

# Analisis Performa CNN-PatchTST untuk Klasifikasi Aritmia melalui Sinyal EKG

Humam Maulana Tsubasanofa Ramadhan<sup>1</sup>, Achmad Junaidi<sup>2\*</sup>, M. Muharrom Al Haromainy<sup>3</sup>

<sup>1,2,3</sup>Informatika, Universitas Pembangunan Nasional “Veteran” Jawa Timur

<sup>1</sup>[20081010084@student.upnjatim.ac.id](mailto:20081010084@student.upnjatim.ac.id)

<sup>3</sup>[muhammad.muharrom.if@upnjatim.ac.id](mailto:muhammad.muharrom.if@upnjatim.ac.id)

\*Corresponding author email: [achmadjunaidi.if@upnjatim.ac.id](mailto:achmadjunaidi.if@upnjatim.ac.id)

**Abstrak**— Penyakit kardiovaskular, khususnya aritmia, merupakan salah satu penyebab kematian tertinggi di dunia. Deteksi aritmia secara manual melalui interpretasi sinyal elektrokardiogram (EKG) membutuhkan waktu lama dan rentan terhadap kesalahan antar-pengamat. Penelitian ini mengusulkan model *hybrid* CNN-PatchTST untuk mengklasifikasikan lima jenis aritmia, yaitu *Atrial Fibrillation* (AF), *First-degree AV Block* (IAVB), *Normal Sinus Rhythm* (NSR), *Sinus Bradycardia* (SB), dan *Sinus Tachycardia* (STach) dari sinyal EKG. Model ini menggabungkan CNN satu dimensi sebagai ekstraktor fitur morfologi lokal dengan PatchTST berbasis Transformer untuk menangkap dependensi temporal jangka panjang. Dataset yang digunakan merupakan gabungan enam sumber publik dari Kaggle dengan total 29.858 rekaman sinyal EKG pada frekuensi 500 Hz. *Preprocessing* mencakup standarisasi sinyal, *noise filtering*, normalisasi Z-score, dan *hybrid sampling* untuk mengatasi ketidakseimbangan kelas. Pengujian dilakukan pada tiga skenario rasio pembagian data yang berbeda. Hasil terbaik diperoleh pada rasio 70:20:10 dengan akurasi 88,8%, sensitivitas makro 84,3%, spesifisitas makro 96,3%, dan F1-score makro 82,5%. Kelas AF dan NSR mencatat performa terbaik dengan F1-score masing-masing 91% dan 93%, sementara kelas IAVB dan SB menunjukkan performa lebih rendah akibat kemiripan morfologi sinyal dengan NSR.

**Kata Kunci**— Aritmia, Elektrokardiogram (EKG), *Convolutional Neural Network* (CNN), Transformer, PatchTST, *time-series*.

## I. PENDAHULUAN

Penyakit kardiovaskular (PKV) hingga saat ini masih menjadi ancaman kesehatan global dengan angka kematian tertinggi di dunia. WHO mencatat bahwa pada tahun 2022, sekitar 19,8 juta jiwa meninggal akibat PKV setiap tahunnya, mewakili 32% dari total kematian secara global, di mana 85% kasus tersebut dipicu oleh serangan jantung dan stroke [1], [2]. Di Indonesia sendiri, data menunjukkan bahwa tidak kurang dari 2.784.064 penduduk Indonesia tercatat menderita penyakit jantung [3]. Salah satu manifestasi yang paling berbahaya dari PKV adalah aritmia, yakni kondisi gangguan irama jantung yang berpotensi memicu komplikasi serius seperti stroke, gagal jantung, bahkan kematian jantung mendadak [4], [5].

Identifikasi dan klasifikasi aritmia menjadi hal yang krusial mengingat kondisi ini berkaitan langsung dengan berbagai komplikasi kardial yang serius. Secara konvensional, identifikasi aritmia dilakukan melalui pengamatan visual terhadap rekaman sinyal EKG, yang mencakup analisis irama,

durasi, orientasi, serta morfologi gelombang [6]. Proses interpretasi manual ini memerlukan waktu yang lama dan rentan terhadap variabilitas antar pengamat [7]. Kesalahan dalam membaca sinyal EKG berisiko mengakibatkan kekeliruan keputusan klinis yang dapat membahayakan keselamatan pasien [8]. Atas dasar pertimbangan tersebut, berbagai model *machine learning* telah dikembangkan sebagai sistem pendukung keputusan bagi klinisi dalam melakukan deteksi dan klasifikasi pola gelombang elektrokardiogram.

Perkembangan pesat teknik *Deep Learning* (DL) dalam beberapa tahun terakhir, khususnya *Convolutional Neural Network* (CNN) dan *Recurrent Neural Network* (RNN), telah memperlihatkan potensi dalam mengotomatisasi proses analisis sinyal EKG. Namun, CNN yang unggul dalam mengekstraksi fitur morfologis lokal kesulitan dalam menangkap ketergantungan temporal global dan jangka panjang yang penting untuk memahami pola ritme kompleks dalam rentang waktu yang panjang [9]. Sementara itu, RNN memiliki kompleksitas komputasi yang tinggi serta kendala dalam melatih model pada sekuens yang sangat panjang akibat permasalahan *vanishing* atau *exploding gradient* [10]. Keterbatasan kedua arsitektur tersebut mendorong perkembangan berbagai pendekatan arsitektur *hybrid* dan berbasis *attention*, di mana CNN difungsikan untuk menangani analisis morfologi lokal, sementara *recurrent network*, *Transformer*, atau model sekuensial lainnya dimanfaatkan untuk mempelajari dinamika ritme jantung dalam jangka panjang.

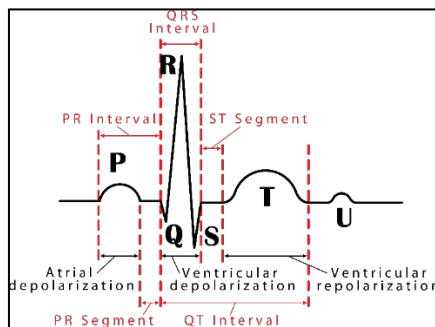
Penelitian ini mengeksplorasi penerapan salah satu arsitektur berbasis *Transformer*, yaitu *Patch Time Series Transformer* (PatchTST), untuk klasifikasi sinyal EKG. Berbeda dengan arsitektur *Transformer* konvensional, PatchTST bekerja dengan cara membagi data deret waktu menjadi segmen-segmen (*patches*) yang selanjutnya diperlakukan sebagai token input. Pendekatan ini secara efektif mereduksi kompleksitas komputasi kuadratik yang melekat pada mekanisme *self-attention* standar, sehingga memungkinkan model untuk memproses data deret waktu dengan jumlah *timesteps* yang jauh lebih panjang secara lebih efisien [11].

