



Prototipe Untuk Mengidentifikasi Kerusakan Bantalan Pada Motor Induksi Menggunakan Convolutional Neural Network

Firmansyah Putra Maulana*, Ardik Wijayanto, Hary Oktavianto

Program Studi Teknik Elektronika/Departemen Teknik Elektro – Politeknik Elektronika Negeri Surabaya
Surabaya, Indonesia

*ardik@pens.ac.id

Abstract— Induction motors are widely applied in the industrial world and are the most critical components whose performance must be considered. Damage from an induction motor generally occurs on the inside of the motor. Such as damage to the bearings and damage to the rotor. Detecting damage is one of the methods used to determine the condition of an induction motor; one of which is detection through vibration on the motor. The disadvantage of detecting vibrations is that there is contact with the induction motor and the price is very expensive. This method is considered less practical when applied to machines that operate in narrow areas because it requires the installation of the right sensor on the measuring object which sometimes endangers the operator and measuring instrument. To avoid unwanted things, voice detection is used. The sound produced by the induction motor will be recorded using a microphone, then the sound signal will be processed to produce a spectrogram. This spectrogram data will later be processed using the Convolutional Neural Network (CNN) classification method. 2 data are classified, namely motor in healthy condition and motor in damaged condition. The learning outcomes from the Convolutional Neural Network are then applied to the STM32F746G in the form of a CNN system mode. From the experimental results, in the training phase the system succeeded in differentiating the sound of a healthy motor and a damaged motor with an accuracy rate of 92.4% and in the testing phase the system was able to distinguish the sound of a damaged motor and a healthy motor with an average accuracy rate of 88.325%.

Abstrak— Motor induksi banyak diaplikasikan dalam dunia industri dan merupakan komponen terpenting yang harus diperhatikan kinerjanya. Kerusakan dari motor induksi umumnya terjadi pada bagian dalam motor. Seperti kerusakan pada bearing maupun kerusakan pada rotor. Mendeteksi kerusakan merupakan salah satu metode yang digunakan untuk mengetahui kondisi dari motor induksi, salah satunya adalah pendeteksian melalui getaran pada motor. Kekurangan dari pendeteksian pada getaran adalah adanya kontak terhadap motor induksi dan harganya sangat mahal. Metode ini dirasa kurang praktis bila diterapkan pada mesin yang beroperasi di daerah yang sempit karena menghendaki pemasangan sensor yang tepat pada objek ukur yang terkadang membahayakan operator dan instrument pengukuran. Untuk menghindari hal yang tidak diinginkan, digunakanlah pendeteksian suara. Suara yang dihasilkan motor induksi akan direkam menggunakan mikrophone, kemudian sinyal suara diolah agar menghasilkan spektrogram. Data spektrogram ini nantinya akan diolah menggunakan metode klasifikasi Convolutional Neural Network (CNN). Terdapat 2 data yang diklasifikasi yaitu motor kondisi sehat dan motor kondisi rusak. Hasil pembelajaran dari Convolutional Neural Network kemudian diterapkan pada STM32F746G berupa model sistem CNN. Dari hasil percobaan, pada fase training sistem berhasil membedakan suara antara motor sehat dan motor rusak dengan tingkat akurasi sebesar 92,4% dan pada fase testing sistem dapat membedakan suara motor rusak dan motor sehat dengan tingkat akurasi rata-rata sebesar 88,325%.

Kata Kunci— Motor induksi; kerusakan bearing; Convolutional Neural Network; spektrogram.

I. PENDAHULUAN

MOTOR induksi banyak digunakan dalam aplikasi industri dan rumah tangga karena strukturnya yang sangat sederhana dan handal. Biaya rendah dan implementasi kontrol yang mudah. Tetapi, lingkungan kerja, instalasi dan faktor produksi bisa menyebabkan kerusakan internal seperti kerusakan pada stator dan rotor. Akibatnya pemantauan status dan diagnosis kesalahannya sangat penting untuk pengoperasian sistem

yang stabil dalam jangka panjang. Secara tradisional, pendeteksian rolling element bearing didasarkan pada getaran dan sinyal akustik [1–4].

