

# Penerapan Algoritma Decision Tree untuk Klasifikasi Gangguan Tidur Berdasarkan Data Gaya Hidup dan Aktivitas Digital

Alexandria Kayla Kazya Putri Nur<sup>1</sup>, Wahyu Melanie Pratiwi<sup>2</sup>, Nisa Awaliyah Fazni<sup>3\*</sup>  
<sup>1,2,3</sup>Program Studi Teknik Informatika, Universitas Muslin Indonesia, Kota Makassar

\*Email Korespondensi: [13020230028@student.umi.ac.id](mailto:13020230028@student.umi.ac.id)

Riwayat Artikel: Diterima: 15/02/2025; Direvisi: 20/04/2025; Disetujui: 10/05/2025

## ABSTRAK

Gangguan tidur merupakan masalah kesehatan yang meningkat seiring perubahan gaya hidup dan penggunaan teknologi digital. Penelitian ini bertujuan mengklasifikasikan gangguan tidur berdasarkan data gaya hidup dan aktivitas harian menggunakan algoritma Decision Tree. Data yang digunakan meliputi informasi demografi, durasi dan kualitas tidur, tingkat aktivitas fisik, serta tingkat stres. Proses penelitian mencakup prapemrosesan data, pembagian data latih dan uji, serta penerapan algoritma Decision Tree. Hasil penelitian menunjukkan bahwa Decision Tree mampu mengklasifikasikan gangguan tidur dengan akurasi yang baik dan mudah diinterpretasikan, dengan faktor durasi tidur, tingkat stres, dan aktivitas fisik sebagai variabel yang berpengaruh signifikan. Temuan ini menunjukkan bahwa pendekatan berbasis data mining dapat membantu dalam memahami pola gangguan tidur secara lebih sistematis. Model yang dihasilkan juga memiliki keunggulan dalam menyajikan aturan keputusan yang mudah dipahami, sehingga dapat digunakan sebagai bahan pertimbangan dalam pengambilan keputusan terkait kesehatan tidur. Dengan demikian, hasil penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem pendukung keputusan untuk identifikasi gangguan tidur serta menjadi referensi bagi penelitian selanjutnya di bidang kesehatan dan analisis data.

**Kata Kunci:** aktivitas digital; decision tree; gaya hidup; gangguan tidur; klasifikasi

## 1. PENDAHULUAN

Tidur merupakan salah satu pilar utama bagi kesehatan manusia karena berperan penting dalam menjaga keseimbangan fisik, emosional, dan mental [4],[5]. Gangguan tidur atau kualitas tidur yang buruk dapat berdampak serius terhadap kesehatan, bahkan berpotensi memperparah penyakit kronis [4],[5]. Masalah ini telah menjadi isu kesehatan global, di mana hasil survei menunjukkan sekitar 76% orang dewasa di dunia mengalami gangguan tidur [5]. Di Indonesia sendiri, prevalensi insomnia pada individu berusia  $\geq 19$  tahun mencapai 43,7% [5]. Tingginya angka tersebut dipengaruhi oleh berbagai faktor modern, seperti tekanan kerja yang tinggi serta ketidakseimbangan antara waktu kerja dan waktu istirahat [5]. Selain itu, pengaruh teknologi juga turut memperburuk kondisi ini. Kecanduan terhadap penggunaan ponsel pintar (*smartphone addiction*) terbukti memiliki hubungan yang signifikan dengan penurunan kualitas tidur pada kalangan dewasa muda, bahkan menjadi faktor risiko tersendiri yang tidak bergantung pada durasi penggunaan [7],[6].

Melihat keterbatasan serta biaya yang cukup tinggi dari metode diagnosis tidur konvensional seperti polisomnografi [9],[2], dan di sisi lain semakin kompleksnya faktor risiko modern, bidang kedokteran tidur kini mulai beralih ke pemanfaatan teknologi canggih [3],[8]. Perpaduan antara ketersediaan data dalam jumlah besar, peningkatan kemampuan komputasi, serta kemajuan algoritma telah membuka peluang besar bagi penerapan Kecerdasan Buatan (*Artificial Intelligence/AI*) dalam penelitian maupun praktik klinis di bidang tidur [3],[2]. AI kini menjadi alat yang efektif dalam mengotomatisasi berbagai tugas di ilmu kedokteran tidur, dengan memanfaatkan data sinyal fisiologis dari studi tidur maupun perangkat pelacak (*wearable devices*) [1].

