

Diagnosa Kesehatan Motor Induksi menggunakan CNNs 1D pada Sinyal Multimodal

¹Dessy Ana Laila Sari, ²Hilda Ashari

¹Rekayasa Elektro, Universitas Negeri Makassar, Makassar

²Pendidikan Teknik Elektro, Universitas Negeri Makassar, Makassar

¹dessynaa@unm.ac.id, ²hildaashari@unm.ac.id

Abstract – The aims is to develop a 1D Convolutional Neural Network (CNNs) model for diagnosis the health condition of induction motors using multimodal data from accelerometer, microphone and temperature sensors. The 1D CNNs model is designed to learn complex pattern in time-series data and classify the motor's condition into 2 categories : “Healthy” or “Faulty”. Experiments were conducted by varying data conditions (Unloaded and Loaded), data training and testing ratios (50:50, 70:30, 80:20, 90:10), and the number of epochs (50,100,500,1000). The result show that the 1D CNNs model achieved varying accuracy depending on the parameter combinations. Under Unloaded conditions, the highest accuracy of 89.10% was obtained with a 90:10 data ratio and 50 epochs. Conversely, under Loaded conditions, the highest accuracy of 87.20% was achieved with a 50:50 ratio and 100 epochs. Overall, accuracy was higher under Unloaded conditions, indicating differences in data characteristics. This research demonstrated the potential of 1D CNNs in induction motor diagnosis. However, further research is needed to improve model performance and generalization.

Keywords — *Induction Motor, CNNs, Condition Diagnosis, Multimodal Data, Parameters Variation*

Abstrak—Penelitian ini mengembangkan model Convolutional Neural Networks (CNNs) 1D untuk mendiagnosa kondisi Kesehatan motor induksi menggunakan data multimodal dari sensor akselerometer, mikrofon dan temperature. Model ini dirancang untuk mempelajari pola kompleks dalam data domain waktu dan mengklasifikasikan kondisi motor induksi ke dalam 2 kategori : “Sehat” atau “Rusak”. Eksperimen dilakukan dengan bervariasi kondisi data (Unloaded dan Loaded), rasio pembagian data training dan testing (50:50, 70:30, 80:20, 90:10), serta jumlah parameter epoch (50,100, 500, 1000). Hasil menunjukkan bahwa model mencapai akurasi yang bervariasi tergantung pada kondisi parameter tersebut. Pada kondisi Unloaded, akurasi tertinggi 89.10% dicapai pada rasio data 90:10 dan 50 epoch, sedangkan pada kondisi Loaded, akurasi tertinggi 87.20% dicapai pada rasio 50:50 dan 100 epoch. Secara umum, akurasi lebih tinggi pada kondisi Unloaded, yang mengindikasikan perbedaan karakteristik data. Penelitian ini menunjukkan potensi CNNs 1D dalam diagnosis motor induksi. Namun penelitian lebih lanjut diperlukan untuk meningkatkan kinerja dan generalisasi model.

Kata Kunci—*Motor Induksi, CNNs, Diagnosis Kondisi, Data Multimodal, Variasi Parameter*

I. Pendahuluan

Motor induksi merupakan komponen yang memiliki peran penting dalam industry. Dengan kemampuan mekanik yang kuat membuat motor induksi mampu beroperasi pada banyak keadaan [1]. Dalam penggunaan jangka panjang, potensi terjadinya deformasi maupun pengurangan kemampuan komponennya mampu menurunkan performa kerja motor induksi [2].

Motor induksi terdiri dari komponen mekanik dan elektrik seperti stator, rotor, *bearing*, *winding* dan lainnya [3]. Karena kemampuan motor induksi yang sangat kuat sehingga dioperasikan di lingkungan yang cukup ekstrim membuat motor induksi menghadapi banyak kondisi penuh tekanan[4]. Akibat kondisi tersebut, penting melakukan identifikasi kesehatan motor listrik secara berkala guna menghindari kerusakan yang fatal [5], [6].

Diagnosa pada motor induksi memiliki peran penting dalam memastikan performa motor induksi berada pada keadaan optimal. Dengan karakteristik motor induksi, deteksi kerusakan dini menjadi sangat penting dalam mencegah perbaikan alat yang mahal [7]. Selain itu, aspek *monitoring* dalam diagnosa kerusakan mesin berperan penting sehingga berbagai sensor diintegrasikan untuk memantau keadaan motor induksi[8]. ``am monitoring kondisi dilakukan observasi terhadap kondisi mesin, yang terdiri dari berbagai proses *maintenance* dengan pendekatan berbasis data [2]. Data ini bisa berupa suhu, getaran, arus motor, gambar, sinyal akustik, dan sebagainya.

