

PREDIKSI FAKTOR RISIKO GANGGUAN TIDUR MENGGUNAKAN PENDEKATAN *MACHINE LEARNING LOGISTIC REGRESSION* DAN *GRADIENT BOOSTING*

Reza Fitriansyah¹, R Tommy Gumelar², Amrizal³,

^{1,2}Teknologi Informasi, Fakultas Teknik dan Desain, Institut Teknologi Dan Bisnis Ahmad Dahlan

³ Akutansi, Fakultas Ekonomi dan Bisnis, Institut Teknologi Dan Bisnis Ahmad Dahlan

Email: rezajurnal91@gmail.com¹, tommy_gumelar@yahoo.com², amrizal@itb-ad.ac.id³

***Koresponden Author:** Reza Fitriansyah, rezajurnal91@gmail.com

Accepted: 08 31, 2025 ; Revised: 08 30, 2025; Published: 08 31, 2025

Abstrak

Gangguan tidur merupakan masalah kesehatan yang berdampak luas pada kualitas hidup, produktivitas, serta risiko penyakit kronis. Penelitian ini bertujuan untuk memprediksi faktor risiko gangguan tidur dengan pendekatan machine learning menggunakan data survei dari National Sleep Foundation. Tahapan penelitian meliputi pembersihan data, Transformasi, normalisasi, serta pembagian data menjadi training (80%) dan testing (20%). Dua algoritma digunakan, yaitu Logistic Regression dan Gradient Boosting, dengan evaluasi kinerja berdasarkan metrik Accuracy, Precision, Recall, dan F1-score, serta interpretabilitas model melalui analisis SHAP. Hasil menunjukkan bahwa Gradient Boosting memberikan performa terbaik dengan akurasi dan F1-score sempurna (1.00), sementara Logistic Regression hanya mencapai akurasi 0.70. Analisis SHAP mengungkap bahwa durasi dan kualitas tidur merupakan faktor paling dominan yang memengaruhi risiko gangguan tidur, disusul konsumsi kafein dan usia. Dengan demikian, model berbasis Gradient Boosting tidak hanya mampu mengklasifikasikan risiko dengan sangat akurat, tetapi juga memberikan wawasan komprehensif mengenai faktor determinan gangguan tidur, sehingga dapat menjadi dasar intervensi kesehatan yang lebih efektif.

Kata kunci: Gangguan Tidur, Machine learning, Logistic Regression, Gradient Boosting, SHAP

Abstract

[PREDICTION OF SLEEP DISORDER RISK FACTORS USING MACHINE LEARNING APPROACH: LOGISTIC REGRESSION AND GRADIENT BOOSTING] Sleep disorders are one of the major public health issues with broad implications for quality of life, productivity, and chronic disease risks. This study aims to predict risk factors of sleep disorders using a machine learning approach with survey data from the National Sleep Foundation. The research process involved data Cleaning, traNSFormation, normalization, and splitting into training (80%) and testing (20%) sets. Two algorithms were applied, Logistic Regression and Gradient Boosting, and their performance was evaluated using Accuracy, Precision, Recall, and F1-score metrics. SHAP analysis was also employed to assess variable contributions to model predictions. The results indicate that Gradient Boosting outperformed Logistic Regression, achieving perfect Accuracy and F1-score (1.00), while Logistic Regression only reached 0.70. SHAP analysis revealed that sleep duration and quality are the most influential factors, followed by caffeine consumption and age. Therefore, Gradient Boosting not only provides accurate classification but also comprehensive insights into key determinants of sleep disorders, serving as a foundation for more effective health interventions.

Keywords: Sleep Disorders, Machine learning, Logistic Regression, Gradient Boosting, SHAP

1. PENDAHULUAN

Gangguan tidur merupakan salah satu masalah kesehatan masyarakat yang semakin mendapat perhatian karena berimplikasi luas terhadap kualitas hidup, produktivitas, serta kesehatan fisik dan mental individu. *National Sleep Foundation (NSF)* menyebutkan bahwa kualitas tidur dipengaruhi oleh beragam faktor, termasuk kondisi psikologis, pola aktivitas, gaya hidup, dan status kesehatan. Dampak gangguan tidur tidak hanya berupa penurunan konsentrasi dan kinerja, tetapi juga berhubungan dengan meningkatnya risiko penyakit kronis seperti hipertensi, diabetes, obesitas, serta gangguan mental seperti depresi dan kecemasan [1].

