

Perbandingan Model Regresi Machine Learning untuk Prediksi Skor Tingkat Stres Berdasarkan Pola Screen Time Tahun 2025

Daffa Pratama Putra^{*1}, Apriyadi², Zikri Firmansyah³, Ken Dhita Tania⁴, Dedy Kurniawan⁵

^{1,2,3}Universitas Sriwijaya, Indonesia

Email: ¹09031282328090@student.unsri.ac.id, ²09031282328078@student.unsri.ac.id,

³09031282328064@student.unsri.ac.id

Abstrak

Transformasi digital yang masif pada era modern telah mendorong peningkatan signifikan dalam durasi paparan layar (screen time), yang diidentifikasi sebagai salah satu faktor risiko utama terhadap kesehatan mental, khususnya peningkatan prevalensi stres psikologis. Metode diagnosis konvensional yang mengandalkan instrumen kuesioner mandiri dinilai kurang optimal karena rentan terhadap bias pelaporan dan bersifat subjektif. Penelitian ini bertujuan untuk membandingkan performa tiga algoritma machine learning, yaitu Random Forest, Support Vector Regression (SVR), dan XGBoost Regression, dalam memprediksi skor tingkat stres secara kontinu (skala 0–10) berdasarkan pola penggunaan perangkat digital. Tahapan penelitian meliputi akuisisi dataset "Screentime vs Mental Wellness Survey 2025" dari repositori publik, pra-pemrosesan data melalui imputasi statistik, normalisasi Min-Max Scaling, dan One-Hot Encoding, dilanjutkan dengan pembangunan model menggunakan evaluasi 10-fold cross-validation serta interpretasi model berbasis metode SHAP. Hasil evaluasi pada data uji menunjukkan bahwa XGBoost merupakan model dengan performa terbaik, mencapai nilai Mean Absolute Error (MAE) terendah sebesar 0,6502, Root Mean Squared Error (RMSE) sebesar 0,8253, dan koefisien determinasi (R^2) sebesar 0,8367. Temuan ini mengindikasikan bahwa model mampu menjelaskan lebih dari 83% variasi tingkat stres pada data yang belum pernah dilatih sebelumnya. Analisis feature importance mengungkapkan bahwa indeks kesejahteraan mental dan produktivitas merupakan prediktor paling dominan, sedangkan durasi screen time berkontribusi relatif kecil, yang menunjukkan bahwa faktor psikologis internal lebih berpengaruh terhadap stres dibandingkan intensitas interaksi digital semata. Penelitian ini menyimpulkan bahwa pendekatan ensemble learning, khususnya XGBoost, efektif dalam memodelkan fenomena stres yang bersifat kompleks dan multidimensional sebagai dasar pengambilan keputusan klinis berbasis data.

Kata kunci: Kesehatan Mental, Machine Learning, Prediksi Stres, Screen Time, XGBoost.

Comparison of Machine Learning Regression Models for Predicting Stress Level Scores Based on 2025 Screen Time Patterns

Abstract

The massive expansion of digital technology has driven a significant increase in screen time duration, identified as a primary risk factor for mental health deterioration, particularly the rising prevalence of psychological stress. Conventional diagnostic methods relying on self-administered questionnaires are considered suboptimal due to their susceptibility to reporting bias and inherent subjectivity. This study aims to compare the performance of three machine learning regression algorithms — Random Forest, Support Vector Regression (SVR), and XGBoost Regression — in predicting continuous stress level scores (on a 0–10 scale) based on digital device usage patterns. The research pipeline encompasses dataset acquisition from the "Screentime vs Mental Wellness Survey 2025", systematic preprocessing through statistical imputation, Min-Max Scaling, and One-Hot Encoding, followed by model construction evaluated via 10-fold cross-validation and interpretability analysis using the SHAP method. Evaluation results on the test set indicate that XGBoost achieved the best performance, attaining the lowest Mean Absolute Error (MAE) of 0.6502, Root Mean Squared Error (RMSE) of 0.8253, and coefficient of determination (R^2) of 0.8367, demonstrating that the model explains more than 83% of stress score variance on previously unseen data. Feature importance analysis reveals that the mental wellness index and productivity level are the most dominant predictors, while screen time duration contributes comparatively little, suggesting that internal psychological factors exert a stronger influence on stress than digital interaction intensity alone. This study concludes that ensemble learning, particularly XGBoost, is highly effective in modeling the complex, multidimensional nature of psychological stress as a foundation for data-driven clinical decision-making.