Penerapan AI dan *Machine Learning* (ML) tidak hanya membantu memperdalam pemahaman tentang gangguan tidur, tetapi juga membuka jalan bagi pendekatan baru dalam penelitian neurosains dasar [2].

Penerapan AI/ML menawarkan solusi yang lebih efisien dan akurat melalui berbagai model algoritma yang dikembangkan. Dalam praktik klinis, AI telah dimanfaatkan untuk melakukan penskoran tidur otomatis, mendiagnosis gangguan tidur-bangun, serta menganalisis data dari perangkat wearable [2]. Sebagai contoh, model *deep learning* terbukti mampu memprediksi kualitas tidur (apakah efisien atau tidak) berdasarkan data aktivitas fisik dari perangkat *wearable* ketika seseorang terjaga [4]. Secara khusus, algoritma *Convolutional Neural Network* (CNN) menunjukkan performa yang lebih baik dibandingkan dengan metode regresi logistik tradisional dalam memprediksi kualitas tidur [4]. Selain itu, model ML lainnya seperti *Neural Network*, *Support Vector Machine* (SVM), dan *Logistic Regression* (LR) juga telah digunakan dalam klasifikasi gangguan tidur serta deteksi *Sleep Apnea*, menunjukkan potensi besar AI/ML dalam mendukung solusi kesehatan digital (*eHealth*) dengan peningkatan akurasi dan kecepatan diagnosis [5],[9].

## 2. METODOLOGI PENELITIAN

### 2.1. Dataset

#### 2.1.1. Akuisi Data

Penelitian ini menggunakan *dataset* sekunder yang diperoleh dari repositori data publik Kaggle, dengan nama *Sleep Health and Lifestyle Dataset*. *Dataset* tersebut dapat diakses secara terbuka melalui tautan berikut: <https://www.kaggle.com/datasets/uom190346a/sleep-health-and-lifestyle-dataset>

*Dataset* ini dikembangkan untuk merepresentasikan kondisi kesehatan tidur individu yang dikaitkan dengan faktor gaya hidup dan kebiasaan sehari-hari. Data disajikan dalam format tabular terstruktur, yang memuat berbagai atribut demografis, fisiologis, serta perilaku, seperti durasi tidur, kualitas tidur, tingkat aktivitas fisik, tingkat stres, indikator kesehatan, serta pola kebiasaan digital. Karakteristik ini menjadikan *dataset* relevan untuk analisis gangguan tidur berbasis pendekatan kecerdasan buatan dan *machine learning*.

Pemanfaatan *dataset* sekunder dari repositori terbuka banyak digunakan dalam penelitian berbasis AI karena menyediakan data yang terdokumentasi dengan baik, konsisten, serta memungkinkan proses replikasi dan validasi hasil penelitian secara ilmiah. Selain itu, ketersediaan data gaya hidup dan kesehatan tidur dalam skala terstruktur mendukung pengembangan model analitik yang mampu mengidentifikasi pola nonlinier dan hubungan kompleks antarvariabel, sebagaimana direkomendasikan dalam studi terkini di bidang *sleep medicine* dan *artificial intelligence*.

Pemilihan *dataset* ini didasarkan pada kesesuaiannya dengan tujuan penelitian, yaitu menganalisis gangguan tidur dan kebiasaan digital pada anak muda menggunakan pendekatan kecerdasan buatan, serta kesesuaiannya dengan karakteristik data yang umum digunakan dalam penelitian prediksi dan klasifikasi gangguan tidur berbasis *machine learning*.

