



## Model CNN-LSTM Untuk Klasifikasi Tingkat Stres Mahasiswa Dalam Menghadapi Ujian Menggunakan Data Elektrokardiogram (EKG)

Amir Mahmud Husein<sup>1</sup>, Lenny Haifa Muntaza<sup>1\*</sup>, Grescilya Sinaga<sup>1</sup>, Khoirulliza<sup>1</sup>, Maychilia Lamerossa Br Sembiring<sup>1</sup>

<sup>1</sup>Program Studi Teknik Informatika, Universitas Prima Indonesia, Indonesia.

### Artikel Info

#### Kata Kunci:

Convolutional Neural Network;  
Elektrokardiogram;  
Long Short-Term Memory;  
Stres.

#### Keywords:

Convolutional Neural Network;  
Electrocardiogram;  
Long Short-Term Memory;  
Stress;

### Riwayat Artikel:

Submitted: 28 Februari 2025

Accepted: 30 Maret 2025

Published: 31 Maret 2025

**Abstrak:** Penelitian ini bertujuan untuk mengklasifikasikan tingkat stres mahasiswa saat menghadapi ujian menggunakan model Convolutional Neural Network (CNN) yang dikombinasikan dengan Long Short-Term Memory (LSTM). Data yang digunakan berupa sinyal Elektrokardiogram (EKG) dari 300 partisipan yang dikumpulkan sebelum dan sesudah ujian. Untuk meningkatkan kualitas data, diterapkan teknik balancing data menggunakan Synthetic Minority Over-sampling Technique (SMOTE) guna mengatasi ketidakseimbangan kelas. Selain itu, augmentasi data dilakukan dengan menambahkan noise kecil untuk memperkaya variasi data dan mencegah overfitting. Hipotesis penelitian ini menyatakan bahwa kombinasi CNN-LSTM, dengan tambahan balancing data dan augmentasi, dapat meningkatkan akurasi klasifikasi tingkat stres berdasarkan perubahan pola sinyal EKG dibandingkan metode konvensional. Arsitektur ini dipilih karena CNN mampu mengekstraksi fitur spasial, sedangkan LSTM menangkap pola temporal dari data sekuensial. Tahapan penelitian mencakup preprocessing data (normalisasi numerik, one-hot encoding, balancing dataset, dan augmentasi), serta pelatihan model selama 79 epoch dengan ukuran batch 16. Model yang dikembangkan mencapai akurasi validasi awal 83,33%, meningkat hingga 98,80%, dengan nilai loss 0,0653, menunjukkan efektivitasnya dalam mengidentifikasi tingkat stres mahasiswa. Namun, penelitian ini memiliki keterbatasan, seperti bias distribusi demografis dan tantangan pemrosesan sinyal EKG yang rentan terhadap noise. Studi lebih lanjut diperlukan untuk mengoptimalkan teknik balancing dan augmentasi serta mempertimbangkan faktor psikologis dan lingkungan eksternal.

**Abstract:** This study aims to classify students' stress levels during exams using a Convolutional Neural Network (CNN) combined with Long Short-Term Memory (LSTM). The data consists of Electrocardiogram (EKG) signals collected from 300 participants before and after exams. To improve data quality, the Synthetic Minority Over-sampling Technique (SMOTE) was applied to address class imbalance. Additionally, data augmentation was performed by adding small noise to enrich data variation and prevent overfitting. The study hypothesizes that the CNN-LSTM combination, along with data balancing and augmentation, can enhance stress level classification accuracy based on changes in EKG signal patterns compared to conventional methods. This architecture was chosen because CNN effectively extracts spatial features, while LSTM captures temporal patterns in sequential data. The research stages include data preprocessing (numerical normalization, one-hot encoding, dataset balancing, and augmentation), followed by model training for 79 epochs with a batch size of 16. The developed model achieved an initial validation accuracy of 83.33%, which increased to 98.80%, with a loss value of 0.0653, demonstrating its effectiveness in identifying student stress levels. However, this study has limitations, such as demographic distribution bias and challenges in processing EKG signals, which are susceptible to noise. Further research is

---

*needed to optimize balancing and augmentation techniques and consider psychological and external environmental factors.*

---

**Corresponding Author:**

Lenny Haifa Muntaza

Email: lennyhaifamutaza@gmail.com

---

## PENDAHULUAN

Stres adalah suatu kondisi yang dinamis saat seorang individu dihadapkan pada peluang, tuntutan, atau sumber daya yang terkait dengan apa yang dihasratkan dan dianggap penting oleh individu tersebut (Suharsono & Anwar, 2020). Dalam konteks akademik, stres merujuk pada perasaan tekanan yang dialami mahasiswa yang ditandai dengan berbagai reaksi fisik dan emosional karena tuntutan perkuliahan (Djoar et al., 2024). Stres akademik ini dapat meningkat, terutama menjelang ujian. Hal ini dapat mengganggu dan menimbulkan dampak negatif pada mahasiswa dalam menghadapi ujian seperti frustrasi, menurunnya konsentrasi dan tidak percaya diri sehingga mengakibatkan tidak lulus ujian (Hastuti et al., 2024). Oleh karena itu, penting untuk mengidentifikasi serta melakukan klasifikasi tingkat stres mahasiswa secara objektif, terutama dalam menghadapi ujian. Salah satu metode yang berinovatif adalah melalui pengukuran fisiologis menggunakan elektrokardiogram (EKG). EKG menyediakan data mentah dengan aktivitas listrik jantung yang kemudian digunakan untuk menghitung interval antar detak jantung yang memungkinkan perhitungan variabilitas detak jantung (HRV) (Baihaqi, 2020). Sebagai analisis variasi interval detak jantung yang mencerminkan aktivitas sistem saraf otonom, HRV yang dihitung dari data EKG, bersama dengan perubahan detak jantung dapat digunakan sebagai indikator fisiologis tingkat stres.