Pengembangan sistem *monitoring* dan diagnosa kerusakan pada motor induksi telah banyak dilakukan dan didokumentasikan. *Review* tentang metode diagnosis kerusakan pada motor induksi, terutama pada bagian *squirrel-cage* telah dilakukan dari tahun ke tahun dengan menyesuaikan domain penerapannya [9]. Penerapan *artificial intelligent* dalam diagnosa kerusakan motor induksi juga dilakukan dengan memanfaatkan teknik berbasis sinyal yang dihasilkan melalui analisis data vibrasi, torsi elektromagnetik hingga analisa suhu pada motor induksi [10]. *Review* mengenai *monitoring* kondisi motor induksi [11] memberikan penguatan mengenai Teknik *non-invasive* dalam melakukan *monitoring* kondisi motor induksi menjadi tren dengan penggunaan metode analisis *thermal imaging* sebagai metode yang paling efisien.

Implementasi metode SVM [12] dalam melakukan diagnosa kerusakan komponen stator pada motor induksi, telah

dilakukan dengan memanfaatkan data sinyal dari sensor tegangan, sensor arus dan *tachometer* pada motor induksi tiga fase yang menghasilkan akurasi diagnosa kerusakan sebesar 90,62%. Penelitian [13] menerapkan optimasi Bayes pada diagnosa kerusakan rotor, pada penelitian ini sinyal motor berupa arus dan getaran pada motor induksi digunakan ke dalam berbagai metode *machine learning* dan menghasilkan akurasi tertinggi 95,20% dengan metode klasifikasi DT. [14] menerapkan metode CNNs dalam deteksi kerusakan rotor dengan penambahan FFT dalam pemrosesan sinyal arus saja, penelitian ini mampu melakukan klasifikasi keadaan komponen rotor pada motor induksi dengan akurasi mencapai 100%. Seluruh penelitian tersebut, memanfaatkan masukan berupa input sinyal arus maupun getaran.

Berdasarkan temuan-temuan pada penelitian sebelumnya, pengembangan sistem diagnosis kesehatan motor induksi yang menggunakan sinyal multimodal terutama kecepatan dari sensor *accelerometer* dan sinyal getaran pada motor induksi belum banyak diterapkan. Adapun metode yang akan digunakan adalah CNNs 1D yang merupakan metode klasifikasi yang cukup dasar dalam *machine learning*.

II. Metode Penelitian

A. Dataset

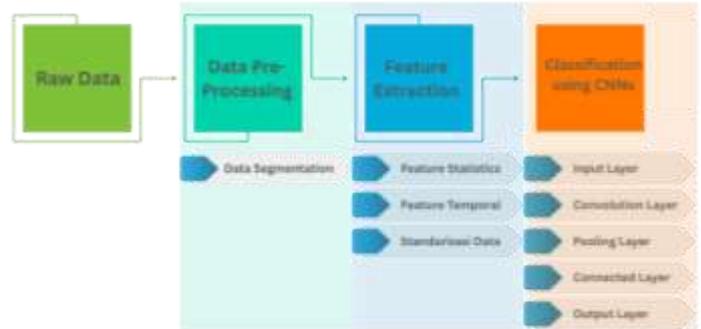
Pada penelitian ini dataset yang diambil berdasar pada dataset University of Ottawa [15]. Dataset terdiri dari 128 file data dengan kategori keadaan motor tanpa beban “*unloaded*” dan keadaan dengan beban “*loaded*”. Dataset terdiri dari sinyal kecepatan sensor *accelerometer*, sinyal akustik berupa getaran dan sinyal dari sensor suhu pada motor induksi objek. Setiap individu dataset berdurasi 10 detik dengan *sampling rate* 42 kHz. Adapun kondisi kerusakan yang dimiliki dibagi menjadi kerusakan rotor, stator serta *bearing*. Dataset ini dipilih karena telah menyediakan jenis data multimodal yang relevan dalam diagnosa kondisi kesehatan motor induksi, yang pada penelitian ini akan didiagnosa keadaan kesehatannya menjadi 2 kategori “Sehat” dan “Rusak” untuk lebih detil dataset dapat dilihat pada Tabel 1.

