



Benchmarking XGBoost and Random Forest for Stress Level Prediction Based on Sleep Physiological Parameters

Benchmarking XGBoost dan Random Forest untuk Prediksi Tingkat Stres dari Parameter Fisiologis Tidur

Stanley Alexsander Tamboto^{1*}, Safitri Jaya²

^{1,2}Program Studi Informatika, Universitas Pembangunan Jaya, Indonesia

E-Mail: ¹stanley.alexсандertamboto@student.upj.ac.id, ²safitri.jaya@upj.ac.id

Received May 13th 2026; Revised Jun 12th 2026; Accepted Jul 04th 2026; Available Online Jul 18th 2026

Corresponding Author: Stanley Alexsander Tamboto

Copyright © 2025 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

Stress is one of the increasingly prevalent mental health disorders in society. Physiological conditions during sleep can serve as indicators of stress levels. This study compares the performance of XGBoost and Random Forest for predicting stress levels in five categories: normal, mild, moderate, high, and very high. The dataset consists of numerical data with eight physiological features, including snoring rate, respiration rate, body temperature, limb movement, blood oxygen, rapid eye movement, sleeping hours, and heart rate. The methodology includes data preprocessing (normalization), data splitting, and model evaluation using accuracy, precision, recall, F1-score, and a confusion matrix. Correlation analysis was also conducted to examine relationships between physiological parameters and stress levels. The results show that both models achieved an accuracy of 98% however, Random Forest demonstrated more stable performance based on cross-validation, with an average score of 99.2% compared to 98.7% for XGBoost. Feature importance analysis identified snoring rate as the most dominant feature, while positive and negative correlations were observed among physiological parameters and stress levels. This study concludes that Random Forest provides better model stability and strong potential for predicting stress levels from sleep physiological data.

Keywords: Machine Learning, Random Forest, Sleep Physiological Parameters, Stress Level, XGBoost

Abstrak

Stres adalah salah satu gangguan kesehatan mental yang semakin meningkat di masyarakat. Kondisi fisiologis saat tidur dapat menjadi indikator tingkat stres. Penelitian ini bertujuan untuk membandingkan kinerja metode XGBoost dan Random Forest dalam memprediksi tingkat stres yang diklasifikasikan ke dalam lima kategori, yaitu normal, ringan, sedang, tinggi, dan sangat tinggi. Data yang digunakan berupa data numerik dengan delapan fitur fisiologis, meliputi *snoring rate*, *respiration rate*, *body temperature*, *limb movement*, *blood oxygen*, *rapid eye movement*, *sleeping hours*, dan *heart rate*. Metodologi penelitian mencakup *preprocessing* data melalui normalisasi dan pembagian data, serta evaluasi kinerja model menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, serta *confusion matrix*. Penelitian ini juga melakukan analisis korelasi pada setiap fitur untuk mengetahui hubungan antara parameter fisiologis dan tingkat stres. Hasil penelitian menunjukkan bahwa kedua model menghasilkan akurasi sebesar 98%, namun Random Forest memiliki kinerja yang lebih stabil berdasarkan *cross-validation* dengan nilai rata-rata 99,2% dibandingkan dengan XGBoost sebesar 98,7%. Analisis *feature importance* menunjukkan bahwa *snoring rate* merupakan fitur paling dominan, serta terdapat korelasi positif dan negatif antarparameter terhadap tingkat stres. Penelitian ini menyimpulkan bahwa Random Forest lebih unggul dalam hal stabilitas model dan berpotensi digunakan untuk memprediksi tingkat stres berbasis data fisiologis tidur.

Kata Kunci: Machine Learning, Parameter Fisiologis Tidur, Random Forest, Tingkat Stres, XGBoost

1. PENDAHULUAN

Gangguan kesehatan mental adalah salah satu masalah atau gangguan pada psikologi manusia, terutama di era modern ini. Gangguan kesehatan mental dapat memengaruhi kualitas hidup individu serta hubungan sosial. Kesehatan mental menjadi komponen vital dalam kesehatan secara menyeluruh, bisa dibilang kesehatan belum lengkap tanpa adanya kesehatan mental [1]. Indikator yang memiliki hubungan dengan gangguan kesehatan mental salah satunya adalah stres. Stres merupakan kondisi adanya rasa beban atau tekanan yang

melebihi kemampuan seseorang dalam aspek psikologis [2]. Stres yang tinggi dapat menyebabkan gangguan kesehatan dan menurunkan produktivitas individu. Sebagian orang mampu mengelola stres secara efektif dalam menghadapi tuntutan, sementara sebagian lainnya mengalami kesulitan sehingga berpotensi mengalami tingkat stres yang lebih tinggi [3]. Kecemasan dan depresi merupakan gangguan kesehatan yang berkaitan dengan stres kronis atau stres yang tinggi [4].

