Penilaian Kebisingan Rumah Sakit Berbasis IoT dengan Pelabelan *Self-Supervised* Menggunakan Klasterisasi PSO-K-Means dan *Spectral Flatness*

Nadya Widdy Astuti
Fakultas Informatik
Universitas Telkom
Bandung
ndyawidd@students.telkomuniversity.ac.id

Aji Gautama Putrad
Fakultas Informatik
Universitas Telkom
Bandung
ajigps@telkomuniversity.ac.id

Ryan Lingga Wicaksono
Fakultas Informatik
Universitas Telkom
Bandung
wicaksonoryan@telkomuniversity.ac.id

Kebisingan kebisingan di lingkungan rumah sakit dapat mengganggu kenyamanan pasien dan kinerja tenaga medis. Pemantauan kebisingan masih banyak dilakukan secara manual sehingga tidak mampu memberikan informasi yang akurat dan terus menerus. Penelitian ini menggunakan data audio untuk mengelompokkan tingkat kebisingan secara otomatis.

Penelitian ini semakin penting karena rumah sakit memiliki banyak sumber suara, seperti alarm alat medis, aktivitas staf, dan aktivitas operasional. Jika pola kebisingan tidak dikenali dengan baik, komunikasi bisa terganggu dan kualitas layanan kesehatan turut menurun. Oleh karena itu, dibutuhkan metode yang dapat membaca karakteristik suara secara objektif.

Penelitian ini mengusulkan model pengelompokan tingkat kebisingan menggunakan fitur *spectral flatness*, RMS, RMSE, SNR, dan dB sebagai fitur akustik. Proses optimasi dilakukan untuk menentukan konfigurasi klaster terbaik, diikuti dengan pengelompokan K-Means untuk menghasilkan kelompok akhir. Kontribusi penelitian ini berupa pemilihan fitur akustik, serta rancangan model yang dapat diintegrasikan sistem IoT untuk pemantauan kebisingan.

Hasil Menunjukkan bahwa konfigurasi tiga klaster merupakan pilihan paling optimal dengan nilai *silhouette score* sebesar 0.54. Visualisasi hasil klaster menunjukkan perbedaan masing-masing kelompok, dengan nilai SNR menjadi penanda utama tingginya tingkat kebisingan. Secara keseluruhan, model yang dibangun bekerja secara efektif dan dapat diadaptasikan dalam sistem pemantauan kebisingan rumah sakit.

Kata kunci: *spectral flatness, internet of things, particle swarm optimization, K-Means clustering, self-supervised learning,* kebisingan di rumah sakit

Abstract

Noise in hospital environments can disrupt patient comfort and reduce the effectiveness of medical personnel. Manual noise monitoring is still widely used, making it difficult to obtain accurate and continuous information. This research utilizes audio data to automatically categorize noise levels.

The urgency of automated noise monitoring is driven by diverse sound sources in hospitals, such as medical device alarms, staff activities, and operational routines. When noise patterns are not properly identified, communication may be hindered and healthcare service quality may decline. Therefore, a method capable of objectively capturing sound characteristics is needed.

This study proposes a noise-level clustering model using spectral flatness, RMS, RMSE, SNR, and dB as acoustic features. An optimization process determines the best cluster configuration, followed by K-Means clustering to generate the final groups. The contribution of this research lies in identifying representative acoustic features and designing a model with potential integration into IoT-based noise monitoring systems.

Results indicate that a three-cluster configuration is most optimal, achieving a silhouette score of 0.54. Visualization clearly differentiates the clusters, with SNR emerging as the primary indicator of high noise intensity. Overall, the model performs effectively and is suitable for hospital noise monitoring applications.

Keywords: spectral flatness, Internet of Things, Particle Swarm Optimization, K-Means clustering, self-supervised learning, hospital noise.

1. Pendahuluan

Latar Belakang

Kebisingan di lingkungan rumah sakit masih menjadi persoalan yang kerap luput dari perhatian, padahal kondisi lingkungan yang tenang memiliki peran penting dalam menunjang proses pemulihan pasien. Chatzilampri dan Stevens [1] menekankan perlunya lingkungan yang kondusif, sementara Andrade *et al*. [2] melaporkan bahwa tingkat kebisingan rumah sakit dapat mencapai 88,6 dB(A), jauh melampaui batas aman *World Health Organization* (WHO) yaitu 35 dB(A). Kondisi ini tidak hanya mengganggu kenyamanan, tetapi juga berpotensi menurunkan kualitas layanan kesehatan.

