

PERBANDINGAN ALGORITMA SVM DAN RANDOM FOREST PADA KLASIFIKASI KESEHATAN MENTAL BERDASARKAN SLEEP DISORDERS

Linda Nurul Taqwa Pulungan*¹⁾, Ema Utami²⁾

1. Magister Informatika, Universitas Amikom, Yogyakarta, Indonesia

2. Magister Informatika, Universitas Amikom, Yogyakarta, Indonesia

Article Info

Kata Kunci: Kesehatan Mental; SVM; Random Forest; Pola Tidur; Klasifikasi.

Keywords: Mental Health; SVM; Random Forest; Sleep Disorders; Classification.

Article history:

Received 16 January 2025

Revised 23 February 2025

Accepted 29 March 2025

Available online 1 September 2025

DOI :

<https://doi.org/10.29100/jupi.v10i3.7392>

* Corresponding author.

Corresponding Author

E-mail address:

lindanurultaqwapulungan@students.amikom.ac.id

ABSTRAK

Kesehatan mental menjadi isu global yang semakin mendesak, dengan meningkatnya jumlah individu yang mengalami gangguan mental di seluruh dunia. Penelitian ini mengevaluasi performa dua algoritma pembelajaran mesin, yaitu Support Vector Machine (SVM) dan Random Forest, dalam mendeteksi gangguan kesehatan mental berdasarkan pola tidur. Data yang digunakan berasal dari dataset "Stress Level Detection" di Kaggle, yang telah diperluas menjadi 1.375 sampel. Dataset ini kemudian dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian model. Hasil penelitian menunjukkan bahwa Random Forest memiliki performa lebih unggul dibandingkan SVM, dengan akurasi mencapai 91% dan F1-score rata-rata 89%. Sebaliknya, SVM memperoleh akurasi sebesar 83% dan F1-score rata-rata 81%. Random Forest terbukti lebih efektif dalam mengidentifikasi pola tidur normal serta gangguan seperti insomnia. Temuan ini mengindikasikan bahwa pembelajaran mesin, khususnya Random Forest, berpotensi menjadi alat yang andal dalam deteksi dini gangguan kesehatan mental berbasis analisis pola tidur, sehingga dapat mendukung proses diagnosis yang lebih cepat dan akurat.

ABSTRACT

Mental health has become an increasingly urgent global issue, with a rising number of individuals experiencing mental disorders worldwide. This study evaluates the performance of two machine learning algorithms, Support Vector Machine (SVM) and Random Forest, in detecting mental health disorders based on sleep patterns. The dataset used is "Stress Level Detection" from Kaggle, which has been expanded to 1,375 samples. The dataset was divided into 80% for model training and 20% for testing. The results indicate that Random Forest outperforms SVM, achieving an accuracy of 91% and an average F1-score of 89%. In contrast, SVM achieved an accuracy of 83% and an average F1-score of 81%. Random Forest proved to be more effective in identifying normal sleep patterns as well as disorders such as insomnia. These findings suggest that machine learning, particularly Random Forest, has the potential to serve as a reliable tool for the early detection of mental health disorders through sleep pattern analysis, thereby supporting a faster and more accurate diagnostic process.

I. PENDAHULUAN

Sering dengan pesatnya kemajuan teknologi dan pembelajaran mesin, banyak peluang besar untuk mengatasi masalah-masalah yang sebelumnya sulit dipecahkan. Salah satunya yaitu mengenai isu kesehatan global yang kini menjadi perhatian utama adalah gangguan kesehatan mental. Laporan Organisasi Kesehatan Dunia (WHO) pada tahun 2023 menyebutkan bahwa kesehatan mental menjadi penyebab utama disabilitas global, dengan prevalensinya yang terus meningkat di banyak negara, termasuk Indonesia. Masalah kesehatan mental ini semakin menjadi perhatian serius, terutama di Indonesia, di mana stigma sosial masih menjadi hambatan utama yang menghalangi individu untuk mencari bantuan medis atau psikologis [1] Stigma sosial yang terkait dengan kesehatan mental, serta keterbatasan akses terhadap layanan kesehatan di daerah-daerah terpencil, menyebabkan

banyak individu dengan gangguan mental tidak mendapatkan pengobatan yang tepat waktu. Hal ini memperburuk kondisi mereka dan dapat memengaruhi kualitas hidup serta produktivitas [2]. Salah satu faktor yang turut memperburuk kondisi kesehatan mental adalah gangguan tidur, seperti sleep disorders yaitu gangguan tidur yang berkaibat pada sleep apnea, insomnia, yang diketahui dapat memperburuk gangguan mental yang sudah ada, termasuk depresi dan kecemasan, serta mengganggu fungsi kognitif[3].

Gangguan tidur dan kesehatan mental merupakan dua masalah yang saling terkait dan saling memengaruhi, di mana gangguan tidur yang tidak segera ditangani dapat memperburuk kondisi mental, dan sebaliknya, masalah mental juga dapat menyebabkan gangguan tidur yang berkepanjangan. Menurut WHO, kesehatan mental adalah keadaan kesejahteraan di mana individu menyadari kemampuannya, dapat menghadapi tekanan hidup sehari-hari, bekerja secara produktif, dan memberikan kontribusi positif kepada komunitasnya World Health Organization, 2023 [4] Dengan meningkatnya prevalensi gangguan tidur yang berhubungan dengan kesehatan mental, deteksi dini menjadi kunci untuk mencegah perkembangan masalah yang lebih serius. Namun, pendekatan konvensional dalam diagnosis yang melibatkan wawancara klinis dan tes psikologis sering kali membutuhkan biaya tinggi dan sulit dijangkau oleh banyak individu [5].

Deteksi dini terhadap gangguan kesehatan mental sangat penting, Dimana pendekatan konvensional dalam diagnosis, yang melibatkan wawancara dan tes psikologis, sering kali memerlukan biaya yang tinggi dan sulit diakses oleh sebagian besar populasi,[6] dari masalah yang disebutkan, Akibatnya, banyak individu dengan gangguan mental tidak terdiagnosis dengan tepat atau terlambat mendapat pengobatan, yang dapat memperburuk kondisi mereka. Oleh karena itu, diperlukan pendekatan yang lebih efisien, non-invasif, dan terjangkau untuk diagnosis deteksi dini[7]. Pola tidur telah dikenal memiliki hubungan yang signifikan dengan kondisi kesehatan mental seseorang. Faktor-faktor seperti durasi, kualitas, dan pola tidur dapat memberikan petunjuk yang berguna tentang keadaan kesehatan mental individu. Sebuah studi yang dilakukan oleh [8] mengungkapkan bahwa gangguan tidur dapat berfungsi sebagai tanda awal dari gangguan mental, seperti depresi dan kecemasan. Dalam beberapa tahun terakhir, kemajuan dalam teknologi wearable yang memungkinkan pemantauan pola tidur secara real-time telah membuka kesempatan baru untuk mendeteksi gangguan kesehatan mental sejak dini. Algoritma pembelajaran mesin seperti Support Vector Machine (SVM) dan Random Forest telah terbukti efektif dalam mengklasifikasikan data pola tidur untuk mengidentifikasi gangguan kesehatan mental dengan tingkat akurasi yang tinggi [9].

