

Implementasi *Long Short Term Memory* (LSTM) dalam Deteksi Kantuk pada Pengemudi Menggunakan Sensor Detak Jantung

Inas Afifah, Ade Silvia Handayani*, Suroso

Teknik Telekomunikasi, Politeknik Negeri Sriwijaya, Politeknik Negeri Sriwijaya, Palembang, Indonesia

Email: afifahins1510@gmail.com, adesilviahy@gmail.com, osorus11@gmail.com

Email Penulis Korespondensi: adesilviahy@gmail.com

Submitted: 23/07/2024; Accepted: 13/09/2024; Published: 16/09/2024

Abstrak—Kecelakaan lalu lintas sering disebabkan oleh rasa kantuk atau kelalaian tidur, serta penggunaan alkohol atau obat-obatan. *Microsleep* yaitu mengantuk atau tertidur dalam beberapa detik tanpa disadari oleh pengemudi, adalah kondisi yang berbahaya yang dapat menyebabkan kematian saat mengemudi. Penelitian ini bertujuan untuk mengimplementasikan algoritma *Long Short Term Memory* (LSTM) sebagai peringatan dini *microsleep* pada pengemudi dan mengembangkan alat deteksi kantuk menggunakan *pulse heart rate sensor*. LSTM, dengan kemampuannya dalam memori informasi jarak jauh, telah terbukti unggul dalam prediksi deret waktu dan diaplikasikan dalam analisis data detak jantung pengemudi secara *real-time*. Hasil penelitian menunjukkan bahwa model LSTM yang diimplementasikan memiliki performa yang baik dalam mendeteksi kantuk, dengan nilai MAE sebesar 6.42 pada data *training* dan 6.35 pada data *testing*. RMSE sebesar 8.82 untuk *training* dan 8.33 untuk *testing*. MAPE sebesar 8.87 % pada data *training* dan 8.97% pada data *testing*, serta MSE sebesar 77.80 pada data *training* dan 69.47 pada *testing*. Dengan demikian, algoritma LSTM efektif dalam mendeteksi kantuk pada pengemudi melalui analisis data detak jantung, yang dapat berfungsi sebagai sistem peringatan dini untuk mencegah kecelakaan lalu lintas yang disebabkan oleh *microsleep*.

Kata Kunci: *Microsleep*; Deteksi Kantuk; *Long Short Term Memory* (LSTM); *Pulse Heart Rate Sensor*

Abstract—Traffic accidents are often caused by drowsiness or negligent sleep, as well the use of alcohol or drugs. *Microsleep*, which is drowsiness or falling asleep within a few seconds without the driver realizing it, is a dangerous condition that can lead to death while driving. This research aims to implement the *Long Short Term Memory* (LSTM) algorithm as an early warning of *microsleep* in drivers and develop a drowsiness detection tool using a *pulse heart rate sensor*. LSTM, with its ability to memory long-range information, has proven to be superior in time series prediction and is applied in real-time driver heart rate data analysis. The results show that the implemented LSTM model has good performance in detecting drowsiness, with MAE values of 6.42 in training data and 6.35 in testing data. RMSE of 8.82 for training and 8.33 for testing. MAPE of 8.87% in training data and 8.97% in testing data, and MSE of 77.80 in training data and 69.47 in testing. Thus, the LSTM algorithm is effective in detecting drowsiness in drivers through heart rate data analysis, which can serve as an early warning system to prevent traffic accidents caused by *microsleep*.

Keywords: *Microsleep*; Sleepiness Detection; *Long Short Term Memory* (LSTM); *Pulse Heart Rate Sensor*

1. PENDAHULUAN

Berdasarkan data dari Korps Lalu Lintas Kepolisian Republik Indonesia (Korlantas Polri) pada tahun 2022 disebutkan bahwa jumlah kecelakaan sebanyak 94.617 kasus laka lantas di Indonesia [1]. Penyebab utama kecelakaan lalu lintas, yang sering terjadi ketika mengemudi adanya rasa kantuk, atau karena kelalaian tidur, kurang tidur, penggunaan alkohol atau obat-obatan. Kantuk mengganggu fungsi otak, seperti mengurangi waktu reaksi atau mengambil keputusan[2]. Hasil penelitian Rahmadiyahani dan Widiyanti [3], menunjukkan bahwa sebanyak 32% responden pernah mengalami kecelakaan saat mengemudi dalam keadaan mengantuk.

Microsleep adalah ketika mengantuk atau tertidur dalam beberapa detik [4]. *Microsleep* sering terjadi saat melakukan pekerjaan yang monoton, seperti menatap layar atau saat mengemudi dalam kurun waktu yang lama. Orang yang mengalami *microsleep* tidak akan menyadari bahwa mereka tertidur dan hal ini dapat berbahaya, terutama saat mengemudi [5]. Deteksi *microsleep* menggunakan detak jantung terbukti efektif karena perubahan dalam detak jantung sering kali menunjukkan penurunan kewaspadaan. Salah satu metode yang digunakan yaitu metode LSTM dengan memori informasi jarak jauh memiliki kinerja prediksi yang luar biasa, dan telah banyak digunakan untuk prediksi deret waktu [6].