Orang dewasa di dunia merasa bahwa sebagian besar waktu mereka mengalami stres [5]. Berdasarkan kondisi tersebut, diperlukan pendekatan yang mampu mengidentifikasi faktor-faktor yang berkaitan dengan tingkat stres, khususnya melalui parameter fisiologis tidur. Tidur merupakan kondisi mental dan fisik yang ditandai dengan penurunan aktivitas tubuh, serta memiliki peran penting dalam menjaga kesehatan mental maupun fisik yang mencakup sekitar 33% dari kehidupan manusia [6]. Tidur melibatkan proses fisiologis yang kompleks, termasuk regulasi sistem saraf dan ritme biologis tubuh, sehingga perubahan yang terjadi selama tidur dapat mencerminkan kondisi fisiologis dan psikologis individu [7]. Kualitas tidur seseorang dapat terganggu oleh tingginya tingkat stres [8]. Dari keadaan tersebut, penelitian ini juga menganalisis hubungan antara berbagai indikator fisiologis tidur dan tingkat stres untuk memperoleh pola yang dapat digunakan sebagai dasar dalam proses prediksi.

Teknologi digunakan sebagai bantuan dalam proses implementasi analisis sehingga menghasilkan hasil yang memuaskan. Teknologi yang digunakan adalah *machine learning*. Teknologi *machine learning* merupakan sistem pengambilan keputusan mandiri yang belajar dari pengalaman melalui data yang diberikan sehingga dapat menjadi lebih pintar tanpa perlu diprogram ulang oleh manusia [9]. *Machine learning* memerlukan algoritma dalam penerapannya untuk menyelesaikan masalah. Terdapat dua pendekatan algoritma yang dapat diterapkan, yaitu *supervised learning* dan kebalikannya, yaitu *unsupervised learning*, untuk diimplementasikan dalam *machine learning* [3]. Pendekatan *machine learning supervised learning* merupakan pendekatan yang menggunakan data pada dataset yang sudah diberi label [10]. Sedangkan pendekatan *unsupervised learning* adalah metode yang tidak memerlukan data berlabel [11].


Metode *machine learning* yang dapat digunakan untuk memprediksi data fisiologis adalah *XGBoost* dan *Random Forest*. Algoritma *XGBoost* berbasis *ensemble* dan menggunakan pengembangan *gradient tree boosting* untuk menangani kasus *machine learning* berskala besar [12]. Sedangkan *Random Forest* merupakan kumpulan algoritma *decision tree* yang kemudian dikelompokkan sehingga menghasilkan algoritma yang lebih akurat [13]. Algoritma *XGBoost* dan *Random Forest* telah banyak dimanfaatkan untuk mengolah data fisiologis atau data medis, terutama untuk memprediksi tingkat stres maupun gangguan kesehatan lainnya. Misalnya, penelitian oleh Astari dkk. (2023) menggunakan algoritma *Random Forest* dan berhasil memperoleh akurasi 93,65% untuk klasifikasi tingkat stres [23]. Studi lain yang dilakukan oleh Larasati dkk. (2024) menunjukkan akurasi sempurna, yaitu 100% dalam deteksi tingkat stres menggunakan algoritma *Random Forest* [3]. Pada penelitian oleh Fahria dkk. (2026) yang mengombinasikan algoritma *Random Forest* dengan *XGBoost* memperoleh akurasi masing-masing 84% dan 78% untuk klasifikasi tingkat stres menggunakan data media sosial [24]. Sementara itu, Chung dan Teo (2023) memperoleh nilai akurasi 87,20% untuk algoritma *XGBoost* dalam klasifikasi gejala depresi [25].

Selain data fisiologis, *XGBoost* dan *Random Forest* juga diterapkan pada data kesehatan lainnya. Klasifikasi penyakit stroke yang menggunakan algoritma *Random Forest* memperoleh akurasi sebesar 93,6% [22]. Dalam sebuah studi terkait klasifikasi penyakit paru-paru, algoritma *XGBoost* dan *Random Forest* mencapai akurasi masing-masing sebesar 94% dan 91%. [20]. Selain itu, algoritma *XGBoost* juga diterapkan untuk klasifikasi gagal ginjal kronis dan menghasilkan akurasi 99% [26].

Berbagai penelitian sebelumnya telah menunjukkan bahwa algoritma *XGBoost* dan *Random Forest* memiliki kinerja yang baik dalam klasifikasi data kesehatan. Sehingga dalam penelitian ini, algoritma *XGBoost* dan *Random Forest* digunakan untuk memprediksi tingkat stres berdasarkan parameter fisiologis tidur. Meskipun berbagai penelitian sebelumnya menunjukkan hasil yang baik, sebagian besar penelitian tersebut belum menggunakan data fisiologis tidur untuk memprediksi tingkat stres dengan menggunakan kombinasi algoritma *XGBoost* dan *Random Forest*. Selain itu, beberapa penelitian hanya berfokus pada hasil akurasi model tanpa melakukan analisis hubungan antarfitur fisiologis maupun analisis untuk mengetahui faktor yang paling memengaruhi tingkat stres. Oleh karena itu, penelitian ini berfokus pada analisis komparatif kinerja model serta analisis korelasi antarfitur untuk menentukan fitur atau faktor apa yang memengaruhi tingkat stres.

2. BAHAN DAN METODE

Tahapan penelitian meliputi pengumpulan dan pemahaman dataset, *preprocessing* data, penerapan algoritma *machine learning* *XGBoost* dan *Random Forest*, serta evaluasi kinerja model. Selain itu, dilakukan analisis lanjutan untuk mengidentifikasi faktor-faktor yang memengaruhi tingkat stres. Keseluruhan tahapan penelitian digambarkan pada Gambar 1 yang menampilkan alur penelitian secara menyeluruh. Skema alur penelitian dapat dilihat pada Gambar 1.

