

PREDIKSI KUALITAS TIDUR BERDASARKAN PENGGUNAAN MEDIA SOSIAL MENGGUNAKAN MULTILAYER PERCEPTRON (MLP)

by Diviandini Azzahra

Submission date: 19-Aug-2025 03:37PM (UTC+0700)

Submission ID: 2731810785

File name: BAB_1-5.docx (742.77K)

Word count: 9415

Character count: 61753

BAB 1

PENDAHULUAN

1.1. Latar Belakang

Seiring dengan kemajuan teknologi yang pesat, penggunaan media sosial telah menjadi bagian integral dari kehidupan sehari-hari. Generasi Z, sebagai kelompok yang tumbuh di tengah revolusi digital, menunjukkan ketergantungan yang sangat besar terhadap platform media sosial. Di Indonesia, jumlah pengguna media sosial pada tahun 2023 diperkirakan mencapai lebih dari 170 juta orang, dengan durasi penggunaan rata-rata yang menghabiskan lebih dari 3 jam per hari [1]. Fenomena ini menunjukkan bahwa media sosial tidak hanya menjadi alat komunikasi, tetapi juga menjadi bagian dari gaya hidup modern, yang turut membentuk kebiasaan sehari-hari generasi muda, termasuk dalam hal pola tidur mereka.

Media sosial, yang awalnya dimaksudkan untuk menghubungkan orang, kini telah berkembang menjadi platform hiburan, pendidikan, dan sumber informasi yang dominan. Namun, penggunaan media sosial yang intens, terutama di malam hari, telah menimbulkan kekhawatiran terkait dampaknya terhadap kualitas tidur. Studi-studi terbaru menunjukkan bahwa penggunaan media sosial yang berlebihan, terutama sebelum tidur, dapat mengganggu kualitas tidur seseorang. Levenson et al. [2] dalam penelitiannya menemukan bahwa individu yang menghabiskan lebih dari 2 jam per hari di media sosial memiliki kemungkinan dua kali lebih besar untuk mengalami gangguan tidur dibandingkan dengan mereka yang tidak terlalu banyak menggunakan media sosial. Hal ini semakin diperburuk oleh kecenderungan penggunaan media sosial pada malam hari, yang dapat menunda onset tidur dan mengurangi durasi tidur yang cukup.

Penurunan kualitas tidur yang disebabkan oleh kebiasaan penggunaan media sosial ini sangat relevan untuk dibahas, mengingat dampaknya yang dapat mengarah pada berbagai masalah kesehatan, baik fisik maupun mental. Hirshkowitz et al. [3] mengemukakan bahwa gangguan tidur yang kronis dapat menyebabkan peningkatan risiko berbagai masalah kesehatan, seperti gangguan mood, penurunan

fungsi kognitif, ¹⁴ penurunan daya tahan tubuh, serta peningkatan risiko penyakit metabolik dan kardiovaskular. ⁹² Oleh karena itu, penting untuk memahami lebih lanjut tentang bagaimana kebiasaan penggunaan media sosial memengaruhi kualitas tidur, terutama pada generasi yang sangat aktif dalam menggunakan platform ini, yaitu Generasi Z.

⁶ Salah satu aspek yang menarik untuk diteliti adalah bagaimana screen time atau durasi penggunaan media sosial yang tercatat pada perangkat, seperti ponsel pintar, dapat menggambarkan hubungan antara kebiasaan digital ini dengan kualitas tidur. Data dari perangkat, seperti *Screen Time* pada iPhone atau *Digital Wellbeing* pada Android, dapat memberikan informasi yang lebih objektif mengenai durasi dan intensitas penggunaan media sosial. Dalam hal ini, data yang lebih objektif dapat memberikan gambaran yang lebih akurat mengenai kebiasaan digital pengguna, dibandingkan dengan data yang diperoleh melalui survei atau kuesioner yang mungkin memiliki bias subjektif.

Namun, meskipun banyak penelitian yang menunjukkan dampak negatif penggunaan media sosial terhadap kualitas tidur, sebagian besar penelitian masih terbatas pada analisis deskriptif atau korelasional yang belum dapat memberikan prediksi yang tepat. Di sinilah machine learning (pembelajaran mesin) berperan penting. Dengan menggunakan algoritma seperti *Multilayer Perceptron* (MLP), sebuah teknik dalam jaringan saraf buatan, kita dapat mengembangkan model prediktif yang ⁵⁵ mampu mempelajari pola-pola kompleks dalam data dan menghasilkan prediksi yang lebih akurat tentang bagaimana ³ penggunaan media sosial memengaruhi kualitas tidur. MLP, dengan kemampuan untuk memproses data dalam beberapa lapisan tersembunyi, mampu mengidentifikasi hubungan yang tidak linear antarvariabel yang lebih kompleks, seperti durasi ³ penggunaan media sosial, waktu penggunaan, dan kualitas tidur [4].

Sebuah penelitian yang dilakukan oleh Zhang et al. [5] menunjukkan bagaimana MLP dapat diterapkan untuk memprediksi gangguan tidur berdasarkan data perilaku, termasuk kebiasaan digital. Penelitian tersebut menyimpulkan bahwa jaringan saraf seperti MLP dapat digunakan untuk menganalisis data yang terdiri

dari banyak variabel dan menghasilkan ¹⁷ prediksi yang lebih akurat dibandingkan dengan metode statistik tradisional. Dalam konteks penelitian ini, model MLP dapat dilatih untuk mengenali pola penggunaan media sosial yang dapat mengindikasikan risiko gangguan tidur pada Gen Z.

Selain itu, penggunaan model seperti MLP juga memungkinkan peneliti untuk memperhitungkan faktor-faktor lain yang dapat memengaruhi kualitas tidur, seperti kecemasan, stres, dan kebiasaan tidur yang terkait dengan penggunaan media sosial. MLP dapat memetakan hubungan antara variabel-variabel ini dengan cara yang lebih fleksibel dan mendalam, memberikan wawasan yang lebih baik mengenai faktor-faktor penyebab gangguan tidur yang mungkin tidak terlihat jelas dengan analisis tradisional.

Dari perspektif psikologis, penggunaan media sosial dapat meningkatkan kecemasan dan ketegangan mental, terutama karena sifatnya yang terus-menerus memperbarui informasi, seperti notifikasi dan pesan yang masuk. Hal ini dapat menciptakan stimulasi mental yang mengganggu proses relaksasi yang dibutuhkan untuk tidur. Penelitian oleh Hale dan Guan [6] menunjukkan bahwa paparan cahaya biru dari ² perangkat elektronik yang digunakan untuk mengakses media sosial juga memiliki dampak langsung terhadap kualitas tidur, karena mengurangi produksi melatonin, hormon yang penting untuk regulasi siklus tidur.

⁷⁶ Tujuan dari penelitian ini adalah untuk mengembangkan model prediksi berbasis MLP yang dapat digunakan untuk menganalisis data penggunaan media sosial dalam rangka memprediksi kualitas tidur, khususnya pada generasi muda. Dengan adanya model ini, ⁵⁷ diharapkan dapat diperoleh pemahaman yang lebih dalam mengenai pola penggunaan media sosial yang berisiko tinggi terhadap gangguan tidur. Penelitian ini tidak hanya ²⁵ bertujuan untuk mengidentifikasi faktor-faktor yang mempengaruhi kualitas tidur, tetapi juga untuk memberikan solusi yang lebih terarah dalam mengatasi masalah tidur yang disebabkan oleh kebiasaan digital, sehingga dapat meningkatkan kualitas hidup secara keseluruhan.

1.2. Rumusan Masalah

Dari rumusan masalah penelitian yang telah diidentifikasi, maka tujuan dari penelitian ini yaitu:

1. Bagaimana model Multilayer Perceptron (MLP) dapat mengklasifikasikan kualitas tidur ke dalam kategori 'Baik' atau 'Buruk' berdasarkan fitur-fitur penggunaan media sosial pada Generasi Z?
2. Seberapa tinggi tingkat akurasi yang dapat dicapai oleh model Multilayer Perceptron (MLP) dalam mengklasifikasikan kualitas tidur, yang dievaluasi menggunakan metrik Akurasi, Presisi, Recall, dan F1-Score?
3. Faktor-faktor apa saja dalam penggunaan media sosial yang memiliki pengaruh paling signifikan terhadap kualitas tidur pada Generasi Z berdasarkan hasil analisis model MLP?

1.3. Batasan Masalah

Untuk memfokuskan penelitian dan mencapai tujuan yang diharapkan, ditetapkan batasan masalah sebagai berikut:

1. Responden penelitian dibatasi pada Generasi Z (usia 18-24 tahun) yang aktif menggunakan media sosial.
2. Data kuantitatif untuk durasi penggunaan media sosial (Instagram, Tiktok, dan Youtube) diperoleh dan divalidasi menggunakan bukti objektif berupa screenshot dari fitur screen time yang disediakan oleh setiap responden.
3. Variabel-variabel yang dianalisis dalam penelitian ini dibatasi pada: fitur perilaku (durasi harian untuk Instagram, TikTok, dan YouTube; pola waktu; jeda sebelum tidur), fitur psikologis (skor FOMO), dan fitur demografis (usia).
4. Model prediksi yang dikembangkan adalah model regresi menggunakan algoritma Multilayer Perceptron (MLP) dengan fokus pada optimasi untuk meminimalkan kesalahan prediksi.
5. Data yang digunakan untuk pelatihan dan validasi model dibatasi maksimal 200 responden.

16

1.4. Tujuan


Dari rumusan masalah penelitian yang telah diidentifikasi, maka tujuan dari penelitian ini yaitu:

1. Mengidentifikasi pola penggunaan media sosial yang berkorelasi dengan skor kualitas tidur pada Generasi Z.
2. Mengembangkan model regresi kualitas tidur berbasis Multilayer Perceptron (MLP) dengan menggunakan data penggunaan media sosial.
3. Mengoptimalkan arsitektur dan parameter model regresi MLP untuk meningkatkan performa prediksi skor kualitas tidur, yang diukur dengan meminimalkan nilai *error*.
4. Mengevaluasi performa model regresi MLP dalam memprediksi skor kualitas tidur, menggunakan data yang divalidasi melalui screenshot screen time dan metrik evaluasi seperti Mean Absolute Error (MAE).
5. Merumuskan rekomendasi praktis tentang pola penggunaan media sosial yang sehat bagi Generasi Z untuk meningkatkan kualitas tidur berdasarkan hasil temuan penelitian.

91

1.5. Kerangka Pemikiran

Kerangka pemikiran ialah suatu dasar pemikiran yang akan menjadi alur dari sebuah penelitian berdasarkan fakta secara logis. Kerangka pemikiran pada penelitian ini digambarkan sebagai berikut :



Gambar 1.1 Diagram Kerangka Berfikir

Pada Gambar 1.1, kerangka pemikiran menggambarkan langkah-langkah yang diambil peneliti untuk mengatasi permasalahan yang dihadapi dalam penelitian ini.

Permasalahan utama yang diidentifikasi adalah tingginya tingkat ketidakakuratan dalam diagnosis kualitas tidur secara manual, yang seringkali mengarah pada rekomendasi perawatan yang tidak tepat.

Untuk mengatasi masalah ini, penelitian ini memilih pendekatan berbasis data dan teknologi, khususnya dengan memanfaatkan data ³¹ penggunaan media sosial yang terhubung dengan kualitas tidur. Pendekatan ini menggunakan teknik pembelajaran mesin untuk menganalisis ⁵ hubungan antara durasi penggunaan media sosial dan kualitas tidur, serta bagaimana faktor-faktor lain seperti waktu layar dan pola tidur mempengaruhi kesehatan mental.

Penelitian ini menggunakan model prediksi berbasis Jaringan Saraf Tiruan (*Multilayer Perceptron*/MLP), yang dipilih karena kemampuannya dalam memproses data numerik dan pola yang kompleks dengan akurasi tinggi. Dalam pengembangan sistem, metode CRISP-DM digunakan sebagai pendekatan utama, yang meliputi tahap pemahaman masalah, persiapan data, pelatihan model, evaluasi, dan implementasi, dengan bahasa pemrograman Python dan Keras sebagai alat utama untuk pengembangan model.

Hasil dari penelitian ini adalah model yang mampu memprediksi kualitas tidur berdasarkan data penggunaan media sosial dan informasi terkait lainnya, memberikan solusi berbasis teknologi untuk meningkatkan pemahaman tentang pengaruh media sosial terhadap tidur dan kesehatan mental secara lebih akurat dan efektif.

⁶ I.6. Sistematika Penulisan

Berikut adalah sistematika penulisan pada penelitian ini yang disusun secara terstruktur:

BAB I Pendahuluan

Bab I yaitu pendahuluan berisi beberapa bahasan seperti latar belakang dari penelitian ini, lalu rumusan masalah pada penelitian, menentukan tujuan serta manfaat apa yang terdapat dalam penelitian, serta membatasi permasalahan pada

penelitian ini, tak lupa ada pula kerangka pemikiran, dan sistematikan penulisan yang ditulis secara terstruktur.

BAB II Kajian Literatur

Bab II memaparkan kajian literatur yang mencakup pembahasan penelitian terdahulu serta penjelasan berbagai teori yang relevan untuk menyelesaikan masalah penelitian.

BAB III Metodologi Penelitian

Bab III metodologi penelitian berisikan tentang uraian bagaimana sistem dirancang lalu dibuat dan dimulai dari pemahaman data, pengumpulan data dan proses pengolahan data dari penelitian.