Penelitian Kiki Dwi Prasetyo, Rifki Wijaya, dan Gia Septiana Wulandari [7], menggunakan metode ARIMA dan LSTM dengan detak jantung dan jumlah langkah sebagai variabel. Dari hasil evaluasi kinerja menunjukkan bahwa model LSTM lebih baik dibandingkan dengan model ARIMA, untuk LSTM nilai MSE sebesar 0,1108 dan RMSE sebesar 0,3329 sedangkan model ARIMA dengan MSE sebesar 0,2397 dan RMSE sebesar 0,4895. Penelitian [8], menggunakan model LSTM untuk deteksi detak jantung dengan tingkat akurasi mencapai 96%.

Teknologi sensor memungkinkan pemantau secara real-time data pengemudi yang dapat membantu mengembangkan alat untuk mendeteksi kantuk pengemudi [9]. Hasil penelitian Yuda Irawan, Yuniar Fernando, Refni Wahyuni [10], menunjukkan bahwa tingkat akurasi *pulse heart rate sensor* sangat tinggi, seperti yang ditunjukkan dengan menghitung presentase nilai akurasi sensor menggunakan rumus.

Di Indonesia, alat peringatan dini untuk pengemudi telah banyak diteliti. Namun, alat ini masih memiliki kelemahan, seperti ukuran yang besar, belum menggunakan *artificial intelligence*, dan memerlukan banyak parameter seperti biometrik, kondisi fisiologis, dan perilaku pengemudi [11]. Penelitian Sang-Ho Jo, Jin-Myung Kim, and Dong Kyoo Kim [12], menunjukkan bahwa detak jantung menurun secara signifikan sebesar 9,3% ketika mengemudi dalam

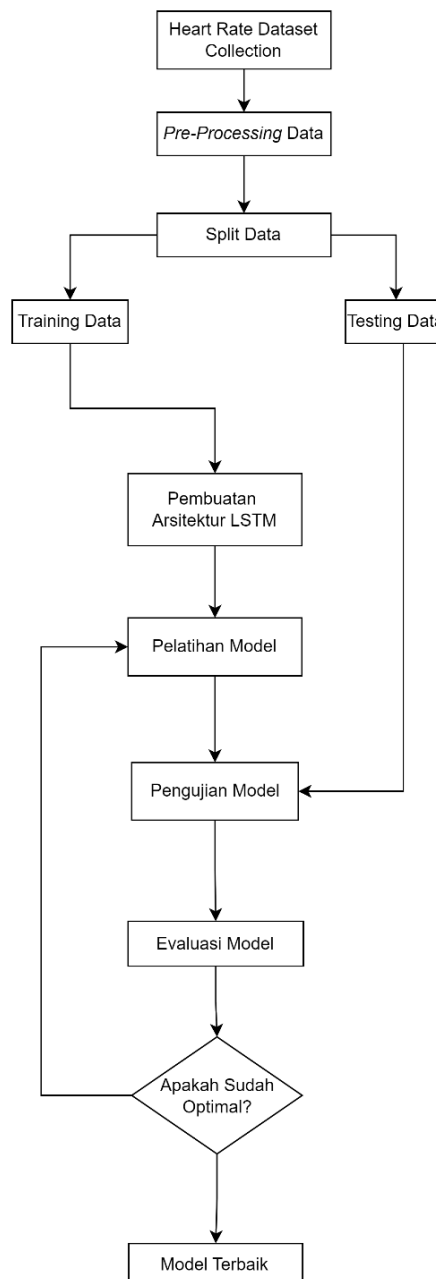
keadaan mengantuk dibandingkan dengan *heart rate* selama mengemudi secara keseluruhan, dan mengalami peningkatan yang tidak signifikan sebesar 7% dibandingkan dengan *heart rate* siang hari. Penurunan *heart rate* ini konsisten dengan penurunan *heart rate* pada tahap awal tidur malam, meskipun perubahan *heart rate* saat mengemudi bervariasi karena aktivitas parasimpatis dan simpatis.

Penelitian ini berfokus pada pengembangan dan implementasi deteksi kantuk berbasis *Long Short Term Memory* (LSTM) menggunakan sensor detak jantung pengemudi. Kemampuan LSTM untuk menangani data berurutan atau sekuensial menjadikannya salah satu arsitektur jaringan saraf tiruan yang paling terkenal [8]. Penerapan LSTM dalam deteksi kantuk pengemudi melalui sensor detak jantung menawarkan solusi inovatif dan efektif untuk mengurangi risiko kecelakaan lalu lintas akibat kantuk. Ini dapat memberikan kontribusi besar dalam meningkatkan keselamatan jalan dan kesejahteraan masyarakat secara keseluruhan.

2. METODOLOGI PENELITIAN

2.1 Metode Penelitian

Secara umum metode penelitian harus menggabungkan alur kerja yang digunakan untuk melaksanakan hasil penelitian. Gambar 1 menyajikan alur penelitian metode LSTM dalam memprediksi detak jantung untuk mendapatkan model terbaik.

