

Model Klasifikasi Cerdas Gangguan Tidur Berbasis Machine Learning Random Forest pada Data Kesehatan dan Perilaku Harian

Laila Maulin Ni'mah*, Defri Kurniawan

Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Dian Nuswantoro, Semarang, Indonesia

Email: ^{1*}111202214424@mhs.dinus.ac.id, ²defri.kurniawan@dsn.dinus.ac.id

Email Penulis Korespondensi: 111202214424@mhs.dinus.ac.id

Submitted: 31/10/2025; Accepted: 09/12/2025; Published: 11/12/2025

Abstrak—Gangguan tidur, seperti insomnia dan sleep apnea telah menjadi isu kesehatan yang signifikan di era modern, didorong oleh tuntutan perubahan gaya hidup. Kondisi ini menyoroti kebutuhan mendesak akan alat deteksi dini yang tidak hanya akurat tetapi juga mudah diakses oleh masyarakat luas. Penelitian ini bertujuan untuk merancang dan mengimplementasikan sebuah sistem klasifikasi cerdas guna mengidentifikasi risiko gangguan tidur secara otomatis berdasarkan data kesehatan dan perilaku harian. Untuk mencapai tujuan tersebut, penelitian ini menerapkan metode machine learning dengan algoritma Random Forest, yang dipilih karena kemampuannya yang andal dalam menangani hubungan data yang kompleks dan non-linear. Data yang digunakan adalah "Sleep Health and Lifestyle Dataset" yang bersumber dari platform Kaggle, mencakup 374 data responden dengan 13 fitur relevan. Proses penelitian meliputi tahapan pra-pemrosesan data untuk memastikan kualitas input, pelatihan model, dan evaluasi performa yang ketat. Hasil evaluasi pada data uji menunjukkan bahwa model Random Forest yang dibangun menunjukkan performa yang sangat solid, berhasil mencapai tingkat akurasi sebesar 91% serta weighted average F1-Score sebesar 0.90. Metrik F1-Score ini, yang menyeimbangkan precision dan recall, mengonfirmasi bahwa model tidak hanya akurat tetapi juga memiliki performa yang seimbang dalam mendeteksi setiap kelas, yang krusial untuk klasifikasi kesehatan. Lebih lanjut, analisis tingkat kepentingan fitur (*feature importance*) mengonfirmasi bahwa Tingkat Stres, Kategori Indeks Massa Tubuh (IMT), dan Detak Jantung merupakan tiga faktor prediktor paling dominan. Puncak dari penelitian ini adalah keberhasilan implementasi model prediktif ini ke dalam sebuah aplikasi web interaktif yang dikembangkan menggunakan framework Streamlit. Aplikasi ini memungkinkan pengguna untuk memasukkan data kesehatan mereka secara mandiri dan menerima umpan balik berupa prediksi risiko secara real-time. Dengan antarmuka yang intuitif dan hasil yang mudah dipahami, aplikasi ini berfungsi sebagai alat skrining awal yang praktis dan informatif untuk analisis kesehatan tidur personal.

Kata Kunci: Random Forest; Insomnia; Klasifikasi; Streamlit; Feature Importance; Aplikasi Web

Abstract—Sleep disorders, such as insomnia and sleep apnea, have become a significant health issue in the modern era, driven by the demands of lifestyle changes. This condition highlights the urgent need for early detection tools that are not only accurate but also easily accessible to the general public. This research aims to design and implement an intelligent classification system to automatically identify the risk of sleep disorders based on health and daily behavior data. To achieve this goal, this study applies a machine learning method using the Random Forest algorithm, which was chosen for its reliable ability to handle complex and non-linear data relationships. The data used is the "Sleep Health and Lifestyle Dataset" sourced from the Kaggle platform, covering 374 respondents with 13 relevant features. The research process included data pre-processing steps to ensure input quality, model training, and rigorous performance evaluation. The evaluation results on the test data show that the developed Random Forest model exhibited very solid performance, successfully achieving an accuracy rate of 91% and a weighted average F1-Score of 0.90. This F1-Score metric, which balances precision and recall, confirms that the model is not only accurate but also has a balanced performance in detecting each class, which is crucial for health classification. Furthermore, the feature importance analysis confirmed that Stress Level, BMI Category, and Heart Rate are the three most dominant predictor factors. The culmination of this research is the successful implementation of this predictive model into an interactive web application developed using the Streamlit framework. This application allows users to independently input their health data and receive feedback in the form of a real-time risk prediction. With an intuitive interface and easy-to-understand results, this application serves as a practical and informative initial screening tool for personal sleep health analysis.

Keywords: Random Forest; Insomnia; Classification; Streamlit; Feature Importance; Web Application

1. PENDAHULUAN

Tidur merupakan salah satu pilar fundamental yang menopang kesehatan dan kesejahteraan manusia, sebuah proses biologis kompleks yang esensial bagi pemulihan dan fungsi optimal tubuh. Jauh dari sekadar kondisi pasif, tidur adalah periode restoratif yang sangat aktif di mana otak dan tubuh melakukan serangkaian tugas vital yang tidak dapat dilakukan secara efisien saat terjaga. Proses ini mencakup konsolidasi memori, di mana informasi yang dipelajari diubah menjadi ingatan jangka panjang, serta regulasi emosi, yang membantu menjaga stabilitas suasana hati dan respons terhadap stres. Secara fisiologis, tidur memfasilitasi perbaikan jaringan seluler, penguatan sistem kekebalan tubuh untuk melawan infeksi, dan yang terpenting, pembersihan produk sampingan metabolik toksik dari otak, seperti beta-amyloid, yang akumulasinya dikaitkan dengan penyakit neurodegeneratif. Seluruh mekanisme ini bersifat krusial untuk menjaga kesehatan fisik maupun mental jangka panjang, serta menunjang performa kognitif, kewaspadaan, dan produktivitas harian [1]. Mengingat peran vitalnya, kualitas dan kuantitas tidur yang buruk dapat berdampak signifikan dan merusak. Kekurangan tidur kronis dapat memicu konsekuensi serius, salah satunya adalah insomnia. Secara klinis, insomnia didefinisikan bukan hanya sebagai kesulitan untuk tidur, melainkan sebagai sindrom komprehensif yang mencakup kesulitan persisten dalam memulai tidur (sleep-onset insomnia), mempertahankan tidur

(sleep-maintenance insomnia), atau bangun terlalu dini tanpa bisa tidur kembali. Kondisi ini secara langsung menyebabkan gangguan fungsi pada siang hari, seperti kelelahan, kesulitan berkonsentrasi, dan iritabilitas [2].

Seiring berkembangnya teknologi dan era data besar, bidang kesehatan kini mengalami transformasi fundamental menuju pendekatan berbasis data (data-driven), dengan machine learning sebagai salah satu motor utamanya. Berbagai penelitian telah menerapkan algoritma komputasional untuk klasifikasi gangguan tidur secara akurat dan efisien. Di antara berbagai metode yang ada, algoritma Random Forest, khususnya, telah menunjukkan kinerja yang sangat baik dan konsisten dalam domain ini. Keunggulannya terbukti relevan dalam berbagai studi. Salah satunya adalah penelitian oleh Fitriyani, dkk., yang berhasil menerapkan Random Forest untuk mengklasifikasikan gangguan tidur berdasarkan pola kehidupan sehari-hari menggunakan dataset dengan rumpun fitur yang serupa [3]. Temuan ini diperkuat oleh penelitian Hidayat, yang juga mengeksplorasi metode tersebut untuk mencapai akurasi klasifikasi yang tinggi, menunjukkan bahwa Random Forest mampu mengidentifikasi pola kompleks yang menghubungkan perilaku harian dengan kesehatan tidur [4].

Dalam evaluasi model prediktif lainnya, selain dalam dunia medis. Random Forest Classifier (RFC) telah dilaporkan menunjukkan performa yang unggul dibandingkan Support Vector Classifier (SVC) dan K-Nearest Neighbors Classifier (KNN)[5]. Selain itu, Random Forest memiliki keunggulan tambahan berupa penyediaan pentingnya fitur (feature importance), yang menawarkan wawasan mengenai prediktor mana yang paling signifikan memengaruhi hasil yang diprediksi. Dengan demikian, Random Forest menyajikan alat yang ampuh untuk memprediksi keparahan insomnia dalam konteks konstitusi Traditional Chinese Medicine (TCM)[6]. Pendekatan kolektif ini secara signifikan meningkatkan akurasi dan stabilitas model. Metode ini sangat sesuai untuk data kesehatan yang seringkali bersifat kompleks dan multidimensional karena kemampuannya menangani interaksi non-linear antar fitur secara efektif serta mengurangi risiko overfitting, yang merupakan tantangan umum pada model tunggal [7]. Pemahaman terhadap faktor risiko seperti gaya hidup—mencakup aktivitas fisik, tingkat stres, dan pola makan, menjadi dasar dari setiap model prediksi yang baik, terutama di kalangan populasi rentan seperti mahasiswa [8]. Dengan kemampuannya yang robust dalam mengelola berbagai tipe data (numerik dan kategorikal) tanpa memerlukan pra-pemrosesan yang rumit seperti penskalaan fitur, Random Forest menjadi pilihan yang ideal untuk menganalisis variabel-variabel perilaku dan kesehatan ini. Algoritma ini telah terbukti efektif dalam berbagai klasifikasi masalah kesehatan lainnya, yang menegaskan posisinya sebagai alat analisis yang andal dan serbaguna [9].

