang kosong, dan data-data lain yang tidak valid) atau tidak konsisten (Sipayung E. M., 2023). Analisis data ini mengidentifikasi tipe data, kategori data, dan jumlah data dalam dataset yang disediakan. Selanjutnya hasil analisis tersebut akan disajikan dalam bentuk diagram untuk visualisasi yang lebih jelas dan informatif.

2.2.2 *Checking Missing Value*

Memeriksa nilai yang hilang (*missing values*) dalam dataset sangat penting karena dapat mempengaruhi hasil analisis dan model (Hakim B., 2021). Setelah proses analisis selesai, dilakukan pemeriksaan menyeluruh terhadap data. Pemeriksaan ini bertujuan untuk mendeteksi keberadaan data kosong. Jika ditemukan data kosong maka jumlahnya ditampilkan.

2.2.3 *Checking Skewness*

Langkah berikutnya yang dilakukan adalah menghitung skewness sepanjang baris dengan mengabaikan baris dengan nilai yang hilang. Jika nilainya lebih dari nol maka termasuk *skewness* positif yang dimana data akan miring ke kiri dan jika nilainya kurang dari nol maka termasuk *skewness* negatif yang dimana data akan miring ke kanan (Hagi A. and Rarasati D. B., 2024).

2.2.4 *Handling Outliers*

Outlier adalah data yang nilainya jauh berbeda dari data lain dalam satu set data. Kemunculannya disebabkan oleh berbagai hal seperti kesalahan saat pengumpulan data, kesalahan pengukuran, atau peristiwa yang tidak biasa. Terdapat dua tahap di bagian *handling outliers* yaitu *checking outliers* dan *impute outliers*. Pertama dalam *checking outliers* yang dilakukan adalah membuat boxplot agar bisa mengetahui kolom data mana yang memiliki *outliers*, jika di dalam boxplot terdapat lingkaran maka menandakan datanya sudah menyimpang dan selanjutnya menemukan indeks *outliers* dengan cara menggunakan metode *Interquartile Range* (IQR) (Billak K. and Saputra R., 2024), yang dimana rumusnya sebagai berikut, dimana Q1 sebagai batas bawah dan Q3 sebagai batas atas.

$$IQR=Q3-Q1 \text{ (1)}$$


Selanjutnya, mencari indeks *outliers* tiap kolom data untuk mengetahui apakah terdapat data yang mempunyai index *outliers* atau tidak ada yang mempunyai indeks *outliers*. Data dalam *impute outliers* yang dianggap menyimpang dihapus dengan cara diubah menjadi nilai null. Sedangkan data yang sudah dijadikan nilai null maka akan diisi oleh mean atau median sesuai dengan *skewness*/kemiringannya. Jika *skewness* di antara -2 sampai +2 maka data yang kosong diisi dengan mean, dan jika *skewness* di luar batas itu maka data yang kosong diisi dengan median (Shodiq U., et al, 2024).

2.2.5 Ekstraksi Fitur

Proses ekstraksi fitur menggunakan *variance threshold*. Batas ini digunakan untuk menghilangkan data yang memiliki kemiripan tinggi agar nantinya pada saat klasifikasi menjadi relevan. Adapun proses ini dapat dilakukan dengan mengubah dataset ke dalam bentuk heatmap yang berbentuk kotak dengan menampilkan nilai-nilai data yang ada di kolom data tersebut. Jika nilai pada kotak tersebut mempunyai hasil negatif dan positif, maka data akan dianggap berpengaruh. Tetapi jika data mendekati angka nol maka data tersebut

dianggap tidak berpengaruh dan harus dihapus dikarenakan memiliki toleransi yang rendah terhadap data lainnya. Setelah proses tersebut diketahui bahwa data yang berisi dari dataset (*data original/untrimmed*) dan data yang telah dihapus pada saat proses pemilihan data (*data trimmed*) (Paleva H. R. and Prasetyo B. H., 2024). Dan untuk melakukan ekstraksi fitur, dilakukan metode MFCC dan STFT untuk melihat metode mana yang cocok untuk mengklasifikasi *engine failure* pada bunyi mobil.