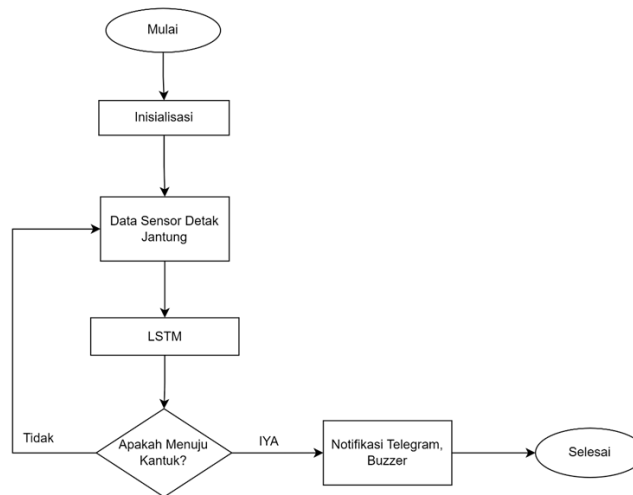


Gambar 1. Skema Pembuatan Model LSTM

Pada gambar 1 menunjukkan tahapan pembuatan model LSTM, yang dimulai dengan pengambilan dataset detak jantung, yang kemudian diikuti dengan *pre-processing* data. Proses *training* model *Long Short Term Memory* (LSTM) diawali dengan pengumpulan dataset lalu *pre-processing* data dengan menggunakan metode *min-max scaler* dari *sklearn* untuk melakukan normalisasi pada dataset [13]. Metode ini mengubah nilai fitur ke dalam rentang [0,1] [14]. *Pre processing* data melibatkan normalisasi data untuk memastikan bahwa keluaran jaringan sesuai dengan fungsi aktivasi yang digunakan [15], serta pembuatan *sequences* data yaitu serangkaian data berurutan yang akan digunakan sebagai input ke model *Long Short Term Memory* (LSTM). Setelah data diproses, dataset dibagi menjadi dua bagian yaitu data *training* 67% dan 33% data *testing*.

2.2 Alur Prediksi

Pada gambar 2 menunjukkan diagram alir proses prediksi kondisi kantuk menggunakan data detak jantung dan model LSTM.

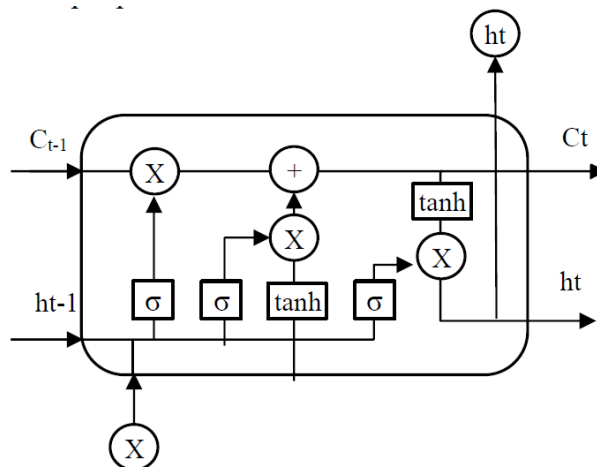


Gambar 2. Diagram Alir Proses Prediksi

Proses dimulai dengan inisialisasi sistem, diikuti dengan pengumpulan data detak jantung dari sensor. Data tersebut kemudian dimasukkan ke dalam model LSTM yang telah dilatih untuk menganalisis pola detak jantung dan memprediksi apakah seseorang sedang menuju kondisi kantuk. Jika prediksi menunjukkan kemungkinan kantuk, sistem akan mengaktifkan notifikasi melalui Telegram dan buzzer sebagai peringatan. Setelah proses notifikasi selesai, sistem akan kembali ke kondisi awal atau menunggu data berikutnya untuk diproses.

2.3 Long Short Term Memory (LSTM)

Arsitektur *Long Short Term Memory* (LSTM) dirancang dengan menentukan jumlah *layer Long Short Term Memory* (LSTM) dan unit per *layer*, serta menambahkan *layer* tambahan seperti *Dense layer* untuk *output*. Arsitektur *Long Short Term Memory* (LSTM) dapat dilihat pada gambar 2 berikut [16],



Gambar 3. Arsitektur LSTM

Arsitektur *Long Short Term Memory* (LSTM) terdapat tiga gerbang utama yang mengatur alur informasi [17], yaitu *forget get* yang menentukan apakah informasi dari *cell* sebelumnya harus dihapuskan atau disimpan, *input gate*

menunjukkan informasi yang diubah atau ditambahkan ke dalam *cell*, dan *output gate* yang memberikan informasi sebagai hasil keluaran sesuai dengan input dan memori pada *cell*,

```

Model: "sequential"
-----
Layer (type)              Output Shape              Param #
-----
lstm (LSTM)                (None, 4)                 96
dense (Dense)              (None, 1)                 5
-----
Total params: 101
Trainable params: 101
Non-trainable params: 0
    
```

Gambar 5. Arsitektur Model LSTM yang Diusulkan

Pada gambar 3. Pengembangan arsitektur model LSTM dilakukan untuk mencapai akurasi terbaik dalam mendeteksi kantuk pada pengemudi. Model ini terdiri dari dua lapisan utama: lapisan LSTM dan lapisan *Dense*. Lapisan LSTM memiliki 96 parameter, dengan *output shape* (None, 4), yang berarti model ini dapat menangani urutan input dengan panjang yang tidak ditentukan dan menghasilkan output dengan ukuran 4. Lapisan *Dense* berikutnya memiliki 5 parameter dan menghasilkan *output* dengan ukuran 1, sesuai dengan tugas regresi yang dilakukan untuk prediksi tingkat kantuk.

Melalui pendekatan ini, model dapat mencapai performa yang sangat baik, seperti yang ditunjukkan oleh hasil evaluasi pada data pelatihan dan pengujian. Desain arsitektur yang sederhana namun efektif ini memungkinkan sistem deteksi kantuk untuk berfungsi dengan baik dalam kondisi nyata, memberikan peringatan dini kepada pengemudi dan berpotensi menyelamatkan banyak nyawa dengan mengurangi risiko kecelakaan akibat kantuk.