Paparan kebisingan dapat menyebabkan gangguan tidur, stres, peningkatan tekanan darah, hingga *burnout* pada pasien maupun tenaga medis [3]. Selain memengaruhi kondisi pasien, lingkungan yang bising juga dapat mengganggu komunikasi tenaga medis, khususnya pada situasi yang membutuhkan respons cepat. Kondisi ini menunjukkan bahwa pemantauan kebisingan secara *real-time* menjadi komponen penting dalam menjaga kualitas lingkungan perawatan.

Dalam beberapa penelitian sebelumnya, sistem pemantauan kebisingan berbasis *Internet of Things* (IoT) telah diusulkan, di antaranya klasifikasi suara menggunakan MFCC dan *Artificial Neural Network* (ANN) oleh Nair et al. [4], dan sistem monitoring kebisingan secara *real-time* oleh Wan Ismail et al. [5]. Namun, sebagian besar metode saat ini bergantung pada pengukuran *Sound Pressure Level* (SPL) dan metode *supervised*, yang dinilai kurang adaptif dalam mengenali keragaman karakteristik suara di lingkungan rumah sakit. Fitur *spectral flatness* telah terbukti mampu membedakan suara bersifat tonal dan *noise* acak [6]. Di sisi lain, metode klasterisasi K-Means masih memiliki keterbatasan yang dapat ditingkatkan menggunakan optimasi menggunakan *Particle Swarm Optimization* (PSO). Beberapa studi menunjukkan bahwa kombinasi PSO–K-Means dapat meningkatkan stabilitas dan akurasi hasil klasterisasi [7] [8], serta menunjukkan kinerja yang baik dalam pemrosesan sinyal pada lingkungan yang dinamis [9].

Hingga saat ini, belum ditemukan penelitian yang mengintegrasikan fitur *spectral flatness*, sistem IoT, dan metode PSO–K-Means dalam satu sistem yang mampu bekerja secara otomatis dan *real-time*. Oleh karena itu, penelitian ini mengusulkan pendekatan yang lebih adaptif dan efisien untuk mengelompokkan tingkat kebisingan di lingkungan rumah sakit secara otomatis. Pendekatan yang diusulkan diharapkan dapat

mendukung upaya pengendalian kebisingan secara berkelanjutan sekaligus menjadi landasan dalam perumusan masalah penelitian ini.

Topik dan Batasannya

Penelitian ini membahas permasalahan tingginya tingkat kebisingan di lingkungan rumah sakit serta kebutuhan akan sistem pemantauan yang dapat bekerja secara otomatis tanpa harus diawasi terus-menerus. Proses pengelompokkan dilakukan secara otomatis menggunakan klasterisasi *unsupervised*, dengan memanfaatkan fitur akustik utama seperti *spectral flatness,* RMS, RMSE, SNR, dB untuk merepresentasikan karakteristik suara. Hasil pengolompokan ini diharapkan dapat digunakan sebagai dasar pengembangan sistem pemantauan kebisingan berbasis IoT di lingkungan rumah sakit.

Untuk menjaga agar ruang lingkup penelitian tetap terarah, beberapa batasan ditetapkan. Data yang digunakan berasal dari dataset audio yang diperoleh melalui *platform* Kaggle. Fitur akustik yang dianalisis dibatasi pada *spectral flatness,* RMS, RMSE, SNR, dan dB. Proses optimasi menggunakan PSO digunakan untuk mennetukan jumlah klaster dan titik awal *centroid*. Penilaian kualitas hasil klasterisasi dilakukan menggunakan *silhouette score.*

Tujuan

Tujuan penelitian ini adalah membangun model klasterisasi kebisingan yang mampu mengelompokkan tingkat kebisingan di rumah sakit secara otomatis berdasarkan karakteristik suara. Penelitian ini mengevaluasi sejauh mana fitur *spectral flatness,* RMS, RMSE, SNR, dan dB mampu menggambarkan kondisi kebisingan, serta menentukan jumlah klaster terbaik dengan PSO. Evaluasi menggunakan *silhouette score* memastikan hasil pengelompokkan dapat dinilai secara objektif.

TABEL
Tabel keterkaitan antara tujuan, pengujian dan kesimpulan.