Metode Mel Frequency Cepstrum Coefficients (MFCC) merupakan metode ekstraksi ciri suara yang bertujuan untuk menangkap ciri suara berdasarkan sinyal diskritnya yang diubah dari berbasis waktu menjadi berbasis frekuensi. Metode ini melakukan filtering dengan skala mel yang memiliki frekuensi suara bernilai lebih kecil dari 1000 Hz sedangkan di atas 1000 Hz bersifat logaritmik. Langkah selanjutnya adalah mengubah kembali *spectrum log mel* menjadi spektrum waktu menggunakan metode *discrete cosine transform* (DCT) dan hasilnya disebut sebagai *mel frequency cepstral coefficients* (Yohannes Y. and Wijaya R., 2021). Adapun proses ekstraksi ciri ini ditunjukkan pada Gambar 2. Tahap pertama diawali dengan *frame blocking* dengan tujuan melakukan segmentasi dari sinyal suara. Segmentasi dilakukan karena kecepatan dari pengucapan kata tiap individu berbeda, dengan adanya segmentasi panjang data akan konsisten. Proses ini dilakukan secara overlapping agar tingkat kontinuitas datanya tetap terjaga.



Gambar 2. Tahapan MFCC

Tahapan selanjutnya adalah *windowing* dengan tujuan untuk menghaluskan hasil pemotongan dari tahapan *frame blocking*. Proses *windowing* ini mencegah adanya perubahan data antar frame yang terlalu jauh kisaran nilainya. Metode yang umum digunakan adalah Hamming window yang data suaranya diambil pada domain waktu. Hal ini mengakibatkan kesulitan pada proses perhitungan dan analisa. Kemudian dilakukan tahap *Fast Fourier Transform* (FFT) untuk mengubah domain waktu menjadi domain frekuensi sehingga akan lebih mudah untuk dianalisis. Setelah data diubah menjadi domain frekuensi maka tahap selanjutnya adalah *mel frequency wrapping* yang menyesuaikan dengan frekuensi didapat dengan frekuensi suara manusia, sehingga menghasilkan ciri suara yang bersesuaian dengan suara manusia.

Tahap terakhir adalah cepstrum yang mengubah kembali data frekuensi menjadi data berdomain waktu. Hasil dari tahap cepstrum menjadi koefisien MFCC yang digunakan sebagai hasil ekstraksi ciri suara (Ranny, et al, 2024). Ukuran data akhir ekstraksi ciri suara adalah sebesar $n \times m$, dimana n adalah jumlah dari data yang diinginkan (diinput pada tahap cepstrum), sedangkan m adalah panjang data yang didapat saat proses perubahan data analog menjadi data digital dan pada tahap *frame blocking*. Hasil dari MFCC ini menjadi input pada proses selanjutnya yaitu proses pelatihan dan pengenalan. Selain itu, pada penelitian ini dikomparasi dengan ekstraksi fitur STFT. Sinyal yang bergantung pada waktu diuraikan menggunakan Transformasi Fourier menjadi frekuensi masing-masing. Salah satu Transformasi Fourier mencakup *Short-Time Fourier Transformation* (STFT) yang banyak digunakan untuk mengekstraksi fitur dari sampel audio. Meskipun MFCC juga banyak digunakan dalam proses ekstraksi fitur, MFCC juga sangat sensitif terhadap derau latar belakang dalam sampel sehingga kurang efektif dalam mengekstraksi fitur, sementara di sisi lain, STFT digunakan bahkan pada sampel audio yang memiliki derau dan memberikan hasil yang efektif. Transformasi Fourier suatu fungsi menghasilkan frekuensi ekuivalennya untuk sinyal amplitudo input. Kemudian sinyal diubah menjadi sinyal frekuensinya menggunakan Transformasi Fourier. STFT adalah metode di mana transformasi FFT diterapkan setelah sinyal dipangkas oleh fungsi jendela. Ekspresi matematika untuk perhitungan fitur STFT (Gourisaria M. K., et al, 2024).