**Gambar 1.** Skema Alur Penelitian


2.1. Pengumpulan Data

Data berupa dataset parameter fisiologis tidur diperoleh dari situs web *Kaggle*. Dataset “*Human Stress Detection in and through Sleep*” [14], [15] diolah dan diaplikasikan dalam proses pelatihan dan pengujian pada algoritma XGBoost dan Random Forest sehingga diperoleh prediksi tingkat stres. Data tersebut disimpan dalam file berformat *comma-separated values* (.csv). Dataset memiliki total 630 data numerik yang merepresentasikan 8 parameter fisiologis, yaitu *snoring rate* (sr), *respiration rate* (rr), *body temperature* (t), *limb movement* (lm), *blood oxygen* (bo), *rapid eye movement* (rem), *sleeping hours* (sh), dan *heart rate* (hr). Parameter *stress level* (sl) digunakan sebagai variabel target untuk parameter lainnya. Variabel sl diklasifikasikan ke dalam lima kategori stres, yaitu normal (0), sangat rendah (1), rendah (2), tinggi (3), dan sangat tinggi (4). Tabel 1 menunjukkan cuplikan isi dari dataset [14], [15].

Tabel 1. Cuplikan Dataset

sr	rr	t	lm	bo	rem	sh	hr	sl
93,8	25,68	91,84	16,6	89,84	99,6	1,84	74,2	3
91,64	25,104	91,552	15,88	89,552	98,88	1,552	72,76	3
60	20	96	10	95	85	7	60	1
85,76	23,536	90,768	13,92	88,768	96,92	0,768	68,84	3
48,12	17,248	97,872	6,496	96,248	72,48	8,248	53,12	0
56,88	19,376	95,376	9,376	94,064	83,44	6,376	58,44	1
47	16,8	97,2	5,6	95,8	68	7,8	52	0
50	18	99	8	97	80	9	55	0
45,28	16,112	96,168	4,224	95,112	61,12	7,112	50,28	0

Setiap parameter memiliki rentang nilai yang berbeda dan saling berhubungan dalam merepresentasikan kondisi fisiologis saat tidur. Setiap data memiliki hubungan antarfitur yang bersifat dinamis, di mana perubahan pada satu parameter fisiologis dapat diikuti oleh perubahan pada parameter lainnya. Distribusi jumlah data pada setiap kategori tingkat stres (sl) bersifat merata, seperti ditunjukkan pada Gambar 2. Distribusi variabel target yang merata dapat mengindikasikan bahwa dataset aman dari *class imbalance*, sehingga model dapat menggunakan data sebagai data latih tanpa bias terhadap kelas tertentu. Distribusi data yang merata ini juga mendukung proses pelatihan model agar mampu mengenali pola pada setiap kategori tingkat stres secara optimal.

**Gambar 2.** Grafik Persebaran *Stress Level* pada Dataset

2.2. Preprocessing Data

Preprocessing dilakukan sebelum data diproses oleh machine learning sehingga data dipastikan bersih dan memiliki nilai serta format yang sesuai [16]. *Preprocessing* pada penelitian ini menerapkan teknik

normalisasi dan pembagian data. Teknik normalisasi dilakukan untuk mengubah rentang nilai pada data yang ditetapkan dalam skala yang ditentukan sehingga setiap atribut seimbang dalam proses pemodelan [17]. Proses normalisasi diterapkan karena setiap data dalam dataset yang digunakan masing-masing memiliki nilai yang rentangnya bervariasi, sehingga dominasi dapat terjadi oleh fitur yang memiliki nilai nilai besar. Min-Max digunakan sebagai metode normalisasi yang diterapkan. Setiap fitur yang memiliki rentang nilai beragam akan diubah ke dalam rentang 0 hingga 1.

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

Berdasarkan persamaan matematika (1), X adalah nilai asli dari suatu data, Xmin adalah nilai minimum pada fitur tersebut, dan Xmax adalah nilai maksimum. Hasil normalisasi X' diperoleh dengan mengurangi nilai asli dengan nilai minimum, kemudian dibagi dengan selisih antara nilai maksimum dan minimum. Tabel 2 menunjukkan data yang telah melewati proses normalisasi metode Min-Max.


Tabel 2. Cuplikan Data Hasil Normalisasi

sr	rr	t	lm	bo	rem	sh	hr	sl
0,887273	0,691429	0,488571	0,840000	0,522667	0,880000	0,204444	0,691429	3
0,848000	0,650286	0,468000	0,792000	0,503467	0,864000	0,172444	0,650286	3
0,272727	0,285714	0,785714	0,400000	0,866667	0,555556	0,777778	0,285714	1
0,741091	0,538286	0,412000	0,661333	0,451200	0,820444	0,085333	0,538286	3
0,056727	0,089143	0,919429	0,166400	0,949867	0,277333	0,916444	0,089143	0
0,216000	0,241143	0,741143	0,358400	0,804267	0,520889	0,708444	0,241143	1
0,036364	0,057143	0,871429	0,106667	0,920000	0,177778	0,866667	0,057143	0
0,090909	0,142857	1,000000	0,266667	1,000000	0,444444	1,000000	0,142857	0
0,005091	0,008000	0,797714	0,014933	0,874133	0,024889	0,790222	0,008000	0