## II. TINJAUAN PUSTAKA

### A. Sistem Kardiovaskuler dan Sinyal EKG

Sistem kardiovaskuler merupakan sistem organ sirkulasi yang tersusun atas jantung, pembuluh darah, dan darah, yang secara

bersama-sama berfungsi mendistribusikan oksigen, nutrisi, serta hormon ke seluruh jaringan tubuh, sekaligus mengangkut sisa metabolisme untuk dikeluarkan dari tubuh [12]. Irama jantung dikendalikan oleh sistem konduksi kelistrikan yang melibatkan beberapa komponen utama, yakni nodus sinoatrial (SA), nodus atrioventrikular (AV), berkas His, serta serabut Purkinje. Dalam kondisi fisiologis normal, nodus SA berperan sebagai *pacemaker* primer yang menghasilkan impuls listrik dengan frekuensi sekitar 60–80 denyut per menit [13]. Aktivitas kelistrikan jantung tersebut dapat direkam dan dievaluasi melalui pemeriksaan elektrokardiogram (EKG). Secara fungsional, EKG memvisualisasikan proses depolarisasi dan repolarisasi miokardium dalam bentuk gelombang yang teratur, sehingga dapat dimanfaatkan sebagai modalitas diagnostik untuk menilai irama jantung, mendeteksi aritmia, mengidentifikasi iskemia dan infark miokard, mengevaluasi hipertrofi jantung, serta memantau pengaruh obat-obatan atau gangguan elektrolit terhadap fungsi jantung [14].



Gbr. 1 Struktur Satu Periode Gelombang Elektrokardiogram [15]

Pada Gambar 1 di atas, dapat dilihat struktur gelombang elektrokardiogram yang dibagi menjadi enam titik P, Q, R, S, T, dan U. Berikut adalah keterangan dari masing-masing gelombang [15], [16]:

- 1) *Gelombang P*: merupakan puncak awal siklus yang menunjukkan depolarisasi atrium.
- 2) *Gelombang Q*: merupakan titik minimum pertama menunjukkan awal depolarisasi ventrikel.
- 3) *Gelombang R*: merupakan titik tertinggi dalam satu siklus yang menunjukkan puncak depolarisasi ventrikel.
- 4) *Gelombang S*: merupakan titik minimum kedua sebagai akhir dari proses depolarisasi ventrikel (kompleks QRS).
- 5) *Gelombang T*: menunjukkan repolarisasi ventrikel.
- 6) *Gelombang U*: merupakan gelombang yang tidak selalu terlihat yang juga menunjukkan proses repolarisasi.

#### B. Aritmia

Aritmia merupakan kondisi gangguan jantung yang ditandai dengan ketidaknormalan irama detak jantung, baik berupa peningkatan frekuensi yang berlebihan, penurunan frekuensi

yang abnormal, maupun irama yang tidak beraturan, akibat adanya gangguan pada penghantaran impuls listrik menuju miokardium [17], [18]. Meskipun sejumlah jenis aritmia bersifat asimtomatik, aritmia dengan derajat keparahan yang lebih tinggi dapat menimbulkan berbagai manifestasi klinis yang signifikan, seperti palpitasi, vertigo, nyeri dada, dispnea, hingga sinkop atau kehilangan kesadaran. Adapun berikut adalah beberapa jenis aritmia [19], [20], [21]:

1) *Atrial Fibrillation*: merupakan jenis aritmia yang ditandai oleh kontraksi atrium yang cepat dan tidak teratur akibat impuls listrik yang tidak berasal dari nodus SA, melainkan dari bagian lain atrium atau vena pulmonalis, sehingga kemampuan atrium dalam memompa darah menjadi terganggu. Sinyal abnormal yang diteruskan ke ventrikel dapat memicu kontraksi yang tidak teratur dan berlebihan. Apabila tidak ditangani secara adekuat, FA berpotensi berkembang menjadi komplikasi serius, termasuk stroke iskemik dan gagal jantung kongestif [17], [22].

2) *First-degree Atrioventricular Block*: merupakan kondisi aritmia akibat gangguan penghantaran impuls listrik dari atrium ke ventrikel melalui nodus AV, baik secara parsial maupun total. Kondisi ini menyebabkan penurunan frekuensi detak jantung atau irama yang tidak teratur, sehingga kemampuan jantung memompa darah terganggu. Dalam kondisi normal, nodus AV berfungsi sebagai satu-satunya penghubung konduksi antara atrium dan ventrikel sekaligus memberikan jeda agar atrium berkontraksi penuh sebelum ventrikel. Gangguan pada fungsi inilah yang menjadi dasar patofisiologi AV Block [23]. *First-degree AV block* ditandai oleh perlambatan konduksi impuls dari atrium ke ventrikel, bukan pemblokiran total. Secara elektrokardiografis, kondisi ini terlihat dari pemanjangan interval PR melebihi 200 milidetik dengan rasio konduksi 1:1, di mana setiap gelombang P tetap diikuti kompleks QRS. Oleh karena itu, kondisi ini lebih tepat disebut sebagai "AV delay" daripada blok sesungguhnya. [24].

3) *Sinus Bradycardia*: merupakan gangguan irama jantung yang ditandai oleh penurunan frekuensi depolarisasi nodus SA di bawah ambang batas normal, yakni kurang dari 60 bpm, meskipun nodus SA tetap berfungsi sebagai *pacemaker* alami jantung. Dalam kondisi ini, inisiasi impuls listrik masih berlangsung secara normal dari nodus SA, namun dengan frekuensi yang lebih rendah dibandingkan kondisi fisiologis pada umumnya. *Sinus bradycardia* dapat bersifat fisiologis dan dianggap normal pada kondisi tertentu, seperti saat tidur, pada atlet muda yang rutin berolahraga, atau pada individu sehat yang tidak menunjukkan keluhan apapun, karena merupakan refleksi dari efisiensi kerja jantung yang optimal.

4) *Sinus Tachycardia*: merupakan kondisi aritmia yang ditandai oleh peningkatan frekuensi depolarisasi nodus SA melebihi batas normal, yakni lebih dari 100 bpm pada orang dewasa, meskipun irama jantung tetap teratur. Impuls listrik

pada *sinus tachycardia* tetap berasal dari nodus SA sebagaimana mestinya, sehingga pola konduksi atrioventrikular masih berjalan secara normal. Kondisi ini seringkali merupakan respons fisiologis yang wajar terhadap aktivitas fisik, stres emosional, demam, atau dehidrasi.

