



Penerapan Random Forest untuk Klasifikasi Gangguan Tidur Berdasarkan Data Kesehatan dan Aktivitas Fisik

Random Forest-Based Sleep Disorder Classification Using Health and Physical Activity Data

Kevin Jordan Moc^{1*}, Huliman², Devi³

STMIK TIME, Medan

Email: kevinjordan506@gmail.com^{1*}, dr.huliman@gmail.com², d3v1wu89@gmail.com³

Article Info

Article history :

Received : 23-07-2026

Revised : 25-07-2026

Accepted : 27-07-2026

Pulished : 29-07-2026

Abstract

Sleep disorders can reduce quality of life and are associated with health and functional problems. This study applies the Random Forest algorithm to classify sleep disorders using health and physical activity data and implements the trained model in an Android-based application. The Sleep Health and Lifestyle Dataset was used as secondary data. The dataset file used in this study contained 374 records; after preprocessing and removal of records without a sleep-disorder label, 155 records met the modeling criteria, consisting of 78 Sleep Apnea and 77 Insomnia records. The data were divided into 124 training records and 31 testing records. Random Forest was configured with 30 trees and a maximum depth of 20. Model performance was evaluated using accuracy, precision, recall, F1-score, and a confusion matrix. The model achieved 90.32% accuracy. Insomnia obtained 87.50% precision, 93.33% recall, and 90.32% F1-score, while Sleep Apnea obtained 93.33% precision, 87.50% recall, and 90.32% F1-score. Feature-importance analysis identified Physical Activity Level as the most influential feature, followed by Daily Steps, Age, Blood Pressure, and Heart Rate. These results indicate that Random Forest can provide balanced binary classification of Insomnia and Sleep Apnea and can be integrated into an Android application as an initial analytical support tool.

Keywords: *Machine Learning, Random Forest, Sleep Disorders*

Abstrak

Gangguan tidur dapat menurunkan kualitas hidup dan berkaitan dengan berbagai masalah kesehatan serta gangguan fungsi sehari-hari. Penelitian ini bertujuan menerapkan algoritma Random Forest untuk mengklasifikasikan gangguan tidur berdasarkan data kesehatan dan aktivitas fisik serta mengimplementasikan model ke dalam aplikasi berbasis Android. Penelitian menggunakan data sekunder dari Sleep Health and Lifestyle Dataset. Dataset awal terdiri atas 374 rekam data; setelah tahap prapemrosesan dan penghapusan rekam data tanpa label gangguan tidur, diperoleh 155 rekam data yang memenuhi kriteria pemodelan, terdiri atas 78 Sleep Apnea dan 77 Insomnia. Data dibagi menjadi 124 data latih dan 31 data uji. Model Random Forest menggunakan 30 pohon keputusan dengan kedalaman maksimum 20. Kinerja model dievaluasi menggunakan akurasi, presisi, recall, F1-score, dan confusion matrix. Model mencapai akurasi 90,32%. Kelas Insomnia menghasilkan presisi 87,50%, recall 93,33%, dan F1-score 90,32%, sedangkan kelas Sleep Apnea menghasilkan presisi 93,33%, recall 87,50%, dan F1-score 90,32%. Analisis feature importance menunjukkan Physical Activity Level sebagai fitur paling berpengaruh, diikuti Daily Steps, Age, Blood Pressure, dan Heart Rate. Hasil penelitian menunjukkan bahwa Random Forest mampu mengklasifikasikan Insomnia dan Sleep Apnea dengan kinerja yang seimbang serta dapat diintegrasikan ke dalam aplikasi Android sebagai alat bantu analisis awal.