2.4 Evaluasi Model

2.4.1 Evaluasi Model LSTM

Model *Long Short Term Memory* (LSTM) di *training* menggunakan data *training*, dengan iterasi yang berulang dan pembaruan bobot berdasarkan *loss function* yang ditetapkan. Setelah *training*, model diuji menggunakan data *testing* untuk mengevaluasi kinerjanya dalam memprediksi data yang tidak terlihat sebelumnya. Untuk evaluasi, model akan diukur menggunakan *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), *Mean Square Error* (MSE). Berikut ini ditampilkan rumus dari matriks tersebut [13] [18] [19] [20].

Nilai kesalahan rata-rata yang merupakan perbedaan antara nilai asli dan nilai prediksi disebut sebagai *Mean Absolute Error* (MAE). MAE digunakan untuk mengukur prediksi kesalahan dalam analisis rangkaian waktu.

$$MAE = \left(\frac{1}{m}\right) \sum_{i=1}^m |X_i - Y_i| \tag{1}$$

Root Mean Square Error (RMSE) merupakan jumlah dari kesalahan kuadrat, atau perbedaan antara nilai asli dan nilai prediksi yang telah ditetapkan. Jika nilai *Root Mean Square Error* (RMSE) rendah atau hampir nol, itu berarti hasil prediksi akan lebih baik.

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (X_i - Y_i)^2} \tag{2}$$

Mean Absolute Percentage Error (MAPE) adalah rata-rata diferensiasi absolut antara nilai asli dan prediksi, yang diwakili sebagai persentase nilai asli. Nilai MAPE yang lebih rendah menunjukkan bahwa hasil prediksi yang lebih akurat.

$$MAPE = 100\% \times \left(\frac{1}{m}\right) \sum_{i=1}^m \left| \frac{Y_i - X_i}{Y_i} \right| \tag{3}$$

Rata-rata kesalahan kuadrat di antara nilai asli dan nilai prediksi dikenal sebagai *Mean Square Error* (MSE). Nilai MSE yang rendah atau hampir nol menunjukkan bahwa hasil prediksi sesuai dengan data asli dan dapat digunakan untuk perhitungan prediksi di masa mendatang.

$$MSE = \frac{1}{m} \sum_{i=1}^m (X_i - Y_i)^2 \tag{4}$$

2.4.2 Evaluasi Hasil Alat

Sebelum pengambilan data detak jantung, peneliti melakukan perbandingan antara alat BPM sensor dengan BPM Oximeter untuk mengevaluasi ketelitian BPM sensor dalam mendeteksi detak jantung. Perbandingan ini bertujuan untuk memastikan bahwa sensor BPM memiliki kemampuan untuk memberikan hasil pengukuran yang akurat dan dapat diandalkan, serupa dengan BPM Oximeter yang sudah teruji keandalannya. Dengan melakukan perbandingan ini, peneliti dapat menilai sejauh mana BPM sensor mampu mendeteksi detak jantung dengan tepat, sehingga data yang dihasilkan dapat digunakan dengan percaya diri dalam pengembangan dan pengujian model deteksi kantuk. Persamaan yang digunakan untuk perbandingan ini, yang dirujuk dalam penelitian sebelumnya [10], membantu dalam menghitung dan membandingkan tingkat ketelitian antara kedua alat, memastikan bahwa BPM sensor memenuhi standar akurasi yang diperlukan untuk sistem pendeteksi kantuk.

$$\text{level of accuracy (\%)} = \frac{\text{sensorpulse}}{\text{manual}} \times 100 \quad (5)$$

3. HASIL DAN PEMBAHASAN

3.1 Pengujian Alat BPM Sensor

Pengujian alat BPM sensor dilakukan dengan melakukan perbandingan antara hasil pengukuran menggunakan BPM sensor dan BPM oximeter. Pada tabel 1 merupakan hasil dari perbandingan yang dilakukan,

Tabel 1. Hasil Perbandingan Pengukuran BPM menggunakan Oximeter dan Sensor

BPM Sensor (bpm)	BPM Oximeter (bpm)	Accuracy Level (%)
75	78	96
64.41	67	96
78	79	98
62.72	67	93
83	85	98

Sensor detak jantung (bpm) memiliki ketepatan tinggi, seperti yang ditunjukkan pada tabel 1. Tingkat ketepatan ini menunjukkan bahwa sensor dapat memberikan informasi yang sangat tepat dan konsisten. Sehingga, sensor ini dapat diandalkan sebagai komponen sistem pendeteksi kantuk.

Dengan akurasi yang baik, sensor ini memastikan bahwa setiap pengukuran detak jantung yang dihasilkan mendekati nilai sebenarnya, yang sangat penting untuk efektivitas model LSTM dalam mendeteksi kondisi kantuk pengemudi. Data yang akurat memungkinkan model untuk membuat prediksi yang lebih andal dan responsif, meningkatkan keselamatan pengemudi dengan mendeteksi potensi kantuk dengan lebih tepat.

3.2 Implementasi Long Short Term Memory (LSTM)

Data detak jantung dalam penelitian dikumpulkan melalui penggunaan alat BPM dengan menit dan detak jantung (bpm) sebagai variable. Data yang diekspor dari alat disajikan dalam format TXT, kemudian diubah ke format CSV untuk diproses lebih lanjut. Tabel 2 menunjukkan contoh output yang telah dikonversi ke format CSV.

