



E-ISSN 3032-601X & P-ISSN 3032-7105

Vol. 2, No. 1, Januari 2025

MISTER

Journal of Multidisciplinary Inquiry in Science,
Technology and Educational Research

**Jurnal Penelitian Multidisiplin dalam Ilmu
Pengetahuan, Teknologi dan Pendidikan**

**UNIVERSITAS SERAMBI MEKKAH
KOTA BANDA ACEH**

mister@serambimekkah.ac.id

Journal of Multidisciplinary Inquiry in Science Technology
and Educational Research

Journal of MISTER

Vol. 2, No. 1, Januari 2025

Pages: 20–30

Penerapan Multi-Layer Perceptron untuk Prediksi Durasi Tidur Berdasarkan Faktor Kebiasaan Harian

Rafif Risdi Aulia¹, Fitra Hidayat Lubis², Lailan Sofinah Harahap³

Program Studi Ilmu Komputer, Fakultas Sains dan Teknologi, Universitas Islam
Negeri Sumatera Utara, Medan, Indonesia^{1,2}

Program Studi Teknologi Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi,
Universitas Muhammadiyah Sumatera Utara, Medan, Indonesia³

Article in Journal of MISTER

Available at : <https://jurnal.serambimekkah.ac.id/index.php/mister/index>

DOI : <https://doi.org/10.32672/mister.v2i1.2326>

How to Cite this Article

APA : Risdi Aulia, R. ., Hidayat Lubis, F., & Sofinah Harahap, L. . (2024). Penerapan Multi-Layer Perceptron untuk Prediksi Durasi Tidur Berdasarkan Faktor Kebiasaan Harian. *Journal of Multidisciplinary Inquiry in Science, Technology and Educational Research*, 2(1), 20 – 30.
<https://doi.org/10.32672/mister.v2i1.2326>

Others Visit : <https://jurnal.serambimekkah.ac.id/index.php/mister/index>

MISTER: *Journal of Multidisciplinary Inquiry in Science, Technology and Educational Research* is a scholarly journal dedicated to the exploration and dissemination of innovative ideas, trends and research on the various topics include, but not limited to functional areas of Science, Technology, Education, Humanities, Economy, Art, Health and Medicine, Environment and Sustainability or Law and Ethics.

MISTER: *Journal of Multidisciplinary Inquiry in Science, Technology and Educational Research* is an open-access journal, and users are permitted to read, download, copy, search, or link to the full text of articles or use them for other lawful purposes. Articles on Journal of MISTER have been previewed and authenticated by the Authors before sending for publication. The Journal, Chief Editor, and the editorial board are not entitled or liable to either justify or responsible for inaccurate and misleading data if any. It is the sole responsibility of the Author concerned.



ISSN 3032-7105

ISSN 3032-601X



9 773032 710001 9 773032 601002

Penerapan Multi-Layer Perceptron untuk Prediksi Durasi Tidur Berdasarkan Faktor Kebiasaan Harian

Rafif Risdi Aulia¹, Fitra Hidayat Lubis², Lailan Sofinah Harahap³

Program Studi Ilmu Komputer, Fakultas Sains dan Teknologi, Universitas Islam Negeri Sumatera Utara, Medan, Indonesia^{1,2}

Program Studi Teknologi Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara, Medan, Indonesia³

*Email Korespondensi: rafif.raulia@gmail.com

Diterima: 06-11-2024

| Disetujui: 07-11-2024

| Diterbitkan: 08-11-2024

ABSTRACT

This study applies a Multi Layer Perceptron (MLP), a type of Artificial Neural Network (ANN), to predict sleep duration based on daily habits, including screen time, exercise, and caffeine intake. The methodology involves data preprocessing, MLP architecture design, hyperparameter tuning using Grid Search, and model evaluation. The final model configuration includes two hidden layers with 10 neurons each, utilizing the tanh activation function and adam optimizer with a learning rate of 0.1. The model evaluation on test data shows promising accuracy, with a Mean Squared Error (MSE) of 0.065 and Mean Absolute Error (MAE) of 0.204. These results indicate that the MLP model effectively captures complex patterns in the dataset and provides accurate sleep duration predictions. However, certain samples showed significant prediction discrepancies, suggesting the potential influence of unobserved factors, such as health conditions or stress. Further research could improve model performance by including additional features or exploring alternative models like Random Forest or Gradient Boosting.