Penelitian sebelumnya mengungkapkan bahwa lebih dari 50% penduduk Indonesia memiliki pandangan negatif terhadap orang yang mengalami gangguan mental, yang berujung pada rendahnya tingkat pengobatan [10]. Penelitian ini bertujuan untuk menawarkan solusi berbasis teknologi guna mendukung inisiatif pemerintah dalam memperluas akses layanan kesehatan mental. Teknologi perangkat wearable telah menciptakan peluang besar untuk pemantauan kesehatan mental secara real-time. Penggunaan perangkat wearable di Indonesia menunjukkan tren pertumbuhan yang signifikan. Berdasarkan laporan Statista pada tahun 2023, penggunaan perangkat wearable meningkat hingga 35% dalam tiga tahun terakhir, yang mencerminkan potensi besar aplikasi teknologi ini dalam bidang kesehatan. Di samping itu, algoritma pembelajaran mesin seperti SVM dan Random Forest terbukti efektif dalam mengklasifikasikan data pola tidur dengan akurasi tinggi. Menurut laporan Statista pada tahun 2023 penggunaan perangkat wearable tumbuh hingga 35% dalam tiga tahun terakhir, mencerminkan potensi besar dalam pengaplikasiannya di bidang kesehatan[11]. Penelitian menunjukkan bahwa kombinasi SVM dengan data dari perangkat wearable dapat mencapai akurasi hingga 90% dalam mendeteksi gangguan tidur yang terkait dengan masalah kesehatan mental. Penelitian ini bertujuan untuk mengembangkan penerapan metode tersebut dengan mengeksplorasi potensinya dalam menyediakan solusi kesehatan mental yang lebih terjangkau dan efektif. SVM dipilih karena kemampuannya dalam mengelola data besar dan kompleks, menawarkan solusi yang efisien untuk klasifikasi pola tidur. Di sisi lain, Random Forest, sebagai teknik ensemble, lebih unggul dalam menangani dataset dengan banyak fitur dan ketahanan terhadap gangguan (noise). Keduanya memiliki kelebihan dalam masalah klasifikasi, namun perbandingan langsung antara SVM dan Random Forest dalam mendeteksi gangguan kesehatan mental berdasarkan pola tidur masih terbatas[12].

Penelitian sebelumnya[13] yang membandingkan performa algoritma SVM dan Random Forest untuk mendeteksi gangguan tidur mengungkapkan adanya variasi dalam hasil evaluasi kedua model tersebut. SVM mencatatkan akurasi sebesar 88%, sementara Random Forest sedikit lebih unggul dengan akurasi 90%. Precision pada SVM tercatat 87%, sedangkan pada Random Forest, nilai tersebut mencapai 91%. Begitu juga dengan recall, dimana SVM memperoleh nilai 85%, sementara Random Forest mendapatkan nilai 89%. F1-Score, yang mencakup gabungan antara precision dan recall, menunjukkan angka 86% untuk SVM dan 90% untuk Random Forest. Berdasarkan temuan ini, dapat disimpulkan bahwa Random Forest memberikan hasil yang lebih baik secara keseluruhan. Sebagai tambahan, penelitian yang dilakukan oleh [14]. juga menunjukkan bahwa Random Forest menunjukkan kinerja yang lebih baik daripada SVM di semua metrik evaluasi, baik pada training set, test set, maupun 4-fold cross-validation. Pada test set, SVM tercatat dengan akurasi sebesar 72,10%, sedangkan Random

Forest mencapai 79,30%, menandakan perbedaan yang signifikan. Pada evaluasi 4-fold cross-validation, Random Forest memperoleh nilai 83,10%, sedangkan SVM hanya mencatatkan 75,60%. Hasil penelitian ini mendukung temuan dari studi sebelumnya yang menunjukkan bahwa Random Forest lebih efektif dalam menangani masalah klasifikasi dengan data yang kompleks. Dari penelitian diatas, penelitian sbelumnya cenderung hanya berfokus pada dua parametre risiko, seperti pola tidur atau tingkat stres, tanpa mempertimbangkan kombinasi multifaktorial yang lebih komprehensif. Selain itu, sebagian besar model klasifikasi tidak menangani ketidakseimbangan data, sehingga sering terjadi bias terhadap kelas mayoritas. Fokus penelitian juga cenderung global, tanpa mempertimbangkan kondisi lokal seperti tekanan pekerjaan dan gaya hidup masyarakat Indonesia.

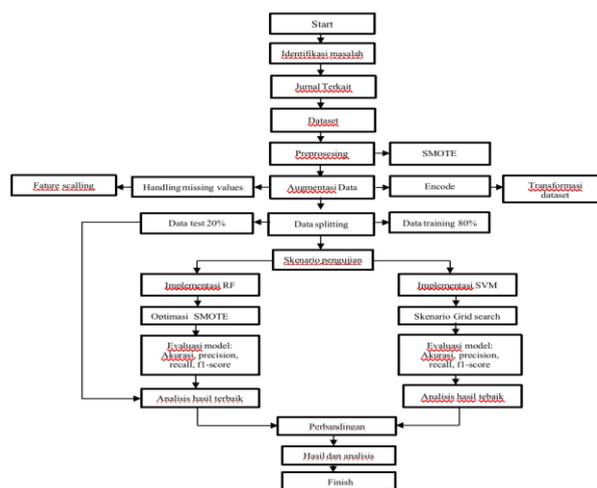
Secara keseluruhan, penelitian ini menyoroti efektivitas penggunaan algoritma dalam mendeteksi gangguan kesehatan, dengan Random Forest menunjukkan hasil yang lebih unggul dalam berbagai metrik. Penelitian ini juga menekankan pentingnya penerapan AI dalam mendeteksi masalah kesehatan lebih dini, terutama di kalangan mahasiswa. Sebagai studi lanjutan, penelitian yang dilakukan oleh [15] juga menunjukkan bahwa model Random Forest dalam studi ini menghasilkan nilai presisi, akurasi, recall, dan F1-Score sebesar 60,5%, 60,5%, 60,5%, dan 58,5%, yang menunjukkan kinerja yang masih memerlukan peningkatan untuk meningkatkan efektivitasnya dalam mendeteksi gangguan kesehatan mental. Penelitian diatas cenderung hanya berfokus pada satu atau dua parameter risiko, seperti pola tidur atau tingkat stres, tanpa mempertimbangkan kombinasi multifaktorial yang lebih komprehensif. Selain itu, sebagian besar model klasifikasi tidak menangani ketidakseimbangan data, sehingga sering terjadi bias terhadap kelas mayoritas. Fokus penelitian juga cenderung global, tanpa mempertimbangkan kondisi lokal seperti tekanan pekerjaan dan gaya hidup masyarakat Indonesia. Penelitian ini menawarkan beberapa kebaruan atau novelty untuk mengisi gap tersebut dengan : Mengintegrasikan beberapa parameter risiko berbasis data wearable, yaitu durasi tidur, level stres, tekanan darah, dan aktivitas harian, Dimana penelitian sebelumnya hanya terakait data tidur tanpa mengaitkan tekanan darah, level stress, tekanan darah, dan aktuvtas harian, Menggunakan teknik SMOTE (*Synthetic Minority Oversampling Technique*) untuk menyeimbangkan dataset gangguan tidur yang tidak seimbang, Membandingkan algoritma Support Vector Machine (SVM) dan Random Forest untuk klasifikasi gangguan tidur berdasarkan data wearable.

