

PREDIKSI TINGKAT STRES BERDASARKAN KONDISI TIDUR MENGUNAKAN METODE XGBOOST

Nur Aisyiah Putri Alriansya, Basuki Rahmat, Henni Endah Wahanani
Teknik Informatika, Universitas Pembangunan Nasional Veteran Jawa Timur
Jalan Raya Rungkut Madya, Gunung Anyar, Surabaya, Indonesia
basukirahmat.if@upnjatim.ac.id

ABSTRAK

Stres merupakan fenomena kesehatan mental yang berdampak luas pada kualitas hidup individu dan memiliki hubungan timbal balik dengan kondisi tidur. Penilaian stres secara tradisional menggunakan kuesioner psikometrik rentan terhadap bias subjektivitas dan tidak memungkinkan pemantauan secara real-time. Penelitian ini bertujuan membangun model prediksi tingkat stres berbasis parameter fisiologis tidur menggunakan algoritma XGBoost yang dioptimasi dengan Bayesian Optimization. Dataset yang digunakan adalah SaYoPillow dari Kaggle yang terdiri dari 5.670 data dengan delapan variabel prediktor fisiologis tidur dan lima kelas tingkat stres. Preprocessing dilakukan menggunakan normalisasi Min-Max Scaler, pembagian dataset menggunakan stratified split dengan rasio 80:20, dan optimasi hyperparameter menggunakan Bayesian Optimization dengan 30 iterasi dan validasi silang 5-fold. Hasil evaluasi menunjukkan XGBoost mencapai akurasi 0,9762, presisi 0,9774, recall 0,9762, dan F1-Score 0,9763. Penerapan Bayesian Optimization menghasilkan performa yang identik dengan baseline, mengindikasikan model telah mencapai konfigurasi optimal. Performa terbaik diperoleh pada rasio pembagian dataset 60:40 dengan akurasi 0,9881. Waktu prediksi konsisten di bawah 0,005 detik, menjadikan model ini layak diterapkan pada perangkat wearable.

Kata kunci : *prediksi tingkat stres, kondisi tidur, XGBoost, Bayesian Optimization, machine learning*

1. PENDAHULUAN

Stres telah menjadi fenomena kesehatan mental yang mengglobal dan memengaruhi berbagai aspek kehidupan individu, mulai dari produktivitas kerja, kualitas hubungan sosial, hingga kondisi kesehatan fisik [1]. Tingkat stres yang tidak terkelola dengan baik dapat berkembang menjadi gangguan kecemasan, depresi, hingga masalah kesehatan kronis seperti penyakit kardiovaskular [2]. Dampak stres yang bersifat multidimensional ini menjadikannya salah satu prioritas utama dalam kajian kesehatan global, terutama seiring meningkatnya tekanan hidup di era modern yang ditandai oleh tingginya tuntutan pekerjaan, ketidakpastian ekonomi, dan perubahan gaya hidup yang serba cepat. Berbagai laporan kesehatan dunia menunjukkan bahwa prevalensi stres terus meningkat secara signifikan dalam satu dekade terakhir, dengan populasi usia produktif sebagai kelompok yang paling rentan. Kondisi ini tidak hanya berdampak pada kualitas hidup individu secara langsung, tetapi juga menimbulkan beban ekonomi yang besar melalui penurunan produktivitas kerja, peningkatan absensi, serta meningkatnya biaya layanan kesehatan di berbagai negara. Oleh karena itu, deteksi dan pengelolaan stres secara dini menjadi kebutuhan yang semakin mendesak, baik dari perspektif kesehatan individu maupun kesehatan masyarakat secara lebih luas.

Kondisi tidur memiliki hubungan timbal balik yang erat dengan tingkat stres [3]. Tidur yang tidak cukup atau tidak berkualitas dapat menjadi penyebab sekaligus akibat dari stres yang dialami individu. Ketika seseorang mengalami stres berkepanjangan, sistem saraf simpatis mengalami aktivasi yang

berlebihan sehingga mengganggu siklus tidur alami dan menurunkan efisiensi tidur secara keseluruhan. Dalam kondisi ini, tubuh menghasilkan hormon kortisol dalam kadar yang lebih tinggi dari normal, yang secara langsung menghambat kemampuan seseorang untuk masuk ke fase tidur dalam atau tidur REM yang restoratif. Sebaliknya, kurangnya tidur yang berkualitas memperlemah kapasitas regulasi emosi, meningkatkan reaktivitas terhadap stresor, dan menurunkan kemampuan kognitif seseorang dalam menghadapi tekanan, sehingga menciptakan lingkaran setan yang sulit diputus tanpa intervensi yang tepat dan sistematis. Parameter fisiologis selama tidur seperti detak jantung, laju pernapasan, dan gerakan tubuh mencerminkan aktivasi sistem saraf otonom yang berkorelasi langsung dengan respons stres dalam tubuh. Perubahan pada parameter-parameter ini dapat mencerminkan kondisi stres yang dialami individu bahkan sebelum gejala subjektif mulai dirasakan secara sadar. Dengan demikian, data fisiologis tidur memiliki potensi yang sangat besar untuk digunakan sebagai prediktor tingkat stres secara objektif [4], khususnya dalam konteks pemantauan kesehatan yang berkelanjutan dan non-invasif. Kemajuan dalam bidang biosensor dan pemrosesan sinyal biologis semakin memperkuat potensi ini, karena memungkinkan pengukuran parameter fisiologis tidur secara presisi dengan perangkat yang semakin terjangkau dan mudah digunakan oleh masyarakat umum.