Metode Min-Max diterapkan pada setiap variabel parameter fisiologis tidur, sementara itu variabel sl tidak dilakukan normalisasi karena digunakan sebagai label klasifikasi yang berfungsi sebagai acuan kelas yang akan diprediksi oleh model. Proses *preprocessing* selanjutnya adalah pembagian data yang membagi dataset menjadi dua bagian, yaitu data latih yang digunakan dalam proses membangun model dan data uji yang digunakan dalam evaluasi model [18]. Dalam penelitian ini, data dibagi menggunakan rasio 80:20. Dari 630 baris data yang tersedia, 504 baris digunakan sebagai data pelatihan dan 126 baris digunakan sebagai data pengujian. Penggunaan rasio 80:20 dipilih karena merupakan rasio yang umum digunakan pada penelitian yang menggunakan machine learning, khususnya pada klasifikasi data kesehatan [3, 22, 24].

2.3. Penerapan XGBoost

XGBoost sebagai varian lanjutan *gradient boosting*, memiliki teknik pengaturan *subsampling*, *regularisasi*, dan optimasi komputasi [19]. *Gradient Tree Boosting* yang diterapkan oleh XGBoost menerapkan *tree boosting* dengan menggabungkan kelompok klasifikasi yang lebih lemah untuk membuat klasifikasi yang lebih kuat [20]. Framework XGBost ditunjukkan pada Gambar 3.



Gambar 3. Framework XGBoost

XGBoost mengolah model lama dengan metode *boosting* untuk membangun model baru yang digunakan untuk memprediksi *error* dari model sebelumnya [21]. Dalam penelitian ini, proses *hyperparameter*

dilakukan menggunakan metode *GridSearchCV* dengan pendekatan *cross-validation* untuk menemukan kombinasi parameter terbaik. Hyperparameter tuning diterapkan pada algoritma XGBoost karena parameter yang digunakan dapat memengaruhi performa klasifikasi, kemampuan generalisasi model, serta risiko overfitting [26]. Konfigurasi *hyperparameter* terbaik yang diperoleh dari proses *GridSearchCV* untuk model XGBoost ditunjukkan pada Tabel 3.


Tabel 3. Konfigurasi *Hyperparameter* XGBoost

<i>Hyperparameter</i>	Nilai
<i>n_estimators</i>	50
<i>learning_rate</i>	0,01
<i>max_depth</i>	3
<i>subsample</i>	0,8
<i>colsample_bytree</i>	0,8

Model XGBoost diinisialisasi dengan beberapa *hyperparameter*, mulai dari *n_estimators* yang digunakan untuk jumlah *decision tree* yang akan dibangun dalam proses *boosting*. Parameter *learning_rate* berfungsi untuk mengatur seberapa besar kontribusi setiap *tree*. Selanjutnya, *max_depth* digunakan untuk membatasi kompleksitas *decision tree*. Parameter *subsample* digunakan sebagai proporsi data latih. Parameter *colsample_bytree* digunakan untuk menentukan proporsi fitur yang dipilih secara acak [26].

2.4. Penerapan Random Forest

Random Forest didefinisikan sebagai metode *ensemble* karena menggunakan kumpulan *Decision Tree* [3]. Model *Random Forest* menggunakan kumpulan *Decision Tree* untuk mendapatkan keputusan akhir dengan cara setiap *Decision Tree* memberikan hasil, kemudian dilakukan voting untuk menentukan hasil [22]. *Framework Random Forest* ditunjukkan pada Gambar 4.



Gambar 4. *Framework Random Forest*

Decision Tree yang ada di dalam *Random Forest* memiliki serangkaian *node* yaitu *root*, *internal*, dan *leaf node*, *node* tersebut mengambil data serta atribut secara acak [21]. Sama seperti model XGBoost, *Hyperparameter tuning* pada model *Random Forest* menggunakan metode *GridSearchCV*. Tabel 4 menunjukkan konfigurasi *hyperparameter* terbaik yang diperoleh dari proses *GridSearchCV* untuk model *Random Forest*.

Tabel 4. Konfigurasi *Hyperparameter* Random Forest

<i>Hyperparameter</i>	Nilai
<i>n_estimators</i>	50
<i>max_depth</i>	3
<i>min_samples_split</i>	2

Parameter yang digunakan pada model *Random Forest* ada tiga parameter utama. Parameter *n_estimators* menunjukkan jumlah *decision tree* yang akan dibangun dalam model. Parameter *max_depth*

digunakan untuk menentukan maksimum kedalaman dari *decision tree*. Parameter *min_samples_split* digunakan untuk mengatur minimum data pada *leaf node* [27].