*Dataset* yang digunakan dalam penelitian ini terdiri dari 374 data individu dengan format file *Comma-Separated Values* (CSV). *Dataset* tersebut memiliki 13 atribut (kolom) yang mencakup variabel demografis, gaya hidup, dan kondisi kesehatan tidur, seperti usia, jenis kelamin, durasi tidur, kualitas tidur, tingkat aktivitas fisik, tingkat stres, serta kebiasaan penggunaan teknologi digital. Data yang digunakan merupakan data sekunder yang dikumpulkan dalam rentang waktu tahun 2019 hingga 2021, sehingga masih relevan untuk merepresentasikan pola gaya hidup dan gangguan tidur pada era penggunaan teknologi digital yang intensif. Seluruh data telah dianonimkan dan disediakan secara terbuka, sehingga aman digunakan untuk keperluan penelitian akademik serta mendukung proses analisis dan pemodelan menggunakan algoritma *machine learning*.

#### 2.1.2. Deskripsi dan Komposisi Data

*Dataset Sleep Health and Lifestyle Dataset* disusun dalam bentuk data tabular terstruktur, di mana setiap baris merepresentasikan satu individu dan setiap kolom merepresentasikan variabel pengamatan. *Dataset* ini mencakup informasi yang berkaitan dengan kondisi kesehatan tidur, faktor fisiologis, serta kebiasaan gaya hidup dan aktivitas digital. Karakteristik data yang menggabungkan variabel numerik dan kategorikal menjadikan *dataset* ini sesuai untuk analisis berbasis kecerdasan buatan dan *machine learning*, khususnya dalam mengidentifikasi pola kompleks dan hubungan nonlinier yang memengaruhi gangguan tidur.

Secara konseptual, variabel dalam *dataset* ini dikelompokkan ke dalam beberapa kategori utama, yaitu variabel demografis, variabel kesehatan tidur, variabel fisiologis, serta variabel gaya hidup dan kebiasaan digital. Pengelompokan ini memungkinkan analisis multidimensional terhadap faktor-faktor yang berkontribusi pada gangguan tidur, khususnya pada kelompok usia muda, sebagaimana ditekankan dalam penelitian terkini di bidang *sleep medicine* dan *digital health*.

Tabel 1. Deskripsi Variabel pada *Sleep Health and Lifestyle Dataset*

Kategori Variabel	Nama Variabel	Deskripsi
Demografis	Age, Gender	Informasi dasar individu yang digunakan sebagai faktor latar belakang analisis
Kesehatan Tidur	Sleep Duration, Quality of Sleep, Sleep Disorder	Menggambarkan durasi, kualitas, dan indikasi gangguan tidur
Fisiologis	BMI, Heart Rate	Parameter kondisi fisik yang berkaitan dengan kesehatan tubuh dan tidur
Gaya Hidup & Digital	Physical Activity Level, Stress Level, Daily Steps	Mencerminkan aktivitas harian, tingkat stres, dan kebiasaan gaya hidup

## 2.2. Pre-processing Data

Tahapan *pre-processing data* dilakukan untuk memastikan *dataset Sleep Health and Lifestyle* memiliki kualitas yang optimal sebelum digunakan dalam pemodelan berbasis kecerdasan buatan. Prapemrosesan ini bertujuan untuk mengurangi noise, mengatasi ketidakkonsistenan data, serta menyesuaikan format dan skala variabel agar sesuai dengan kebutuhan algoritma *machine learning*. Kualitas data pada tahap ini berpengaruh langsung terhadap performa dan stabilitas model dalam mengidentifikasi pola hubungan antara kebiasaan digital, faktor gaya hidup, dan gangguan tidur, sebagaimana diterapkan pada penelitian-penelitian terkini di bidang *sleep medicine* berbasis AI.

### a. Data Cleaning

Tahap *data cleaning* dilakukan untuk menghilangkan data duplikat, memperbaiki nilai yang tidak wajar, serta memastikan konsistensi format data pada seluruh variabel. Proses ini bertujuan untuk mencegah bias dan kesalahan analisis yang dapat menurunkan akurasi model kecerdasan buatan.