2.2.6 Splitting Data


Tahap *splitting* data dibagi menjadi dua data yaitu data *untrimmed* (data original) dan data *trimmed* (data yang sudah dihapus pada saat proses pemilihan data). Data *untrimmed* mempresentasikan realitas data sedangkan data *trimmed* memberikan akurasi yang lebih baik. Data *untrimmed* dan data *trimmed* dibagi menjadi *training set* sebesar 80% dari data dan *testing set* sebanyak 20% dari data (Hakim B., et al, 2025).

<https://doi.org/10.35145/joisie.v9i1.4936>

2.3 Building MLP Model

Tahap building *Multilayer Perceptron* (MLP) model merupakan rancangan model klasifikasi kerusakan kendaraan berdasarkan data yang telah diolah melalui data preprocessing. Model MLP ini didasarkan pada arsitektur jaringan saraf tiruan feedforward yang terdiri dari input layer, hidden layers, dan output layer. Setiap lapisan dalam MLP terhubung sepenuhnya dengan lapisan berikutnya melalui koneksi berbobot. Model ini digunakan untuk tahap training yang melakukan pengenalan pola sinyal suara sehingga dapat indentifikasi kerusakan kendaraan. Selanjutnya dilakukan tahap testing test dengan menggunakan model yang telah dirancang sehingga menghasilkan klasifikasi label dengan benar.

Metode machine learning merupakan metode yang digunakan untuk memecahkan permasalahan pada penelitian di bidang Ilmu Komputer. Permasalahan yang biasa dipecahkan antara lain, klasifikasi, clustering, prediksi dan penemuan pola. Salah satu metode klasifikasi untuk identifikasi kerusakan kendaraan berdasarkan diagnosis menggunakan *Multilayer Perceptron* (MLP) *Neural Network*. Metode ini dapat mengelompokkan data dari dataset yang telah diberikan (Suwitono Y.A and Kaunang F. J, 2022). Adapun MLP didasarkan pada arsitektur jaringan saraf tiruan *feedforward*. Model MLP terdiri dari input layer, *hidden layers*, dan output layer. Setiap lapisan terhubung sepenuhnya dengan lapisan berikutnya melalui koneksi berbobot yang ditunjukkan pada Gambar 3.



Gambar 3. Struktur MLP model dengan 2 *hidden layers*


Sebagaimana digambarkan dalam arsitektur MLP, fitur input dipetakan melalui beberapa lapisan neuron yang setiap lapisannya semakin kompleks dalam mengekstraksi pola. Selanjutnya pola digabungkan sehingga menjadi lapisan output untuk menghasilkan keputusan klasifikasi akhir. Dalam setiap hidden layer parameter MFCC dan STFT kemudian diimplementasikan pada dua MLP yang dibuat paralel. Pada masing-masing MLP diterapkan *hyperparameter tuning* dengan jumlah *epoch* 50, *learning rate* 0,1, dan menggunakan *Keras TensorFlow*.

2.4 Evaluation Model

Tahap ini melakukan evaluasi model MLP yang telah dirancang dengan menggunakan *confusion matrix*. Serta cross-validation dengan nilai k 10 *folds*. Adapun unsur yang diuji yaitu akurasi menggambarkan tingkat kesesuaian nilai hasil klasifikasi dengan nilai sebenarnya. Kemudian diuji *precision* yaitu kesesuaian antar data benar positif dengan data prediksi. Selanjutnya, *recall* yang memaparkan keberhasilan klasifikasi dalam memperoleh informasi dari semua data yang tersedia. Terakhir uji *F1-score* menggambarkan hasil gabungan dari *precision* dan *recall* yang menunjukkan kinerja keseluruhan suatu model (Haristu A., et al, 2023).


3. HASIL DAN PEMBAHASAN

Dataset pada penelitian ini telah dihimpun dan terdapat 1.698 dataset dengan 849 dengan label bunyi engine failure dan 849 dengan label normal. Pada tahap *preprocessing* data bunyi dengan label engine failure dan normal divisualisasikan dengan *wave transform* dari amplitudo terhadap waktu yang dapat dilihat pada Gambar 4.