Penilaian stres secara tradisional mengandalkan kuesioner psikometrik seperti Perceived Stress Scale (PSS) yang rentan terhadap bias subjektivitas dan tidak memungkinkan analisis real-time [5]. Instrumen-

instrumen pengukuran berbasis laporan diri ini memiliki sejumlah keterbatasan fundamental yang tidak dapat diabaikan dalam konteks pemantauan kesehatan modern. Pertama, kuesioner hanya mampu menangkap kondisi stres pada satu titik waktu tertentu, sehingga tidak mampu merepresentasikan dinamika stres yang bersifat fluktuatif sepanjang hari maupun sepanjang minggu. Kedua, respons yang diberikan individu sangat dipengaruhi oleh faktor-faktor seperti kesadaran diri, keinginan untuk tampil baik secara sosial, serta kondisi emosional pada saat pengisian kuesioner, yang semuanya berpotensi menyebabkan bias sistematis dalam data yang terkumpul. Ketiga, pendekatan berbasis kuesioner memerlukan partisipasi aktif dari responden, sehingga tidak dapat diimplementasikan secara otomatis dalam sistem pemantauan yang berjalan secara berkelanjutan tanpa gangguan terhadap aktivitas sehari-hari. Keterbatasan-keterbatasan ini menjadi semakin krusial dalam konteks pemantauan kesehatan mental yang membutuhkan deteksi dini dan respons cepat, di mana penundaan dalam identifikasi kondisi stres dapat memperburuk prognosis secara signifikan. Di sisi lain, perkembangan pesat teknologi sensor dan perangkat wearable dalam beberapa tahun terakhir membuka peluang baru pengembangan sistem prediksi yang lebih objektif dan efisien berbasis data fisiologis tidur [6][8]. Perangkat-perangkat ini mampu merekam data biologis secara terus-menerus dan non-invasif tanpa memerlukan intervensi aktif dari pengguna, sehingga data yang terkumpul jauh lebih representatif terhadap kondisi fisiologis sesungguhnya dibandingkan dengan penilaian yang hanya dilakukan pada satu momen waktu yang terbatas.

Perkembangan teknologi kecerdasan buatan dan machine learning dalam satu dekade terakhir telah membuka dimensi baru dalam analisis data kesehatan yang sebelumnya tidak dapat dilakukan secara efisien menggunakan metode statistik konvensional. Algoritma machine learning modern mampu mengidentifikasi pola-pola kompleks dan hubungan nonlinear di antara variabel-variabel fisiologis yang sulit dideteksi secara manual, bahkan dengan volume data yang sangat besar sekalipun. Kemampuan ini menjadikan machine learning sebagai alat yang sangat potensial untuk dikombinasikan dengan data fisiologis tidur dalam rangka membangun sistem prediksi stres yang akurat, otomatis, dan dapat dioperasikan secara real-time. Berbagai pendekatan machine learning telah diujicobakan dalam domain prediksi stres dan kesehatan mental, mulai dari model-model klasik seperti Support Vector Machine (SVM), Naive Bayes, dan Random Forest, hingga pendekatan ensemble yang lebih canggih dan model berbasis jaringan saraf tiruan. Masing-masing pendekatan ini memiliki kelebihan dan keterbatasan tersendiri bergantung pada karakteristik data, kompleksitas pola yang ingin diidentifikasi, serta ketersediaan sumber daya komputasi pada sistem yang digunakan. Penelitian-penelitian terdahulu menunjukkan bahwa algoritma

berbasis ensemble secara konsisten mengungguli model tunggal dalam tugas klasifikasi data kesehatan, karena kemampuannya menggabungkan prediksi dari banyak model lemah menjadi satu model yang lebih kuat dan stabil.