BAB IV Hasil dan Pembahasan

Bab IV hasil dan pembahasan berisikan tentang hasil dari sistem yang telah dirancang dan dibangun yang nantinya akan dievaluasi.

BAB V Penutup

Bab V penutup merupakan tahapan akhir yang berisi tentang kesimpulan singkat dari penelitian yang telah dilakukan serta saran untuk pengembangan penelitian terkait yang lebih baik di masa mendatang.

Daftar Pustaka

Daftar pustaka berisi tentang sumber-sumber tertulis yang dipakai dan dijadikan acuan dalam penelitian ini.

Lampiran

Dokumen-dokumen tambahan yang digunakan dalam proses penyusunan dan perancangan penelitian.

BAB II

KAJIAN LITERATUR

2.1. State Of The Art

State of the art merupakan kumpulan tinjauan literatur dari penelitian terdahulu yang relevan dengan penelitian ini untuk mengidentifikasi perbedaan antara penelitian ini dengan penelitian terdahulu. Pada Tabel 2.1 merupakan kumpulan literatur yang relevan pada penelitian ini.

Tabel 2.1 *State of The Art*

No	Peneliti	Dataset	Metode	Teknologi	Hasil
1	Silva, M. L. G. F., et al. (2021). [6]	Data survei demografi, penggunaan media sosial, dan kualitas tidur (indeks PSQI).	Supervised Machine Learning, Klasifikasi (Baik vs. Buruk).	Random Forest, Support Vector Machines (SVM), Multilayer Perceptron (MLP).	mencapai "akurasi tinggi" dengan model MLP
2	Alshoai bi, A., et al. (2022). [7]	Data fisiologis dan kuesioner dari 400+ partisipan, termasuk kebiasaan penggunaan perangkat elektronik.	Supervised Learning (Klasifikasi).	Random Forest, Decision Tree, Naive Bayes, K-Nearest Neighbors (KNN).	Random Forest mencapai akurasi tertinggi dalam memprediksi level kualitas tidur berdasarkan data perilaku

No	Peneliti	Dataset	Metode	Teknologi	Hasil
					dan fisiologis.
3	⁹⁵ Lee, Y. J., Kim, Y. S., & Lee, J. Y. (2021) [8]	Data penggunaan <i>smartphone</i> (termasuk <i>screen time</i> aplikasi sosial) dan skor kualitas tidur (PSQI).	Supervised ⁹⁴ Machine Learning.	Logistic Regression, Random Forest, Gradient Boosting.	Pola penggunaan <i>smartphone</i> , terutama durasi penggunaan pada malam hari, merupakan prediktor signifikan untuk kualitas tidur yang buruk.
4	Wang, W., et al. (2018). [9]	Data sinyal EKG (Lead-I) selama tidur.	Deep Learning, Klasifikasi.	Convolutional Neural Network (CNN).	Model CNN dapat secara akurat mengklasifikasi tahapan tidur (REM, NREM) dan kualitas tidur dari data sensor jantung, menunjukkan

No	Peneliti	Dataset	Metode	Teknologi	Hasil
					potensi data pasif.
5	Baumel, A., et al. (2018) [10]	Data tidur yang diinput pengguna, data <i>mood</i> , dan aktivitas harian.	Analisis Korelasional dan Visualisasi.	Aplikasi mobile, Visualisasi Data.	Platform berhasil membantu pengguna mengidentifikasi korelasi antara perilaku harian (termasuk penggunaan media) dan kualitas tidur mereka secara visual.
6	Chinoy, E. D., et al. (2021). [11]	Data sensor gerak dan suara dari <i>smartphone</i> yang diletakkan di tempat tidur.	Machine Learning untuk deteksi peristiwa tidur.	Sensor <i>smartphone</i> (akselerometer, mikrofon).	Algoritma dapat secara akurat mendeteksi waktu tidur, bangun, dan gangguan tidur, divalidasi dengan perangkat medis

No	Peneliti	Dataset	Metode	Teknologi	Hasil
					standar (polysomnography).
7	Sadeghi niat, A., et al. (2022). [12]	Data dari <i>wearable device</i> (detak jantung, aktivitas) dan kuesioner psikologis (stres, kecemasan).	Supervised Learning (Regresi).	XGBoost, Random Forest.	Kombinasi data sensor dan data psikologis menghasilkan prediksi skor kualitas tidur yang sangat akurat, di mana tingkat stres menjadi fitur penting.
8	Saad, M. N. H., & Fadzil, M. H. A. (2020). [13]	Data detak jantung, pernapasan, dan gerakan dari <i>wearable device</i> selama tidur.	Supervised Learning (Klasifikasi).	Support Vector Machine (SVM).	Model SVM mampu mengklasifikasi kualitas tidur menjadi 'Baik', 'Cukup', dan 'Buruk' dengan akurasi yang menjanjikan.

No	Peneliti	Dataset	Metode	Teknologi	Hasil
9	Stachl, C., et al. (2020) [14]	Data penggunaan <i>smartphone</i> (komunikasi, penggunaan aplikasi sosial, mobilitas) selama 30 hari.	Model prediktif (Regresi).	Machine Learning, Analisis Data Perilaku.	Pola perilaku digital dapat memprediksi ciri kepribadian, termasuk <i>neuroticism</i> yang sangat terkait dengan kecenderungan gangguan tidur.
10	Levenson, J. C., et al. (2016). [15]	Data survei dari 1.788 dewasa muda di AS mengenai frekuensi dan durasi penggunaan 11 platform media sosial.	Analisis Statistik.	Statistik Inferensial (Regresi Logistik).	Menjadi studi fundamental yang menunjukkan hubungan dosis-respons: semakin banyak waktu dihabiskan di media sosial, semakin tinggi kemungkinan

No	Peneliti	Dataset	Metode	Teknologi	Hasil
					mengalami gangguan tidur.
11	Pratama, R. A., & Susanto, A. (2023). [16]	Data survei durasi, frekuensi, dan jenis konten media sosial, serta tingkat stres (sangat berhubungan dengan tidur).	Supervised Learning (Klasifikasi).	Multilayer Perceptron (MLP).	Model MLP mampu memprediksi tingkat stres mahasiswa dengan akurasi yang baik.
12	Sari, D. P., & Nugroho, L. E. (2021). [17]	Data kuesioner gaya hidup, termasuk jam penggunaan gadget/media sosial, dan data kualitas tidur.	Supervised Learning (Klasifikasi).	Naive Bayes Classifier.	Algoritma Naive Bayes cukup baik dalam mengklasifikasi kualitas tidur, dengan variabel penggunaan gadget sebelum tidur menjadi

No	Peneliti	Dataset	Metode	Teknologi	Hasil
					atribut berpengaruh.
13	Firmansyah, Y., & Wibowo, A. (2022). [18]	Data dari kuesioner kebiasaan bermedia sosial, kecemasan, dan gejala insomnia.	Supervised Learning (Klasifikasi).	Pohon Keputusan (Algoritma C4.5).	Model mengidentifikasi kasi durasi penggunaan >3 jam dan penggunaan 1 jam sebelum tidur sebagai faktor utama risiko insomnia.
14	Wijaya, I. K., & Setiawan, R.	Data kuesioner adiksi media sosial.	Supervised Learning.	Support Vector Machine (SVM).	SVM berhasil memodelkan faktor-faktor penyebab

No	Peneliti	Dataset	Metode	Teknologi	Hasil
	(2024). [19]				kecanduan, yang menjadi dasar pemahaman penggunaan berlebih yang berdampak pada tidur.
15	Lestari, S., & Wulandari, Y. (2022). [20]	Data kuesioner intensitas penggunaan Instagram dan kualitas tidur (PSQI).	Analisis Korelasional.	Statistik (Uji Korelasi Spearman).	Terdapat hubungan negatif signifikan; ²¹ semakin tinggi intensitas penggunaan Instagram, semakin buruk kualitas tidur mahasiswa.
16	Anggraini, F. D. (2023). [21]	Data jejak digital (waktu online terakhir) dan data tidur yang	Supervised Learning.	Jaringan Saraf Tiruan (termasuk MLP).	Model JST menunjukkan potensi besar dalam memprediksi kualitas tidur hanya dari

No	Peneliti	Dataset	Metode	Teknologi	Hasil
		dilaporkan sendiri.			data waktu aktivitas digital pengguna.
17	Fauzi, A., & Tolle, H. (2021). [22]	Data survei pola penggunaan <i>smartphone</i> , termasuk penggunaan aplikasi media sosial.	Supervised Learning (Klasifikasi).	K-Nearest Neighbor (KNN).	Model dapat memprediksi tingkat ketergantungan, dengan durasi dan frekuensi membuka aplikasi sosial menjadi fitur utama.
18	Santoso, H., & Mahendra, Y. (2022). [23]	Data dari kuesioner dan sensor akselerometer pada <i>smartphone</i> .	Perbandingan model supervised learning.	SVM, Naive Bayes, Random Forest.	Random Forest memberikan akurasi terbaik, menunjukkan kombinasi data survei dan sensor meningkatkan performa prediksi.

No	Peneliti	Dataset	Metode	Teknologi	Hasil
19	Setiawan, B. (2022). [24]	Kumpulan <i>tweet</i> berbahasa Indonesia tentang kesehatan mental dan media sosial.	Supervised Learning, Analisis Teks.	Multilayer Perceptron (MLP), Natural Language Processing (NLP).	MLP efektif mengklasifikasi sentimen, di mana banyak sentimen negatif menghubungkan media sosial dengan kecemasan dan gangguan tidur.
20	Zulfikar, & Anam, C. (2022). [25]	Dataset medis umum (relevan secara metodologi)	Optimasi Model Machine Learning.	Multilayer Perceptron (MLP), Algoritma Genetika.	Menunjukkan optimasi <i>hyperparameter</i> dan arsitektur pada MLP secara signifikan meningkatkan akurasi, sebuah teknik yang bisa diterapkan pada

No	Peneliti	Dataset	Metode	Teknologi	Hasil
					penelitian kualitas tidur.

Tujuan dari penelitian ini, "Prediksi Kualitas Tidur Berdasarkan Penggunaan Media Sosial Menggunakan *Multilayer Perceptron* (MLP)", adalah untuk mengembangkan model prediksi yang dapat memprediksi kualitas tidur berdasarkan kebiasaan penggunaan media sosial, khususnya pada Generasi Z. Berdasarkan penelitian sebelumnya, berbagai metode seperti *Long Short-Term Memory* (LSTM), *XGBoost*, dan *Support Vector Machine* (SVM) telah digunakan untuk menganalisis hubungan antara penggunaan media sosial dan kualitas tidur. Beberapa penelitian sebelumnya, misalnya, menggunakan model LSTM untuk memprediksi kualitas tidur dengan akurasi sekitar 80%, sementara model *XGBoost* memperoleh akurasi 81%.

Namun, penelitian ini memiliki kesenjangan yang jelas: sebagian besar penelitian sebelumnya berfokus pada data yang terbatas, tidak menggunakan metode pembelajaran mesin yang lebih kompleks seperti *Multilayer Perceptron* (MLP), serta belum mengeksplorasi penggunaan data screen time pada perangkat untuk memprediksi kualitas tidur. Selain itu, penelitian sebelumnya belum menguji sejauh mana algoritma MLP dapat mengatasi masalah non-linearitas dalam hubungan antara penggunaan media sosial dan kualitas tidur. Dengan demikian, penelitian ini bertujuan untuk mengisi kesenjangan tersebut dan memberikan wawasan yang lebih mendalam mengenai penerapan MLP untuk memprediksi gangguan tidur yang disebabkan oleh kebiasaan digital, terutama pada generasi muda yang sangat terhubung dengan media sosial.

2.2. Landasan Teori

2.2.1. Kualitas Tidur

Kualitas tidur merupakan aspek penting dalam kesehatan fisik dan mental seseorang. Tidur yang berkualitas dapat mempengaruhi daya ingat, konsentrasi, serta kestabilan emosional seseorang. Sebaliknya, gangguan tidur seperti insomnia atau tidur yang tidak nyenyak dapat berdampak negatif pada kesejahteraan individu. Menurut Organisasi Kesehatan Dunia (World Health Organization - WHO), tidur yang cukup adalah kunci untuk kesehatan yang baik, dengan kebanyakan orang dewasa membutuhkan sekitar 7-9 jam tidur per malam (WHO, 2021). [26]

Faktor-faktor yang memengaruhi kualitas tidur meliputi stres, pola makan, kebiasaan tidur, dan penggunaan teknologi, termasuk media sosial. Sebuah penelitian yang dilakukan oleh LeBourgeois et al. (2017) menunjukkan bahwa penggunaan media sosial pada malam hari dapat mengganggu kualitas tidur, yang berdampak pada kesehatan mental dan fisik penggunanya. Efek buruk media sosial terhadap kualitas tidur sering dikaitkan dengan peningkatan kecemasan, stres, serta kecanduan digital yang membuat seseorang sulit tidur tepat waktu. [27]

2.2.2. Penggunaan Media Sosial

Media sosial merujuk pada berbagai platform yang memungkinkan pengguna untuk berinteraksi, berbagi konten, dan berkomunikasi satu sama lain. Media sosial mencakup berbagai aplikasi seperti Facebook, Instagram, Twitter, dan TikTok. Meskipun menawarkan berbagai manfaat seperti interaksi sosial dan akses informasi, penggunaan media sosial yang berlebihan, terutama pada malam hari, dapat menyebabkan gangguan tidur.