Keywords: *Machine Learning, Mental Health, Screen Time, Stress Prediction, XGBoost.*

1. PENDAHULUAN

Transformasi digital yang masif pada tahun 2025 telah mengaburkan batasan antara kehidupan produktif dan ketergantungan perangkat elektronik. Meskipun teknologi menawarkan efisiensi, peningkatan durasi paparan layar (screen time) telah diidentifikasi sebagai katalisator utama krisis kesehatan mental global, khususnya peningkatan prevalensi stres psikologis [1]. Pola penggunaan perangkat digital kini dianggap sebagai "digital biomarkers" yang menyimpan data perilaku kompleks, di mana durasi penggunaan yang berlebihan dan adiksi ponsel pintar berkorelasi signifikan dengan penurunan kepuasan hidup serta gangguan emosional pasca-pandemi [2].

Metode diagnosis stres tradisional yang mengandalkan kuesioner mandiri mulai dianggap kurang efektif karena sifatnya yang subjektif dan rentan terhadap bias pelaporan [3]. Sebagai alternatif, integrasi Kecerdasan Buatan (AI) dan Machine Learning (ML) menawarkan pendekatan proaktif melalui analisis prediktif yang lebih objektif dan real-time [4]. Sejumlah studi terkini menunjukkan bahwa pendekatan pembelajaran mesin mampu memodelkan pola perilaku digital secara akurat untuk tujuan prediksi kesehatan mental, baik melalui kerangka klasifikasi maupun regresi, tergantung pada bentuk variabel target yang dianalisis [5], [6].

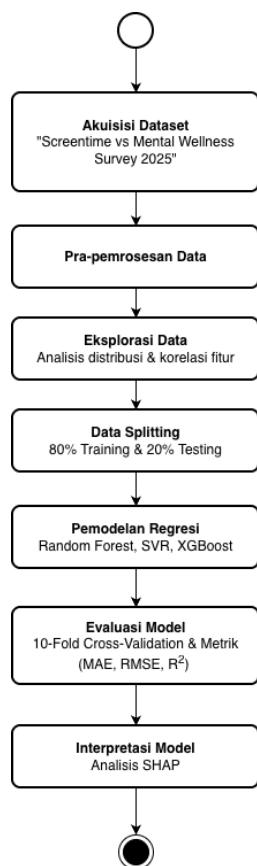
Namun demikian, terdapat celah literatur (research gap) yang signifikan dalam penelitian terkini. Sebagian besar penelitian terdahulu berfokus pada pendekatan klasifikasi untuk mendeteksi gangguan mental secara kategorikal [7], [8], yang seringkali gagal menangkap pola non-linear pada data perilaku digital yang kompleks. Pendekatan tersebut belum sepenuhnya merepresentasikan variasi intensitas stres dalam bentuk skor kontinu. Di sisi lain, meskipun model berbasis deep learning menunjukkan performa tinggi, isu interpretabilitas masih menjadi tantangan utama dalam aplikasi kesehatan mental [9]. Selain itu, optimalisasi seleksi fitur untuk mengidentifikasi variabel screen time yang paling relevan terhadap prediksi stres belum banyak dikaji secara sistematis dalam konteks data terkini [4], [10].

Penggunaan algoritma berbasis ensemble learning telah terbukti memberikan performa yang superior dalam berbagai domain analisis perilaku digital. Penelitian oleh Al Fachrozi dan Tania [11] menunjukkan bahwa algoritma Random Forest efektif dalam menangkap pola perilaku kompleks melalui analisis aspek pada data aplikasi digital. Keunggulan model ensemble lainnya, khususnya XGBoost, juga telah divalidasi dalam memprediksi perilaku pengguna yang bersifat dinamis dengan tingkat akurasi dan interpretabilitas yang tinggi [12]. Secara spesifik, efektivitas komparatif antara Random Forest dan XGBoost telah terbukti sangat relevan dalam kasus klasifikasi tingkat stres pengguna media sosial, di mana kedua algoritma tersebut mampu memberikan hasil yang konsisten dibandingkan model tradisional lainnya [13].

Berdasarkan landasan tersebut, penelitian ini bertujuan untuk menjawab keterbatasan pada studi-studi sebelumnya melalui analisis komparatif tiga algoritma pembelajaran mesin, yaitu Random Forest, Support Vector Regression (SVR), dan XGBoost Regression dalam memprediksi skor tingkat stres berdasarkan pola penggunaan perangkat digital. Kebaruan penelitian ini terletak pada pemanfaatan dataset survei tahun 2025 serta penerapan optimasi model untuk menghasilkan prediksi stres yang lebih akurat dan interpretatif sebagai dasar pengambilan keputusan klinis di era modern..

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif eksperimental yang dirancang secara sistematis untuk membangun serta mengevaluasi model prediksi tingkat stres berbasis data perilaku digital. Alur penelitian dimulai dengan akuisisi dataset sekunder yang relevan dengan pola penggunaan perangkat digital tahun 2025, dilanjutkan dengan tahap pra-pemrosesan untuk memastikan kualitas dan konsistensi data. Selanjutnya, dilakukan eksplorasi data awal (Exploratory Data Analysis) guna memahami distribusi variabel serta hubungan antar fitur. Tahap inti penelitian mencakup pembangunan model prediksi menggunakan tiga algoritma regresi, yaitu Random Forest Regression, Support Vector Regression (SVR), dan XGBoost Regression. Tahap akhir difokuskan pada interpretasi model menggunakan metode SHAP untuk memperoleh pemahaman yang lebih transparan terhadap faktor-faktor utama pemicu stres.