Gambar 4. Audio Waveform Data Bunyi Mobil Engine Failure dan Bunyi Mobil Normal

Dataset ini tidak ada silent part dalam bunyi mobil, namun masih terdapat gangguan suara seperti suara orang berbicara, suara radio, suara lingkungan, yang bukan bunyi mesin. Kemudian gangguan tersebut dihilangkan dengan metode Denoising Wavelet Transform (DWT) yang terlihat pada Gambar 5.




Gambar 5. Waveform Hasil DWT Bunyi Engine Failure (kiri) dan Bunyi Normal (kanan)

Ekstraksi fitur untuk menjadi patokan klasifikasi apakah mobil tersebut mengalami kerusakan engine failure atau tidak dilakukan dengan menggunakan dua metode yaitu MFCC dan STFT. Berikut hasil ekstraksi fitur dengan visualisasi heatmap dan spectrogram pada Gambar 6 untuk label engine failure dan Gambar 7 untuk label normal.



Gambar 6. Hasil MFCC (kiri) dan STFT (kanan) pada dataset label engine failure



Gambar 7. Hasil MFCC (kiri) dan STFT (kanan) pada dataset label normal

Fitur yang diekstraksi dengan MFCC membagi rentang waktu dengan jumlah 13 dengan masing-masing fitur dari setiap rentang waktunya sekitar lebih dari 10.000 koefisien MFCC. Jangkauan koefisien dari skor -50 sampai 150 yang dihasilkan dari amplitudo, frekuensi, dan intensitas bunyi aslinya dengan rata-rata tiap fiturnya yaitu 25 untuk label engine failure, dan -5 untuk label normal. Sedangkan untuk STFT membagi 8192 bagian fitur dengan isi nilai intensitas -80 sampai +0 desibel (dB) dengan rata-rata tiap fiturnya -53 dB untuk label engine failure dan -30 dB untuk label normal. Dengan ekstraksi fitur tersebut nantinya akan menjadi penentu input untuk perhitungan selanjutnya dari algoritma machine learning yang dipakai yaitu *Multilayer Perceptron* (MLP) model.

Untuk *Multilayer Perception* (MLP) model, dengan konfigurasi pengaturan beberapa parameter yang ditentukan adalah jumlah layer yaitu 4-layer dan neuron per layer yaitu 64, 256, 512, serta fungsi aktivasi dengan menggunakan fungsi *Rectified Linear Unit* (ReLU) karena cepat dan efektif untuk menghindari gradient yang tidak ada atau menghilang serta dan fungsi aktivasi *sigmoid*. Evaluasi performa model pada penelitian ini menggunakan *confusion matrix* dengan label engine failure dan normal serta prediksi engine failure dan normal yang sudah diterapkan pada training dan testing data pada model. Tabel 1 berisikan isi hasil akurasi dari konfigurasi model berbeda dengan ekstraksi fitur MFCC dan STFT.

Tabel 1. Hasil akurasi konfigurasi model berbeda untuk MFCC dan STFT

MLP Model		Akurasi	
Fungsi Aktivasi	Neurons	MFCC	STFT
ReLU	64	78,05%	73,00%
	256	81,67%	77,50%
	512	83,25% *	78,82%*
sigmoid	64	63,20%	58,75%
	256	78,83%	65,33%
	512	78,56%	73,05%

Penelitian ini memberikan hasil bahwa konfigurasi model terbaik adalah konfigurasi dengan fungsi aktivasi ReLU dengan 4-layer masing-masing memiliki 512 neurons yang dibuktikan dengan baik dengan ekstraksi model MFCC maupun STFT menghasilkan nilai akurasi tertinggi yaitu 83,25% dan 78,82%. Sedangkan untuk perbandingan ekstraksi fitur, MFCC lebih unggul dengan 83,25% nilai akurasi dengan selisih 4,43 poin dari nilai akurasi STFT. Hal ini menunjukkan bahwa model MLP lebih baik menggunakan ekstraksi fitur MFCC 13 rentang waktu fitur ketimbang STFT dengan banyak fitur. Hal ini disebabkan karena MFCC lebih robust terhadap noise yang ada pada suara mesin yang sangat kuat dan menyebabkan fitur lebih tidak berkoleransi setelah diterapkan *discrete cosine transform* dimana denoising sangat penting untuk ekstraksi fitur yang lebih jelas pada perhitungan pada hidden layer MLP. Sedangkan STFT menghasilkan spektrum dua dimensi besar yaitu frekuensi dan waktu yang masih harus dilakukan *preprocessing* lebih lanjut.