Data EKG dan HRV memberikan dasar untuk memahami respons fisiologis terhadap stres. Namun, untuk mengklasifikasikan tingkat stres secara efektif diperlukan algoritma yang tepat. Penelitian (Kang et al., 2021) mengadaptasi model ensemble CNN-LSTM untuk klasifikasi stres mental menggunakan sinyal EKG, dengan proses pre-processing yang melibatkan Fast Fourier Transform (FFT) dan spektrogram untuk meningkatkan akurasi, evaluasi kerja yang komprehensif menggunakan Confusion Matrices, Receiver Operating Characteristic (ROC) dan Precision Recall (PR) hingga mencapai akurasi 98,3%. Penelitian yang dilakukan oleh (Roopa et al., 2024) dengan memanfaatkan metode jaringan saraf dalam deep neural network. Hasilnya yang didapatkan mencapai akurasi 92%. Penelitian (Seo et al., 2019) mengusulkan jaringan Deep ECG-Respiration Network (DeepER Net) menghasilkan akurasi rata-rata 89,9%, F1 score 0,81 dan AUC 0,92. Penelitian (Ghosh et al., 2022) mengusulkan metode deteksi stres mental menggunakan jaringan saraf dalam berbasis pengkodean gambar, dengan mengubah data waktu multivariat menjadi gambar Gramian Angular Field (GAF) yang menghasilkan akurasi pengujian mencapai 94,8% dan 99,39%. Sedangkan penelitian (Hafidh et al., 2023) menggunakan metode K-Nearest Neighbours pada sistem deteksi stress mencapai akurasi hingga 70% dan 64,29%.

Berdasarkan hasil penelitian sebelumnya yang telah mengeksplorasi berbagai pendekatan untuk klasifikasi tingkat stres, penelitian ini mengadopsi arsitektur Convolutional Neural Networks (CNN) yang dikombinasikan dengan Long Short-Term Memory (LSTM). Penggunaan CNN dapat memudahkan pembuatan model jaringan syaraf tiruan dan implementasi Deep Learning (Fadlila Rachman et al., 2024). Sedangkan penggunaan LSTM dapat diaplikasikan pada berbagai domain dalam Natural Language Processing (NLP), yang memungkinkan untuk mempelajari ketergantungan jangka panjang dalam kasus long-term dependencies (Damayanti et al., 2024). Terutama dalam analisis data EKG, pemilihan CNN dalam ekstraksi fitur karena dapat mengekstraksi fitur yang sangat kompleks dari sinyal EKG sehingga dapat mencegah kehilangan informasi-informasi penting pada dataset (Julia Nurriski, n.d.). Sedangkan penggunaan model berbasis LSTM merupakan salah satu jenis arsitektur

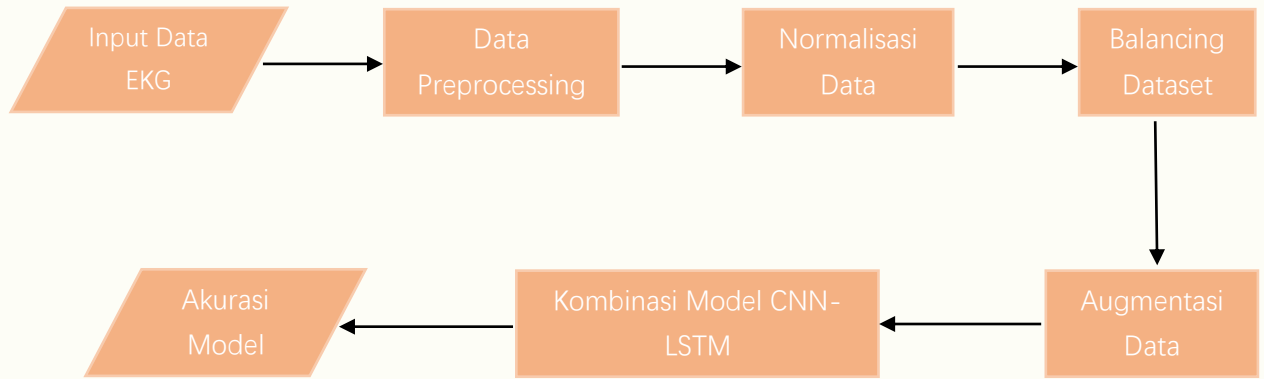
jaringan saraf tiruan yang mampu menangani data berurutan dengan baik, sehingga sangat cocok untuk pemantauan dan prediksi detak jantung yang bersifat sekuensial (Foresta et al., 2024).