2.5. Evaluasi Model

Tahapan ini ditujukan untuk menilai kinerja model dan mengevaluasi peran parameter fisiologis dalam memengaruhi tingkat stres. Pada penelitian ini proses implementasi dilakukan menggunakan bahasa pemrograman *Python* pada platform *Google Colab*. *Library* yang digunakan meliputi *Pandas* dan *NumPy* untuk pengolahan data, *Scikit-learn* untuk *preprocessing* data, pembagian data, *GridSearchCV*, *cross-validation*, *confusion matrix*, dan evaluasi model, serta *XGBoost* untuk implementasi algoritma *XGBoost*. Visualisasi data dilakukan menggunakan *Matplotlib* dan *Seaborn*, sedangkan proses normalisasi data menggunakan *MinMaxScaler* dari *library Scikit-learn*. Model *XGBoost* dan *Random Forest* yang telah dilatih dan diuji menghasilkan nilai *accuracy*, *precision*, *recall*, dan *F1-score*. Evaluasi model menggunakan *confusion matrix* juga digunakan untuk menggambarkan jumlah data yang telah diklasifikasikan, baik yang menghasilkan hasil benar maupun salah, berdasarkan data pengujian. Pada tahapan terakhir, model diterapkan menggunakan teknik *cross-validation*. Penerapan metode tersebut bertujuan untuk memperoleh evaluasi model yang lebih representatif dalam membandingkan kinerja antaralgoritma. Selain mengevaluasi kinerja model, penelitian ini juga mengevaluasi korelasi antarfitur menggunakan visualisasi *heatmap* dan grafik korelasi antarfitur.


3. HASIL DAN ANALISIS

Proses pelatihan model *XGBoost* dan *Random Forest* dilakukan menggunakan data pelatihan yang sama, yaitu 504 data. Pengujian model *XGBoost* dilakukan menggunakan data uji yang telah ditentukan sebelumnya sebanyak 126 data. Hal yang sama juga diterapkan pada model *Random Forest*, di mana proses pengujian dilakukan menggunakan data pengujian yang sama.

Tabel 5. Hasil Pengujian *XGBoost* dan *Random Forest*

Metrik	<i>XGBoost</i>	<i>Random Forest</i>
<i>Accuracy</i>	0,980	0,980
<i>Precision (avg)</i>	0,978	0,984
<i>Recall (avg)</i>	0,976	0,984
<i>F1-Score (avg)</i>	0,976	0,984

Berdasarkan hasil pengujian pada Tabel 5, kedua model menunjukkan kemampuan yang baik dalam mengenali pola hubungan antara parameter fisiologis tidur dan tingkat stres. Konsistensi metrik penilaian pada setiap kelas menunjukkan bahwa model mampu mempertahankan performa klasifikasi secara merata tanpa mengalami penurunan performa yang signifikan pada kelas tertentu. Kondisi tersebut mengindikasikan bahwa distribusi fitur fisiologis pada setiap kategori stres memiliki karakteristik yang cukup jelas sehingga model dapat membedakan antarkelas dengan optimal. Karakteristik dataset yang memiliki distribusi data seimbang berkontribusi terhadap konsistensi performa model pada seluruh metrik evaluasi.



Gambar 5. Perbandingan *Confusion Matrix XGBoost* dan *Random Forest*


Gambar 5 menunjukkan hasil *Confusion Matrix*, bahwa kedua model dapat melakukan klasifikasi dengan hasil yang hampir sempurna pada setiap kategori. Hal ini mengindikasikan bahwa kedua algoritma dapat membedakan karakteristik antar kelas dengan baik. Kesalahan klasifikasi yang kecil dan hanya muncul pada kelas yang berdekatan, menunjukkan bahwa perbedaan antar kategori stres memiliki pola yang relatif mirip sehingga berpotensi menimbulkan ambiguitas pada batas kelas. Selain itu, tidak terlihat adanya kesalahan

klasifikasi yang signifikan pada kelas yang berjauhan, yang menandakan bahwa model mampu mempertahankan konsistensi dalam mengenali perbedaan tingkat stres secara keseluruhan.

Tabel 6. *Cross Validation* pada Model *XGBoost* dan *Random Forest*


Model	Rata-rata <i>Cross Validation</i>
<i>XGBoost</i>	0,98730
<i>Random Forest</i>	0,99206

Terlihat pada Tabel 6 bahwa kedua model dapat melakukan generalisasi terhadap data uji dengan sangat baik. Hasil *cross-validation* menunjukkan bahwa nilai akurasi pada setiap *fold* pengujian memiliki perbedaan yang relatif kecil, sehingga performa model dapat dikatakan cukup stabil terhadap variasi pembagian data. Kondisi ini menunjukkan bahwa model tersebut tidak hanya bekerja dengan baik pada satu skenario data tertentu, tetapi juga mampu mempertahankan kinerja klasifikasi pada beberapa kombinasi data pelatihan dan data pengujian yang berbeda. Selain itu, penggunaan *hyperparameter tuning* melalui *GridSearchCV* juga membantu meningkatkan kestabilan model dengan memilih kombinasi parameter yang optimal berdasarkan beberapa proses validasi. Meskipun keduanya menunjukkan performa yang tinggi, *Random Forest* lebih unggul dibandingkan *XGBoost*. Kondisi ini dipengaruhi oleh mekanisme *ensemble learning* pada *Random Forest* yang membangun banyak *decision tree* secara independen menggunakan teknik *bootstrap sampling* dan *random feature selection*. Pendekatan tersebut membantu *Random Forest* mengurangi variansi model dan membuat prediksi lebih stabil terhadap perubahan pada data pelatihan. Karakteristik dataset pada penelitian ini yang memiliki pola terstruktur dan distribusi data yang seimbang juga lebih sesuai dengan pendekatan *Random Forest*. Hasil *XGBoost* yang sedikit lebih rendah dapat dipengaruhi oleh mekanisme *boosting* yang membentuk *tree* secara bertahap berdasarkan kesalahan prediksi sebelumnya. Pada dataset dengan pola yang relatif sederhana dan overlap antarkelas yang tidak terlalu kompleks, proses *boosting* yang lebih agresif tidak dapat memberikan *boost* performa secara optimal. Perbedaan performa tersebut menunjukkan bahwa karakteristik dataset memengaruhi efektivitas algoritma *machine learning* yang digunakan.