Tabel 2. Output Read CSV

Menit	Detak Jantung (bpm)
1	75
2	80
3	78
4	82
5	77
...	
520	62
521	61
522	59

Data yang dihasilkan alat memiliki nilai yang berbeda, oleh sebab itu normalisasi dilakukan untuk mengurangi kesalahan atau error. Normalisasi data adalah proses yang penting dalam pengolahan data, karena membantu mengurangi skala perbedaan antar nilai data, sehingga model *machine learning* dapat lebih mudah untuk mempelajari pola yang ada. Dalam penelitian ini, metode Min-Max Scaler digunakan untuk melakukan normalisasi. Metode ini bekerja dengan mengubah setiap nilai data ke dalam rentang nilai 0 dan 1. Dengan menggunakan Min-Max Scaler, dapat memastikan bahwa semua fitur atau variabel dalam dataset memiliki skala yang sama. Ini dapat meningkatkan

kinerja model dalam menemukan pola dan membuat prediksi yang lebih akurat. Tabel 3 menunjukkan hasil dari normalisasi data.

Tabel 3. Hasil Normalisasi Data

Minute	Heart Rate (bpm)
1	0.396
2	0.500
3	0.458
4	0.451
5	0.437
...	
520	0.125
521	0.104
522	0.062

Selanjutnya pembentukan dataset *training*. Dataset tersebut terbagi menjadi dua yaitu, 67% untuk data *training* dan 33% untuk data *testing*. Pembagian ini membantu dalam mengevaluasi generalisasi model, yaitu seberapa baik model dapat memprediksi data baru yang tidak digunakan selama *training*. Selama *training*, model akan menjalani beberapa iterasi yang disebut sebagai *epoch*. Pada setiap *epoch*, model akan memproses seluruh dataset *training* dan memperbarui bobotnya berdasarkan *error* yang dihitung menggunakan fungsi *loss*.

Dalam hal ini, model akan dilatih sebanyak 100 *epoch*. Setiap *epoch* memberikan kesempatan bagi model untuk memperbaiki bobotnya dan mengurangi *error*, sehingga model dapat lebih baik dalam memprediksi *output* yang benar. Sebelum *training* dimulai, model harus dikompilasi dengan menentukan fungsi *loss* dan *optimizer*. Fungsi *loss* yang digunakan adalah *Mean Square Error* (MSE). MSE dipilih karena mampu memberikan penalti yang lebih besar untuk prediksi yang jauh dari nilai sebenarnya, sehingga mendorong model lebih akurat dalam memprediksi.

Optimizer yang digunakan yaitu *Adaptive Moment Estimation* (ADAM), yang mampu menyesuaikan laju pembelajaran secara otomatis selama *training* dan model dapat lebih efisien dalam menemukan bobot optimal yang meminimalkan fungsi *loss*.


Pada gambar 4, terlihat proses training dan testing dari model *Long Short Term Memory* (LSTM) yang telah dirancang dan diimplementasikan. Gambar ini memberikan visualisasi yang komprehensif mengenai tahapan dan hasil dari *training* serta *testing* model. Dalam tahap *training*, model LSTM dilatih menggunakan dataset yang sudah disiapkan, di mana model belajar untuk mengenali pola-pola dalam data detak jantung yang berkaitan dengan kondisi mengantuk.

```

277/277 - 0s - loss: 0.0349 - val_loss: 0.0314 - 466ms/epoch - 2ms/step
Epoch 93/100
277/277 - 0s - loss: 0.0348 - val_loss: 0.0320 - 448ms/epoch - 2ms/step
Epoch 94/100
277/277 - 0s - loss: 0.0348 - val_loss: 0.0319 - 488ms/epoch - 2ms/step
Epoch 95/100
277/277 - 0s - loss: 0.0349 - val_loss: 0.0313 - 484ms/epoch - 2ms/step
Epoch 96/100
277/277 - 1s - loss: 0.0348 - val_loss: 0.0312 - 617ms/epoch - 2ms/step
Epoch 97/100
277/277 - 1s - loss: 0.0347 - val_loss: 0.0311 - 540ms/epoch - 2ms/step
Epoch 98/100
277/277 - 1s - loss: 0.0346 - val_loss: 0.0315 - 619ms/epoch - 2ms/step
Epoch 99/100
277/277 - 0s - loss: 0.0346 - val_loss: 0.0316 - 498ms/epoch - 2ms/step
Epoch 100/100
277/277 - 0s - loss: 0.0348 - val_loss: 0.0314 - 481ms/epoch - 2ms/step
11/11 [=====] - 1s 1ms/step
6/6 [=====] - 0s 1ms/step
    
```

Gambar 6. Proses *Training* dan *Testing* Model LSTM


Gambar 5 menunjukkan data prediksi model LSTM dan data aktual yang dikumpulkan selama percobaan. Hasil dari *training* dan *testing* menunjukkan bagaimana model LSTM berfungsi dalam memprediksi kondisi kantuk pengemudi.



Gambar 7. Grafik Data Prediksi

Pada grafik gambar 5, dapat dilihat bahwa garis berwarna oranye merupakan hasil prediksi model yang mengikuti pergerakan grafik data asli yang berwarna biru. Grafik ini menunjukkan bagaimana prediksi model mengikuti pola detak jantung yang terekam dalam data asli. Garis biru yang menunjukkan data asli memiliki fluktuasi yang jelas dalam rentang detak jantung selama periode waktu yang diukur dalam menit. Garis oranye menunjukkan bahwa model prediksi mampu mengikuti perubahan dalam detak jantung dengan akurasi yang tinggi.