Jadi berdasarkan penelitian sebagai pemanding diatas alasan aloritma SVM dan Random forest dipiliha karena cocok dengan dataset yang digunakan dalam penelitian ini(1.375 sampel) SVM dipilih karena cocok untuk dataset menengah dan dapat menangani pola non-linear menggunakan kernel RBF. Random Forest dipilih karena lebih tahan terhadap noise dan dapat menangani dataset dengan banyak fitur serta ketidakseimbangan data melalui mekanisme ensemble learning. Dataset pada penelitian ini kurang seusuai jika menggunakan model Deep Learning, karena CNN/LSTM umumnya memerlukan jumlah data yang jauh lebih besar untuk menghindari overfitting. XGBoost lebih cocok untuk dataset dengan distribusi kelas yang seimbang, sementara penelitian ini menggunakan SMOTE untuk menyeimbangkan data, yang lebih efektif dengan SVM dan Random Forest. Studi Sebelumnya Studi oleh [16]. dalam penelitian ini menegaskan bahwa SVM dan Random Forest sudah memiliki akurasi tinggi dalam klasifikasi gangguan tidur, sehingga penggunaan Deep Learning tidak diperlukan dalam penelitian ini, sebagai tambahan penelitian yang dilakukan oleh [17] dalam penelitian ini juga menyebutkan bahwa model Random Forest lebih stabil dibandingkan model kompleks seperti Deep Learning.

Pemilihan kedua algoritma ini juga bertujuan untuk membandingkan efektivitas pendekatan yang berbeda, di mana SVM menggunakan margin maksimal untuk memisahkan kelas, sementara RF menggunakan voting berdasarkan banyak pohon keputusan. Perbandingan ini menjadi penting untuk mengevaluasi dampak metode oversampling seperti SMOTE terhadap algoritma dengan karakteristik berbeda. Hasil penelitian sebelumnya juga mendukung penggunaan kedua algoritma ini, di mana SVM menghasilkan akurasi tinggi dalam klasifikasi yang menunjukkan keunggulan RF setelah penerapan SMOTE. Berdasarkan latar belakang penjelasan diatas maka penelitian ini bertujuan untuk mengembangkan penerapan metode tersebut dengan mengeksplorasi potensinya dalam menyediakan solusi kesehatan mental yang lebih hemat biaya dan efektif. Dengan mengevaluasi kedua algoritma menggunakan metrik seperti akurasi, presisi, *recall*, dan F1-Score, diharapkan penelitian ini dapat menentukan algoritma yang lebih efisien dalam mendeteksi gangguan tidur dengan berbagai tingkat keparahan. Hasil penelitian ini juga diharapkan mendorong pengembangan teknologi wearable sebagai alat pemantauan kesehatan mental yang lebih luas dan dapat diakses oleh lebih banyak individu, sehingga dapat mengurangi dampak negatif dari gangguan kesehatan mental.

II. METODOLOGI PENELITIAN

Metode pada penelitian ini akan memberikan Gambaran umum tentang tahapan penelitian yang dilakukan dari awal hingga akhir, alur penelitian dapat dilihat pada gambar 1 sebagai berikut :



Gambar 1 Alur Penelitian

A. Pengumpulan Data

Langkah awal dalam penelitian ini adalah pengumpulan dataset melalui internet data yang diambil yaitu data yang relevan dan berkualitas, yang digunakan sebagai dasar untuk pengembangan model. Dataset yang digunakan dalam penelitian ini diperoleh dari platform publik Kaggle, khususnya dari dataset yang berjudul "Stress Level Detection". Dataset ini mencakup 375 entri data yang awalnya dikumpulkan menggunakan perangkat wearable pada tanggal 21 Agustus 2024. Data yang terkumpul mencakup berbagai parameter penting, seperti jenis kelamin, usia, pekerjaan, kualitas tidur, aktivitas sehari-hari, tingkat stres, berat badan, dan tekanan darah. Dataset ini bersifat observasional, yang berarti data dikumpulkan tanpa adanya eksperimen langsung, namun melalui pengumpulan data berbasis angket atau metode pengukuran lain yang sudah terbukti efektif dalam penelitian sebelumnya, kemudian dataset diekstraksi menjadi format.csv.

C. Preprocessing

Pra-pemrosesan data adalah langkah krusial untuk memastikan dataset siap digunakan dalam analisis machine learning [18]. Dalam penelitian ini, dataset yang digunakan sudah dilabeli ke dalam tiga kategori utama: Insomnia, Sleep Apnea, dan Normal. Langkah pertama dalam proses ini adalah menangani data yang hilang. Untuk kolom numerik, data yang kosong diisi menggunakan nilai rata-rata (mean) dari kolom terkait, sedangkan untuk kolom kategorikal, nilai yang hilang diganti dengan kategori yang paling sering muncul (most frequent). Metode ini bertujuan untuk memastikan dataset tetap lengkap dan tidak ada informasi yang hilang yang dapat memengaruhi hasil analisis.

Selanjutnya, kolom yang berisi data kategorikal diubah menjadi format numerik dengan menggunakan teknik OneHotEncoder. Transformasi ini penting untuk menghindari interpretasi yang salah oleh algoritma machine learning, yang dapat terjadi jika data kategorikal tidak diubah terlebih dahulu. Setelah itu, dilakukan skalasi fitur menggunakan teknik Min-Max Scaling, di mana nilai numerik diubah ke dalam rentang tertentu, yaitu antara 0 dan 1. Langkah ini memastikan bahwa setiap fitur memiliki skala yang sama, sehingga algoritma seperti SVM dapat memproses data secara optimal tanpa bias akibat perbedaan skala. Transformasi data diterapkan secara terintegrasi pada kolom-kolom yang sesuai menggunakan teknik ColumnTransformer, sehingga berbagai langkah pra-pemrosesan dapat dilakukan secara efisien dan seragam. Setelah proses ini selesai, dataset dibagi menjadi dua bagian, yaitu training set sebanyak 80% untuk melatih model dan testing set sebanyak 20% untuk menguji kinerjanya. Pembagian data dilakukan dengan mempertimbangkan keseimbangan distribusi kategori, sehingga setiap kategori terwakili secara proporsional, menghindari bias terhadap salah satu kategori.

Untuk meningkatkan akurasi hasil, digunakan teknik k-fold cross-validation pada data pelatihan. Teknik ini membagi data pelatihan ke dalam beberapa subset lebih kecil, memungkinkan model untuk dilatih dan diuji secara bergantian pada masing-masing subset, sehingga evaluasi kinerja model menjadi lebih konsisten. Selain itu, untuk mencegah overfitting, diterapkan early stopping, yaitu mekanisme untuk menghentikan proses pelatihan jika performa pada data validasi tidak lagi menunjukkan peningkatan. Dengan tahapan pra-pemrosesan ini, dataset menjadi lebih siap untuk digunakan oleh algoritma SVM dan Random Forest, yang diharapkan dapat menghasilkan klasifikasi yang lebih akurat untuk gangguan tidur dan kesehatan mental.

D. Skenario Pengujian

Penelitian ini menerapkan dua skenario pengujian untuk menilai kinerja model SVM dan Random Forest dalam klasifikasi gangguan tidur dan kesehatan mental. Skenario pertama menggunakan model SVM tanpa melakukan penyesuaian atau optimasi tambahan pada parameter model, sehingga memungkinkan evaluasi kinerja dasar dari algoritma tersebut. Skenario kedua, di sisi lain, mencakup penggunaan teknik optimasi pada model SVM, termasuk pengaturan kernel dan parameter regularisasi untuk meningkatkan akurasi dan kinerja keseluruhan model.

Kedua skenario ini diuji dengan berbagai variasi pembagian data pelatihan dan pengujian, serta penyesuaian pada hyperparameter untuk mengamati pengaruhnya terhadap akurasi dan kemampuan generalisasi model. Proses pengujian dilakukan dengan membagi dataset menjadi dua bagian: 80% untuk pelatihan dan 20% untuk pengujian. Teknik cross-validation diterapkan untuk meningkatkan proses pelatihan dan memberikan estimasi yang lebih andal mengenai akurasi model. Dengan cross-validation, model dilatih dan diuji pada beberapa subset data, memberikan gambaran yang lebih baik tentang kestabilan dan akurasi model secara keseluruhan. Selain itu, untuk menghindari overfitting dan menjaga kestabilan model, teknik early stopping diterapkan, yang menghentikan pelatihan ketika kinerja pada data validasi mulai menurun. Pendekatan ini memastikan proses pelatihan model dilakukan dengan efisien dan optimal. Melalui analisis hasil dari kedua skenario pengujian ini, penelitian ini bertujuan untuk memberikan pemahaman yang lebih mendalam mengenai kelebihan dan kekurangan dari masing-masing algoritma, serta memberikan rekomendasi yang lebih tepat mengenai penerapan algoritma yang lebih efektif dalam klasifikasi gangguan tidur dan kesehatan mental.