Meskipun banyak model prediktif yang berhasil dikembangkan di lingkungan akademis, salah satu tantangan terbesar yang masih ada adalah bagaimana menerjemahkan model-model tersebut menjadi alat yang dapat diakses, dipahami, dan bermanfaat bagi masyarakat luas. Sebuah model dengan akurasi tinggi memiliki nilai praktis yang terbatas jika hanya tersimpan dalam laporan penelitian. Menyadari hal ini, beberapa peneliti telah mulai menjembatani kesenjangan antara penelitian dan aplikasi praktis. Telah ada upaya, misalnya, untuk mengimplementasikan model prediksi penyakit jantung ke dalam sebuah sistem web interaktif menggunakan framework Streamlit. Proyek-proyek semacam ini membuktikan kelayakan teknis dan manfaat dari penerjemahan machine learning yang kompleks menjadi alat praktis yang dapat digunakan langsung oleh pengguna akhir tanpa memerlukan latar belakang teknis [10].


Dari tinjauan literatur di atas, terlihat bahwa meskipun penelitian sebelumnya telah membuktikan efektivitas Random Forest, penelitian ini mengambil pendekatan yang berbeda secara metodologis dan praktis. Pertama, penelitian ini berfokus pada justifikasi metodologis yang berbeda terkait penanganan data. Alih-alih mengubah data secara artifisial (misalnya dengan teknik oversampling seperti SMOTE), penelitian ini mengambil keputusan strategis untuk tetap menggunakan dataset dengan proporsi aslinya. Keputusan ini didasarkan pada tujuan untuk menguji kemampuan model pada skenario data yang realistis (dunia nyata), di mana kasus insomnia (kelas minoritas) secara alami memang lebih jarang ditemukan. Pendekatan ini sekaligus menjadi ajang pembuktian keandalan dan kapabilitas bawaan dari algoritma Random Forest itu sendiri dalam menangani data yang tidak dimanipulasi.

Kedua, dan yang menjadi kontribusi utama, fokus penelitian yang ada cenderung terpisah; ada yang berfokus pada evaluasi model, ada yang berfokus pada implementasi. Masih jarang ditemukan penelitian yang mengintegrasikan kedua proses ini secara utuh: mulai dari membangun model yang diuji pada data realistis, menganalisis feature importance-nya, hingga melanjutkan proses tersebut ke tahap akhir, yaitu implementasi model ke dalam sebuah aplikasi web yang fungsional, interaktif, dan mudah diakses oleh publik. Penelitian ini dirancang secara spesifik untuk mengisi kesenjangan tersebut. Tujuannya tidak hanya untuk membangun model klasifikasi gangguan tidur berbasis Random Forest yang akurat, tetapi juga untuk mengimplementasikan model final tersebut ke dalam sebuah aplikasi interaktif menggunakan Streamlit. Dengan demikian, penelitian ini diharapkan dapat menghasilkan solusi yang tidak hanya valid secara teknis dan akurat secara prediktif, tetapi juga praktis, bermanfaat, dan dapat memberikan wawasan langsung kepada pengguna mengenai faktor-faktor yang memengaruhi kesehatan tidur mereka.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini dilaksanakan melalui serangkaian tahapan yang terstruktur dan sekuensial untuk mencapai tujuan yang telah ditetapkan. Alur penelitian secara garis besar menggambarkan proses mulai dari identifikasi masalah hingga penarikan kesimpulan, seperti yang divisualisasikan pada Gambar 1.



Gambar 1. Tahap Penelitian

Gambar 1 menunjukkan proses penelitian yang dimulai dari identifikasi masalah dan studi literatur untuk membangun landasan teoretis yang kuat. Tinjauan ini mencakup pemahaman mendalam tentang insomnia dan faktor risikonya, terutama pada populasi mahasiswa [11], [12], serta meninjau pendekatan teknis dan intervensi yang ada [13], [14], [15]. Proses selanjutnya adalah pengumpulan dataset yang relevan, kemudian dilakukan tahap eksplorasi data (*exploratory data analysis*) dan pra-pemrosesan untuk memastikan data dalam kondisi bersih dan siap digunakan. Setelah itu, dilakukan pelatihan model menggunakan algoritma *Random Forest* untuk menganalisis pola dan melakukan prediksi terkait gangguan tidur. Model tersebut kemudian dievaluasi untuk memastikan kinerjanya sesuai dengan kriteria yang diharapkan. Setelah model terbaik diperoleh, langkah terakhir adalah mengimplementasikannya ke dalam aplikasi berbasis *Streamlit* sebagai sarana visualisasi hasil dan interaksi pengguna. Proses penelitian diakhiri ketika sistem dapat berjalan secara efektif dan kesimpulan penelitian dapat ditarik dengan baik.

2.2 Persiapan Dataset

Bahan utama yang digunakan dalam penelitian ini adalah sebuah dataset publik yang bersumber dari platform repositori data Kaggle berjudul *'Sleep, Health, and Lifestyle'* oleh Henry Shan. Dataset ini dipilih karena memuat informasi faktor kardiovaskular dan gaya hidup yang relevan untuk prediksi insomnia, di mana faktor-faktor seperti stres, kecemasan, dan gaya hidup telah terbukti dalam berbagai studi berhubungan dengan kejadian insomnia, terutama pada populasi mahasiswa. Dataset ini terdiri dari 374 baris data dan 13 kolom yang mendeskripsikan berbagai atribut terkait demografi, gaya hidup, dan indikator kesehatan. Deskripsi rinci mengenai setiap atribut yang digunakan dalam pemodelan disajikan pada Tabel 1.

Tabel 1. Deskripsi Atribut Dataset

Nama Atribut	Type Data	Keterangan
Gender	Kategorikal	Jenis kelamin responden (Pria/Wanita).
Age	Numerik	Usia responden dalam tahun.
Occupation	Kategorikal	Jenis pekerjaan responden.
Sleep Duration	Numerik	Durasi tidur rata-rata per hari (jam).
Quality of Sleep	Numerik	Kualitas tidur (skala 1-10).
Physical Activity Level	Numerik	Tingkat aktivitas fisik (menit/hari).
Stress Level	Numerik	Tingkat stres yang dirasakan (skala 1-10).
BMI Category	Kategorikal	Kategori Indeks Massa Tubuh (Normal/Overweight/Obese).
Blood Pressure	String	Tekanan darah (Sistolik/Diastolik).
Heart Rate	Numerik	Denyut jantung istirahat (denyut/menit).
Daily Steps	Numerik	Jumlah langkah rata-rata per hari.
Sleep Disorder	Kategorikal	Jenis gangguan tidur (None/Insomnia/Sleep Apnea).

Berdasarkan Tabel 1, sebagai langkah krusial dalam persiapan, dataset yang telah dimuat dipisahkan menjadi dua bagian utama: data latih (*training set*) dan data uji (*testing set*). Pembagian ini dilakukan menggunakan fungsi `train_test_split` dari library *Scikit-learn* dengan proporsi 80% untuk data latih dan 20% untuk data uji. Penerapan data uji yang sepenuhnya terpisah dari proses pelatihan dan validasi model memastikan bahwa evaluasi akhir terhadap model dilakukan pada data yang belum pernah "dilihat" sebelumnya, sehingga memberikan estimasi performa yang lebih objektif dan tidak bias mengenai kemampuan generalisasi model pada data baru.

2.3 Exploratory Data Analysis (EDA)

Sebelum tahap pra-pemrosesan data, langkah fundamental yang dilakukan adalah *Exploratory Data Analysis (EDA)*. Tahap ini bertujuan untuk melakukan investigasi awal terhadap dataset guna memahami karakteristik, menemukan pola, mengidentifikasi anomali atau *outlier*, serta menguji asumsi awal melalui statistik deskriptif dan visualisasi data. Proses EDA memberikan wawasan krusial yang menginformasikan dan memvalidasi langkah-langkah transformasi data selanjutnya. Berdasarkan analisis yang telah dilakukan, beberapa analisis kunci yang dijalankan meliputi:

- a. Analisis Statistik Deskriptif: Menggunakan fungsi `.describe()` dari library *Pandas* untuk menghasilkan ringkasan statistik (seperti rata-rata, median, standar deviasi, kuartil) dari fitur-fitur numerik. Analisis ini memberikan gambaran umum mengenai sebaran dan tendensi sentral dari setiap variabel, seperti usia rata-rata responden atau durasi tidur pada umumnya.