Kata Kunci: *Gangguan Tidur, Pembelajaran Mesin, Random Forest*



PENDAHULUAN

Tidur merupakan salah satu kebutuhan biologis manusia yang sangat penting untuk menjaga keseimbangan fisik, emosional, dan mental. Kualitas tidur yang baik berkontribusi terhadap daya tahan tubuh, fungsi kognitif, suasana hati, serta produktivitas sehari-hari (Zhang et al., 2024). Sebaliknya, gangguan tidur seperti insomnia dan sleep apnea dapat berdampak buruk terhadap kesehatan secara keseluruhan. Insomnia ditandai dengan kesulitan untuk tidur atau mempertahankan tidur, sedangkan sleep apnea merupakan gangguan pernapasan yang terjadi saat tidur, yang menyebabkan henti napas secara periodik dan dapat menurunkan kadar oksigen dalam tubuh. Kedua gangguan ini, apabila tidak ditangani dengan tepat, berisiko meningkatkan kemungkinan terkena penyakit kronis seperti hipertensi, diabetes, dan gangguan jantung (Sharaf, 2023).

Menurut data dari World Health Organization (WHO) dan berbagai lembaga kesehatan, gangguan tidur semakin sering ditemui, terutama di masyarakat urban dengan gaya hidup modern. Kurangnya kualitas tidur yang kronis telah dikaitkan dengan peningkatan risiko penyakit jantung, hipertensi, diabetes, gangguan suasana hati, dan bahkan penurunan sistem imun (Dimitriadis et al., 2021). Oleh karena itu, deteksi dini gangguan tidur sangat penting untuk mencegah konsekuensi kesehatan jangka panjang serta untuk memastikan bahwa individu mendapatkan intervensi medis (An et al., 2025).

Seiring berkembangnya teknologi dan kecerdasan buatan, metode pembelajaran mesin (machine learning) telah dimanfaatkan untuk membantu proses diagnosis medis, termasuk dalam mendeteksi gangguan tidur. Salah satu algoritma yang cukup efektif dalam klasifikasi data adalah algoritma Random Forest (Tanuku & Tummala, 2023). Algoritma ini merupakan metode ensemble berbasis pohon keputusan (decision tree) yang bekerja dengan membuat sejumlah pohon keputusan dan menggabungkan hasilnya untuk meningkatkan akurasi klasifikasi (Bhongade & Gandhi, 2024).

Algoritma Random Forest merupakan salah satu metode machine learning berbasis ensemble learning yang banyak digunakan dalam bidang medis karena kemampuannya yang unggul dalam mengklasifikasikan data kompleks dan beragam (Widyastuty & Azis, 2024). Dalam konteks klasifikasi gangguan tidur berdasarkan data kesehatan dan aktivitas fisik, algoritma ini memiliki sejumlah kelebihan yang menjadikannya pilihan tepat untuk mendeteksi pola gangguan tidur secara otomatis dan akurat (Hidayat, 2023).

Aplikasi penerapan algoritma Random Forest adalah sistem berbasis komputer yang dirancang untuk menganalisis dan mengolah data guna membantu pengambilan keputusan atau prediksi dalam berbagai bidang, termasuk kesehatan. Secara khusus, dalam konteks klasifikasi gangguan tidur, aplikasi ini memanfaatkan data kesehatan dan aktivitas fisik pengguna untuk mengidentifikasi pola-pola yang dapat mengindikasikan adanya gangguan tidur (Kilic et al., 2023).

Data kesehatan yang digunakan biasanya meliputi detak jantung, durasi tidur, tingkat stres, variabilitas detak jantung (heart rate variability), serta parameter fisiologis lain yang dapat dipantau melalui perangkat wearable atau catatan medis. Sementara itu, data aktivitas fisik mencakup jumlah langkah, durasi aktivitas harian, intensitas olahraga, dan kebiasaan fisik lainnya yang berpengaruh terhadap kualitas tidur (Skaramagkas et al., 2025). Dengan menggabungkan kedua jenis data ini,



aplikasi mampu melihat hubungan kompleks antara aktivitas harian, kondisi kesehatan, dan kualitas tidur.