### C. High-Pass Butterworth Filter

*High-pass Butterworth filter* digunakan untuk menghilangkan *baseline wander* (pergeseran *baseline*) pada sinyal ECG/fisiologis. *Baseline wander* umumnya disebabkan oleh gerakan elektroda, pernapasan, atau pergerakan tubuh yang menghasilkan komponen frekuensi rendah di bawah 0.5 Hz. Dengan memotong frekuensi di bawah ambang tersebut, sinyal ECG yang relevan (komponen >0.5 Hz) tetap dipertahankan utuh [25].

### D. Powerline Filtering

*Powerline noise* adalah interferensi dari jaringan listrik AC yang masuk ke sinyal ECG pada frekuensi 50 Hz (standar Eropa/Asia) atau 60 Hz (standar Amerika Utara). *Noise* ini disebabkan oleh induksi elektromagnetik dari peralatan listrik di sekitar elektroda. Karena frekuensinya berada di dalam rentang frekuensi sinyal ECG (0.05–150 Hz), *powerline noise* tidak bisa dihilangkan dengan *simple low-pass filter* [26]. NeuroKit2 mengimplementasikan *powerline filtering* menggunakan *moving average kernel* dengan lebar satu periode dari frekuensi *powerline*. *Moving average* ini berfungsi sebagai *low-pass filter* yang secara efektif menghapus komponen 50 Hz karena rata-rata satu siklus penuh dari gelombang sinusoidal adalah nol [27].

### E. Synthetic Minority Oversampling Technique (SMOTE)

SMOTE merupakan salah satu pendekatan yang umum digunakan untuk mengatasi permasalahan ketidakseimbangan kelas. SMOTE bekerja dengan membuat sampel sintetis baru pada kelas minoritas melalui proses interpolasi antara suatu data minoritas dengan tetangga terdekatnya (*k-nearest neighbors*), sehingga distribusi kelas menjadi lebih seimbang dan model dapat belajar secara lebih merata [28].


### F. Random Undersampling

*Random Undersampling* (RUS) merupakan salah satu pendekatan yang digunakan untuk menangani ketidakseimbangan kelas pada dataset. RUS bekerja dengan cara menghapus secara acak sejumlah sampel dari kelas mayoritas hingga distribusi kelas menjadi lebih seimbang [29]. Pengurangan ukuran kelas mayoritas melalui RUS juga memberikan manfaat tambahan berupa berkurangnya beban komputasi, sehingga analisis pada dataset berukuran besar menjadi lebih efisien [30].

### G. Convolutional Neural Network (CNN)

*Convolutional Neural Network* (CNN) merupakan salah satu jenis jaringan saraf tiruan yang secara khusus dirancang untuk

memproses data seperti citra dua dimensi, dengan memanfaatkan operasi konvolusi untuk mengekstraksi representasi fitur secara lokal dan hierarkis [31], [32]. Arsitektur CNN pada umumnya tersusun atas *convolutional layer*, lapisan *pooling*, lapisan *activation*, dan lapisan *fully connected* yang bekerja secara bertahap untuk mengidentifikasi pola visual dari data masukan. Meskipun CNN pada awalnya dikembangkan dalam domain pengolahan citra, penerapannya tidak terbatas pada data dua dimensi saja. CNN juga bisa diterapkan di luar domain citra seperti penggunaan CNN untuk klasifikasi audio berbasis fitur spektral seperti MFCC dan Mel-spectrogram untuk pengenalan emosi musik [33]. CNN juga terbukti efektif diaplikasikan pada *Natural Language Processing* (NLP) maupun *time series* satu dimensi, berkat kemampuannya dalam mendeteksi pola lokal yang relevan pada berbagai jenis data sekuensial [34], [35].



Gbr. 2 Contoh Arsitektur 1D CNN

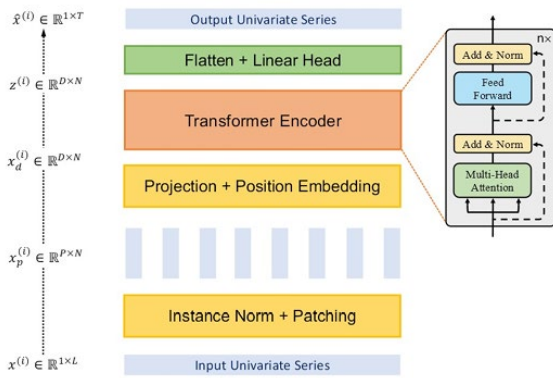
Seperti yang bisa dilihat pada Gambar 2 di atas, umumnya 1D CNN memiliki lapisan utama sebagai berikut:

- 1) *Convolutional Layer*: merupakan lapisan inti dalam arsitektur CNN yang bertanggung jawab atas proses pengenalan dan ekstraksi fitur dari data masukan. Lapisan ini bekerja dengan menggeser filter (*kernel*) secara sistematis di atas seluruh data input, sehingga menghasilkan *activation map* atau *feature map* yang merepresentasikan pola-pola dasar yang berhasil diidentifikasi, seperti tepi, tekstur, maupun pola morfologis lainnya.
- 2) *Pooling Layer*: berfungsi melakukan *down-sampling* terhadap *activation map* yang dihasilkan oleh *convolutional layer*, dengan tujuan mereduksi dimensi spasial data tanpa menghilangkan informasi yang signifikan. Proses reduksi ini dilakukan melalui dua pendekatan utama, yaitu *max pooling* yang mengambil nilai maksimum dalam suatu jendela lokal, atau *average pooling* yang menghitung nilai rata-rata dari jendela tersebut, sehingga kompleksitas komputasi dan jumlah parameter model dapat ditekan secara efisien.
- 3) *Activation Layer*: berperan dalam menyisipkan sifat non-linearitas ke dalam jaringan CNN, sehingga model mampu mempelajari dan merepresentasikan hubungan yang kompleks antara data masukan dan keluaran. Beberapa fungsi aktivasi yang umum digunakan antara lain Sigmoid, Tanh, dan *Rectified Linear Unit* (ReLU).

4) *Fully Connected Layer*: merupakan lapisan akhir dalam arsitektur CNN yang bertugas mengintegrasikan seluruh fitur hasil ekstraksi dari lapisan-lapisan sebelumnya untuk menghasilkan keputusan klasifikasi akhir. Sebelum memasuki lapisan ini, *feature map* multidimensional dari lapisan *pooling* atau *convolutional* terakhir terlebih dahulu diratakan (*flatten*) menjadi sebuah vektor, kemudian setiap neuron pada lapisan ini dihubungkan secara penuh dengan seluruh neuron dari lapisan sebelumnya untuk menghasilkan vektor probabilitas kelas keluaran.