4. SIMPULAN

Dalam melakukan pengklasifikasian deteksi engine failure pada bunyi mobil dapat diterapkan machine learning dengan model *Multilayer Perceptron* (MLP) dengan ekstraksi fitur MFCC yang terbukti lebih baik secara akurasi dengan nilai 83,25% untuk dataset suara. Rata-rata MFCC koefisien untuk data dengan label engine failure sebesar 25 sedangkan label normal -5. Untuk STFT memiliki fitur paling efektif yaitu intensitas suara dengan rata-rata -53 dB untuk label engine failure sedangkan label normal -30dB. Dengan diketahui

<https://doi.org/10.35145/joisie.v9i1.4936>

JOISIE licensed under a Creative Commons Attribution-ShareAlike 4.0 International License (CC BY-SA 4.0)

simpulan seperti diatas, eksplorasi arsitektur CNN-RNN dan eksplorasi ekstraksi selain MFCC atau STFT dapat dilakukan dalam proses penanganan suara mesin rusak. Hasil model ini diharapkan terdapat aplikasi baik built-in maupun tambahan untuk masyarakat dapat mendeteksi tanda-tanda engine failure agar dapat dilakukan tindakan segera sehingga peluang untuk model ini diimplementasikan dapat diintegrasikan dengan aplikasi bengkel yang dapat bisa memanggil teknisi untuk memperbaiki.

5. UCAPAN TERIMA KASIH

Terima kasih kepada Mitra Bengkel-Bengkel yang sudah berkenan menjadi mitra pada penelitian ini dan Universitas Bunda Mulia yang mendanai penelitian ini pada Hibah Kolaboratif Nasional.