Algoritma Random Forest sendiri merupakan metode machine learning berbasis ensemble, yang terdiri dari banyak decision tree yang bekerja bersama untuk meningkatkan akurasi prediksi. Setiap decision tree memberikan keputusan atau prediksi independen, kemudian hasil keseluruhan ditentukan berdasarkan mayoritas suara dari semua pohon (Gao & Ding, 2020). Keunggulan algoritma Random Forest antara lain adalah kemampuannya dalam menangani data yang besar dan kompleks, toleransi terhadap noise, serta kemampuannya memberikan informasi tentang feature importance, yaitu seberapa besar pengaruh masing-masing variabel terhadap prediksi (Khasanah et al., 2025).

Machine Learning untuk klasifikasi gangguan tidur adalah metode komputasi yang memungkinkan komputer belajar dari data sehingga dapat membuat prediksi atau keputusan secara otomatis (Farrahi & Rostami, 2024). Dalam konteks kesehatan, sering digunakan untuk menganalisis data fisiologis dan aktivitas untuk mengidentifikasi kondisi tertentu, seperti gangguan tidur, kualitas tidur buruk, Insomnia, Sleep apnea.

Machine Learning mencakup konsep dasar pembelajaran dari data, jenis-jenis metode pembelajaran, proses pengembangan model, evaluasi, dan tantangan seperti overfitting (Hamza & Kebiri, 2023). Dalam konteks klasifikasi gangguan tidur, machine learning menjadi metode analisis yang sangat efektif karena mampu mengolah data kesehatan yang kompleks, tidak linear, dan memiliki banyak variabel. algoritma seperti Random Forest memberikan kemampuan prediktif yang akurat dan stabil untuk mendeteksi gangguan tidur berdasarkan berbagai parameter kesehatan (Shin et al., 2024). Ada beberapa jenis machine learning, yaitu:

Random Forest pertama kali diperkenalkan oleh Breiman (2001) sebagai pengembangan dari decision tree dan metode bagging (bootstrap aggregation). Inti dari Random Forest adalah membangun sejumlah besar pohon keputusan (decision tree) yang dibentuk secara acak, kemudian menggabungkan hasil prediksinya melalui mekanisme majority voting (untuk klasifikasi) atau averaging (untuk regresi). Kombinasi antar pohon inilah yang membuat Random Forest lebih stabil dan akurat dibandingkan pohon tunggal (ŞEVGIN, 2023).

Algoritma Random Forest merupakan salah satu teknik ensemble learning dalam bidang machine learning yang sangat populer dan banyak digunakan, khususnya untuk tugas klasifikasi dan regresi. Kepopuleran Random Forest didasarkan pada kemampuannya menangani dataset berskala besar, toleransi terhadap noise, serta kemampuannya menghasilkan akurasi tinggi meskipun data memiliki variabilitas dan non-linearitas yang kompleks (Adefemi Ayodele, 2023).

Gangguan Tidur (Sleep Disorder) adalah kondisi medis yang ditandai oleh anomali atau ketidaknormalan reguler pada kuantitas, kualitas, atau waktu tidur seseorang, yang menyebabkan distress signifikan dan/atau gangguan fungsi fisik, mental, sosial, pekerjaan, atau fungsi penting lainnya di siang hari. Secara klinis, gangguan tidur memerlukan intervensi karena mereka bukan sekadar masalah gaya hidup atau kebiasaan buruk, melainkan masalah yang berakar pada disfungsi neurologis, fisiologis, atau psikologis. Gangguan tidur adalah indikator penting kesehatan umum dan kualitas hidup. Penanganannya membutuhkan pengenalan mendalam terhadap mekanisme dasarnya dan intervensi yang komprehensif (Morin et al., 2023).



Berdasarkan uraian tersebut, tujuan penelitian ini adalah menerapkan dan mengevaluasi algoritma Random Forest untuk klasifikasi biner Insomnia dan Sleep Apnea berdasarkan data kesehatan dan aktivitas fisik, menganalisis fitur yang paling berpengaruh terhadap keputusan model, serta mengimplementasikan model ke dalam aplikasi Android sebagai alat bantu analisis awal.