- b. Visualisasi Distribusi Fitur:
 1. Fitur Numerik: *Histogram* dibuat untuk setiap fitur numerik (Age, Sleep Duration, Heart Rate, dll.) untuk memahami bentuk distribusinya, apakah normal, miring (skewed), atau bimodal.
 2. Fitur Kategorikal: *Count plot* digunakan untuk melihat frekuensi setiap kategori dalam fitur seperti Gender, Occupation, dan BMI Category. Analisis ini penting untuk mengetahui komposisi demografis dari dataset.
 3. Variabel Target: Distribusi variabel target *Sleep Disorder* divisualisasikan untuk memeriksa apakah terdapat ketidakseimbangan kelas (class imbalance) antara kategori 'None', 'Insomnia', dan 'Sleep Apnea'.
- c. Analisis Korelasi: Sebuah matriks korelasi dihitung untuk semua fitur numerik. Hasilnya kemudian divisualisasikan menggunakan heatmap dari library *Seaborn*. Heatmap ini secara visual menyoroti kekuatan dan arah hubungan linear antar variabel. Korelasi yang tinggi antar fitur prediktor dapat mengindikasikan adanya multikolinearitas, yang dapat memengaruhi interpretasi beberapa jenis model.

2.4 Pra-pemrosesan Data

Setelah melakukan analisis data eksplorasi, tahap selanjutnya adalah pra-pemrosesan data. Tahap ini memegang peranan krusial karena bertujuan untuk membersihkan, mentransformasi, dan menyiapkan data mentah menjadi format yang berkualitas tinggi dan sesuai untuk diolah oleh algoritma machine learning. Kualitas data input sangat menentukan performa dan keandalan model yang akan dihasilkan. Implementasi metode ini dalam penelitian dilakukan melalui beberapa langkah kunci yang berurutan sebagai berikut:

- a. Transformasi Variabel Target: Langkah pertama adalah menyesuaikan variabel target agar sesuai dengan tujuan utama penelitian, yaitu klasifikasi biner spesifik untuk prediksi insomnia. Kolom Sleep Disorder pada dataset asli memiliki tiga kategori: 'None', 'Insomnia', dan 'Sleep Apnea'. Untuk memfokuskan model secara eksklusif pada perbedaan antara 'Insomnia' dan 'None' (*tidak ada gangguan*), data yang memiliki kategori 'Sleep Apnea' dieksklusi (*dihilangkan*) dari analisis. Selanjutnya, data yang tersisa ditransformasi menjadi variabel biner, di mana nilai 'Insomnia' diberi label 1 dan nilai 'None' diberi label 0.
- b. Ekstraksi Fitur (Feature Extraction): Kolom *Blood Pressure* pada dataset asli berformat string (contoh: "140/95"), sehingga tidak dapat langsung diproses oleh model. Oleh karena itu, dilakukan ekstraksi fitur untuk memisahkan nilai tersebut menjadi dua fitur numerik yang independen, yaitu *Systolic* (tekanan darah atas) dan *Diastolic* (tekanan darah bawah). Langkah ini memastikan informasi tekanan darah dapat dimanfaatkan secara efektif oleh model.
- c. Encoding Fitur Kategorikal: Algoritma *machine learning* umumnya bekerja dengan data numerik. Untuk itu, semua fitur yang bersifat kategorikal, seperti *Gender*, *Occupation*, dan *BMI Category*, perlu diubah ke dalam format numerik. Dalam penelitian ini, digunakan teknik *one-hot encoding*. Teknik ini membuat kolom biner baru untuk setiap kategori unik dalam sebuah fitur, di mana nilai 1 menandakan keberadaan kategori tersebut dan 0 sebaliknya. Pendekatan ini menghindari asumsi urutan atau bobot antar kategori yang tidak semestinya.
- d. Standardisasi Data (Feature Scaling): Tahap ini bertujuan untuk menstandarkan seluruh fitur numerik agar memiliki skala yang seragam. Proses standardisasi dilakukan menggunakan kelas *StandardScaler* dari library *Scikit-learn*, yang bekerja dengan cara mengurangi setiap nilai data terhadap rata-rata (mean) dan membaginya dengan standar deviasi. Dengan demikian, setiap fitur akan memiliki distribusi dengan rata-rata nol dan standar deviasi satu. Meskipun algoritma *Random Forest* secara umum tidak terlalu sensitif terhadap perbedaan skala antar fitur, penerapan standardisasi tetap dilakukan guna menjaga konsistensi data dan meningkatkan stabilitas proses pelatihan model. Langkah ini juga membantu memastikan bahwa seluruh variabel memiliki kontribusi yang seimbang dalam proses pembentukan model prediksi [16]

2.5 Random Forest

Random Forest adalah salah satu algoritma *supervised learning* yang termasuk dalam kategori *ensemble learning*. Metode ini bekerja dengan membangun sejumlah besar pohon keputusan (*decision tree*) secara independen selama proses pelatihan. Keunggulan utama dari algoritma ini adalah kemampuannya untuk meningkatkan akurasi prediksi dan mengontrol *overfitting*, yang sering menjadi masalah pada satu pohon keputusan tunggal. Algoritma ini telah terbukti efektif dalam berbagai aplikasi klasifikasi, termasuk dalam domain kesehatan untuk menganalisis kesehatan mental mahasiswa [17] dan untuk mendeteksi serta mengukur tingkat stres pada mahasiswa tingkat akhir [18]. Prinsip kerja Random Forest adalah sebagai berikut:

- a. Bootstrap Aggregating (Bagging): Dari dataset pelatihan, algoritma ini mengambil beberapa sampel acak dengan penggantian (*bootstrap samples*). Artinya, beberapa data mungkin muncul lebih dari sekali dalam satu sampel, sementara data lain mungkin tidak terpilih sama sekali.
- b. Pembangunan Pohon: Untuk setiap *bootstrap sample*, sebuah pohon keputusan dibangun. Namun, pada setiap *node* (titik keputusan) di dalam pohon, algoritma hanya mempertimbangkan sebagian kecil fitur yang dipilih secara acak untuk menentukan pemisahan (*split*) terbaik, bukan semua fitur.
- c. Voting: Setelah semua pohon dibangun, proses prediksi untuk data baru dilakukan dengan melewati data tersebut ke setiap pohon. Setiap pohon akan memberikan "suara" atau prediksi kelasnya masing-masing. Hasil prediksi akhir dari model Random Forest ditentukan oleh suara mayoritas (*majority voting*) dari seluruh pohon. Proses prediksi ini dapat direpresentasikan secara matematis sebagai berikut:

$$\hat{y} = mode \{h_1(x), h_2(x), \dots, h_k(x)\} \tag{1}$$

Pada rumus (1), \hat{y} merupakan hasil prediksi akhir dari keseluruhan model Random Forest. Hasil ini diperoleh dengan mengambil mode atau kelas yang paling sering muncul dari himpunan prediksi yang dihasilkan oleh setiap pohon keputusan individu. Simbol $h_k(x)$ merepresentasikan fungsi prediksi dari pohon keputusan ke- k (dari total k pohon) untuk input data x . Dengan kata lain, algoritma ini mengumpulkan "suara" dari setiap pohon dan memilih suara mayoritas sebagai keputusan akhirnya, sehingga mengurangi varians dan meningkatkan keandalan prediksi.

2.6 Evaluasi Model

valuasi model merupakan tahap krusial untuk mengukur kinerja dan efektivitas model klasifikasi secara kuantitatif. Proses ini dilakukan dengan membandingkan hasil prediksi model dengan nilai aktual pada data uji yang belum pernah dilihat sebelumnya. Landasan utama dari semua metrik evaluasi dalam penelitian ini adalah *Confusion Matrix*. *Confusion matrix* adalah sebuah tabel yang memvisualisasikan performa algoritma klasifikasi dengan menyajikan rincian jumlah prediksi yang benar dan salah untuk setiap kelas. Matriks ini memungkinkan analisis yang lebih mendalam terhadap tipe-tipe kesalahan yang dibuat oleh model (seperti *True Positive*, *True Negative*, *False Positive*, dan *False Negative*), sehingga memudahkan penghitungan metrik seperti akurasi, presisi, recall, dan F1-score [19]. Selain itu, penerapan *confusion matrix* umumnya dikombinasikan dengan teknik validasi silang (*k-fold cross-validation*) untuk memastikan hasil evaluasi yang lebih robust dan tidak bergantung pada pembagian data tunggal. Pendekatan ini membantu meningkatkan reliabilitas performa model dalam memprediksi data baru [20]. Untuk masalah klasifikasi biner, matriks ini terdiri dari empat kategori utama yang dijelaskan pada Tabel 2.