#### H. Patch Time Series Transformers (PatchTST)

PatchTST adalah arsitektur transformer yang dirancang untuk data *time-series*, menggabungkan dua komponen utama yaitu *patching* untuk membagi deret waktu menjadi segmen-segmen, dan *channel independence* yang memproses setiap kanal secara terpisah dengan berbagi bobot transformer yang sama.



Gbr. 3 PatchTST Backbone

1) *Channel Independence*: Input *time-series multi channel* dipecah menjadi *single channel*, kemudian masing-masing channel dimasukkan ke *transformer encoder* secara terpisah namun dengan bobot model yang sama (*shared weights*).

2) *Patching*: Setiap *time-series*  $x^{(i)}$  dibagi menjadi beberapa *patch* baik *overlapping* ataupun *non-overlapping*. Dengan panjang *patch*  $P$  dan *stride*  $S$  (jarak *non-overlapping* antar dua *patch* berurutan).

3) *Linear Projection*: Setiap *patch time series* dengan panjang  $P$  dipetakan (*projecting*) menjadi dimensi yang ditentukan dengan menggunakan persamaan linear.

4) *Positional Encoding*: Karena mekanisme *self-attention* tidak dapat mengenali urutan, maka setiap *embedding patch* ditambahkan vektor *positional encoding* yang bergantung pada indeks *patch*-nya.

$$x_d^{(i)} = W_p \cdot x_p^{(i)} + W_{pos} \quad (1)$$

Keterangan:

$x_d^{(i)}$  = hasil akhir *positional embedding*

$W_p$  = matriks *weight linear projection*

$x_p^{(i)}$  = *patch time series* univariat ke- $i$

$W_{pos}$  = matriks *positional encoding*

5) *Transformer Encoder*: terdiri dari *self-attention*, *feed-forward network*, serta residual dan normalisasi yang terletak antara *self-attention* dan *feed-forward network*

6) *Self Attention*: Mekanisme *self-attention* memungkinkan setiap *patch* menangkap pola dependensi temporal yang kompleks dengan memanfaatkan informasi dari seluruh *patch* dalam sekuen, setelah melalui proses *embedding* dan *positional encoding*. Untuk setiap *head*  $h = 1, \dots, H$  dalam *multi-head attention*, transformasi dilakukan sebagai berikut:

$$\begin{aligned} Q_h^i &= (x_E^i)^T W_h^Q \\ K_h^i &= (x_E^i)^T W_h^K \\ V_h^i &= (x_E^i)^T W_h^V \end{aligned} \quad (2)$$

Keterangan:

$x_E^i \in \mathbb{R}^{D \times N}$  = input hasil *positional encoding*

$W_h^Q, W_h^K \in \mathbb{R}^{D \times d_k}$  = matriks bobot *query* dan *key*

$W_h^V \in \mathbb{R}^{D \times d_v}$  = matriks bobot *value*

$D$  = dimensi *hidden dimension*

$N$  = jumlah *patch*

$d_k$  = dimensi *query* dan *key*

Perhitungan *attention*:

$$O_h^i = \text{Attention}(Q_h^i, K_h^i, V_h^i) = \text{Softmax}\left(\frac{Q_h^i K_h^{i^T}}{\sqrt{d_k}}\right) V_h^i \quad (3)$$

Keterangan:

$O_h^i \in \mathbb{R}^{N \times d_v}$  = output dari *attention* ke- $h$

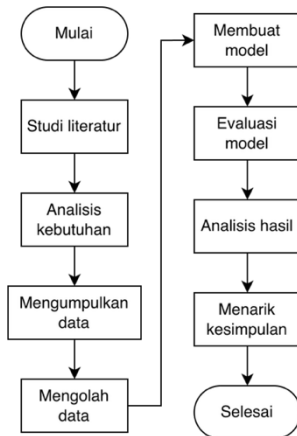
7) *Feed-Forward Network*: Setelah melalui *multi-head self-attention*, setiap representasi *patch* diproses oleh *feed-forward network* (FFN), yakni jaringan dua *layer* linear dengan fungsi aktivasi non-linear. FFN berfungsi untuk mengubah dan memperkaya fitur setiap *patch* secara independen, sehingga pola yang dipelajari *self-attention* dapat direpresentasikan lebih optimal.

8) *Residual Layer dan Normalisasi*: Pada setiap sub-layer, *transformer encoder* menerapkan *residual connection* dan normalisasi untuk menjaga kestabilan informasi. *Residual connection* menambahkan kembali input awal ke output sub-layer guna mencegah hilangnya fitur penting saat data melewati banyak *layer*, diikuti normalisasi menggunakan LayerNorm atau BatchNorm untuk menstabilkan proses *learning*.

- *Pooling dan Classification Head*: Output *transformer encoding* berupa deretan vektor per *patch* dirangkum menjadi satu vektor global melalui MeanPooling. Vektor ini kemudian diproses oleh *classification head* untuk menghasilkan skor per kelas, di mana fungsi *loss (cross-entropy)* digunakan selama pelatihan dan kelas dengan skor tertinggi diambil sebagai hasil klasifikasi.

### III. METODE PENELITIAN

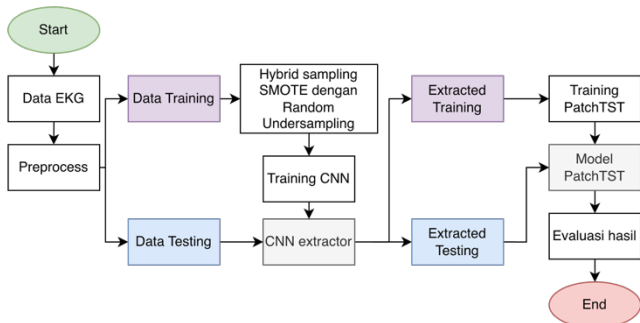
Dalam pelaksanaan penelitian ini, penulis menyusun alur penelitian secara sistematis sebagai panduan penelitian yang bisa dilihat pada Gambar 4 di bawah.



Gbr. 4 Diagram alur penelitian

#### A. Membuat Model

Setelah dilakukan *preprocessing*, data siap digunakan dalam pembuatan dan pelatihan model dengan alur seperti pada gambar 5 di bawah.



Gbr. 5 Diagram alur usulan model CNN-PatchTST

- 1) *Hybrid sampling*: Dataset yang didapat menunjukkan ketidakseimbangan distribusi antar kelas, sehingga diperlukan teknik sampling untuk menyeimbangkannya. Penelitian ini menerapkan pendekatan *hybrid sampling* yang mengombinasikan *Random Undersampling* pada kelas mayoritas (*Normal Sinus Rhythm*) dan SMOTE (*Synthetic Minority Oversampling Technique*) pada kelas-kelas minoritas.