Gambar 6. Perbandingan *Feature Importance* *XGBoost* dan *Random Forest*

Feature Importance pada Gambar 6 menunjukkan kedua model memiliki pola penilaian yang berbeda terhadap kontribusi masing-masing fitur dalam memprediksi tingkat stres. Pada model *XGBoost*, kontribusi prediksi didominasi oleh beberapa fitur. Algoritma *XGBoost* menggunakan mekanisme *boosting*, pada pendekatan ini fitur yang mampu memperbaiki *error* klasifikasi pada setiap iterasi akan memperoleh nilai *importance* yang lebih tinggi. Oleh karena itu, *XGBoost* cenderung lebih sensitif terhadap pola hubungan *non-linear* maupun interaksi antar fitur pada dataset. *Random Forest* menunjukkan distribusi fitur yang lebih merata, di mana hampir seluruh fitur memberikan kontribusi terhadap proses prediksi. Pada algoritma *Random Forest*, *feature importance* diperoleh berdasarkan seberapa besar suatu fitur mampu mengurangi *impurity* pada banyak *decision tree* yang dibangun secara independen. Karena setiap *tree* dibentuk menggunakan *bootstrap sampling* dan pemilihan fitur secara acak, *Random Forest* cenderung menghasilkan distribusi *importance* yang lebih stabil terhadap fitur-fitur yang memiliki hubungan konsisten dengan variabel target. Selain itu, dataset fisiologis tidur pada penelitian ini memiliki pola hubungan antar fitur yang relatif jelas terhadap tingkat stres sehingga kedua algoritma mampu mengenali pola klasifikasi dengan baik. Korelasi yang cukup kuat antara parameter fisiologis dan tingkat stres menyebabkan fitur-fitur utama secara konsisten dianggap penting oleh kedua algoritma.



Gambar 7. Heatmap Korelasi Setiap Fitur

Korelasi antarfitur yang dominan pada *feature importance* tervalidasi melalui *heatmap* pada Gambar 7. Terlihat adanya konsistensi bahwa fitur yang memiliki pengaruh dominan dalam model juga menunjukkan korelasi yang kuat dengan tingkat stres. Berdasarkan visualisasi tersebut, beberapa fitur seperti *snoring rate*, *respiration rate*, *limb movement*, *rapid eye movement*, dan *heart rate* menunjukkan korelasi positif yang cukup kuat dengan variabel *stress level*. Hal ini memberikan indikasi meningkatnya stres, diikuti oleh peningkatan aktivitas fisiologis tertentu selama tidur, seperti peningkatan denyut jantung, perubahan pola pernapasan, serta peningkatan gerakan tubuh saat tidur. Di sisi lain, fitur *sleeping hours* dan *blood oxygen* menunjukkan korelasi negatif dengan tingkat stres. Kondisi tersebut berbanding terbalik terhadap tingkat stres, meningkatnya stres diikuti penurunan durasi tidur serta kualitas respirasi yang menurun selama tidur.



Gambar 8. Hubungan antara *Stress Level* dengan *Snoring Rate* dan *Sleeping Hours*

Gambar 8 menunjukkan fitur dengan korelasi positif dan negatif terhadap tingkat stres juga menunjukkan pola hubungan yang serupa secara visual. terlihat bahwa peningkatan tingkat stres diikuti oleh peningkatan nilai *snoring rate*, yang mengindikasikan adanya hubungan positif antara keduanya. Secara fisiologis, stres dapat memengaruhi sistem pernapasan dan kualitas tidur individu sehingga menyebabkan gangguan pola tidur, peningkatan ketegangan otot, serta perubahan ritme pernapasan selama tidur [14]. Oleh karena itu, snoring rate menjadi salah satu parameter yang dominan pada proses prediksi tingkat stres. Sebaliknya, pada grafik kedua terlihat peningkatan tingkat stres diikuti oleh penurunan durasi tidur (*sleeping hours*), yang menunjukkan adanya hubungan negatif. Berdasarkan penelitian sebelumnya menyatakan individu yang memiliki tingkat stres tinggi dapat mengalami penurunan kualitas tidur dan penurunan durasi tidur akibat meningkatnya aktivitas psikologis dan kesulitan mencapai kondisi relaksasi [8]. Sehingga dapat dikatakan hasil analisis tersebut sejalan dengan penelitian sebelumnya. Pola ini menggambarkan bahwa perubahan kondisi fisiologis selama tidur memiliki keterkaitan langsung terhadap tingkat stres individu.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan model prediksi tingkat stres berdasarkan parameter fisiologis tidur menggunakan algoritma *XGBoost* dan *Random Forest*. Hasil evaluasi menunjukkan bahwa kedua algoritma dapat menghasilkan performa yang sangat baik, dan algoritma *Random Forest* memiliki kinerja yang lebih stabil berdasarkan hasil *cross-validation*. Penelitian ini juga menunjukkan bahwa parameter fisiologis tidur memiliki keterkaitan dengan kondisi stres, di mana fitur seperti *snoring rate*, *respiration rate*, *limb movement*, dan *body temperature* memberikan kontribusi signifikan dalam proses prediksi tingkat stres pada kedua model. Hasil pelatihan dan pengujian model menunjukkan bahwa pendekatan machine learning berbasis data fisiologis tidur berpotensi digunakan sebagai metode pendukung untuk analisis kondisi stres secara objektif. Penelitian selanjutnya dapat menerapkan metode *deep learning*, serta mengeksplorasi penggunaan dataset yang memiliki fitur beragam seperti penggunaan data *real-time* perangkat *wearable* untuk penerapan model dalam skenario kehidupan sehari-hari.