Sejumlah penelitian menunjukkan bahwa faktor-faktor utama yang memengaruhi kualitas tidur meliputi tingkat stres, keteraturan pola tidur, konsumsi kafein, tingkat aktivitas fisik, kondisi kesehatan, usia, dan jenis kelamin. Pemahaman terhadap variabel-variabel ini penting karena dapat memberikan gambaran komprehensif mengenai determinan gangguan tidur, sekaligus menjadi dasar dalam merancang strategi pencegahan dan intervensi kesehatan yang lebih efektif [2].

Penelitian terkini mengenai gangguan tidur semakin banyak memanfaatkan pendekatan berbasis data dengan teknik analisis prediktif. Model prediksi berbasis *machine learning* dinilai mampu memberikan hasil yang lebih akurat dalam mengidentifikasi faktor risiko dibandingkan metode tradisional. Beberapa studi menemukan bahwa stres psikologis, konsumsi kafein, dan rendahnya aktivitas fisik merupakan prediktor penting munculnya insomnia maupun sleep disorder lainnya [3].


National Sleep Foundation menekankan pentingnya pola tidur yang teratur, gaya hidup sehat, dan kondisi fisik yang baik dalam menjaga kualitas tidur. Sejalan dengan itu, penggunaan data multivariat dalam analisis prediksi memungkinkan penelitian ini untuk mengidentifikasi pola kompleks antarvariabel yang mungkin tidak terdeteksi dengan metode konvensional.

2. METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan metode *machine learning* untuk memprediksi faktor risiko gangguan tidur. Data diperoleh dari survei perilaku tidur *National Sleep Foundation*.

Sebelum analisis, data diproses melalui tahap *Cleaning* (penanganan data hilang dan (*outlier*), Transformasi (*encoding*), serta normalisasi. Selanjutnya, data dibagi menjadi *training* (80%) dan *testing* (20%).

Dua algoritma diterapkan, yaitu *Logistic Regression* dan *Gradient Boosting*. Kinerja model dievaluasi menggunakan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-score*. Analisis interpretabilitas dilakukan dengan *SHAP* (*SHAPley Additive Explanations*) untuk memahami kontribusi tiap variabel terhadap prediksi model.



Gambar 2.1 Flowchart Metode

1. Sumber dan Pengumpulan Data

Untuk mendukung penelitian ini, data diperoleh dari *National Sleep Foundation (NSF)*, sebuah lembaga internasional yang berfokus pada penelitian, edukasi, dan advokasi mengenai kesehatan tidur. Dataset

yang digunakan memuat informasi terkait faktor-faktor yang memengaruhi kualitas tidur, meliputi:

Table 1. Data *National Sleep Foundation*

Kondisi	Tidur	Kafein	Aktivitas	Kesehatan	Usia	Kelamin
Stres Rendah	Tidak Teratur	Sering	Aktif	Sehat	Dewasa	Perempuan
Stres Tinggi	Tidak Teratur	Jarang	Kurang Aktif	Terganggu	Remaja	Perempuan
Stres Tinggi	Tidak Teratur	Jarang	Kurang Aktif	Terganggu	Dewasa	Laki
Stres Rendah	Teratur	Jarang	Kurang Aktif	Sehat	Dewasa	Perempuan
Stres Tinggi	Tidak Teratur	Sering	Aktif	Terganggu	Dewasa	Laki
Stres Rendah	Tidak Teratur	Jarang	Kurang Aktif	Sehat	Remaja	Perempuan
Stres Tinggi	Tidak Teratur	Sering	Aktif	Terganggu	Remaja	Perempuan
Stres Rendah	Teratur	Sering	Kurang Aktif	Sehat	Dewasa	Laki
Stres Rendah	Tidak Teratur	Jarang	Kurang Aktif	Sehat	Remaja	Laki
Stres Rendah	Teratur	Sering	Aktif	Sehat	Remaja	Laki
Stres Rendah	Teratur	Jarang	Kurang Aktif	Sehat	Dewasa	Laki
Stres Rendah	Tidak Teratur	Jarang	Kurang Aktif	Sehat	Remaja	Laki
Stres Rendah	Tidak Teratur	Sering	Kurang Aktif	Sehat	Remaja	Perempuan
Stres Rendah	Teratur	Sering	Aktif	Sehat	Dewasa	Laki
Stres Rendah	Teratur	Sering	Kurang Aktif	Sehat	Remaja	Laki
Stres Rendah	Tidak Teratur	Sering	Aktif	Sehat	Dewasa	Laki
Stres Rendah	Tidak Teratur	Sering	Aktif	Sehat	Remaja	Perempuan
Stres Rendah	Tidak Teratur	Sering	Aktif	Sehat	Remaja	Perempuan
Stres Tinggi	Tidak Teratur	Jarang	Aktif	Terganggu	Dewasa	Laki
Stres Rendah	Teratur	Sering	Kurang Aktif	Sehat	Dewasa	Laki
Stres Rendah	Tidak Teratur	Jarang	Kurang Aktif	Sehat	Dewasa	Perempuan
Stres Tinggi	Tidak Teratur	Jarang	Aktif	Terganggu	Dewasa	Laki
Stres Rendah	Teratur	Sering	Aktif	Sehat	Remaja	Laki
Stres Tinggi	Tidak Teratur	Sering	Aktif	Terganggu	Remaja	Laki
Stres Rendah	Teratur	Sering	Aktif	Sehat	Dewasa	Perempuan
Stres Tinggi	Teratur	Jarang	Kurang Aktif	Terganggu	Remaja	Perempuan
Stres Rendah	Teratur	Sering	Aktif	Sehat	Remaja	Laki

Data dikumpulkan melalui survei berskala besar yang dilakukan oleh *NSF*, yang secara rutin mengukur perilaku tidur masyarakat. Sebelum dilakukan analisis, data tersebut melalui tahap pembersihan (*Cleaning*), termasuk penanganan nilai hilang, normalisasi variabel numerik, serta Transformasi variabel kategorikal. Dengan demikian, data yang diperoleh memiliki kualitas yang memadai untuk dianalisis menggunakan pendekatan *machine learning* guna mengeksplorasi faktor-faktor yang paling signifikan dalam memengaruhi gangguan tidur.

2. Pra-pemrosesan Data

Sebelum proses pelatihan model, data perlu dipersiapkan agar berkualitas baik dan siap diolah. Tahap ini meliputi:

Data *Cleaning* Menghapus data kosong, mendeteksi dan menangani nilai ekstrem (*outlier*) agar tidak memengaruhi hasil.

Transformasi Data Variabel kategorikal diubah menjadi numerik menggunakan metode label encoding agar dapat diproses algoritma *machine learning*.



Normalisasi/Standarisasi Menyamakan skala variabel numerik untuk meningkatkan stabilitas pelatihan model, jika diperlukan.

3. Pembagian Data

Dataset dibagi menjadi dua subset

- Data *Training* (80%): Digunakan untuk melatih model agar mempelajari pola dari data.
- Data *Testing* (20%): Digunakan untuk menguji performa model yang telah dilatih.

4. Penerapan Algoritma

Dalam penelitian ini digunakan dua algoritma utama, yaitu *Logistic Regression* dan *Gradient Boosting*. *Logistic Regression* diterapkan untuk memodelkan hubungan linier antara variabel input (misalnya stres, pola tidur, konsumsi kafein) dengan probabilitas terjadinya gangguan tidur. Model ini menghasilkan probabilitas klasifikasi biner sehingga sesuai untuk kasus *sleep disorder detection*.

Sementara itu, *Gradient Boosting* digunakan sebagai pendekatan ensemble learning yang membangun model secara bertahap melalui kombinasi weak learners (pohon keputusan). Setiap literasi berfokus pada perbaikan kesalahan prediksi sebelumnya, sehingga menghasilkan model yang lebih kuat dan akurat.