No	Tujuan	Pengujian	Kesimpulan
1	Mengetahui fitur suara yang paling menggambarkan tingkat kebisingan	Mengukur *spectral flatness* dan metrik akustik lainnya	Fitur suara dapat membedakan area yang bising dan tenang
2	Membuat sistem yang bisa membagi tingkat kebisingan secara otomatis	Mencari jumlah klaster terbaik dengan PSO lalu menjalankan K-Means	Sistem bisa menentukan kelompok kebisingan otomatis tanpa setting manual
3	Memastikan hasil pembagian klaster sudah tepat	*Silhouette score* dan visualisasi hasil klaster	Hasil pembagian klaster sesuai dengan kondisi nyata di lapangan

Organisasi Tulisan

Jurnal ini disusun dalam lima bagian utama. Pertama, Pendahuluan menjelaskan alasan penelitian dilakukan dan apa yang ingin dicapai. Kedua. Studi Terkait berisi teori dan referensi penelitian sebelumnya. Ketiga, Sistem yang Dibangun menerangkan bagaimana model dirancang dan data diproses. Keempat, Evaluasi menampilkan hasil uji coba sistem. Kelima, Kesimpulan merangkum hasil dan memberikan saran untuk penelitian berikutnya.

2. Studi Terkait

Penelitian tentang pemantauan kebisingan berbasis IoT dan pemrosesan sinyal audio telah banyak dilakukan, terutama di bidang analisis lingkungan dan sistem monitoring berbasis sensor. Perangkat IoT dapat mengukur tingkat kebisingan secara *real-time* menggunakan sensor suara, mikrokontroler, dan platform komputasi awan [10] [11]. Metode pengukuran otomatis ini dapat diterapkan pada lingkungan rumah sakit.

Dalam pemrosesan audio, *spectral flatness* banyak dimanfaatkan untuk membedakan apakah suatu suara bersifta tonal atau menyerupai noise, karena fitur ini mengukur tingkat pemerataan distribusi energi frekuensi [6] [12]. Berbagai penelitian menunjukkan bahwa *spectral flatness* dapat menggambarkan kondisi suara lingkungan dengan baik. Selain itu, sejumlah studi juga menggunakan metrik akustik lain seperti RMS, RMSE, dan SNR sebagai parameter kuantitatif untuk mengevaluasi intensitas serta kualitas sinyal audio.

Pada proses klasterisasi, K-Means merupakan algoritma yang paling sering digunakan dalam proses klasterisasi. Namun, performa K-Means sangat dipengaruhi oleh inisialisasi *centroid*, sehingga kadang berhenti di solusi yang kurang optimal [13]. Untuk mengatasi hal ini, beberapa penelitian menggabungakannya dengan algoritma PSO, yang mampu menemukan posisi *centroid* terbaik melalui eksplorasi global. Pendekatan PSO–K-Means terbukti mampu memberikan hasil pengelompokan yang lebih stabil dan lebih akurat, terutama untuk mengelompokkan jenis suara yang muncul pada lingkungan nyata.

Penelitian terdahulu juga menjelaskan bahwa teknologi IoT dan analisis audio sudah banyak digunakan untuk memonitor kebisingan di berbagai bidang, termasuk rumah sakit, industri, dan area perkotaan. Perbandingan penelitian sebelumnya disajikan pada Tabel 2, yang merangkum fitur, metode, serta kontribusi masing-masing penelitian. Dari tabel tersebut dapat dilihat bahwa meskipun penelitian mengenai IoT dan klasifikasi suara telah banyak dikaji, belum ada penelitian yang secara khusus menggabungkan *spectral flatness* dan metode PSO–K-Means untuk pelabelan otomatis tingkat kebisingan di rumah sakit.

TABEL 2
Perbandingan Studi Terkait dengan Metode yang Diusulkan.

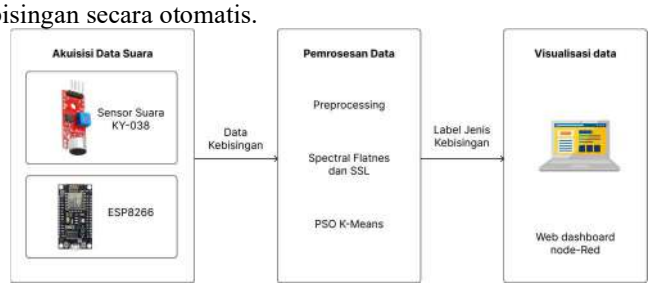
Keyword	[6]	[10]	[11]	[12]	[14]	Proposed
Spectral Flatness	✓	x	x	✓	x	✓
Entropy & Bandwidth	x	x	x	✓	x	✓
IoT-Based Noise Monitoring	x	✓	✓	x	x	✓
Real-time Dashboard	x	✓	x	x	x	✓
Microcontroller Type	x	✓	✓	x	x	✓
K-Means Clustering	x	x	x	x	✓	✓

3. Sistem yang Dibangun

3.1 Arsitektur Umum Sistem

Sistem ini dikembangkan untuk membantu melakukan penilaian tingkat kebisingan di rumah sakit secara otomatis dengan memanfaatkan perangkat IoT dan teknik klasterisasi.