REFERENCES

- [1] World Health Organization, "Mental health," WHO. [Daring]. Tersedia: <https://www.who.int/data/gho/data/themes/theme-details/GHO/mental-health>. [Diakses: 10 Maret 2026].
- [2] I. N. Amalia, J. Budhiana, dan W. Sanjaya, "Hubungan Stres Dengan Gangguan Siklus Menstruasi Pada Remaja Putri," *Jurnal Wacana Kesehatan*, vol. 8, no. 2, hlm. 75, 2023, doi: 10.52822/jwk.v8i2.526.
- [3] S. S. A. Larasati, E. N. K. Dewi, B. H. Farhansyah, F. A. Bachtar, dan F. Pradana, "Penerapan Decision Tree dan Random Forest dalam Deteksi Tingkat Stres Manusia Berdasarkan Kondisi Tidur," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 5, hlm. 1043–1050, 2024, doi: 10.25126/jtiik.2024117993.
- [4] C. Nursadrina, K. Rahmayanti, M. Sofia, dan S. Asyura, "Pengaruh Stres Terhadap Kesehatan Mental Dan Fisik: Tinjauan Psikologi Klinis," *Journal of Healthcare Technology and Medicine*, vol. 11, no. 1, hlm. 701–705, 2025, doi: 10.33143/jhtm.v11i1.5288.
- [5] Gallup, "State of the World's Emotional Health Report," Gallup, 2025. [Daring]. Tersedia: <https://www.gallup.com/analytics/349280/state-of-worlds-emotional-health.aspx>. [Diakses: 13 Maret 2026].
- [6] R. T. Yusan dan S. H. Fadlilah, "Tinjauan Tidur Dan Kurang Tidur," *Medical and Health Journal*, vol. 2, no. 1, hlm. 27–48, 2022, doi: 10.20884/1.mhj.2023.2.1.7820.
- [7] N. A. Salikunna, W. Didik Astiawan, F. Handayani, dan M. Z. Ramadhan, "Hubungan Antara Kualitas Tidur Dengan Tingkat Konsentrasi Pada Mahasiswa," *Healthy Tadulako Journal (Jurnal Kesehatan Tadulako)*, vol. 8, no. 3, hlm. 157–163, 2022, doi: 10.22487/htj.v8i3.525.
- [8] D. H. P. Babo, "Hubungan Tingkat Stres Dengan Kualitas Tidur Pada Mahasiswa Kesehatan," *Health Science Journal: Jurnal Kesehatan Mayapada*, vol. 1, no. 1, hlm. 15–18, 2025. [Daring]. Tersedia: <https://jurnal.stikesmayapada.ac.id/index.php/HealthScience/article/view/47>.
- [9] A. Wijoyo, A. Y. Saputra, S. Ristanti, S. R. Sya'ban, M. Amalia, dan R. Febriansyah, "Pembelajaran Machine Learning," *OKTAL : Jurnal Ilmu Komputer dan Science*, vol. 3, no. 2, hlm. 375–380, 2024. [Daring]. Tersedia: <https://journal.mediapublikasi.id/index.php/oktal/article/view/2305>.
- [10] R. S. Nurhalizah, R. Ardianto, dan P. Purwono, "Analisis Supervised dan Unsupervised Learning pada Machine Learning: Systematic Literature Review," *Jurnal Ilmu Komputer dan Informatika*, vol. 4, no. 1, hlm. 61–72, 2024, doi: 10.54082/jiki.168.
- [11] M. N. Fahmi, "Implementasi Mechine Learning menggunakan Python Library: Scikit-Learn (Supervised dan Unsupervised Learning)," *Sains Data Jurnal Studi Matematika dan Teknologi*, vol. 1, no. 2, hlm. 87–96, 2023, doi: 10.52620/sainsdata.v1i2.31.
- [12] E. H. Yulianti, O. Soesanto, dan Y. Sukmawaty, "Penerapan Metode Extreme Gradient Boosting (XGBOOST) pada Klasifikasi Nasabah Kartu Kredit," *JOMTA Journal of Mathematics: Theory and Applications*, vol. 4, no. 1, hlm. 21–26, 2022, doi: 10.31605/jomta.v4i1.1792.
- [13] M. M. Alvanof, Bustami, R. K. Dinata, "Penerapan Algoritma Random Forest dalam Deteksi dan Klasifikasi Ransomware," *Jurnal Elektronika Dan Teknologi Informasi*, vol. 5, no. 2, hlm. 23–31, 2024, doi: 10.5201/jet.v5i2.488.
- [14] L. Rachakonda, A. K. Bapatla, S. P. Mohanty, dan E. Kougianos, "SaYoPillow: Blockchain-Integrated Privacy-Assured IoMT Framework for Stress Management Considering Sleeping Habits," *IEEE Transactions on Consumer Electronics*, vol. 67, no. 1, hlm. 20–29, 2021, doi: 10.1109/TCE.2020.3043683.
- [15] L. Rachakonda, S. P. Mohanty, E. Kougianos, K. Karunakaran, dan M. Ganapathiraju, "Smart-Pillow: An IoT Based Device for Stress Detection Considering Sleeping Habits," dalam *2018 IEEE International Symposium on Smart Electronic Systems (iSES) (Formerly iNiS)*, IEEE, 2018, hlm. 161–166. doi: 10.1109/iSES.2018.00043.