Kinerja kedua model diukur menggunakan metrik klasifikasi, yaitu *Accuracy*, *Precision*, *Recall*, dan *F1-score* yang dihitung berdasarkan Confusion Matrix. Selain itu, interpretabilitas model diperkuat dengan analisis *SHAP* (*SHAPley Additive Explanations*), yang memungkinkan identifikasi kontribusi setiap variabel terhadap prediksi, baik secara global (feature importance) maupun individual (decision plot). Dengan demikian, hasil tidak hanya memberikan prediksi yang akurat tetapi juga wawasan mengenai faktor-faktor dominan yang memengaruhi risiko gangguan tidur.

a. Logistic Regression

Model *Logistic Regression* memprediksi probabilitas seseorang mengalami gangguan tidur ($y=1y$) berdasarkan kombinasi linier dari variabel-variabel input ($X_1, X_2, \dots, X_n$) [4].

$$P(y = 1|X) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n)}} \quad (2.1)$$

Keterangan

$P(y=1|X)$ = Probabilitas terjadinya gangguan tidur

$X_1, X_2, \dots, X_n$ = Variabel input (misalnya stres, pola tidur, konsumsi kafein, dll.)

β_0 = Intersep, yaitu nilai dasar model saat tidak ada input

$\beta_1, \beta_2, \dots, \beta_n$ = Koefisien yang merepresentasikan besarnya pengaruh setiap variabel terhadap probabilitas gangguan tidur

e = Bilangan eksponensial (sekitar 2,718)

b. Gradient Boosting

Gradient Boosting bekerja dalam M iterasi, di mana pada setiap iterasi model baru dibangun untuk memperbaiki kesalahan model sebelumnya [5].

$$F_m(x) = F_{m-1}(x) + v \cdot h_m(x) \quad (2.2)$$

Keterangan

$F_m(x)$ = Model pada iterasi ke- m

$F_{m-1}(x)$ = Model dari iterasi sebelumnya

$h_m(x)$ = Pohon keputusan (weak learner) yang dilatih untuk meminimalkan error (residual)

v = *Learning rate*, yaitu faktor skala yang mengatur seberapa besar kontribusi setiap pohon

x = Variabel input

c. Accuracy

Accuracy adalah ukuran seberapa sering model memprediksi dengan benar dibandingkan dengan keseluruhan data yang diuji [6].

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.3)$$

Keterangan :

TP = Data positif diprediksi benar sebagai positif

TN = Data negatif diprediksi benar sebagai negatif

FP = Data negatif diprediksi salah sebagai positif (*false alarm*)

FN = Data positif diprediksi salah sebagai negatif (*missed case*)

b. Precision

mengukur ketepatan model saat memprediksi data positif [7].

$$Precision = \frac{TP}{TP + FP} \quad (2.4)$$

Precision menghitung berapa banyak dari prediksi positif yang benar-benar positif. Semakin tinggi *Precision*, semakin sedikit kesalahan memprediksi negatif sebagai positif.

c. Recall

Mengukur kemampuan model menemukan semua data positif [8].

$$Recall = \frac{TP}{TP + FN} \quad (2.5)$$

Recall mengukur seberapa banyak data positif yang sebenarnya berhasil diprediksi benar. Semakin tinggi *Recall*, semakin sedikit kasus positif yang terlewat.

d. F1-score

Rata-rata harmonis antara *Precision* dan *Recall*.

$$Recall = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2.6)$$

F1-Score merupakan rata-rata harmonis antara *Precision* dan *Recall*. Nilainya tinggi jika *Precision* dan *Recall* keduanya tinggi.

e. Analisis SHAP


Interpretabilitas model dilakukan menggunakan *SHAP* (*SHAPley Additive Explanations*), yaitu metode berbasis teori game theory yang mengukur kontribusi setiap variabel terhadap hasil prediksi. *SHAP* digunakan untuk menilai pengaruh global melalui *feature importance plot*, serta menjelaskan arah kontribusi variabel pada level individu dengan *decision plot* [9]. Dengan demikian, hasil model tidak hanya menunjukkan tingkat akurasi, tetapi juga dapat dipahami faktor-faktor mana yang paling menentukan risiko gangguan tidur.