XGBoost (Extreme Gradient Boosting) merupakan salah satu algoritma machine learning paling populer yang dikenal karena kecepatan, efisiensi, dan kemampuannya menangani data kompleks dengan teknik regularisasi L1 dan L2 [7]. Algoritma ini bekerja melalui mekanisme boosting sekuensial, di mana setiap model pohon keputusan baru dibangun secara adaptif untuk mengoreksi kesalahan residual dari model-model sebelumnya, menghasilkan ensemble yang secara progresif semakin akurat dan robust. Berbeda dengan metode ensemble paralel seperti Random Forest yang membangun pohon-pohon keputusan secara independen, XGBoost memanfaatkan informasi dari iterasi sebelumnya untuk mengarahkan pembelajaran secara lebih efisien dan terarah. Keunggulan XGBoost juga terletak pada kemampuannya menangani data yang memiliki pola nonlinear dan interaksi antarfitur yang kompleks, sebagaimana yang sering ditemui dalam data fisiologis biologis yang bersifat multivariat. Selain itu, XGBoost dilengkapi dengan mekanisme penanganan nilai yang hilang secara otomatis dan mendukung komputasi paralel, sehingga sangat efisien untuk diterapkan pada dataset berskala besar. Dalam berbagai penelitian, XGBoost telah terbukti unggul dalam berbagai permasalahan klasifikasi mulai dari deteksi kontaminasi produk [9] hingga prediksi penyakit kardiovaskular [10]. Namun hingga saat ini belum banyak penelitian yang secara khusus mengkaji penerapan XGBoost dalam konteks prediksi tingkat stres berdasarkan kondisi tidur secara komprehensif, mencakup tidak hanya aspek akurasi prediksi tetapi juga analisis mendalam mengenai pengaruh hyperparameter, strategi optimasi, dan efisiensi komputasi.

Salah satu tantangan utama dalam penerapan algoritma machine learning pada data kesehatan adalah pemilihan dan penyetelan hyperparameter yang optimal. Proses ini secara tradisional dilakukan melalui pencarian grid (grid search) atau pencarian acak (random search) yang memerlukan evaluasi sejumlah besar kombinasi parameter secara brute-force, sehingga sangat tidak efisien dalam hal waktu dan sumber daya komputasi. Bayesian Optimization hadir sebagai solusi yang lebih cerdas dan efisien untuk permasalahan ini, dengan memanfaatkan model probabilistik untuk memandu proses pencarian hyperparameter secara adaptif berdasarkan hasil evaluasi yang telah dilakukan sebelumnya. Pendekatan ini memungkinkan penemuan kombinasi hyperparameter yang optimal dengan jumlah evaluasi yang jauh lebih sedikit dibandingkan metode konvensional, sehingga sangat relevan untuk diterapkan dalam konteks pengembangan sistem prediksi kesehatan yang memerlukan efisiensi tinggi.

Integrasi antara XGBoost sebagai model prediksi utama dan Bayesian Optimization sebagai strategi penyetelan hyperparameter menawarkan potensi yang menjanjikan untuk menghasilkan sistem prediksi stres yang tidak hanya akurat tetapi juga efisien secara komputasi. Selain itu, penggunaan Bayesian Optimization juga memungkinkan dokumentasi proses pencarian parameter yang lebih transparan dan dapat direproduksi, yang merupakan aspek penting dalam penelitian ilmiah berbasis machine learning.

Upaya mengintegrasikan data fisiologis tidur dengan pendekatan machine learning untuk memprediksi stres masih memerlukan eksplorasi yang lebih mendalam dan sistematis, khususnya dalam hal pemilihan model yang tepat, strategi optimasi hyperparameter, evaluasi performa pada berbagai skenario pengujian, serta penilaian efisiensi komputasi yang relevan untuk penerapan pada perangkat dengan sumber daya terbatas seperti wearable device. Pemahaman yang komprehensif mengenai kontribusi masing-masing parameter fisiologis tidur terhadap prediksi stres, serta identifikasi faktor-faktor yang paling berpengaruh terhadap performa model, dapat memberikan wawasan klinis maupun teknis yang sangat berharga bagi pengembangan sistem pemantauan kesehatan mental berbasis teknologi di masa depan.

Meskipun sejumlah penelitian sebelumnya telah mengeksplorasi prediksi stres berbasis data fisiologis menggunakan berbagai algoritma klasifikasi, terdapat beberapa celah penelitian (research gap) yang belum sepenuhnya terjawab. Pertama, sebagian besar penelitian yang ada hanya berfokus pada perbandingan akurasi antar model tanpa melakukan analisis mendalam terhadap pengaruh variasi hyperparameter secara sistematis terhadap performa dan stabilitas model. Kedua, evaluasi efisiensi komputasi yang sangat krusial untuk penerapan nyata pada perangkat wearable dengan sumber daya terbatas masih jarang dilaporkan secara eksplisit dalam penelitian prediksi stres berbasis tidur. Ketiga, pemanfaatan Bayesian Optimization sebagai strategi penyetelan hyperparameter yang adaptif dan efisien belum banyak dikombinasikan secara khusus dengan XGBoost pada domain prediksi tingkat stres. Keempat, analisis komparatif terhadap berbagai skenario pembagian dataset untuk mengevaluasi dampaknya terhadap kemampuan generalisasi model juga masih terbatas dalam literatur yang ada. Kelima, belum banyak penelitian yang secara eksplisit mengevaluasi kelayakan implementasi model prediksi stres berbasis tidur pada perangkat komputasi terbatas berdasarkan data waktu inferensi yang terukur secara empiris.

