

BAB I PENDAHULUAN

1.1 Latar Belakang

Penyakit kardiovaskular masih merupakan permasalahan kesehatan utama dan berkontribusi besar terhadap angka morbiditas dan mortalitas. Salah satu gangguan yang berbahaya adalah aritmia, yaitu kelainan irama jantung yang dapat memicu komplikasi serius serta meningkatkan risiko sudden cardiac death, sehingga deteksi dini menjadi sangat penting (Könemann et al. 2023). Selain itu, aritmia juga dapat berhubungan dengan kondisi klinis lain yang memperberat keadaan pasien (Mehra et al. 2022).

Aritmia didefinisikan sebagai gangguan irama jantung yang terjadi akibat kelainan pembentukan impuls listrik atau gangguan penghantaran impuls listrik. Jenis aritmia yang umum meliputi atrial fibrillation, ventricular arrhythmia, atrioventricular block, premature ventricular contraction (PVC), dan lainnya, dengan dampak klinis mulai dari penurunan kualitas hidup hingga risiko kejadian fatal bila tidak ditangani secara tepat (Könemann et al. 2023; Lukas Laws et al. 2022).

Permasalahan aritmia menjadi semakin krusial pada populasi lansia. Risiko gangguan sistem konduksi seperti atrioventricular block dilaporkan meningkat seiring bertambahnya usia dan dipengaruhi faktor risiko tertentu (Zhang et al. 2024). Selain itu, aritmia pada lansia cenderung lebih kompleks sehingga dapat membutuhkan pendekatan penanganan khusus pada pasien usia lanjut (Di Monaco et al. 2023). Kompleksitas klinis dan gejala yang kerap tidak khas berpotensi menyebabkan keterlambatan diagnosis dan meningkatkan risiko komplikasi.

Dalam praktik klinis, Elektrokardiogram (EKG) merupakan metode utama untuk menganalisis aktivitas listrik jantung dan mendeteksi aritmia. Berbagai studi juga menegaskan EKG sebagai sumber data penting untuk pengembangan klasifikasi penyakit kardiovaskular berbasis machine learning dan deep learning (Soltanieh, Hashemi, dan Etemad 2024). Namun, interpretasi EKG manual membutuhkan tenaga ahli dan dapat kurang efisien ketika volume data besar.

Perkembangan machine learning dan deep learning telah mendorong klasifikasi aritmia secara otomatis menggunakan metode klasik maupun deep learning. Tinjauan

penelitian menunjukkan beragam pendekatan ML/DL pada EKG, namun banyak metode supervised bergantung pada data berlabel dalam jumlah besar (Soltanieh et al. 2024). Contoh pendekatan deep learning seperti CNN-BiLSTM telah digunakan untuk klasifikasi aritmia berbasis EKG (Hassan et al. 2022), sementara studi komparatif ML klasik juga menyoroti tantangan performa dan kebutuhan data pada klasifikasi aritmia (Sharma et al. 2024). Penelitian Rizki dkk. (2025) juga menunjukkan bahwa klasifikasi aritmia pada lansia dapat dilakukan menggunakan algoritma Support Vector Machine (SVM) berbasis fitur fisiologis EKG, seperti RR, PR, QRS, QT, segmen ST, heart rate, dan rasio R/S. Penelitian tersebut memperoleh akurasi pengujian sebesar 94,57% dan nilai AUC 0,98–1,00 pada tiap kelas, sehingga memperkuat bahwa fitur EKG memiliki potensi besar dalam mendukung klasifikasi aritmia pada populasi lansia (Rizki et al., 2025).

Pada konteks lansia, tantangan menjadi lebih berat karena sinyal EKG dapat lebih bervariasi dan dipengaruhi faktor klinis, sementara pelabelan membutuhkan validasi ahli yang memakan biaya dan waktu. Hal ini berkontribusi pada keterbatasan label dan potensi ketidakseimbangan kelas pada beberapa studi, sehingga pendekatan yang mampu mempelajari representasi fitur tanpa selalu bergantung pada label sejak tahap awal pembelajaran menjadi relevan (Soltanieh et al. 2024; Zhang et al. 2024).

Untuk menjawab tantangan tersebut, Self-Supervised Representation Learning (SSRL) menjadi pendekatan yang menjanjikan. SSRL memungkinkan model mempelajari representasi fitur kuat melalui tugas pretext seperti rekonstruksi, masking, atau contrastive learning tanpa menggunakan label pada tahap pembelajaran representasi (Soltanieh et al. 2024). Sejumlah penerapan SSRL pada domain medis, misalnya citra ultrasound dan fundus, menunjukkan bahwa SSRL efektif meningkatkan kualitas representasi untuk tugas downstream (Chhipa et al. 2023; Li et al. 2023). Dengan karakter EKG sebagai data time-series, SSRL berpotensi membantu model mengenali pola penting pada sinyal meskipun data berlabel terbatas, sehingga diharapkan mendukung performa klasifikasi aritmia pada lansia (Soltanieh et al. 2024; Vandecasteele et al. 2021). Pada penelitian ini, dataset yang digunakan tetap memiliki label output, namun label tersebut tidak digunakan pada tahap pembelajaran representasi. Label output digunakan setelah representasi laten fitur EKG diperoleh, yaitu pada tahap klasifikasi aritmia.

Sebagai penguatan landasan teoretis dan empiris, penelitian ini juga merujuk pada kumpulan studi yang membahas aritmia dan klasifikasinya (Könemann et al. 2023), (Mehra et al. 2022), (Lukas Laws et al. 2022), (Hassan et al. 2022), (Sharma et al. 2024), aritmia pada lansia serta faktor klinis terkait (Di Monaco et al. 2023; Zhang et al. 2024), strategi self-supervised representation learning di domain medis dan pembelajaran representasi (Vandecasteele et al. 2021),(Pałczyński et al. 2022),(Aziz, Ahmed, dan Alouini 2021),(Tripathi et al. 2022),(Hong et al. 2020) serta kajian dan implementasi analisis EKG untuk klasifikasi penyakit kardiovaskular (Soltanieh et al. 2024),(Li et al. 2023),(Chhipa et al. 2023).