Gambar 1. Alur penelitian

Dataset yang digunakan dalam penelitian ini adalah “Screentime vs Mental Wellness Survey 2025” yang diperoleh dari repositori data publik. Dataset ini mencakup variabel independen berupa durasi penggunaan media sosial, hiburan digital, komunikasi, frekuensi notifikasi, serta atribut demografis. Variabel dependen dalam penelitian ini adalah skor tingkat stres kontinu pada rentang 0–10. Pra-pemrosesan data dilakukan melalui pembersihan data untuk menangani nilai hilang menggunakan imputasi statistik (median untuk fitur numerik dan modus untuk fitur kategorikal). Fitur numerik dinormalisasi menggunakan metode Min-Max Scaling untuk mentransformasikan nilai ke dalam rentang seragam, sehingga menghindari dominasi fitur tertentu dalam algoritma berbasis jarak seperti SVR.

Pemilihan ketiga algoritma ini didasarkan pada karakteristik data survei kesehatan mental yang cenderung memiliki sebaran non-linear. Random Forest dipilih karena ketangguhannya terhadap outlier dan kemampuannya menangani interaksi antar fitur tanpa memerlukan asumsi distribusi data yang ketat [11], [13]. Sementara itu, Support Vector Regression (SVR) diintegrasikan karena kemampuannya dalam melakukan pemetaan data ke ruang dimensi tinggi melalui fungsi kernel, yang efektif untuk dataset dengan jumlah fitur terbatas namun memiliki hubungan yang kompleks [1]. Terakhir, XGBoost digunakan sebagai model unggulan karena efisiensi komputasinya dan penerapan teknik regularized boosting (L1 dan L2) yang secara signifikan meminimalkan risiko overfitting pada data perilaku digital yang dinamis [12].

Setelah tahap pra-pemrosesan selesai, seleksi fitur dilakukan untuk mengidentifikasi variabel yang paling relevan terhadap prediksi stres. Proses ini bertujuan untuk mengurangi noise, meningkatkan efisiensi komputasi, serta memperkuat performa model. Model regresi kemudian dibangun menggunakan pustaka Scikit-Learn dan XGBoost pada lingkungan Python 3.11. Random Forest Regression dikonfigurasi melalui optimasi parameter seperti jumlah pohon ($n_estimators$), sedangkan SVR menggunakan kernel RBF dengan penyetelan parameter C dan gamma. Model XGBoost Regression diatur menggunakan learning rate serta mekanisme regularisasi untuk menghindari overfitting. Seluruh model dilatih menggunakan skema k-fold cross-validation ($k=10$) guna menjamin validitas hasil prediksi.

Evaluasi performa model dilakukan menggunakan metrik regresi yang komprehensif, yaitu Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), serta koefisien determinasi (R^2). Metrik ini dipilih karena mampu menggambarkan tingkat kesalahan prediksi secara kuantitatif pada skor stres kontinu. Setelah model terbaik diperoleh, analisis Explainable AI dilakukan menggunakan metode SHAP untuk menjelaskan kontribusi

masing-masing fitur terhadap prediksi stres. Visualisasi seperti summary plot dan dependence plot digunakan untuk mengidentifikasi pola perilaku digital yang paling berpengaruh dalam meningkatkan skor stres responden.

3. HASIL DAN PEMBAHASAN

3.1. Gambaran Umum Data

Dataset yang digunakan dalam penelitian ini terdiri dari 400 observasi dengan 14 variabel independen dan satu variabel dependen, yaitu tingkat stres dalam rentang skala 0–10. Variabel target bersifat numerik kontinu sehingga pendekatan regresi dipilih sebagai metode pemodelan yang paling sesuai.

Seluruh fitur dalam dataset mencakup kombinasi variabel numerik dan kategorikal. Variabel numerik meliputi durasi screen time, indeks kesejahteraan mental, produktivitas, kualitas tidur, serta beberapa indikator perilaku digital lainnya. Sementara itu, variabel kategorikal mencakup karakteristik demografis seperti jenis kelamin.

Tahap pra-pemrosesan dilakukan secara sistematis melalui beberapa langkah, yaitu penanganan nilai hilang, normalisasi data numerik menggunakan Min-Max Scaling, serta transformasi variabel kategorikal menggunakan teknik One-Hot Encoding. Proses encoding menghasilkan peningkatan jumlah fitur secara signifikan, dari 14 fitur awal menjadi 341 fitur setelah transformasi. Peningkatan ini merupakan konsekuensi logis dari representasi kategori menjadi variabel biner.