Tabel 2. Kategori dalam Confusion Matrix

Kategori	Deskripsi
<i>True Positive</i> (TP)	Jumlah data yang sebenarnya positif (berisiko insomnia) dan diprediksi dengan benar sebagai positif.
<i>False Positive</i> (FP)	Jumlah data yang sebenarnya negatif (tidak berisiko) namun salah diprediksi sebagai positif. (Kesalahan Tipe I)
<i>True Negative</i> (TN)	Jumlah data yang sebenarnya negatif (tidak berisiko) dan diprediksi dengan benar sebagai negatif.
<i>False Negative</i> (FN)	Jumlah data yang sebenarnya positif (berisiko insomnia) namun salah diprediksi sebagai negatif. (Kesalahan Tipe II)

Berdasarkan keempat kategori fundamental ini, beberapa metrik performa turunan dihitung untuk memberikan analisis yang komprehensif terhadap kinerja model.

a. Akurasi (Accuracy)

$$Accuracy = \frac{TP+TN}{TP+FP+FN+TN} \tag{5}$$

Akurasi adalah metrik yang mengukur proporsi total prediksi yang benar untuk memberikan gambaran umum tentang kinerja model. Namun, metrik ini bisa menyesatkan jika jumlah data antar kelas tidak seimbang (*imbalanced dataset*).

b. Presisi (Precision)

$$Precision = \frac{TP}{TP+FP} \tag{6}$$

Presisi mengukur ketepatan prediksi positif yang dibuat model. Metrik ini menjawab pertanyaan, "Dari semua yang diprediksi berisiko insomnia, berapa persen yang benar?" Presisi yang tinggi menunjukkan rendahnya tingkat alarm palsu (*False Positive*), yang penting dalam konteks medis untuk menghindari diagnosis yang salah.

c. Recall (Sensitivitas)

$$Recall = \frac{TP}{TP+FN} \tag{7}$$

Recall (sensitivitas) mengukur kemampuan model untuk mengidentifikasi semua kasus positif yang sebenarnya. Metrik ini menjawab pertanyaan, "Dari semua yang benar-benar berisiko insomnia, berapa persen yang berhasil terdeteksi?" *Recall* yang tinggi sangat penting dalam diagnosis medis untuk meminimalkan jumlah kasus yang terlewat (*False Negative*) dan memastikan individu yang berisiko dapat diidentifikasi.

d. F1-Score

$$F1-Score = \frac{2 \cdot Precision \cdot Recall}{Precision+Recall} \tag{8}$$

F1-Score adalah rata-rata harmonik dari presisi dan *recall* yang memberikan nilai tunggal untuk menyeimbangkan keduanya. Metrik ini sangat berguna untuk dataset dengan kelas tidak seimbang, di mana nilai yang tinggi menandakan keseimbangan yang baik antara meminimalkan alarm palsu dan kasus yang terlewat. Selain itu, kurva

ROC-AUC dianalisis untuk mengevaluasi kemampuan diskriminatif model secara keseluruhan di berbagai ambang batas klasifikasi.

2.7 Implementasi Streamlit

Tahap akhir dari penelitian ini adalah implementasi dan *deployment*, di mana model dengan performa terbaik diintegrasikan ke dalam sebuah aplikasi web interaktif. Untuk tujuan ini, digunakan *framework* Streamlit, sebuah *library open-source* pada *Python* yang memungkinkan pembuatan aplikasi web untuk ilmu data dengan cepat dan efisien [21]. Model yang telah dilatih dan dioptimalkan disimpan dalam sebuah file untuk kemudian dimuat ke dalam skrip aplikasi, yang dirancang dengan antarmuka pengguna (UI) interaktif. Pengguna dapat memasukkan data mereka melalui berbagai komponen seperti *slider* dan *dropdown*, yang kemudian akan diproses oleh aplikasi—mengikuti langkah pra-pemrosesan yang sama seperti pada data pelatihan—untuk memberikan hasil prediksi risiko insomnia secara *real-time*. Setelah aplikasi berhasil dikembangkan dan berjalan dengan baik secara lokal, langkah selanjutnya adalah *deploy*-nya agar dapat diakses secara publik. Proses ini dimulai dengan mengunggah seluruh kode sumber proyek ke *GitHub*, sebuah platform untuk kontrol versi dan kolaborasi. Proyek ini mencakup file skrip utama *Python*, file *requirements.txt* yang berisi daftar semua *library* yang dibutuhkan, serta file model yang telah dilatih. Selanjutnya, repositori *GitHub* ini dihubungkan ke platform *hosting* seperti *Streamlit Community Cloud*. Platform ini secara otomatis membaca file-file dari repositori, menginstal semua dependensi yang tercantum dalam *requirements.txt*, dan menjalankan skrip aplikasi di server *cloud*. Hasilnya adalah sebuah aplikasi web yang ter-*hosting*, dapat diakses oleh siapa saja melalui sebuah URL publik. Proses implementasi ini berhasil mentransformasi model prediktif yang kompleks menjadi sebuah alat praktis yang mudah digunakan oleh pengguna akhir tanpa memerlukan pengetahuan teknis mendalam [22].

3. HASIL DAN PEMBAHASAN

3.1 Exploratory Data Analyst

Langkah ini melibatkan analisis awal untuk mengenali berbagai aspek fundamental data, seperti pola distribusi, adanya data kosong, dan perbandingan jumlah anggota setiap kelas, guna menginformasikan tahapan pra-pemrosesan berikutnya.

a. Menampilkan Informasi Umum Dataset

Proses eksplorasi data diawali dengan investigasi fundamental untuk memahami struktur dan komposisi dataset. Analisis ini meliputi verifikasi jumlah sampel dan fitur, identifikasi tipe data setiap atribut, serta penentuan variabel target yang menjadi fokus penelitian, sebagaimana dirangkum pada Gambar 2.

```

Informasi Dataset:
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 374 entries, 0 to 373
Data columns (total 13 columns):
 #   Column                               Non-Null Count  Dtype
---  -
 0   Gender                               374 non-null   int64
 1   Age                                   374 non-null   int64
 2   Occupation                           374 non-null   int64
 3   Sleep Duration                       374 non-null   float64
 4   Quality of Sleep                     374 non-null   int64
 5   Physical Activity Level              374 non-null   int64
 6   Stress Level                         374 non-null   int64
 7   BMI Category                         374 non-null   int64
 8   Heart Rate                           374 non-null   int64
 9   Daily Steps                          374 non-null   int64
10  Sleep Disorder                       374 non-null   int64
11  Systolic                             374 non-null   int64
12  Diastolic                             374 non-null   int64
dtypes: float64(1), int64(12)
memory usage: 38.1 KB

```

Gambar 2. Rangkuman Informasi Dataset

Pada Gambar 2, menunjukkan bahwa dataset terdiri dari 374 baris dan 13 kolom dengan kombinasi tipe data integer, float, dan object. Informasi ini juga mengonfirmasi bahwa tidak ada nilai yang hilang (null) pada sebagian besar fitur, kecuali pada kolom target *Sleep Disorder* yang hanya memiliki 155 data terisi, sebuah temuan penting untuk tahap pra-pemrosesan selanjutnya.

b. Statistik deskriptif

Analisis dilanjutkan dengan pemeriksaan statistik deskriptif untuk mendapatkan ringkasan kuantitatif dari fitur-fitur numerik dalam dataset. Proses ini sangat penting untuk memahami tendensi sentral (seperti rata-rata dan median), dispersi (standar deviasi), serta jangkauan nilai (minimum dan maksimum) dari setiap atribut, seperti yang disajikan pada Gambar 3.



```

... Statistik Deskriptif:
      Person ID      Age  Sleep Duration  Quality of Sleep \
count 374.000000 374.000000 374.000000 374.000000
mean 187.500000 42.184492 7.132086 7.312834
std 108.108742 8.673133 0.795657 1.196956
min 1.000000 27.000000 5.800000 4.000000
25% 94.250000 35.250000 6.400000 6.000000
50% 187.500000 43.000000 7.200000 7.000000
75% 280.750000 50.000000 7.800000 8.000000
max 374.000000 59.000000 8.500000 9.000000

      Physical Activity Level  Stress Level  Heart Rate  Daily Steps
count 374.000000 374.000000 374.000000 374.000000
mean 59.171123 5.385027 70.165775 6816.844920
std 20.830804 1.774526 4.135676 1617.915679
min 30.000000 3.000000 65.000000 3000.000000
25% 45.000000 4.000000 68.000000 5600.000000
50% 60.000000 5.000000 70.000000 7000.000000
75% 75.000000 7.000000 72.000000 8000.000000
max 90.000000 8.000000 86.000000 10000.000000
    
```