-
- [16] M. Fadhilla, R. Wandri, A. Hanafiah, P. R. Setiawan, Y. Arta, dan S. Daulay, "Analisis Performa Algoritma Machine Learning Untuk Identifikasi Depresi Pada Mahasiswa," *Journal of Informatics Management and Information Technology*, vol. 5, no. 1, hlm. 40–47, 2025, doi: 10.47065/jimat.v5i1.473.
 - [17] I. Permana, dan F. Nur Salisah, "Pengaruh Normalisasi Data Terhadap Performa Hasil Klasifikasi Algoritma Backpropagation," *IJIRSE: Indonesian Journal of Informatic Research and Software Engineering*, vol. 2, no. 1, hlm. 67-72, 2022, doi: 10.57152/ijirse.v2i1.311.
 - [18] R. Aziz dan Y. Yamasari, "Eksplorasi Fitur Seleksi pada SVM dan Random Forest dalam Analisis Sentimen Aplikasi GoPay," *Journal of Informatics and Computer Science*, vol. 06, no. 1, hlm. 55-65, 2024, doi: 10.26740/jinacs.v6n01.p55-65.
 - [19] B. Wulan Sari dan D. Prabowo, "Analisis Perbandingan Prediksi Harga Rumah Dengan Random Forest, Gradient Boosting, dan XGBoost," *Intellect: Indonesian Journal of Learning and Technological Innovation*, vol. 4, no. 1, hlm. 42–51, 2025, doi: 10.57255/intellect.v4i1.1385.
 - [20] R. Harahap, M. Irfan, M. A. Dinata, L. Efrizoni, dan Rahmaddeni, "Perbandingan Algoritma Random Forest Dan Xgboost Untuk Klasifikasi Penyakit Paru-Paru Berdasarkan Data Demografi Pasien," *Jurnal Ilmiah Betrik*, vol. 15, no. 2, hlm. 130-141, 2024, doi: 10.36050/3v3xwn06.
 - [21] H. Arrasyid, F. A. Setiawan, dan F. Riana, "Perbandingan Metode Random Forest Dan Xgboost Dalam Prediksi Harga Jual Rumah Di Wilayah Jabodetabek," *Kohesi: Jurnal Multidisiplin Saintek*, vol. 8, no. 7, hlm. 1-19, 2025, doi: 10.8734/Kohesi.v1i2.365.
 - [22] M. Fadli dan R. A. Saputra, "Klasifikasi Dan Evaluasi Performa Model Random Forest Untuk Prediksi Stroke," *Jurnal Teknik*, vol. 12, no. 2, hlm. 72-80, 2023, doi: 10.31000/jt.v12i2.9099.
 - [23] D. F. Astari, Y. H. Chrisnanto, dan Melina, "Klasifikasi Tingkat Stres Saat Tidur Menggunakan Algoritma Random Forest," *Jurnal Mahasiswa Teknik Informatika*, vol. 7, no. 5, hlm. 3676-3684, 2023, doi: 10.36040/jati.v7i5.7750.
 - [24] D. N. Fahria, K. D. Tania, dan R. D. Kurnia, "Analisis Komparatif Algoritma Random Forest, Xgboost, Dan Catboost Untuk Klasifikasi Tingkat Stres Pengguna Media Sosial", *rabit*, vol. 11, no. 1, hlm. 1843–1853, 2026, doi: 10.36341/rabit.v11i1.7449.
 - [25] J. Chung dan J. Teo, "Single classifier vs. ensemble machine learning approaches for mental health prediction," *Brain Informatics*, vol. 10, no. 1, hlm. 1-10, 2023, doi: 10.1186/s40708-022-00180-6.
 - [26] M. Abdillah, B. T. Sarira, A. N. Hidayat, A. N. Fauzan, R. Nurhidayat, A. Septiarini, dan N. Puspitasari, "Implementasi XGBoost dalam Klasifikasi Gagal Ginjal Kronis Menggunakan Dataset Chronic Kidney Disease," *JATISI*, vol. 12, no. 3, hlm. 333-346, 2025, doi: 10.35957/jatisi.v12i3.11546.
 - [27] R. M. Saputra, F. Alzami, Y. T. C. Pramudi, L. Erawan, R. A. Megantara, R. A. Pramunendar, dan M. Yusuf, "Improving Cervical Cancer Classification Using ADASYN and Random Forest with GridSearchCV Optimization," *Infotekmesin*, vol. 16, no. 1, hlm. 59-67, 2025, doi: 10.35970/infotekmesin.v16i1.2552.
-