Data kemudian dibagi menggunakan skema hold-out dengan proporsi 80% sebagai data pelatihan dan 20% sebagai data pengujian. Dengan demikian, diperoleh 320 data latih dan 80 data uji. Pendekatan ini bertujuan untuk memastikan bahwa model dievaluasi pada data yang belum pernah dilihat sebelumnya sehingga mengurangi risiko overfitting.

3.2. Evaluasi Kinerja Model Menggunakan Cross-Validation

Evaluasi awal dilakukan menggunakan teknik 10-fold cross-validation untuk mengukur konsistensi dan performa model pada data pelatihan. Pendekatan ini bertujuan untuk mengurangi bias akibat pembagian data tunggal serta memberikan estimasi performa yang lebih stabil.

Perbandingan nilai rata-rata Mean Absolute Error (MAE) dan standar deviasi dari masing-masing algoritma ditampilkan pada Tabel 1.

Tabel 1. Hasil Evaluasi Cross-Validation (10-Fold)

Model	CV MAE (Mean)	CV MAE (Std)
Random Forest	0.5661	0.0856
SVR (RBF)	0.6185	0.0923
XGBoost	0.5593	0.1024

Berdasarkan hasil pada Tabel 1, algoritma XGBoost menghasilkan nilai rata-rata MAE terendah sebesar 0,5593, diikuti oleh Random Forest sebesar 0,5661 dan Support Vector Regression sebesar 0,6185. Temuan ini menunjukkan bahwa secara rata-rata XGBoost memiliki tingkat kesalahan prediksi paling kecil selama proses validasi silang.

Dari sisi stabilitas model, Random Forest menunjukkan nilai standar deviasi terkecil yaitu 0,0856, yang mengindikasikan variasi performa antar-fold relatif lebih konsisten dibandingkan dua algoritma lainnya. Sementara itu, XGBoost memiliki standar deviasi sebesar 0,1024, sedikit lebih tinggi namun masih dalam rentang yang dapat diterima untuk model prediktif.

Hasil ini memperlihatkan bahwa meskipun XGBoost unggul dalam akurasi rata-rata, Random Forest menunjukkan kestabilan performa yang marginally lebih baik pada berbagai subset data pelatihan.

3.3. Evaluasi Akhir pada Data Uji

Setelah proses pelatihan dan validasi silang selesai dilakukan, tahap berikutnya adalah menguji performa model pada data uji yang tidak terlibat dalam proses pelatihan. Evaluasi ini bertujuan untuk mengukur kemampuan generalisasi model dalam memprediksi tingkat stres pada data baru.

Hasil pengujian menggunakan metrik Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan koefisien determinasi (R^2) disajikan pada Tabel 2

Tabel 2. Rancangan Analisis Komputasi

Model	MAE	RMSE	R ²
XGBoost	0.6502	0.8253	0.8367
Random Forest	0.6666	0.8902	0.8100
SVR (RBF)	0.6921	0.8680	0.8193

Berdasarkan Tabel 2, algoritma XGBoost menunjukkan performa terbaik dengan nilai MAE terendah sebesar 0,6502 dan RMSE sebesar 0,8253. Selain itu, nilai R² yang mencapai 0,8367 mengindikasikan bahwa model mampu menjelaskan lebih dari 83% variasi tingkat stres pada data uji. Hasil ini menunjukkan kemampuan prediksi yang tinggi serta generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya. Superioritas XGBoost dalam penelitian ini (R² = 0.8367) mengonfirmasi temuan Ardhani dan Tania [12] yang juga melaporkan performa XGBoost sebagai model paling stabil dalam prediksi perilaku pengguna digital. Menariknya, nilai MAE sebesar 0,6502 dalam studi ini menunjukkan presisi yang lebih tinggi dibandingkan penelitian El Morr et al. [14] yang menggunakan Random Forest dan SVM untuk memprediksi tingkat stres mahasiswa di Lebanon. Hal ini menunjukkan bahwa optimasi parameter pada model gradient boosting lebih efektif dalam menangkap variasi skor stres kontinu dibandingkan model klasifikasi tradisional.


Random Forest menempati posisi kedua dengan MAE sebesar 0,6666 dan R² sebesar 0,8100. Meskipun memiliki kestabilan yang cukup baik pada tahap validasi silang, performanya sedikit lebih rendah dibandingkan XGBoost pada data uji.

Sementara itu, Support Vector Regression menghasilkan MAE sebesar 0,6921 dengan nilai R² sebesar 0,8193. Meskipun performanya relatif kompetitif, nilai kesalahan prediksi yang lebih tinggi menunjukkan bahwa model ini kurang optimal dibandingkan dua algoritma ensemble yang digunakan.