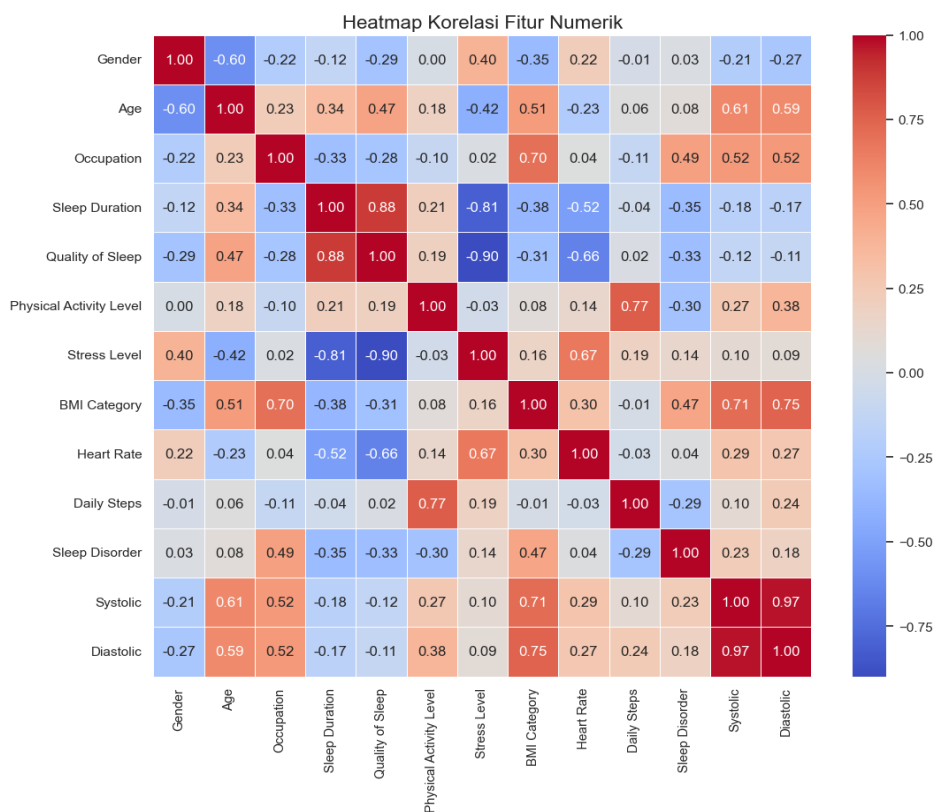
Gambar 3. Statistik Deskriptif Fitur Numerik

Dari Gambar 3, dapat diperoleh wawasan kunci seperti usia rata-rata responden adalah sekitar 42 tahun, dengan durasi tidur rata-rata 7.1 jam, dan tingkat stres rata-rata 5.4. Statistik ini juga mengonfirmasi bahwa tidak ada nilai yang hilang pada kolom-kolom numerik ini, karena jumlah data (*count*) konsisten sebanyak 374.

c. Korelasi Antar Fitur

Salah satu langkah krusial dalam tahap eksplorasi data adalah memahami hubungan dan interdependensi antar variabel numerik. Untuk tujuan ini, dilakukan analisis korelasi yang bertujuan untuk mengukur kekuatan dan arah hubungan linear antara setiap pasang fitur. Matriks korelasi yang dihasilkan kemudian divisualisasikan menggunakan sebuah heatmap, sebagaimana disajikan pada Gambar 4. Heatmap merupakan alat visualisasi yang sangat efektif karena mampu menyajikan data kompleks dalam format grafis yang intuitif dan mudah diinterpretasikan.

Visualisasi ini menggunakan spektrum warna untuk merepresentasikan kekuatan dan arah korelasi, di mana setiap sel pada matriks menunjukkan koefisien korelasi antara dua variabel. Dalam konteks ini, warna merah pekat (hangat) mengindikasikan korelasi positif yang kuat, yang berarti ketika nilai satu variabel meningkat, nilai variabel lainnya juga cenderung meningkat secara proporsional. Sebaliknya, warna biru pekat (dingin) melambangkan korelasi negatif yang kuat, yang artinya ketika nilai satu variabel meningkat, nilai variabel lainnya cenderung menurun. Intensitas warna secara langsung berkorelasi dengan kekuatan hubungan: semakin pekat warnanya, semakin kuat korelasinya, sedangkan warna yang lebih pucat atau mendekati netral menandakan hubungan yang lemah atau tidak ada sama sekali.



Gambar 4. Korelasi Antar Fitur Numerik

Berdasarkan analisis pada Gambar 4, heatmap korelasi menunjukkan beberapa hubungan signifikan antar variabel. *Quality of Sleep* memiliki korelasi positif yang sangat kuat dengan *Sleep Duration* ($r = 0.88$), mengindikasikan bahwa durasi tidur yang lebih panjang berasosiasi dengan kualitas tidur yang lebih baik. Sebaliknya, *Stress Level* menunjukkan korelasi negatif yang sangat kuat dengan *Quality of Sleep* ($r = -0.90$) dan *Sleep Duration* ($r = -0.81$). Temuan ini memberikan bukti kuantitatif bahwa peningkatan stres berdampak buruk terhadap kesehatan tidur. Selain itu, *Physical Activity Level* berkorelasi positif lemah dengan *Quality of Sleep* ($r = 0.19$) dan *Sleep Duration* ($r = 0.21$). Hasil analisis ini menjadi landasan fundamental dalam tahap pemodelan menggunakan algoritma Random Forest.

3.2 Pre-processing

a. Transformasi Variabel Target

Tahap analisis distribusi variabel target dilakukan setelah proses transformasi label untuk mengidentifikasi proporsi data pada masing-masing kelas. Langkah ini krusial untuk memahami komposisi dataset sebelum melangkah ke tahap pelatihan model.

```
Distribusi Target Setelah Perubahan (1: Insomnia, 0: Bukan Insomnia):
Sleep Disorder
0      297
1       77
Name: count, dtype: int64
```

Gambar 5. Distribusi Target Setelah Perubahan (Sleep Disorder)

Berdasarkan pada Gambar 5, terkonfirmasi bahwa dataset bersifat tidak seimbang (*imbalanced*), dengan 297 sampel untuk kelas 'Bukan Insomnia' (0) dan 77 sampel untuk kelas 'Insomnia' (1). Sesuai dengan keputusan metodologis penelitian, proporsi data asli ini sengaja dipertahankan untuk menguji kapabilitas bawaan algoritma *Random Forest* dalam menangani skenario data realistis (dunia nyata), tanpa melakukan manipulasi data artifisial seperti *oversampling*.

b. Ekstraksi Fitur (*Feature Extraction*)

Pada tahap ini dilakukan ekstraksi fitur (*feature extraction*) terhadap kolom *Blood Pressure* yang semula berbentuk string dengan format "*Systolic/Diastolic*". Proses ini memisahkan nilai tersebut menjadi dua kolom numerik terpisah, yaitu *Systolic* (tekanan darah atas) dan *Diastolic* (tekanan darah bawah), agar data dapat diproses lebih efektif oleh model pembelajaran mesin.

	Blood Pressure	Systolic	Diastolic
0	126/83	126.0	83.0
1	125/80	125.0	80.0
2	125/80	125.0	80.0
3	140/90	140.0	90.0
4	140/90	140.0	90.0

Gambar 6. Hasil Ekstraksi Fitur pada Kolom Blood Pressure

Berdasarkan Gambar 6, kolom *Blood Pressure* berhasil dipecah menjadi dua fitur baru dengan nilai numerik yang merepresentasikan tekanan darah atas dan bawah secara independen. Langkah ini meningkatkan kualitas data serta memungkinkan analisis yang lebih spesifik terhadap pengaruh tekanan darah terhadap risiko insomnia.

c. Encoding Fitur Kategorikal

Tahap selanjutnya yang dilakukan dalam proses pra-pemrosesan data adalah encoding variabel kategorikal, yaitu proses mengubah data non-numerik menjadi bentuk numerik agar dapat diolah oleh algoritma *machine learning*. Hal ini sangat penting karena sebagian besar model pembelajaran mesin hanya dapat memproses data dalam format angka. Pada penelitian ini digunakan metode *One-Hot Encoding*, yang bekerja dengan cara mengonversi setiap kategori unik pada fitur kategorikal seperti kolom *Occupation* menjadi variabel biner (True/False atau 1/0) yang menunjukkan keberadaan suatu kategori dalam setiap entri data. Misalnya, kategori seperti *Manager*, *Nurse*, atau *Sales Representative* akan diubah menjadi kolom terpisah seperti *Occupation_Manager*, *Occupation_Nurse*, dan *Occupation_Sales Representative*. Pendekatan ini bertujuan untuk mencegah model salah menginterpretasikan data kategorikal sebagai nilai ordinal yang memiliki urutan tertentu, serta memastikan bahwa setiap kategori diperlakukan secara independen dalam proses pelatihan. Dengan demikian, hasil *encoding* ini membantu meningkatkan akurasi dan interpretabilitas model klasifikasi yang akan dibangun.