Penelitian menunjukkan bahwa penggunaan media sosial sebelum tidur dapat menyebabkan peningkatan kecemasan dan stimulasi mental yang mengganggu proses tidur alami. Pengguna media sosial cenderung lebih terpapar oleh stres dan kecemasan akibat informasi yang mereka terima

melalui platform tersebut. Selain itu, penggunaan layar digital sebelum tidur mempengaruhi produksi hormon melatonin yang mengatur siklus tidur, yang pada akhirnya mengganggu kualitas tidur (LeBourgeois et al., 2017; Twenge & Campbell, 2018). [28]

2.2.3. Multilayer Perceptron (MLP)

Multilayer Perceptron (MLP) adalah salah satu jenis jaringan saraf tiruan yang terdiri dari lebih dari satu lapisan tersembunyi (*hidden layer*) antara lapisan *input* dan *output*. MLP termasuk dalam kategori model jaringan saraf dalam *deep learning* yang memiliki kemampuan untuk mempelajari pola yang kompleks dalam data. Struktur dasar MLP terdiri dari lapisan *input*, beberapa lapisan tersembunyi, dan lapisan *output*.

Pada MLP, data yang masuk diproses melalui lapisan-lapisan tersembunyi menggunakan fungsi aktivasi nonlinear, yang memungkinkan model untuk memetakan hubungan yang lebih kompleks antarvariabel. Model ini sering digunakan dalam berbagai aplikasi seperti klasifikasi, prediksi, dan regresi, termasuk prediksi kualitas tidur berdasarkan data penggunaan media sosial.

Salah satu keunggulan MLP adalah kemampuannya untuk mengatasi masalah klasifikasi yang tidak linear dan kompleks dengan mempelajari representasi yang lebih dalam dari data. Hal ini membuat MLP sangat cocok untuk memodelkan hubungan antara variabel yang saling berinteraksi, seperti penggunaan media sosial dan kualitas tidur. Selain itu, MLP dapat dioptimalkan menggunakan algoritma pelatihan seperti *backpropagation* untuk meminimalkan kesalahan dan meningkatkan akurasi model.

2.2.4. Penggunaan Jaringan Syaraf Tidur untuk Prediksi Kualitas Tidur

Penerapan jaringan saraf tiruan dalam prediksi kualitas tidur telah banyak diteliti, dengan berbagai pendekatan yang menggunakan data dari berbagai sumber, termasuk sensor *wearable*, pola perilaku tidur, dan faktor eksternal seperti penggunaan media sosial. Penelitian oleh Zhang *et al.* (2020)

menunjukkan bahwa algoritma berbasis *deep learning*, seperti MLP, dapat digunakan untuk memprediksi kualitas tidur berdasarkan pola aktivitas pengguna, termasuk faktor-faktor eksternal yang mempengaruhi tidur, seperti stres, konsumsi media sosial, dan kebiasaan lainnya. [29]

⁸⁰ Selain itu, penelitian oleh Wu *et al.* (2019) menunjukkan bahwa menggunakan data media sosial untuk memprediksi kualitas tidur adalah pendekatan yang efektif, karena media sosial dapat memberikan gambaran tentang kehidupan sosial dan emosional individu yang berpengaruh pada kondisi tidur mereka. [30] Teknik-teknik *deep learning* seperti MLP dapat menganalisis ⁵ hubungan antara data penggunaan media sosial dan kualitas tidur dengan akurasi yang tinggi, sehingga model ini dapat digunakan untuk memberikan rekomendasi berbasis data untuk meningkatkan kualitas tidur.

2.2.5. Keterkaitan Antara Kualitas Tidur ⁷⁷ dan Kesehatan Mental

Kualitas tidur yang buruk dapat berpengaruh langsung terhadap kesehatan mental. Banyak penelitian menunjukkan hubungan timbal balik antara gangguan tidur dan gangguan mental seperti depresi, kecemasan, dan stres. Sebagai contoh, Kalmbach et al. (2018) menemukan bahwa orang yang mengalami gangguan tidur lebih rentan terhadap depresi dan kecemasan, sementara orang dengan gangguan mental juga lebih mungkin untuk mengalami kualitas tidur yang buruk. Media sosial sering kali menjadi faktor pemicu yang meningkatkan kecemasan atau stres, yang berkontribusi pada gangguan tidur. Oleh karena itu, memprediksi kualitas tidur dengan mempertimbangkan penggunaan media sosial menjadi penting untuk memahami lebih dalam tentang interaksi antara kedua faktor tersebut. [32]

2.2.6. ²² CRISP-DM

CRISP-DM (*Cross Industry Standard Process for Data Mining*) adalah metode yang sering digunakan dalam proses data mining dan pembelajaran mesin. Proses ini terdiri dari enam tahap: pemahaman bisnis, pemahaman data, persiapan data, pemodelan, evaluasi, dan penerapan. Dalam konteks prediksi

kualitas tidur menggunakan MLP, CRISP-DM dapat digunakan untuk merancang alur kerja yang sistematis dalam mengumpulkan data penggunaan media sosial, mempersiapkan data tersebut, dan membangun model untuk prediksi kualitas tidur.

2.2.7. Pengaruh Cahaya Biru dari Layar Digital

Salah satu faktor yang semakin diakui dalam penelitian terkait kualitas tidur adalah pengaruh cahaya biru yang dipancarkan oleh layar perangkat digital, termasuk ponsel, tablet, dan komputer. Cahaya biru ini ²¹ dapat menghambat produksi hormon melatonin, yang memainkan peran penting dalam mengatur siklus tidur. Menurut penelitian oleh Harvard Medical School (2012), paparan cahaya biru pada malam hari dapat memperlambat produksi melatonin hingga 90 menit, sehingga membuat tidur menjadi lebih sulit dan kurang berkualitas. [31]

Paparan media sosial pada malam hari, terutama yang melibatkan penggunaan perangkat dengan layar, dapat menyebabkan gangguan tidur yang lebih parah karena efek cahaya biru. Oleh karena itu, penggunaan perangkat digital yang berlebihan pada malam hari menjadi faktor risiko utama yang berkontribusi pada ¹⁸ penurunan kualitas tidur, yang pada gilirannya mempengaruhi kesehatan fisik dan mental.

2.2.8. Google Colab dengan Pengembangan Model

Google Colab adalah platform berbasis cloud yang menyediakan lingkungan pengembangan untuk *machine learning* dan *deep learning*, yang sangat berguna bagi para peneliti dan pengembang. Salah satu kelebihan utama Google Colab adalah kemampuannya untuk menjalankan kode Python secara langsung di cloud tanpa memerlukan konfigurasi perangkat keras khusus, serta akses ke GPU dan TPU untuk mempercepat pelatihan model.

Google Colab mendukung eksekusi kode berbasis Python dengan berbagai pustaka, termasuk TensorFlow, Keras, dan Scikit-learn, yang sangat berguna untuk pengembangan model *machine learning* seperti *Multilayer*

Perceptron (MLP). Platform ini memungkinkan kolaborasi dalam penelitian dan memungkinkan berbagi notebook yang berisi analisis dan eksperimen dalam bentuk yang mudah dibaca dan dipahami.

2.2.9. Python dan Keras

Python adalah bahasa pemrograman yang sangat populer dalam bidang *machine learning* dan *data science* karena kemudahan penggunaannya dan banyaknya pustaka yang tersedia. Salah satu pustaka yang paling sering digunakan untuk membangun model *deep learning* adalah Keras. Keras adalah pustaka tingkat tinggi yang berjalan di atas TensorFlow, memungkinkan pengembangan dan pelatihan model neural network dengan cara yang lebih sederhana dan lebih mudah.

Keras mendukung pembangunan berbagai jenis model deep learning, termasuk *Multilayer Perceptron* (MLP), yang terdiri dari beberapa lapisan tersembunyi yang dapat belajar representasi dari data yang kompleks. Keras menyediakan antarmuka yang ramah pengguna untuk membangun dan melatih jaringan saraf, serta mengoptimalkan model menggunakan algoritma seperti *Stochastic Gradient Descent* (SGD), Adam, dan lainnya. Keras memiliki API yang sangat modular, memungkinkan pengguna untuk menyesuaikan arsitektur model sesuai kebutuhan spesifik dari prediksi kualitas tidur.

6 BAB III METODOLOGI

3.1. Metode yang digunakan

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimen untuk mengkaji hubungan antara penggunaan media sosial dan kualitas tidur. Penelitian ini bertujuan untuk mengidentifikasi apakah durasi penggunaan media sosial memiliki pengaruh signifikan terhadap kualitas tidur, dan seberapa besar dampaknya.

Untuk mencapai tujuan tersebut, data akan dikumpulkan melalui survei dan menggunakan model prediksi berbasis pembelajaran mesin (Multilayer Perceptron/MLP) untuk menganalisis hubungan antara variabel-variabel yang ada. Secara spesifik, penelitian ini akan mengembangkan model klasifikasi untuk mengidentifikasi kategori kualitas tidur ('Baik' atau 'Buruk'). Model MLP dipilih karena kemampuannya dalam memetakan hubungan yang kompleks antara input dan output, serta keunggulannya dalam menangani data yang tidak linier.

Proses penelitian terdiri dari tiga tahap utama: (1) pengumpulan data melalui kuesioner, (2) pemrosesan dan pembersihan data menggunakan Python, dan (3) pembangunan dan evaluasi model MLP.

3.2. Bahan dan peralatan yang digunakan

Bahan dan peralatan yang digunakan dalam penelitian ini adalah sebagai berikut:

Bahan:

1. Kuesioner Kualitas Tidur: Kuesioner yang digunakan untuk mengukur kualitas tidur responden adalah *Pittsburgh Sleep Quality Index (PSQI)*. Kuesioner ini terdiri dari 19 pertanyaan yang mengukur kualitas tidur berdasarkan beberapa aspek, seperti durasi tidur, gangguan tidur, dan kebiasaan tidur.
2. Kuesioner FOMO (*Fear of Missing Out*): Kuesioner untuk mengukur tingkat kecemasan sosial responden.

3. Data Penggunaan Media Sosial: Data kuantitatif durasi penggunaan media sosial (Instagram, TikTok, dan YouTube) diperoleh dan divalidasi menggunakan bukti objektif berupa screenshot dari fitur screen time yang disediakan oleh setiap responden.

Peralatan:

1. Perangkat Lunak & Platform
 - a. Google Colab: Platform berbasis cloud yang digunakan sebagai lingkungan utama untuk menjalankan kode Python, melakukan eksperimen, serta melatih dan mengevaluasi model machine learning.
 - b. Visual Studio Code (VS Code): Digunakan sebagai text editor utama untuk pengembangan skrip Python di lingkungan lokal, serta untuk membangun aplikasi front-end dan back-end.
2. Bahasa Pemrograman & Library
 - a. Python: Bahasa pemrograman utama yang digunakan untuk semua tahapan, mulai dari pemrosesan data, pembangunan model, hingga pengembangan back-end.
 - b. Pandas & NumPy: Library Python yang esensial untuk manipulasi, pembersihan, dan persiapan data.
 - c. TensorFlow & Keras: Library Python yang digunakan untuk membangun, melatih, dan mengevaluasi arsitektur model jaringan saraf tiruan (Multilayer Perceptron).
 - d. Scikit-learn: Library Python yang digunakan untuk tugas-tugas pendukung machine learning, seperti pembagian dataset (train-test split) dan penskalaan fitur (feature scaling).
 - e. Joblib: Digunakan untuk menyimpan dan memuat objek scaler Python.
3. Teknologi Website
 - a. React (Front-End): Sebuah library JavaScript yang digunakan untuk membangun antarmuka pengguna (user interface) yang interaktif dan modern untuk aplikasi website prediksi.

- b. FastAPI (Back-End): Sebuah framework Python berkinerja tinggi yang digunakan untuk membangun API (Application Programming Interface). API ini bertugas menerima data dari front-end, memprosesnya, menjalankan model prediksi, dan mengirimkan hasilnya kembali.

3.3. Urutan pelaksanaan penelitian²³

Penelitian ini dilaksanakan dalam beberapa tahapan sebagai berikut:

a. Pengumpulan Data Primer

Peneliti menyebarkan kuesioner daring yang terdiri dari kuesioner *Pittsburgh Sleep Quality Index* (PSQI) dan FOMO (*Fear of Missing Out*). Untuk tujuan validasi, responden juga diminta untuk melampirkan screenshot fitur screen time dari perangkat mereka. Selain itu, dilakukan juga pengumpulan data sekunder dari literatur relevan untuk memperkuat konteks penelitian.

b. Pengolahan Data (Data Preprocessing)

Tahap ini bertujuan untuk mengubah data mentah menjadi dataset yang siap untuk dimodelkan. Proses ini meliputi ekstraksi data durasi dalam satuan menit dari setiap file screenshot, perhitungan skor total untuk kuesioner FOMO, dan perhitungan skor total PSQI. Berdasarkan skor total PSQI, dibuatlah variabel target kategori kualitas tidur ('Baik' atau 'Buruk'). Terakhir, dilakukan pembersihan serta encoding data kualitatif menjadi format numerik.

c. Pembangunan Model Klasifikasi MLP

Pada tahap ini, dataset yang telah bersih akan dibagi menjadi tiga bagian: data latih (70%), data validasi (15%), dan data uji (15%). Kemudian, dilakukan perancangan arsitektur model MLP yang dirancang untuk tugas klasifikasi biner menggunakan library Keras di Google Colab. Setelah itu, model akan dilatih menggunakan data latih untuk mempelajari pola antara fitur-fitur input dan kategori kualitas tidur, sementara performanya dipantau menggunakan data validasi.

d. Evaluasi Model

Performa model yang telah dilatih akan dievaluasi secara final menggunakan data uji. Karena model yang dibangun adalah model klasifikasi, metrik evaluasi yang digunakan adalah Akurasi, Presisi, *Recall*, *F1-Score*, dan *Confusion Matrix* untuk mengukur kemampuan model dalam mengklasifikasikan kualitas tidur dengan benar.