Secara keseluruhan, hasil pengujian pada data uji memperkuat temuan sebelumnya bahwa XGBoost merupakan model dengan kinerja paling unggul dalam memprediksi tingkat stres berdasarkan variabel-variabel yang digunakan dalam penelitian ini.

3.4. Visualisasi Akurasi Prediksi dan Analisis Residual

3.4.1. Visualisasi Nilai Aktual dan Prediksi




Gambar 2. Scatter Plot antara Nilai Aktual dan Nilai Prediksi Tingkat Stres (XGBoost)

Scatter plot antara nilai aktual dan nilai prediksi digunakan untuk mengevaluasi kesesuaian hasil prediksi model terhadap data sebenarnya. Pada Gambar 2 terlihat bahwa sebagian besar titik berada di sekitar garis diagonal, yang menunjukkan bahwa model mampu mengikuti pola umum data dengan cukup baik.

Namun demikian, seiring meningkatnya nilai tingkat stres, terutama pada rentang nilai tinggi, terlihat adanya peningkatan kepadatan titik prediksi di sekitar nilai maksimum. Hal ini mengindikasikan bahwa model cenderung menghasilkan prediksi yang terkonsentrasi pada level stres tinggi ketika data aktual juga berada pada rentang tersebut.

Pola ini menunjukkan bahwa meskipun model memiliki akurasi prediksi yang baik secara keseluruhan, distribusi data target yang tidak merata pada level stres tinggi dapat memengaruhi penyebaran hasil prediksi. Fenomena ini umum terjadi pada data perilaku atau psikologis yang memiliki kecenderungan akumulasi pada nilai ekstrem.

3.4.2 Analisis Residual Model XGBoost



Gambar 3. Residual Plot Model XGBoost

Residual plot digunakan untuk mengevaluasi pola kesalahan prediksi dan mendeteksi potensi bias pada model. Residual dihitung sebagai selisih antara nilai aktual dan nilai prediksi tingkat stres.

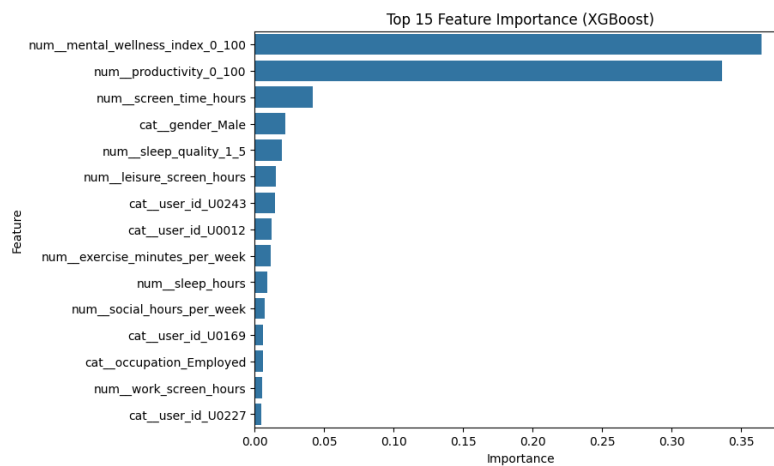
Berdasarkan Gambar 3, residual terlihat tersebar di sekitar garis nol tanpa membentuk pola tertentu, baik di atas maupun di bawah garis referensi. Penyebaran residual yang relatif simetris ini menunjukkan bahwa model tidak memiliki kecenderungan untuk secara sistematis melebihkan atau meremehkan nilai prediksi.

Meskipun terdapat penumpukan residual pada nilai stres tinggi, khususnya pada rentang mendekati nilai maksimum, pola tersebut tidak menunjukkan tren melengkung atau pola struktural yang mengindikasikan kesalahan spesifikasi model. Dengan demikian, dapat disimpulkan bahwa model memiliki performa prediksi yang stabil dan tidak menunjukkan indikasi bias signifikan.

3.5 Analisis Feature Importance dan Implikasi Prediktor

Tabel 3. Sepuluh Fitur dengan Kontribusi Terbesar pada Model XGBoost

Peringkat	Fitur	Importance
1	mental_wellness_index_0_100	0.3645
2	productivity_0_100	0.3364
3	screen_time_hours	0.0419
4	gender_Male	0.0218
5	sleep_quality_1_5	0.0198
6	leisure_screen_hours	0.0154
7	user_id_U0243	0.0145
8	user_id_0012	0.0125
9	exercise_minutes_per_week	0.0116
10	sleep_hours	0.0093



Gambar 4. Visualisasi Sepuluh Fitur Terpenting Model XGBoost

Analisis feature importance menunjukkan bahwa variabel mental_wellness_index_0_100 memiliki kontribusi paling dominan terhadap prediksi tingkat stres dengan nilai importance sebesar 0,3645. Temuan ini

mengindikasikan bahwa kondisi kesejahteraan mental individu merupakan faktor yang paling kuat dalam menentukan variasi tingkat stres pada dataset yang dianalisis.