Tabel 1. Deskripsi Dataset

No	Kondisi Beban Motor	Kondisi Kesehatan Motor	Jumlah Data
1	Tanpa Beban	Sehat	8
		Rusak	56
2	Dengan Beban	Sehat	8
		Rusak	56

B. Alur Penelitian

Analisis kondisi kesehatan motor induksi dilakukan dengan menerapkan Teknik *artificial intelligent* CNNs pada dataset yang digunakan [15] dengan alur yang ditunjukkan pada Gambar 2 berikut.



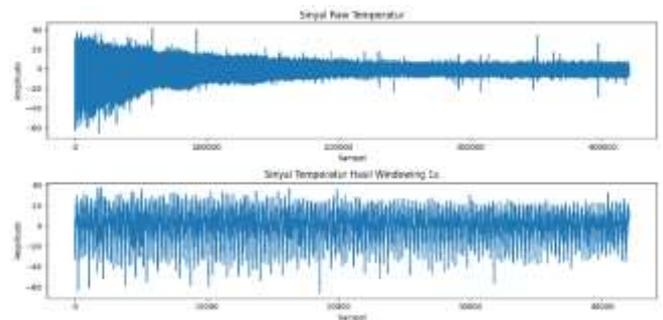
Gambar 1. Alur Penelitian

C. Data Preprocessing

1. Data Segmentation

Data sinyal yang dimiliki merupakan data *raw*, sehingga perlu dilakukan *preprocessing*. Adapun pada tahap ini, data sinyal keseluruhan akan disegmen menjadi bagian kecil. Data *raw* yang sangat besar ini perlu disegmen menjadi lebih kecil lagi. Dengan melakukan segmentasi pada data, model mampu menjadi lebih peka dalam mengambil pola rentang pendek dalam data[16]. Selain itu, hubungan antara variabel *multivariate* dapat mempermudah pengambilan informasi.

Sinyal dataset[15] memiliki durasi pencuplikan data selama 10s dan *sampling rate* 42 kHz data menjadi sangat besar sehingga pada penelitian ini dilakukan segmentasi dengan metode *windowing* menjadi 1s. Dengan adanya proses segmentasi, data sinyal yang panjang ini dapat dipecah menjadi bagian lebih kecil sehingga mudah untuk dianalisis hal ini memungkinkan model CNNs 1D yang didesain dapat mempelajari pola-pola local dalam sinyal yang mungkin terlewatkan apabila seluruh data dianalisis secara keseluruhan.



Gambar 2. Proses segmentasi dengan metode *windowing* 1s

2. Feature Extraction

Tahap selanjutnya yaitu *feature extraction*. *Feature extraction* merupakan proses transformasi data *raw* ke dalam representasi numerik [16] yang lebih ringkas dan informatif sehingga dapat digunakan sebagai *input* untuk model CNNs yang dikembangkan. Dalam penelitian, proses *feature extraction* bertujuan untuk mendapatkan *feature* utama pada data yang telah disegmentasi sebelumnya dengan mempertimbangkan karakteristik sinyal yang relevan untuk diagnosa kondisi kesehatan motor induksi. Adapun *feature* yang diambil adalah *feature* statistik dan *feature* temporal pada dataset yang dimiliki.

Feature statistic merupakan representasi numerik yang dapat meringkas karakteristik utama dalam data. Secara umum, *feature statistic* menggambarkan berbagai aspek dari distribusi data seperti nilai pusat, sebaran, bentuk serta keberadaan *outlier*. Dalam penelitian ini, *feature statistic* digunakan untuk menangkap pola-pola yang relevan dengan kondisi kesehatan motor induksi, seperti perubahan Tingkat getaran, kebisingan dan suhu. Adapun rincian terkait *feature* statistik dapat dilihat pada Tabel 2 berikut.

Tabel 2. Detail *feature* statistik yang digunakan dalam penelitian[17]

No	Feature	Formula
1	Rata – rata (μ)	$RE_1 = \frac{1}{N} \sum_{j=1}^N e_i$
2	Standar deviasi (σ)	$RE_2 = \sqrt{\frac{\sum_{j=1}^N (e_i - \mu)^2}{N}}$
3	Nilai minimum	$RE_3 = \min(e_i)$
4	Nilai maksimum	$RE_4 = \max(e_i)$
5	Skewness	$RE_5 = \sqrt{\frac{1}{6N} \sum_{j=1}^N \left(\frac{e_i - RE_1}{RE_2}\right)^3}$
6	Kurtosis	$RE_6 = \sqrt{\frac{N}{24} \left(\frac{1}{N} \sum_{j=1}^N -3\right)}$

Selain *feature* statistik, dalam penelitian juga menggunakan *feature* temporal pada data untuk menangkap karakteristik dinamis yang relevan dengan kesehatan motor induksi. *Feature* ini dapat memberikan informasi terkait perubahan sinyal seiring dengan waktu atau frekuensi data. Adapun *feature* temporal yang digunakan dalam penelitian berdasar dengan FFT, *Wavelet Transform* dan autokorelasi sebagai metode ekstraksinya sehingga didapatkan pola frekuensi dan waktu yang mungkin tersembunyi dalam domain waktu. Secara garis

besar, hasil *feature* yang didapatkan pada proses ini dapat dilihat pada Tabel 3 di bawah ini.