Keywords: Multilayer Perceptron, Artificial Neural Network, Sleep Duration Prediction, Hyperparameter Tuning, Daily Habits,

ABSTRAK

Penelitian ini menerapkan model Multilayer Perceptron (MLP), yang merupakan salah satu jenis Jaringan Syaraf Tiruan (JST), untuk memprediksi durasi tidur berdasarkan kebiasaan harian, termasuk waktu layar, olahraga, dan konsumsi kafein. Metodologi yang digunakan meliputi praproses data, desain arsitektur MLP, hyperparameter tuning menggunakan Grid Search, dan evaluasi model. Konfigurasi model akhir mencakup dua hidden layer dengan 10 neuron masing-masing, menggunakan fungsi aktivasi tanh dan optimizer adam dengan learning rate sebesar 0,1. Evaluasi model pada data uji menunjukkan akurasi yang memuaskan, dengan Mean Squared Error (MSE) sebesar 0,065 dan Mean Absolute Error (MAE) sebesar 0,204. Hasil ini menunjukkan bahwa model MLP efektif menangkap pola kompleks dalam dataset dan memberikan prediksi durasi tidur yang akurat. Namun, terdapat beberapa sampel yang menunjukkan perbedaan prediksi yang signifikan, yang mengindikasikan kemungkinan pengaruh faktor lain, seperti kondisi kesehatan atau stres. Penelitian lebih lanjut disarankan untuk meningkatkan performa model dengan menambah fitur tambahan atau mengeksplorasi model alternatif seperti Random Forest atau Gradient Boosting.

Katakunci: Multilayer Perceptron, Jaringan Syaraf Tiruan, Prediksi Durasi Tidur, Hyperparameter Tuning, Kebiasaan Harian

PENDAHULUAN

Tidur merupakan salah satu aspek penting dalam kehidupan manusia yang berpengaruh langsung terhadap kesehatan, produktivitas, dan kesejahteraan individu. Kualitas dan durasi tidur yang baik tidak hanya membantu proses pemulihan fisik dan mental, tetapi juga berperan dalam menjaga kesehatan jangka panjang. Penelitian menunjukkan bahwa kurang tidur atau tidur yang berkualitas rendah dapat menyebabkan berbagai masalah kesehatan, termasuk depresi, obesitas, diabetes, dan penyakit kardiovaskular (Kudrnáčová & Kudrnáč, 2023). Selain itu, tidur yang cukup berkontribusi pada peningkatan konsentrasi, kreativitas, dan kinerja akademik (Okano et al., 2019).

Tidur yang cukup berhubungan erat dengan kesehatan fisik. Penelitian menunjukkan bahwa kurang tidur dapat meningkatkan risiko berbagai penyakit kronis seperti penyakit jantung, diabetes, obesitas, dan bahkan kanker. Tidur membantu dalam proses pemulihan tubuh dan pengaturan metabolisme. Sebuah studi menunjukkan bahwa kualitas tidur yang baik dapat mengurangi risiko penyakit kardiovaskular ketika dikombinasikan dengan gaya hidup sehat lainnya (Ramar et al., 2021).

Durasi tidur yang optimal sangat penting untuk menjaga kesehatan. Menurut National Sleep Foundation, durasi tidur ideal untuk remaja dan dewasa muda adalah 7-9 jam per malam (Rahmawati et al., 2021). Durasi tidur yang terlalu pendek (<7 jam) telah dikaitkan dengan peningkatan risiko obesitas, tekanan darah tinggi, dan penyakit jantung koroner (Wulansih et al., 2024).

Kualitas dan durasi tidur juga mempengaruhi produktivitas. Mahasiswa yang memiliki kualitas tidur baik cenderung lebih aktif dalam beraktivitas fisik dan memiliki performa akademik yang lebih baik. Sebuah studi di Yogyakarta menemukan bahwa hanya 28,2% mahasiswa perantau di Yogyakarta yang memiliki kualitas tidur baik, sedangkan 71,8% memiliki kualitas tidur yang buruk (Anggelia et al., 2017). Penelitian lain menunjukkan bahwa mahasiswa dengan kualitas tidur yang baik memiliki performa akademik yang lebih tinggi dibandingkan dengan mereka yang mengalami gangguan tidur. Selain itu, kurang tidur juga dikaitkan dengan peningkatan tingkat stres dan penurunan konsentrasi (Sara et al., 2020).

Dari segi kesehatan mental, kurang tidur dapat memperburuk kondisi psikologis seperti kecemasan dan depresi. Tidur yang tidak memadai dapat meningkatkan respons emosional negatif terhadap stres dan mengurangi kemampuan seseorang untuk mengatur emosi. Penelitian menunjukkan bahwa orang yang mengalami insomnia memiliki tingkat kecemasan dan depresi yang lebih tinggi dibandingkan mereka yang tidur dengan baik. Selain itu, kurang tidur dapat mempengaruhi kemampuan kognitif, termasuk perhatian, pembelajaran, dan memori (Columbia University Department of Psychiatry, 2022).

Peningkatan waktu yang dihabiskan di depan layar, baik itu televisi, komputer, maupun perangkat mobile, telah terbukti berkontribusi terhadap kualitas tidur yang buruk. Penelitian menunjukkan bahwa paparan cahaya biru dari layar dapat mengganggu ritme sirkadian dan mengurangi produksi melatonin, hormon yang mengatur siklus tidur. Hal ini menyebabkan kesulitan dalam memulai tidur dan mengurangi durasi tidur secara keseluruhan. Selain itu, kebiasaan menggunakan perangkat elektronik sebelum tidur sering kali berhubungan dengan peningkatan kecemasan dan stres, yang juga berdampak negatif pada kualitas tidur (Frank et al., 2017).