E. Evaluasi Matrix

Pada penelitian ini, evaluasi model dilakukan dengan menggunakan beberapa metrik untuk menilai kinerja algoritma SVM dan Random Forest dalam klasifikasi gangguan tidur dan kesehatan mental berdasarkan data yang telah diproses. Metrik yang digunakan mencakup akurasi, presisi, recall, dan F1 score. Akurasi digunakan untuk menilai sejauh mana model dapat memprediksi kelas yang benar dari total data yang diuji, memberikan gambaran umum tentang performa model secara keseluruhan[19]. Presisi adalah ukuran yang digunakan untuk menilai seberapa banyak hasil prediksi positif yang benar-benar relevan, dibandingkan dengan semua prediksi positif yang dikeluarkan oleh model[20]. Recall mengukur sejauh mana model dapat menemukan semua kasus yang relevan dari kelas positif yang ada[21]. F1-score adalah metrik yang menggabungkan kedua aspek penting dari klasifikasi, yaitu presisi dan recall, dengan menggunakan rata-rata harmonik. F1-score memberikan gambaran lebih menyeluruh tentang kinerja model, terutama dalam situasi di mana data tidak seimbang, dan kedua metrik (presisi dan recall) perlu dijaga agar seimbang untuk memberikan hasil yang optimal. yang dihitung berdasarkan persamaan[22]. Berikut adalah rumus untuk menghitung accuracy, precision, recall, dan f1-score dapat dilihat pada persamaan (1),(2), (3) dan (4) dibawah ini :

a. Akurasi

$$\text{Akurasi} = \frac{\text{Jumlah prediksi benar}}{\text{Total data}} \quad (1)$$

b. Presisi

$$\text{Presisi} = \frac{\text{True Positif}}{\text{True Positif} + \text{False Positif}} \quad (2)$$

c. Recall

$$\text{Recall} = \frac{\text{True Positif}}{\text{True Positif} + \text{False negatif}} \quad (3)$$

d. F1 score

$$\text{F1 score} = 2x \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \quad (4)$$

Selain itu juga penelitian ini dilakukandengan tahap pengujian n menggunakan Confusion Matrix, yang

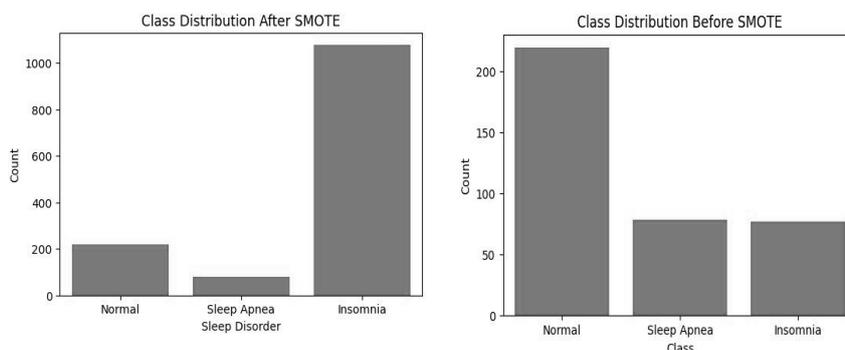
merupakan proses penting dalam mengevaluasi kinerja algoritma. Confusion Matrix digunakan untuk menilai seberapa baik algoritma tersebut berkinerja[23]. Dalam Confusion Matrix, jumlah prediksi yang benar mencakup True Positive (TP) dan True Negative (TN). True Positive (TP) adalah jumlah prediksi yang benar untuk kelas positif, sementara True Negative (TN) adalah jumlah prediksi yang benar untuk kelas negatif. Sebaliknya, False Positive (FP) dan False Negative (FN) mewakili prediksi yang salah: FP menunjukkan kasus yang seharusnya negatif tetapi diprediksi sebagai positif, sementara FN menunjukkan kasus yang seharusnya positif tetapi diprediksi sebagai negatif

III. HASIL DAN PEMBAHASAN

Bagian hasil dan pembahasan memaparkan evaluasi kinerja model serta eksperimen yang dilakukan untuk menilai efektivitas model dalam mengklasifikasikan tingkat stres berdasarkan data pola tidur. Kinerja model dievaluasi menggunakan metrik utama seperti akurasi, presisi, recall, dan F1-score, yang bertujuan untuk menilai sejauh mana model mampu melakukan klasifikasi pada dataset yang digunakan secara efektif. Selain itu, analisis menggunakan matriks kebingungan (confusion matrix) dilakukan untuk mengeksplorasi distribusi prediksi model, termasuk mengidentifikasi kesalahan klasifikasi antar kategori tingkat stres, yaitu rendah, sedang, dan tinggi. Untuk melengkapi analisis, visualisasi tambahan seperti kurva ROC dan precision-recall curve diterapkan, guna mengevaluasi kemampuan model dalam membedakan kelas, khususnya pada data yang tidak seimbang.

A. Tahap Pengujian

Setelah melalui tahapan pengumpulan data, preprocessing, klasifikasi model, dan evaluasi, penelitian ini menghasilkan data pengujian sebagai dasar analisis. Pengujian dilakukan untuk menilai performa model dari kedua mode yaitu svm dan random forest dalam mengklasifikasikan kesehatan mental berdasarkan data sleep disorders yang telah diproses. Hasil pengujian meliputi metrik akurasi, presisi, recall, dan F1-score, yang menjadi landasan dalam mengevaluasi keefektifan model. Tahap ini memainkan peran penting dalam memberikan wawasan terkait kemampuan model untuk mendeteksi hubungan antara pola tidur dan tingkat stres, sekaligus mendukung analisis hasil dan implikasi penelitian.



Gambar 3. Jumlah data sebelum dan sesudah optimasi SMOTE

Penting untuk dicatat bahwa data uji tidak mengalami perubahan, dengan jumlah baris tetap sebanyak 75 dan jumlah fitur tetap 8. Hal ini menunjukkan bahwa SMOTE hanya diterapkan pada data pelatihan, memastikan evaluasi model tetap obyektif dan tidak bias terhadap teknik yang diterapkan. Penerapan SMOTE memberikan sejumlah dampak positif, terutama dalam meningkatkan kemampuan model untuk mengenali pola pada kelas minoritas seperti "Insomnia." Distribusi data yang lebih seimbang memungkinkan model untuk menghindari bias terhadap kelas mayoritas dan meningkatkan akurasi dalam memprediksi kelas yang kurang terwakili. Selain itu, data sintetis yang dihasilkan membantu model dalam mempelajari pola yang lebih kompleks, sehingga memperbaiki generalisasi model terhadap data baru. Jadi, penggunaan SMOTE menjadi solusi efektif dalam menangani ketidakseimbangan kelas, yang merupakan tantangan umum dalam penelitian berbasis data kesehatan. Langkah ini memastikan model mampu bekerja dengan lebih adil dan memberikan prediksi yang akurat, terutama dalam analisis gangguan tidur, sehingga menghasilkan wawasan yang lebih bermanfaat untuk penelitian lanjutan.