Tabel 3. *Feature* temporal yang diekstraksi pada penelitian ini

No	Feature	Metode ekstraksi
1	Frekuensi dominan	FFT
2	Amplitudo frekuensi	FFT
3	Koefisien <i>wavelet</i>	<i>Wavelet Transform</i>
4	Koefisien autokorelasi	Autokorelasi

3. Standarisasi Data

Normalisasi data dilakukan untuk mengubah rentang nilai *feature* data menjadi rentang yang lebih seragam. Dalam penelitian proses standarisasi dilakukan dengan menggunakan metode *StandardScaler* yang dimiliki *library* *scikit-learn* di Python yang mentransformasi setiap *feature* numerik menjadi nilai dalam rentang 0 dan 1 yang ditunjukkan pada (1). Proses standarisasi menjadi penting dalam penelitian ini karena pada model CNNs 1D sangat sensitive terhadap skala data.

Standarisasi juga diterapkan secara terpisah untuk setiap modalitas data akselerometer, mikrofon dan temperatur karena adanya perbedaan karakteristik dan rentang nilai yang signifikan antar datanya. Dengan adanya perlakuan ini, setiap set *feature* dari masing-masing sensor distandarisasi secara independent untuk memastikan bahwa kontribusi setiap *feature* dalam model CNNs 1D seimbang.

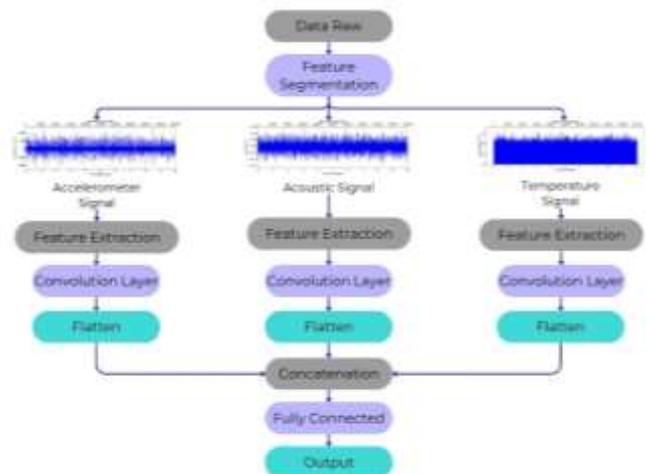
$$z = \frac{e_i - \mu}{\sigma} \tag{1}$$

Keterangan :

- e_i = nilai *feature* asli
- μ = rata – rata dari *feature* tersebut
- σ = standar deviasi dari *feature* tersebut
- z = nilai *feature* yang telah distandarisasi

D. Metode CNNs

Convolutional Neural Network (CNNs) merupakan salah satu struktur *deep neural network* yang digunakan secara



Gambar 3. Arsitektur CNNs 1D yang dibuat

luas. Dengan kemampuannya dalam mengekstrak fitur data *raw* secara langsung, CNNs menunjukkan performa yang kompetitif Ketika dikombinasikan dengan fitur input buatan [18], [19]. Dalam konteks penelitian ini, CNNs dipilih karena kemampuannya dalam menangkap pola-pola local dalam sinyal sensor multimodal yang terdiri dari akselerometer, mikrofon dan temperature yang relevan dengan kondisi kesehatan pada motor induksi. Arsitektur CNNs 1D yang digunakan pada penelitian ini digambarkan pada Gambar 2 berikut.

1. Input Layer

Seperti pada ilustrasi Gambar 2. *Input* model yang diberikan terdiri dari tiga input terpisah, yang masing-masing untuk data akselerometer, mikrofon dan temperature. Setiap *nput* memiliki dimensi yang sesuai dengan jumlah fitur yang telah diekstraksi dari setiap modalitas sensor.

2. Convolution Layer

Lapisan konvolusi atau *convolution layer* berfungsi untuk mengekstraksi fitur-fitur lokal dari data. Pada setiap lapisan konvolusi terdapat filter-filter kecil yang berperan untuk memindai sinyal dan menghasilkan peta fitur (*feature maps*) yang merepresentasikan pola-pola spesifik dalam sinyal.