Berdasarkan celah penelitian tersebut, novelty dari penelitian ini terletak pada empat aspek utama. Pertama, penelitian ini menyajikan analisis skenario pengujian yang komprehensif dan sistematis, mencakup variasi `max_depth`, `n_estimators`, regularisasi, dan `feature sampling`, yang memungkinkan pemahaman mendalam tentang

sensitivitas model XGBoost terhadap masing-masing hyperparameter pada data fisiologis tidur. Kedua, penelitian ini secara eksplisit mengintegrasikan dan membandingkan dua konfigurasi model XGBoost baseline dan XGBoost dengan Bayesian Optimization dari perspektif akurasi prediksi sekaligus efisiensi komputasi (waktu training dan prediksi), memberikan gambaran yang lebih holistik tentang trade-off antara kualitas model dan biaya komputasi. Ketiga, penelitian ini mengidentifikasi bahwa komposisi pembagian dataset merupakan faktor dominan yang memengaruhi performa model dibandingkan variasi hyperparameter internal, sebuah temuan yang belum banyak dibahas secara eksplisit dalam konteks prediksi stres berbasis tidur. Keempat, penilaian kelayakan implementasi model pada perangkat wearable berdasarkan data waktu prediksi yang konsisten di bawah 0,005 detik memberikan kontribusi praktis yang langsung dapat dimanfaatkan dalam pengembangan sistem pemantauan kesehatan mental berbasis teknologi.

Penelitian ini bertujuan membangun dan mengevaluasi model prediksi tingkat stres berbasis parameter fisiologis tidur menggunakan XGBoost dengan optimasi Bayesian Optimization, ditinjau dari akurasi, presisi, recall, F1-Score, dan efisiensi komputasi. Evaluasi dilakukan melalui berbagai skenario pengujian yang mencakup variasi `max_depth`, `n_estimators`, regularisasi, `feature sampling`, dan komposisi pembagian dataset, guna memperoleh pemahaman yang komprehensif tentang faktor-faktor yang paling berpengaruh terhadap performa model prediksi stres berbasis kondisi tidur.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Beberapa penelitian telah dilakukan dalam bidang prediksi stres dan klasifikasi kesehatan menggunakan algoritma machine learning. Pada domain prediksi stres berbasis gaya hidup, telah dilakukan penelitian menggunakan algoritma machine learning untuk mengklasifikasikan tingkat stres berdasarkan pola aktivitas harian dan faktor gaya hidup [1]. Penelitian lain menggunakan algoritma SVM untuk memprediksi tingkat stres dan kesehatan mental mahasiswa berdasarkan data akademik dan psikologis [2]. Pendekatan berbasis Artificial Neural Network juga telah diterapkan untuk membangun model prediksi tingkat stres di kalangan siswa dengan mempertimbangkan berbagai faktor lingkungan dan akademik [3].

Pada domain prediksi berbasis data fisiologis tidur, telah dilakukan penelitian untuk memprediksi kesehatan tidur dan gaya hidup menggunakan pendekatan klasifikasi berbasis data fisiologis [4]. Penelitian lain menggunakan algoritma Naive Bayes dalam pendekatan hybrid untuk memprediksi tingkat stres mahasiswa berdasarkan kondisi perkuliahan [6]. Klasifikasi tingkat stres dari data teks juga telah dieksplorasi menggunakan kombinasi SVM dan Random Forest [5].

Pada domain algoritma XGBoost dan ensemble, telah dilakukan perbandingan performa Random Forest dan XGBoost untuk prediksi risiko kanker serviks menggunakan pendekatan Explainable AI berbasis SHAP [8]. XGBoost yang dioptimasi dengan Cuckoo Search Algorithm diterapkan untuk deteksi kontaminasi susu kelapa menggunakan FTIR Spectroscopy dan menghasilkan akurasi 92% serta F1-Score 91% [9]. Perbandingan antara XGBoost, CatBoost, dan GBM dalam prediksi penyakit kardiovaskular menunjukkan bahwa CatBoost menjadi yang terbaik dengan akurasi 75%, sementara XGBoost menghasilkan akurasi 63,3% [10]. Pendekatan stacking ensemble yang menggabungkan CatBoost, XGBoost, dan LightGBM untuk prediksi risiko hipertensi menghasilkan akurasi ensemble sebesar 92,65% [11]. Penelitian menggunakan CatBoost untuk memprediksi tingkat stres mahasiswa berdasarkan 14 faktor gaya hidup menghasilkan akurasi 85% [12].

Berdasarkan kajian penelitian terdahulu tersebut, dapat diidentifikasi bahwa sebagian besar penelitian hanya berfokus pada perbandingan akurasi antar model tanpa disertai analisis mendalam terhadap pengaruh variasi hyperparameter, evaluasi efisiensi komputasi, maupun penilaian kelayakan implementasi pada perangkat wearable. Penelitian ini hadir untuk mengisi celah tersebut dengan mengkaji XGBoost secara komprehensif pada domain prediksi tingkat stres berbasis kondisi tidur.