Arsitektur sistem dapat dilihat pada Gambar 1, yang memperlihatkan alur kerja mulai dari merekam suara, mengolah sinyal audio, hingga mengelompokkan tingkat kebisingan secara otomatis.



GAMBAR 1
Gambaran Umum Sistem.

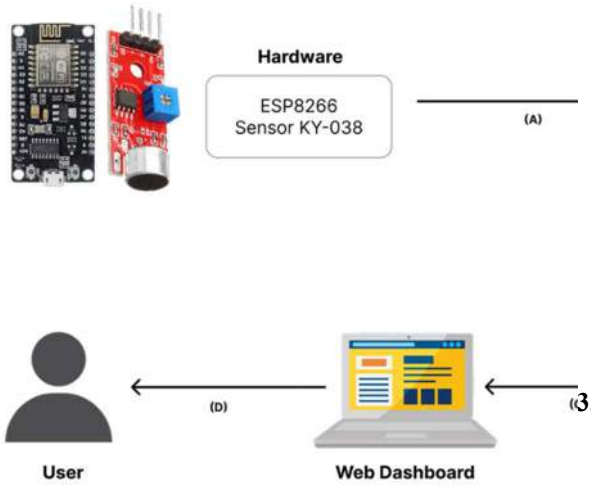
3.2 Data dan Karakteristik Kebisingan Rumah Sakit

Dataset yang digunakan pada penelitian ini adalah *Hospital Noise Dataset* dari Kaggle. Dataset tersebut berisi berbagai contoh suara rumah sakit, termasuk alarm medis, suara orang berbicara, suara mesin dan aktivitas ruang perawatan.

Sebelum sistem diuji menggunakan perangkat IoT di lapangan, dataset ini membantu memberikan gambaran awal tentang kondisi kebisingan nyata.

3.3 Rancangan Sistem IoT

Walaupun data penelitian berasal dari dataset publik, konsep sistem IoT tetap dirancang untuk menunjukkan bagaimana sistem diterapkan secara nyata. Rancangan sistem ditunjukkan pada Gambar 2.



GAMBAR 2
Rancangan Sistem IoT.

Sensor suara KY-038 dalam rancangan sistem ini menangkap tingkat kebisingan dan mengirimkannya ke mikrokontroler ESP8266. Mikrokontroler ESP8266 kemudian meneruskan data tersebut ke server melalui jaringan Wi-Fi secara *real-time*. Data yang masuk diolah dan ditampilkan melalui Node-RED, sehingga pengguna dapat melihat kondisi kebisingan rumah sakit secara langsung kapan pun dibutuhkan.

3.4 Pemrosesan Audio dan Ekstraksi Fitur

Setiap rekaman audio diproses melalui tahap *preprocessing* untuk memastikan keseragaman format dan kualitas sinyal audio. Setelah itu, dilakukan proses ekstraksi fitur akustik yang diperlukan untuk proses klasterisasi. Ekstraksi fitur dilakukan dengan menggabungkan dua pendekatan agar informasi yang diperoleh lebih lengkap.

Pendekatan pertama menggunakan fitur statistik akustik, seperti *spectral flatness,* RMS, RMSE, level dB, dan SNR. *Spectral flatness* dihitung menggunakan *librosa* [15] untuk memodelkan distribusi energi frekuensi, sedangkan RMS, RMSE, dB, dan SNR digunakan untuk merepresentasikan intensitas dan kualitas sinyal. Rangkuman metrik dapat dilihat pada Tabel 3.

TABEL 3.
Deskripsi Metrik Akustik untuk Analisis Kebisingan.