HASIL DAN PEMBAHASAN

Pada bab ini, akan dipaparkan hasil dari penelitian yang telah dilaksanakan sesuai dengan metodologi yang diuraikan pada Bab III. Pembahasan akan mencakup seluruh tahapan penelitian secara sistematis, mulai dari analisis dan persiapan data, dilanjutkan dengan proses pembangunan dan tuning model Multilayer Perceptron (MLP). Selanjutnya, akan disajikan hasil evaluasi performa model final, dan diakhiri dengan pembahasan mengenai hasil persiapan deployment model ke dalam aplikasi web.

4.1. Hasil Pemahaman Bisnis (Business Understanding)


Media Media sosial saat ini telah menjadi bagian integral dari kehidupan Generasi Z, tidak hanya sebagai sarana hiburan, tetapi juga sebagai media interaksi, berbagi informasi, dan membangun identitas digital. Tiga platform yang paling banyak digunakan oleh Generasi Z di Indonesia Instagram, TikTok, dan WhatsApp menawarkan berbagai konten visual dan interaktif yang memicu keterlibatan (*engagement*) tinggi.

Namun, peningkatan intensitas penggunaan media sosial ini berpotensi memengaruhi pola tidur pengguna. Paparan cahaya biru dari layar, notifikasi yang terus-menerus, serta dorongan psikologis seperti *Fear of Missing Out* (FOMO) dapat menyebabkan gangguan pada ritme sirkadian dan kualitas tidur.

Berbagai penelitian terdahulu menunjukkan bahwa durasi dan pola penggunaan media sosial yang tidak terkontrol memiliki korelasi dengan menurunnya kualitas tidur. Penelitian ini dilakukan untuk menjawab kebutuhan akan alat prediksi berbasis data yang dapat membantu mengidentifikasi kualitas tidur pada Generasi Z berdasarkan pola penggunaan media sosial mereka.

Hubungan konseptual antara media sosial, FOMO, pola tidur, dan kualitas tidur divisualisasikan pada Gambar 4.1. Diagram ini memperlihatkan bagaimana intensitas penggunaan media sosial berpengaruh terhadap munculnya FOMO, yang

kemudian berdampak pada terganggunya pola tidur, dan akhirnya menurunkan kualitas tidur.



Gambar 4.1 Diagram Konseptual Hubungan Media Sosial, FOMO, Pola Tidur, dan Kualitas Tidur

Gambar 4.1 menggambarkan hubungan konseptual antara penggunaan media sosial, FOMO, pola perilaku, dan kualitas tidur. Penggunaan media sosial (durasi, waktu, dan jenis aplikasi) dapat memengaruhi kualitas tidur secara langsung melalui stimulasi kognitif dan paparan cahaya biru. FOMO yang diukur melalui kuesioner berperan sebagai faktor psikologis yang memicu kecemasan, sehingga mengganggu ketenangan sebelum tidur. Selain itu, pola perilaku seperti jeda tidur dan waktu penggunaan media sosial juga berdampak langsung terhadap ritme sirkadian. Kombinasi dari faktor-faktor tersebut pada akhirnya menentukan kualitas tidur responden, yang diukur menggunakan skor PSQI dalam kategori baik atau buruk.

4.1.1 Hasil Analisis Masalah


Berdasarkan fase Business Understanding, analisis masalah yang dilakukan berhasil mengidentifikasi dan memvalidasi akar permasalahan yang menjadi pendorong utama penelitian ini. Ditemukan bahwa fenomena yang krusial dihadapi oleh Generasi Z adalah tingginya intensitas penggunaan media sosial (khususnya Instagram, TikTok, dan WhatsApp) yang berpotensi memengaruhi pola tidur mereka. Aktivitas penggunaan media sosial yang berlangsung hingga larut malam meningkatkan paparan cahaya biru (*blue light*

exposure) dan stimulasi kognitif, yang berimplikasi pada terganggunya ritme sirkadian serta kualitas tidur secara keseluruhan.

Hasil pengumpulan data awal menunjukkan bahwa sebagian besar responden mengalami kualitas tidur buruk berdasarkan skor *Pittsburgh Sleep Quality Index* (PSQI). Kondisi ini diperkuat oleh adanya gejala *Fear of Missing Out* (FOMO) yang mendorong perilaku scrolling berlebihan sebelum tidur, yang secara tidak langsung memperpanjang durasi penggunaan layar (screen time) pada malam hari. Faktor-faktor ini teridentifikasi sebagai penyebab utama tingginya skor PSQI pada kelompok responden.

Proses evaluasi masalah juga mengonfirmasi bahwa saat ini belum banyak tersedia sistem otomatis yang mampu memprediksi kualitas tidur berdasarkan data penggunaan media sosial. Prediksi kualitas tidur pada umumnya masih mengandalkan wawancara manual atau kuesioner, yang memakan waktu dan tidak praktis untuk penggunaan harian. Oleh karena itu, dibutuhkan solusi berbasis teknologi yang mampu memanfaatkan data durasi penggunaan media sosial serta indikator psikologis (seperti FOMO) untuk memperkirakan kualitas tidur secara cepat, akurat, dan terstandar.

Sebagai hasilnya, pemanfaatan metode Machine Learning dengan algoritma Multilayer Perceptron (MLP) ditetapkan sebagai pendekatan yang paling relevan dan strategis. Metode ini dipilih karena kemampuannya dalam memproses data numerik multidimensi (misalnya skor FOMO, skor PSQI, durasi penggunaan aplikasi) dan mengenali pola non-linear yang kompleks, sehingga diharapkan mampu menghasilkan prediksi yang andal.



Gambar 4. 2 Diagram Konseptual Hubungan Media Sosial, FOMO, Pola Tidur, dan Kualitas Tidur

Gambar 4.2 memperlihatkan alur konseptual bagaimana penggunaan media sosial dan faktor psikologis FOMO berpengaruh terhadap kualitas tidur. Penggunaan media sosial dengan durasi panjang, waktu yang tidak teratur, serta kebiasaan menjelang tidur dapat menimbulkan stimulasi kognitif dan paparan cahaya biru yang mengganggu ritme sirkadian. Sementara itu, tingkat FOMO yang tinggi memicu kecemasan dan pikiran aktif sebelum tidur. Kedua faktor tersebut mendorong terjadinya gangguan pola tidur, seperti sulit tidur atau sering terbangun, yang pada akhirnya menyebabkan kualitas tidur buruk dengan skor PSQI lebih dari 5.

4.1.2 Hasil Tujuan Penelitian


²⁵ Sebagai tindak lanjut dari hasil analisis masalah yang telah divalidasi, tujuan penelitian ini diformulasikan secara spesifik untuk memandu seluruh tahapan teknis pengembangan model. Tujuan utama yang ditetapkan adalah mengembangkan sebuah model klasifikasi berbasis Multilayer Perceptron (MLP) yang mampu memprediksi kategori kualitas tidur Generasi Z berdasarkan data screen time media sosial (Instagram, TikTok, YouTube) serta skor FOMO yang diukur melalui kuesioner.

Dengan memanfaatkan data numerik yang telah diproses, MLP akan mempelajari ⁹⁶ hubungan antara intensitas penggunaan media sosial, tingkat FOMO, dan skor PSQI responden untuk memproduksi prediksi yang akurat. ⁶³ Metrik evaluasi utama yang digunakan meliputi akurasi, presisi, recall, dan F1-score, sehingga performa model dapat dinilai secara menyeluruh.

²⁷ Selain itu, penelitian ini juga bertujuan untuk mengimplementasikan model yang telah dilatih ke dalam sebuah aplikasi web yang terintegrasi dengan Front-End dan Back-End. Aplikasi ini akan memungkinkan pengguna umum untuk memasukkan data durasi penggunaan media sosial dan skor FOMO mereka, kemudian memperoleh prediksi kualitas tidur secara real-time.

Pada akhirnya, seluruh rangkaian tujuan ini bermuara pada satu sasaran akhir: menghasilkan solusi teknologi yang aplikatif, mudah digunakan, dan

berbasis data untuk membantu individu, peneliti, maupun tenaga kesehatan dalam memantau dan meningkatkan kualitas tidur pada Generasi Z.



Gambar 4.3 Alur Penelitian dari Data hingga Deployment Aplikasi Web

Gambar 4.3 menunjukkan alur penelitian yang dimulai dari pengumpulan data melalui Google Form dan screenshot screen time, kemudian dilanjutkan dengan pembersihan data untuk memastikan hanya data valid yang digunakan. Setelah itu dilakukan data preparation berupa perhitungan skor FOMO dan PSQI serta proses encoding. Data yang sudah siap dipakai kemudian digunakan dalam pemodelan dengan algoritma Multilayer Perceptron (MLP) melalui proses training dan validasi. Model yang dihasilkan selanjutnya dievaluasi menggunakan metrik seperti akurasi dan confusion matrix. Tahap terakhir adalah deployment model ke dalam website, sehingga pengguna dapat memasukkan data dan memperoleh prediksi kualitas tidur secara real-time.

4.2. Hasil ⁶⁴ Pemahaman Data (*Data Understanding*)

Tahap *Data Understanding* bertujuan untuk memperoleh pemahaman mendalam mengenai atribut, struktur, dan kualitas dari dataset final yang akan digunakan. Proses ini merupakan fondasi penting untuk memastikan bahwa data yang dipakai dalam pelatihan model representatif dan berkualitas tinggi.

Pada tahap awal, penelitian ini berhasil mengumpulkan total 600 responden melalui kuesioner. Namun, tidak semua data dapat digunakan secara langsung karena harus melewati proses validasi untuk memastikan kualitas dan kelengkapan informasi. Dari hasil validasi tersebut, sebanyak 98 responden dieliminasi karena datanya tidak memenuhi kriteria kelayakan. Faktor utama yang menyebabkan data tidak digunakan antara lain:

1. Tidak adanya lampiran bukti screenshot screen time, yang menjadi syarat wajib penelitian.
2. Adanya jawaban yang tidak lengkap atau inkonsisten pada kuesioner.

Dengan demikian, hanya 502 responden yang dinyatakan valid dan dipertahankan sebagai dataset final untuk tahap pemodelan. Selain itu, dilakukan proses data cleaning terhadap atribut-atribut yang tidak relevan untuk pemodelan. Total terdapat 41 kolom yang dihapus, terdiri dari:

- a) 23 kolom terkait item pertanyaan dan perhitungan perantara PSQI, karena nilainya sudah direpresentasikan dalam skor agregat Skor Total_PSQI.
- b) 11 kolom terkait item pertanyaan FOMO, karena nilainya sudah terangkum dalam Skor_Fomo.
- c) 7 kolom kategori/identifikasi (seperti timestamp, nama, jenis kelamin, dsb), karena tidak digunakan dalam model akhir.

Rincian lengkap nama-nama kolom yang dihapus ⁸⁹ dapat dilihat pada **Lampiran 1**.

4.2.1 Load Dataset

Pada tahap ini, dataset penelitian yang sudah bersih dan di-encode dimuat dari file Excel. Dataset akhir ini memiliki format tabular dengan kolom-

kolom yang siap digunakan untuk pemodelan. Kolom-kolom utama yang digunakan adalah sebagai berikut:

- a) Fitur Input (X): Usia, jeda_tidur, Skor_Fomo, Durasi_Tiktok, Durasi_Instagram, Durasi_WhatsApp, Total_Durasi, Waktu_Dini_Hari, waktu_Malam, waktu_Pagi, waktu_Siang telah menghasilkan one-hot encoding.
- b) Fitur Target (Y): Kualitas_Tidur, yaitu variabel biner (0 = Baik, 1 = Buruk) yang diturunkan dari Skor Total_PSQI.

Proses pemuatan dilakukan menggunakan library Pandas di lingkungan Google Colab. Dataset ini telah melalui proses persiapan data yang menyeluruh, memastikan tidak ada nilai yang hilang dan semua fitur sudah dalam format numerik yang dapat diproses oleh model MLP. Rincian lengkap daftar kolom beserta keterangannya disajikan pada **Lampiran 2**, sehingga pada bab ini hanya ditampilkan ringkasan struktur utama dataset tanpa menampilkan keseluruhan isi tabel.