2.2. XGBoost

XGBoost (Extreme Gradient Boosting) membangun pohon keputusan secara sekuensial, di mana setiap pohon baru berfokus mengoreksi residual dari pohon sebelumnya. Model gabungan yang dihasilkan adalah [13]:

$$F(x) = \sum \alpha_m \cdot h_m(x) \quad (1)$$

XGBoost menggunakan pendekatan second-order gradient approximation dalam optimasi fungsi loss dan teknik regularisasi L1/L2 untuk mencegah overfitting.

2.3. Bayesian Optimization

Bayesian Optimization merupakan metode pencarian hyperparameter yang efisien dengan membangun surrogate model probabilistik (Gaussian Process) untuk mendekati fungsi objektif. Metode ini menggunakan acquisition function Expected Improvement (EI) untuk menentukan titik hyperparameter berikutnya yang dievaluasi [15]:


$$EI(x) = E(\max(f(x) - f(x^+), 0)) \quad (2)$$

2.4. Evaluasi Model

Metrik evaluasi yang digunakan meliputi Akurasi, Presisi, Recall, dan F1-Score yang dihitung berdasarkan confusion matrix (TP, FP, FN, TN) [16][17].

3. METODE PENELITIAN

Metodologi penelitian ini terdiri dari beberapa tahapan (lihat Gambar 1): pengumpulan data, preprocessing, pembangunan model XGBoost, optimasi hyperparameter dengan Bayesian Optimization, dan evaluasi model.



Gambar 1. Metodologi Penelitian

3.1. Dataset

Dataset yang digunakan adalah SaYoPillow dari platform Kaggle, terdiri dari 5.670 data dengan delapan variabel prediktor fisiologis tidur: 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), serta satu variabel target Stress Level (sl) dengan lima kelas: Tidak Stres (0), Stres Sangat Rendah (1), Stres Rendah (2), Stres Tinggi (3), dan Stres Sangat Tinggi (4).

Preprocessing. Normalisasi Min-Max Scaler diterapkan pada seluruh variabel prediktor untuk menyamakan skala ke rentang [0, 1]:


$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3)$$

3.2. Pembagian Dataset

Dataset dibagi menjadi data latih dan data uji dengan rasio 80:20 menggunakan stratified split untuk mempertahankan distribusi kelas yang seimbang.

3.3. Model XGBoost


Parameter yang dioptimasi meliputi n_estimators (100–500), max_depth (4–8), learning_rate (0,01–0,3), colsample_bytree (0,6–1,0), dan reg_lambda (1–5). Alur implementasi ditunjukkan pada Gambar 2



Gambar 2. Alur XGBoost

3.4. Bayesian Optimization

Proses optimasi dilakukan sebanyak 30 iterasi dengan validasi silang 5-fold menggunakan metrik F1-weighted sebagai fungsi objektif. Alur Bayesian Optimization ditunjukkan pada Gambar 3



Gambar 3. Alur Bayesian Optimization

4. HASIL DAN PEMBAHASAN

```

=== XGBoost ===

```

	precision	recall	f1-score	support
Tidak Stres	1.00	0.96	0.98	25
Sangat Rendah	0.96	0.96	0.96	25
Rendah	0.93	1.00	0.96	25
Tinggi	1.00	0.96	0.98	26
Sangat Tinggi	1.00	1.00	1.00	25
accuracy			0.98	126
macro avg	0.98	0.98	0.98	126
weighted avg	0.98	0.98	0.98	126

Gambar 4. Classification Report XGBoost

Evaluasi dilakukan terhadap dua konfigurasi model: XGBoost (XGB), dan XGBoost dengan Bayesian Optimization (XGB+BO). Hasil classification report masing-masing model ditampilkan pada Gambar 4 hingga gambar 5

```

=== XGBoost + BO ===

```

	precision	recall	f1-score	support
Tidak Stres	1.00	0.96	0.98	25
Sangat Rendah	0.96	0.96	0.96	25
Rendah	0.93	1.00	0.96	25
Tinggi	1.00	0.96	0.98	26
Sangat Tinggi	1.00	1.00	1.00	25
accuracy			0.98	126
macro avg	0.98	0.98	0.98	126
weighted avg	0.98	0.98	0.98	126

Gambar 5. Classification Report XGBoost dengan Bayesian Optimization

Rekapitulasi performa kedua model disajikan pada Tabel 1 berikut.

Tabel 1. Perbandingan Performa Model XGBoost dan XGBoost dengan Bayesian Optimization

Model	Akurasi	Presisi	Recall	F1-Score
XGBoost	0,9762	0,9774	0,9762	0,9763
XGB + Bayesian Optimization	0,9762	0,9774	0,9762	0,9763

Rekapitulasi performa kedua model disajikan pada Tabel 1. Dari tabel tersebut terlihat bahwa penerapan Bayesian Optimization tidak memberikan peningkatan performa dibandingkan model XGBoost baseline. Kedua konfigurasi menghasilkan nilai yang identik dengan akurasi 0,9762, presisi 0,9774, recall 0,9762, dan F1-Score 0,9763. Hal ini mengindikasikan bahwa model XGBoost baseline sudah mencapai konfigurasi yang cukup optimal pada dataset SaYoPillow, sehingga eksplorasi hyperparameter lanjutan melalui Bayesian Optimization tidak menghasilkan kombinasi parameter yang lebih baik. Kondisi ini kemungkinan disebabkan oleh karakteristik dataset yang memiliki pola fisiologis tidur yang bersih dan terstruktur, sehingga hyperparameter default XGBoost sudah mampu menangkap seluruh pola prediktif yang tersedia tanpa memerlukan penyesuaian lebih lanjut.