Model CNN-LSTM memiliki keunggulan signifikan dalam mengenali pola spasial dan temporal pada data EKG, menjadikannya lebih efektif untuk menganalisis sinyal biologis berurutan. Jika dibandingkan dengan metode seperti K-Nearest Neighbors (KNN) yang hanya mengukur jarak antar data tanpa mempertimbangkan urutan waktu atau pola berkelanjutan, CNN-LSTM jauh lebih unggul dalam menangkap fluktuasi stres yang terekam dalam sinyal EKG. CNN mengekstraksi fitur penting dari sinyal EKG, termasuk pola halus yang sering terabaikan oleh metode lain, sedangkan LSTM mampu mendeteksi perubahan detak jantung akibat stres secara bertahap. Dengan akurasi validasi mencapai 98,80%, CNN-LSTM jauh lebih unggul dibandingkan KNN yang hanya mencapai akurasi 64,29% hingga 70%. Namun demikian, model ini memiliki keterbatasan seperti kompleksitas tinggi yang membutuhkan daya komputasi besar serta waktu pelatihan lebih lama. Selain itu, meskipun akurasinya tinggi, potensi kesalahan dalam klasifikasi tingkat stres dengan karakteristik mirip masih ada.

Penelitian sebelumnya tentang klasifikasi tingkat stres seringkali hanya berfokus pada data EKG. Namun, penelitian ini berpendapat bahwa faktor-faktor lain seperti usia, jenis kelamin, Indeks Prestasi Kumulatif (IPK), pembelajaran teori maupun praktikum, finansial, status sosial yang direpresentasikan oleh kondisi tempat tinggal seperti tinggal bersama orang tua ataupun tinggal di kos, dan status pekerjaan dapat berperan penting dalam mempengaruhi tingkat stress seseorang. Usia yang berdampak pada stres terkait penyesuaian diri dengan lingkungan kampus dan peningkatan tanggung jawab akademik maupun pribadi (Abdullah et al., 2024). Jenis kelamin menjadi salah satu faktor pengaruh stress terhadap mahasiswa di mana perempuan cenderung mengalami tingkat stres yang lebih tinggi dibandingkan laki-laki (Sitepu et al., 2024). Indeks Prestasi Kumulatif (IPK) merupakan indikator penting dalam dunia akademik yang mana IPK rendah serta tuntutan untuk mempertahankan nilai tinggi dapat memicu stress (Saptarina et al., n.d.). Pengaruh mata kuliah teori maupun praktikum juga menjadi salah satu faktor pemicu tingkat stres mahasiswa yang masing-masing memberikan tekanan tersendiri (Permana et al., n.d.). Keterbatasan finansial menjadi sumber stres yang signifikan bagi banyak mahasiswa (Bayantari et al., 2022). Status sosial yang direpresentasikan oleh kondisi tempat tinggal, dengan tinggal bersama orang tua memberikan dukungan emosional sementara tinggal di kos menuntut kemandirian (Timothy, 2019). Status pekerjaan yang menambah beban stres akibat kewajiban ganda antara bekerja dan belajar (Indriyani & Handayani, 2018). Oleh karena itu, penelitian ini diharapkan mampu membandingkan akurasi dalam pengklasifikasian tingkat stres mahasiswa sebelum dan sesudah ujian dengan kombinasi model CNN-LSTM. Penelitian ini bertujuan untuk mengevaluasi efektivitas model dalam mendeteksi fluktuasi tingkat stres berdasarkan data EKG serta mempertimbangkan faktor-faktor demografis dan sosial yang dapat mempengaruhi hasil klasifikasi. Dengan demikian, diharapkan penelitian ini dapat memberikan kontribusi signifikan dalam pemahaman tentang pengaruh stres akademik terhadap mahasiswa serta menyediakan alat bantu yang lebih akurat untuk identifikasi tingkat stres yang dapat digunakan oleh pihak akademik dalam mendukung kesejahteraan mahasiswa.

## METODE

Metode penelitian yang digunakan dalam penelitian ini adalah Metode Penelitian CNN-LSTM. Tahapan metode ini disajikan pada Gambar 1.