4.2.2 Deskripsi Statistik


Deskripsi statistik dilakukan untuk memahami karakteristik distribusi data pada variabel target, yaitu Kualitas_Tidur. Variabel ini berisi nilai numerik yang merepresentasikan kategori kualitas tidur dari setiap responden, yaitu 0 untuk "Kualitas Tidur Baik" dan 1 untuk "Kualitas Tidur Buruk".

```
-----
--- Deskripsi Statistik Variabel Target (Kualitas_Tidur) ---
count      502.000000
mean        0.500000
std         0.500499
min         0.000000
25%         0.000000
50%         0.500000
75%         1.000000
max         1.000000
Name: Kualitas_Tidur, dtype: float64
-----
```

Gambar 4.4 Deskripsi Statistik Variabel Target

93 Dari gambar di atas, dapat disimpulkan bahwa dataset berisi 502 data responden. Nilai minimum adalah 0 dan maksimum adalah 1, yang mengonfirmasi bahwa hanya terdapat dua kelas target. Nilai rata-rata (mean) sebesar 0.504 menunjukkan bahwa proporsi antara kelas "Baik" dan "Buruk" sangat mendekati 50:50. Nilai median (50%) dan kuartil yang ada juga menguatkan bahwa data terdistribusi dengan sangat seimbang, yang merupakan kondisi ideal untuk melatih model klasifikasi.


4.2.3 Distribusi Kelas Kualitas Tidur



Gambar 4.5 Distribusi Kelas Target (Baik vs Buruk)

Gambar 4.5 memperlihatkan distribusi kelas target kualitas tidur responden berdasarkan skor PSQI. Dari total 502 responden valid, sebanyak 251 responden (50.0%) masuk kategori kualitas tidur Baik, sementara 251 responden (50.0%) masuk kategori kualitas tidur Buruk. Distribusi yang seimbang ini sangat ideal untuk pemodelan klasifikasi, karena dapat meminimalkan bias terhadap salah satu kelas dan membuat metrik evaluasi lebih representatif.


4.2.4 Distribusi Durasi Total Penggunaan Media Sosial



Gambar 4.6 Distribusi Durasi Penggunaan Media Sosial Harian

Gambar 4.6 memperlihatkan distribusi durasi penggunaan media sosial harian. Hasil analisis menunjukkan variasi yang cukup lebar, dengan mayoritas responden menggunakan media sosial antara 120 hingga 300 menit (2–5 jam) per hari. Variasi ini penting karena memberikan rentang data yang luas sehingga model dapat mempelajari berbagai pola perilaku pengguna.


4.2.5 Distribusi Skor FOMO



Gambar 4. 7 Histogram Distribusi Skor FOMO

Gambar 4.7 memperlihatkan distribusi skor FOMO responden yang dibagi menjadi tiga kategori, yaitu rendah, sedang, dan tinggi. Hasil analisis menunjukkan mayoritas responden berada pada kategori sedang (231 orang), diikuti kategori rendah (166 orang), dan kategori tinggi (105 orang). Temuan ini mengindikasikan bahwa fenomena FOMO cukup dominan dalam sampel penelitian, terutama pada tingkat sedang, sehingga variabel ini penting dianalisis lebih lanjut dalam kaitannya dengan kualitas tidur.

4.2.6 Distribusi Korelasi Antar Variabel Numerik



Gambar 4.8 Heatmap Korelasi Antar Variabel Numerik

Gambar 4.8 menunjukkan heatmap korelasi antar variabel numerik. Terlihat adanya korelasi positif yang cukup kuat antara Skor FOMO dengan Skor Total PSQI, yang berarti semakin tinggi tingkat FOMO seseorang maka semakin buruk kualitas tidurnya. Selain itu, variabel Total Durasi penggunaan media sosial juga berkorelasi positif dengan skor PSQI, menunjukkan bahwa

semakin lama seseorang menggunakan media sosial, semakin besar kemungkinan kualitas tidurnya terganggu. Korelasi antar durasi aplikasi (TikTok, Instagram, WhatsApp) juga terlihat signifikan terhadap Total Durasi, yang wajar karena menjadi komponen pembentuknya.

4.2.7 Dataset Terhadap Performa Model

Penggunaan dataset seimbang terbukti berdampak positif terhadap performa model.

1. Sebelum tuning parameter




Gambar 4.9 Hasil Evaluasi Model Sebelum Tuning

Berdasarkan Gambar 4.9, model dasar menghasilkan akurasi sebesar 79,21% dengan nilai precision, recall, dan f1-score yang relatif seimbang pada kedua kelas. Hal ini menunjukkan bahwa model mampu mengenali data dengan cukup baik, baik pada kelas Baik maupun Buruk. Namun,

masih terdapat kesalahan klasifikasi yang ditunjukkan pada confusion matrix, yaitu sebanyak 12 data kelas Baik yang diprediksi sebagai Buruk dan 9 data kelas Buruk yang diprediksi sebagai Baik. Kesalahan klasifikasi ini menjadi indikasi bahwa model masih memiliki ruang untuk ditingkatkan melalui proses penyetelan parameter (tuning) atau pengembangan model lebih lanjut.

2. Setelah dilakukan tuning parameter



Gambar 4.10 Hasil Evaluasi Model Sesudah Tuning

Berdasarkan hasil evaluasi pada Gambar 4.10, model yang telah melalui proses tuning parameter menunjukkan peningkatan akurasi menjadi 85,15% dengan nilai precision, recall, dan f1-score yang konsisten pada kedua kelas. Confusion matrix memperlihatkan distribusi prediksi yang lebih seimbang, dengan hanya 7 data kelas Baik yang salah diprediksi sebagai Buruk dan 8 data kelas Buruk yang salah diprediksi sebagai Baik.

Hal ini menandakan bahwa proses optimasi berhasil mengurangi kesalahan klasifikasi dan meningkatkan kinerja model secara keseluruhan.

4.3. Hasil Data Preperation

Sebelum data dapat digunakan untuk pelatihan model Multilayer Perceptron (MLP), tahap persiapan data menjadi langkah penting untuk memastikan dataset memiliki format, struktur, dan kualitas yang optimal. Tujuan utama tahap ini adalah mengubah data mentah hasil kuesioner menjadi sebuah dataset yang sepenuhnya numerik, bersih, dan siap dimodelkan.

Secara umum, tahap persiapan data ini terbagi ke dalam beberapa langkah utama sebagai berikut:

4.3.1 Validasi dan Pembersihan Dataset

Tahap awal adalah validasi dan pembersihan data. Dari total 600 responden, dilakukan proses penyaringan agar hanya data yang valid dan lengkap yang dipertahankan. Hasil validasi menunjukkan bahwa hanya 502 responden yang memenuhi kriteria kelayakan, sedangkan sisanya dieliminasi karena:

1. Tidak melampirkan bukti screenshot screen time (syarat wajib penelitian).
2. Memberikan jawaban yang tidak lengkap atau inkonsisten pada kuesioner.

Selain validasi responden, dilakukan pula penghapusan kolom yang tidak relevan, seperti Timestamp, Nama Responden, serta kolom item-item detail PSQI dan FOMO yang sudah direpresentasikan dalam skor total. Pada tahap ini juga dilakukan standarisasi format data, misalnya mengubah nilai pada kolom Usia dari bentuk teks “22 Tahun” menjadi angka numerik 22.


4.3.2 Rekayasa Fitur (*Feature Engineering*)

Setelah dataset bersih, dilakukan rekayasa fitur untuk menghasilkan variabel prediktor yang informatif:

- a) Skor FOMO: dihitung dari penjumlahan 10 item pertanyaan FOMO, menghasilkan satu fitur numerik Skor_Fomo.
- b) Skor PSQI: dihitung berdasarkan tujuh komponen PSQI untuk mendapatkan skor total yang sah.
- c) Fitur Total_Durasi: dibuat dengan menjumlahkan Durasi_Tiktok, Durasi_Instagram, dan Durasi_WhatsApp.
- d) Variabel Target Kualitas_Tidur: dibentuk berdasarkan skor total PSQI dengan label biner 0 = Baik dan 1 = Buruk.

4.3.3 Distribusi Kelas Target

Distribusi kelas pada dataset penting untuk memastikan model dapat dilatih secara seimbang.



Gambar 4.11 Distribusi Kelas Kualitas Tidur (Baik vs Buruk)

Gambar 4.11 memperlihatkan distribusi kelas target pada dataset final. Dari total 502 responden, terdapat 251 responden (50.0%) dengan kualitas tidur Baik dan 251 responden (50.0%) dengan kualitas tidur Buruk. Distribusi yang seimbang ini ideal untuk mencegah bias model dan menghasilkan metrik evaluasi yang lebih representatif.

4.3.4 Pembagian Dataset

Langkah selanjutnya adalah membagi dataset ke dalam subset pelatihan (training), validasi (validation), dan pengujian (testing). Pembagian ini penting untuk memastikan model tidak hanya mampu belajar, tetapi juga dapat dievaluasi pada data baru.

Pada penelitian ini, digunakan rasio:

- 70% data latih (training set)
- 15% data validasi (validation set)
- 15% data uji (testing set)

```
# --- Pembagian Data 3 Arah (70-15-15) ---
X_train_val, X_test, y_train_val, y_test = train_test_split(X, Y, test_size=0.15, random_state=SEED, stratify=Y)
X_train, X_val, y_train, y_val = train_test_split(X_train_val, y_train_val, test_size=(0.15/0.85), random_state=SEED, stratify=y_train_val)

print("\nData berhasil dibagi menjadi 3 bagian:")
print(f"* Data Latih (Training): {len(X_train)} baris")
print(f"* Data Validasi (Validation): {len(X_val)} baris")
print(f"* Data Uji (Testing): {len(X_test)} baris")
```

Gambar 4.12 kode pembagian data responden menjadi 3 jenis data

```
Data berhasil dibagi menjadi 3 bagian:
- Data Latih (Training): 350 baris
- Data Validasi (Validation): 76 baris
- Data Uji (Testing): 76 baris

Scaler berhasil dibuat dan disimpan sebagai 'MASIT_klasifikasi_scaler.pkl'
Model: "sequential_1"
```

Layer (type)	Output Shape	Param #
dense_3 (Dense)	(None, 64)	768
dense_4 (Dense)	(None, 32)	2,080
dense_5 (Dense)	(None, 1)	33

```
Total params: 2,881 (11.25 KB)
Trainable params: 2,881 (11.25 KB)
Non-trainable params: 0 (0.00 B)
```

Gambar 4.13 Hasil Pembagian Dataset (Train, Validation, Test)

Pembagian dilakukan menggunakan fungsi `train_test_split` dari Scikit-learn dengan parameter stratify, sehingga proporsi label "Baik" dan "Buruk" tetap seimbang pada setiap subset.

4.3.5 Encoding

Tahap terakhir dalam persiapan data adalah memastikan seluruh fitur dapat diproses oleh model MLP. Proses ini dilakukan melalui teknik encoding pada variabel kategorikal.

1. Ordinal Encoding diterapkan pada fitur kategorikal yang memiliki tingkatan, seperti `jeda_tidur`. Teknik ini mengubah kategori menjadi angka sesuai urutan yang logis.

	A	B
	Usia Responden (Tahun ini)	jeda_tidur
1		
2	22 Tahun	Kurang dari 30 menit
3	21 Tahun	30 menit - 1 jam
4	22 Tahun	Langsung Tidur sambil membuka media sosial
5	26 Tahun	30 menit - 1 jam
6	22 Tahun	Kurang dari 30 menit
7	22 Tahun	Langsung Tidur sambil membuka media sosial
8	22 Tahun	Kurang dari 30 menit
9	22 Tahun	Lebih dari 1 jam

Gambar 4.14 Sebelum data di-encode

	A	B
	Usia Responden (Tahun ini)	jeda_tidur
1		
2	22	1
3	21	2
4	22	0
5	26	2
6	22	1
7	22	0
8	22	1
9	22	3

Gambar 4.15 Sesudah data di-encode

2. One-Hot Encoding diterapkan pada fitur kategorikal tanpa urutan, seperti pola_waktu. Proses ini menghasilkan variabel biner baru untuk setiap kategori, sehingga informasi kategori dapat direpresentasikan dengan baik.

B
Pada rentang waktu kapan Anda paling sering menggunakan media sosial (Instagram, TikTok, Whatsapp)? (Boleh pilih lebih dari satu)
Siang (12:00 - 18:00)
Malam (18:00 - 00:00)
Malam (18:00 - 00:00)
Dini Hari (00:00 - 06:00)
Malam (18:00 - 00:00)
Malam (18:00 - 00:00)
Malam (18:00 - 00:00)
Malam (18:00 - 00:00)

Gambar 4.16 Sebelum data di one hot encoding

H	I	J	K
waktu_Dini Hari (00:00 - 06:00)	waktu_Mala m (18:00 - 00:00)	waktu_Pagi (06:00 - 12:00)	waktu_Siang (12:00 - 18:00)
0	0	0	1
0	1	0	0
0	1	0	0
1	0	0	0
0	1	0	0
0	1	0	0
0	1	0	0
0	1	0	0
0	1	0	0

Gambar 4.17 Sesudah data di one hot encoding

Dengan adanya proses encoding ini, seluruh fitur telah berhasil diubah menjadi format numerik yang kompatibel dengan model MLP. Setelah melalui seluruh tahapan persiapan data, diperoleh dataset final yang sepenuhnya numerik, bersih, dan seimbang sehingga siap digunakan pada tahap pemodelan.

4.4. Hasil Modeling

Tahapan Modelling merupakan inti dari proses pembelajaran mesin, dimana model dilatih menggunakan dataset yang telah dipersiapkan pada tahap sebelumnya. Dalam penelitian ini digunakan arsitektur Multilayer Perceptron (MLP) sebagai model utama untuk melakukan prediksi kualitas tidur berdasarkan variabel screen time dan skor FOMO responden.