Konsumsi kafein merupakan salah satu faktor signifikan yang memengaruhi durasi tidur. Penelitian menunjukkan bahwa kafein yang dikonsumsi hingga 6 jam sebelum waktu tidur dapat menyebabkan gangguan tidur yang signifikan. Sebuah studi menemukan bahwa kafein dapat mengurangi total waktu tidur dan memperpanjang waktu yang dibutuhkan untuk tertidur. Konsumsi kafein yang tinggi di kalangan mahasiswa juga berhubungan dengan kualitas tidur yang buruk dan peningkatan rasa kantuk di siang hari

(Bonanni et al., 2022). Kafein bekerja dengan menghambat reseptor adenosin, yang berfungsi untuk meningkatkan rasa kantuk, sehingga mengganggu pola tidur normal.

Pola makan juga memiliki pengaruh besar terhadap durasi tidur. Konsumsi makanan tinggi kalori atau makanan dengan indeks glikemik tinggi sebelum tidur dapat menyebabkan gangguan pada proses tidur. Misalnya, makanan tinggi karbohidrat dapat meningkatkan kadar triptofan dalam tubuh, yang berkontribusi pada peningkatan kualitas tidur jika dikonsumsi pada waktu yang tepat. Namun, pola makan tidak teratur dan konsumsi makanan berat dekat dengan waktu tidur dapat memperburuk kualitas tidur dan menyebabkan kesulitan untuk tertidur (Putri, 2022).

Sebuah studi di rumah sakit di Bandar Lampung juga menunjukkan bahwa kebiasaan harian seperti penggunaan gadget sebelum tidur, konsumsi kafein, dan pola aktivitas fisik berpengaruh besar terhadap kualitas dan durasi tidur. Penggunaan layar sebelum tidur dapat mengganggu siklus tidur alami, sedangkan konsumsi kafein dapat memperlambat proses tidur. Di sisi lain, aktivitas fisik yang teratur terbukti meningkatkan kualitas tidur dan membantu individu untuk mendapatkan waktu tidur yang lebih baik (Fitriyani et al., 2024).

Tidur yang tidak cukup dapat menyebabkan masalah kesehatan mental seperti depresi dan kecemasan. Sebuah penelitian di Kabupaten Gowa menunjukkan bahwa individu yang mengalami gangguan tidur cenderung memiliki tingkat stres yang lebih tinggi dan kualitas hidup yang lebih rendah (Fadhilah et al., 2023).

Jaringan syaraf tiruan (JST) memainkan peran penting dalam memprediksi berbagai aspek kesehatan, termasuk durasi tidur. Dengan kemampuan untuk menganalisis data yang kompleks dan besar, JST dapat mengidentifikasi pola-pola yang mungkin tidak terlihat oleh manusia, sehingga memungkinkan prediksi yang lebih akurat tentang faktor-faktor yang memengaruhi kesehatan individu. Penelitian menunjukkan bahwa model JST dapat mencapai akurasi tinggi dalam memprediksi variabel kesehatan. Sebagai contoh, sebuah studi membandingkan algoritma Neural Network dengan metode lain untuk memprediksi gangguan tidur, di mana akurasi model Neural Network mencapai 91.2% (Sari, 2024).

Sebuah studi menggunakan dataset NetHealth dari 698 mahasiswa yang dilengkapi perangkat wearable untuk memprediksi kualitas tidur. Penelitian ini membandingkan berbagai teknik deep learning, termasuk Convolutional Neural Networks (CNN) dan Multilayer Perceptron (MLP). Hasil menunjukkan bahwa CNN mencapai akurasi tertinggi sebesar 97,30% dalam mengklasifikasikan kualitas tidur mingguan, menunjukkan kemampuan JST dalam menangkap pola kompleks dari data fisiologis yang dihasilkan oleh wearable (Kilic et al., 2023).

Multilayer Perceptron adalah jenis jaringan syaraf tiruan yang terdiri dari beberapa lapisan neuron, termasuk lapisan input, satu atau lebih lapisan tersembunyi, dan lapisan output. MLP memiliki kemampuan untuk menangkap hubungan non-linear antara variabel input dan output, yang membuatnya sangat efektif dalam menangani masalah prediksi yang kompleks. Dalam MLP, setiap neuron dalam lapisan tersembunyi menerapkan fungsi aktivasi untuk memproses informasi yang diterima dari lapisan sebelumnya. Proses ini memungkinkan MLP untuk belajar dari data dan mengidentifikasi pola yang mungkin tidak terlihat dengan metode analisis tradisional (Bagheri et al., 2023).