Target jumlah sampel setiap kelas ditetapkan berdasarkan rata-rata jumlah seluruh kelas sebelum sampling dilakukan.

- 2) *CNN feature extraction*: Arsitektur CNN yang digunakan dalam penelitian ini adalah *Convolutional Neural Network* satu dimensi (CNN-1D) karena data input sinyal EKG yang bersifat *time-series* satu dimensi. Output dari CNN ini adalah 128 *channel* fitur temporal dengan panjang 336 timesteps.

- 3) *PatchTST*: Setelah melewati ekstraksi fitur CNN, fitur yang sudah diekstrak akan masuk ke PatchTST sebagai data input. Data hasil ekstraksi fitur CNN pertama-tama dilakukan *patching* dengan membagi sinyal menjadi sekuens kecil yang akan diperlakukan sebagai token *transformer*. Kemudian setiap patch akan masuk ke *transformer encoder* untuk menangkap dependensi jangka panjang antar patch. Kemudian yang terakhir adalah *classification head* yang menerima representasi hasil *encoding* kemudian melakukan *flatten* dan memetakannya ke dalam ruang output melalui linear layer untuk menghasilkan prediksi kelas aritmia. Adapun konfigurasi parameter yang digunakan pada penelitian ini bisa dilihat pada Tabel 1 di bawah.

TABEL 1  
NILAI PARAMETER PATCHTST

Parameter	Nilai
patch length	32
stride	16
d_model	64
num_attention_head	4
num_hidden_layer	3
ffn_dim	128
dropout	0.2
pooling type	"mean"

Parameter *patch\_length=32* dan *stride=16* dipilih mengikuti penelitian asli PatchTST [36]. Sedangkan parameter yang lain mengikuti konfigurasi *default* dari library Huggingface dengan beberapa penyesuaian pada *d\_model* dan *ffn\_dim* yang lebih kecil dibanding nilai *default* untuk mengurangi beban komputasi.

#### B. Skenario Pengujian

Dalam penelitian ini, penulis melakukan pengujian dengan tiga skenario yang berbeda seperti yang bisa dilihat pada Tabel 2 di bawah.

TABEL 2  
SKENARIO PENGUJIAN

Skenario	train:test:val	Konfigurasi
Skenario 1	60:30:10	Look-back window=336 patch_length=32 stride=16
Skenario 2	70:20:10	Look-back window=336 patch_length=32 stride=16

Skenario 3	80:10:10	Look-back window=336 patch_length=32 stride=16
---------------	----------	--

Perbedaan rasio pembagian data pada skenario pengujian dilakukan untuk mengetahui apakah model memiliki performa yang konsisten di berbagai skenario pembagian data.

#### IV. HASIL PENELITIAN

##### A. Dataset

Setelah mengumpulkan data dari enam sumber [37], [38], [39], [40], [41], [42], dan melakukan filter untuk memilih lima jenis aritmia, didapatkan data dengan distribusi kelas yang bisa dilihat pada Tabel 3 di bawah.

TABEL 3  
DISTRIBUSI KELAS ARITMIA

Aritmia	Jumlah
Atrial Fibrillation (AF)	3.461
First-degree Atrioventricular Block (IAVB)	2.383
Normal Sinus Rhythm (NSR)	19.854
Sinus Bradycardia (SB)	2.094
Sinus Tachycardia (STach)	2.066

Data yang dikumpulkan adalah data berupa 10 detik rekaman sinyal EKG berbentuk *time-series* dengan frekuensi 500 Hz dan panjang 5.000 *timesteps*.

##### B. Hasil Skenario Pengujian

Setelah melakukan pengujian ke semua skenario pengujian, penulis mencatat metrik performa hasil pengujian yaitu akurasi, sensitivitas, spesifisitas, dan f1-score yang bisa dilihat pada Tabel 4 di bawah.

TABEL 4  
HASIL SKENARIO PENGUJIAN

Split	Akurasi	Sensitivitas	Spesifisitas	F1-score
60:30:10	88,3%	82,2%	95,9%	81,2%
70:20:10	88,8%	84,3%	96,3%	82,5%
80:10:10	88,2%	83,4%	96,2%	81,3%

Ketiga skenario pembagian menunjukkan performa yang sangat konsisten, dengan akurasi berkisar 88,2%–88,8%, spesifisitas 95,9%–96,3%, dan F1-score 81,2%–82,5%. Rentang yang sempit ini mengindikasikan model stabil serta tidak sensitif terhadap variasi pembagian data.

##### C. Analisis Classification Report

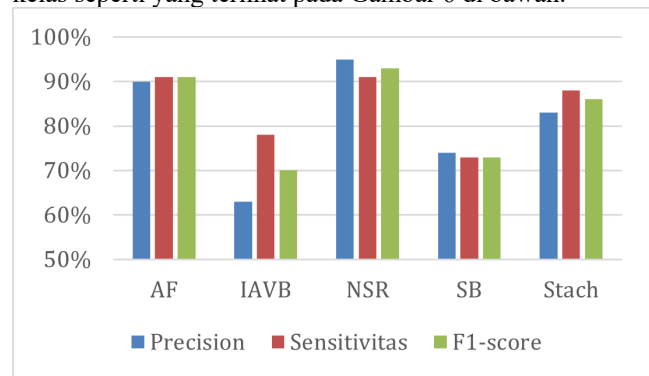
Hasil *classification report* skenario pengujian terbaik dapat dilihat pada Tabel 5 di bawah.

TABEL 5  
NILAI METRIK SKENARIO 70:20:10

Kelas	Precision	Sensitivitas	F1-score	Support
AF	90%	91%	91%	629
IAVB	63%	78%	70%	476

NSR	95%	91%	93%	3965
SB	74%	73%	73%	418
STach	83%	88%	86%	413
Macro avg	81%	84%	83%	5964
Weighted avg	89%	89%	89%	5964

Model klasifikasi ini diuji pada 5.964 sampel dengan 5 kelas aritmia. Secara keseluruhan, model mencatat performa yang baik. Namun dalam dataset yang tidak seimbang, akurasi tidak mencerminkan performa keseluruhan model. Jika dilihat lebih lanjut, semua metrik *weighted avg* memiliki nilai yang lebih besar dibanding metrik *macro avg*. Perbedaan ini mengindikasikan adanya ketidakseimbangan performa antar kelas seperti yang terlihat pada Gambar 6 di bawah.