METODE PENELITIAN

Sumber Data dan Prapemrosesan

Penelitian ini menggunakan Sleep Health and Lifestyle Dataset yang diperoleh dari Kaggle. Dataset tersebut memuat variabel kesehatan, pola tidur, dan gaya hidup, meliputi Gender, Age, Occupation, Sleep Duration, Quality of Sleep, Physical Activity Level, Stress Level, BMI Category, Blood Pressure, Heart Rate, Daily Steps, serta Sleep Disorder sebagai label. Dataset awal yang digunakan dalam eksperimen terdiri atas 374 rekam data sebelum tahap pembersihan.

Tahap prapemrosesan dilakukan untuk memastikan konsistensi dan kesiapan data sebelum pemodelan. Tahapan ini meliputi pemeriksaan struktur data, pembersihan data, penanganan nilai yang tidak dapat digunakan, serta penghapusan rekam data tanpa label gangguan tidur. Setelah rekam data tanpa label Sleep Disorder dihapus, diperoleh 155 rekam data yang terdiri atas 78 Sleep Apnea dan 77 Insomnia. Oleh karena itu, eksperimen akhir menggunakan skema klasifikasi biner dan tidak mencakup kelas tidur normal.

Data hasil prapemrosesan dibagi dengan rasio 80:20 menjadi 124 data latih dan 31 data uji. Data latih digunakan untuk membangun model, sedangkan data uji digunakan untuk mengevaluasi kemampuan generalisasi model terhadap data yang tidak digunakan selama proses pelatihan.

Pemodelan Random Forest

Random Forest membangun sejumlah decision tree menggunakan bootstrap sampling dan pemilihan fitur secara acak pada proses pemisahan node. Prediksi setiap pohon kemudian digabungkan melalui majority voting untuk menentukan kelas akhir. Mekanisme ini mengikuti prinsip dasar Random Forest sebagai ensemble pohon keputusan.

Pada eksperimen ini, model Random Forest dikonfigurasi dengan $n_estimators = 30$ dan $max_depth = 20$, kemudian dilatih menggunakan 124 data latih. Model menghasilkan prediksi kelas Insomnia atau Sleep Apnea. Selain itu, analisis tingkat kepentingan fitur (feature importance) digunakan untuk mengidentifikasi fitur yang memberikan kontribusi relatif terbesar terhadap proses klasifikasi.

Evaluasi Model dan Implementasi Android

Evaluasi kinerja model dilakukan menggunakan akurasi, presisi, recall, F1-score, dan confusion matrix. Akurasi menunjukkan proporsi prediksi yang benar terhadap seluruh data uji. Presisi menunjukkan ketepatan prediksi pada suatu kelas, recall menunjukkan kemampuan model mengidentifikasi anggota kelas aktual, sedangkan F1-score merupakan rata-rata harmonik antara presisi dan recall. Confusion matrix digunakan untuk mengidentifikasi distribusi prediksi benar dan salah pada masing-masing kelas.

Model yang telah dilatih diintegrasikan ke dalam aplikasi Android. Aplikasi menyediakan fungsi autentikasi, pemilihan dan pengunggahan dataset, proses pelatihan, penyajian hasil evaluasi,



masukan data untuk prediksi, keluaran hasil klasifikasi, serta fungsi keluar dari aplikasi (logout). Pengujian fungsional dilakukan menggunakan pendekatan black-box untuk menilai kesesuaian keluaran setiap fungsi dengan skenario pengujian yang telah ditetapkan.


HASIL DAN PEMBAHASAN

Implementasi pada Aplikasi Android


Aplikasi Android berfungsi sebagai antarmuka untuk menjalankan tahapan penggunaan model. Fitur utama aplikasi mencakup login, pemilihan dataset, proses pelatihan, penyajian hasil evaluasi, formulir prediksi, penyajian hasil prediksi, dan logout. Pengujian black-box terhadap delapan skenario utama menunjukkan bahwa seluruh fungsi memberikan keluaran yang sesuai dengan hasil yang diharapkan. Temuan ini menunjukkan bahwa aplikasi mampu mendukung proses pengujian dan penggunaan model sesuai dengan rancangan sistem. Gambar 1 sampai Gambar 6 menyajikan antarmuka aplikasi Android yang terdiri atas halaman splashscreen, login, dataset, training, predict, dan logout.