Durasi tidur dipengaruhi oleh banyak faktor harian seperti waktu layar, kebiasaan olahraga, dan konsumsi kafein. MLP mampu menangkap interaksi kompleks antara faktor-faktor ini dan durasi tidur, memberikan hasil prediksi yang lebih akurat dibandingkan dengan metode linier lainnya (Gulo & Lubis, 2024). Penelitian sebelumnya oleh Pardede dan teman-teman telah menunjukkan bahwa MLP dapat

memberikan akurasi tinggi dalam prediksi dan klasifikasi. Dengan kinerja yang baik dalam pengolahan data time series dan pola non-linear, MLP menjadi pilihan ideal untuk analisis ini (Pardede et al., 2022).

Berdasarkan studi literatur dan beberapa penelitian sebelumnya, penelitian ini bertujuan untuk menerapkan algoritma Multilayer Perceptron (MLP) dalam memprediksi durasi tidur individu berdasarkan berbagai faktor kebiasaan harian. Tujuan utama penelitian ini adalah untuk mengidentifikasi dan menganalisis pengaruh faktor-faktor kegiatan harian terhadap durasi tidur. Selanjutnya, penelitian ini diharapkan dapat memberikan wawasan yang dapat digunakan untuk memahami algoritma pada jaringan syaraf tiruan serta dapat menjadi alat prediktif yang bermanfaat untuk membantu individu mengelola kualitas tidurnya.

METODE PENELITIAN

Metode pada penelitian ini mencakup langkah-langkah yang ditempuh untuk mengembangkan dan mengoptimalkan model Multilayer Perceptron (MLP) guna memprediksi durasi tidur berdasarkan kebiasaan harian. Metodologi ini terdiri dari beberapa tahapan utama yaitu Pengumpulan dan Praproses Data, Desain Arsitektur MLP, Pelatihan Model dan tuning Hyperparameter, serta Evaluasi Model.



Gambar 1. Metode Penelitian

Pada penelitian ini, Dataset yang digunakan adalah dataset dalam format tabular yang diambil dari Website Kaggle, sebuah repositori database daring dengan URL <https://www.kaggle.com/datasets/krupa1999/sleep-pattern>. Dataset ini terdiri dari 11 atribut dengan total 46 entri, sebagaimana terlihat pada Tabel 1. Dataset ini mengandung berbagai variabel kebiasaan harian yang bersifat kategorikal dan numerik.

Tabel 1. Dataset

Atribut	Keterangan
<i>Age</i>	Usia individu dalam dataset (dalam tahun)
<i>Gender</i>	Jenis kelamin individu, misalnya "Male" atau "Female"
<i>meals/day</i>	Jumlah waktu makan setiap hari, seperti "two" atau "three"
<i>physical illness</i>	Apakah individu memiliki penyakit fisik atau tidak ("yes"/ "no")
<i>screen time</i>	Durasi penggunaan layar setiap hari, seperti "2hrs", "3-4 hrs", "more than 5"
<i>bluelight filter</i>	Apakah individu menggunakan filter cahaya biru atau tidak ("yes"/"no")
<i>sleep direction</i>	Arah tidur individu, misalnya "west", "south", atau "east"
<i>exercise</i>	Frekuensi berolahraga individu, seperti "sometimes" atau "no"
<i>smoke/drink</i>	Kebiasaan merokok atau minum alkohol ("yes"/"no")
<i>beverage</i>	Jenis minuman yang biasa dikonsumsi, misalnya "Tea", "Coffee", "Tea and Coffee both"

(Sumber : <https://www.kaggle.com/datasets/krupa1999/sleep-pattern>, 2020)

Langkah berikutnya adalah menangani nilai kosong (*missing values*). Berdasarkan hasil inspeksi awal, semua atribut pada dataset sudah terisi, sehingga tidak diperlukan penanganan tambahan untuk nilai kosong. Namun, langkah ini tetap penting untuk memastikan data yang digunakan dalam pelatihan model adalah lengkap dan bebas dari informasi yang hilang.

Dataset ini mengandung beberapa variabel kategorikal, seperti *Gender*, *meals/day*, *physical illness*, *screen time*, *bluelight filter*, *sleep direction*, *exercise*, *smoke/drink*, dan *beverage*. Variabel-variabel ini dikonversi ke dalam bentuk numerik menggunakan teknik *One-Hot Encoding*, yang menghasilkan kolom biner untuk setiap kategori (Sharma, 2023).

One-Hot Encoding mengubah setiap kategori dalam variabel menjadi kolom biner terpisah. Misalnya, jika kita memiliki variabel "warna" dengan kategori "merah", "hijau", dan "biru", One-Hot Encoding akan menghasilkan tiga kolom baru: "warna_merah", "warna_hijau", dan "warna_biru". Setiap baris dalam dataset akan memiliki nilai 1 di kolom yang sesuai dengan warna tersebut dan 0 di kolom lainnya. Ini memungkinkan model untuk memahami bahwa setiap kategori adalah entitas yang terpisah tanpa hubungan ordinal di antara mereka

Sebagai contoh, misalkan ada variabel *Gender* yang memiliki dua kategori: *Male* dan *Female*. Setelah *One-Hot Encoding*, variabel *Gender* akan diubah menjadi dua kolom:

- Gender_Male: Kolom biner yang bernilai 1 jika *Gender* adalah *Male*, dan 0 jika tidak.
- Gender_Female: Kolom biner yang bernilai 1 jika *Gender* adalah *Female*, dan 0 jika tidak.