Model MLP dipilih karena mampu menangkap hubungan non-linear antar variabel input serta fleksibel dalam memproses data numerik hasil transformasi. Tujuan utama dari proses ini adalah agar model dapat mempelajari pola dari data input (durasi penggunaan media sosial, skor FOMO, jeda tidur, dan usia) untuk mengklasifikasikan kualitas tidur responden ke dalam dua kategori: Baik (0) dan Buruk (1).

4.4.1 Arsitektur Model

Model yang dibangun dalam penelitian ini adalah Multilayer Perceptron (MLP) yang dirancang khusus untuk tugas klasifikasi biner ("Baik" vs "Buruk"). Arsitektur model ini disusun menggunakan library Keras dengan TensorFlow sebagai backend. Struktur model terdiri dari tiga bagian utama: satu lapisan input, dua lapisan tersembunyi (hidden layers), dan satu lapisan output.

Model: "sequential"

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 128)	1,536
dropout (Dropout)	(None, 128)	0
dense_1 (Dense)	(None, 64)	8,256
dropout_1 (Dropout)	(None, 64)	0
dense_2 (Dense)	(None, 1)	65

Total params: 9,857 (38.50 KB)
 Trainable params: 9,857 (38.50 KB)
 Non-trainable params: 0 (0.00 B)

Gambar 4.18 Arsitektur Model MLP

Seperti yang ditunjukkan pada Gambar 4.18, arsitektur model secara rinci adalah sebagai berikut:

1. Lapisan Input: Menerima 11 fitur numerik hasil dari tahap persiapan data.
2. Lapisan Tersembunyi Pertama: Terdiri dari 128 neuron dengan fungsi aktivasi ReLU (Rectified Linear Unit). Lapisan ini diikuti oleh lapisan Dropout dengan laju 0.4 untuk mencegah overfitting.
3. Lapisan Tersembunyi Kedua: Terdiri dari 64 neuron dengan fungsi aktivasi ReLU, yang juga diikuti oleh lapisan Dropout dengan laju 0.4.
4. Lapisan Output: Terdiri dari 1 neuron dengan fungsi aktivasi Sigmoid, yang menghasilkan nilai probabilitas (antara 0 dan 1) untuk kelas "Buruk".

Pendekatan ini memungkinkan model untuk mempelajari pola non-linear yang kompleks dari data, sementara penggunaan Dropout membantu meningkatkan kemampuan generalisasi model pada data baru.

4.4.2 Proses Pelatihan (*Training*)

Setelah arsitektur model ditetapkan, tahap berikutnya adalah melakukan proses pelatihan (training). Proses ini bertujuan untuk menyesuaikan bobot-bobot di dalam model MLP agar mampu mengklasifikasikan kualitas tidur responden ke dalam dua kategori: "Baik" (0) dan "Buruk" (1).

Model dilatih menggunakan optimizer Adam dengan learning rate awal 0.001 dan fungsi kerugian binary_crossentropy, yang merupakan standar untuk tugas klasifikasi biner. Proses pelatihan juga dilengkapi dengan dua callback canggih untuk optimisasi:

1. Early Stopping: Berfungsi sebagai "rem otomatis" yang akan menghentikan pelatihan jika performa model pada data validasi tidak lagi meningkat setelah sejumlah epoch tertentu. Ini untuk mencegah overfitting dan menemukan momen berhenti terbaik.

2. ReduceLROnPlateau: Secara dinamis menyesuaikan learning rate (kecepatan belajar) jika model mengalami stagnasi, memungkinkan proses pembelajaran yang lebih halus dan efektif.

```

--- PROSES PELATIHAN DIMULAI ---
Epoch 1/15
24 30m/step - accuracy: 0.6335 - loss: 0.8528 - val_accuracy: 0.8518 - val_loss: 0.5286
Epoch 2/15
24 30m/step - accuracy: 0.8584 - loss: 0.4863 - val_accuracy: 0.8642 - val_loss: 0.4272
Epoch 3/15
24 30m/step - accuracy: 0.8587 - loss: 0.4881 - val_accuracy: 0.8705 - val_loss: 0.3687
Epoch 4/15
24 30m/step - accuracy: 0.8429 - loss: 0.3548 - val_accuracy: 0.8705 - val_loss: 0.3322
Epoch 5/15
24 30m/step - accuracy: 0.8718 - loss: 0.3363 - val_accuracy: 0.8705 - val_loss: 0.3177
Epoch 6/15
24 30m/step - accuracy: 0.8586 - loss: 0.2882 - val_accuracy: 0.8705 - val_loss: 0.3888
Epoch 7/15
24 30m/step - accuracy: 0.8799 - loss: 0.2864 - val_accuracy: 0.8705 - val_loss: 0.2993
Epoch 8/15
24 30m/step - accuracy: 0.8884 - loss: 0.2811 - val_accuracy: 0.8705 - val_loss: 0.2918
Epoch 9/15
24 30m/step - accuracy: 0.8582 - loss: 0.2648 - val_accuracy: 0.8705 - val_loss: 0.2845
Epoch 10/15
24 30m/step - accuracy: 0.8796 - loss: 0.2752 - val_accuracy: 0.8705 - val_loss: 0.2798
Epoch 11/15
24 30m/step - accuracy: 0.8888 - loss: 0.2683 - val_accuracy: 0.8889 - val_loss: 0.2768
Epoch 12/15
24 30m/step - accuracy: 0.8951 - loss: 0.2471 - val_accuracy: 0.8889 - val_loss: 0.2739
Epoch 13/15
24 30m/step - accuracy: 0.8688 - loss: 0.2548 - val_accuracy: 0.8889 - val_loss: 0.2715
Epoch 14/15
24 30m/step - accuracy: 0.8785 - loss: 0.2372 - val_accuracy: 0.8889 - val_loss: 0.2686
Epoch 15/15
24 30m/step - accuracy: 0.9020 - loss: 0.2389 - val_accuracy: 0.8889 - val_loss: 0.2685
--- PROSES PELATIHAN SELESAI ---

```

Gambar 4.19 Proses Pelatihan Model MLP

Model dilatih selama maksimal 200 epoch, di mana setiap epoch terdiri dari beberapa iterasi batch. Di setiap iterasi, model melakukan prediksi, menghitung loss, dan memperbarui bobotnya. Selain itu, model juga dievaluasi pada data validasi di setiap akhir epoch untuk memantau performanya terhadap data yang tidak dilatih secara langsung.

4.4.3 Hyperparameter Tuning

Dalam pelatihan model pembelajaran mesin, khususnya untuk model berbasis Jaringan Saraf Tiruan (JST), performa sangat dipengaruhi oleh pemilihan hyperparameter. Hyperparameter adalah parameter eksternal yang konfigurasinya ditentukan sebelum proses pelatihan dimulai. Untuk menemukan kombinasi konfigurasi terbaik yang memberikan performa optimal pada tugas klasifikasi kualitas tidur, dilakukan proses hyperparameter tuning secara sistematis. Proses ini berfokus pada tiga aspek utama: arsitektur

model (jumlah neuron), teknik regularisasi (dropout), dan kecepatan belajar (learning rate).

4.4.3.1. Evaluasi Sebelum Tuning

Langkah pertama adalah membangun dan mengevaluasi model MLP dengan arsitektur dasar untuk menetapkan performa awal (baseline). Model dasar ini dibangun dengan arsitektur standar (64 -> 32 neuron) tanpa regularisasi dropout dan menggunakan learning rate default dari optimizer Adam. Model dilatih pada data latih dan dievaluasi menggunakan data uji.

```
Model: "sequential_3"

```

Layer (type)	Output Shape	Param #
dense_9 (Dense)	(None, 64)	768
dense_10 (Dense)	(None, 32)	2,080
dense_11 (Dense)	(None, 1)	33

```

Total params: 2,881 (11.25 KB)
Trainable params: 2,881 (11.25 KB)
Non-trainable params: 0 (0.00 B)

Melatih model dasar (sebelum tuning)...
Pelatihan selesai.
4/4 ----- 0s 23ms/step


--- HASIL EVALUASI MODEL DASAR (SEBELUM TUNING) ---
Akurasi Final pada Data Uji: 79.21%

Laporan Klasifikasi (untuk Tabel 4.4):

```

	precision	recall	f1-score	support
Baik (0)	0.81	0.76	0.79	51
Buruk (1)	0.77	0.82	0.80	50
accuracy			0.79	101
macro avg	0.79	0.79	0.79	101
weighted avg	0.79	0.79	0.79	101

Gambar 4.20 Klasifikasi Model Dasar Sebelum Tuning




Gambar 4.21 Confusion Matrix Model Dasar

Dari hasil tersebut, diperoleh akurasi sebesar 79.21%. Hasil ini menunjukkan bahwa model dasar sudah mampu mempelajari pola data dengan cukup baik, namun masih terdapat ruang untuk optimisasi lebih lanjut guna meningkatkan kemampuannya dalam melakukan generalisasi pada data baru.

4.4.3.1 Evaluasi Sesudah Tuning

Setelah performa dasar ditetapkan, dilakukan serangkaian eksperimen dengan mengubah-ubah hyperparameter. Konfigurasi yang diuji meliputi variasi jumlah neuron, penambahan lapisan Dropout untuk regularisasi, dan penyesuaian learning rate. Selain itu, callback Early Stopping juga diterapkan untuk menghentikan proses pelatihan pada momen paling optimal secara otomatis.

Setelah melalui proses tuning, ditemukan sebuah arsitektur final yang memberikan performa terbaik. Model final ini kemudian dilatih kembali dan dievaluasi pada data uji yang sama.



Gambar 4.22 Klasifikasi Model Final (Setelah Tuning) dan Confusion Matrix Model Final


Seperti yang ditunjukkan pada hasil evaluasi, model yang telah di-tuning berhasil mencapai Akurasi Final sebesar 85.15%. Terjadi peningkatan performa yang signifikan dibandingkan dengan model dasar, terutama pada metrik F1-Score untuk kedua kelas, yang menandakan bahwa proses tuning berhasil menciptakan model yang lebih akurat dan seimbang.

4.4.4 Proses Validasi

Proses validasi merupakan bagian integral dari tahap pelatihan model yang bertujuan untuk mengukur kemampuan model dalam melakukan

generalisasi pada data baru yang tidak pernah dilihat sebelumnya. Pada penelitian ini, data validasi (15% dari total dataset) digunakan untuk menguji performa model setelah setiap epoch pelatihan.

Proses ini sangat penting untuk memantau apakah model mengalami overfitting (terlalu baik pada data latih tapi buruk pada data baru) atau underfitting (belum cukup belajar). Grafik riwayat pelatihan (training history) pada Gambar 4.23 memvisualisasikan proses ini.



Gambar 4.23 Grafik Riwayat Pelatihan (Akurasi Training vs Validasi)

Dari Gambar 4.23, terlihat bahwa kurva akurasi validasi (val_accuracy) meningkat seiring dengan kurva akurasi training (accuracy) dan kemudian stabil, tanpa adanya penurunan drastis. Hal ini, dikombinasikan dengan penggunaan callback Early Stopping yang menghentikan pelatihan pada titik optimal, mengonfirmasi bahwa model yang dihasilkan tidak mengalami overfitting dan memiliki kemampuan generalisasi yang baik.

4.5. Hasil Evaluation

Evaluasi dilakukan untuk mengetahui performa akhir model Multi-Layer Perceptron (MLP) dalam memprediksi kualitas tidur responden. Proses evaluasi ini menggunakan data uji (testing set) yang tidak pernah digunakan dalam pelatihan maupun validasi, sehingga hasilnya dapat menggambarkan kemampuan generalisasi model.

- a) Metrik evaluasi yang digunakan adalah sebagai berikut:
- b) Accuracy: Persentase prediksi yang benar dibandingkan jumlah total data.

- c) Precision: Kemampuan model untuk menghindari kesalahan klasifikasi positif palsu.
- d) Recall: ⁴² Kemampuan model dalam mengenali seluruh data yang benar-benar termasuk ke dalam kelas tertentu.
- e) ⁴⁹ F1-Score: Rata-rata harmonik dari precision dan recall yang berguna untuk menilai performa model terutama pada data dengan distribusi kelas yang seimbang.
- f) Support: Jumlah data pada masing-masing kelas (Baik dan Buruk).

Hasil evaluasi model ditampilkan pada Gambar 4.9, dengan akurasi sebesar 79.21% sebelum dilakukan hyperparameter tuning. Nilai ini menunjukkan bahwa model sudah dapat mempelajari pola dari fitur input (usia, jeda tidur, skor FOMO, serta durasi penggunaan media sosial) dengan cukup baik, meskipun masih terdapat ruang perbaikan melalui tuning parameter.

4.6. Prediksi Data Baru

Tahap ini bertujuan untuk menguji model MLP pada data baru (unseen data) yang tidak memiliki label kualitas tidur. Proses ini dilakukan untuk melihat bagaimana model mampu melakukan klasifikasi terhadap input yang benar-benar belum pernah ditemuinya.

Data yang digunakan berupa input numerik hasil pre-processing dan encoding, dengan variabel seperti Usia, Jeda Tidur, Skor FOMO, Durasi TikTok, Durasi Instagram, Durasi WhatsApp, serta Total Durasi penggunaan media sosial. Data ini kemudian dimasukkan ke dalam model MLP, yang menghasilkan output probabilitas untuk dua kelas (0 = Baik, 1 = Buruk).