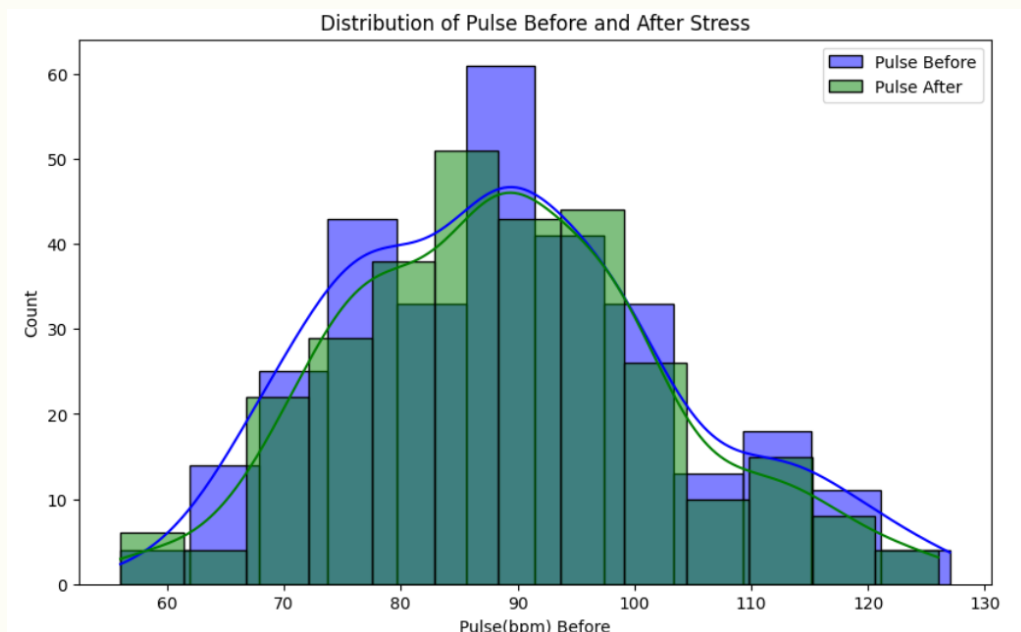


Gambar 1. Metode Penelitian CNN-LSTM pada Tingkat Stres

Tahap awal penelitian ini difokuskan pada pengumpulan data EKG dari 300 partisipan. Data yang dikumpulkan secara langsung mencakup denyut nadi dan informasi demografis serta akademis, seperti usia, jenis kelamin, status sosial ekonomi, metode pembelajaran, dan Indeks Prestasi Kumulatif (IPK). Data denyut nadi dari setiap partisipan direkam selama 2-3 menit baik sebelum maupun sesudah ujian untuk kemudian dikategorikan ke dalam tiga tingkatan stres, yang direpresentasikan dalam bentuk angka, yaitu: ringan, sedang, dan berat.

### Preprocessing

Sebelum data digunakan dalam pelatihan model, serangkaian tahap preprocessing dilakukan untuk memastikan kualitas dan konsistensi data. Tahapan ini mencakup pembersihan dan transformasi data. Pembersihan data menjadi langkah awal, bertujuan menghilangkan inkonsistensi melalui penghapusan data duplikat, penanganan missing values (imputasi rata-rata untuk data numerik, modus untuk data kategorikal), dan filtering outliers (khususnya pada denyut nadi).



Gambar 2. Perbandingan distribusi denyut nadi sebelum dan setelah ujian

Gambar 2 menunjukkan visualisasi perbandingan distribusi denyut nadi sebelum dan setelah ujian dilakukan untuk memberikan pemahaman lebih baik tentang perubahan pola denyut nadi akibat stres, yang menunjukkan peningkatan signifikan denyut nadi setelah mengalami stres. Dataset kemudian dibagi menjadi Data Training dan Data Testing (70% : 30%), dan data latih dipersiapkan dengan penambahan noise untuk augmentasi dan peningkatan performa model.

### Normalisasi Data

Bagian ini menyajikan hasil normalisasi data untuk berbagai fitur (umur, gender, IPK, status pembelajaran, status ekonomi, tempat tinggal, status pekerjaan, denyut jantung sebelum dan sesudah). Normalisasi bertujuan mengubah nilai mentah menjadi skala yang lebih mudah dianalisis dengan menggunakan rumus:

$$\text{Normalized Value} = \frac{(X - \min)}{(\max - \min)}$$

### Balancing Dataset

Dataset awal yang digunakan dalam penelitian ini tidak seimbang, dengan jumlah sampel yang berbeda di setiap kelas. Untuk mengatasi masalah ini, diterapkan teknik SMOTE (Synthetic Minority Over-sampling Technique) yang bertujuan untuk menyeimbangkan jumlah sampel di setiap kelas. Setelah penerapan SMOTE, distribusi kelas menjadi lebih seimbang, sehingga meningkatkan kualitas analisis dan hasil dari model yang akan dibangun.

```
Jumlah data sebelum pembagian: 300
-----
Distribusi kelas sebelum pembagian data:
Low Stress: 84 sampel
Medium Stress: 186 sampel
High Stress: 30 sampel
-----
Distribusi kelas setelah pembagian data:
Train Data:
Low Stress: 59 sampel
Medium Stress: 130 sampel
High Stress: 21 sampel
=====
Test Data:
Low Stress: 25 sampel
Medium Stress: 56 sampel
High Stress: 9 sampel
-----
Distribusi kelas setelah SMOTE:
Low Stress: 130 sampel
Medium Stress: 130 sampel
High Stress: 130 sampel
```

Gambar 3. Hasil Balancing Dataset

### Augmentasi Data

Data augmentasi dilakukan dengan menambahkan noise kecil, dengan faktor noise sebesar 0.05, ke data asli untuk meningkatkan variasi data dan mencegah overfitting. Proses ini tidak hanya memperkaya dataset dengan variasi baru, tetapi juga menggabungkan data asli dan data augmentasi untuk memperluas keseluruhan dataset.