Bearing merupakan komponen motor induksi yang membantu rotor agar dapat bergerak secara bebas. Kerusakan bearing dapat menyebabkan terjadinya peningkatan getaran, peningkatan kebisingan, peningkatan suhu kerja, kehilangan efisiensi yang dapat menyebabkan kerusakan pada bagian motor induksi [5–8].

Metode pendeteksian berdasarkan pada getaran memerlukan pemasangan alat yang tepat pada motor yang akan dideteksi. Berbeda halnya dengan pendeteksian berdasarkan sinyal suara. Alat yang digunakan tidak perlu dipasangkan secara tepat dengan motor, cu-


Naskah diterima 18 Januari 2023, revisi 4 Maret 2023, terbit online 23 Maret 2023. Emitor merupakan Jurnal Teknik Elektro – Universitas Muhammadiyah Surakarta yang terakreditasi dengan Sinta 3 beralamat di <https://journals2.ums.ac.id/index.php/emitor/index>.

kup mendekatkan alat pendeteksi tersebut ke motor induksi yang akan dideteksi. Pendeteksian kerusakan pada bearing telah dibahas pada beberapa penelitian sebelumnya. Berdasarkan hasil penelitian dengan menggunakan software MATLAB dan metode Fast Fourier Transform (FFT) untuk mengolah sinyal suara, didapatkan letak frekuensi kerusakannya terjadi pada frekuensi 144,5 Hz [9–13]. Nilai ini didapatkan dari hasil perhitungan teori dan hasil pengujian secara langsung. Penelitian selanjutnya [14–18] melakukan pendeteksian kerusakan bearing melalui analisis arus stator dengan menggunakan metode Fast Fourier Transform (FFT). Pengujian dilakukan dengan pemberian beban mekanik berupa generator, dan untuk membuat beban bervariasi maka generator diberi pembebanan listrik berupa lampu. Hasil pengujian terdiri dari 3 macam kerusakan bearing dan 5 macam variasi beban. Pada pengujian kerusakan bearing dengan 1 lubang 2mm didapatkan rata-rata tingkat keberhasilan pendeteksian sebesar 60%. Pada pengujian kerusakan bearing dengan 2 lubang 2mm didapatkan rata-rata tingkat keberhasilan pendeteksian sebesar 48%. Pada pengujian kerusakan bearing dengan 3 lubang 2mm didapatkan rata-rata tingkat keberhasilan pendeteksian sebesar 41%. Dari pengujian ini didapatkan kesimpulan bahwa efek pembebanan yang diberikan pada motor induksi mempermudah untuk proses pendeteksian.

Merujuk pada penelitian-penelitian sebelumnya, penulis akan melakukan perbandingan dengan sistem yang langsung diterapkan pada hardware berupa microcontroller jenis STM32F746G-Discovery. Dengan cara mengolah sinyal suara yang sudah didapatkan menggunakan Python untuk mendapatkan data spektrogram. Spektrogram adalah tampilan detail audio yang dapat mewakili waktu, frekuensi, dan amplitudo dari suatu sinyal dalam satu grafik. Kemudian data spektrogram yang sudah didapatkan akan diklasifikasi dengan Convolutional Neural Network untuk mendapatkan hasil berupa informasi kondisi motor induksi dalam keadaan sehat ataupun motor induksi dalam keadaan rusak. Sistem ini diharapkan mampu membantu pekerja di dunia industri yang berhubungan dengan motor induksi ketika melakukan pengecekan kondisi motor tanpa menggunakan metode getaran, untuk mengantisipasi keadaan yang tidak diinginkan.