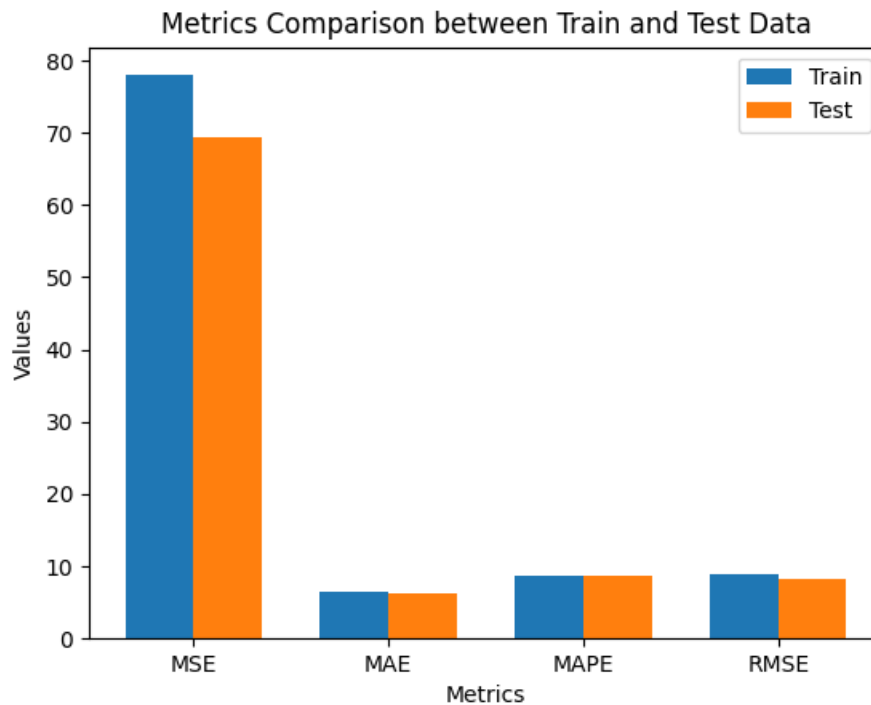
Selain itu, terdapat juga garis hijau pada grafik, yang kemungkinan menunjukkan data testing yang juga mengikuti pola detak jantung yang serupa. Rentang hasil akurasi yang tidak terlalu besar antara data *training* dan *testing* menunjukkan bahwa model yang dilatih memiliki generalisasi yang baik. Ini berarti bahwa model tidak hanya mampu memprediksi data yang telah dilatih tetapi juga bekerja dengan baik dengan data baru.



Gambar 8. Grafik Loss *Training* dan *Testing*

Pada gambar 6 grafik menunjukkan penurunan signifikan pada *loss training* dan *testing* dalam 100 *epoch* pertama, dengan penurunan tajam di awal dan stabil setelah sekitar 10 *epoch*. *Loss training* dan *testing* awalnya tinggi, namun menurun cepat, menunjukkan model belajar dengan cepat. Setelah 10 *epoch*, laju penurunan melambat,

mengindikasikan konvergensi dengan sedikit perbedaan antara *loss training* dan *testing*. Hal ini menunjukkan model bekerja baik pada dataset *training* dan *testing* tanpa tanda-tanda *overfitting*.



Gambar 9. Grafik Hasil Evaluasi Metrik

Untuk mengukur kualitas model yang dibangun, dapat dilakukan evaluasi metrik dengan beberapa pengukuran seperti *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan *Mean Squared Error* (MSE). Setiap metrik ini memberikan perspektif berbeda mengenai seberapa akurat dan efektif model tersebut dalam memprediksi hasil. Pada gambar 7 dan tabel 4, hasil dari berbagai pengukuran evaluasi metrik tersebut dapat dilihat, yang memberikan gambaran komprehensif mengenai performa model dalam berbagai aspek. Evaluasi metrik ini sangat penting untuk memastikan bahwa model yang dibangun tidak hanya akurat tetapi juga dapat diandalkan dalam berbagai situasi.

Tabel 4. Hasil Evaluasi Metrik

	MAE	RMSE	MAPE	MSE
<i>Training</i>	6.42	8.82	8.78%	77.80
<i>Testing</i>	6.35	8.32	8.97%	69.47

Berdasarkan tabel 4, nilai MSE untuk data training adalah 77.80 dan untuk data testing 69.47, menunjukkan kesalahan kuadrat rata-rata sedikit lebih tinggi pada data training. Meskipun ada perbedaan, nilai MAE, MAPE, dan RMSE konsisten antara data training dan testing. MAE untuk training adalah 6.42 dan untuk testing 6.35, menunjukkan kesalahan absolut rata-rata kecil dan stabil. MAPE adalah 8.87% untuk training dan 8.97% untuk testing, mengindikasikan prediksi model yang dapat diandalkan dalam persentase. RMSE, yang menghukum kesalahan besar lebih berat, adalah 8.82 untuk training dan 8.33 untuk testing, menunjukkan performa model yang konsisten dalam mengurangi kesalahan besar.

3.3 Pengujian Deteksi pada alat

Setelah berhasil mendapatkan model *Long Short Term Memory* (LSTM) dengan hasil evaluasi metrik yang memuaskan, langkah berikutnya adalah mengimplementasikan model tersebut pada alat pendeteksi kantuk menggunakan pulse heart rate sensor. Dalam implementasi ini, dilakukan serangkaian percobaan testing sebanyak 10 kali dengan menggunakan data uji yang terdiri dari detak jantung pengemudi. Fokus dari percobaan ini adalah untuk mendeteksi kondisi mengantuk, yang diindikasikan oleh nilai detak jantung pengemudi yang berada di bawah 65 denyut per menit.