### Kombinasi Model CNN-LSTM


Model Convolutional Neural Network (CNN) - Long Short-Term Memory (LSTM) ini dibangun melalui beberapa lapisan berurutan. Input Layer menerima data 3D dengan dimensi (samples, timesteps, features) yang kemudian direshape menjadi (samples, 1, features) agar kompatibel dengan lapisan Conv1D. Conv1D Layer menggunakan 64 filter berukuran kernel 2 dengan fungsi aktivasi ReLU untuk menambahkan non-linearitas, dilanjutkan Batch Normalization guna menstabilkan distribusi input ke lapisan berikutnya. MaxPooling1D Layer diaplikasikan dengan ukuran pooling 1 dan stride 1 untuk mengurangi dimensi spasial meskipun efeknya minimal pada konfigurasi ini. Selanjutnya, LSTM Layer dengan 64 unit memproses data sekuensial untuk menangkap dependensi temporal. Output



LSTM kemudian diubah menjadi vektor 1D melalui Flatten Layer. Pada Dense Layer, terdapat 32 neuron dengan aktivasi ReLU dan Dropout (rate 0.5) yang berfungsi mengurangi risiko overfitting.

Terakhir, Output Layer menggunakan fungsi aktivasi Softmax untuk menghasilkan distribusi probabilitas kelas, memungkinkan model melakukan klasifikasi multikelas secara efektif. Setiap lapisan dirancang untuk mengoptimalkan ekstraksi fitur spasial-temporal dan generalisasi model. Model ini dikompilasi dengan menggunakan Optimizer Adam dengan learning rate sebesar 0.001, yang dikenal efektif dalam mempercepat konvergensi. Untuk Loss Function, digunakan Categorical Crossentropy, yang sesuai untuk masalah klasifikasi multi-kelas. Sebagai metrik evaluasi, Metrics yang diterapkan adalah akurasi, yang memberikan gambaran jelas tentang kinerja model.

Selain itu, beberapa Callback diterapkan untuk meningkatkan proses pelatihan; Early Stopping digunakan untuk menghentikan pelatihan jika validasi loss tidak menunjukkan perbaikan selama 10 epoch, sementara ReduceLROnPlateau berfungsi untuk mengurangi learning rate jika validasi loss stagnan. Dengan pengaturan ini, model diharapkan dapat belajar secara efisien dan menghindari overfitting. Proses ini dapat dilihat pada Gambar 4.



Gambar 4. Kombinasi Model CNN-LSTM

### Validasi dan Evaluasi

Setelah tahap penggabungan model Convolutional Neural Network (CNN) Long Short-Term Memory (LSTM) selesai, model tersebut dilatih menggunakan data pelatihan yang terdiri dari 210 sampel (70% dari total 300 partisipan). Proses ini diikuti dengan validasi menggunakan 90 sampel dari total data (30% dari 300 partisipan) yang digunakan sebagai testing set.

Data pengujian ini mencakup sinyal EKG yang direkam dari partisipan sebelum dan sesudah ujian. Validasi dilakukan untuk memastikan kemampuan model dalam menggeneralisasi dengan baik pada data baru yang terlihat sebelumnya. Evaluasi dilakukan untuk menilai kinerja model menggunakan metrik seperti akurasi, presisi, recall, dan F1 score. Hasil evaluasi ini memberikan pemahaman yang lebih baik tentang efektivitas kombinasi CNN-LSTM dalam klasifikasi tingkat stress. Dengan penilaian yang komprehensif ini, hasil evaluasi dapat menjadi acuan untuk meningkatkan akurasi klasifikasi dan memperbaiki kualitas model yang dikembangkan.

### HASIL DAN PEMBAHASAN

Dari total data yang ada, 30% digunakan sebagai testing set, yang berarti sebanyak 90 sampel denyut nadi mahasiswa. Evaluasi model dilakukan pada testing set ini untuk menilai kinerja model dalam klasifikasi tingkat stres.

### Data Preprocessing

Pada penelitian ini, tahap pre-processing data terdiri dari Normalisasi numerik dengan Min-Max Scaling untuk denyut nadi, One-hot encoding untuk variabel kategorikal seperti gender dan metode pembelajaran, serta Discretization/binning untuk IPK, tingkat stres, dan status ekonomi yang dikategorikan menjadi rendah, sedang, dan tinggi. Serta Tahap Exploratory Data Analysis (EDA) untuk memahami pola dalam dataset. EDA membantu dalam melihat distribusi data mengidentifikasi hubungan antarvariabel, serta mendeteksi potensi bias atau ketidakseimbangan kelas dalam data.

### Hasil Normalisasi Data Berdasarkan Kategori

Fitur-fitur yang dinormalisasi meliputi: usia menggunakan Min-Max Scaling (17-21 tahun menjadi 0-1), gender dengan One-Hot Encoding (laki-laki = 0, perempuan = 1), IPK dikelompokkan (rendah = 0, sedang = 1, tinggi = 2), metode pembelajaran dengan One-Hot Encoding (teori = 0, praktikum = 1), status ekonomi berdasarkan penghasilan (0-2 juta = 0, 2-4 juta = 1, > 4 juta = 2), status sosial (tinggal dengan keluarga = 0, kos = 1) menggunakan kode biner. Denyut nadi sebelum dan sesudah ujian serta tingkat stres dinormalisasi menggunakan Min-Max Scaling dan dikategorikan (rendah = 0, sedang = 1, tinggi = 2).