Metrik	Deskripsi	Persamaan	Nilai Rendah / Nilai Tinggi
dB Level	Kekuatan suara dari sinyal audio.	$\mathrm{dB} = 10 \log_{10}\left(\frac{p}{p_0}\right)$	Lingkungan yang tenang / Lingkungan yang bising
RMS	Nilai *Root Mean Square* dari sinyal.	$\mathrm{RMS} = \sqrt{\frac{1}{N}\sum_{i=1}^{N} x_i^2}$	Energi rendah, senyap / Energi tinggi, keras
RMSE	*Root Mean Squared Error* dibandingkan dengan referensi.	$\mathrm{RMSE} = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(x_i - y_i)^2}$	Distorsi rendah / Berisik, terdistorsi
SNR (dB)	Kejernihan sinyal dibandingkan dengan *noise*.	$\mathrm{SNR} = 10 \log_{10}\left(\frac{Signal\ Power}{Noise\ Power}\right)$	Sangat bising / Sinyal jernih
Spectral Flatness	Mengindikasikan apakah suara lebih mirip derau atau nada.	$\mathrm{SF} = \frac{Geometric\ Mean}{Arithmeti\ \ Mean}$	Suara tonal / Suara *noise*

Pendekatan kedua memanfaatkan fitur berbasis *self-supervised learning* (SSL), yang dapat menghasilak *embedding audio* tanpa memerlukan label manual [16]. Dengan pendekatan ini, sistem dapat menangkap informasi akustik yang lebih kompleks.

3.5 Klasterisasi dan Pelabelan Otomatis menggunakan PSO–K-Means

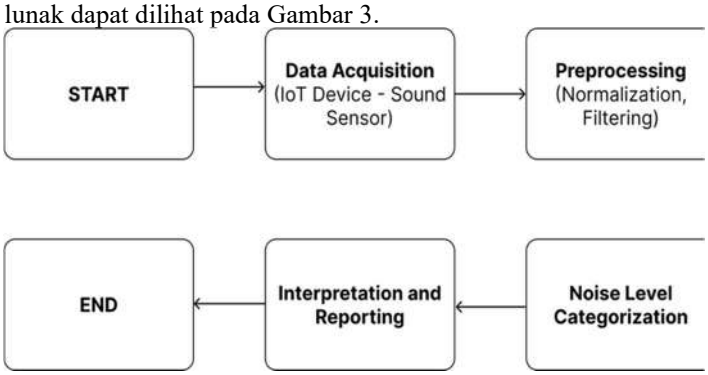
PSO-K-Means digunakan untuk proses pengelompokan tingkat kebisingan dalam penelitian ini. PSO digunakan untuk mencari titik pusat klaster *(centroid)* dan jumlah klaster terbaik. Setiap konfigurasi dievaluasi menggunakan *silhouette score* untuk mengetahui seberapa baik data terpisah antar klaster, hingga diperoleh konfigurasi paling optimal *(gbest)*.

Hasil optimasi tersebut kemudian digunakan sebagai inisialisasi awal bagi K-Means, untuk membentuk kelompok data berdasarkan kemiripan fitur. Metode ini mengurangi risiko kesalahan pengelompokan yang sering terjadi pada K-Means standar dan memungkinkan sistem untuk menentukan kategori kebisingan secara otomatis tanpa perlu pelabelan manual.

3.6 *Flowchart* Perangkat Lunak

Untuk menggambarkan proses pemrosesan data dalam sistem yang dikembangkan, digunakan sebuah flowchart yang merangkum seluruh tahapan utama mulai dari input data hingga keluaran hasil. Diagram ini menunjukkan proses ekstraksi fitur menggunakan pendekatan SSL, penggabungan fitur statistik, dan tahapan klasterisasi menggunakan

algoritma PSO dan K-Means. Selain itu, *silhouette score* digunakan untuk menilai hasil klaster. Setiap proses ini terintegrasi dalam sebuah pipeline perangkat lunak yang dapat dijalankan secara end-to-end. Flowchart dari perangkat lunak dapat dilihat pada Gambar 3.



GAMBAR 3
Flowchart Penilaian Kebisingan di Rumah Sakit.