Fitur `productivity_0_100` menempati posisi kedua dengan nilai kontribusi sebesar 0,3364, yang menunjukkan bahwa tingkat produktivitas individu memiliki hubungan prediktif yang signifikan terhadap tingkat stres. Kombinasi dua variabel ini menyumbang lebih dari 70% total kontribusi relatif model, menegaskan bahwa faktor internal psikologis dan performa personal memiliki peran yang jauh lebih besar dibandingkan variabel eksternal lainnya.

Menariknya, variabel `screen_time_hours` hanya memiliki nilai *importance* sebesar 0,0419, jauh lebih rendah dibandingkan dua variabel utama sebelumnya. Hal ini menunjukkan bahwa durasi penggunaan layar bukan merupakan determinan utama tingkat stres apabila dibandingkan dengan indikator kesejahteraan mental dan produktivitas. Temuan bahwa 'Mental Wellness Index' menjadi prediktor paling dominan dibandingkan durasi 'Screen Time' merupakan poin diskusi yang krusial. Hal ini sejalan dengan studi klinis oleh Pieh et al. [1] yang menyatakan bahwa intervensi pada kualitas kesehatan mental internal jauh lebih berdampak pada pengurangan stres daripada sekadar membatasi waktu paparan layar. Hal ini juga didukung oleh teori Carter et al. [15] yang menekankan bahwa pola penggunaan perangkat (*problematic usage*) lebih bersifat prediktif terhadap kecemasan dibandingkan durasi penggunaan dalam satuan jam.

Beberapa variabel gaya hidup seperti kualitas tidur, durasi tidur, serta aktivitas fisik mingguan menunjukkan kontribusi yang relatif kecil namun tetap relevan dalam memperkaya kemampuan prediksi model. Sementara itu, munculnya beberapa variabel berbasis identitas pengguna (`user_id`) dalam daftar sepuluh teratas mengindikasikan adanya karakteristik individual tertentu yang turut memengaruhi pola stres, meskipun kontribusinya tidak dominan.

Secara keseluruhan, hasil analisis ini memperlihatkan bahwa prediksi tingkat stres dalam penelitian ini lebih banyak dipengaruhi oleh faktor psikologis internal dan performa individu dibandingkan oleh variabel perilaku digital semata.

3.6. Pembahasan

3.6.1 Analisis Perbandingan Kinerja Model

Hasil pengujian menunjukkan bahwa XGBoost menghasilkan performa terbaik dengan nilai MAE terendah serta koefisien determinasi (R^2) tertinggi pada data uji. Keunggulan ini konsisten baik pada tahap *cross-validation* maupun evaluasi akhir, sehingga dapat disimpulkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data baru.

Secara konseptual, keunggulan XGBoost dapat dijelaskan melalui mekanisme *boosting*, yaitu proses pembelajaran sekuensial yang secara bertahap memperbaiki kesalahan model sebelumnya. Pendekatan ini memungkinkan model menangkap pola nonlinier dan interaksi kompleks antar-variabel secara lebih efektif dibandingkan metode yang bersifat paralel seperti Random Forest.

Random Forest, yang menggunakan pendekatan *bagging*, menunjukkan tingkat stabilitas yang sedikit lebih tinggi berdasarkan nilai standar deviasi *cross-validation*. Hal ini sejalan dengan karakteristik *bagging* yang cenderung mereduksi varians model. Namun demikian, dari sisi akurasi prediksi absolut, performanya masih berada di bawah XGBoost.

Sementara itu, Support Vector Regression menunjukkan performa yang kompetitif namun relatif kurang optimal dibandingkan kedua model *ensemble*. Kemungkinan penyebabnya adalah sensitivitas SVR terhadap parameter kernel dan kompleksitas distribusi data yang mungkin tidak sepenuhnya terakomodasi oleh fungsi kernel radial basis.

Temuan ini memperkuat pemahaman bahwa untuk data dengan interaksi fitur yang kompleks dan dimensi tinggi akibat proses *encoding*, algoritma *boosting* cenderung lebih adaptif dalam memaksimalkan akurasi prediksi.

3.6.2. Interpretasi Faktor Prediktif Utama

Analisis *feature importance* menunjukkan bahwa *mental_wellness_index* dan *productivity* merupakan dua variabel dengan kontribusi terbesar terhadap prediksi tingkat stres. Kedua variabel ini secara kumulatif menyumbang lebih dari dua pertiga total bobot kepentingan model.

Dominasi variabel kesejahteraan mental dalam model prediktif mengindikasikan bahwa kondisi psikologis internal individu memiliki hubungan yang jauh lebih kuat terhadap tingkat stres dibandingkan faktor eksternal seperti durasi penggunaan perangkat digital. Hal ini menegaskan bahwa stres tidak semata-mata merupakan konsekuensi dari paparan teknologi, melainkan lebih berkaitan dengan kondisi psikologis dan kapasitas individu dalam mengelola tekanan.