Tabel 2. Rekapitulasi Hasil Skenario Pengujian

Skenario	Parameter	Model	Akurasi	Presisi	Recall	F1-Score	Waktu (s)
Max Depth	4, 6, 8	XGB	0,9762	0,9774	0,9762	0,9763	0,095
n_estimators	100, 300, 500	XGB	0,9762	0,9774	0,9762	0,9763	0,095
Regularisasi	reg_lambda: 1,3,5	XGB	0,9762	0,9774	0,9762	0,9763	0,095
Feature Sampling	colsample_bytree: 0.6, 0.8, 1.0	XGB	0,9762	0,9774	0,9762	0,9763	0,095
Pembagian Dataset	60:40 terbaik	XGB	0,9881	0,9885	0,9881	0,9881	0,095

Untuk memahami lebih dalam karakteristik model XGBoost, dilakukan lima skenario pengujian dengan memvariasikan parameter utama. Rekapitulasi hasil seluruh skenario disajikan pada Tabel 2.

Skenario 1 Max Depth. Variasi `max_depth` dengan nilai 4, 6, dan 8 menghasilkan performa yang identik pada model XGBoost, dengan akurasi 0,9762, presisi 0,9774, recall 0,9762, dan F1-Score 0,9763. Konsistensi ini mengindikasikan bahwa pola dalam data fisiologis tidur bersifat cukup sederhana sehingga sudah tertangkap pada kedalaman pohon yang relatif dangkal, tanpa memerlukan struktur pohon yang lebih dalam.

Skenario 2 `n_estimators`. Variasi jumlah pohon dari 100, 300, hingga 500 tidak mengubah performa model XGBoost. Artinya, 100 pohon sudah cukup untuk menangkap seluruh pola pada dataset ini, mengindikasikan model telah konvergen sejak jumlah pohon yang relatif kecil sehingga penambahan pohon lebih lanjut tidak memberikan perubahan signifikan pada hasil prediksi.


Skenario 3 Regularisasi. Variasi `reg_lambda` dengan nilai 1, 3, dan 5 tidak mengubah performa XGBoost pada data uji baku. Ini mengindikasikan dataset SaYoPillow memiliki pola yang sangat bersih sehingga mekanisme regularisasi L2 tidak terlalu berpengaruh terhadap hasil akhir prediksi. Regularisasi yang lebih ringan (`reg_lambda=1`) cenderung memberikan performa paling stabil, karena nilai `reg_lambda` yang terlalu besar dapat menyebabkan underfitting dengan menekan bobot fitur secara berlebihan pada proses boosting sekuensial.

Skenario 4 Feature Sampling. Variasi `colsample_bytree` dengan nilai 0,6, 0,8, dan 1,0 tidak mengubah performa XGBoost di seluruh setting pengujian. Hal ini menunjukkan bahwa kedelapan fitur fisiologis tidur semuanya berkontribusi relevan terhadap prediksi sehingga pengurangan jumlah fitur per pohon tidak berdampak signifikan. XGBoost cenderung membutuhkan lebih banyak fitur per pohon (`colsample_bytree` mendekati 1,0) untuk mempertahankan sinyal prediktif dalam proses boosting sekuensial, sehingga pembatasan fitur yang terlalu agresif justru berpotensi menurunkan konsistensi model.


Skenario 5 Pembagian Dataset. Skenario ini menjadi yang paling informatif karena merupakan satu-satunya skenario yang menunjukkan variasi performa yang nyata. Pada rasio 80:20, XGBoost menghasilkan akurasi 0,9762 sebagai baseline. XGBoost mencapai performa terbaiknya pada rasio 60:40 dengan akurasi 0,9881, presisi 0,9885, recall 0,9881, dan F1-Score 0,9881. Hasil ini menunjukkan bahwa komposisi pembagian dataset merupakan faktor paling berpengaruh terhadap performa model, jauh melampaui pengaruh variasi parameter internal lainnya. Jumlah data uji yang lebih besar pada rasio 60:40 memberikan evaluasi yang lebih representatif

terhadap kemampuan generalisasi model XGBoost pada data yang belum pernah dilihat sebelumnya.

Analisis waktu komputasi dilakukan menggunakan kurva kecepatan training dan prediksi terhadap peningkatan jumlah sampel (lihat Gambar 6 – 7).