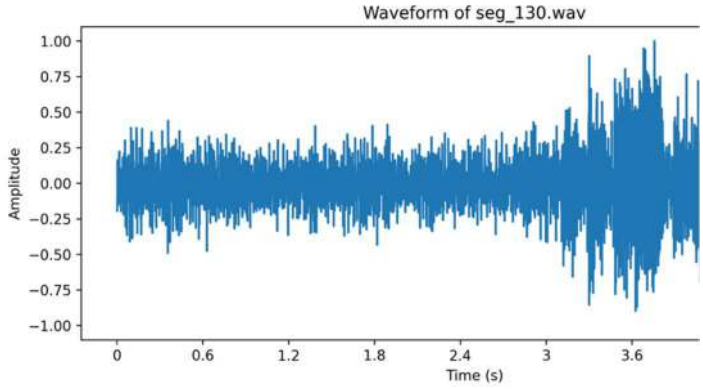
4. Evaluasi

Bagian ini membahas hasil pengujian PSO-K-Means pada data kebisingan rumah sakit dan analisis performanya. Evaluasi dilakukan untuk memastikan bahwa sistem dapat mengelompokkan tingkat kebisingan secara otomatis sesuai dengan tujuan penelitian.

4.1 Hasil Pengujian

Pengujian dilakukan melaului dua tahap utama, yaitu ekstraksi fitur akustik dan klasterisasi menggunakan metode PSO-K-Means. Tahap pertama bertujuan memperoleh parameter akustik yang merepresentasikan karakteristik sinyal audio, sedangkan tahap kedua digunakan untuk menentukan pembagian klaster yang optimal.

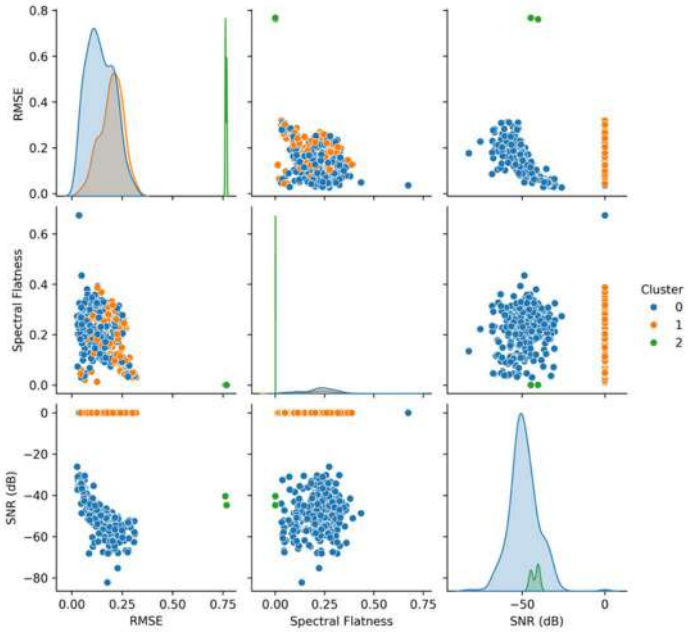
Pada tahap pertama, data audio diolah untuk mendapatkan nilai RMS, RMSE, SNR, dB, dan *spectral flatness*. Salah satu contoh *waveform* audio ditunjukkan pada Gambar 4 dan digunakan sebagai dasar perhitungan fitur. Hasil fitur inilah yang digunakan sebagai input pada proses klasterisasi.



GAMBAR 4
Waveform dari audio *seg 130.wav.*

Pada tahap kedua, algoritma PSO mencapai titik konvergensi pada iterasi ke-20 dari total 40 iterasi. Dari hasil optimasi, menunjukkan bahwa kombinasi fitur terbaik terdiri dari *spectral flatness*, RMSE, dan SNR. Selain itu, PSO menentukan jumlah klaster optimal sebanyak tiga, dengan nilai *silhouette score* sebesar 0,54, yang lebih tinggi dibandingkan pendekatan elbow method yang menghasilkan enam klaster dengan nilai *silhouette score* 0,22.

Hasil pengelompokan kemudian divisualisasikan menggunakan *scatter plot matrix* pada Gambar 5. Visualisasi ini menunjukkan menunjukkan bahwa penggunaan konfigurasi hasil optimasi PSO menghasilkan performa pengelompokan yang lebih unggul.



GAMBAR 5
Scatter plot matrix dari klaster yang dibentuk oleh PSO-K-Means.

4.2 Analisis Hasil Pengujian

Tujuan analisis ini adalah untuk memahami seperti apa karakter suara yang muncul di setiap klaster dan apa dampaknya terhadap kondisi kebisingan di rumah sakit. Berdasarkan *scatter plot matrix* dan hasil pengelompokan, rangkuman karakteristik tiap klaster tercantum pada Tabel 4. Sebagian besar data berada pada Klaster 0, yang ditandai oleh SNR sangat rendah dan *spectral flatness* tinggi, menunjukkan suara bising yang terus menerus, seperti bunyi mesin AC atau perangkat medis.