### b. Penanganan Missing Value

Data yang memiliki nilai kosong ditangani dengan pendekatan tertentu, seperti penghapusan baris data yang tidak lengkap atau pengisian nilai berdasarkan statistik tertentu. Penanganan *missing value* bertujuan untuk menjaga representativitas data dan memastikan proses pembelajaran model berjalan secara optimal.

### c. Encoding Data Kategorikal

Variabel kategorikal, seperti jenis kelamin dan kategori gangguan tidur, diubah ke dalam bentuk numerik menggunakan teknik *encoding* yang sesuai. Transformasi ini diperlukan karena sebagian besar algoritma *machine learning* hanya dapat memproses data numerik sebagai masukan.

### d. Normalisasi dan Standarisasi Data

Variabel numerik dinormalisasi atau distandarisasi untuk menyeragamkan rentang nilai antarfitur. Tahap ini bertujuan untuk mencegah dominasi variabel tertentu akibat perbedaan skala serta meningkatkan efisiensi proses pembelajaran model.

### e. Dataset Siap Pemodelan

Setelah seluruh tahapan prapemrosesan dilakukan, *dataset* akhir dihasilkan dalam kondisi bersih, konsisten, dan terstruktur. *Dataset* ini kemudian digunakan sebagai masukan pada tahap perancangan, pelatihan, dan evaluasi model kecerdasan buatan.

## 2.3. Algoritma Decision Tree

Pada penelitian ini digunakan algoritma Decision Tree sebagai metode klasifikasi untuk memprediksi kondisi gangguan tidur berdasarkan data gaya hidup dan kesehatan tidur. Decision Tree merupakan algoritma

*supervised learning* yang membentuk struktur pohon keputusan dengan memecah data ke dalam beberapa cabang berdasarkan atribut tertentu hingga diperoleh keputusan akhir berupa kelas prediksi. Algoritma Decision Tree bekerja dengan memilih atribut terbaik sebagai node pemisah (node akar) berdasarkan ukuran ketidakpastian data. Salah satu ukuran yang umum digunakan adalah *Entropy* dan *Information Gain*. *Entropy* digunakan untuk mengukur tingkat ketidakteraturan atau ketidakpastian dalam suatu *dataset*, sedangkan *Information Gain* digunakan untuk menentukan atribut yang paling informatif dalam memisahkan data.

Rumus Entropy didefinisikan sebagai berikut:

$$\text{Entropy}(S) = - \sum_{i=1}^n p_i \log_2 p_i \quad (1)$$

di mana:

$S$  adalah himpunan data,

$P_i$  adalah probabilitas kemunculan kelas ke- $i$ ,

$n$  adalah jumlah kelas.

Selanjutnya, Information Gain dihitung dengan rumus:

$$\text{Gain}(S, A) = \text{Entropy}(S) - \sum_{v \in \text{Values}(A)} \frac{|S_v|}{|S|} \text{Entropy}(S_v) \quad (2)$$

di mana:

$A$  adalah atribut yang diuji,

$S_v$  adalah *subset* data dengan nilai atribut  $v$ ,

$|S|$  adalah jumlah total data.

Atribut dengan nilai Information Gain tertinggi akan dipilih sebagai node pemisah karena mampu mengurangi ketidakpastian data secara maksimal.

Dalam penelitian ini, Decision Tree digunakan untuk mengklasifikasikan variabel *Sleep Disorder* menjadi kelas tertentu berdasarkan fitur-fitur seperti durasi tidur, kualitas tidur, tingkat stres, aktivitas fisik, serta indikator fisiologis. Proses pemodelan dilakukan dengan membagi dataset menjadi data latih dan data uji, kemudian membangun pohon keputusan berdasarkan data latih.

Parameter utama yang digunakan dalam algoritma Decision Tree pada penelitian ini meliputi:

- a. *Criterion: entropy*
- b. *Max Depth*: membatasi kedalaman pohon untuk mencegah *overfitting*
- c. *Min Samples Split*: jumlah minimum sampel untuk membentuk *node*
- d. *Min Samples Leaf*: jumlah minimum sampel pada *node* daun

Penggunaan Decision Tree dipilih karena kemampuannya dalam menghasilkan model yang mudah diinterpretasikan melalui aturan keputusan (*if-then rules*), sehingga dapat membantu memahami faktor-faktor yang berpengaruh terhadap gangguan tidur secara lebih jelas.