Hasil Encoding One-Hot:

	Person ID	Age	Sleep Duration	Quality of Sleep	Physical Activity Level	\
0	1	27	6.1	6	42	
1	2	28	6.2	6	60	
2	3	28	6.2	6	60	
3	4	28	5.9	4	30	
4	5	28	5.9	4	30	

	Stress Level	Blood Pressure	Heart Rate	Daily Steps	Sleep Disorder	...	\
0	6	126/83	77	4200	NaN	...	
1	8	125/80	75	10000	NaN	...	
2	8	125/80	75	10000	NaN	...	
3	8	140/90	85	3000	Sleep Apnea	...	
4	8	140/90	85	3000	Sleep Apnea	...	

	Occupation_Manager	Occupation_Nurse	Occupation_Sales Representative	\
0	False	False	False	
1	False	False	False	
2	False	False	False	
3	False	False	True	
4	False	False	True	

	Occupation_Salesperson	Occupation_Scientist	Occupation_Software Engineer	\
0	False	False	True	
1	False	False	False	
...				

Gambar 7. Hasil One-Hot Encoding pada Variabel Kategorikal

Berdasarkan Gambar 7, terlihat bahwa kolom kategorikal seperti *Occupation* telah berhasil diubah menjadi beberapa kolom baru, misalnya *Occupation_Manager*, *Occupation_Nurse*, dan *Occupation_Sales Representative*. Proses ini memastikan bahwa seluruh data bersifat numerik sehingga model dapat mengenali pola tanpa bias terhadap urutan kategori tertentu.

d. Standardisasi Data (Feature Scaling)

Tahap berikutnya yang dilakukan dalam proses pra-pemrosesan data adalah standarisasi data, yaitu langkah penting untuk mengubah skala seluruh fitur numerik agar memiliki distribusi yang seragam dengan nilai rata-rata (*mean*) sebesar 0 dan standar deviasi sebesar 1. Tujuan utama dari proses ini adalah untuk menghindari dominasi fitur tertentu yang memiliki rentang nilai lebih besar dibandingkan fitur lainnya, sehingga setiap variabel dapat berkontribusi secara proporsional dalam proses pembelajaran model. Dengan dilakukannya proses standarisasi, diharapkan performa model dapat menjadi lebih optimal dalam mengenali pola dan hubungan antar fitur tanpa dipengaruhi oleh perbedaan satuan atau besaran nilai pada masing-masing variabel.

Data setelah Standardisasi:

	Person ID	Age	Sleep Duration	Quality of Sleep	\
0	-1.727426	-1.753096	-1.298887	-1.098280	
1	-1.718163	-1.637643	-1.173036	-1.098280	
2	-1.708901	-1.637643	-1.173036	-1.098280	
3	-1.699639	-1.637643	-1.550588	-2.771424	
4	-1.690376	-1.637643	-1.550588	-2.771424	

	Physical Activity Level	Stress Level	Heart Rate	Daily Steps	Systolic	\
0	-0.825418	0.347021	1.654719	-1.619584	-0.330002	
1	0.039844	1.475592	1.170474	1.970077	-0.459239	
2	0.039844	1.475592	1.170474	1.970077	-0.459239	
3	-1.402260	1.475592	3.591698	-2.362273	1.479309	
4	-1.402260	1.475592	3.591698	-2.362273	1.479309	

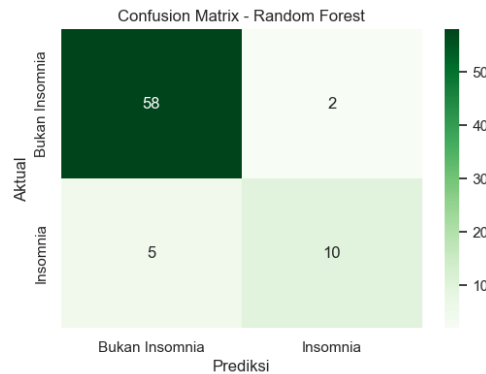
	Diastolic
0	-0.268102
1	-0.755640
2	-0.755640
3	0.869486
4	0.869486

Gambar 8. Hasil Standardisasi Data Numerik

Berdasarkan Gambar 8, terlihat bahwa nilai pada setiap fitur, seperti *Age*, *Sleep Duration*, *Heart Rate*, *Systolic*, dan *Diastolic*, telah diubah ke dalam skala standar. Proses ini membantu meningkatkan stabilitas dan performa model klasifikasi dalam mengenali pola data secara optimal.

3.3 Model Random Forest

Setelah proses pelatihan (*training*) dan pengujian (*testing*) dilakukan, tahap selanjutnya adalah mengevaluasi performa model *Random Forest* dalam mengklasifikasikan kondisi tidur individu. Evaluasi ini bertujuan untuk mengetahui sejauh mana model mampu membedakan antara kategori *Insomnia* dan *Sleep Apnea* berdasarkan fitur-fitur yang telah diolah sebelumnya.



Gambar 9. Confusion Matrix Model Random Forest

Berdasarkan hasil *Confusion Matrix* pada Gambar 9, terlihat bahwa model *Random Forest* memiliki kinerja yang sangat baik dalam mengklasifikasikan data. Model berhasil memprediksi dengan benar 58 data Bukan Insomnia (True Negative) dan 10 data Insomnia (True Positive). Sementara itu, terdapat 2 kesalahan klasifikasi pada kategori Bukan Insomnia yang diprediksi sebagai Insomnia (False Positive) serta 5 kesalahan pada kategori Insomnia yang diprediksi sebagai Bukan Insomnia (False Negative). Pola ini menunjukkan bahwa Random Forest mampu memahami hubungan antar fitur dengan baik, meskipun masih terdapat beberapa kesalahan prediksi yang wajar mengingat kompleksitas data biologis dan perilaku tidur manusia. Selain *Confusion Matrix*, performa model juga dianalisis menggunakan Laporan Klasifikasi (Classification Report) yang mencakup metrik *precision*, *recall*, dan *f1-score* untuk setiap kelas.

```

--- Hasil Evaluasi Random Forest ---
Akurasi: 0.9067
Laporan Klasifikasi:

```

	precision	recall	f1-score	support
0	0.92	0.97	0.94	60
1	0.83	0.67	0.74	15
accuracy			0.91	75
macro avg	0.88	0.82	0.84	75
weighted avg	0.90	0.91	0.90	75

Gambar 10. Laporan Evaluasi Model Random Forest

Berdasarkan hasil evaluasi pada Gambar 10, model *Random Forest* menunjukkan performa yang sangat solid dengan akurasi keseluruhan mencapai 91%, membuktikan kemampuannya yang tinggi dalam memprediksi risiko insomnia. Keandalan model ini terutama terlihat pada kemampuannya mengidentifikasi kelas Bukan Insomnia (0), dengan nilai *precision* 0.92 dan *recall* 0.97 yang nyaris sempurna. Untuk kelas Insomnia (1) yang lebih menantang, model ini menunjukkan karakteristik *trade-off* yang jelas antara *precision* dan *recall*. Model ini berhasil mencapai *precision* tinggi sebesar 0.83, yang sangat menguntungkan karena ini berarti ketika model memprediksi seseorang berisiko Insomnia, prediksi tersebut memiliki tingkat kebenaran yang tinggi (83%) dan model tidak sering salah dalam memberikan 'label' insomnia (rendah *False Positive*). Meskipun nilai *recall* (0.67) mengindikasikan bahwa model mengambil pendekatan yang lebih 'hati-hati' sehingga belum menangkap seluruh kasus positif, performa secara keseluruhan tetap sangat seimbang, seperti yang ditunjukkan oleh *weighted avg f1-score* sebesar 0.90. Hasil ini menegaskan bahwa algoritma *Random Forest* telah berhasil membangun model yang stabil, efektif, dan memiliki tingkat presisi yang dapat diandalkan, didukung oleh kemampuan *ensemble learning* yang terbukti mampu mengurangi *overfitting* dan menjaga generalisasi data.

3.4 Evaluasi Model

Model *Random Forest* digunakan untuk mengevaluasi kemampuan prediksi terhadap dua kategori gangguan tidur, yaitu Insomnia dan *Sleep Apnea*. Hasil evaluasi menunjukkan bahwa model memiliki performa yang konsisten pada berbagai metrik pengujian seperti *precision*, *recall*, dan *F1-score*. Nilai-nilai ini mencerminkan keseimbangan antara ketepatan dan sensitivitas model dalam mengenali kedua kelas.