Berikut adalah contoh tabel sebelum dan sesudah *One-Hot Encoding*:

Tabel 2. Contoh data sebelum One-Hot Encoding

Age	Gender	meals/day	beverage	sleep time
22	Male	two	Tea	6.75
23	Female	three	Coffee	8.00
24	Male	three	Tea	7.50
22	Female	two	Both	6.25

Tabel 3. Contoh data setelah One-Hot Encoding


Age	sleep time	Gender_Male	Gender_Female	meals/day_two	meals/day_three	beverage_Tea	beverage_Coffee	beverage_Both
22	6.75	1	0	1	0	1	0	0
23	8.00	0	1	0	1	0	1	0
24	7.50	1	0	0	1	1	0	0
22	6.25	0	1	1	0	0	0	1

Data numerik seperti *Age* dan *sleep time* dinormalisasi menggunakan Min-Max Scaling untuk menempatkan semua variabel dalam rentang [0, 1]. Dengan menerapkan Min-Max Scaling, kualitas data dapat ditingkatkan. Proses ini membantu dalam mengurangi noise dan outlier yang dapat mempengaruhi hasil analisis atau klasifikasi. Penelitian menunjukkan bahwa normalisasi data, termasuk Min-Max Scaling, dapat meningkatkan kinerja klasifikasi secara signifikan (Singh & Singh, 2020). Normalisasi ini tidak hanya membantu mengurangi ketidakstabilan model tetapi juga mempercepat proses konvergensi saat pelatihan

(Chen & Guestrin, 2016).

$$X_{baru} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

dengan X_{baru} merupakan data hasil normalisasi. Normalisasi ini penting untuk menghindari dominasi atribut numerik tertentu dalam proses pelatihan model.




Gambar 2. Distribusi fitur *age* dan *sleep time* sebelum dan sesudah normalisasi

Pada Gambar 2. dapat dilihat grafik distribusi variabel numerik *Age* dan *sleep time* sebelum dan sesudah proses normalisasi. Grafik ini menunjukkan perubahan distribusi data, di mana rentang nilai variabel telah diubah menjadi skala [0, 1] setelah normalisasi. Hal ini dilakukan untuk memastikan bahwa variabel-variabel tersebut memiliki skala yang seragam dalam pelatihan model MLP, sehingga membantu meningkatkan kinerja model dengan menghindari bias pada skala yang lebih besar.

Proses hyperparameter tuning dilakukan untuk meningkatkan akurasi dan kinerja model proses ini merupakan langkah penting dalam pengembangan model machine learning. Salah satu metode yang umum digunakan untuk hyperparameter tuning adalah Grid Search. Metode ini bekerja dengan cara melakukan pencarian secara menyeluruh (exhaustive search) di seluruh kombinasi nilai hyperparameter yang telah ditentukan sebelumnya (Rede, 2024). Parameter Grid Search ini dipilih karena pendekatannya yang sistematis, yang memungkinkan peneliti untuk mengevaluasi setiap kombinasi hyperparameter dengan menggunakan teknik validasi silang (cross-validation). Metode ini memungkinkan pencarian kombinasi hyperparameter terbaik, seperti jumlah neuron, fungsi aktivasi, learning rate, dan jumlah iterasi maksimal (Nugraha & Sasongko, 2022).

Manfaat dari proses tuning ini sangat signifikan. Dengan menemukan konfigurasi optimal dari hyperparameter, model dapat berfungsi lebih baik dalam memprediksi data baru, sehingga meningkatkan akurasi dan keandalan hasil. Selain itu, hyperparameter tuning juga dapat membantu dalam menghindari *overfitting* dengan memastikan bahwa model tidak terlalu kompleks untuk data pelatihan (Rede, 2024).

Multi Layer Perceptron (MLP) dirancang untuk memprediksi durasi tidur dengan komponen Input Layer yang jumlah 34 neuron (setelah One-Hot Encoding). Lalu Hidden Layers yang terdapat dua hidden layers masing-masing dengan 10 neuron. Terakhir ada Output Layer yang memiliki satu neuron dengan fungsi aktivasi linear tanh, yang digunakan untuk memprediksi variabel kontinu (*sleep time*). Pemilihan fungsi aktivasi tanh didasarkan pada kemampuannya menangani pola non-linear dengan baik dan membantu menjaga stabilitas pembelajaran gradien. Struktur jaringan syaraf ini dipilih berdasarkan eksperimen dan hasil *hyperparameter tuning* yang menunjukkan bahwa konfigurasi ini memberikan hasil terbaik dalam hal keseimbangan antara akurasi prediksi dan efisiensi komputasi (Schmidhuber, 2015).