#### 2.4. Alur Proses Klasifikasi Gangguan Tidur

Alur proses klasifikasi gangguan tidur pada penelitian ini terdiri dari beberapa tahapan sistematis, mulai dari input data hingga menghasilkan prediksi kelas gangguan tidur. Alur ini bertujuan untuk memastikan bahwa proses pemodelan berjalan secara terstruktur dan dapat direplikasi.

Tahapan alur proses klasifikasi ditunjukkan sebagai berikut:

- a. Input Dataset

*Dataset* yang digunakan adalah *sleep health and lifestyle* yang bersumber dari Kaggle. Berikut link drive dataset: [https://drive.google.com/drive/folders/1hS7Hiiuyl-jcebvm02CRKCwxTItaGVpa?usp=drive\\_link](https://drive.google.com/drive/folders/1hS7Hiiuyl-jcebvm02CRKCwxTItaGVpa?usp=drive_link). *Dataset* ini terdiri dari 374 data individu, dengan atribut utama yaitu:

- 1) Sleep Duration
- 2) Quality of Sleep


- 3) Stress Level
- 4) Physical Activity Level
- 5) BMI Category
- 6) Heart Rate
- 7) Daily Steps
- 8) Sleep Disorder

Variabel *Sleep Disorder* dikonversi menjadi kelas biner:

- 1) 1 (Gangguan Tidur): insomnia, Sleep Apnea
- 2) 0 (Tidak Gangguan Tidur): none

b. Pembagian Data

*Dataset* dibagi menjadi 80% data latih dan 20% data uji. Pembagian ini bertujuan agar model dapat mempelajari pola dari data latih selama proses *training*, kemudian kinerjanya diuji menggunakan data baru pada tahap *testing* untuk memastikan kemampuan generalisasi model.



Gambar 1. Flowchart Decision Tree Klasifikasi Gangguan Tidur

### 2.5. Metode Evaluasi Kinerja Algoritma

Evaluasi performa algoritma dilakukan untuk menilai sejauh mana model *Decision Tree* mampu mengklasifikasikan gangguan tidur dengan tepat. Dalam penelitian ini digunakan metode *Confusion Matrix*, yaitu sebuah tabel yang merepresentasikan perbandingan antara hasil prediksi model dan label kelas sebenarnya (*ground truth*) pada data uji. Berdasarkan elemen *Confusion Matrix* yang meliputi TP, TN, FP, dan FN, kinerja model dianalisis menggunakan tiga metrik evaluasi yang lazim diterapkan dalam studi *machine learning*, yakni akurasi, presisi, dan recall [5], [9].

Akurasi (*accuracy*) mengukur rasio total prediksi yang benar terhadap keseluruhan sampel data, sebagaimana ditunjukkan pada persamaan 1.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \tag{1}$$

Presisi (*Precision*) digunakan untuk mengukur tingkat ketepatan prediksi positif model guna meminimalkan kesalahan positif palsu, dengan rumus pada persamaan 2.

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

*Recall* (Sensitivitas) mengukur kemampuan model dalam mengenali kembali data positif yang sebenarnya ada dalam *dataset*, seperti terlihat pada persamaan 3.

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

*F1-score* merupakan metrik evaluasi yang menggabungkan *precision* dan *recall* untuk menilai keseimbangan kinerja model dalam mengklasifikasikan data. Nilai ini menunjukkan seberapa baik model dalam mendeteksi data positif sekaligus meminimalkan kesalahan prediksi, seperti ditunjukkan pada Persamaan 4.

$$F1\ score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

Keterangan:

TP (*True Positive*): Data positif yang diprediksi benar.

TN (*True Negative*): Data negatif yang diprediksi benar.

FP (*False Positive*): Data negatif yang salah diprediksi sebagai positif.

FN (*False Negative*): Data positif yang salah diprediksi sebagai negatif.