3. HASIL DAN PEMBAHASAN

Distribusi prediksi yang relatif seimbang antara dua kategori menunjukkan bahwa model tidak mengalami bias yang signifikan terhadap salah satu kelas. Dalam konteks pemodelan klasifikasi, distribusi prediksi yang seimbang merupakan indikasi awal bahwa model mampu mengenali pola dari kedua kelas dengan proporsi yang hampir setara. Hal ini penting karena pada masalah klasifikasi biner, model yang terlalu dominan memprediksi salah satu kelas biasanya memiliki kinerja yang kurang baik pada metrik seperti *Recall* atau *Precision*, terutama jika distribusi data asli juga seimbang.

1. Perbandingan Algoritma




Gambar 3.1 Perbandingan Algoritma

Hasil evaluasi Gambar 3.1 performa model menunjukkan bahwa *Gradient Boosting* unggul dengan akurasi dan *F1-score* sempurna (1.00), yang berarti mampu mengklasifikasikan seluruh data uji tanpa kesalahan serta menjaga keseimbangan optimal antara presisi dan *Recall*.

Sebaliknya, *Logistic Regression* hanya mencapai akurasi dan *F1-score* sebesar 0.70, menandakan adanya penurunan kinerja akibat kesalahan klasifikasi yang lebih tinggi serta ketidakseimbangan dalam mendeteksi kelas positif dan negatif.


2. Precision-Recall (PR) Curve



Gambar 3.2 Precision-Recall Curve

Precision-Recall (PR) curve pada Gambar 3.2 menunjukkan bahwa *Gradient Boosting* memiliki performa jauh lebih baik dibandingkan *Logistic Regression*. Kurva *Gradient Boosting* (garis oranye) hampir mendekati nilai *Precision* dan *Recall* = 1.0 secara konsisten, yang menandakan kinerja prediksi yang stabil dan akurat. Sebaliknya, *Logistic Regression* (garis biru) tampak menurun secara bertahap, menunjukkan adanya trade-off lebih besar antara *Precision* dan *Recall* sehingga model lebih rentan menghasilkan kesalahan klasifikasi positif maupun negatif.

3. ROC Curve




Gambar 3.3 ROC Curve

Pada Gambar 3.3 ROC Curve menunjukkan bahwa *Gradient Boosting* (garis oranye) memiliki kinerja prediksi yang sangat sempurna dengan nilai AUC mendekati 1.0, menandakan kemampuan tinggi dalam membedakan kelas positif dan negatif secara konsisten. Sebaliknya, *Logistic Regression* (garis biru) menghasilkan kurva yang lebih rendah dan mendekati garis diagonal, dengan AUC yang lebih kecil. Hal ini menunjukkan bahwa *Logistic Regression* memiliki kinerja klasifikasi yang lebih lemah dan lebih rentan terhadap kesalahan dibandingkan *Gradient Boosting*.

4. Perbandingan Analisis Confusion Matrix

a. Confusion Matrix Gradient Boosting




Gambar 3.4 Confusion Matrix Gradient Boosting

Berdasarkan Gambar 3.4 (*Confusion Matrix* untuk *Gradient Boosting*), model *Gradient Boosting* berhasil mengklasifikasikan data dengan akurasi yang sempurna. Dari total 100 data uji, sebanyak 49 data dengan label aktual 0 diprediksi dengan benar sebagai 0 (*True Negative*), dan 51 data dengan label aktual 1 diprediksi dengan benar sebagai 1 (*True Positive*).

Tidak ada kesalahan klasifikasi yang terjadi, ditunjukkan oleh nilai *False Positive* (0) dan *False Negative* (0). Hasil ini mengindikasikan bahwa *Gradient Boosting* mampu mempelajari pola data dengan sangat baik dan menghasilkan prediksi yang akurat tanpa kesalahan pada dataset yang digunakan.

b. *Confusion Matrix Logistic Regression*



Gambar 3.5 *Confusion Matrix Logistic Regression*

Sebaliknya, Gambar 3.5 (*Confusion Matrix* untuk *Logistic Regression*) menunjukkan bahwa model ini memiliki performa yang lebih rendah dibandingkan *Gradient Boosting*. Dari 49 data dengan label aktual 0, hanya 30 data yang diprediksi benar sebagai 0 (*True Negative*), sementara 19 data lainnya salah diprediksi sebagai 1 (*False Positive*). Demikian pula, dari 51 data dengan label aktual 1, sebanyak 40 data diprediksi benar sebagai 1 (*True Positive*), sedangkan 11 data salah diprediksi sebagai 0 (*False Negative*). Hal ini menandakan bahwa *Logistic Regression* cenderung memiliki kesalahan prediksi baik pada kelas positif maupun negatif.