TABEL 4
Karakteristik Audio Setiap Klaster Hasil Klasterisasi.

Klaster	Rentang RMSE	Rentang SNR	Karakteristik *Spectral Flatness*	Indikasi Lingkungan / Sumber Suara
Klaster 0	Rendah – Sedang	Sangat rendah (–75 dB hingga –30 dB)	Relatif tinggi (noise-like)	Suara mesin seperti AC, kipas, dan perangkat rumah sakit lainnya yang menghasilkan kebisingan kontinyu.
Klaster 1	Rendah	Relatif lebih baik	Cenderung tonal	Kondisi lingkungan tenang, biasanya terjadi pada malam hari atau saat aktivitas ruangan rendah.
Klaster 2	Tinggi	Rendah – Sedang	Tonal	Suara keras dengan karakteristik tonal, misalnya

				pengumuman melalui pengeras suara.

Klaster 1 menunjukkan kondisi yang lebih tenang, dengan nilai RMSE rendah dan karakter tonal yang lebih stabil, seperti kondisi ruangan ketika aktivitas relatif minimum. Sementara itu, klaster 2 menunjukkan tingkat kebisingan yang lebih tinggi dan karakter tonal kuat, misalnya bunyi pengumuman dari pengeras suara.

Distribusi data tiap klaster membuktikan dominasi kebisingan di lingkungan rumah sakit, dengan 350 data di Klaster 0, 196 di Klaster 1, dan hanya 16 di Klaster 2. Hal ini juga diperkuat oleh kisaran nilai SNR –75 dB hingga –30 dB yang menandakan rendahnya kejernihan sinyal audio akibat tingginya tingkat kebisingan.

Secara keseluruhan, hasil penelitian menunjukkan bahwa PSO-K-Means mampu mengelompokkan data dengan baik, serta memberikan gambaran nyata kondisi kebisingan di rumah sakit. Hasil ini selaras dengan penelitian sebelumnya yang menyatakan bahwa kebisingan rumah sakit berdampak pada kualitas tidur pasien, meningkatkan stres tenaga medis, dan menghambat proses komunikasi [3]. Oleh karena itu, sistem klasterisasi kebisingan ini dapat menjadi landasan untuk pengembangan sistem pemantauan kebisingan secara *real-time*.

5. Kesimpulan

Penelitian ini berhasil mengembangkan sistem penilaian kebisingan berbasis ekstraksi fitur akustik dan metode pengelompokan PSO–K-Means yang dapat beroperasi secara otomatis tanpa memerlukan pelabelan manual. Hasil evaluasi menunjukkan bahwa PSO mampu menemukan konfigurasi klaster terbaik, yaitu tiga klaster, dengan nilai *silhouette score* 0,54, lebih baik dari elbow method yang hanya menghasilkan 0,22. Penggunaan kombinasi fitur *spectral flatness,* RMSE, dan SNR terbukti paling efektif dalam membedakan karakteristik suara di lingkungan rumah sakit. Hasil klasterisasi menunjukkan bahwa sebagian besar sampel berada pada kategori kebisingan tinggi, yang ditandai oleh nilai SNR yang sangat rendah, berkisar antara –75 dB hingga –30 dB. Kondisi ini mencerminkan dominasi suara mesin atau peralatan medis yang beroperasi secara terus-menerus di lingkungan rumah sakit.

Secara keseluruhan, seluruh tujuan penelitian dapat dicapai dengan baik. Berdasarkan proses perancangan dan pengujian yang dilakukan, sistem yang dikembangkan dinilai mampu merepresentasikan kondisi kebisingan rumah sakit secara cukup realistis dan memiliki potensi untuk diintegrasikan ke dalam sistem pemantauan kebisingan berbasis IoT.

Untuk pengembangan di masa mendatang, penelitian dapat diperluas pada lebih banyak area di rumah sakit seperti ICU, IGD, atau ruang tunggu agar memperoleh hasil yang mewakili kondisi suara yang lebih luas. Sistem IoT juga dapat ditingkatkan dengan sensor suara yang lebih sensitif dan modul komunikasi seperti LoRa atau BLE agar pemantauan dapat dilakukan di banyak ruangan sekaligus secara *real-time*. Penelitian mendatang juga dapat mempertimbangkan integrasi fitur akustik lanjutan seperti MFCC atau *Spectral Centroid*, serta perbandingan dengan algoritma alternatif seperti DBSCAN, GMM, SVM, atau ANN untuk melihat mana yang paling efektif. Selain itu, sistem dapat dikembangkan agar mampu memberikan peringatan otomatis saat kebisingan melewati batas aman, sehingga sistem benar-benar bisa bermanfaat untuk menjaga kenyamanan dan keselamatan pasien maupun tenaga medis.