Gambar 1. Tampilan Halaman Splashscreen




Gambar 2. Tampilan Halaman Login




Gambar 3. Tampilan Halaman Dataset



Gambar 4. Tampilan Halaman Training



Gambar 5. Tampilan Halaman Predict



Gambar 6. Tampilan Halaman Logout

Hasil Prapemrosesan

Tahap prapemrosesan mengurangi jumlah data dari 374 menjadi 155 rekam data yang memiliki label gangguan tidur dan memenuhi kriteria pemodelan. Data akhir terdiri atas 78 Sleep



Apnea dan 77 Insomnia, sehingga distribusi kedua kelas relatif seimbang. Distribusi tersebut membantu mengurangi potensi dominasi salah satu kelas dalam proses pelatihan dan pengujian model.

Tabel 1. Ringkasan Hasil Prapemrosesan

Keterangan	Jumlah
Data sebelum pembersihan	374
Data setelah pembersihan	155
Sleep Apnea	78
Insomnia	77
Jumlah kolom dataset	12

Kinerja Model Random Forest

Model dilatih menggunakan 124 data latih dan dievaluasi menggunakan 31 data uji. Dengan konfigurasi 30 pohon keputusan dan kedalaman maksimum 20, model mencapai akurasi sebesar 90,32%. Nilai presisi, recall, dan F1-score pada kedua kelas juga menunjukkan kinerja yang relatif seimbang sebagaimana disajikan pada Tabel 2.

Tabel 2. Laporan Klasifikasi Model Random Forest


Kelas	Precision	Recall	F1-Score	Support
Insomnia	87,50%	93,33%	90,32%	15
Sleep Apnea	93,33%	87,50%	90,32%	16
Accuracy	-	-	90,32%	31
Macro Avg	90,42%	90,42%	90,32%	31
Weighted Avg	90,51%	90,32%	90,32%	31

Pada kelas Insomnia, recall sebesar 93,33% lebih tinggi dibandingkan presisi sebesar 87,50%. Hasil tersebut menunjukkan bahwa model mampu mengidentifikasi sebagian besar data Insomnia aktual, meskipun masih terdapat kesalahan klasifikasi. Sebaliknya, kelas Sleep Apnea memiliki presisi lebih tinggi, yaitu 93,33%, dengan recall 87,50%. Nilai F1-score yang sama pada kedua kelas, yaitu 90,32%, menunjukkan bahwa model memiliki kinerja yang relatif seimbang pada dua kelas yang diuji.

Confusion Matrix dan Tingkat Kepentingan Fitur

Confusion matrix menunjukkan bahwa 28 dari 31 data uji diklasifikasikan dengan benar. Sebanyak 14 data Insomnia diklasifikasikan dengan benar, sedangkan satu data Insomnia diprediksi sebagai Sleep Apnea. Pada kelas Sleep Apnea, sebanyak 14 data diklasifikasikan dengan benar dan dua data diprediksi sebagai Insomnia. Dengan demikian, terdapat tiga kesalahan klasifikasi pada seluruh data uji.

Visualisasi confusion matrix hasil klasifikasi ditunjukkan pada Gambar 7.




Gambar 7. Confusion Matrix Hasil Klasifikasi

Tabel 3. Ringkasan Confusion Matrix

Aktual / Prediksi	Insomnia	Sleep Apnea
Insomnia	14	1
Sleep Apnea	2	14

Analisis feature importance menunjukkan urutan fitur paling berpengaruh adalah Physical Activity Level, Daily Steps, Age, Blood Pressure, dan Heart Rate. Dominasi fitur aktivitas fisik memperlihatkan bahwa pola aktivitas harian berkontribusi besar terhadap pemisahan kelas pada model ini. Fitur kesehatan kardiovaskular dan usia juga muncul sebagai variabel penting, sehingga keputusan model tidak bergantung pada satu aspek tunggal. Temuan ini sejalan dengan kajian yang menempatkan machine learning sebagai pendekatan yang relevan untuk memahami keterkaitan aktivitas fisik, perilaku sedentari, dan tidur.