5. Evaluasi

Model	Accuracy	Precision	Recall	F1
Gradient Boosting	1.0	1.0	1.0	1.0
Logistic Regression	0.7	0.7043	0.7	0.698

Gambar 3.6 Evaluasi

a. *Accuracy*

- 1) Mengukur proporsi prediksi yang benar dibandingkan seluruh data.
- 2) *Gradient Boosting* = 1.0 semua prediksi tepat.
- 3) *Logistic Regression* = 0.7 hanya 70% prediksi yang benar, sisanya salah.

b. *Precision*

- 1) Menggambarkan ketepatan klasifikasi positif, yaitu dari semua data yang diprediksi positif, berapa yang benar-benar positif.
- 2) *Gradient Boosting* = 1.0 tidak ada *False Positive*, semua prediksi positif benar.
- 3) *Logistic Regression* ≈ 0.70 masih ada sekitar 30% prediksi positif yang keliru.

c. *Recall*

- 1) Mengukur kemampuan model dalam mendeteksi semua data positif, yaitu dari seluruh data positif, berapa yang berhasil ditemukan.
- 2) *Gradient Boosting* = 1.0 semua data positif berhasil terdeteksi.
- 3) *Logistic Regression* = 0.7 hanya 70% data positif yang terdeteksi, sisanya terlewat (*False Negative*).

d. *F1-score*

- 1) Rata-rata harmonik antara *Precision* dan *Recall*, memberikan gambaran keseimbangan antara keduanya.
- 2) *Gradient Boosting* = 1.0 keseimbangan sempurna karena *Precision* dan *Recall* sama-sama 1.0.
- 3) *Logistic Regression* = 0.698 menunjukkan ketidakseimbangan karena *Precision* dan *Recall* sama-sama rendah.

6. *SHAP Summary (Beeswarm) Plot*.




Gambar 3.7 *SHAP Beeswarm Plot*

Hasil dari Gambar 3.7 analisis *SHAP* menunjukkan bahwa durasi dan kualitas tidur merupakan faktor paling dominan. Nilai tidur rendah (biru) meningkatkan risiko gangguan tidur, sedangkan tidur yang baik (merah) menurunkan risiko.

Selain itu, konsumsi kafein juga berpengaruh signifikan, di mana asupan kafein tinggi cenderung meningkatkan prediksi gangguan tidur. Variabel lain seperti usia, aktivitas fisik, dan kesehatan umum turut memberi kontribusi, meski relatif lebih kecil, sementara jenis kelamin memiliki pengaruh paling rendah.


7. SHAP Feature Importance bar plot



Gambar 3.8 *SHAP Importance bar plot*

Hasil dari Gambar 3.8 *SHAP* menunjukkan bahwa durasi dan kualitas tidur merupakan faktor paling berpengaruh dalam memprediksi risiko gangguan tidur. Kafein dan usia juga berkontribusi signifikan, diikuti oleh aktivitas fisik serta kesehatan umum dengan pengaruh sedang. Sementara itu, kondisi dan jenis kelamin memiliki kontribusi relatif kecil, dengan jenis kelamin menempati posisi terendah.

8. SHAP Decision Plot



Gambar 3.9 *SHAP Decision Plot*

Visualisasi Gambar 3.9 *SHAP* decision plot menunjukkan bahwa durasi tidur menjadi faktor dominan dalam arah prediksi.

Nilai rendah meningkatkan risiko gangguan, sedangkan nilai tinggi bersifat protektif. Kafein dan usia juga memberi kontribusi signifikan dengan kecenderungan meningkatkan risiko. Sementara itu, aktivitas fisik dan kesehatan umum lebih berperan sebagai faktor protektif, sedangkan kondisi dan jenis kelamin memberikan pengaruh relatif kecil.

4. KESIMPULAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa penggunaan algoritma *machine learning*, khususnya *Gradient Boosting*, terbukti mampu memberikan prediksi yang sangat akurat dalam mengidentifikasi faktor risiko gangguan tidur dibandingkan *Logistic Regression*. Analisis interpretabilitas dengan *SHAP* menegaskan bahwa durasi dan kualitas tidur merupakan determinan utama dalam memengaruhi risiko gangguan tidur, diikuti oleh konsumsi kafein dan faktor usia, sementara variabel lain seperti aktivitas fisik, kesehatan umum, kondisi, dan jenis kelamin memiliki kontribusi yang lebih kecil. Temuan ini menunjukkan bahwa model prediksi berbasis data tidak hanya efektif dalam mengklasifikasikan risiko, tetapi juga dapat memberikan pemahaman komprehensif mengenai pola keterkaitan antarvariabel, sehingga berpotensi menjadi landasan bagi strategi intervensi dan pencegahan gangguan tidur yang lebih tepat sasaran.

5. DAFTAR PUSTAKA

- [1] Mohammad Rasel Mahmud, Al Shahriar Uddin Khondakar Pranta, Anamul Haque Sakib, Abdullah Al Sakib, and Md Ismail Hossain Siddiqui, "Robust feature selection for improved sleep stage classification," *Int. J. Sci. Res. Arch.*, vol. 15, no. 1, pp. 1790–1797, 2025, doi: 10.30574/ijrsra.2025.15.1.1160.
- [2] Md Ismail Hossain Siddiqui, Anamul Haque Sakib, Sanjida Akter, Jesika Debnath, and Mohammad Rasel Mahmud, "Comparative analysis of traditional *machine learning* Vs deep learning for sleep stage classification," *Int. J. Sci. Res. Arch.*, vol. 15, no. 1, pp. 1778–1789, 2025, doi: 10.30574/ijrsra.2025.15.1.1159.
- [3] G. Long, W. Qingyan, T. Jian, W. Duo, W. Xiaotian, and D. Hongfei, "Advances in Aeronautical Science and Engineering," *Adv. Aeronaut. Sci. Eng.*, vol. 14, no. 2, pp. 178–190, 2023.
- [4] M. Jain and A. Srihari, "Comparison of *Machine learning* Algorithm in Intrusion Detection Systems: A Review Using Binary Logistic Regression," *Int. J. Comput. Sci. Mob. Comput.*, vol. 13, no. 10, pp. 45–53, 2024, doi: 10.47760/ijcsmc.2024.v13i10.005.
- [5] C. Zhang, Y. Zhang, J. Pu, Z. Liu, Z. Wang, and L. Wang, "An hourly solar radiation prediction model using *eXtreme Gradient Boosting* algorithm with the effect of fog-haze," *Energy Built Environ.*, vol. 6, no. 1, pp. 18–26, 2025, doi: 10.1016/j.enbenv.2023.08.001.
- [6] J. Crossa *et al.*, "*Machine learning* algorithms translate big data into predictive breeding *Accuracy*," *Trends Plant Sci.*, vol. 30, no. 2, pp. 167–184, 2025, doi: 10.1016/j.tplants.2024.09.011
- [7] R. Vadiasetty *et al.*, "Artificial Intelligence-Based ML Techniques and Big Data Analytics to *Precision* Diabetes Diagnosis in Healthcare Systems," vol. 2023, no. 3, pp. 1–8, 2023, doi: 10.71010/2023/JCETAI-e103-1.
- [8] J. P. Ntayagabiri, Y. Bentaleb, J. Ndikumagenge, and H. El Makhtoum, "A Comparative Analysis of Supervised *Machine learning* Algorithms for IoT Attack Detection and Classification," *J. Comput. Theor. Appl.*, vol. 2, no. 3, pp. 395–409, 2025, doi: 10.62411/jcta.11901.
- [9] S. M. K. Alam, P. Li, M. Rahman, M. Fida, and V. Elumalai, "Key factors affecting groundwater nitrate levels in the Yinchuan Region, Northwest China: Research using the *eXtreme Gradient Boosting* (XGBoost) model with the *SHAP*ley Additive Explanations (*SHAP*) method," *Environ. Pollut.*, vol. 364, no. P1, p. 125336, 2025, doi: 10.1016/j.envpol.2024.125336.