Pada penelitian, setiap *input* diproses pada lapisan konvolusi 1D terpisah.

3. Pooling Layer

Pooling layer berfungsi untuk mengurangi dimensi peta fitur dan membuat model lebih *invariant* terhadap pergeseran kecil dalam sinyal sehingga tidak mudah terjadi *overfitting*.

4. Connected Layer

Pada lapisan ini hubungan *non-linear* antara fitur-fitur yang diekstraksi dari lapisan konvolusi akan dipelajari, fitur-fitur tersebut dipetakan ke dalam ruang fitur yang lebih tinggi.. *Output* pada lapisan sebelumnya, diratakan (*flatten*) dan digabungkan (*concatenation*) menjadi satu vektor berisi fitur gabungan di lapisan ini.

5. Output Layer

Pada lapisan akhir ini, prediksi klasifikasi yang dilakukan akan disimpulkan apakah kondisi motor induksi dalam keadaan “sehat” atau “rusak”.

Dalam penelitian ini, dilakukan eksperimen dengan tiga keadaan data: *Loaded*, *Unloaded* dan kombinasi keduanya. Selain eksperimen keadaan data, dilakukan variasi rasio pembagian data *training* dan *testing* yaitu 50:50, 70:30, 80:20 dan 90:10, serta variasi jumlah *epoch* pelatihan, yaitu 50, 100, 500 dan 1000. Variasi-variasi ini dilakukan untuk mengevaluasi kinerja model CNNs 1D dalam berbagai kondisi dan parameter pelatihan.

III. Hasil dan Pembahasan

A. Kondisi Data Input

Tabel 4 menunjukkan hasil evaluasi model CNNs 1D menggunakan metrik akurasi, presisi, *recall* dan *F1-score* untuk berbagai kondisi data yaitu *unloaded* dan *loaded* keduanya pada rasio pembagian data seragam yaitu 80:20 dengan parameter *epoch* sebesar 100.

Tabel 4. Evaluasi model CNNs 1D dengan variasi kondisi data input

No	Kondisi Data	Metrik Evaluasi Model			
		Akurasi (%)	Presisi	<i>Recall</i>	<i>F1-score</i>
1	Tanpa beban (<i>unloaded</i>)	88.28 %	0.60	0.19	0.290
2	Dengan beban (<i>loaded</i>)	84.38%	0.25	0.06	0.09

Berdasarkan Tabel 4, nilai akurasi menunjukkan persentase prediksi yang benar dari total prediksi. Pada kondisi *unloaded* model mencapai akurasi 88.28% yang menunjukkan bahwa kinerja model cukup baik. Namun, pada kondisi *loaded*, akurasi mengalami penurunan menjadi 84.38%. Penurunan nilai akurasi mengindikasikan bahwa model mengalami kesulitan dalam memprediksi kondisi motor induksi dengan beban.

Komponen metrik presisi memberikan ukuran ketepatan model dalam memprediksi kelas positif. Pada kondisi *unloaded* nilai presisi cukup rendah yaitu 0.6 yang berarti 60% dari prediksi positif model benar. Pada kondisi *loaded*, presisi model mengalami penurunan drastic yaitu 0.25 yaitu hanya 25% dari prediksi model benar.

Recall mengukur kemampuan model untuk mendeteksi semua kasus positif yang sebenarnya. Pada kedua kondisi, nilai *recall* sangat rendah. Ini menunjukkan bahwa model memiliki kesulitan dalam mendeteksi kasus “rusak”.

Sama dengan nilai *recall*, nilai *F1-score* cukup rendah yang berarti secara keseluruhan kinerja model buruk, terutama pada keadaan *loaded*.