Tabel 3. Hasil Evaluasi Model Random Forest

e	Precision	Recall	F1-Score	Support
0	0.92	0.97	0.94	60
1	0.83	0.97	0.74	15
Accuracy	---	---	0.91	75
Macro Avg	0.88	0.82	0.84	75
Weighted Avg	0.90	0.91	0.90	75

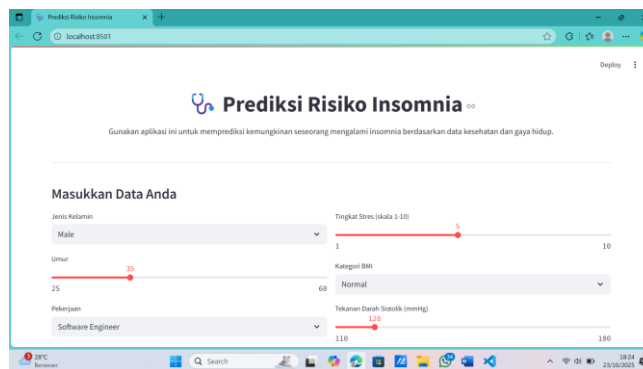
Berdasarkan hasil evaluasi pada Tabel 3, model Random Forest menunjukkan kinerja yang sangat baik dengan akurasi keseluruhan mencapai 91%. Model ini terbukti sangat andal dalam mengidentifikasi individu tanpa risiko insomnia (*precision* 0.92, *recall* 0.97), serta memiliki kemampuan yang baik untuk mendeteksi kasus insomnia sebenarnya (*precision* 0.83). Dengan *Weighted Avg F1-Score* sebesar 0.90, performa model seimbang dan tidak bias terhadap salah satu kelas. Keberhasilan ini menegaskan bahwa algoritma *Random Forest* mampu menghasilkan model klasifikasi yang akurat dan dapat diandalkan, menjadikannya fondasi yang kuat untuk aplikasi web prediktif yang telah dikembangkan sebagai alat bantu analisis awal risiko insomnia

3.4 Implementasi Streamlit

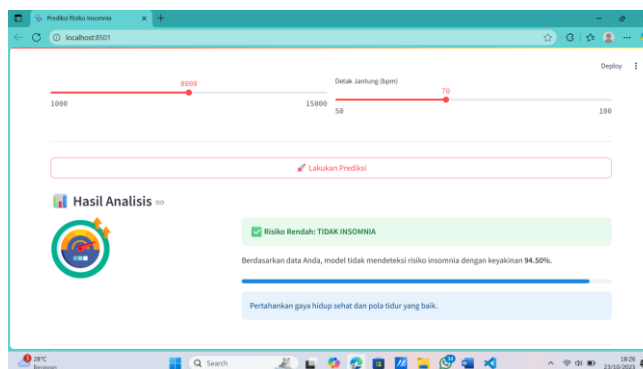
Setelah model *Random Forest* dengan performa optimal berhasil divalidasi, tahap akhir dan paling krusial dari penelitian ini adalah implementasi dan *deployment*. Fase ini bertujuan untuk menjembatani kesenjangan antara model komputasional yang abstrak dan pengguna akhir dengan menerjemahkannya menjadi sebuah alat yang fungsional, interaktif, dan mudah diakses.

a. Pengembangan dan Uji Coba Aplikasi di Lingkungan Lokal

Untuk pengembangan awal, *framework* Streamlit dipilih karena kemampuannya membangun aplikasi web berbasis data dengan cepat dan efisien. Aplikasi prediksi risiko insomnia ini dirancang sebagai alat kesehatan digital yang mudah diakses, memungkinkan pengguna melakukan evaluasi mandiri. Antarmuka pengguna (UI) dirancang agar bersih dan intuitif, di mana pengguna dapat dengan mudah memasukkan data personal mereka melalui berbagai komponen interaktif seperti *dropdown menu* dan *slider*.



Gambar 11. Antarmuka Input Aplikasi Streamlit

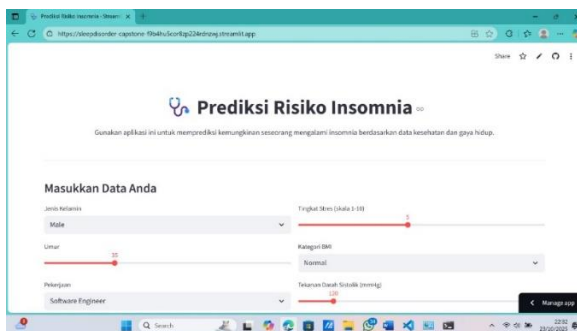


Gambar 12. Tampilan Hasil Prediksi dan Interpretasi Model

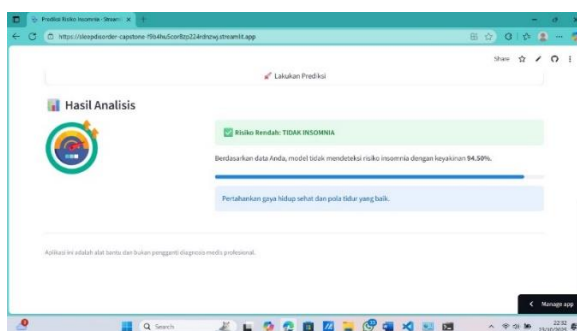
Setelah semua data dimasukkan, pengguna menekan tombol "Lakukan Prediksi". Tombol ini memicu model prediktif di *backend* untuk memproses data secara instan. Hasil analisis kemudian disajikan dengan format yang komprehensif dan mudah dipahami. Outputnya tidak hanya menampilkan kesimpulan diagnosis awal seperti "Risiko Rendah: TIDAK INSOMNIA", tetapi juga memperkuatnya dengan metrik kuantitatif berupa persentase keyakinan model, visualisasi *gauge meter*, dan rekomendasi tindak lanjut yang personal. Tahap ini mengonfirmasi bahwa aplikasi berfungsi sepenuhnya di lingkungan pengembangan lokal.

b. Deployment Aplikasi Menggunakan *GitHub* untuk Akses Publik

Setelah aplikasi terbukti berfungsi dengan baik di lingkungan lokal, langkah berikutnya adalah mempublikasikannya. Proses ini menggunakan *GitHub* untuk manajemen kode dan *Streamlit Community Cloud* untuk *hosting*.



Gambar 13. Tampilan Aplikasi Setelah Berhasil di-Deploy



Gambar 14. Hasil Tampilan Aplikasi Setelah Berhasil di-Deploy

Dengan berhasilnya proses *deployment*, aplikasi kini dapat diakses secara publik melalui URL. Tahap ini secara efektif mentransformasi prototipe lokal menjadi alat kesehatan digital yang fungsional dan dapat dijangkau oleh pengguna luas.

4. KESIMPULAN

Penelitian ini telah berhasil secara komprehensif mencapai tujuan utamanya, yaitu merancang, mengembangkan, dan mengimplementasikan sebuah sistem klasifikasi gangguan tidur berbasis machine learning dengan menggunakan algoritma *Random Forest*. Model prediktif yang dibangun menunjukkan performa yang sangat solid dan dapat diandalkan, mencapai akurasi keseluruhan sebesar 91%. Secara spesifik, model ini sangat andal dalam mengidentifikasi Kelas 0 (Bukan Insomnia) dengan *precision* 0.92 dan *recall* 0.97. Untuk Kelas 1 (Insomnia), model menunjukkan *trade-off* performa yang seimbang, dengan *precision* tinggi sebesar 0.83 dan *recall* 0.67. Nilai *precision* yang tinggi ini sangat positif, karena menunjukkan bahwa ketika model memprediksi seseorang berisiko Insomnia, prediksi tersebut memiliki tingkat kebenaran yang tinggi. Keseimbangan performa model secara keseluruhan ini ditegaskan oleh *Weighted Avg F1-Score* sebesar 0.90, yang secara kuantitatif menunjukkan kapabilitas model dalam membedakan berbagai kondisi tidur dengan tingkat kesalahan klasifikasi yang minimal. Salah satu kontribusi nyata dari penelitian ini adalah keberhasilan dalam mengidentifikasi faktor-faktor kunci yang paling berpengaruh terhadap kesehatan tidur. Melalui analisis feature importance, terungkap secara jelas bahwa Tingkat Stres (*Stress Level*), Kategori Indeks Massa Tubuh (*BMI Category*), dan Detak Jantung (*Heart Rate*) merupakan tiga prediktor dengan daya pengaruh paling dominan. Temuan ini memberikan bukti empiris yang kuat, mengonfirmasi bahwa kondisi psikologis dan parameter fisiologis individu memegang peranan sentral dan tidak terpisahkan dari kualitas tidur seseorang. Penelitian ini berhasil mentransformasikan model data sains yang kompleks menjadi sebuah aplikasi web interaktif yang fungsional dan ramah pengguna, dibangun menggunakan *framework Streamlit*. Aplikasi ini berhasil menjembatani kesenjangan antara analisis data dan pengguna awam dengan menyediakan platform yang tidak hanya mampu memberikan prediksi risiko gangguan tidur secara *real-time*, tetapi juga menyajikan interpretasi hasil yang mudah dicerna. Keberhasilan implementasi ini disempurnakan dengan proses deployment aplikasi ke platform publik melalui repositori *GitHub*, sehingga alat ini tidak hanya fungsional tetapi juga dapat diakses secara luas. Dengan demikian, aplikasi ini berfungsi sebagai alat skrining awal yang praktis dan memberdayakan pengguna dengan wawasan personal mengenai kesehatan tidur mereka. Meskipun hasil yang dicapai sangat positif, penelitian ini menyadari adanya beberapa keterbatasan, terutama terkait ukuran dan *homogenitas demografis* dari dataset yang digunakan, yang berpotensi membatasi generalisasi model pada populasi yang lebih beragam. Oleh karena itu, arah

penelitian di masa depan berfokus pada penggunaan dataset yang lebih besar dan heterogen. Selain itu, pengembangan selanjutnya dapat diarahkan pada proses validasi klinis untuk meningkatkan kredibilitas medis aplikasi, serta pengintegrasian fitur rekomendasi gaya hidup yang dipersonalisasi secara dinamis berdasarkan profil risiko pengguna untuk meningkatkan dampak positif dan nilai praktisnya secara signifikan.