Gambar 3. Diagram arsitektur MLP

Evaluasi model dilakukan dengan menghitung Mean Squared Error (MSE) dan Mean Absolute Error (MAE) pada data uji. *Mean Squared Error* (MSE) adalah metrik yang mengukur rata-rata kesalahan kuadrat dari prediksi model terhadap nilai sebenarnya. MSE merupakan salah satu fungsi loss yang umum digunakan pada model regresi karena sifatnya yang konveks, sehingga memudahkan proses optimasi dalam algoritma pembelajaran mesin. Secara matematis, MSE didefinisikan sebagai rata-rata dari kuadrat selisih antara nilai yang diobservasi dan nilai yang diprediksi (Alameer et al., 2019). Rumusnya adalah:

$$\text{Mean Squared Error (MSE)} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Pada rumus ini, y_i adalah nilai yang diobservasi, $\hat{y}_i$ adalah nilai yang diprediksi, dan n adalah jumlah pengamatan. MSE mengukur seberapa dekat prediksi model dengan nilai sebenarnya, dengan penalti lebih besar untuk kesalahan yang lebih besar karena kesalahan dikuadratkan.

Berbeda dengan MSE, MAE tidak menggunakan kuadrat pada kesalahan, sehingga tidak terlalu sensitif terhadap outlier. MAE hanya mempertimbangkan besarnya kesalahan tanpa memperhitungkan arah kesalahan (positif atau negatif) (Goodfellow et al., 2019). Proses perhitungan dilakukan sesuai dengan rumusnya yaitu:

$$\text{Mean Absolute Error (MAE)} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

Hasil dari perhitungan MSE dan MAE menunjukkan seberapa baik model dalam memprediksi data uji. Nilai MSE yang kecil menunjukkan bahwa rata-rata kesalahan kuadrat antara prediksi dan nilai sebenarnya rendah, yang berarti model mampu memberikan prediksi yang cukup akurat. Nilai MAE yang kecil menunjukkan bahwa rata-rata kesalahan absolut juga rendah, yang memberikan indikasi kuat bahwa model memberikan prediksi yang stabil dan mendekati nilai sebenarnya tanpa terpengaruh secara berlebihan oleh outlier (Nurdina et al., 2022).

HASIL DAN PEMBAHASAN


Pada penelitian ini, model Multi Layer Perceptron (MLP) dikembangkan untuk memprediksi durasi tidur berdasarkan kebiasaan harian. Setelah melalui tahapan hyperparameter tuning, diperoleh konfigurasi parameter yang memberikan hasil terbaik untuk model, sebagaimana dirangkum pada Tabel 4.

Tabel 4. Konfigurasi *Tuning Hyperparameter*

Parameter	Konfigurasi	Nilai Terbaik
Fungsi Aktivasi	tanh atau relu	tanh
Hidden Layer Sizes	(10,), (20,), (10, 10), (20, 10), (20, 20)	(10, 10)
Learning Rate	0.001, 0.01, 0.1	0.1
Max Iterations	500 atau 1000	500
Solver	adam atau sgd	adam

Model dengan konfigurasi terbaik ini menunjukkan hasil yang memuaskan dalam memprediksi durasi tidur berdasarkan data kebiasaan harian. Kombinasi ini efektif dalam menangkap pola-pola non-linear dalam data, terutama dengan pemilihan fungsi aktivasi tanh yang sesuai untuk data yang terdistribusi di sekitar nol (Schmidhuber, 2015). Pemilihan learning rate sebesar 0.1 membantu model dalam mempercepat proses konvergensi, yang penting untuk menghindari waktu komputasi yang terlalu panjang, namun tetap menjaga stabilitas dalam pembelajaran model.

Setelah proses pelatihan dan hyperparameter tuning, model dievaluasi menggunakan metrik Mean Squared Error (MSE) dan Mean Absolute Error (MAE), serta pembahasan mengenai faktor-faktor yang memengaruhi kinerja model. Setelah proses pelatihan dan tuning, model MLP dievaluasi menggunakan data uji untuk mengukur akurasi dalam memprediksi durasi tidur. Hasil evaluasi ditunjukkan pada Gambar 4. di bawah ini.



Gambar 4. Hasil evaluasi model

Dari Gambar 4. menunjukkan nilai MSE sebesar 0.065 yang berarti bahwa rata-rata kuadrat kesalahan prediksi cukup kecil, sehingga model dapat menghasilkan prediksi yang cukup akurat. Nilai MSE yang rendah mencerminkan ketepatan model dalam menyesuaikan pola-pola non-linear yang ada di antara variabel kebiasaan harian dan durasi tidur. MAE sebesar 0.204 menunjukkan bahwa rata-rata kesalahan absolut model adalah sekitar 20.4% dalam skala normalisasi. Nilai ini cukup rendah, mengindikasikan bahwa model dapat memberikan prediksi yang mendekati nilai asli durasi tidur. Secara keseluruhan, kedua metrik ini menunjukkan bahwa model telah mencapai tingkat akurasi yang cukup memadai untuk memprediksi durasi tidur berdasarkan data yang tersedia.