Grafik tingkat kepentingan fitur (feature importance) model Random Forest disajikan pada Gambar 8.



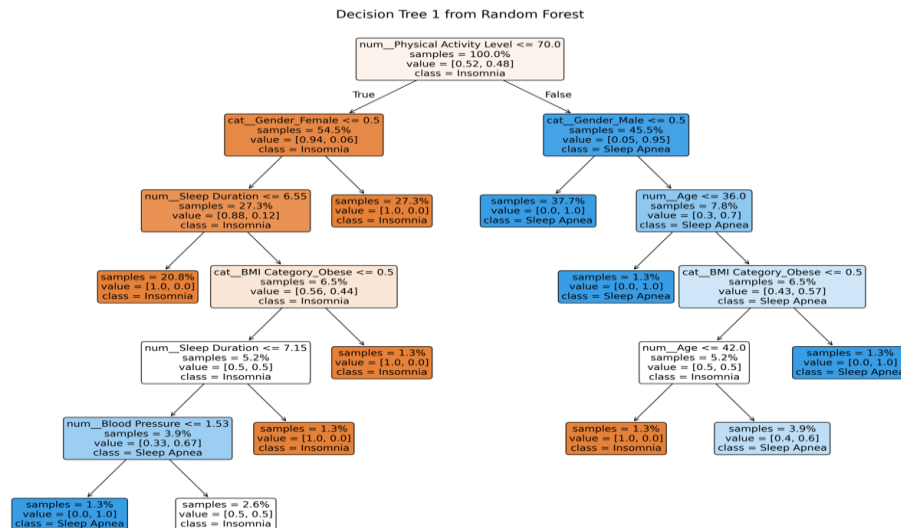
Gambar 8. Grafik Feature Importance

Pada salah satu pohon keputusan, Physical Activity Level menjadi node awal, kemudian proses percabangan menggunakan fitur lain, seperti Gender, Sleep Duration, BMI Category, Age, dan Blood Pressure. Struktur tersebut menunjukkan bahwa Random Forest mempertimbangkan interaksi beberapa karakteristik kesehatan dan gaya hidup dalam proses klasifikasi. Meskipun



feature importance membantu interpretasi model, nilainya menunjukkan kontribusi relatif fitur terhadap prediksi dan tidak dapat ditafsirkan sebagai hubungan sebab-akibat klinis.

Visualisasi salah satu pohon keputusan pada model Random Forest disajikan pada Gambar 9.



Gambar 9. Decision Tree 1 dari Model Random Forest

Pengujian Black-Box Aplikasi

Tabel 4. Ringkasan Pengujian Black-Box Aplikasi

No	Skenario	Hasil
1	Login dengan kredensial valid	Valid
2	Pengujian koneksi server	Valid
3	Memilih file CSV	Valid
4	Mengunggah dataset dan menampilkan preprocessing	Valid
5	Menjalankan pelatihan dan menampilkan hasil evaluasi	Valid
6	Mengisi form prediksi	Valid
7	Menjalankan prediksi gangguan tidur	Valid
8	Keluar dari aplikasi (logout) dan menampilkan konfirmasi	Valid

Pembahasan

Hasil akurasi 90,32% menunjukkan bahwa Random Forest mampu membentuk batas klasifikasi yang efektif pada data akhir yang digunakan. Performa yang relatif seimbang antar kelas penting karena tujuan eksperimen bukan sekadar memperoleh accuracy tinggi, tetapi juga memastikan bahwa kemampuan model mendeteksi Insomnia dan Sleep Apnea tidak timpang. Hasil ini mendukung penggunaan Random Forest pada data kesehatan dan gaya hidup sebagaimana ditunjukkan oleh penelitian sebelumnya.