REFERENCES

- [1] RSUP Prof. I. G. N. G. Ngoerah, *Modul Materi Gangguan Tidur*. Denpasar: Fakultas Kedokteran Universitas Udayana, 2022. [Online]. Available: <https://neurologiudayana.com/wp-content/uploads/2024/06/11.-Modul-Gangguan-Tidur.pdf>
- [2] A. M. Prakoso, *Psikologi Tidur: Dari Kualitas Tidur hingga Insomnia*. Jakarta: PT Elex Media Komputindo, 2020. [Online]. Available: <https://opac.perpusnas.go.id/DetailOpac.aspx?id=1334119>
- [3] A. I. Sharaf, "Sleep Apnea Detection Using Wavelet Scattering Transformation and Random Forest Classifier," *Entropy*, vol. 25, no. 3, 2023, DOI: 10.3390/e25030399.
- [4] I. A. Hidayat, "Classification of Sleep Disorders Using Random Forest on Sleep Health and Lifestyle Dataset," *Journal of DINDA: Data Science, Information Technology, and Data Analytics*, vol. 3, no. 2, pp. 71–76, 2023. [Online]. Available: <http://journal.itelkom-pwt.ac.id/index.php/dinda>. doi: 10.56855/dinda.v3i2.188
- [5] I. Adriansyah, M. D. Mahendra, E. Rasywir, and Y. Pratama, "Perbandingan Metode Random Forest Classifier dan SVM pada Klasifikasi Kemampuan Level Beradaptasi Pembelajaran Jarak Jauh Siswa," *Bulletin of Informatics and Data Science*, vol. 1, no. 2, pp. 98–103, Nov. 2022, doi: 10.61944/bids.v1i2.49.
- [6] S. Li, P. Zhu, G. Cai, J. Li, T. Huang, dan W. Tang, "Application Of Machine Learning Models In Predicting Insomnia Severity: An Integrative Approach With Constitution Of Traditional Chinese Medicine," *Frontiers In Medicine*, Vol. 10, Art. no. 1292761, 2023, doi: 10.3389/fmed.2023.1292761.
- [7] W. Widyastuty and M. A. Azis, "Classification and Evaluation of Sleep Disorders Using Random Forest Algorithm in Health and Lifestyle Dataset," *Compiler*, vol. 13, no. 1, p. 11, May 2024, doi: 10.28989/compiler.v13i1.2184.
- [8] P. E. Sudiarti, R. R. Lestari, and P. Tuanku Tambusai, "Hubungan Gaya Hidup Dengan Kejadian Insomnia Pada Mahasiswa Prodi Teknik Informatika Universitas Pahlawan Tuanku Tambusai," *Jurnal Ners*, vol. 6, no. 2, pp. 132–137, 2022, doi: 10.31004/jn.v6i2.7813
- [9] J. B. Putri Kristiani, L. Leokadja, and I. Binanto, "Perbandingan Metode Klasifikasi Random Forest dan Support Vector Machine Terhadap Dataset Resiko Kanker Serviks," *JTRISTE (Jurnal Teknologi Rekayasa Informasi dan Sains Terapan)*, vol. 11, no. 1, pp. 60–66, 2024, doi: 10.55645/jtriste.v11i1.507
- [10] A. Putranto, N. L. Azizah, I. Ratna, and I. Astutik, "Web-Based Heart Disease Prediction System Using SVM Method and Streamlit Framework [Sistem Prediksi Penyakit Jantung Berbasis Web Menggunakan Metode SVM dan Framework Streamlit]," *Kesatria: Jurnal Penerapan Sistem Informasi (Komputer dan Manajemen)*, vol. 1, no. 1, pp. 1–10, 2023, doi: 10.21070/ups.1378
- [11] A. Satara, S. Ernawati, and F. Purnomosidi, "Kecemasan Pada Mahasiswa Insomnia," *Jurnal Asosiatif*, vol. 4, no. 1, pp. 1–9, 2025, doi: 10.47942/asosiatif.v4i1.1848
- [12] D. Maulina, R. Anugrahwati, S. Adiana, P. K. Syafitri, V. Arianti, A. U. H. Rochjana, and A. D. Retnani, "Manajemen Komprehensif Insomnia Terkait Smartphone Pada Mahasiswa: Perspektif Keperawatan, Farmasi, Dan Fisioterapi," *Indonesian Journal of Health Science*, vol. 5, no. 4, pp. 760–772, 2025, doi: 10.54957/ijhs.v5i4.1619.
- [13] L. Susanti, "Faktor-Faktor Yang Mempengaruhi Kejadian Insomnia Di Poliklinik Saraf RS DR. M. Djamil Padang," *Jurnal Kesehatan Andalas*, vol. 4, no. 3, pp. 951–956, 2015, doi: 10.25077/jka.v4i3.391.
- [14] P. A. A. Krisnawan and M. P. D. Bajirani, "Intervensi untuk Menurunkan Insomnia pada Mahasiswa," *Jurnal Penelitian Inovatif*, vol. 5, no. 2, pp. 2119–2130, May 2025, doi: 10.54082/jupin.1383.
- [15] Taufiq Fadli, A. Chairunnas, M. I. Suriyansyah, and K. Kunci, "Deteksi Insomnia Menggunakan Sensor GSR dan Max30102 Metode Naïve Bayes," *Joutica (Journal Of Informatics Unisla)*, vol. 10, no. 1, pp. 115–123, 2025, doi: 10.30736/informatika.v10i1.1370
- [16] K. Inra Gunawan, Nurgahayu, and Haeruddin, "Faktor Determinan Kejadian Insomnia Pada Mahasiswa Tingkat Akhir Fakultas Kesehatan Masyarakat Universitas Muslim Indonesia," *Window Of Public Health Journal*, vol. 3, no. 3, pp. 488–501, 2022, doi: 10.33096/woph.v3i3.104
- [17] A. Ananda Hapsari, A. Syafei Nursuwanda, H. Zuhriyah, and D. Junesco Vresdian, "Klasifikasi Kesehatan Mental Mahasiswa Model TMAS Dengan Algoritma Decision Tree, Logistic Regression, Dan Random Forest," *INTEK: Jurnal Informatika dan Teknologi Informasi*, vol. 7, no. 2, pp. 101–109, 2024, doi: 10.37729/intek.v7i2.5690
- [18] V. Oktaviani, N. Rosmawami, and M. Panji Muslim, "Perbandingan Kinerja Random Forest Dan SMOTE Random Forest Dalam Mendeteksi Dan Mengukur Tingkat Stres Pada Mahasiswa Tingkat Akhir," *Informatik: Jurnal Ilmu Komputer*, vol. 20, no. 1, pp. 45–55, 2024, doi: 10.52958/iftk.v20i1.9158
- [19] P. L. Romadloni, B. A. Kusuma, and W. M. Baihaqi, "Komparasi Metode Pembelajaran Mesin Untuk Implementasi Pengambilan Keputusan Dalam Menentukan Promosi Jabatan Karyawan," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 6, no. 2, 2022, DOI: 10.36040/jati.v6i2.5238
- [20] Abdah Syakiroh Gustian and Fathoni Mahardika, "Analisis Klasifikasi Risiko Dropout Mahasiswa Menggunakan Algoritma Decision Tree dan Random Forest," *Jupiter: Publikasi Ilmu Keteknikan Industri, Teknik Elektro dan Informatika*, vol. 3, no. 4, pp. 182–189, Jul. 2025, doi: 10.61132/jupiter.v3i4.980.
- [21] D. Devalio, A. Anisya, A. Syahrani, I. Warman, and B. Busran, "PERANCANGAN WEBSITE UNTUK PREDIKSI JUMLAH PENGELUARAN MAHASISWA BERBASIS FRAMEWORK STREAMLIT," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 13, no. 2, Apr. 2025, doi: 10.23960/jitet.v13i2.6451.
- [22] G. Ayu Syafarina and I. Kalimantan Muhammad Arsyad Al Banjari Banjarmasin, "Implementasi Framework Streamlit Sebagai Prediksi Harga Jual Rumah Dengan Linear Regresi," vol. 7, p. 2023, doi: 10.47002/metik.v7i2.680.