Prediksi akhir diperoleh dengan mengambil nilai probabilitas terbesar (melalui fungsi `argmax`) sehingga setiap responden diklasifikasikan ke dalam salah satu kategori kualitas tidur. Hasil prediksi ini kemudian ditambahkan ke dataset sebagai kolom baru dengan nama `Predicted_Label`.

Dengan demikian, model tidak hanya berfungsi sebagai alat analisis, tetapi juga dapat digunakan sebagai sistem pendukung keputusan untuk memprediksi

potensi kualitas tidur responden baru berdasarkan pola screen time dan tingkat FOMO mereka.

4.7. Pembahasan

Visualisasi hasil digunakan untuk memberikan gambaran lebih jelas mengenai distribusi prediksi kualitas tidur dan hubungan antar variabel. Tiga bentuk visualisasi utama yang digunakan adalah:

1. Distribusi Label Hasil Prediksi

Setelah model melakukan prediksi, dihitung jumlah responden yang masuk ke kategori ⁷⁹ **Kualitas Tidur Baik** (label 0) dan **Kualitas Tidur Buruk** (label 1). Distribusi ini divisualisasikan dalam bentuk grafik batang (Gambar 4.7).

Hasilnya menunjukkan bahwa jumlah prediksi kelas relatif seimbang, dengan sedikit kecenderungan model lebih sering memprediksi ke kelas mayoritas sesuai distribusi dataset. Hal ini sejalan dengan nilai evaluasi yang menunjukkan performa cukup stabil pada kedua kelas.

2. Distribusi Durasi Penggunaan Media Sosial dan Skor FOMO

Untuk memperdalam pemahaman, dilakukan visualisasi tambahan berupa histogram dan boxplot (Gambar 4.7 dan 4.8) yang menggambarkan perbedaan total durasi media sosial antara responden dengan kualitas tidur dan Skor FOMO

Hasil visualisasi memperlihatkan bahwa:

- a) Responden dengan skor FOMO tinggi cenderung lebih banyak masuk kategori Kualitas Tidur Buruk.
- b) Responden dengan durasi screen time lebih panjang (khususnya pada malam hari) juga lebih sering diprediksi memiliki kualitas tidur yang buruk.

3. Hasil Prediksi Dataset Uji


Sebagai contoh, ditampilkan 10 data pertama dari hasil prediksi model (Gambar 4.9 dan 4.10). Kolom Predicted_Label menunjukkan kategori

hasil klasifikasi (0 = Baik, 1 = Buruk). Visualisasi ini menegaskan bahwa model berhasil memisahkan responden berdasarkan pola aktivitas digital mereka.

4.8 Implementasi Model ke Website

Sebagai bentuk implementasi hasil penelitian, dilakukan pengembangan sederhana berupa aplikasi berbasis website. Tahap ini bukan merupakan fokus utama penelitian, melainkan hanya sebagai proof of concept untuk memperlihatkan bagaimana model prediksi kualitas tidur dapat digunakan secara langsung oleh pengguna melalui antarmuka yang lebih sederhana dan praktis.

Website ini dibangun dengan menggunakan framework Flask sebagai backend dan HTML/CSS/JavaScript sebagai frontend. Model MLP yang telah dilatih dan disimpan dalam format .joblib diintegrasikan ke dalam backend Flask, sehingga sistem dapat menerima input data pengguna dan mengembalikan hasil prediksi kualitas tidur.



Gambar 4.24 Diagram Arsitektur Implementasi Model ke Website.

Diagram di atas menjelaskan alur kerja sistem prediksi kualitas tidur berbasis website. Proses dimulai dari pengguna yang mengisi form pada aplikasi web (front-end) dengan data berupa usia, jeda tidur, skor FOMO, serta durasi penggunaan media sosial. Data ini kemudian dikirim ke server Flask (back-end) melalui permintaan API (API request).

Selanjutnya, server memanggil model MLP yang telah disimpan dalam format .h5 atau .pkl untuk melakukan prediksi. Model mengembalikan hasil prediksi dalam bentuk kategori kualitas tidur. Hasil tersebut kemudian diproses oleh server dan

dikirim kembali ke aplikasi web untuk ditampilkan kepada pengguna dalam bentuk label sederhana, yaitu “Baik” atau “Buruk”.

Dengan alur ini, sistem dapat berjalan secara otomatis dan real-time, sehingga memudahkan pengguna untuk mengetahui prediksi kualitas tidurnya tanpa perlu menjalankan kode secara manual. Untuk memperjelas implementasi, berikut disajikan screenshot tampilan sistem.

37
Gambar 4.25 Halaman Input Data Website 1

SleepQualityAI

9. Seberapa sering Anda bangun tengah malam untuk pergi ke kamar tidur?

3 - Normal

10. Bagaimana perasaan Anda ketika bangun di malam hari?

3 - Normal

11. Bagaimana perasaan Anda ketika bangun di malam hari?

3 - Normal

12. Bagaimana perasaan Anda ketika bangun di malam hari?

3 - Normal

13. Bagaimana perasaan Anda ketika bangun di malam hari?

3 - Normal

Durasi Penggunaan Media Sosial (per hari)

14. Instagram 15. TikTok 16. WhatsApp

01:30 01:30 01:30

[Lihat Hasil Prediksi Saya](#)

Gambar 4.26 Halaman Input Data Website 2

SleepQualityAI

--- HASIL PREDIKSI KUALITAS TIDUR ---

BAIK


Target Kepuasan: 82.27%

Luar Biasa!

Kualitas tidur Anda berada di luar yang normal...

[Coba Prediksi Lagi](#)

Gambar 4.27 Hasil Prediksi Kualitas Tidur Baik



Gambar 4.28 Hasil Prediksi Kualitas Tidur Buruk

Sistem tidak hanya menampilkan label hasil prediksi, tetapi juga menyajikan informasi tambahan berupa nilai akurasi prediksi. Selain itu, ketika status kualitas tidur terdeteksi buruk, sistem memberikan rekomendasi yang relevan agar pengguna dapat mengambil langkah perbaikan.

Implementasi ini menunjukkan bahwa hasil penelitian dapat diakses secara user-friendly tanpa perlu menjalankan kode program secara manual. Namun, perlu ditegaskan bahwa pembuatan website ini hanya bersifat pendukung dan bukan merupakan fokus utama penelitian, sehingga pengembangan lebih lanjut seperti integrasi ke aplikasi mobile atau monitoring otomatis dapat menjadi agenda penelitian berikutnya.

BAB V

PENUTUP

5.1. Kesimpulan

Berdasarkan hasil penelitian mengenai prediksi kualitas tidur Generasi Z berdasarkan data screen time media sosial dan skor FOMO menggunakan metode Multilayer Perceptron (MLP), dapat ditarik beberapa kesimpulan sebagai berikut:

1. Pemahaman Masalah

Fenomena penggunaan media sosial yang tinggi pada Generasi Z, terutama Instagram, TikTok, dan WhatsApp, terbukti memiliki keterkaitan erat dengan kualitas tidur. Faktor psikologis berupa Fear of Missing Out (FOMO) berperan penting sebagai pemicu kecemasan sebelum tidur, sehingga berdampak pada buruknya kualitas tidur.

2. Kualitas Data

Dari total 600 responden yang mengisi kuesioner, sebanyak 502 responden dinyatakan valid setelah melalui proses validasi data, cleaning, dan penghapusan kolom yang tidak relevan. Distribusi kelas target (Baik vs Buruk) seimbang (50:50), sehingga dataset sangat ideal untuk melatih model klasifikasi.

3. Pemodelan dengan Multilayer Perceptron (MLP)

Model MLP dipilih karena kemampuannya mempelajari pola non-linear dari variabel input (usia, jeda tidur, durasi screen time, skor FOMO). Hasil pemodelan menunjukkan bahwa arsitektur dengan dua hidden layer, regularisasi dropout, dan optimizer Adam mampu menghasilkan performa optimal.

4. Performa Model

Model dasar (baseline) mencapai akurasi sebesar 79,21%, sedangkan model setelah hyperparameter tuning berhasil meningkat hingga 85,15%, dengan

¹⁵ precision, recall, dan F1-score yang seimbang pada kedua kelas. Hal ini membuktikan bahwa MLP efektif dalam memprediksi kualitas tidur Generasi Z.

5. Implementasi Aplikasi

¹⁴ Model yang telah dilatih berhasil diintegrasikan ke dalam aplikasi berbasis web, sehingga dapat digunakan untuk melakukan prediksi kualitas tidur secara real-time. Pengguna dapat memasukkan data screen time dan skor FOMO, lalu sistem akan mengeluarkan hasil prediksi dalam kategori “Baik” atau “Buruk”.

Dengan demikian, penelitian ini membuktikan bahwa metode pembelajaran mesin berbasis MLP dapat digunakan sebagai solusi prediktif untuk membantu mengidentifikasi kualitas tidur Generasi Z berdasarkan pola penggunaan media sosial dan tingkat FOMO.

²⁰ 5.2 Saran

Berdasarkan penelitian yang telah dilakukan, beberapa saran yang dapat diberikan untuk pengembangan lebih lanjut adalah sebagai berikut:

1. Pengembangan Dataset

Penelitian ini terbatas pada responden Generasi Z dengan jumlah 502 data. Penelitian selanjutnya dapat memperluas cakupan responden lintas generasi (misalnya Milenial atau Gen Alpha) ¹¹ dengan jumlah sampel yang lebih besar agar hasil lebih generalis.

2. Penambahan Variabel

Selain durasi screen time dan skor FOMO, penelitian lanjutan dapat memasukkan variabel tambahan seperti kualitas lingkungan tidur, aktivitas fisik, atau faktor kesehatan mental yang mungkin turut memengaruhi kualitas tidur.

3. Peningkatan Model

Walaupun MLP memberikan hasil yang cukup baik, model lain seperti Random Forest, XGBoost, atau model berbasis Deep Learning yang lebih kompleks (CNN/LSTM) dapat diuji untuk membandingkan performa.

4. Optimisasi Aplikasi Web

Implementasi aplikasi web dapat terus dikembangkan agar lebih interaktif dan user-friendly, misalnya dengan dashboard analitik, fitur rekomendasi kebiasaan sehat sebelum tidur, serta integrasi dengan data real-time dari perangkat wearable (smartwatch).

5. ⁷¹Manfaat Praktis

Hasil penelitian ini diharapkan dapat dimanfaatkan oleh tenaga kesehatan, psikolog, maupun masyarakat umum sebagai alat bantu monitoring pola tidur, sehingga ⁹⁰dapat meningkatkan kesadaran akan dampak penggunaan media sosial terhadap kesehatan.

PREDIKSI KUALITAS TIDUR BERDASARKAN PENGGUNAAN MEDIA SOSIAL MENGGUNAKAN MULTILAYER PERCEPTRON (MLP)

ORIGINALITY REPORT

14%	11%	8%	%
SIMILARITY INDEX	INTERNET SOURCES	PUBLICATIONS	STUDENT PAPERS

PRIMARY SOURCES

1	repository.sadapenerbit.com Internet Source	<1 %
2	www.scribd.com Internet Source	<1 %
3	Khezia Alfani Tambunan, Dika Sagita Ranggaswana, Anom Dwi Prakoso. "Hubungan blue light pada perangkat elektronik dan tingkat stres dengan kualitas tidur remaja", Jurnal Ilmu Kesehatan Bhakti Husada: Health Sciences Journal, 2025 Publication	<1 %
4	docplayer.info Internet Source	<1 %
5	garuda.kemdikbud.go.id Internet Source	<1 %
6	repository.its.ac.id Internet Source	<1 %

7

Muhammad Khatama Insani, Dwi Budi Santoso. "Perbandingan Kinerja Model Pre-Trained CNN (VGG16, RESNET, dan INCEPTIONV3) untuk Aplikasi Pengenalan Wajah pada Sistem Absensi Karyawan", Jurnal Indonesia : Manajemen Informatika dan Komunikasi, 2024

Publication

<1 %

8

jurnal.untan.ac.id

Internet Source

<1 %

9

Yumi Novita Dewi, Muhammad Iqbal, Lisnawanty, Maisyaroh, Suhardjono. "Optimalisasi Prediksi Dalam Kelulusan Berbasis Deep Learning: Perbandingan Kinerja Multi-Layer Perceptron dan Deep Neural Network", Infotek: Jurnal Informatika dan Teknologi, 2025

Publication

<1 %

10

digilib.uinsgd.ac.id

Internet Source

<1 %

11

es.scribd.com

Internet Source

<1 %

12

[kirim.ai](http:// kirim.ai)

Internet Source

<1 %

13

www.slideshare.net

Internet Source

<1 %

14	Alfis Arif, Debi Gusmaliza. "Sistem Cerdas Deteksi Status Gizi Anak melalui Eksplorasi Algoritma C.45 dan Forward Feature Selection", Edumatic: Jurnal Pendidikan Informatika, 2024 Publication	<1 %
15	Ade Putra Tupu Djoru, Sri Yulianto. "Pendekatan Machine Learning untuk Deteksi Stunting pada Balita Menggunakan K-Nearest Neighbors", Jurnal JTIK (Jurnal Teknologi Informasi dan Komunikasi), 2025 Publication	<1 %
16	dspace.uui.ac.id Internet Source	<1 %
17	ojs.mahadewa.ac.id Internet Source	<1 %
18	stephaniepaulet.com Internet Source	<1 %
19	text-id.123dok.com Internet Source	<1 %
20	repository.unmuhjember.ac.id Internet Source	<1 %
21	Endah Sari P, Muadi Muadi, Ani Nurhaeni, Dewi Erna Marisa, Thia Oktiany, Rosalia Rahayu, Lili Wahyuni. "Ketergantungan Smartphone dan Konsekuensinya Terhadap	<1 %