B. Rasio Data Training dan Testing

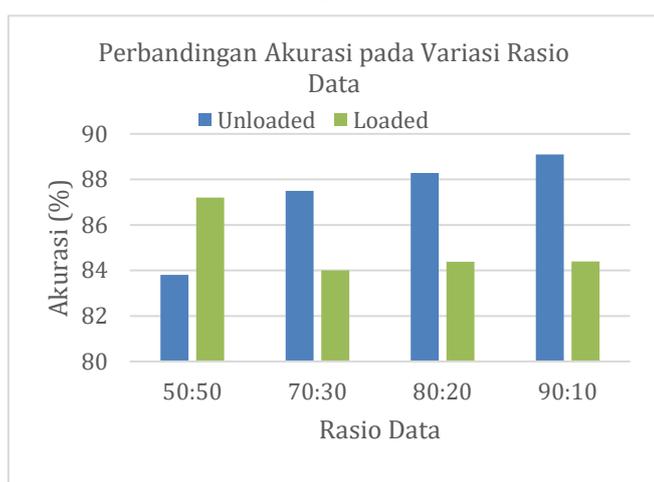
Tabel 5 menyajikan hasil evaluasi model CNNs 1D untuk setiap rasio pembagian data terhadap akurasi prediksi kesehatan pada motor induksi. Hasil ini mampu memberikan Gambaran komprehensi bagaimana kinerja model berubah seiring dengan perubahan proporsi data *training* dan *testing*. Dalam eksperimen ini digunakan parameter *epoch* seragam yaitu 100.

Tabel 5. Evaluasi model CNNs 1D dengan variasi rasio data *training* dan *testing*

No	Kondisi Data	Rasio Data	Akurasi (%)
1	Tanpa beban	50:50	83.80
2	(<i>Unloaded</i>)	70:30	87.50

No	Kondisi Data	Rasio Data	Akurasi (%)
3	Dengan beban (Loaded)	80:20	88.28
4		90:10	89.10
5		50:50	87.20
6		70:30	84.00
7	Tanpa beban (Unloaded)	80:20	84.38
8		90:10	84.40

Secara umum, nilai akurasi model cenderung meningkat sejalan dengan peningkatan proporsi data *training* dan *testing*. Pada rasio 90:10 dengan kondisi data dalam keadaan *Unloaded*, nilai akurasi mencapai 89.10% dan terjadi perbedaan kinerja dengan nilai akurasi tertinggi terdapat pada rasio 50:50 yaitu 87.20%. Hal ini mengindikasikan bahwa karakteristik data pada kedua kondisi memiliki perbedaan. Selain itu, peningkatan proporsi data *training* tidak selalu meningkatkan kinerja model pada kedua kondisi.



Gambar 4. Plot perbandingan akurasi pada 2 kondisi data terhadap variasi rasio data *training* dan *testing*

C. Variasi Parameter Epoch

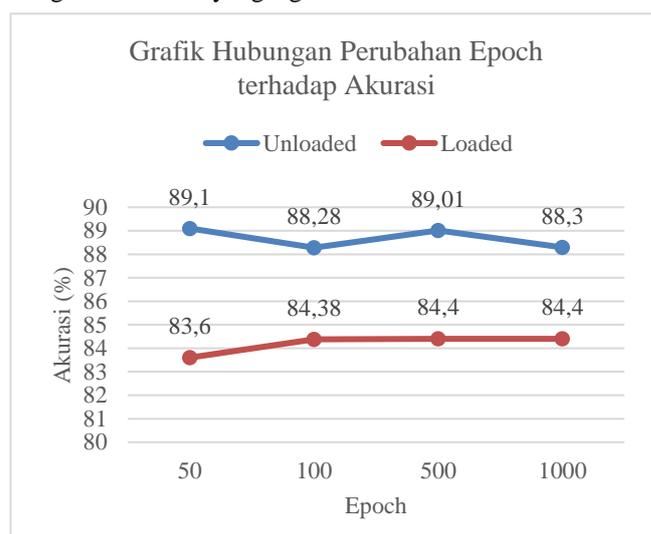
Pada penelitian dilakukan eksperimen terhadap variasi parameter *epoch* yang disajikan pada Tabel 6 di bawah. Pada eksperimen ini, digunakan rasio data *training* dan *testing* seragam yaitu 80 : 20.

Tabel 1. Evaluasi model CNNs 1D dengan penambahan variasi parameter epoch

No	Kondisi Data	Parameter Epoch	Akurasi (%)
1	Tanpa beban (Unloaded)	50	89.10
2		100	88.28
3		500	89.01
4		1000	88.30
5	Dengan beban (Loaded)	50	83.60
6		100	84.38
7		500	84.40
8		1000	84.40

Pada kondisi *unloaded* akurasi tertinggi dicapai pada 50 *epoch* yaitu 89.10%. Peningkatan *epoch* hingga 500 tidak memberikan peningkatan akurasi yang signifikan dan bahkan pada 1000 *epoch* nilai akurasi cenderung turun hingga 88.30%. Hal ini mengindikasikan bahwa model telah mencapai kinerja optimal pada parameter *epoch* yang relative rendah, dan penambahan parameter *epoch* lebih lanjut tidak berkontribusi dalam peningkatan akurasi, bahkan mampu berpotensi menyebabkan *overfitting*.