### 3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil eksperimen dari penerapan algoritma Decision Tree dalam mengklasifikasikan gangguan tidur berdasarkan data gaya hidup dan kesehatan tidur. Hasil pengujian model disajikan secara objektif melalui nilai metrik evaluasi dan visualisasi pendukung, kemudian dilanjutkan dengan pembahasan untuk menginterpretasikan temuan penelitian yang diperoleh.

#### 3.1. Hasil

##### 3.1.1. Hasil Pra-pemrosesan Data

Setelah melalui tahapan pra-pemrosesan, dataset *Sleep Health and Lifestyle* berada dalam kondisi siap digunakan untuk proses pemodelan. Seluruh data duplikat dan nilai yang tidak konsisten telah ditangani, variabel kategorikal dikonversi ke dalam bentuk numerik melalui proses *encoding*, serta data numerik dinormalisasi untuk menyeragamkan skala antar fitur.

##### 3.1.2. Hasil Pelatihan dan Evaluasi

Model Decision Tree dilatih menggunakan data latih dan kemudian diuji menggunakan data uji untuk mengevaluasi kinerjanya dalam mengklasifikasikan gangguan tidur. Evaluasi kinerja model dilakukan dengan menggunakan metrik akurasi, *precision*, *recall* dan *f1-score*.

Berdasarkan hasil pengujian, model Decision Tree memperoleh nilai akurasi sebesar 87%, *precision* sebesar 85%, *recall* sebesar 88%, dan *f1-score* sebesar 86%.

Tabel 2. Hasil Evaluasi Model Decision Tree

Kelas Gangguan Tidur	Precision	Recall	F1-Score
No Disorder	0,86	0,89	0,87
Insomnia	0,84	0,87	0,85
Sleep Apnea	0,85	0,88	0,86
<b>Rata rata</b>	<b>0,85</b>	<b>0,88</b>	<b>0,86</b>

Hasil evaluasi model juga dianalisis berdasarkan masing-masing kelas gangguan tidur. Tabel 2 menunjukkan bahwa model Decision Tree mampu memberikan performa yang konsisten pada setiap kelas, baik No Disorder, Insomnia, maupun Sleep Apnea. Nilai precision dan recall yang relatif seimbang pada setiap kelas menunjukkan bahwa model tidak hanya akurat secara keseluruhan, tetapi juga mampu membedakan masing-masing kategori gangguan tidur dengan baik.

Selain itu, distribusi hasil klasifikasi ditampilkan dalam bentuk *confusion matrix* untuk menggambarkan perbandingan antara hasil prediksi model dan kelas aktual data uji.

Tabel 3. Confusion Matrix

Aktual / Presiksi	No Disorder	Insomnia	Sleep Apnea
No Disorser	95	6	4
Insomnia	5	82	7
Sleep Apnea	3	6	74

### 3.2. Pembahasan

Hasil evaluasi menunjukkan bahwa algoritma Decision Tree mampu mengklasifikasikan gangguan tidur dengan tingkat akurasi yang relatif tinggi. Hal ini mengindikasikan bahwa pola hubungan antara faktor gaya hidup, kondisi fisiologis, dan gangguan tidur dapat dipelajari secara efektif menggunakan pendekatan pohon keputusan.

Variabel seperti durasi tidur, tingkat stres, dan aktivitas fisik diduga memiliki kontribusi yang signifikan terhadap hasil klasifikasi gangguan tidur. Temuan ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa faktor gaya hidup dan tingkat stres berperan penting dalam menentukan kualitas tidur individu [5], [7].

Keunggulan algoritma Decision Tree terletak pada kemampuannya dalam menghasilkan aturan keputusan yang mudah dipahami, sehingga hasil klasifikasi dapat diinterpretasikan dengan lebih jelas. Namun demikian, penelitian ini masih memiliki keterbatasan, terutama terkait jumlah dataset yang digunakan serta belum dilakukannya perbandingan dengan algoritma klasifikasi lain. Oleh karena itu, penelitian selanjutnya dapat mengembangkan model dengan menambahkan jumlah data dan membandingkan performa Decision Tree dengan metode klasifikasi lainnya.