Gbr. 6 Diagram Batang Performa Skenario 70:20:10

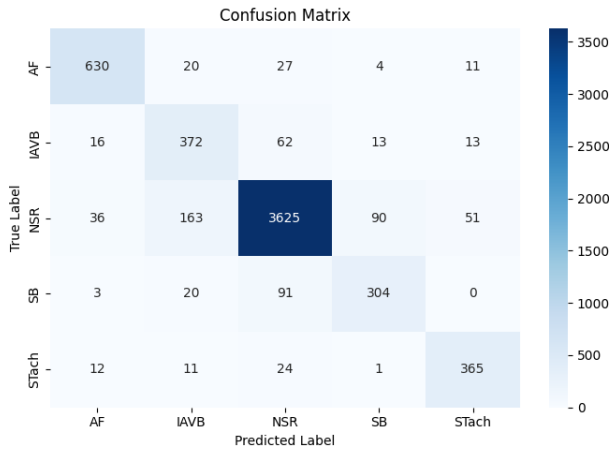
Kelas NSR dan AF mencatat performa terbaik dengan F1-score masing-masing 93% dan 91%. NSR diuntungkan oleh dominasi data (66,5% sampel uji), sementara AF mudah dikenali berkat karakteristik khasnya yaitu ritme ireguler dan absennya gelombang P yang jelas.

Sebaliknya, IAVB mencatat performa terburuk (F1-score 70%) dengan *precision* hanya 63%, mengindikasikan model cenderung overdiagnosis terhadap kelas ini. SB juga terbatas dengan F1-score 73% yang seimbang antara *precision* dan sensitivitas, menunjukkan kesulitan yang merata dalam mengenali kelas tersebut. Kedua kelas ini berbagi akar masalah yang sama, yaitu morfologi sinyal yang sangat mirip dengan NSR, sehingga batas keputusan antar kelas sulit dipelajari model.

STach berada di tengah dengan F1-score 86%, di mana sensitivitas (88%) lebih tinggi dari *precision* (83%) yang mengindikasikan model cukup sensitif mendeteksi STach namun masih salah mengklasifikasikan sebagian sampel kelas lain sebagai STach.

##### D. Analisis Confusion Matrix

Hasil *confusion matrix* skenario pengujian terbaik dapat dilihat pada Gambar 10 di bawah.



Gbr. 7 Confusion Matrix Skenario 70:20:10

*Confusion matrix* pada Gambar 7 di atas menunjukkan satu pola dominan di mana hampir semua kesalahan klasifikasi tertuju ke NSR. Kelas IAVB, SB, dan STach secara konsisten salah diprediksi sebagai NSR, yang mencerminkan tumpang tindih morfologi sinyal sekaligus keterbatasan data sintetis hasil *hybrid sampling* dalam merepresentasikan variasi antar kelas.

Pada kelas AF, model sangat jarang salah mengklasifikasikan kelas lain sebagai AF (FP rendah), namun 27 dari 62 sampel AF yang tidak terdeteksi salah diprediksi sebagai NSR. Kondisi ini perlu mendapat perhatian klinis karena AF yang terlewat meningkatkan risiko stroke [43].

Pola kesalahan IAVB paling besar secara absolut dengan 214 *false positive* dan 62 *false negative* ke NSR, konsisten dengan rendahnya *precision* pada *classification report*. Hal ini mengindikasikan model belum mampu mengenali perpanjangan interval PR sebagai penanda IAVB secara konsisten. Serupa dengan IAVB, SB hampir seluruh kesalahannya (91 dari 114 FN) mengarah ke NSR karena secara fisiologis perbedaan SB dan NSR hanya terletak pada frekuensi denyut, bukan morfologi gelombang.

STach justru menunjukkan performa yang relatif baik di *confusion matrix* dengan spesifisitas 98,7%, meski sebagian kecil *sampelnya* salah diprediksi sebagai NSR (24 sampel) dan AF (12 sampel) di rentang frekuensi perbatasan.

#### E. Perbandingan dengan Model Baseline

Untuk mengevaluasi kontribusi komponen PatchTST, model CNN-PatchTST dibandingkan dengan CNN *standalone*. Hasil perbandingan keduanya pada skenario 70:20:10 ditampilkan pada Tabel 6 di bawah.

TABEL 6  
PERBANDINGAN PERFORMA CNN DAN CNN-PATCHTST

Model	Akurasi	Sensitivitas	Spesifisitas	F1-score
CNN	85,8%	81,7%	95,6%	78,2%
CNN-PatchTST	88,8%	84,3%	96,3%	82,5%

CNN-PatchTST mengungguli CNN *standalone* di seluruh metrik evaluasi. Peningkatan paling signifikan terlihat pada F1-score makro yang naik 4,3 poin persentase (dari 78,2% menjadi 82,5%), diikuti sensitivitas makro yang meningkat 2,6 poin (dari 81,7% menjadi 84,3%). Peningkatan pada F1-score yang lebih besar dibanding akurasi mengindikasikan bahwa PatchTST memberikan manfaat yang lebih merata di seluruh kelas, termasuk kelas-kelas minoritas yang sulit seperti IAVB dan SB. Hal ini konsisten dengan kemampuan PatchTST dalam menangkap dependensi temporal jangka panjang melalui mekanisme *self-attention*, yang memungkinkan model untuk membedakan pola ritme antar kelas secara lebih efektif dibanding CNN yang hanya mengandalkan fitur morfologi lokal.

## V. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, didapatkan beberapa kesimpulan sebagai berikut:

- Model PatchTST terbukti dapat diaplikasikan untuk mengklasifikasikan aritmia dengan performa mencapai akurasi 88,8%, sensitivitas makro 84,3%, spesifisitas makro 96,3%, dan F1-score makro 82,5%. Hasil ini menunjukkan bahwa mekanisme *patching* pada PatchTST mampu menangkap pola morfologi temporal dari sinyal EKG yang relevan untuk membedakan antar kelas aritmia.
- Kelas NSR dan AF memiliki performa terbaik dengan masing-masing f1-score 93% dan 91%. Hal ini menunjukkan model berhasil menebak AF dengan baik berkat karakteristik yang jelas yaitu ritme yang tidak teratur dan absennya gelombang P. Sedangkan model berhasil menebak NSR dengan baik berkat jumlah data yang banyak sehingga model terlatih mendeteksi NSR dengan baik.
- Kelas SB dan IAVB memiliki performa terburuk dengan masing-masing f1-score 73% dan 70%. Jika dilihat dari *confusion matrix*, kelas SB dan IAVB banyak melakukan misklasifikasi NSR. Ini menunjukkan bahwa model kesulitan membedakan SB dengan NSR karena perbedaan denyut heart rate yang tipis. Model juga kesulitan membedakan IAVB dengan NSR karena karakteristik IAVB yaitu perpanjangan interval PR yang tidak terlalu kentara.