Variabel produktivitas juga menunjukkan peran signifikan. Secara teoritis, tingkat produktivitas dapat mencerminkan kemampuan individu dalam mengelola waktu, beban kerja, dan tuntutan aktivitas sehari-hari. Hubungan ini menunjukkan bahwa tekanan yang berkaitan dengan performa atau pencapaian dapat menjadi faktor penting dalam variasi tingkat stres.

Menariknya, durasi screen time hanya menempati peringkat ketiga dengan kontribusi yang relatif kecil. Temuan ini memberikan perspektif yang lebih seimbang terhadap narasi umum yang sering mengaitkan penggunaan layar secara langsung dengan peningkatan stres. Berdasarkan model prediktif yang dibangun, pengaruh screen time tampaknya bersifat sekunder dibandingkan kondisi kesejahteraan mental dan produktivitas.

3.6.3. Validasi Visual dan Stabilitas Model

Hasil visualisasi melalui scatter plot menunjukkan bahwa prediksi model mengikuti pola aktual secara umum, meskipun terdapat konsentrasi prediksi pada level stres tinggi. Pola ini kemungkinan dipengaruhi oleh distribusi data yang tidak sepenuhnya merata pada rentang nilai tertentu.

Analisis residual memperlihatkan penyebaran kesalahan yang relatif simetris di sekitar garis nol tanpa pola sistematis. Tidak ditemukannya pola kurvilinear atau struktur tertentu dalam residual mengindikasikan bahwa model tidak mengalami bias prediktif yang signifikan.

Selain itu, hasil cross-validation menunjukkan bahwa meskipun XGBoost memiliki standar deviasi sedikit lebih tinggi dibandingkan Random Forest, nilai tersebut masih berada dalam rentang yang dapat diterima. Hal ini menandakan bahwa model tetap konsisten dan tidak menunjukkan fluktuasi performa yang ekstrem antar subset data.

3.6.4. Implikasi Praktis dan Konseptual

Temuan penelitian ini memiliki implikasi penting dalam konteks pemantauan dan prediksi tingkat stres berbasis data perilaku digital dan indikator psikologis. Model prediktif yang dibangun menunjukkan bahwa intervensi yang berfokus pada peningkatan kesejahteraan mental dan pengelolaan produktivitas kemungkinan lebih efektif dibandingkan pendekatan yang hanya membatasi durasi penggunaan perangkat digital.

Dari perspektif metodologis, penelitian ini juga menunjukkan bahwa penggunaan algoritma boosting seperti XGBoost dapat menjadi pilihan yang efektif dalam memodelkan fenomena sosial-perilaku yang memiliki karakteristik nonlinier dan multidimensional.

4. KESIMPULAN

Penelitian ini bertujuan untuk membandingkan kinerja beberapa algoritma regresi dalam memprediksi tingkat stres berdasarkan variabel perilaku digital dan indikator psikologis. Berdasarkan hasil evaluasi menggunakan skema 10-fold cross-validation dan pengujian pada data uji, XGBoost menunjukkan performa terbaik dengan nilai MAE terendah dan koefisien determinasi (R^2) tertinggi.

Model XGBoost mampu menjelaskan lebih dari 83% variasi tingkat stres pada data uji, yang menunjukkan kemampuan prediksi yang kuat serta generalisasi yang baik terhadap data yang belum pernah dilatih sebelumnya. Meskipun Random Forest menunjukkan tingkat stabilitas yang sedikit lebih tinggi dalam validasi silang, akurasi prediksi absolut tetap unggul pada pendekatan boosting.

Analisis feature importance mengungkap bahwa indeks kesejahteraan mental dan tingkat produktivitas merupakan faktor yang paling dominan dalam memprediksi tingkat stres. Sebaliknya, durasi penggunaan layar memiliki kontribusi yang relatif lebih kecil dibandingkan variabel psikologis internal. Temuan ini menegaskan bahwa tingkat stres tidak hanya dipengaruhi oleh intensitas interaksi digital, tetapi lebih erat berkaitan dengan kondisi mental dan performa individu.

Secara keseluruhan, penelitian ini menunjukkan bahwa pendekatan machine learning berbasis ensemble, khususnya XGBoost, efektif dalam memodelkan fenomena stres yang bersifat kompleks dan multidimensional. Secara praktis, model prediktif ini membuka peluang besar bagi integrasi AI dalam sistem asuhan keperawatan dan solusi tenaga kerja kesehatan mental masa depan. Sebagaimana ditekankan dalam tinjauan integratif oleh Milasan dan Scott-Purdy [10], pemanfaatan machine learning untuk deteksi dini biomarker digital dapat membantu praktisi kesehatan dalam memberikan intervensi yang lebih personal dan akurat bagi individu yang berisiko mengalami krisis kesehatan mental di era digital [4].