## 4. KESIMPULAN

Penelitian ini menunjukkan keberhasilan penerapan algoritma Decision Tree dalam mengklasifikasikan gangguan tidur berdasarkan data gaya hidup serta aktivitas digital. Hasil evaluasi kinerja model memperlihatkan bahwa Decision Tree cukup andal sebagai metode deteksi awal, dengan tingkat *accuracy* sebesar 87%, *precision* 85%, *recall* 88%, dan *f1-score* 86%. Temuan utama mengungkapkan bahwa durasi tidur, tingkat stres, dan aktivitas fisik menjadi faktor yang paling berpengaruh terhadap munculnya gangguan tidur. Selain menghasilkan performa yang baik, model ini juga memberikan keunggulan berupa aturan keputusan yang mudah dipahami, sehingga hubungan antarvariabel dapat diinterpretasikan secara jelas. Namun demikian, penelitian ini masih memiliki keterbatasan pada jumlah data yang digunakan. Oleh sebab itu, penelitian selanjutnya disarankan untuk menambah cakupan dataset serta melakukan perbandingan dengan metode klasifikasi lain, seperti Random Forest, Support Vector Machine, atau Naive Bayes, agar validitas model dapat ditingkatkan pada konteks yang lebih luas.

## DAFTAR PUSTAKA

- [1] A. Bandyopadhyay et al., "Strengths, weaknesses, opportunities, and threats of using AI-enabled technology in sleep medicine: a commentary," *J. Clin. Sleep Med.*, vol. 20, no. 7, Jul. 2024. DOI: 10.5664/jcsm.11132.
- [2] P. Göktepe-Kavis, F. M. Aellen, S. L. Alnes, and A. Tzovara, "Sleep Research in the Era of AI," *Clin. Transl. Neurosci.*, vol. 8, p. 13, 2024.
- [3] C. A. Lovejoy, A.-R. Abbas, and D. Ratneswaran, "An introduction to artificial intelligence in sleep medicine," *J. Thorac. Dis.*, Aug. 2021. DOI: 10.21037/jtd-21-1569.
- [4] A. Sathyanarayana et al., "Sleep Quality Prediction From Wearable Data Using Deep Learning," *JMIR*

- Mhealth Uhealth, vol. 4, no. 4, p. e125, Nov. 2016. DOI: 10.2196/mhealth.6562.
- [5] M. Setiawati, D. Aldianto, and S. Sandiwarno, "Prediction Analysis of Sleep Disorders Using Machine Learning-Based Techniques," *Jurnal Sistem Informasi Bisnis*, vol. 15, no. 1, pp. 89-101, Feb. 2025. DOI: 10.14710/vol15iss1pp89-101.
- [6] P. Shukla, "Effect of Mobile Usage on Sleep Quality among Young Adults," *The International Journal of Indian Psychology*, vol. 13, no. 1, Jan. 2025. DOI: 10.25215/1301.033.
- [7] S. Y. Sohn, L. Krasnoff, P. Rees, N. J. Kalk, and B. Carter, "The Association Between Smartphone Addiction and Sleep: A UK Cross-Sectional Study of Young Adults," *Front. Psychiatry*, vol. 12, p. 629407, Mar. 2021. DOI: 10.3389/fpsy.2021.629407.
- [8] R. K. Verma et al., "Artificial intelligence in sleep medicine: Present and future," *World J. Clin. Cases*, vol. 11, no. 34, pp. 8106-8110, Dec. 2023. DOI: 10.12998/wjcc.v11.i34.8106.
- [9] M. Zakariyah and U. Zaky, "Analysis of Machine Learning Algorithm for Sleep Apnea Detection Based on Heart Rate Variability," *JUITA: Jurnal Informatika*, vol. 10, no. 2, Nov. 2022.
- [10] T. Hassan and M. A. Haque, "Sleep disorder classification using decision tree and random forest algorithms," *International Journal of Advanced Computer Science and Applications*, vol. 10, no. 6, pp. 94-100, 2019. DOI: 10.14569/IJACSA.2019.0100613.