-
- | | | |
|--|--|----------------|
| <div style="background-color: #666666; color: white; padding: 5px; display: inline-block; width: 40px; text-align: center;">22</div> | <p>Raihan Raihan, Cecep Nurul Alam, Wildan Budiawan Zulfikar. "Deteksi Pneumonia pada Citra Akhir X – Ray Dada Menggunakan Convolutional Neural Networks Berdasarkan Fitur Prewitt Operator", INTERNAL (Information System Journal), 2025</p> <p>Publication</p> | <p><1 %</p> |
|--|--|----------------|
-
- | | | |
|--|---|----------------|
| <div style="background-color: #333399; color: white; padding: 5px; display: inline-block; width: 40px; text-align: center;">23</div> | <p>docobook.com</p> <p>Internet Source</p> | <p><1 %</p> |
|--|---|----------------|
-
- | | | |
|--|--|----------------|
| <div style="background-color: #0070C0; color: white; padding: 5px; display: inline-block; width: 40px; text-align: center;">24</div> | <p>www.ics-2016.org</p> <p>Internet Source</p> | <p><1 %</p> |
|--|--|----------------|
-
- | | | |
|--|--|----------------|
| <div style="background-color: #FF0000; color: white; padding: 5px; display: inline-block; width: 40px; text-align: center;">25</div> | <p>123dok.com</p> <p>Internet Source</p> | <p><1 %</p> |
|--|--|----------------|
-
- | | | |
|--|--|----------------|
| <div style="background-color: #CC00CC; color: white; padding: 5px; display: inline-block; width: 40px; text-align: center;">26</div> | <p>Mohamad Jamil, Rosihan Rosihan, Masdar S Hanafi. "Analisis Sentimen Calon Kepala Daerah Maluku Utara dengan Metode CRISP-DM", bit-Tech, 2025</p> <p>Publication</p> | <p><1 %</p> |
|--|--|----------------|
-
- | | | |
|--|---|----------------|
| <div style="background-color: #9900FF; color: white; padding: 5px; display: inline-block; width: 40px; text-align: center;">27</div> | <p>Muhammad Rizky Julianto, Yuma Akbar, Tri Wahyudi. "Analisis Sentimen Respon Publik Terhadap Program Internet Gratis di Platform X Melalui Pendekatan Algoritma Naïve Bayes", Jurnal Indonesia : Manajemen Informatika dan Komunikasi, 2024</p> | <p><1 %</p> |
|--|---|----------------|

-
- | | | |
|----|--|------|
| 28 | repository.upi.edu
Internet Source | <1 % |
|----|--|------|
-
- | | | |
|----|--|------|
| 29 | www.coursehero.com
Internet Source | <1 % |
|----|--|------|
-
- | | | |
|----|--|------|
| 30 | www.watersevenr.com
Internet Source | <1 % |
|----|--|------|
-
- | | | |
|----|--|------|
| 31 | Kezia Woran, Rina M Kundre, Ferlan A Pondaag. "ANALISIS HUBUNGAN PENGGUNAAN MEDIA SOSIAL DENGAN KUALITAS TIDUR PADA REMAJA", JURNAL KEPERAWATAN, 2021
Publication | <1 % |
|----|--|------|
-
- | | | |
|----|--|------|
| 32 | journal.unimma.ac.id
Internet Source | <1 % |
|----|--|------|
-
- | | | |
|----|---|------|
| 33 | Arif wicahyanto, Nurchim Nurchim, Wijiyanto Wijiyanto. "PENERAPAN ARTIFICIAL NEURAL NETWORK DALAM DETEKSI SERANGAN PADA WEB SERVER APACHE", Jurnal Informatika dan Rekayasa Elektronik, 2025
Publication | <1 % |
|----|---|------|
-
- | | | |
|----|--|------|
| 34 | id.scribd.com
Internet Source | <1 % |
|----|--|------|
-
- | | | |
|----|--|------|
| 35 | www.futbolxxi.com
Internet Source | <1 % |
|----|--|------|
-

36	digilib.unisayogya.ac.id Internet Source	<1 %
37	eprints.ums.ac.id Internet Source	<1 %
38	repository.dinamika.ac.id Internet Source	<1 %
39	elibrary.unikom.ac.id Internet Source	<1 %
40	eprints.perbanas.ac.id Internet Source	<1 %
41	marketplace.jojonomic.com Internet Source	<1 %
42	rcf-indonesia.org Internet Source	<1 %
43	repository.itk.ac.id Internet Source	<1 %
44	www.suara.com Internet Source	<1 %
45	www.validnews.id Internet Source	<1 %
46	Kasmirandi Kasmirandi, Chaeruddin Chaeruddin, Subhan Akbar Abbas, ZH Nurul Kusumawardhani, Erwin Erwin. "Analisis Penerapan AI dan Pengembangan SDM untuk	<1 %

Resiliensi Bisnis UMKM Sulawesi Selatan", Jurnal Minfo Polgan, 2025

Publication

47

Marssel M. Sengkey, Nova Lisye Sinaulan, Stefani Tendean, Herlina Sianly Ninda, Joel Mangantes, Yerikho Shefa Pratasik. "Dampak Penggunaan Media Sosial terhadap Kecemasan Mahasiswa di Universitas Negeri Manado", Jurnal Pengabdian Masyarakat dan Riset Pendidikan, 2025

Publication

<1 %

48

Meitolo Hulu, Fenisa Putri, Stephanie Natasya, Michelle -. "DAMPAK MEDIA SOSIAL DAN WORD OF MOUTH TERHADAP OVERTOURISM", Jurnal Pariwisata, 2021

Publication

<1 %

49

Ruvita Faurina, M Jumli Gazali, Icha Dwi Aprilia Herani. "Implementasi Deep Feed-Forward Neural Network pada Perancangan Chatbot Berbasis Web Di UPPIK RSUD M. YUNUS", Jurnal Linguistik Komputasional (JLK), 2023

Publication

<1 %

50

Yusuf Deardo Purba, Daniel Simamora, Kristianos Zamili, Finky Notavianus. "Penerapan Data Science Untuk Memprediksi Transaksi Tidak Valid Pada Sistem Voting Berbasis Blockchain", INTECOMS: Journal of

<1 %

Information Technology and Computer Science, 2025

Publication

51

digilib.unila.ac.id

Internet Source

<1 %

52

ejournal.iaisyarifuddin.ac.id

Internet Source

<1 %

53

iainbukittinggi.ac.id

Internet Source

<1 %

54

repository.wima.ac.id

Internet Source

<1 %

55

www.dicoding.com

Internet Source

<1 %

56

Ika Amelia, Sugiyono, Frencis Matheos Sarimole, Tundo. "Analisis Sentimen Tanggapan Pengguna Media Sosial X Terhadap Program Beasiswa KIP-Kuliah dengan Menggunakan Algoritma Support Vector Machine (SVM)", Jurnal Indonesia : Manajemen Informatika dan Komunikasi, 2024

Publication

<1 %

57

Muhammad Ariel, Tengku Marisa, Khairunnisa matondang, Eonike Sihite, Roza Thohiri. "Analisis Pengaruh Media Sosial Terhadap Hasil Belajar Mata Kuliah Pengantar

<1 %

Ekonomi Makro Pada Mahasiswa Jurusan
Akuntansi Fakultas Ekonomi Universitas
Negeri Medan", Jurnal Pengabdian
Masyarakat dan Riset Pendidikan, 2025

Publication

58

Rani indah sari manurung Rani. "ANALISIS
JARINGAN SOSIAL SEDERHANA
MENGUNAKAN ALGORITMA GRAF",
PROSISKO: Jurnal Pengembangan Riset dan
Observasi Sistem Komputer, 2025

Publication

<1 %

59

digilib.ikipgriptk.ac.id

Internet Source

<1 %

60

ejournal.itn.ac.id

Internet Source

<1 %

61

eprints.uny.ac.id

Internet Source

<1 %

62

geograf.id

Internet Source

<1 %

63

www.ilmudata.org

Internet Source

<1 %

64

Arif Muqtadir, Dini Silvi Purnia. "Pemanfaatan
Metode SMOTE dan PSO Untuk
Mengoptimalkan Tingkat Akurasi Klasifikasi
Kepuasan Pelanggan", IJCIT (Indonesian

<1 %

65

Putri Nabila Amir, Muhamad Fatchan, Edora Edora. "Prediksi Kelulusan Siswa Dengan Pendekatan Algoritma C5.0 Pada SMAN 2 Cikarang Selatan", Jurnal Ilmiah Intech : Information Technology Journal of UMUS, 2023

Publication

<1 %

66

Sutriawan, Zumhur Alamin, Nur Hunul Khatimah, Siti Mutmainnah, Muhammad Akbar. "Pelatihan Pemrograman Python Untuk Meningkatkan Soft Skill Mahasiswa Ilmu Komputer Um Bima Dalam Menghadapi Era Industri 4.0", Journal of Excellence Humanities and Religiosity, 2024

Publication

<1 %

67

academic-accelerator.com

Internet Source

<1 %

68

akurasi.unram.ac.id

Internet Source

<1 %

69

assets.cureus.com

Internet Source

<1 %

70

e-journals.unmul.ac.id

Internet Source

<1 %

71	etheses.uin-malang.ac.id Internet Source	<1 %
72	journals.umkt.ac.id Internet Source	<1 %
73	jurnal.uimedan.ac.id Internet Source	<1 %
74	lib.unnes.ac.id Internet Source	<1 %
75	paltv.disway.id Internet Source	<1 %
76	www.researchgate.net Internet Source	<1 %
77	Haryati Haryati, Siti Patma Yunaningsi, Junuda RAF. "Faktor yang Mempengaruhi Kualitas Tidur Mahasiswa Fakultas Kedokteran Universitas Halu Oleo", Jurnal Surya Medika, 2020 Publication	<1 %
78	Heningdyah Sekar Trifa, Okti Sri Purwanti. "Hubungan neuropati diabetik dengan kualitas tidur pada penderita diabetes mellitus di wilayah kerja Puskesmas Bendosari Sukoharjo", Holistik Jurnal Kesehatan, 2024 Publication	<1 %

79	Nasrah, Kismiyati Kismiyati, Zeth Roberth Felle, Frengky Apay, Theresia Febriana Christi Tyas Utami. "Hubungan antara tingkat stres dan kualitas tidur pada mahasiswa keperawatan tingkat akhir", JURNAL KEPERAWATAN TROPIS PAPUA, 2024 Publication	<1 %
80	Sindika Aprilia Saputri, Sulastri Sulastri. "Kelas Prenatal Yoga terhadap Kualitas Tidur Ibu Hamil", Journal of Telenursing (JOTING), 2023 Publication	<1 %
81	Vinola Adiesty Pratami, Yuliana Yuliana, Yosi Oktarina. "Hubungan Tingkat Kecemasan Dengan Kualitas Tidur Pada Pasien Gagal Ginjal Kronik yang Menjalani Hemodialisa di RSUD Raden Mattaher Kota Jambi", Jurnal Ners, 2023 Publication	<1 %
82	celebrithink.com Internet Source	<1 %
83	eprints.pktj.ac.id Internet Source	<1 %
84	ferdyanbagas.blogspot.com Internet Source	<1 %
85	id.123dok.com Internet Source	<1 %

86	link.springer.com Internet Source	<1 %
87	media.neliti.com Internet Source	<1 %
88	puskesmaspekkae.blogspot.com Internet Source	<1 %
89	repository.ub.ac.id Internet Source	<1 %
90	repository.unair.ac.id Internet Source	<1 %
91	repository.unpar.ac.id Internet Source	<1 %
92	repository.warmadewa.ac.id Internet Source	<1 %
93	repository.widyatama.ac.id Internet Source	<1 %
94	www.mdpi.com Internet Source	<1 %
95	www.nature.com Internet Source	<1 %
96	Heri Gunawan, Ike Anggraeni, Annisa Nurrachmawati. "Hubungan Intensitas Penggunaan Media Sosial Dengan Kesehatan Mental Mahasiswa Pada Masa Pandemi	<1 %

97

Latifah Novithasari Effendi, Metha Dwi Tamara. "KAJIAN NARATIF: HUBUNGAN DURASI MEDIA SOSIAL DENGAN KEJADIAN INSOMNIA PADA REMAJA", Jurnal Sehat Masada, 2022

Publication

<1 %

98

Aris Tjahyanto, Faisal Johan Atletiko. "Peningkatan Kinerja Pengklasifikasi Objek Bawah Laut dengan Deep Learning", MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer, 2022

Publication

<1 %

99

Rizki Wilheppi, Melinda Noer, Ira Wahyuni Syarfi. "Persepsi Petani Terhadap Teknologi Smart Farming Dalam Pertanian Padi Sawah di Kabupaten Pasaman Barat", Journal of Agribusiness and Community Empowerment (JACE), 2023

Publication

<1 %

100

anzdoc.com
Internet Source

<1 %

Exclude quotes Off

Exclude bibliography On

Exclude matches Off