II. METODE PENELITIAN

Diagram alur untuk sistem yang akan dibuat dapat dilihat pada Gambar 1. Penelitian dimulai dari pengumpulan data set suara dengan menggunakan microphone MEMS yang terdapat pada STM32F746G-Discovery. Selanjutnya sinyal suara diubah dari model PDM ke model PCM agar bisa disimpan ke microSD. Proses me-



Gambar 1: Diagram alur sistem

rekan suara dilakukan selama 15 detik setelah itu diolah menggunakan metode Fast Fourier Transform (FFT) untuk mendapatkan spektrogram. Grafik spektrogram antara kondisi motor sehat dan kondisi motor rusak kemudian diklasifikasi menggunakan Convolutional Neural Network (CNN). Hasil pembelajaran/learning dari CNN nantinya akan diterapkan ke microcontroller sehingga dapat mendeteksi kerusakan.

i. Fast Fourier Transform (FFT)

Fast Fourier Transform (FFT) merupakan pengembangan suatu metode perhitungan cepat dari Discrete Fourier Transform (DFT). DFT merupakan suatu metode perhitungan yang mengubah sinyal dari domain waktu ke domain frekuensi. Biasanya FFT digunakan untuk keperluan analisis spektrum dalam domain frekuensi [14]. Rumus untuk FFT dapat dilihat pada Persamaan (1).

$$X_n = \sum_{k=0}^{N-1} X_0(k)W_n^{kn} \quad (1)$$


dengan $n = 0, 1, 2, \dots, N - 1$. Untuk W_n merupakan notasi dalam Persamaan (2) berikut.

$$W_n = e^{-j\frac{2\pi}{n}} \quad (2)$$

ii. Spektrogram

Spektrogram adalah tampilan detail audio, yang dapat mewakili waktu, frekuensi, dan amplitudo semuanya dalam satu grafik. Spektrogram didapatkan dengan cara melakukan perhitungan Short Time Fourier Transform (STFT) pada sinyal yang akan dikonversi [19]. Short Time Fourier Transform (STFT), yaitu suatu modifikasi dari transformasi Fourier yang menganalisis sinyal secara lokal dengan membatasi sinyal tersebut dengan

suatu fungsi window $W(t)$ yang memiliki durasi tertentu. Setelah itu dilakukan perhitungan FFT pada tiap frame. kemudian hasil dari perhitungan tersebut disusun vertikal sesuai waktu. Kemudian nilai-nilai nya diwakilkan oleh warna-warna, sehingga hasil akhirnya adalah berupa gambar grafik 2 dimensi.



Gambar 2: Hasil spektrogram untuk motor kondisi (a) sehat (b) rusak

iii. Convolutional Neural Network


Convolutional Neural Network (CNN) merupakan pengembangan dari multilayer perceptron (MLP) yang didesain untuk mengolah data dua dimensi dalam bentuk citra. CNN ini termasuk kedalam jenis Deep Neural Network karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra. Pada dasarnya klasifikasi citra dapat digunakan dengan MLP, akan tetapi dengan metode MLP kurang sesuai untuk digunakan karena tidak menyimpan informasi spasial dari data citra dan menganggap setiap piksel adalah fitur yang independen sehingga menghasilkan hasil yang kurang baik. Penelitian awal yang mendasari penemuan CNN ini pertama kali dilakukan oleh Hubel dan Wiesel [20] mengenai visual cortex pada indera penglihatan kucing.

iv. TensorFlow

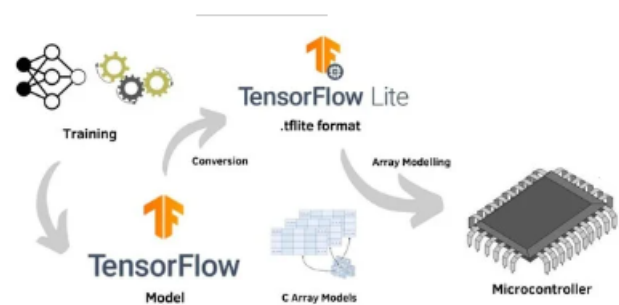
TensorFlow adalah library yang bersifat open source untuk membangun, melatih, mengevaluasi, dan menerapkan model pembelajaran mesin. Sebagian pengembangan menggunakan library Python untuk membangun sebuah sistem. KERAS merupakan salah satu library TensorFlow API tingkat tinggi yang memudahkan untuk membangun dan melatih jaringan pembelajaran yang mendalam. Dengan menggunakan TensorFlow Lite dapat menjalankan model hasil pembelajaran pada sebuah microcontroller [21].