## UCAPAN TERIMA KASIH

Terima kasih disampaikan kepada seluruh pihak yang terlibat dalam penelitian dan penyusunan artikel ilmiah ini. Ucapan terima kasih juga disampaikan kepada teman-teman yang sudah memberikan dukungan selama pengerjaan penelitian ini.

## REFERENSI

- [1] "Cardiovascular diseases (CVDs)." Diakses: 2 Oktober 2025. [Daring]. Tersedia pada: [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))
- [2] "Cardiovascular diseases." Diakses: 2 Oktober 2025. [Daring]. Tersedia pada: [https://www.who.int/health-topics/cardiovascular-diseases#tab=tab\\_1](https://www.who.int/health-topics/cardiovascular-diseases#tab=tab_1)

- [3] N. Arsani, N. Wahyuni, N. N. M. Agustini, dan M. Budiawan, "Deteksi Dini dan Pencegahan Penyakit Kardiovaskular," *Proceeding Senadimas Undiksha*, vol. 1, no. 1, hlm. 663–668, 2022.
- [4] N. T. Srinivasan dan R. J. Schilling, "Sudden Cardiac Death and Arrhythmias," *Arrhythm. Electrophysiol. Rev.*, vol. 7, no. 2, hlm. 111, 2018, doi: 10.15420/AER.2018:15:2.
- [5] "Indonesian Heart Rhythm Society |." Diakses: 12 Januari 2026. [Daring]. Tersedia pada: <https://inahrs.or.id/news/satu-dekade-inahrs-an-overview-and-outlook>
- [6] S. Agrawal dan A. Gupta, "Fractal and EMD based removal of baseline wander and powerline interference from ECG signals," *Comput. Biol. Med.*, vol. 43, no. 11, hlm. 1889–1899, Nov 2013, doi: 10.1016/J.COMPBIOMED.2013.07.030.
- [7] G. A. L. Silva, P. H. L. Silva, G. J. P. Moreira, L. S. Freitas, J. C. Gertrudes, dan E. J. S. Luz, "A SYSTEMATIC REVIEW OF ECG ARRHYTHMIA CLASSIFICATION: ADHERENCE TO STANDARDS, FAIR EVALUATION, AND EMBEDDED FEASIBILITY".
- [8] S. Śmigiel, K. Pałczyński, dan D. Ledziński, "ECG Signal Classification Using Deep Learning Techniques Based on the PTB-XL Dataset," *Entropy* 2021, Vol. 23, Part 1121, vol. 23, no. 9, hlm. 1121, Agu 2021, doi: 10.3390/E23091121.
- [9] D. Kim dkk., "A novel hybrid CNN-transformer model for arrhythmia detection without R-peak identification using stockwell transform," *Scientific Reports* 2025 15:1, vol. 15, no. 1, hlm. 7817-, Mar 2025, doi: 10.1038/s41598-025-92582-9.
- [10] Y. Ansari, O. Mourad, K. Qaraq, dan E. Serpedin, "Deep learning for ECG Arrhythmia detection and classification: an overview of progress for period 2017–2023," *Front. Physiol.*, vol. 14, hlm. 1246746, Sep 2023, doi: 10.3389/FPHYS.2023.1246746/FULL.
- [11] Y. Nie, N. H. Nguyen, P. Sinthong, dan J. Kalagnanam, "A Time Series is Worth 64 Words: Long-term Forecasting with Transformers," 11th International Conference on Learning Representations, ICLR 2023, Nov 2022, Diakses: 4 Mei 2026. [Daring]. Tersedia pada: <https://arxiv.org/pdf/2211.14730>
- [12] "Kardiovaskular (Pengertian, Sebab, dan Contoh Penyakit)." Diakses: 9 Januari 2026. [Daring]. Tersedia pada: <https://labcito.co.id/kardiovaskular-pengertian-sebab-dan-contoh-penyakit/>
- [13] A. Handayani, D. Kardiologi, dan K. Vaskular, "Sistem Konduksi Jantung," *Buletin Farmatera*, vol. 2, no. 3, hlm. 116–123, Okt 2017, doi: 10.30596/BF.V2I3.1197.G1269.
- [14] "Elektrokardiogram (EKG) - Gejala, Penyebab, dan Pengobatan." Diakses: 9 Januari 2026. [Daring]. Tersedia pada: <https://www.halodoc.com/kesehatan/elektrokardiogram-ekg>
- [15] "048 How to Read an Electrocardiogram (ECG/EKG) | Interactive Biology, with Leslie Samuel." Diakses: 9 Januari 2026. [Daring]. Tersedia pada: <https://interactivebiology.com/2265/048-how-to-read-an-electrocardiogram-ecgek/>
- [16] F. D. Ratnasari, B. Y. D. Mandicky, Y. S. Kartika, dan M. E. Ferisa, "ANALISIS DETAK JANTUNG ABNORMAL MENGGUNAKAN FAST FOURIER TRANSFORM (FFT) PADA DATA EKG PTB DENGAN IMPLEMENTASI PYTHON," *Kohesi: Jurnal Sains dan Teknologi*, vol. 8, no. 1, hlm. 51–60, Mei 2025, doi: 10.2238/NA68DP86.
- [17] G. A. Andika, A. Sukohar, dan A. Yonata, "Management of Arrhythmia: Atrial Fibrillation," *Medical Profession Journal of Lampung*, vol. 11, no. 3, hlm. 247–252, Okt 2021, doi: 10.53089/MEDULA.V11I3.309.
- [18] Y. Yuniadi, "Mengatasi aritmia, mencegah kematian mendadak," *eJournal Kedokteran Indonesia*, vol. 5, no. 3, hlm. 46–139, 2017, Diakses: 10 Oktober 2025. [Daring]. Tersedia pada: <https://www.academia.edu/download/58317794/227864-mengatasi-aritmia-mencegah-kematian-mend-c9ba84c4.pdf>
- [19] "Inilah Jenis-Jenis Aritmia yang Perlu Diketahui." Diakses: 17 Desember 2025. [Daring]. Tersedia pada: <https://www.halodoc.com/artikel/inilah-jenis-jenis-aritmia-yang-perlu-diketahui>
- [20] "Arrhythmias - Types | NHLBI, NIH." Diakses: 17 Desember 2025. [Daring]. Tersedia pada: <https://www.nhlbi.nih.gov/health/arrhythmias/types>
- [21] "Types of Arrhythmia | Stanford Health Care." Diakses: 17 Desember 2025. [Daring]. Tersedia pada: <https://stanfordhealthcare.org/medical-conditions/blood-heart-circulation/arrhythmia/types.html>
- [22] "Atrial Fibrillation - What Is Atrial Fibrillation? | NHLBI, NIH." Diakses: 18 Desember 2025. [Daring]. Tersedia pada: <https://www.nhlbi.nih.gov/health/atrial-fibrillation>
- [23] "Atrioventricular Block - Gejala, Penyebab, dan Pengobatan -." Diakses: 18 Desember 2025. [Daring]. Tersedia pada: <https://www.alodokter.com/atrioventricular-block>
- [24] I. Ahmed, A. Goyal, dan L. Chhabra, "Atrioventricular Block," *StatPearls*, Feb 2024, Diakses: 18 Desember 2025. [Daring]. Tersedia pada: <https://www.ncbi.nlm.nih.gov/books/NBK459147/>
- [25] G. Lenis, N. Pilia, A. Loewe, W. H. W. Schulze, dan O. Dössel, "Comparison of Baseline Wander Removal Techniques considering the Preservation of ST Changes in the Ischemic ECG: A Simulation Study," *Comput. Math. Methods Med.*, vol. 2017, hlm. 9295029, 2017, doi: 10.1155/2017/9295029.
- [26] I. Ahmad, "Power Line Noise Reduction in Ecg by Butterworth Notch Filters: A Comparative Study," 1 Januari 2013. Diakses: 17 April 2026. [Daring]. Tersedia pada: [https://www.academia.edu/85361154/Power\\_Line\\_Noise\\_Reduction\\_in\\_Ecg\\_by\\_Butterworth\\_Notch\\_Filters\\_A\\_Comparative\\_Study](https://www.academia.edu/85361154/Power_Line_Noise_Reduction_in_Ecg_by_Butterworth_Notch_Filters_A_Comparative_Study)
- [27] "Documentation — NeuroKit 0.0.39 documentation." Diakses: 17 April 2026. [Daring]. Tersedia pada: <https://rpdanderson-neurokit2.readthedocs.io/en/latest/index.html>
- [28] A. Fauzihan, B. Sajiwo, B. Rahmat, dan A. Junaidi, "KLASIFIKASI INDEKS STANDAR PEMERANAN UDARAN (ISPU) MENGGUNAKAN ALGORITMA XGBOOST DENGAN TEKNIK IMBALANCED DATA (SMOTE)," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 3, hlm. 2830–7062, Agu 2024, doi: 10.23960/JITAP.V12I3.4699.
- [29] M. S. Kraiem, F. Sánchez-Hernández, dan M. N. Moreno-García, "Selecting the Suitable Resampling Strategy for Imbalanced Data Classification Regarding Dataset Properties. An Approach Based on Association Models," *Applied Sciences* 2021, Vol. 11, Page 8546, vol. 11, no. 18, hlm. 8546, Sep 2021, doi: 10.3390/APP11188546.
- [30] T. Hasanin, T. M. Khoshgofaar, J. L. Leevy, dan R. A. Bauder, "Severely imbalanced Big Data challenges: investigating data sampling approaches," *J. Big Data*, vol. 6, no. 1, hlm. 107-, Des 2019, doi: 10.1186/S40537-019-0274-4/FIGURES/3.
- [31] P. A. Nugroho, I. Fenriana, dan R. Arijanto, "IMPLEMENTASI DEEP LEARNING MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) PADA EKSPRESI MANUSIA," *ALGOR*, vol. 2, no. 1, hlm. 12–20, Nov 2020, Diakses: 10 Januari 2026. [Daring]. Tersedia pada: <https://jurnal.ubd.ac.id/index.php/algorg/article/view/441>
- [32] "Apa itu Convolutional Neural Network? | IBM." Diakses: 10 Januari 2026. [Daring]. Tersedia pada: <https://www.ibm.com/id-id/think/topics/convolutional-neural-networks>
- [33] F. S. Pakpahan, M. M. Al Haromainy, dan B. M. Mulyo, "CNN Implementation for Instrumental Songs Classification Using Audio Feature," *bit-Tech*, vol. 8, no. 3, hlm. 3288–3298, Apr 2026, doi: 10.32877/BT.V8I3.3438.
- [34] A. Penelitian, E. Y. Hidayat, dan D. Handayani, "Penerapan 1D-CNN untuk Analisis Sentimen Ulasan Produk Kosmetik Berdasar Female Daily Review," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 8, no. 3, hlm. 153–163, Jan 2022, doi: 10.25077/TEKNOSI.V8I3.2022.153-163.
- [35] L. Xiaolin, B. Cardiff, dan D. John, "A 1D Convolutional Neural Network for Heartbeat Classification from Single Lead ECG," *ICECS 2020 - 27th IEEE International Conference on Electronics, Circuits and Systems, Proceedings*, Nov 2020, doi: 10.1109/ICECS49266.2020.9294838.
- [36] Y. Nie, N. H. Nguyen, P. Sinthong, dan J. Kalagnanam, "A TIME SERIES IS WORTH 64 WORDS: LONG-TERM FORECASTING WITH TRANSFORMERS".