DAFTAR PUSTAKA

- [1] C. Pieh et al., "Smartphone screen time reduction improves mental health: a randomized controlled trial," *BMC Med.*, vol. 23, no. 1, 2025, doi: 10.1186/s12916-025-03944-z.

-
- [2] C. Zhu, S. Li, and L. Zhang, "The impact of smartphone addiction on mental health and its relationship with life satisfaction in the post-COVID-19 era," *Front. Psychiatry*, vol. 16, no. March, pp. 1–10, 2025, doi: 10.3389/fpsy.2025.1542040.
- [3] M. Abd Al-Alim, R. Mubarak, N. M. Salem, and I. Sadek, "A machine-learning approach for stress detection using wearable sensors in free-living environments," *Comput. Biol. Med.*, vol. 179, 2024, doi: 10.1016/j.combiomed.2024.108918.
- [4] O. Higgins and R. L. Wilson, "Integrating Artificial Intelligence (AI) With Workforce Solutions for Sustainable Care: A Follow Up to Artificial Intelligence and Machine Learning (ML) Based Decision Support Systems in Mental Health," *Int. J. Ment. Health Nurs.*, vol. 34, no. 2, pp. 1–10, 2025, doi: 10.1111/inm.70019.
- [5] S. K. Sharma, A. I. Alutaibi, A. R. Khan, G. G. Tejani, F. Ahmad, and S. J. Mousavirad, "Early detection of mental health disorders using machine learning models using behavioral and voice data analysis," *Sci. Rep.*, vol. 15, no. 1, pp. 1–19, 2025, doi: 10.1038/s41598-025-00386-8.
- [6] F. D. E. Baran and M. Cetin, "AI-driven early diagnosis of specific mental disorders: a comprehensive study," *Cogn. Neurodyn.*, vol. 19, no. 1, 2025, doi: 10.1007/s11571-025-10253-x.
- [7] M. Payne et al., "Enhancing Mental Health Decision-Making with Artificial Intelligence / Machine Learning: A Prescriptive Analytics Approach for Customised Outcomes," *medRxiv*, 2025, [Online]. Available: <https://www.medrxiv.org/content/10.1101/2025.06.16.25329741.abstract>
<https://www.medrxiv.org/content/medrxiv/early/2025/06/17/2025.06.16.25329741.full.pdf>
- [8] L. Zhang, S. Zhao, Z. Yang, H. Zheng, and M. Lei, "An artificial intelligence tool to assess the risk of severe mental distress among college students in terms of demographics, eating habits, lifestyles, and sport habits: an externally validated study using machine learning," *BMC Psychiatry*, vol. 24, no. 1, 2024, doi: 10.1186/s12888-024-06017-2.
- [9] Y. Zhang et al., "Employing Machine Learning and Deep Learning Models for Mental Illness Detection," *Computation*, vol. 13, no. 8, pp. 1–14, 2025, doi: 10.3390/computation13080186.
- [10] L. H. Milasan and D. Scott-Purdy, "The Future of Artificial Intelligence in Mental Health Nursing Practice: An Integrative Review," *Int. J. Ment. Health Nurs.*, vol. 34, no. 1, pp. 1–19, 2025, doi: 10.1111/inm.70003.
- [11] M. Al Fachrozi and K. D. Tania, "Comparison of Naive Bayes, SVM, K-NN, Decision Tree, and Random Forest in Sentiment Analysis Based on SeaBank Application Aspects," vol. XII, no. 1, 2025.
- [12] D. Amanda Ardhani and K. D. Tania, "Knowledge Discovery on E-Commerce Customer Churn Using Interpretable Machine Learning: A Comparative Study of SHAP-Based Classifiers," *J. Appl. Informatics Comput.*, vol. 9, no. 5, pp. 2695–2702, 2025, doi: 10.30871/jaic.v9i5.10811.
- [13] D. N. Fahlria, K. D. Tania, and R. D. Kurnia, "Analisis komparatif algoritma random forest, xgboost, dan catboost untuk klasifikasi tingkat stres pengguna media sosial 1)," vol. 11, no. 1, pp. 1843–1853, 2026.
- [14] C. El Morr et al., "Predictive Machine Learning Models for Assessing Lebanese University Students' Depression, Anxiety, and Stress During COVID-19," *J. Prim. Care Community Heal.*, vol. 15, 2024, doi: 10.1177/21501319241235588.
- [15] B. Carter, M. Payne, P. Rees, S. Y. Sohn, J. Brown, and N. J. Kalk, "A multi-school study in England, to assess problematic smartphone usage and anxiety and depression," *Acta Paediatr. Int. J. Paediatr.*, vol. 113, no. 10, pp. 2240–2248, 2024, doi: 10.1111/apa.17317.