III. HASIL PENELITIAN DAN DISKUSI

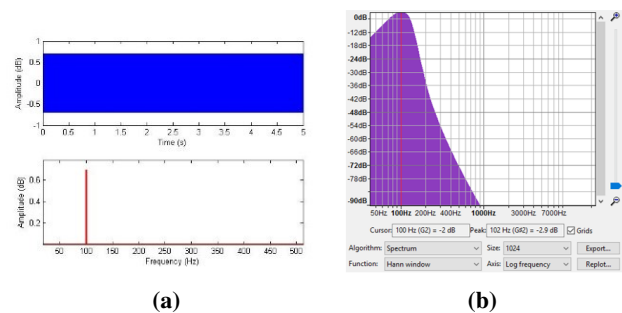
Pada bagian ini akan dibahas hasil dari pengujian sistem yang telah dibuat. Hasil Pengujian terdiri dari sub hasil pengujian:



Gambar 3: Arsitektur CNN yang digunakan oleh sistem



Gambar 4: Alur kerja TensorFlow Lite



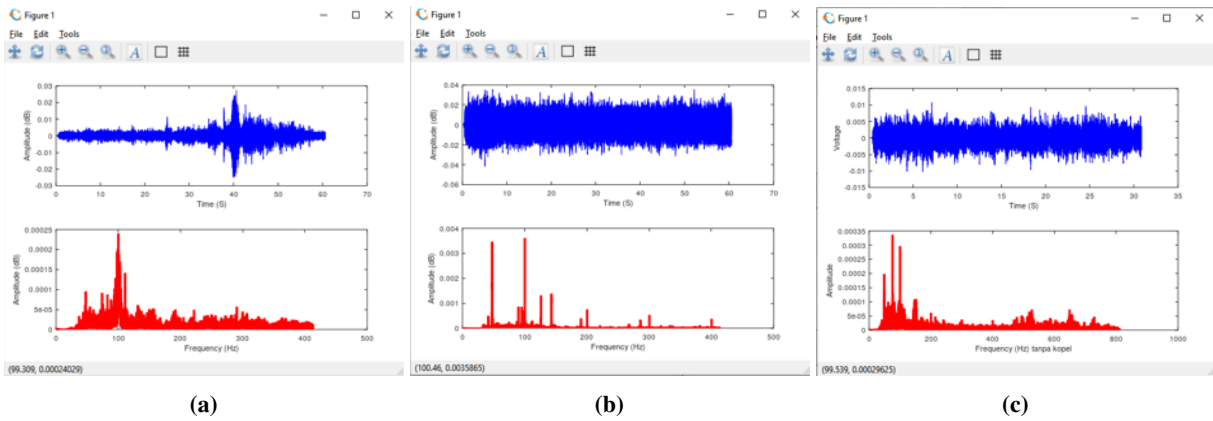
Gambar 5: Hasil FFT sinyal dengan frekuensi 100Hz pada (a) Octave (b) Audacity

i. Pre-processing

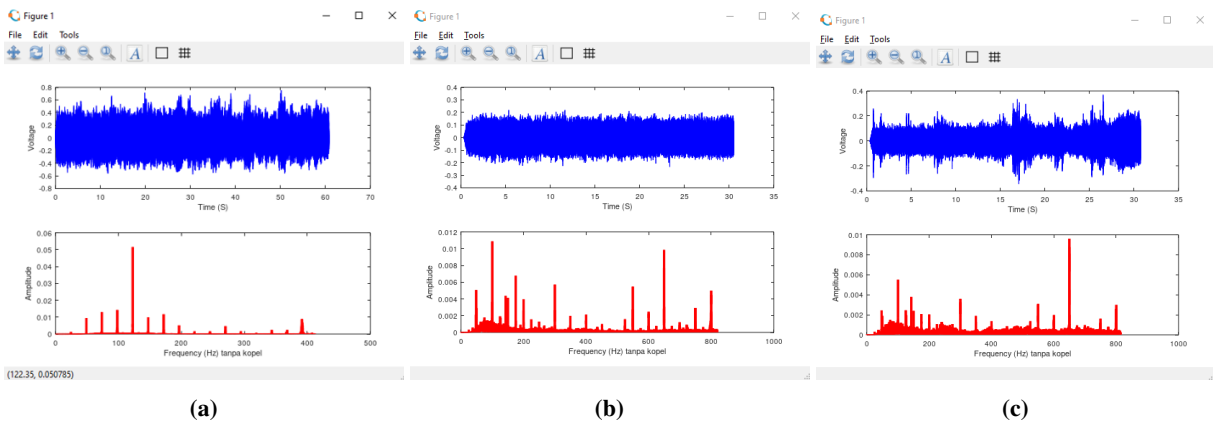
Untuk melakukan validasi terhadap algoritma FFT yang akan digunakan dalam pengolahan sinyal suara maka dilakukan pre-processing. Seperti yang diperlihatkan pada Gambar 5, sinyal yang akan diolah menggunakan FFT adalah sinyal dengan frekuensi 100Hz dengan waktu selama 5 detik.