Kekuatan utama model terdapat pada kemampuannya menggabungkan banyak pohon keputusan dan memanfaatkan variasi fitur untuk menghasilkan prediksi agregat. Pada dataset tabular dengan hubungan nonlinier, karakteristik tersebut dapat membantu membentuk model yang stabil. Di sisi lain, konfigurasi 30 pohon dan kedalaman maksimum 20 pada penelitian ini



merupakan konfigurasi yang digunakan pada eksperimen final, sehingga hasil yang diperoleh belum dapat dianggap sebagai konfigurasi optimal tanpa pengujian hyperparameter yang lebih luas. Pendekatan optimasi parameter dapat menjadi salah satu arah pengembangan berikutnya, sebagaimana penggunaan optimasi hyperparameter dalam penelitian prediksi penyakit.

Penelitian ini memiliki beberapa keterbatasan. Pertama, tahap prapemrosesan menghapus rekam data tanpa label gangguan tidur, sehingga klasifikasi akhir hanya mencakup Insomnia dan Sleep Apnea dan tidak mencakup kelas tidur normal. Kedua, jumlah data setelah pembersihan hanya 155 rekam data, sehingga kemampuan generalisasi model terhadap populasi yang lebih luas masih perlu diuji menggunakan dataset yang lebih besar dan beragam. Ketiga, data penelitian berasal dari dataset terbuka; oleh karena itu, aplikasi yang dikembangkan berfungsi sebagai alat bantu analisis awal dan bukan sebagai sistem diagnosis medis. Penerapan model dalam konteks klinis memerlukan validasi menggunakan data klinis, prosedur evaluasi yang lebih ketat, serta keterlibatan tenaga kesehatan.

KESIMPULAN

Algoritma Random Forest berhasil diterapkan untuk klasifikasi biner gangguan tidur berdasarkan data kesehatan dan aktivitas fisik. Dari 374 rekam data awal, tahap prapemrosesan menghasilkan 155 rekam data yang memenuhi kriteria, terdiri atas 78 Sleep Apnea dan 77 Insomnia. Data dibagi menjadi 124 data latih dan 31 data uji. Model dengan 30 pohon keputusan dan kedalaman maksimum 20 memperoleh akurasi 90,32%, dengan F1-score sebesar 90,32% pada kedua kelas. Confusion matrix menunjukkan 28 prediksi benar dari 31 data uji. Physical Activity Level merupakan fitur paling berpengaruh, diikuti Daily Steps, Age, Blood Pressure, dan Heart Rate. Model juga berhasil diintegrasikan ke dalam aplikasi Android, sedangkan seluruh skenario utama pada pengujian black-box menunjukkan hasil valid. Penelitian selanjutnya perlu menggunakan dataset yang lebih besar dan beragam, memasukkan kelas tidur normal, membandingkan Random Forest dengan algoritma lain, serta melakukan optimasi hyperparameter dan validasi menggunakan data klinis.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada STMIK TIME Medan atas dukungan akademik dan fasilitas yang diberikan selama pelaksanaan penelitian dan penyusunan artikel ini.

DAFTAR PUSTAKA

- Adefemi Ayodele. (2023). A comparative study of ensemble learning techniques for imbalanced classification problems. *World Journal of Advanced Research and Reviews*, 19(2), 1633–1643. <https://doi.org/10.30574/wjarr.2023.19.1.1202>
- An, X., Zhou, J., Xu, Q., Zhao, Z., & Li, W. (2025). Artificial intelligence in obstructive sleep apnea: A bibliometric analysis. In *Digital Health* (Vol. 11). SAGE Publications Inc. <https://doi.org/10.1177/20552076251324446>
- Bhongade, A., & Gandhi, T. K. (2024). *Predict-OSA: Integrative Multimodal-based Early Prediction of Sleep Apnea using Single-lead ECG Signal*. <https://doi.org/10.22541/au.173452558.89977628/v1>
- Dimitriadis, S. I., Salis, C. I., & Liparas, D. (2021). An automatic sleep disorder detection based on EEG cross-frequency coupling and random forest model. *Journal of Neural Engineering*, 18(4). <https://doi.org/10.1088/1741-2552/abf773>