Kondisi ini dianggap sebagai salah satu tanda pengemudi mengalami kantuk, yang dapat berpotensi membahayakan jika dibiarkan tanpa tindakan. Dalam setiap percobaan, sensor detak jantung mencatat data real-time yang kemudian diproses oleh model LSTM untuk menentukan apakah pengemudi sedang mengantuk atau tidak. Hasil dari percobaan ini kemudian dicatat dan dianalisis untuk mengevaluasi akurasi dan keandalan model dalam mendeteksi kantuk. Adapun hasil dari percobaan tersebut, termasuk persentase deteksi yang berhasil dan kesalahan

yang terjadi, dirangkum dalam tabel 3.5 berikut, memberikan gambaran jelas mengenai performa model dalam situasi nyata. Evaluasi ini sangat penting untuk memastikan bahwa model LSTM yang dikembangkan dapat diandalkan dalam kondisi operasional sebenarnya, dan memberikan kontribusi signifikan dalam meningkatkan keselamatan pengemudi di jalan raya.

Tabel 5. Hasil *Testing* Menggunakan Alat Pendeteksi

Umur	Jenis Kelamin	Detak Jantung (bpm)	Kondisi	Hasil Prediksi
18	P	87	Normal	Benar
22	P	92	Normal	Benar
26	L	64.41	Kantuk	Benar
35	L	75	Normal	Benar
40	L	57.88	Kantuk	Benar
20	P	78	Normal	Benar
19	L	81	Normal	Benar
21	P	62.72	Kantuk	Benar
23	L	83	Normal	Benar
28	L	64.29	Kantuk	Benar

Tabel 5 menunjukkan hasil pengujian alat pendeteksi kantuk pada pengemudi menggunakan sensor detak jantung dan model LSTM. Subjek berumur antara 18 hingga 40 tahun, terdiri dari laki-laki (L) dan perempuan (P), dengan detak jantung bervariasi dari 57.88 bpm hingga 92 bpm. Kondisi subjek ditentukan sebagai normal atau mengantuk, dan prediksi alat selalu akurat. Misalnya, subjek berumur 18 dan 22 tahun dengan detak jantung 87 bpm dan 92 bpm dalam kondisi normal diprediksi dengan benar. Subjek berumur 26 dan 40 tahun dengan detak jantung 64.41 bpm dan 57.88 bpm dalam kondisi mengantuk juga diprediksi dengan benar. Ini menunjukkan bahwa model LSTM memiliki akurasi tinggi dalam mendeteksi kantuk, meskipun terdapat variasi dalam detak jantung dan profil demografis.

4. KESIMPULAN

Penelitian ini mengimplementasikan Long Short Term Memory (LSTM) pada sensor detak jantung untuk mendeteksi kantuk pada pengemudi. Dalam proses pelatihan model, metrik evaluasi menunjukkan bahwa model LSTM mencapai Mean Absolute Error (MAE) sebesar 6.42 pada data pelatihan dan 6.35 pada data pengujian, *Root Mean Squared Error* (RMSE) sebesar 8.82 untuk pelatihan dan 8.33 untuk pengujian, *Mean Absolute Percentage Error* (MAPE) masing-masing sebesar 8.78% dan 8.97%, serta *Mean Squared Error* (MSE) sebesar 77.80 pada data pelatihan dan 69.47 pada data pengujian. Hasil ini menunjukkan bahwa model LSTM memiliki performa yang baik dalam mendeteksi kantuk pada pengemudi, dengan kemampuan prediksi yang konsisten antara data pelatihan dan pengujian. Penelitian ini sangat signifikan karena berpotensi membantu mengurangi risiko kecelakaan lalu lintas akibat kantuk, yang merupakan salah satu penyebab utama kecelakaan di jalan raya. Dengan mendeteksi tanda-tanda awal kantuk, sistem ini dapat memberikan peringatan dini kepada pengemudi untuk mengambil tindakan pencegahan yang diperlukan, seperti istirahat atau berhenti sejenak, sehingga meningkatkan keselamatan di jalan raya. Teknologi ini berpotensi untuk diintegrasikan ke dalam kendaraan modern sebagai fitur keselamatan tambahan yang dapat menyelamatkan banyak nyawa. Selain itu, implementasi sistem deteksi kantuk berbasis LSTM ini memungkinkan penelitian lebih lanjut untuk mengembangkan teknologi keselamatan kendaraan yang lebih canggih dan responsif terhadap kondisi pengemudi.