Dari hasil pengujian algoritma FFT pada 2 software yang berbeda, menunjukkan hasil pembacaan audio frekuensi 100Hz selama 5 detik dengan akurat. Hal ini membuktikan bahwa algoritma yang telah disusun bisa dikatakan benar sehingga dapat digunakan pengolahan sinyal dalam penelitian ini.


Selanjutnya dilakukan pre-processing terhadap



Gambar 6: Kondisi ruangan tanpa suara motor (a) sepi (b) normal (c) ramai



Gambar 7: Kondisi ruangan dengan suara motor (a) sepi (b) normal (c) ramai



Gambar 8: Tampilan microcontroller saat (a) proses merekam (b) selesai merekam

kondisi ruangan. Terdapat 2 kategori yaitu kondisi ruangan tanpa suara motor seperti pada Gambar 6 dan kondisi ruangan dengan suara motor seperti pada Gambar 7.

Dapat ditarik sebuah informasi bahwasanya noise pada kondisi ruangan sepi tidak akan mempengaruhi suara motor seperti pada Gambar 7 (a). Hal itu dikarenakan karakteristik lingkungan sepi memiliki frekuensi tersendiri dengan amplitude yang relatif kecil, dan juga suara motor memiliki karakter frekuensi dengan amplitude yang lebih besar dari pada amplitude yang dihasilkan oleh frekuensi lingkungan/ruangan. Untuk kondisi ruangan normal seperti pada Gambar 7 (b) memiliki frekuensi baru yang muncul, diprediksi frekuensi-frekuensi tersebut muncul karena adanya

komponen kelistrikan yang menyala seperti: AC, kul-kas, dan lampu. Karena pada dasarnya seluruh komponen kelistrikan memiliki frekuensi tersendiri. Untuk kondisi ruangan ramai seperti pada Gambar 7 (c) hal ini sama persis dengan apa yang ada pada kondisi normal hanya saja kondisi ramai ini memiliki banyak sekali frekuensi baru dibandingkan dengan kondisi normal. Berdasarkan dari pengujian pre-processing kondisi ruangan diatas, maka untuk pengujian sistem pada motor dilakukan pada kondisi ruangan sepi.

ii. Pengujian microphone

Pengujian ini dilakukan untuk memastikan microphone yang terdapat pada STM32F746G-Discovery berfungsi dengan baik. Proses merekam dilakukan selama 15 detik, setelah itu rekaman akan secara otomatis tersimpan kedalam microSD.

iii. Learning


Proses learning bertujuan untuk mendapatkan model yang dapat diterapkan pada mikrokontroller.

Jika data validasi dan juga testing diplot maka akan muncul grafik accuracy dan juga grafik

Tabel 1: Dataset yang akan digunakan untuk proses learning

Kondisi motor	Jumlah data	Training (%)	Validasi (%)	Testing (%)
Sehat	480			
Rusak	480	80%	10%	10%
Jumlah	960			

loss/cross_entropy seperti Gambar 9. Untuk grafik berwarna biru menunjukkan hasil trainig sedangkan grafik berwarna merah menunjukkan hasil evaluasi.