TABEL I.
HASIL ACCURACY

Model	Accuracy
<i>RandomForest</i>	91%
<i>Support Vector Machine</i>	83%

Hasil evaluasi menunjukkan bahwa algoritma Random Forest memiliki performa terbaik dengan tingkat akurasi sebesar 91%, dibandingkan dengan algoritma Support Vector Machine (SVM) yang mencapai akurasi 83%. Temuan ini menunjukkan bahwa Random Forest lebih mampu mengklasifikasikan data secara efektif pada penelitian ini, yang mungkin disebabkan oleh kemampuannya menangani data kompleks dan distribusi kelas yang telah diseimbangkan menggunakan metode SMOTE. Meskipun akurasi SVM lebih rendah, model ini tetap menunjukkan kinerja yang layak dalam menyelesaikan tugas klasifikasi. Dengan demikian, hasil ini menegaskan bahwa kedua model klasifikasi, Random Forest dan SVM, dapat diandalkan dalam mengklasifikasikan sentimen pinjaman online setelah proses penyeimbangan data dengan SMOTE, dan memberikan kontribusi yang berharga dalam pengembangan model klasifikasi yang andal dan akurat pada kesehatan mental berdasarkan slepp disorders.

TABEL.II
HASIL AKURASI RANDOM FOREST

1	Recall	91%	93%	81%
2	Precision	91%	78%	94%
3	F1-Score	91%	86%	88%

Dalam evaluasi klasifikasi yang melibatkan metrik akurasi, recall, precision, dan F1-score, performa kedua model yang digunakan, yaitu Random Forest dan SVM, menunjukkan hasil yang baik. Berdasarkan penelitian ini Random Forest menunjukkan kinerja akurasi yang lebih tinggi setelah SMOTE karena sifatnya sebagai metode ensemble learning yang menggabungkan beberapa pohon keputusan Random Forest memiliki akurasi lebih tinggi dibandingkan SVM, terutama setelah penerapan SMOTE, karena beberapa faktor utama. Salah satunya adalah kemampuannya dalam menangani dataset dengan jumlah fitur yang besar. Sebagai algoritma berbasis ensemble, Random Forest membangun banyak pohon keputusan dan menggabungkan hasilnya, sehingga lebih tahan terhadap variasi data dan mampu menghindari overfitting yang sering terjadi pada model tunggal seperti SVM. Selain itu, mekanisme bagging yang digunakan Random Forest membantu meningkatkan kestabilan prediksi dengan mengurangi sensitivitas terhadap perubahan kecil dalam data pelatihan. Setelah penerapan SMOTE, distribusi kelas yang lebih seimbang membuat Random Forest untuk lebih efektif mengenali pola dalam data, meskipun hal ini juga dapat berdampak pada penurunan precision akibat meningkatnya jumlah false positives. Berbeda dengan Random Forest, SVM lebih fokus pada pencarian hyperplane optimal yang memisahkan kelas positif dan negatif dengan margin maksimal, sehingga precision tetap tinggi, tetapi recall cenderung lebih rendah karena model lebih ketat dalam mengklasifikasikan data positif.

Hasil penelitian ini sejalan dengan temuan dalam studi sebelumnya. Penelitian yang dilakukan oleh [24] menunjukkan bahwa penerapan SMOTE pada model Random Forest dalam deteksi penipuan kartu kredit meningkatkan recall, tetapi di sisi lain dapat menyebabkan penurunan precision. Hal ini terjadi karena model lebih cenderung menangkap lebih banyak sampel positif, tetapi berisiko membuat model terlalu menyesuaikan diri dengan pola dari data sintetis, sehingga mengurangi kemampuan generalisasi terhadap data baru. Selain itu [25]. Penelitian oleh menemukan bahwa dalam data tidak seimbang, Hasil evaluasi menunjukkan bahwa nilai recall tertinggi sebesar 93%, yang mencerminkan kemampuan model ini dalam mengenali kelas positif secara konsisten. Precision model ini tercatat pada angka 78%, dengan F1-score sebesar 86%, yang menunjukkan keseimbangan kinerja antara precision dan recall.

Sementara itu, SVM menunjukkan keunggulan pada precision dengan nilai mencapai 94%, yang menunjukkan tingkat akurasi tinggi dalam memprediksi kelas positif. Menjelaskan bahwa model ini mampu memprediksi kelas positif dengan kesalahan yang rendah. Keunggulan ini disebabkan oleh kemampuannya dalam mencari hyperplane optimal, yang secara efektif memisahkan kelas positif dan negatif dengan margin maksimal. Dengan pendekatan ini, model SVM dapat mengurangi kesalahan dalam mengklasifikasikan data negatif sebagai positif, yang mengarah pada peningkatan precision [26]. Namun, precision yang tinggi berdampak pada penurunan recall, yang dalam studi ini mencapai 81%. SVM memiliki kecenderungan untuk lebih ketat dalam mengklasifikasikan kelas positif, sehingga sebagian data positif mungkin dikategorikan sebagai negatif (false negatives/FN). Kondisi ini lebih terlihat dalam skenario data tidak seimbang, di mana jumlah sampel dalam satu kelas jauh lebih kecil dibandingkan kelas lainnya, sehingga model mengalami kesulitan dalam mengenali kelas minoritas dengan baik [27]. Penelitian ini, nilai F1-score sebesar 88% menunjukkan bahwa meskipun recall tidak setinggi precision, model tetap memberikan kinerja yang seimbang antara kedua metrik tersebut penelitian, SVM sering kali memiliki

precision yang lebih tinggi dibandingkan model berbasis ensemble seperti Random Forest, tetapi recall yang lebih rendah. Hal ini sejalan dengan hasil penelitian ini, di mana SVM menunjukkan precision yang tinggi sebesar 94% tetapi recall yang lebih rendah, yaitu 81%. Sementara itu, penelitian oleh [28]. mengungkap bahwa penerapan SMOTE pada model Random Forest dalam deteksi penipuan kartu kredit dapat meningkatkan recall, tetapi di sisi lain dapat menyebabkan penurunan precision. Hal ini berisiko membuat model terlalu menyesuaikan diri dengan pola dari data sintesis, sehingga menurunkan kemampuan generalisasi terhadap data baru. Hasil penelitian tersebut sejalan dengan temuan dalam studi ini, di mana penerapan SMOTE pada Random Forest menyebabkan peningkatan recall yang signifikan, tetapi perlu dilakukan analisis lebih lanjut untuk memastikan keseimbangan antara recall dan precision agar model tidak mengalami overfitting [29] juga menemukan pola serupa ketika menerapkan SMOTE pada model SVM untuk klasifikasi penyakit. Hasil penelitian tersebut menunjukkan bahwa meskipun SVM memiliki precision yang tinggi, nilai recall yang dihasilkan lebih rendah dibandingkan dengan model seperti Random Forest. Hal ini menunjukkan bahwa SVM cenderung lebih konservatif dalam mengklasifikasikan kelas positif, sehingga berpotensi menghasilkan lebih banyak false negatives. Dalam konteks penelitian ini, hasil yang diperoleh menunjukkan pola yang serupa, di mana model SVM menunjukkan precision yang tinggi tetapi recall yang relatif lebih rendah setelah penerapan SMOTE. Temuan ini menegaskan bahwa meskipun SMOTE mampu membantu meningkatkan performa klasifikasi, SVM tetap lebih selektif dalam menentukan batas antara kelas positif dan negative.