Untuk memberikan gambaran lebih jelas mengenai performa model, berikut adalah contoh hasil prediksi model pada beberapa sampel data uji, dengan normalisasi terbalik ke skala asli dalam satuan jam.

Tabel 5. Contoh hasil prediksi model

Sampel	Durasi Tidur Asli (Jam)	Durasi Tidur Prediksi (Jam)
1	6.0	6.37
2	5.0	7.41
3	5.0	5.90
4	8.0	5.75
5	7.0	5.19

Model menunjukkan prediksi yang cukup akurat pada beberapa sampel, seperti Sampel 1 dan Sampel 3, di mana prediksi berada dekat dengan nilai asli. Pada beberapa sampel lainnya, seperti Sampel 2 dan Sampel 5, terdapat perbedaan yang lebih signifikan antara prediksi dan nilai asli. Hal ini mengindikasikan bahwa model MLP yang digunakan mungkin masih memerlukan peningkatan dalam menangkap beberapa pola tertentu pada data kebiasaan.

KESIMPULAN

Penelitian ini berhasil mengembangkan model Multi Layer Perceptron (MLP) untuk memprediksi durasi tidur berdasarkan faktor kebiasaan harian, dengan hasil evaluasi menunjukkan Mean Squared Error (MSE) sebesar 0.065 dan Mean Absolute Error (MAE) sebesar 0.204, yang mencerminkan tingkat akurasi prediksi yang baik. Melalui hyperparameter tuning dan praproses data yang komprehensif, model dapat menangkap pola dari data kebiasaan harian secara efektif. Meski model cukup akurat pada sebagian besar sampel, beberapa prediksi menunjukkan kesalahan yang mengindikasikan adanya faktor lain, seperti kondisi kesehatan atau stres, yang mungkin juga berperan dalam memengaruhi durasi tidur tetapi tidak tercakup dalam dataset. Untuk pengembangan lebih lanjut, direkomendasikan untuk menambah jumlah data latih dan memasukkan fitur-fitur tambahan yang lebih berhubungan langsung dengan durasi tidur. Selain itu, eksplorasi model prediksi lain seperti Random Forest atau Gradient Boosting dapat menjadi langkah berikutnya untuk meningkatkan akurasi prediksi.

DAFTAR PUSTAKA

- Alameer, Z., Elaziz, M. A., Ewees, A. A., Ye, H., & Jianhua, Z. (2019). Forecasting gold price fluctuations using improved multilayer perceptron neural network and whale optimization algorithm. *Resources Policy*, 61(September 2018), 250–260. <https://doi.org/10.1016/j.resourpol.2019.02.014>
- Anggelia, D. A., Kusmaedi, N., & Indonesia, U. P. (2017). *Hubungan Aktivitas Fisik Dengan Indeks*. 01, 227–234.
- Bagheri, S., Taridashti, S., Farahani, H., Watson, P., & Rezvani, E. (2023). Multilayer perceptron modeling for social dysfunction prediction based on general health factors in an Iranian women sample. *Frontiers in Psychiatry*, 14(December), 1–12. <https://doi.org/10.3389/fpsyt.2023.1283095>
- Bonanni, O., Mullen, M., Falcon, T., Huang, H., Lowry, A., & Perron, T. (2022). Caffeine: Effects on sleep and academic performance in college students. *British Journal of Child Health*, 3(6), 281–285. <https://doi.org/10.12968/chhe.2022.3.6.281>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 13-17-August-2016, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Columbia University Department of Psychiatry. (2022). *How Sleep Deprivation Impacts Mental Health*. Columbia University Department of Psychiatry. <https://www.columbiapsychiatry.org/news/how-sleep-deprivation-affects-your-mental-health>
- Fadhilah, N., Salam, A., & Trisasmita, L. (2023). Gambaran kebiasaan sarapan dan durasi tidur pada remaja status gizi lebih di smp muhammadiyah limbung. *The Journal of Indonesian Community Nutrition*, 12(2), 93–105.
- Fitriyani, Fathurrahman, A., & Mandala, Z. (2024). Gambaran Kualitas Tidur Pada Mahasiswa Pendidikan ProfesiDokter Di Rumah Sakit Pertamina Bintang Amin. *Jurnal Ilmu Kedokteran dan Kesehatan*, 11(6), 2549–4864. <http://ejournalmalahayati.ac.id/index.php/kesehatan>
- Frank, S., Gonzalez, K., Lee-Ang, L., Young, M. C., Tamez, M., & Mattei, J. (2017). Diet and sleep physiology: Public health and clinical implications. *Frontiers in Neurology*, 8(AUG), 1–9. <https://doi.org/10.3389/fneur.2017.00393>
- Goodfellow, I., Beggio, Y., & Courville, A. (2019). Deep learning. *Nature*, 29(7553), 1–73.
- Gulo, S. H., & Lubis, A. H. (2024). Penerapan Multi-Layer Perceptron untuk Mengklasifikasi Penduduk Kurang Mampu. *Explorer*, 4(2), 51–59.
- Kilic, O., Saylam, B., & Durmaz Incel, O. (2023). Sleep Quality Prediction from Wearables using