Age	Gender	IPK	Learning	Economi	St Social	Statu	Employer	Pulse(bpm)	Pulse(bpm)	Total Stress	Tingkat Stre
19	Female		3,3 Theory	2.000.000	-	Kost	Not Workin	120	112	77	High Stress
19	Female		3,4 Theory	2.000.000	-	Kost	Not Workin	96	95	45	Medium Sti
19	Female		3,5 Theory	2.000.000	-	Kost	Not Workin	93	93	44	Medium Sti
18	Female		3,8 Theory	2.000.000	-	Kost	Not Workin	92	115	59	Medium Sti
19	Female		3,9 Theory	2.000.000	-	Kost	Not Workin	126	120	82	High Stress
19	Female		3,9 Theory	2.000.000	-	Kost	Not Workin	109	101	71	High Stress
19	Female		3,1 Theory	0 - 2.000.00	Kost	Not Workin	96	93	45	Medium Sti	
19	Female		3,1 Theory	0 - 2.000.00	Kost	Not Workin	78	76	38	Low Stress	
18	Female		3,1 Theory	0 - 2.000.00	Kost	Not Workin	71	88	36	Low Stress	
18	Female		3,2 Theory	0 - 2.000.00	Kost	Not Workin	89	85	39	Low Stress	
19	Male		3,8 Theory	0 - 2.000.00	Living At Hc	Not Workin	95	111	60	Medium Sti	
19	Male		3,7 Theory	> 4.000.000	Kost	Not Workin	77	83	40	Low Stress	
19	Female		3,8 Theory	2.000.000	-	Living At Hc	Not Workin	85	83	42	Medium Sti
19	Female		3 Theory	> 4.000.000	Living At Hc	Not Workin	100	115	62	Medium Sti	
19	Female		3,9 Theory	0 - 2.000.00	Kost	Not Workin	114	120	78	High Stress	
19	Female		3,8 Theory	0 - 2.000.00	Kost	Not Workin	98	109	60	Medium Sti	
19	Female		3,8 Theory	0 - 2.000.00	Living At Hc	Not Workin	89	108	58	Medium Sti	
19	Male		3,1 Theory	> 4.000.000	Living At Hc	Not Workin	94	82	43	Medium Sti	
19	Male		3,4 Theory	2.000.000	-	Living At Hc	Not Workin	67	58	26	Low Stress
19	Female		3,6 Theory	2.000.000	-	Kost	Not Workin	91	101	56	Medium Sti
19	Female		3,5 Theory	2.000.000	-	Living At Hc	Not Workin	100	88	45	Medium Sti

Gambar 5. Data Sebelum Dilakukan Normalisasi

Gambar 5 menggambarkan data mentah yang berisi berbagai fitur seperti usia, jenis kelamin, IPK, dan denyut jantung mahasiswa, yang masih dalam bentuk asli dan memerlukan pemrosesan lebih lanjut untuk analisis.

Age	Gender	IPK	Learning	Economic	Social Status	Employment	Category I	Category II	Tingkat Stres
00.05	1	1	0	1	1	0	2	2	2
00.05	1	1	0	1	1	0	1	1	1
00.05	1	1	0	1	1	0	1	1	1
00.25	1	2	0	1	1	0	1	2	1
00.05	1	2	0	1	1	0	2	2	2
00.05	1	2	0	1	1	0	2	2	2
00.05	1	0	0	0	1	0	1	1	1
00.05	1	0	0	0	1	0	0	0	0
00.25	1	0	0	0	1	0	0	1	0
00.25	1	0	0	0	1	0	1	1	0
00.05	0	2	0	0	0	0	1	2	1
00.05	0	2	0	2	1	0	0	1	0
00.05	1	2	0	1	0	0	1	1	1
00.05	1	0	0	2	2	0	2	2	1
00.05	1	2	0	0	1	0	2	2	2
00.05	1	2	0	0	1	0	1	2	1
00.05	1	2	0	0	0	0	1	2	1
00.05	0	0	0	2	0	0	1	1	1
00.05	0	1	0	1	0	0	0	0	0
00.05	1	2	0	1	1	0	1	2	1
00.05	1	1	0	1	0	0	2	1	1

Gambar 6. Data Sesudah Dilakukan Normalisasi

Gambar 6 menunjukkan hasil data setelah proses normalisasi, semua nilai telah disesuaikan ke dalam skala yang konsisten, meningkatkan kejelasan dan efektivitas analisis. Normalisasi ini, yang menggunakan Min-Max Scaling untuk fitur numerik dan One-Hot Encoding untuk variabel kategorikal, sangat penting untuk memastikan bahwa setiap fitur memberikan kontribusi yang seimbang dalam klasifikasi tingkat stres mahasiswa.


### Hasil Pelatihan dan Validasi

Penelitian ini melibatkan proses pelatihan dan validasi model yang dihentikan jika tidak ada perbaikan pada nilai validation loss setelah sejumlah epoch tertentu, menggunakan metode early stopping untuk mencegah overfitting. Model yang digunakan adalah kombinasi Convolutional Neural Network (CNN) dan Long Short Term Memory (LSTM), dirancang untuk mengklasifikasikan tingkat stres mahasiswa selama ujian. Pelatihan dilakukan dengan ukuran batch 16 selama 79 epoch, di mana model mencapai nilai validation loss terbaik pada epoch ke-47.