Sebaliknya pada kondisi *loaded*, akurasi meningkat dari 83.60% pada 50 *epoch* menjadi 84.38% pada 100 *epoch* dan stabil pada 84.40% pada 500 *epoch* dan 1000 *epoch*. Hal ini menunjukkan pada kondisi *loaded* diperlukan lebih banyak *epoch* untuk mencapai kinerja yang stabil. Namun, setelah mencapai stabilitas, penambahan *epoch* tidak memberikan peningkatan akurasi yang signifikan.



Gambar 5. Plot perubahan nilai akurasi model CNNs 1D terhadap variasi parameter *epoch*

Secara keseluruhan, akurasi pada keadaan *unloaded* lebih tinggi daripada keadaan *loaded* dari eksperimen variasi parameter *epoch* yang dilakukan. Ini mengindikasikan bahwa model CNNs 1D relative lebih efektif memprediksi kondisi kesehatan motor induksi *unloaded*. Variasi *epoch* memiliki pengaruh yang berbeda pada kedua kondisi data, menunjukkan bahwa karakteristik data mempengaruhi jumlah *epoch* optimal pada model.

IV. Kesimpulan

Berdasarkan hasil penelitian dapat diambil Kesimpulan :

1. Penelitian telah berhasil mengembangkan model *Convolutional Neural Network (CNNs)* 1D untuk melakukan diagnosa kondisi kesehatan motor induksi memanfaatkan data multimodal.
2. Dilakukan eksperimen diagnosa kondisi kesehatan motor dengan mempertimbangkan

variasi kondisi data (*unloaded* dan *loaded*), rasio pembagian data *training* dan *testing* (50:50, 70:30, 80:20, 90:10), serta jumlah parameter *epoch* (50,100,500,1000).

3. Hasil menunjukkan bahwa model mencapai nilai akurasi yang bervariasi tergantung dari kombinasi parameter-parameter tersebut.
4. Pada kondisi *unloaded*, akurasi tertinggi dicapai pada rasio data 90:10 dengan *epoch* 50 sebesar 89.10% yang mengindikasikan bahwa data yang lebih banyak untuk training dan *epoch* yang sedikit mampu memberikan hasil yang optimal.
5. Sebaliknya, pada kondisi *loaded*, akurasi tertinggi dicapai pada rasio data 50:50 dan *epoch* 100 yaitu 87.20%. Hal ini menunjukkan bahwa data training yang lebih seimbang dan *epoch* yang cukup mampu memberikan hasil terbaik.
6. Secara umum, hasil akurasi pada kondisi *unloaded* menunjukkan nilai yang lebih tinggi daripada *loaded* mengindikasikan bahwa terdapat perbedaan karakteristik data antar kondisi. Sehingga untuk meningkatkan kinerja dan generalisasi model
7. Untuk penelitian lebih lanjut disarankan untuk mengeksplorasi metode ekstraksi fitur yang lebih luas, penggunaan *feature selection*, maupun arsitektur model yang lebih kompleks.