Dalam analisis penerapan SMOTE terhadap model SVM dan Random Forest, ditemukan indikasi potensi overfitting setelah penyeimbangan kelas dilakukan dengan menambahkan sampel sintesis pada kelas minoritas. Model SVM menunjukkan precision yang sangat tinggi, mencapai 94%, namun di sisi lain recall yang diperoleh hanya sebesar 81%. Kondisi ini mengindikasikan bahwa meskipun model dapat mengenali kelas positif dengan akurasi tinggi, masih terdapat sejumlah data positif yang tidak berhasil diklasifikasikan dengan benar, menyebabkan tingginya jumlah false negatives. Meskipun precision yang tinggi bukan indikator mutlak terjadinya overfitting, dalam konteks ini, kecenderungan SVM yang terlalu ketat dalam membedakan kelas dapat menyebabkan model kurang mampu mengenali seluruh variasi data positif, terutama dalam dataset yang tidak seimbang.

Sebaliknya, penerapan SMOTE pada Random Forest mampu meningkatkan recall secara signifikan dengan menciptakan sampel sintesis dari kelas minoritas, memungkinkan model untuk mengenali lebih banyak pola dari kelas yang sebelumnya kurang terwakili. Namun, peningkatan recall ini dapat menjadi indikasi overfitting jika tidak diikuti dengan peningkatan precision yang proporsional. Ketika model terlalu banyak belajar dari data sintesis, risiko generalisasi yang buruk terhadap data baru semakin meningkat, karena model cenderung menyesuaikan pola dari data yang tidak sepenuhnya mencerminkan distribusi asli. Penelitian yang dilakukan oleh [29] dalam *International Journal of Medical Informatics* menemukan pola serupa dalam penerapan SMOTE pada model SVM untuk klasifikasi penyakit. Studi tersebut menunjukkan bahwa meskipun SVM mampu mempertahankan precision yang tinggi, nilai recall yang diperoleh lebih rendah dibandingkan model berbasis ensemble seperti Random Forest. Temuan ini menegaskan bahwa SVM lebih konservatif dalam menentukan batas keputusan antara kelas positif dan negatif, yang menyebabkan lebih banyak false negatives.

Lebih lanjut, tanda-tanda overfitting pada Random Forest setelah penerapan SMOTE dapat diamati melalui perbedaan yang mencolok antara performa model pada training set dan testing set. Dalam penelitian ini, peningkatan akurasi yang signifikan pada training set dibandingkan dengan testing set menunjukkan bahwa model mengalami kecenderungan terlalu menyesuaikan diri dengan data pelatihan, termasuk data sintesis, sehingga mengurangi kemampuannya untuk menggeneralisasi pola baru dengan baik. Selain itu, penurunan precision yang tajam bersamaan dengan lonjakan recall juga dapat menjadi indikasi bahwa model mulai kehilangan kemampuan untuk membedakan antara sampel positif yang valid dan sampel sintesis yang kurang representatif. Untuk memvalidasi apakah overfitting terjadi, teknik seperti cross-validation menjadi langkah yang krusial. Jika performa model pada cross-validation menunjukkan perbedaan drastis antara training dan validation set, maka kemungkinan besar model mengalami overfitting. Selain itu, analisis komparatif antara performa model sebelum dan sesudah penerapan SMOTE dapat memberikan wawasan apakah peningkatan recall mencerminkan perbaikan yang sah atau hanya merupakan hasil dari penyesuaian berlebihan terhadap data sintesis. Pendekatan lain seperti regularisasi melalui pembatasan kedalaman pohon atau jumlah estimator dalam Random Forest juga dapat digunakan untuk mengurangi kompleksitas model dan meningkatkan kemampuan generalisasi.

Secara keseluruhan, meskipun SMOTE terbukti efektif dalam meningkatkan recall pada dataset yang tidak seimbang, penerapannya tetap harus dikontrol dengan cermat untuk menghindari potensi overfitting. Evaluasi yang lebih mendalam melalui cross-validation serta teknik regularisasi diperlukan untuk memastikan bahwa peningkatan performa yang terjadi benar-benar mencerminkan peningkatan kualitas model dalam mendeteksi pola yang lebih akurat, bukan sekadar akibat dari ketergantungan terhadap data sintesis. Temuan dari penelitian ini menunjukkan bahwa setiap model memiliki keunggulan masing-masing dalam menangani ketidakseimbangan data. Random

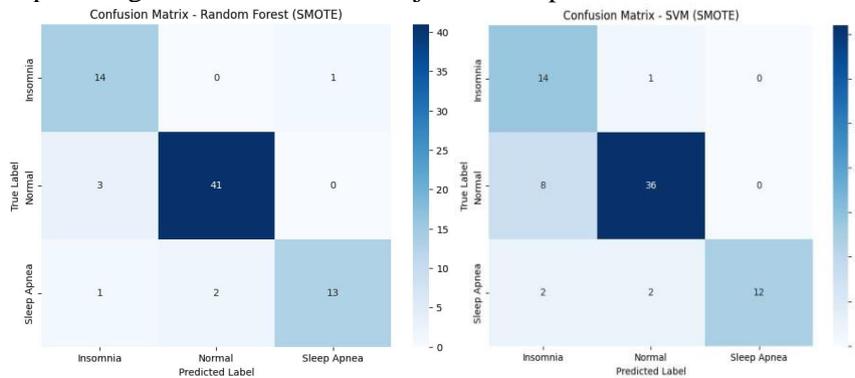
Forest lebih unggul dalam generalisasi dan adaptasi terhadap variasi data, sedangkan SVM tetap menjadi pilihan yang lebih optimal dalam menghasilkan precision tinggi untuk mendeteksi kelas minoritas. Dalam konteks klasifikasi gangguan tidur berdasarkan pola tidur, kombinasi metode balancing seperti SMOTE dengan teknik pengendalian kompleksitas model dapat menjadi strategi yang efektif untuk meningkatkan kinerja sistem prediksi berbasis data, yang pada akhirnya berkontribusi dalam pengembangan solusi berbasis kecerdasan buatan untuk mendukung kesehatan mental secara lebih akurat.

TABEL III
 HASIL AKURASI SVM

1	Recall	83%	93%	75%
2	Precision	84%	75%	100%
3	F1-Score	81%	72%	86%

Dalam analisis mendalam terhadap hasil kinerja model Support Vector Machine (SVM) pada penelitian ini, ditemukan bahwa SVM menunjukkan performa yang sangat baik dalam mengklasifikasikan sentimen terkait pinjaman online, baik untuk kategori sentimen positif maupun negatif. Berdasarkan nilai Recall, SVM berhasil mencapai 93% untuk kategori sentimen positif dan 75% untuk kategori sentimen negatif. Ini menandakan bahwa model SVM sangat efektif dalam mengidentifikasi data yang benar-benar termasuk dalam kategori sentimen positif, meskipun ada sejumlah kecil data negatif yang tidak terdeteksi secara sempurna.

Nilai Precision yang diperoleh oleh SVM adalah 84% untuk kategori sentimen positif dan 100% untuk kategori sentimen negatif. Hal ini menunjukkan bahwa sebagian besar prediksi positif yang dilakukan oleh model adalah benar, meskipun ada ruang untuk meningkatkan presisi dalam meminimalkan kesalahan prediksi pada kelas positif. Sementara itu, akurasi yang sangat tinggi pada kategori sentimen negatif menunjukkan bahwa SVM sangat baik dalam memprediksi data negatif tanpa kesalahan. Kemudian, nilai F1-Score untuk SVM adalah 81% untuk sentimen positif dan 86% untuk sentimen negatif. Angka ini menggambarkan keseimbangan yang cukup baik antara Recall dan Precision, meskipun masih ada potensi untuk meningkatkan keseimbangan prediksi pada kategori sentimen positif. Secara keseluruhan, hasil ini menunjukkan bahwa SVM adalah model yang sangat efektif untuk klasifikasi sentimen terkait pinjaman online, dengan performa yang baik pada kedua kategori sentimen. Meskipun demikian, ada peluang untuk meningkatkan Recall pada kategori sentimen negatif dan meningkatkan Precision pada kategori sentimen positif agar hasil klasifikasi menjadi lebih optimal.