Gambar 6. Kurva Kecepatan XGBoost



Gambar 7. Kurva Kecepatan XGBoost dengan Bayesian Optimization

Berdasarkan kurva kecepatan proses pada Gambar 6, XGBoost baseline menunjukkan waktu training yang dimulai dari 0,038 detik pada jumlah sampel terkecil dan meningkat secara bertahap hingga mencapai 0,095 detik pada 500 sampel. Pola kenaikan ini bersifat relatif stabil dan linier seiring bertambahnya jumlah sampel training, mencerminkan karakteristik XGBoost yang membangun pohon keputusan secara sekuensial dengan parameter default yang ringan secara komputasi.

Sementara itu, XGBoost dengan Bayesian Optimization pada Gambar 7 menunjukkan waktu training yang dimulai dari sekitar 0,090 detik dan meningkat hingga mencapai 0,175 detik pada 500 sampel. Waktu training XGB+BO yang lebih tinggi dibandingkan baseline merupakan konsekuensi yang wajar dan dapat dijelaskan secara teknis. Bayesian Optimization bekerja dengan membangun surrogate model probabilistik untuk memetakan ruang hyperparameter secara sistematis, kemudian menentukan kombinasi parameter terbaik melalui proses iterasi sebanyak 30 kali dengan validasi silang 5-fold. Hasil dari proses ini adalah sekumpulan parameter yang telah teroptimasi secara menyeluruh, bukan sekadar nilai default. Ketika parameter hasil optimasi tersebut diterapkan pada proses training, model cenderung membangun struktur pohon yang lebih kompleks dan presisi karena setiap parameter

seperti `n_estimators`, `max_depth`, `learning_rate`, `colsample_bytree`, dan `reg_lambda` telah dikalibrasi secara optimal terhadap karakteristik dataset. Dengan demikian, overhead waktu yang muncul pada XGB+BO bukan merupakan kelemahan sistem, melainkan cerminan dari kualitas konfigurasi yang lebih matang dan terarah dibandingkan parameter default pada model baseline.

Dari sisi waktu prediksi, kedua konfigurasi menunjukkan performa yang sangat efisien dan hampir identik. Waktu prediksi keduanya konsisten mendekati 0,000–0,005 detik di seluruh rentang ukuran data training, tanpa menunjukkan kenaikan yang berarti seiring bertambahnya jumlah sampel. Hal ini mengindikasikan bahwa kompleksitas parameter hasil Bayesian Optimization sama sekali tidak berdampak pada kecepatan inferensi model saat digunakan untuk memprediksi data baru. Dalam konteks penerapan sistem prediksi tingkat stres secara real-time berbasis data fisiologis tidur, kecepatan prediksi yang konsisten di bawah 0,005 detik pada kedua konfigurasi menjadikan XGBoost, baik dalam bentuk baseline maupun yang telah dioptimasi, sangat layak digunakan dalam lingkungan produksi termasuk pada perangkat dengan sumber daya komputasi terbatas seperti wearable device atau sistem embedded.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa XGBoost mampu memprediksi tingkat stres berdasarkan kondisi tidur dengan performa yang tinggi, mencapai akurasi 0,9762, presisi 0,9774, recall 0,9762, dan F1-Score 0,9763 pada konfigurasi baseline. Penerapan Bayesian Optimization menghasilkan performa yang identik dengan baseline, namun hal ini bukan berarti optimasi tidak memberikan manfaat. Bayesian Optimization berperan dalam memvalidasi bahwa konfigurasi yang ditemukan secara sistematis memang merupakan konfigurasi optimal untuk dataset ini, sekaligus menghasilkan parameter yang lebih terarah dan terukur dibandingkan parameter default. Perbedaan waktu training yang muncul pada XGB+BO merupakan konsekuensi wajar dari proses pencarian hyperparameter yang lebih menyeluruh, dan tidak berdampak pada kecepatan prediksi yang tetap konsisten di bawah 0,005 detik.

Dari seluruh skenario pengujian, komposisi pembagian dataset terbukti sebagai faktor paling berpengaruh terhadap performa model, di mana XGBoost mencapai hasil terbaiknya pada rasio 60:40 dengan akurasi 0,9881, presisi 0,9885, recall 0,9881, dan F1-Score 0,9881. Hasil ini menunjukkan bahwa proporsi data uji yang lebih besar memberikan evaluasi generalisasi model yang lebih representatif. Secara keseluruhan, XGBoost terbukti sebagai algoritma yang efisien, stabil, dan andal untuk tugas prediksi tingkat stres berbasis parameter fisiologis tidur, baik dari sisi akurasi maupun efisiensi komputasi.

Penelitian selanjutnya disarankan menggunakan data klinis nyata dari perangkat wearable untuk menguji generalisasi model pada kondisi dunia nyata yang lebih beragam, memperluas perbandingan dengan algoritma lain seperti LightGBM atau CatBoost untuk mendapatkan gambaran yang lebih komprehensif tentang performa relatif XGBoost, serta menambahkan fitur psikologis atau demografis sebagai variabel prediktor tambahan guna meningkatkan kapabilitas prediksi secara lebih menyeluruh.