- Convolution Neural Networks and Ensemble Learning. *ACM International Conference Proceeding Series*, 116–120. <https://doi.org/10.1145/3589883.3589900>
- Kudrnáčová, M., & Kudrnáč, A. (2023). Better sleep, better life? testing the role of sleep on quality of life. *PLoS ONE*, 18(3 March), 1–18. <https://doi.org/10.1371/journal.pone.0282085>
- Nugraha, W., & Sasongko, A. (2022). Hyperparameter Tuning pada Algoritma Klasifikasi dengan Grid Search Hyperparameter Tuning on Classification Algorithm with Grid Search. *SISTEMASI: Jurnal Sistem Informasi*, 11(2), 391–401. <http://sistemasi.ftik.unisi.ac.id>
- Nurdina, A., Aryani, D., Venita, E., & Astiti, S. (2022). Analisis Peramalan Permintaan Golang-Galing dalam Memaksimalkan Manajemen Rantai Pasok Menggunakan Metode Weighted Moving Average. *JURIKOM (Jurnal Riset Komputer)*, 9(4), 1167. <https://doi.org/10.30865/jurikom.v9i4.4551>
- Okano, K., Kaczmarzyk, J. R., Dave, N., Gabrieli, J. D. E., & Grossman, J. C. (2019). Sleep quality, duration, and consistency are associated with better academic performance in college students. *npj Science of Learning*, 4(1). <https://doi.org/10.1038/s41539-019-0055-z>
- Pardede, D., Hayadi, B. H., & Iskandar. (2022). Kajian Literatur Multi Layer Perceptron Seberapa Baik Performa Algoritma Ini. *Journal of Ict Applications and System*, 1(1), 23–35. <https://doi.org/10.56313/jictas.v1i1.127>
- Putri, P. A. (2022). Hubungan Pola Konsumsi Makanan Tinggi Kalori dan Kopi, Durasi Tidur, dan Tingkat Stress dengan Status Gizi Pada Mahasiswa Tingkat Akhir. *Media Gizi Kesmas*, 11(02), 464–474.
- Rahmawati, E., Firdaningrum, N. E., & Agoes, A. (2021). Hubungan antara Durasi Tidur dengan Asupan Makan, Aktivitas Fisik dan Kejadian Obesitas Pada Mahasiswa Program Studi Pendidikan Dokter UIN Maulana Malik Ibrahim Malang. *Journal of Islamic Medicine*, 5(1), 9–19. <https://doi.org/10.18860/jim.v5i1.11674>
- Ramar, K., Malhotra, R. K., Carden, K. A., Martin, J. L., Abbasi-Feinberg, F., Aurora, R. N., Kapur, V. K., Olson, E. J., Rosen, C. L., Rowley, J. A., Shelgikar, A. V., & Trotti, L. M. (2021). Sleep is essential to health: An American Academy of Sleep Medicine position statement. *Journal of Clinical Sleep Medicine*, 17(10), 2115–2119. <https://doi.org/10.5664/jcsm.9476>
- Rede, A. (2024). *Tutorial on Hyperparameter Tuning Using scikit-learn*. Georgia Tech. <https://sites.gatech.edu/omscs7641/2024/02/16/tutorial-on-hyperparameter-tuning-using-scikit-learn/>
- Sara, K., Risma, R., & Sutisna, N. (2020). Hubungan Durasi Tidur dan Perilaku Sedentari dengan Body Mass Index pada Siswa SMA Negeri 3 Ciamis. *Jurnal Terapan Ilmu Keolahragaan*, 5(2), 120–127. <https://doi.org/10.17509/jtikor.v5i2.27960>
- Sari, D. (2024). Prediksi Gangguan Tidur pada Sleep Health and Lifestyle Menggunakan Support Vector Machine dan Neural Network. *JAVIT: Jurnal Vokasi Informatika*, 36–42. <https://doi.org/10.24036/javit.v4i1.168>
- Schmidhuber, J. (2015). Deep Learning in neural networks: An overview. *Neural Networks*, 61, 85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Sharma, P. (2023). *One Hot Encoding and Label Encoding Explained*. tutorialspoint. <https://www.tutorialspoint.com/one-hot-encoding-and-label-encoding-explained>
- Singh, D., & Singh, B. (2020). Investigating the impact of data normalization on classification performance. *Applied Soft Computing*, 97(xxxx), 105524. <https://doi.org/10.1016/j.asoc.2019.105524>
- Wulansih, N. C., Raisa Zharfan, F., Wikrama Aurelia Biyang, A., Ratri Anggraini, M., & Kharin Herbawani, C. (2024). Tinjauan Literatur: Dampak Durasi dan Kualitas Tidur yang Buruk Pada Kesehatan Tubuh Usia Produktif Literature Review: The Impact of Poor Sleep Duration and Quality on Health in Productive Age. 12(1), 71–82.