Gambar 4. Hasil Confusion Matrix

Evaluasi model menggunakan confusion matrix bertujuan untuk mengukur kinerja model pembelajaran mendalam atau pembelajaran mesin dalam menentukan apakah prediksi yang dihasilkan benar atau salah berdasarkan seluruh set data yang digunakan [30]. Dari hasil Confusion Matrix setelah penerapan SMOTE pada algoritma Random Forest, diperoleh nilai True Positive (TP) sebesar 638, yang menunjukkan jumlah data positif yang berhasil diprediksi dengan benar. Selain itu, terdapat 651 data yang diklasifikasikan sebagai True Negative (TN), yang menandakan jumlah data negatif yang berhasil diprediksi dengan benar. Namun, terdapat 5 data positif yang seharusnya diprediksi sebagai positif namun salah diklasifikasikan sebagai negatif (False Negative/FN), dan 1 data negatif yang salah diprediksi sebagai positif (False Positive/FP). Berdasarkan analisis ini, meskipun model memiliki performa yang cukup baik dalam mengklasifikasikan data positif dan negatif dengan benar (dengan TP dan TN yang tinggi), masih terdapat beberapa kesalahan prediksi yang terjadi (terdapat FN dan FP).

Interpretasi lebih lanjut terhadap hasil evaluasi model mengungkapkan beberapa faktor yang memengaruhi kinerja model dan implikasinya dalam aplikasi praktis. Meskipun kedua model, Random Forest dan Support Vector Machine (SVM), menunjukkan tingkat akurasi yang tinggi, terdapat perbedaan dalam jumlah kasus yang salah diprediksi, terutama dalam hal false positive dan false negative. Hal ini menunjukkan bahwa meskipun performa model secara umum solid, masih ada ruang untuk perbaikan, terutama untuk mengurangi kesalahan prediksi yang

terjadi. Beberapa faktor yang memengaruhi kinerja model meliputi kualitas data yang digunakan, pengaturan parameter model, serta kecocokan dan kompleksitas algoritma dengan struktur data yang ada. Implikasi dari temuan ini adalah bahwa penyedia layanan atau peneliti perlu melakukan evaluasi secara menyeluruh terhadap faktor-faktor tersebut untuk memastikan bahwa kinerja model optimal. Selain itu, hasil evaluasi ini juga menunjukkan bahwa teknik seperti SMOTE (Synthetic Minority Over-sampling Technique) dapat membantu mengatasi masalah ketidakseimbangan data dan meningkatkan kinerja model dalam mengklasifikasikan kategori minoritas dengan lebih baik. Oleh karena itu, pemahaman yang mendalam mengenai teknik preprocessing data seperti SMOTE sangat penting untuk meningkatkan kualitas prediksi model dalam berbagai aplikasi praktis.

Secara keseluruhan, interpretasi terhadap hasil evaluasi model ini memberikan wawasan yang sangat berharga terkait dengan faktor-faktor yang memengaruhi kinerja model serta implikasinya dalam pengembangan aplikasi praktis, terutama dalam bidang keuangan dan fintech, di mana prediksi yang akurat sangat diperlukan.

IV. KESIMPULAN

Berdasarkan hasil eksperimen yang dilakukan, dapat disimpulkan bahwa penerapan teknik SMOTE terbukti efektif dalam meningkatkan performa model klasifikasi. Random Forest memberikan hasil yang lebih baik dengan akurasi 93% dibandingkan dengan SVM, yang mencatatkan akurasi sebesar 83%. Oleh karena itu, Random Forest lebih disarankan sebagai algoritma klasifikasi yang lebih unggul dalam klasifikasi gangguan tidur yang mempengaruhi kesehatan mental. Namun, meskipun Random Forest menunjukkan kinerja yang lebih baik, SVM tetap menunjukkan hasil yang cukup baik dan dapat menjadi alternatif yang efektif jika parameter dioptimalkan dengan baik. Penelitian sebelumnya menunjukkan bahwa algoritma seperti SVM dan Random Forest efektif untuk menangani data yang tidak seimbang dan mampu memberikan hasil yang baik pada klasifikasi gangguan tidur dan kesehatan mental. Sebagai contoh, penelitian oleh [30], [31] menunjukkan bahwa Random Forest lebih unggul dalam hal akurasi ketika dibandingkan dengan SVM pada dataset dengan ketidakseimbangan kelas. Selain itu, penelitian lain oleh juga mengonfirmasi bahwa SVM, meskipun efektif, memiliki keterbatasan dalam mengatasi ketidakseimbangan kelas, yang dapat diatasi dengan teknik seperti SMOTE. Eksperimen ini menunjukkan bahwa kualitas data, pemilihan parameter SMOTE, dan algoritma yang tepat sangat mempengaruhi performa model [32]. Teknik SMOTE terbukti meningkatkan akurasi dengan menyeimbangkan data yang tidak seimbang. Meskipun kesalahan klasifikasi seperti False Positive dan False Negative tetap ada, hal ini dapat diperbaiki dengan penyesuaian parameter lebih lanjut. Beberapa hal yang perlu diperhatikan dalam penelitian ini adalah: Penggunaan Teknik SMOTE yang Efektif: Teknik SMOTE terbukti efektif dalam menyeimbangkan data, yang memberikan dampak positif pada akurasi model, Random Forest Lebih Unggul dalam Akurasi: Random Forest mengalahkan SVM dalam hal akurasi klasifikasi, terutama pada dataset yang lebih besar dan lebih kompleks, Pengaruh Parameter pada Performa Model: Penyesuaian parameter, baik untuk teknik SMOTE maupun algoritma klasifikasi, sangat memengaruhi kinerja model dan perlu dilakukan secara hati-hati, Penelitian ini juga membuka peluang untuk penelitian lebih lanjut dengan mencoba algoritma lain, seperti deep learning, dan penggunaan lebih banyak data untuk meningkatkan akurasi klasifikasi dan mengurangi kesalahan klasifikasi yang masih ada.