6. DAFTAR PUSTAKA

- Ahmad B., (2024), Jumlah kendaraan bermotor menurut provinsi dan jenis kendaraan (unit), *Jurnal Badan Pusat Statistik (BPS)*, 18(1), 202-208, <https://doi.org/10.369493/bps.v18i1.29304>
- Abdul Z. K. and A. K. Al-Talabani, (2022), Mel frequency cepstral coefficient and its applications: A review, *IEEE Access*, 10(2), pp. 122136–122158, 10.1109/ACCESS.2022.3223444
- Billah, K., & Saputra, R. (2024). Deteksi penipuan kartu kredit menggunakan metode random forest. *JOISIE (Journal Of Information Systems And Informatics Engineering)*, 8(2), 200-208. <https://doi.org/10.35145/joisie.v8i2.4064>
- Dimitrov G. T, (2023), speaker recognition, *University of Patras*, 8(1), pp 24-36, <https://doi.org/10.2193/3928-9329.v8i1.2039>
- Gourisaria, M.K., Agrawal, R., Sahni, M. (2024), Comparative analysis of audio classification with MFCC and STFT features using machine learning techniques. *Discov Internet Things*, 4(1), 24-36, <https://doi.org/10.1007/s43926-023-00049-y>
- Hagi A. and Rarasati D. B., (2024), Sentiment Analysis of Sirekap Application Review Using Logistic Regression Algorithm, *Jurnal Informatika*, 11(2), pp. 55–64, <https://doi.org/10.31294/inf.v11i2.22066>
- Hakim B., (2021), analisa sentimen data text preprocessing pada data mining dengan menggunakan machine learning, *Journal of business and audit information systems*, 4(2), 16-22, <http://dx.doi.org/10.30813/jbase.v4i2.3000>
- Hakim, B., Kaunang, F. J., Susanto, C., Salim, J., & Indradjaja, R. (2025). Implementasi machine learning dalam pengelompokan musik menggunakan algoritma k-means clustering. *IDEALIS : InDonEsiA Journal Information System*, 8(1), 74–83. <https://doi.org/10.36080/idealis.v8i1.3357>
- Halderman J. D., (2022), Automotive Engines: Theory and Servicing, *Pearson Education*, 12(2), pp 76-89, https://books.google.co.id/books?id=E_v0DQAAQBAJ
- Haristu, A., Herdiyeni, Y., & Marimin, M. (2023). Prediksi harga komoditi pertanian menggunakan algoritme long short term memory di desa kabandungan sukabumi. *JOISIE (Journal Of Information Systems And Informatics Engineering)*, 7(2), 181-192. 10.35145/joisie.v7i2.3104
- Karaman E., Rende H., and Akşahin M. F., (2021), Recognizing cars by engine sounds, *Journal of Mühendis ve Makina*, 60(5), pp. 148–164. <https://dergipark.org.tr/tr/pub/muhendismakina/issue/48382/612553>
- Liu T., Yan D., Wang R., Yan N., Chen G., (2021), Identification of fake stereo audio using SVM and CNN, *Information 2021*, 12(7), 263-277, <https://doi.org/10.3390/info12070263>
- Liu Y., Zhang J., and L. Ma, (2024) A fault diagnosis approach for diesel engines based on self-adaptive WVD, improved FCBF and PECOC-RVM, *Neurocomputing*, 177(5), pp. 600–611, <https://doi.org/10.1016/j.neucom.2024.11.074>
- Murtagh F., (2021), Multilayer perceptrons for classification and regression, *Neurocomputing*, 2(6), pp. 183–197, [https://doi.org/10.1016/0925-2312\(21\)90023-5](https://doi.org/10.1016/0925-2312(21)90023-5)
- Paleva, H. R., & Prasetyo, B. H. (2024). Penerapan Short Time Fourier Transform pada MFCC untuk Sistem Pengenalan Ucapan Tingkat Stres. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 8(4), <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/13376>
- Ranny, Lestari D. P., Mengko T. L. E. R., (2024), Separation sound event localization and detection using neural network and time frequency masking, *International Journal of Innovative Computing, Information and Control (IJICIC)*, 20(3), 709-721, 10.24507/ijicic.20.03.709
- Shodiq, U., Maimunah, M., & Avizenna, M. (2024). Klasifikasi jalan rusak menggunakan transfer learning arsitektur vgg16. *JOISIE (Journal Of Information Systems And Informatics Engineering)*, 8(1), 75-85. doi:10.35145/joisie.v8i1.4243
- Sipayung E. M., (2023), Klasifikasi image jenis kayu pada furnitur dengan convolutional neural network, *Jurnal Telematika*, 18(2), pp. 82–87, <https://doi.org/10.61769/telematika.v18i2.617>
- Suwitono Y. A., Kaunang F. J., (2022), Implementasi algoritma convolutional neural network (cnn) untuk <https://doi.org/10.35145/joisie.v9i1.4936>

klasifikasi daun dengan metode data mining semma menggunakan keras, *Jurnal Komtika*, 6(2), 38-52, <https://doi.org/10.31603/komtika.v6i2.8054>

Taye M. M., (2023), Theoretical understanding of convolutional neural network: concepts, architectures, applications, future directions, *Computation* 2023, 11(3), 52-66, <https://doi.org/10.3390/computation11030052>

Xu L., Wang T, Xie J., Yang J., and Gao G., (2022), A mechanism-based automatic fault diagnosis method for gearboxes, *Journal of Sensors*, 22(23), p. 9150-9164, <https://doi.org/10.3390/s22239150>

Yohannes, Y., & Wijaya, R. (2021). Klasifikasi makna tangisan bayi menggunakan cnn berdasarkan kombinasi fitur MFCC dan DWT. *JATISI (Jurnal Teknik Informatika Dan Sistem Informasi)*, 8(2), 599-610. <https://doi.org/https://doi.org/10.35957/jatisi.v8i2.470>