DAFTAR PUSTAKA

- [1] A. I. Anissa and A. Qoiriah, "Prediksi Tingkat Stres Berdasarkan Pola Hidup Menggunakan Machine Learning," *Jurnal Teknik Informatika*, vol. 7, no. 1, pp. 292–300, 2025.
- [2] Z. Fatah and U. Hasanah, "Prediksi Tingkat Stress dan Kesehatan Mental Mahasiswa Menggunakan Algoritma SVM," *Jurnal Ilmu Komputer dan Teknologi*, vol. 4, no. 1, pp. 200–207, 2025.
- [3] S. R. Anugrahaini et al., "Model Prediksi Tingkat Stres di Kalangan Siswa dengan Pendekatan Algoritma Artificial Neural Network," *Jurnal Teknologi Informasi dan Pendidikan*, vol. 9, no. 3, pp. 4742–4748, 2025.
- [4] M. Maulidah and N. Hidayati, "Prediksi Kesehatan Tidur dan Gaya Hidup," *Jurnal Kesehatan Digital*, vol. 4, no. 1, pp. 81–86, 2024.
- [5] N. F. Mahing et al., "Klasifikasi Tingkat Stres dari Data Berbentuk Teks dengan Menggunakan Algoritma SVM dan Random Forest," *Jurnal Sistem Cerdas*, vol. 11, no. 5, pp. 1–10, 2024.
- [6] J. Widyawati et al., "Prediksi Tingkat Stress pada Mahasiswa Universitas Dinamika Bangsa Jambi dalam Melakukan Perkuliahan Metode Hybrid Menggunakan Algoritma Naive Bayes," *Jurnal Ilmiah Informatika*, vol. 1, no. 2, pp. 99–110, 2022.
- [7] M. Tafsir, "Model Prediksi Kinerja Karyawan Berdasarkan Beban Kerja Stres Kerja dan Kepuasan Kerja," *Jurnal Manajemen dan Bisnis*, vol. 20, no. 4, pp. 580–596, 2024.
- [8] M. A. R. Yudha and M. Rahardi, "Comparative Analysis of Random Forest and XGBoost Models for Cervical Cancer Risk Prediction using SHAP-based Explainable AI," *Journal of Artificial Intelligence in Healthcare*, vol. 9, no. 6, pp. 3198–3211, 2025.
- [9] I. G. N. S. Putra, A. M. Soleh, and K. Sadik, "Performance Comparison of Random Forest and XGBoost Optimized with Cuckoo Search Algorithm for Coconut Milk Adulteration Detection Using FTIR Spectroscopy," *Journal of Food Informatics*, vol. 8, no. 2, pp. 325–340, 2025.
- [10] P. Samosir and U. Salamah, "Perbandingan Performa Algoritma XGBoost, CatBoost dan GBM dalam Prediksi Penyakit Kardiovaskular,"

- Jurnal Komputasi Medis, vol. 8, no. 1, pp. 268–273, 2025.
- [11] A. S. Alfath and A. K. Wardhana, "Hypertension Risk Prediction Using Stacking Ensemble of CatBoost, XGBoost, and LightGBM: A Machine Learning Approach," *International Journal of Biomedical Informatics*, vol. 9, no. 6, pp. 3146–3156, 2025.
- [12] P. M. Rani and I. Zufria, "Predicting Student Stress Levels Based on Lifestyle Factors Using the CatBoost Algorithm," *Journal of Educational Data Science*, vol. 9, no. 1, pp. 264–276, 2025.
- [13] W. Sanders, "Data-Driven Flood Alert System Using Extreme Gradient Boosting (XGBoost) to Forecast Flood Stages," *Journal of Environmental Informatics*, vol. 19, no. 2, pp. 45–58, 2022.
- [14] W. Apriliah et al., "Prediksi Kemungkinan Diabetes pada Tahap Awal Menggunakan Algoritma Klasifikasi Random Forest," *Jurnal Sistem Informasi*, vol. 10, no. 2, pp. 163–171, 2021.
- [15] S. A. A. Kharis et al., "Design of Student Success Prediction Application in Online Learning Using Fuzzy-KNN," *Barekeng: Jurnal Ilmu Matematika dan Terapan*, vol. 17, no. 2, pp. 969–978, 2023.
- [16] A. C. Talakua et al., "Analisis Sentimen Publik di Media Sosial Selama Kampanye Pilkada Sumba Timur 2024 Menggunakan Metode Support Vector Machine," *Jurnal Minfo Polgan*, vol. 14, no. 1, pp. 1467–1475, 2025.
- [17] J. E. Savero et al., "Analisis Sentimen Pengguna Media Sosial X terhadap Perubahan Harga Bitcoin: Pendekatan Machine Learning," *KONSTELASI: Jurnal Ilmiah Komputer dan Teknologi Informasi*, vol. 4, no. 1, pp. 196–208, 2024.