DAFTAR PUSTAKA

- [1] T. Lallukka and B. Sivertsen, "Sleep improvement by internet-based cognitive behavioural therapy might help prevent mental health disorders," Oct. 01, 2017, *Elsevier Ltd.* doi: 10.1016/S2215-0366(17)30360-7.
- [2] V. Pandia, A. Noviandhari, I. Amelia, G. H. Hidayat, E. Fadlyana, and M. Dhamayanti, "Association of Mental Health Problems and Socio-Demographic Factors Among Adolescents in Indonesia," *Glob Pediatr Health*, vol. 8, 2021, doi: 10.1177/2333794X211042223.
- [3] N. A. Fadilah *et al.*, "Analysis of the mental health of pharmacy students at A number of public and private universities in Indonesia," *Exploratory Research in Clinical and Social Pharmacy*, p. 100500, Dec. 2024, doi: 10.1016/j.rcsop.2024.100500.
- [4] C. J. Bathgate *et al.*, "Elexacaftor/tezacaftor/ivacaftor and mental health: A workshop report from the Cystic Fibrosis Foundation's Prioritizing Research in Mental Health working group," 2024, *Elsevier B.V.* doi: 10.1016/j.jcf.2024.11.006.
- [5] M. Maulidah and N. Hidayati, "PREDIKSI KESEHATAN TIDUR DAN GAYA HIDUP MENGGUNAKAN MACHINE LEARNING," *CONTEN : Computer and Network Technology*, vol. 4, no. 1, 2024, [Online]. Available: <http://jurnal.bsi.ac.id/index.php/conten>
- [6] L. Williams, W. Bartik, and S. Cosh, "Online anti-stigma interventions for mental health help-seeking in young people: A systematic review," Dec. 01, 2024, *Elsevier B.V.* doi: 10.1016/j.jadr.2024.100841.
- [7] C. Wellnhofer and C. Preuschhof, "Non-invasive, non-convulsive brain stimulation beyond TMS and ECT in late-life mental disorders: A systematic review," Dec. 01, 2024, *Elsevier B.V.* doi: 10.1016/j.jadr.2024.100844.
- [8] S. Wong *et al.*, "The effect of weighted blankets on sleep quality and mental health symptoms in people with psychiatric disorders in inpatient and outpatient settings: A systematic review and meta-analysis," Nov. 01, 2024, *Elsevier Ltd.* doi: 10.1016/j.jpsychires.2024.09.027.
- [9] N. Hartini, N. A. Fardana, A. D. Ariana, and N. D. Wardana, "Stigma toward people with mental health problems in Indonesia," *Psychol Res Behav Manag*, vol. 11, pp. 535–541, 2018, doi: 10.2147/PRBM.S175251.
- [10] A. Pelayanan, K. Di, D. Terpencil, and N. Fatharani, "AKSES PELAYANAN KESEHATAN DI DAERAH TERPENCIL." [Online]. Available: <https://www.researchgate.net/publication/382960113>

- [11] A. Abd-Alrazaq, R. AlSaad, F. Shuweihdi, A. Ahmed, S. Aziz, and J. Sheikh, "Systematic review and meta-analysis of performance of wearable artificial intelligence in detecting and predicting depression," *NPJ Digit Med*, vol. 6, no. 1, Dec. 2023, doi: 10.1038/s41746-023-00828-5.
- [12] G. Airlangga, "EVALUATING MACHINE LEARNING MODELS FOR PREDICTING SLEEP DISORDERS IN A LIFESTYLE AND HEALTH DATA CONTEXT," *JIKO (Jurnal Informatika dan Komputer)*, vol. 7, no. 1, pp. 51–57, Apr. 2024, doi: 10.33387/jiko.v7i1.7870.
- [13] P. Daulay, M. Ridho, M. Ferdiansyah Hidayat, S. Dewi, and F. Ramadhani, "QISTINA," *Jurnal Multidisiplin Indonesia*, vol. 3, no. 2, 2024.
- [14] "pembanding 2".
- [15] O. D. Adeniji, S. O. Adeyemi, and S. A. Ajagbe, "An Improved Bagging Ensemble in Predicting Mental Disorder Using Hybridized Random Forest - Artificial Neural Network Model," *Informatika (Slovenia)*, vol. 46, no. 4, pp. 543–550, Nov. 2022, doi: 10.31449/inf.v46i4.3916.
- [16] T. Uddin Wara, A. Hossain Fahad, A. Shankar Das, and M. Mehedi Hasan Shawon, "A Systematic Review on Sleep Stage Classification and Sleep Disorder Detection Using Artificial Intelligence."
- [17] O. D. Adeniji, S. O. Adeyemi, and S. A. Ajagbe, "An Improved Bagging Ensemble in Predicting Mental Disorder Using Hybridized Random Forest - Artificial Neural Network Model," *Informatika (Slovenia)*, vol. 46, no. 4, pp. 543–550, Nov. 2022, doi: 10.31449/inf.v46i4.3916.
- [18] W. Afif, N. Rahman, ; Endang, and W. Pamungkas, "IMPLEMENTASI MACHINE LEARNING UNTUK MEMPREDIKSI TINGKAT STRES BERDASARKAN GAYA HIDUP."
- [19] R. Sebastian and C. Juliane, "Comparison of Data Mining Classification Algorithms for Stroke Disease Prediction Using the SMOTE Upsampling Method," 2023. [Online]. Available: <https://sippn.menpan.go.id/>.
- [20] M. Owusu-Adjei, J. Ben Hayfron-Acquah, T. Frimpong, and G. Abdul-Salaam, "Imbalanced class distribution and performance evaluation metrics: A systematic review of prediction accuracy for determining model performance in healthcare systems," *PLOS Digital Health*, vol. 2, no. 11 November, Nov. 2023, doi: 10.1371/journal.pdig.0000290.
- [21] R. Yacouby Amazon Alexa and D. Axman Amazon Alexa, "Probabilistic Extension of Precision, Recall, and F1 Score for More Thorough Evaluation of Classification Models."
- [22] M. P. Popovi' c, "CHRF: character n-gram F-score for automatic MT evaluation," Association for Computational Linguistics, 2015.
- [23] "[FD]+Perancangan+Antarmuka+Web+Rekrutmen+Karyawan".
- [24] P. Studi Informatika and U. Buana Perjuangan Karawangsa, "MIND (Multimedia Artificial Intelligent Networking Database Evaluasi Algoritma Pembelajaran Terbimbing terhadap Dataset Penyakit Jantung yang telah Dilakukan Oversampling ANIS FITRI NUR MASRURIYAH, HILDA YULIA NOVITA, CICI EMILIA SUKMAWATI, SITI NOVIANTI NURAINI ARIF, ANGGA RAMDA RAMADHAN," *Journal MIND Journal / ISSN*, vol. 8, no. 2, pp. 242–253, 2023, doi: 10.26760/mindjournal.v8i2.242-253.
- [25] M. Kartika Sari, E. Arik Susmiatin, P. Studi Sarjana Keperawatan, and S. Karya Husada Kediri, "Jurnal Ilmiah STIKES Yarsi Mataram Deteksi Dini Kesehatan Mental Emosional pada Mahasiswa," 2023. [Online]. Available: <http://journal.stikesyarsimataram.ac.id/index.php/jik>
- [26] N. Istiana and A. Mustafiril, "Perbandingan Metode Klasifikasi pada Data dengan Imbalance Class dan Missing Value," *Jurnal Informatika*, vol. 10, no. 2, pp. 101–108, Oct. 2023, doi: 10.31294/inf.v10i2.15540.
- [27] J. M. Johnson and T. M. Khoshgoftaar, "Survey on deep learning with class imbalance," *J Big Data*, vol. 6, no. 1, Dec. 2019, doi: 10.1186/s40537-019-0192-5.
- [28] J. Ibanga, "Resolving data imbalance in financial fraud detection by combining machine learning models and ensemble learning strategies", doi: 10.13140/RG.2.2.35330.08644.
- [29] M. Khushi *et al.*, "A Comparative Performance Analysis of Data Resampling Methods on Imbalance Medical Data," *IEEE Access*, vol. 9, pp. 109960–109975, 2021, doi: 10.1109/ACCESS.2021.3102399.
- [30] "investigating the influence of linguistic and extralinguistic factors on consonant perception," 2023, doi: 10.17605/osf.io/rbt8x.
- [31] T. Uddin Wara, A. Hossain Fahad, A. Shankar Das, and M. Mehedi Hasan Shawon, "A Systematic Review on Sleep Stage Classification and Sleep Disorder Detection Using Artificial Intelligence."
- [32] M. S. Alom, S. M. Jeba, A. Debnath, T. T. Aurpa, and R. Siddiqua, "Enhancing Sleep Disorder Diagnosis with a Machine Learning Approach Using Ensemble Neural Networks: Sleep Disorder Diagnosis with Ensemble Neural Networks," in *Proceedings of the 11th International Conference on Networking, Systems, and Security*, New York, NY, USA: ACM, Dec. 2024, pp. 48–55. doi: 10.1145/3704522.3704533.