- Farrahi, V., & Rostami, M. (2024). Machine learning in physical activity, sedentary, and sleep behavior research. In *Journal of Activity, Sedentary and Sleep Behaviors* (Vol. 3, Number 1). BioMed Central Ltd. <https://doi.org/10.1186/s44167-024-00045-9>
- Gao, L., & Ding, Y. (2020). Disease prediction via Bayesian hyperparameter optimization and ensemble learning. *BMC Research Notes*, 13(1). <https://doi.org/10.1186/s13104-020-05050-0>
- Hamza, & Kebiri. (2023). *Deep learning methods for diffusion MRI in early development of the human brain: resolution enhancement and model estimation* Kebiri Hamza Kebiri Hamza, 2023, *Deep learning methods for diffusion MRI in early development of the human brain: resolution enhancement and model estimation*. <http://serval.unil.chhttp://serval.unil.ch>
- Hidayat, I. A. (2023). Classification of Sleep Disorders Using Random Forest on Sleep Health and Lifestyle Dataset. *Journal of Dinda Data Science, Information Technology, and Data Analytics*, 3(2), 71–76. <http://journal.ittelkom-pwt.ac.id/index.php/dinda>
- Khasanah, N., Uki Eka Saputri, D., Aziz, F., Hidayat, T., Nusa Mandiri Jl, U., & Author, C. (2025). Studi Perbandingan Algoritma Random Forest dan K-Nearest Neighbors (KNN) dalam Klasifikasi Gangguan Tidur. In *Cipinang Melayu, Kec. Makasar* (Vol. 5, Number 1). <http://jurnal.bsi.ac.id/index.php/co-science>
- 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>
- Morin, C. M., Chen, S. J., Ivers, H., Beaulieu-Bonneau, S., Krystal, A. D., Guay, B., Bélanger, L., Cartwright, A., Simmons, B., Lamy, M., Busby, M., & Edinger, J. D. (2023). Effect of Psychological and Medication Therapies for Insomnia on Daytime Functions: A Randomized Clinical Trial. *JAMA Network Open*, 6(12). <https://doi.org/10.1001/jamanetworkopen.2023.49638>
- ŞEVGIN, H. (2023). A comparative study of ensemble methods in the field of education: Bagging and Boosting algorithms. *International Journal of Assessment Tools in Education*, 10(3), 544–562. <https://doi.org/10.21449/ijate.1167705>
- Sharaf, A. I. (2023). Sleep Apnea Detection Using Wavelet Scattering Transformation and Random Forest Classifier. *Entropy*, 25(3). <https://doi.org/10.3390/e25030399>
- Shin, Y. W., Byun, J.-I., Kim, H.-J., & Jung, K.-Y. (2024). *FORECAST-RBD: Forecasting Phenoconversion Risks and Its Clinical Phenotype in Patients with Isolated RBD Using Machine Learning and Explainable AI*. <https://doi.org/10.1101/2024.06.02.24308240>
- Skaramagkas, V., Kyprakis, I., Karanasiou, G. S., Fotiadis, D. I., & Tsiknakis, M. (2025). A Review on Deep Learning for Quality of Life Assessment Through the Use of Wearable Data. In *IEEE Open Journal of Engineering in Medicine and Biology* (Vol. 6, pp. 261–268). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/OJEMB.2025.3526457>
- Tanuku, S. R., & Tummala, V. (2023). *Integration of Feature Selection Techniques using a Sleep Quality Dataset for Comparing Regression Algorithms*. <http://arxiv.org/abs/2303.02467>
- Widyastuty, W., & Azis, M. A. (2024). Classification and Evaluation of Sleep Disorders Using Random Forest Algorithm in Health and Lifestyle Dataset. *Compiler*, 13(1), 11. <https://doi.org/10.28989/compiler.v13i1.2184>
- Zhang, C., Yu, L., Li, L., Zeng, P., & Zhang, X. (2024). Screening for moderate to severe obstructive sleep apnea by using heart rate variability features based on random forest algorithm. *Sleep and Breathing*, 28(6), 2521–2530. <https://doi.org/10.1007/s11325-024-03151-9>