Tabel 1. Hasil kombinasi model CNN-LSTM pada training set

Model Kombinasi	Training Set		Validation Set	
	Accuracy (%)	Loss	Accuracy (%)	Loss
	CNN-LSTM			
Batch 16	96.13%	0.1045	98.80%	0.0653


Pada titik tersebut, akurasi pelatihan mencapai 96.13%, sedangkan akurasi validasi lebih tinggi, yaitu 98.80%. Nilai training loss tercatat 0.1045, sementara validation loss mencapai 0.0653. Hasil ini menunjukkan bahwa model efektif dalam mempelajari pola data dan memiliki kemampuan generalisasi yang baik, sehingga dapat diandalkan untuk mengidentifikasi tingkat stres mahasiswa dengan akurasi tinggi.



Gambar 7. Training accuracy vs validation accuracy, dan training loss vs validation loss CNN-LSTM dengan batch 16

Selama proses pelatihan, data yang digunakan merupakan kombinasi data latih dan data uji dengan perbandingan 70:30 pembagian ini memastikan model memiliki cukup data untuk belajar (data latih) sambil mempertahankan set data terpisah untuk menguji kinerja model (data uji). Evaluasi terhadap data validasi dilakukan menggunakan confusion matrix, yang mencakup metrik evaluasi seperti akurasi, presisi, recall, dan F1 score.





Gambar 8. Confusion matrix model CNN-LSTM dengan batch 16 dalam klasifikasi tingkat stress (High, Low, Medium)

Berdasarkan hasil confusion matrix pada validation set diatas dapat diketahui bahwa nilai akurasi 79%, presisi 78%, recall 79%, dan F1 score 77%. Hasil tersebut diperoleh melalui penggabungan tiga kategori tingkat stres, yaitu low, medium, dan high, yang dihitung berdasarkan rata-rata dari masing-masing kategori.

Tabel 2. Hasil Confusion Matrix

Kategori	Presisi	Recall	F1 Score	Akurasi	Akurasi keseluruhan
Low	72 %	52 %	60 %	52 %	79 %
Medium	79 %	89 %	84 %	89 %	
High	89 %	89 %	89 %	89 %	

Pada tabel tersebut, kategori Low mencapai presisi 72%, recall 52%, F1 Score 60%, akurasi untuk kategori tersebut 52% dan 79% untuk akurasi keseluruhan, sementara kategori Medium menunjukkan presisi 79% dan recall 89% dengan F1 Score 84% dan akurasi 89%, dan kategori High memiliki presisi 89% dan recall 89% dengan F1 Score 89% dan akurasi 89%, yang menunjukkan bahwa model secara keseluruhan efektif dalam memprediksi kategori dengan akurasi tinggi dan mampu mendeteksi pola data dengan baik.

## KESIMPULAN

Berdasarkan hasil penelitian model CNN-LSTM untuk klasifikasi tingkat stres mahasiswa dalam menghadapi ujian menggunakan data elektrokardiogram (EKG). Model ini dirancang untuk mengklasifikasikan tingkat stres mahasiswa selama ujian. Pelatihan dilakukan dengan ukuran batch 16 selama 79 epoch, di mana model mencapai nilai validation loss terbaik pada epoch ke-47. Pada titik tersebut, akurasi pelatihan mencapai 96.13%, sedangkan akurasi validasi lebih tinggi, yaitu 98.80%. Nilai training loss tercatat 0.1045, sementara validation loss mencapai 0.0653. Hasil ini menunjukkan bahwa model efektif dalam mempelajari pola data dan memiliki kemampuan generalisasi yang baik, sehingga dapat diandalkan untuk mengidentifikasi tingkat stres mahasiswa dengan akurasi tinggi. Model CNN-LSTM memiliki keunggulan dalam menangkap pola temporal dan spasial dalam data EKG. CNN efektif dalam mengekstraksi fitur, sementara LSTM menangani ketergantungan jangka panjang dalam data sekuensial. Namun, model ini masih memiliki potensi kesalahan klasifikasi karena kesamaan karakteristik antara tingkat stres yang berbeda. Penerapan teknik balancing data menggunakan SMOTE berhasil mengatasi ketidakseimbangan kelas dalam dataset, sementara augmentasi data dengan penambahan noise membantu memperkaya variasi data dan mengurangi risiko overfitting. Untuk meningkatkan keandalan model, penelitian lebih lanjut dapat dilakukan dengan menguji teknik balancing dan augmentasi lainnya untuk meningkatkan akurasi klasifikasi.