V. Daftar Pustaka

- [1] M.-C. Kim, J.-H. Lee, D.-H. Wang, and I.-S. Lee, "Induction Motor Fault Diagnosis Using Support Vector Machine, Neural Networks, and Boosting Methods," *Sensors*, vol. 23, no. 5, p. 2585, Feb. 2023, doi: 10.3390/s23052585.
- [2] R. R. Kumar, M. Andriollo, G. Cirrincione, M. Cirrincione, and A. Tortella, "A Comprehensive Review of Conventional and Intelligence-Based Approaches for the Fault Diagnosis and Condition Monitoring of Induction Motors," *Energies (Basel)*, vol. 15, no. 23, p. 8938, Nov. 2022, doi: 10.3390/en15238938.
- [3] P. Gangsar and R. Tiwari, "Comparative investigation of vibration and current monitoring for prediction of mechanical and electrical faults in induction motor based on multiclass-support vector machine algorithms," *Mech Syst Signal Process*, vol. 94, pp. 464–481, Sep. 2017, doi: 10.1016/j.ymsp.2017.03.016.
- [4] P. Gandhi, D. N. Turk, and D. R. Dahiya, "Health monitoring of induction motors through embedded systems-simulation of broken rotor bar fault and abnormal gear teeth fault," *Microprocess Microsyst*, vol. 76, p. 103077, Jul. 2020, doi: 10.1016/j.micpro.2020.103077.
- [5] S. K. Gundewar and P. V. Kane, "Condition Monitoring and Fault Diagnosis of Induction Motor," *Journal of Vibration Engineering & Technologies*, vol. 9, no. 4, pp. 643–674, Jun. 2021, doi: 10.1007/s42417-020-00253-y.
- [6] S. Shirdel, M. Teimoortashloo, M. Mohammadiun, and A. A. Gharahbagh, "A hybrid method based on deep learning and ensemble learning for induction motor fault detection using sound signals," *Multimed Tools Appl*, vol. 83, no. 18, pp. 54311–54329, Dec. 2023, doi: 10.1007/s11042-023-15996-5.
- [7] C.-Y. Lee and W.-C. Lin, "Induction Motor Fault Classification Based on ROC Curve and t-SNE," *IEEE Access*, vol. 9, pp. 56330–56343, 2021, doi: 10.1109/ACCESS.2021.3072646.
- [8] A. Saxena *et al.*, "Abnormal Health Monitoring and Assessment of a Three-Phase Induction Motor Using a Supervised CNN-RNN-Based Machine Learning Algorithm," *Math Probl Eng*, vol. 2023, no. 1, Jan. 2023, doi: 10.1155/2023/1264345.
- [9] Y. Liu and A. M. Bazzi, "A review and comparison of fault detection and diagnosis methods for squirrel-cage induction motors: State of the art," *ISA Trans*, vol. 70, pp. 400–409, Sep. 2017, doi: 10.1016/j.isatra.2017.06.001.
- [10] P. Gangsar and R. Tiwari, "Signal based condition monitoring techniques for fault detection and diagnosis of induction motors: A state-of-the-art review," *Mech Syst Signal Process*, vol. 144, p. 106908, Oct. 2020, doi: 10.1016/j.ymsp.2020.106908.
- [11] A. Choudhary, D. Goyal, S. L. Shimi, and A. Akula, "Condition Monitoring and Fault Diagnosis of Induction Motors: A Review," *Archives of Computational Methods in Engineering*, vol. 26, no. 4, pp. 1221–1238, Sep. 2019, doi: 10.1007/s11831-018-9286-z.
- [12] K. Yatsugi, S. E. Pandarakone, Y. Mizuno, and H. Nakamura, "Common Diagnosis Approach to Three-Class Induction Motor Faults Using Stator Current Feature and Support Vector Machine," *IEEE Access*, vol. 11, pp. 24945–24952, 2023, doi: 10.1109/ACCESS.2023.3254914.
- [13] M. Bachir Bechiri *et al.*, "Effective Diagnosis Approach for Broken Rotor Bar Fault Using Bayesian-Based Optimization of Machine Learning Hyperparameters," *IEEE Access*, vol. 12, pp. 139923–139936, 2024, doi: 10.1109/ACCESS.2024.3464108.
- [14] M. Valtierra-Rodriguez, J. R. Rivera-Guillen, J. A. Basurto-Hurtado, J. J. De-Santiago-Perez, D. Granados-Lieberman, and J. P. Amezcua-Sanchez, "Convolutional Neural Network and Motor Current Signature Analysis during the Transient State for Detection of Broken Rotor Bars in Induction Motors," *Sensors*, vol. 20, no. 13, p. 3721, Jul. 2020, doi: 10.3390/s20133721.
- [15] M. Sehri and P. Dumond, "University of Ottawa constant and variable speed electric motor vibration and acoustic fault signature dataset," *Data Brief*, vol. 53, p. 110144, Apr. 2024, doi: 10.1016/j.dib.2024.110144.
- [16] X. Kong *et al.*, "Deep learning for time series forecasting: a survey," *International Journal of Machine Learning and Cybernetics*, Feb. 2025, doi: 10.1007/s13042-025-02560-w.

-
- [17] H. Pan, M. Azimi, G. Gui, F. Yan, and Z. Lin, "Vibration-Based Support Vector Machine for Structural Health Monitoring," 2018, pp. 167–178. doi: 10.1007/978-3-319-67443-8_14.
- [18] K. Ranipa, W.-P. Zhu, and M. N. S. Swamy, "Multimodal CNN Fusion Architecture with Multi-Features for Heart Sound Classification," in *2021 IEEE International Symposium on Circuits and Systems (ISCAS)*, IEEE, May 2021, pp. 1–5. doi: 10.1109/ISCAS51556.2021.9401551.
- [19] S. Hershey *et al.*, "CNN architectures for large-scale audio classification," in *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, Mar. 2017, pp. 131–135. doi: 10.1109/ICASSP.2017.7952132.