REFERENCES

- [1] Kementerian Perhubungan Republik Indonesia, "Tekan Angka Kecelakaan Lalu Lintas, Kemenhub Ajak Masyarakat Beralih ke Transportasi Umum dan Utamakan Keselamatan Berkendara", [Online]. Available: <https://dephub.go.id/post/read/tekan-angka-kecelakaan-lalu-lintas,-kemenhub-ajak-masyarakat-beralih-ke-transportasi-umum-dan-utamakan-keselamatan-berkendara>, tanggal akses 20 July 2024
- [2] S. Saleem, "Risk assessment of road traffic accidents related to sleepiness during driving: a systematic review," *East. Mediterr. Heal. J.*, vol. 28, no. 9, pp. 695–700, 2022, doi: 10.26719/emhj.22.055.
- [3] R. Rahmadiyahani and A. widyanti, "Prevalence of drowsy driving and modeling its intention: An Indonesian case study," *Transp. Res. Interdiscip. Perspect.*, vol. 19, no. May, p. 100824, 2023, doi: 10.1016/j.trip.2023.100824.
- [4] C. Aj. Saputra, D. Erwanto, and P. N. Rahayu, "Deteksi Kantuk Pengendara Roda Empat Menggunakan Haar Cascade Classifier Dan Convolutional Neural Network," *JEECOM J. Electr. Eng. Comput.*, vol. 3, no. 1, pp. 1–7, 2021, doi: 10.33650/jeeecom.v3i1.1510.
- [5] Khan Salman, Mukhtar Husnaeni, and Pramudita Brahmantya, "Perancangan Sistem Pendeteksi Microsleep Untuk Peringatan Kelelahan Pada Pengemudi Kendaraan," *E-Proceeding Eng.*, vol. 9, no. 4, p. 1810, 2022.
- [6] Y. Y. Haijun Lin, Sirao Zhang, Qinghao Li, Ya Li, Jianmin Li, "A new method for heart rate prediction based on LSTM-BiLSTM-Att," *J. Int. Meas. Confed.*, vol. Volume 207, 2023, doi: <https://doi.org/10.1016/j.measurement.2022.112384>.
- [7] K. D. Prasetyo, R. Wijaya, and G. S. Wulandari, "Comparative Analysis of ARIMA and LSTM Models for Predicting



- Physical Fatigue in Bandung Workers,” *J. Media Inform. Budidarma*, vol. 8, pp. 528–536, 2024, doi: 10.30865/mib.v8i1.7282.
- [8] A. F. A. Zen, E. S. Pramukantoro, K. Amron, V. Wardhani, and P. A. Kamila, “Prediksi Detak Jantung Berbasis LSTM pada Raspberry Pi untuk Pemantauan Kesehatan Portabel,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 10, no. 7, pp. 1555–1562, 2023, doi: 10.25126/jtiik.1078015.
- [9] P. Madona and A. L. Tobing, “Early Detection of Microsleep in Motorcycle Helmet Based on Pulse Sensor,” *J. Electron. Technol. Explor.*, vol. 1, no. 2, pp. 45–52, 2023, doi: 10.52465/joetex.v1i2.228.
- [10] Y. Irawan, Y. Fernando, and R. Wahyuni, “Detecting Heart Rate Using Pulse Sensor As Alternative Knowing Heart Condition,” *J. Appl. Eng. Technol. Sci.*, vol. 1, no. 1, pp. 30–42, 2019, doi: 10.37385/jaets.v1i1.16.
- [11] T. Arakawa, “A review of heartbeat detection systems for automotive applications,” *Sensors*, vol. 21, no. 18, 2021, doi: 10.3390/s21186112.
- [12] S. H. Jo, J. M. Kim, and D. K. Kim, “Heart rate change while drowsy driving,” *J. Korean Med. Sci.*, vol. 34, no. 8, pp. 8–12, 2019, doi: 10.3346/jkms.2019.34.e56.
- [13] L. Wiranda and M. Sadikin, “Penerapan Long Short Term Memory pada Data Time Series untuk Memprediksi Penjualan Produk PT. Metiska Farma,” *J. Nas. Pendidik. Tek. Inform.*, vol. 8, no. 3, pp. 184–196, 2019.
- [14] J. Cahyani, S. Mujahidin, and T. P. Fiqar, “Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional,” *J. Sist. dan Teknol. Inf.*, vol. 11, no. 2, p. 346, 2023, doi: 10.26418/justin.v11i2.57395.
- [15] N. N. D. Ardriani, J. A. Y. Yastawil, K. N. Erawati, I. G. M. Yudi Antara, and G. A. Santiago, “Multivariat Predict Sales Data Using the Recurrent Neural Network (RNN) Method,” *IJCCS (Indonesian J. Comput. Cybern. Syst.)*, vol. 18, no. 1, p. 83, 2024, doi: 10.22146/ijccs.90165.
- [16] B. A. H. Kholifatullah and A. Prihanto, “Penerapan Metode Long Short Term Memory Untuk Klasifikasi Pada Hate Speech,” *J. Informatics Comput. Sci.*, vol. 04, pp. 292–297, 2023, doi: 10.26740/jinacs.v4n03.p292-297.
- [17] T. Bastian Sianturi, I. Cholissodin, and N. Yudistira, “Penerapan Algoritma Long Short-Term Memory (LSTM) berbasis Multi Fungsi Aktivasi Terbobot dalam Prediksi Harga Ethereum,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 7, no. 3, pp. 1101–1107, 2023, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [18] D. Chicco, M. J. Warrens, and G. Jurman, “The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation,” *PeerJ Comput. Sci.*, vol. 7, pp. 1–24, 2021, doi: 10.7717/PEERJ-CS.623.
- [19] R. B. Radite Putra and H. Hendry, “Multivariate Time Series Forecasting pada Penjualan Barang Retail dengan Recurrent Neural Network,” *INOVTEK Polbeng - Seri Inform.*, vol. 7, no. 1, p. 71, 2022, doi: 10.35314/isi.v7i1.2398.
- [20] Khalis Sofi, Aswan Supriyadi Sunge, Sasmitoh Rahmad Riady, and Antika Zahrotul Kamalia, “Perbandingan Algoritma Linear Regression, Lstm, Dan Gru Dalam Memprediksi Harga Saham Dengan Model Time Series,” *Seminastika*, vol. 3, no. 1, pp. 39–46, 2021, doi: 10.47002/seminastika.v3i1.275.