## DAFTAR PUSTAKA

- Abdullah, A. A. P., Royani, I., Hamzah, P. N., Amir, S. P., & Jaya, M. A. (2024). Hubungan Antara Beban Belajar dengan Tingkat Stres Mahasiswa Fakultas Kedokteran UMI Angkatan 2020. *Fakumi Medical Journal: Jurnal Mahasiswa Kedokteran*, 4(2), 134-140.
- Baihaqi, H. D. (2020). Analisis Heart Rate Variability (Hrv) Antara Elektrokardiogram (Ekg) Dengan Stetoskop Elektronik Littmann 3200. <https://dspace.uui.ac.id/bitstream/handle/123456789/30378/>
- Bayantari, N. M., Indonesiani, S. H., & Apsari, P. I. B. (2022). Regulasi Diri dalam Belajar dan Hubungannya dengan Stres Akademik Pada Mahasiswa Tingkat Pertama Fakultas Kedokteran. *Jurnal Imiah Pendidikan Dan Pembelajaran*, 6(3), 609-618. <https://doi.org/10.23887/jipp.v6i3.51175>
- Damayanti, E., Vitianingsih, A. V., Kacung, S., Suhartoyo, H., & Lidya Maukar, A. (2024). Sentiment Analysis of Alfagift Application User Reviews Using Long Short-Term Memory (LSTM) and Support Vector Machine (SVM) Methods. *Decode: Jurnal Pendidikan Teknologi Informasi*, 4(2), 509-521. <https://doi.org/10.51454/decode.v4i2.478>
- Djoar, R. K., & Anggarani, A. P. M. (2024). Faktor-faktor yang mempengaruhi stress akademik mahasiswa tingkat akhir. *Jambura Health and Sport Journal*, 6(1), 52-59. <https://doi.org/10.37311/jhsj.v6i1.24064>
- Ghosh, S., Kim, S., Ijaz, M. F., Singh, P. K., & Mahmud, M. (2022). Classification of mental stress from wearable physiological sensors using image-encoding-based deep neural network. *Biosensors*, 12(12), 1153. <https://doi.org/10.3390/bios12121153>
- Hastuti, E. A., Widiyanti, E., Siagian, I. M., & Septriyani, D. (2024). Self-Management Dengan Tingkat Stres Pada Mahasiswa Dalam Menghadapi Ujian Objective Structured Clinical Examination (OSCE). *Jurnal Keperawatan' Aisyiyah*, 11(1), 61-68. <https://doi.org/10.33867/sm58ry57>
- Indriyani, S., & Handayani, N. S. (2018). Stres Akademik Dan Motivasi Berprestasi Pada Mahasiswa Yang Bekerja Sambil Kuliah. *Jurnal Psikologi*, 11(2), 153-160. <https://doi.org/10.35760/psi.2018.v11i2.2260>
- Kang, M., Shin, S., Jung, J., & Kim, Y. T. (2021). Classification of mental stress using CNN-LSTM algorithms with electrocardiogram signals. *Journal of Healthcare Engineering*, 2021(1), 9951905. <https://doi.org/10.1155/2021/9951905>
- Maulana, M. H. W., & Widasari, E. R. (2023). Sistem Deteksi Stres berdasarkan Detak Jantung dan Kelenjar Keringat menggunakan Metode K-Nearest Neighbours. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 7(3), 1108-1115.
- Nurriski, Y. J., & Alamsyah, A. (2023). Optimasi Deep Convolutional Neural Network (Deep CNN) untuk Deteksi Aritmia Melalui Sinyal EKG Menggunakan Arsitektur Conv1D. *Indonesian Journal of Mathematics and Natural Sciences*, 46(1), 10-20. <https://doi.org/10.15294/ijmns.v46i1.46176>
- Permana, A. A., Huang, C., Augustino, J. C., Kurniawan, K., Kurniadi, N., & Novanto, Y. (2024). Analisis Perbedaan Tingkat Stres Akademik Mahasiswa Baru Universitas X di Tangerang. *Jurnal Psikologi: Jurnal Ilmiah Fakultas Psikologi Universitas Yudharta Pasuruan*, 11(2), 357-373.
- Roopa, C. K., Kakaraparthi, I., Suroor, I., Khan, A. A., Shoaib Ahmed, S., & Harish, B. S. (2024). DeepChill: ECG Analysis using Deep Learning for Automatic Stress Recognition. *Procedia Computer Science*, 235, 132-141. <https://doi.org/10.1016/j.procs.2024.04.016>

- Saptarina, D., Nurikhwan, P. W., Santoyo, D. D., Bakhriansyah, M., & Limantara, S. (2023). Hubungan Tingkat Kecemasan Terhadap IPK Mahasiswa PSKPS FK ULM. *Homeostasis*, 6(1), 145-152. <https://doi.org/10.20527/ht.v6i1.8800>
- Seo, W., Kim, N., Kim, S., Lee, C., & Park, S. M. (2019). Deep ECG-respiration network (DeepER net) for recognizing mental stress. *Sensors (Switzerland)*, 19(13). <https://doi.org/10.3390/s19133021>
- Sitepu, E., Juliana Tampubolon, Sudianto Manulang, & Sisti Nadia Amalia. (2024). Analisis Faktor-Faktor yang Berhubungan dengan Kejadian Stres Pada Mahasiswa Tingkat Akhir S1 Matematika di Universitas Negeri Medan. *Statistika*, 24(1), 93–101. <https://doi.org/10.29313/statistika.v24i1.3257>
- Suharsono, Y., & Anwar, Z. (2020). Analisis stress dan penyesuaian diri pada mahasiswa. *Cognicia*, 8(1), 41-53. <https://doi.org/10.22219/cognicia.v8i1.11527>
- Timothy, A. T. (2019). Hubungan Tempat Tinggal Bersama Orang Tua Dan Tidak Bersama Orang Tua Dengan Stres Psikologis Pada Mahasiswa Kedokteran Preklinik Universitas Pelita Harapan.
- Zen, A. F. A., Pramukantoro, E. S., Amron, K., Wardhani, V., & Kamila, P. A. (2024). Prediksi Detak Jantung Berbasis LSTM pada Raspberry Pi untuk Pemantauan Kesehatan Portabel. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 11(5), 1097-1104. <https://doi.org/10.25126/jtiik.2024118015>