1.2 Rumusan Masalah

- 1) Bagaimana tahapan pengolahan data fitur EKG lansia agar siap digunakan untuk pembelajaran mesin?
- 2) Bagaimana menerapkan Self-Supervised Representation Learning menggunakan denoising autoencoder untuk mempelajari representasi fitur EKG tanpa menggunakan output pada tahap pembelajaran representasi?
- 3) Bagaimana membangun model klasifikasi aritmia pada lansia menggunakan representasi laten hasil Self-Supervised Representation Learning?
- 4) Seberapa baik performa model klasifikasi aritmia pada lansia berdasarkan metrik accuracy, macro recall, macro precision, ROC-AUC, macro F1-score, kurva ROC, confusion matrix, sertavalidasi silang 5-fold?

1.3 Tujuan Penelitian

- 1) Menyusun pipeline pengolahan data fitur EKG lansia agar siap digunakan untuk pelatihan model pembelajaran mesin.
- 2) Membangun model representasi berbasis Self-Supervised Representation Learning menggunakan denoising autoencoder dengan memanfaatkan fitur EKG tanpa menggunakan label output pada tahap pembelajaran representasi.

- 3) Melatih model klasifikasi aritmia menggunakan representasi laten hasil pembelajaran Self-Supervised Representation Learning.
- 4) Mengevaluasi performa model klasifikasi aritmia menggunakan metrik accuracy, macro recall, macro precision, ROC-AUC, macro F1-score, confusion matrix, kurva ROC, dan validasi silang 5-fold.

1.4 Manfaat Penelitian

Manfaat yang diinginkan melalui studi ini yakni:

- 1) Manfaat akademik: memberikan kontribusi kajian penerapan Self-Supervised Representation Learning pada data fitur EKG, khususnya dalam konteks klasifikasi aritmia pada lansia.
- 2) Manfaat praktis: menyediakan pendekatan pembelajaran representasi yang dapat digunakan untuk mendukung proses klasifikasi aritmia berbasis fitur EKG.
- 3) Manfaat klinis (dukungan): membantu arah pengembangan sistem pendukung keputusan berbasis EKG untuk deteksi dini aritmia, khususnya pada populasi lansia.

1.5 Keterbaruan

Terdapat beberapa penelitian sebelumnya yang berkaitan dengan klasifikasi aritmia berbasis EKG serta pemanfaatan pembelajaran representasi/pendekatan terkait untuk meningkatkan kinerja ketika data berlabel terbatas. Berikut ringkasan penelitian terdahulu:

1. Hong dkk. (2020) menyajikan tinjauan sistematis peluang dan tantangan deep learning pada data EKG, serta menekankan isu umum seperti kualitas data, generalisasi model, dan kebutuhan data berlabel yang besar pada banyak studi supervised (Hong et al. 2020).
2. Hassan dkk. (2022) mengembangkan model CNN-BiLSTM untuk klasifikasi aritmia berbasis EKG dan menunjukkan performa yang baik, namun pendekatan

ini tetap bergantung pada pelatihan supervised dengan label yang memadai (Hassan et al. 2022).

3. Sharma dkk. (2024) melakukan studi komparatif berbagai algoritma machine learning pada klasifikasi aritmia dengan seleksi fitur, serta menyoroti tantangan performa akibat variasi dataset dan ketidakseimbangan kelas (Sharma et al. 2024).
4. Rizki dkk. (2025) mengembangkan model klasifikasi aritmia pada lansia menggunakan algoritma Support Vector Machine (SVM) berbasis sinyal EKG. Penelitian tersebut menggunakan fitur fisiologis seperti RR, PR, QRS, QT, segmen ST, heart rate, dan rasio R/S, serta memperoleh akurasi 94,57% pada data pengujian dengan nilai AUC 0,98–1,00 pada tiap kelas. Namun, pendekatan tersebut masih berbasis supervised learning, sehingga berbeda dengan penelitian ini yang menerapkan Self-Supervised Representation Learning untuk mempelajari representasi fitur tanpa menggunakan label output pada tahap awal pembelajaran (Rizki et al., 2025).
5. Pałczyński dkk. (2022) mengkaji few-shot learning untuk klasifikasi EKG (PTB-XL) sebagai solusi ketika label terbatas, yang mengindikasikan pentingnya representasi fitur yang kuat pada skenario data berlabel minim (Pałczyński et al. 2022).
6. Soltanieh, Hashemi, & Etemad (2024) mengusulkan self-supervised ECG representation learning untuk deteksi aritmia, termasuk evaluasi in-distribution dan out-of-distribution, serta menunjukkan bahwa representasi hasil self-supervised dapat meningkatkan kemampuan generalisasi pada tugas downstream (Soltanieh et al. 2024).

Berdasarkan penelitian terdahulu tersebut, keterbaruan penelitian ini terletak pada:

- (1) penerapan Self-Supervised Representation Learning menggunakan denoising autoencoder pada dataset fitur EKG lansia; (2) pemanfaatan label output hanya pada tahap klasifikasi, sedangkan tahap pembelajaran representasi dilakukan tanpa menggunakan label output; dan (3) evaluasi model klasifikasi aritmia menggunakan metrik accuracy, macro recall, macro precision, ROC-AUC, macro F1-score, confusion matrix, kurva ROC, serta validasi silang 5-fold.