**Gambar 9:** Data validasi dan juga testing diplot maka akan muncul grafik (a) Grafik akurasi (b) Grafik loss/cross_entropy**Tabel 2:** Hasil pengujian pada motor sehat tanpa pengereman

Pengujian ke-	Keterangan
1	Sehat
2	Sehat
3	Rusak
4	Sehat
5	Sehat
6	Sehat
7	Sehat
8	Sehat
9	Sehat
10	Sehat
11	Sehat
12	Sehat
13	Sehat
14	Sehat
15	Sehat

iv. Pengujian Motor Sehat Tanpa Pengereman

Pengujian dilakukan untuk membuktikan bahwa sistem yang sudah dibuat dapat mendeteksi bahwa motor dalam kondisi sehat tidak mengalami kerusakan.

Pada pengujian ini, dari 15 kali dilakukan pengujian terdapat 1 data menunjukkan output yang tidak sesuai dengan kondisi asli motor yaitu kondisi motor sehat. Data output yang keluar adalah motor broken. Hal ini dikarenakan rekaman pengujian yang digunakan adalah kondisi ruangan yang ramai, sehingga suara dari motor tercampur dengan suara lain. Berdasarkan data pada Tabel 2 diatas tingkat akurasi untuk pengujian pada kondisi motor rusak yaitu sebesar 93,33%.

**Gambar 10:** Hasil pengujian yang memperlihatkan (a) berhasil mendeteksi sehat pada pengujian pertama (b) gagal mendeteksi sehat pada pengujian ke 3

v. Pengujian Motor Rusak Tanpa Pengereman

Pengujian dilakukan untuk membuktikan bahwa sistem yang sudah dibuat dapat mendeteksi bahwa motor dalam kondisi mengalami kerusakan.

**Gambar 11:** Hasil pengujian menunjukkan (a) berhasil mendeteksi rusak pada pengujian pertama (b) gagal mendeteksi rusak pada pengujian ke 6, 8 dan 12**Tabel 3:** Hasil Pengujian Motor Rusak Tanpa Pengereman

Pengujian ke-	Keterangan
1	Rusak
2	Rusak
3	Rusak
4	Rusak
5	Rusak
6	Sehat
7	Rusak
8	Sehat
9	Rusak
10	Rusak
11	Rusak
12	Sehat
13	Rusak
14	Rusak
15	Rusak

Pada pengujian ini, dari 15 kali dilakukan pengujian terdapat 3 data menunjukkan output yang tidak sesuai dengan kondisi asli motor yaitu kondisi motor rusak. Data output yang keluar adalah motor safe. Hal ini dikarenakan rekaman pengujian yang digunakan adalah kondisi ruangan yang ramai, sehingga suara dari motor tercampur dengan suara lain. Berdasarkan data pada Tabel 3 diatas tingkat akurasi untuk pengujian pada kondisi motor rusak yaitu sebesar 80%.

Tabel 4: Hasil pengujian pada motor sehat dengan pengereman

Pengereman (Beban)	Pengujian ke-	Keterangan
3 kg	1	Sehat
	2	Sehat
	3	Sehat
	4	Sehat
	5	Sehat
4 kg	1	Sehat
	2	Sehat
	3	Sehat
	4	Sehat
	5	Sehat
5 kg	1	Sehat
	2	Sehat
	3	Sehat
	4	Sehat
	5	Sehat

Tabel 5: Hasil pengujian pada motor sehat dengan pengereman

Pengereman (Beban)	Pengujian ke-	Keterangan
3 kg	1	Rusak
	2	Rusak
	3	Sehat
	4	Rusak
	5	Rusak
4 kg	1	Sehat
	2	Rusak
	3	Rusak
	4	Rusak
	5	Sehat
5 kg	1	Rusak
	2	Rusak
	3	Rusak
	4	Rusak
	5	Rusak

vi. Pengujian Motor Sehat Dengan Pengereman

Pengujian kali ini dilakukan dengan variasi pengereman. Tipe pengereman yang digunakan adalah mekanik menggunakan timbal dengan berat 3 kg, 4 kg dan 5 kg. Motor di couple dengan sisi pengereman seperti ditunjukkan pada Gambar 12.