REFERENSI

[1] G. Chatzilampri and F. Stevens, "Are Noisy Hospitals Making Us Sick?," *Frontiers for Young Minds,* vol. 9, 2022.

[2] E. e Lima Andrade, D. C. da Cunha e Silva, E. A. de Lima, R. A. de Oliveira, P. H. T. Zannin and A. C. G. Martins, "Environmental noise in hospitals: a systematic review," *Environmental Science and Pollution Research,* vol. 28, 2021.

[3] A. S. Soni, "Exploring the Therapeutic Potential of Acoustic Interventions in Healing Environments," *Indian Scientific Journal Of Research In Engineering And Management,* 2024.

[4] S. S. Nair, V. S. Meghashree and A. Mukhopadhyay, "*Real-time* Hospital Noise Detection and Classification Using IoT Devices, MFCC, and Artificial Neural Networks," in *2024 International Conference on Computing, Sciences and Communications (ICCSC)*, 2024.

[5] W. B. W. Ismail, R. Rosdi and S. K. Zulkefli, "A *Real-time* Noise Detector for Patient Monitoring at Hospital Wards," in *2024 IEEE 14th Symposium on Computer Applications & Industrial Electronics (ISCAIE)*, 2024.

[6] D. Hu, Z. Chen and F. Yin, "Frequency response analytical calibration based on spectral flatness for microphone arrays," *IEEE Transactions on Instrumentation and Measurement,* vol. 70, 2020.

[7] E. R. Krishna, N. Devarakonda, M. Y. H. Al-Shamri and D. Revathi, "A novel hybrid clustering analysis based on combination of k-means and pso algorithm," in *Data Intelligence and Cognitive Informatics: Proceedings of ICDICI 2021* , Springer , 2022.

[8] Q. Pu, J. Gan, L. Qiu, J. Duan and H. Wang, "An efficient hybrid approach based on PSO, ABC and k-means for cluster analysis," *Multimedia Tools and Applications ,* vol. 81, no. 14, 2022.

[9] W. Yang, Y.-s. Liu and F.-m. Wu, "Unsteady Narrowband Spectrum Enhancement Method of Ship Noise Using PSO and Stochastic Resonance Processing," in *2024 OES China Ocean Acoustics (COA)* , 2024.

[10] A. A. Rafiq, S. D. Riyanto and H. Susanti, "Noise Detection System in The Classroom Using Sound Sensors and NodeMCU ESP6288," *Journal of Electronics Technology Exploration,* vol. 1, no. 1, pp. 1-14, 2023.

[11] R. Rifqah, S. Suciyati, A. Surtono and A. Pauzi, "Design of a Classroom Noise Monitoring Tool Using a KY-037 Sound Sensor Based on Wemos D1R1," *Journal of Energy, Material, and*

Instrumentation Technology, vol. 4, p. 125–135, 2023.

[12] E. Segerstrom, L. Vanfretti, C. Mishra, X. Xu, K. D. Jones and R. M. Gardner, "Using Spectral Flatness to Detect and Label Power System Oscillations in the Presence of Intermittent Broadband Noise," in *2022 IEEE Power & Energy Society General Meeting (PESGM)*, 2022.

[13] S. Harris and R. C. De Amorim, "An extensive empirical comparison of k-means initialization algorithms," *IEEE Access,* vol. 10, 2022.

[14] S. Riyadi, A. S. Salsabila and A. R. P. Dewi, "Analysis of Music Genre Based on Similar Audio Features Using K-Means Algorithm: A Case of Spotify Top Hits," in *2024 International Conference on Information Technology and Computing (ICITCOM)*, 2024.

[15] J. Devaney, "Digital Audio Processing Tools for Music Corpus Studies," in *The Oxford Handbook of Music and Corpus Studies* , Oxford Academic , 2023.

[16] S. Ozsoy, S. Hamdan, S. Arik, D. Yuret and A. Erdogan, "Self-supervised learning with an information maximization criterion," *Advances in Neural Information Processing Systems ,* vol. 35, 2022.