- [37] "St Petersburg INCART 12-lead Arrhythmia Database." Diakses: 27 Juni 2026. [Daring]. Tersedia pada: <https://www.kaggle.com/datasets/physionet/st-petersburg-incart-12lead-arrhythmia-database>
- [38] "PTB Diagnostic ECG Database." Diakses: 27 Juni 2026. [Daring]. Tersedia pada: <https://www.kaggle.com/datasets/physionet/ptb-diagnostic-ecg-database>
- [39] "Georgia 12-Lead ECG Challenge Database." Diakses: 27 Juni 2026. [Daring]. Tersedia pada: <https://www.kaggle.com/datasets/physionet/georgia-12lead-ecg-challenge-database>
- [40] "China Physiological Signal Challenge in 2018." Diakses: 27 Juni 2026. [Daring]. Tersedia pada: <https://www.kaggle.com/datasets/physionet/china-physiological-signal-challenge-in-2018>
- [41] "China 12-Lead ECG Challenge Database." Diakses: 27 Juni 2026. [Daring]. Tersedia pada: <https://www.kaggle.com/datasets/physionet/china-12lead-ecg-challenge-database>
- [42] "PTB-XL electrocardiography Database." Diakses: 27 Juni 2026. [Daring]. Tersedia pada: <https://www.kaggle.com/datasets/physionet/ptbxl-electrocardiography-database>
- [43] S. E. Choi, D. Sagris, A. Hill, G. Y. H. Lip, dan A. H. Abdul-Rahim, "Atrial fibrillation and stroke," *Expert Rev. Cardiovasc. Ther.*, vol. 21, no. 1, hlm. 35–56, Jan 2023, doi: 10.1080/14779072.2023.2160319.