**Gambar 12:** Rangkaian pengujian dengan pengereman

Pada pengujian ini, motor diberikan pengereman dengan menggunakan beban seberat 3 kg, 4 kg dan 5 kg. Berdasarkan data pada Tabel 4 hasil output sesuai dengan kondisi asli motor, yaitu motor dalam kondisi sehat tanpa mengalami kerusakan dengan tingkat akurasi 100%.

vii. Pengujian Motor Rusak Dengan Pengereman

Cara pengujian sama halnya dengan pengujian pada motor sehat.

Pada pengujian ini, dari 15 kali dilakukan pengujian terdapat 3 data menunjukkan output yang tidak sesuai dengan kondisi asli motor yaitu kondisi motor

rusak. Data output yang keluar adalah motor safe. Hal ini dikarenakan rekaman suara pada Tabel 5 beban 3 kg pengujian ketiga dan Tabel 5 beban 4 kg pengujian pertama dan pengujian kelima memiliki karakteristik suara kerusakana yang cenderung lebih pelan. Berdasarkan data pada Tabel 5 diatas tingkat akurasi untuk pengujian pada kondisi motor rusak dengan beban yaitu sebesar 80%.

Berdasarkan hasil pengujian sebelumnya maka dapat ditulis ulang pada tabel berikut ini:

Tabel 6: Rata-rata akurasi sistem

Jenis pengujian	Akurasi
Motor sehat tanpa pengereman	93,3%
Motor rusak tanpa pengereman	80%
Motor sehat dengan pengereman	100%
Motor rusak dengan pengereman	80%
Rata-rata akurasi	88,325%

IV. KESIMPULAN

Kesimpulan dari makalah penelitian adalah spektrogram berhasil didapatkan dengan mengolah sinyal frekuensi menggunakan metode Fast Fourier Transform (FFT). Pengenalan pola spektrogram menggunakan Convolutional Neural Network (CNN) sudah dapat membedakan suara motor induksi yang sehat maupun suara motor induksi yang rusak. Penerapan sistem yang sudah didesain berhasil diterapkan pada microcontroller STM32F746G-Discovery dengan tingkat akurasi rata-rata sebesar 88,325%.

DAFTAR PUSTAKA

- [1] M. Yang, N. Chai, Z. Liu, B. Ren, dan D. Xu, "Motor speed signature analysis for local bearing fault detection with noise cancellation based on improved drive algorithm," *IEEE Transactions on Industrial Electronics*, vol. 67, no. 5, pp. 4172–4182, 2019.
- [2] J. Sufrianti dan A. Hamzah, "Simulasi dan deteksi gangguan belitan stator motor induksi tiga fasa menggunakan arus starting dengan matlab/simulink," *Jurnal Online Mahasiswa (JOM) Bidang Teknik dan Sains*, vol. 4, no. 1, pp. 1–11, 2017.
- [3] R. Z. Haddad, C. A. Lopez, J. Pons-Llinares, J. Antonino-Daviu, dan E. G. Strangas, "Outer race bearing fault detection in induction machines using stator current signals," in *2015 IEEE 13th International Conference on Industrial Informatics (INDIN)*. IEEE, 2015, pp. 801–808.
- [4] I. D. P. Karyatanti, R. S. Zulkifli, A. Noersena, F. R. Purnomo, B. Y. Dewantara, dan A. Wijayanto, "Identification of ball bearing damage on induction motors through sound signal analysis," *Journal of Electrical and Electronics Engineering*, vol. 15, no. 1, pp. 33–38, 2022.
- [5] T. Ciszewski, "Induction motor bearings diagnostic indicators based on mcsa and normalized triple covariance," in *2017 IEEE 11th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)*. IEEE, 2017, pp. 498–502.
- [6] V. K. A. Shankar, S. Umashankar, S. Paramasivam, dan N. Hanigovszki, "A comprehensive review on energy efficiency enhancement initiatives in centrifugal pumping system," *Applied Energy*, vol. 181, pp. 495–513, 2016.
- [7] E. Skjong, R. Volden, E. Rødskar, M. Molinas, T. A. Johansen, dan J. Cunningham, "Past, present, and future challenges of the marine vessel's electrical power system," *IEEE Transactions on Transportation Electrification*, vol. 2, no. 4, pp. 522–537, 2016.
- [8] H. Liu, J. Zhou, Y. Zheng, W. Jiang, dan Y. Zhang, "Fault diagnosis of rolling bearings with recurrent neural network-based autoencoders," *ISA transactions*, vol. 77, pp. 167–178, 2018.
- [9] A. Anggriawan dan F. Huda, "Deteksi kerusakan motor induksi dengan menggunakan sinyal suara," *Jurnal Online Mahasiswa (JOM) Bidang Teknik dan Sains*, vol. 5, no. 1, pp. 1–7, 2018.
- [10] F. Huda, A. Anggriawan, dan M. Rusli, "The using of sound signal and simple microphone to detect damages in induction motor," in *IOP Conference Series: Materials Science and Engineering*, vol. 539, no. 1. IOP Publishing, 2019, p. 012034.
- [11] M. S. Raghav dan R. B. Sharma, "A review on fault diagnosis and condition monitoring of gearboxes by using ae technique," *Archives of Computational Methods in Engineering*, vol. 28, no. 4, pp. 2845–2859, 2021.
- [12] P. K. Selvam, R. Kulenovic, E. Laurien, J. Kickhofel, dan H.-M. Prasser, "Thermal mixing of flows in horizontal t-junctions with low branch velocities," *Nuclear Engineering and Design*, vol. 322, pp. 32–54, 2017.
- [13] K. Miyoshi, M. Kamaya, Y. Utanohara, dan A. Nakamura, "An investigation of thermal stress characteristics by wall temperature measurements at a mixing tee," *Nuclear Engineering and Design*, vol. 298, pp. 109–120, 2016.
- [14] M. Abduh, D. Iradiratu, dan B. Y. Dewantara, "Deteksi kerusakan outer race bearing pada motor induksi melalui analisa arus stator menggunakan metode fast fourier transform (fft)," *Prosiding SENIATI*, vol. 5, no. 3, pp. 175–181, 2019.
- [15] I. D. PK, B. Y. Dewantara, dan W. M. Utomo, "Healthy monitoring and fault detection outer race bearing in induction motor using stator current," *International Journal of Integrated Engineering*, vol. 11, no. 3, 2019.
- [16] S. Isfar, I. D. P. Karyatanti, dan B. Y. Dewantara, "The effects of damage to the outer race bearing on the efficiency of the induction motor using fast fourier transform (fft) method," *JEEE-U (Journal of Electrical and Electronic Engineering-UMSIDA)*, vol. 5, no. 1, pp. 103–115, 2021.
- [17] D. P. Iradiratu, B. Y. Dewantara, D. Rahmatullah, I. Winarno, dan C. Hidayanto, "Decomposition wavelet transform as identification of outer race bearing damage through stator flow analysis in induction motor," in *2019 International Conference on Information and Communications Technology (ICOIACT)*. IEEE, 2019, pp. 733–737.
- [18] S. E. Pandarakone, M. Masuko, Y. Mizuno, dan H. Nakamura, "Fault classification of outer-race bearing damage in low-voltage induction motor with aid of fourier analysis and svm," in *2018 IEEE International Conference on Industrial Technology (ICIT)*. IEEE, 2018, pp. 407–412.
- [19] A. S. Khan, Z. Ahmad, J. Abdullah, dan F. Ahmad, "A spectrogram image-based network anomaly detection system using deep convolutional neural network," *IEEE Access*, vol. 9, pp. 87 079–87 093, 2021.
- [20] T. R. Vidyasagar dan U. T. Eysel, "Origins of feature selectivities and maps in the mammalian primary visual cortex," *Trends in neurosciences*, vol. 38, no. 8, pp. 475–485, 2015.
- [21] N. Schizas, A. Karras, C. Karras, dan S. Sioutas, "Tinyml for ultra-low power ai and large scale iot deployments: A systematic review," *Future Internet*, vol. 14, no. 12, p. 363, 2022.