



## **OPTIMASI KLASIFIKASI GANGGUAN TIDUR PADA DATASET TIDAK SEIMBANG MENGUNAKAN SMOTE DAN ALGORITMA MACHINE LEARNING**

**Titik Misriati<sup>1)</sup>, Riska Aryanti<sup>\*2)</sup>**

<sup>1,2</sup>Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika

<sup>1,2</sup>Jalan Kramat Raya No 98, Jakarta Pusat, DKI Jakarta

Email: <sup>1</sup>titik.tmi@bsi.ac.id, <sup>2\*</sup>riska.rts@bsi.ac.id

### **Abstract**

*Sleep disorders are increasingly common health problems that have a significant impact on quality of life. Early detection and classification of sleep disorders is crucial to support proper diagnosis and effective clinical decision-making. However, the classification process of sleep disorders often faces challenges due to the imbalance of data distribution, where the amount of data from the majority class is much more than the minority class. This causes the predictive model to be biased towards the majority class, thus degrading the overall classification performance. This study aims to optimize the performance of sleep disorder classification on unbalanced datasets by applying Synthetic Minority Over-sampling Technique (SMOTE) as a data balancing method, as well as evaluating the effectiveness of several machine learning algorithms in detecting sleep disorders. The algorithms used include Random Forest (RF), Neural Network (NN), Naive Bayes (NB), K-Nearest Neighbor (KNN), Support Vector Machine (SVM), and Logistic Regression (LR), both before and after the application of SMOTE. Performance evaluation was conducted using accuracy, precision, recall, and F1-score metrics to ensure comprehensive results. The results showed that the application of SMOTE consistently improved the performance of all tested algorithms. The Neural Network model with SMOTE produced the highest performance with an accuracy of 92.00%, precision of 91.88%, recall of 92.00%, and F1-score of 91.91%. Meanwhile, the Random Forest algorithm with SMOTE gave the highest F1-score of 93.18%, showing superior performance stability in classification. This performance improvement confirms that combining oversampling techniques with machine learning algorithms can overcome data imbalance and produce more accurate and reliable predictions. This research makes a significant contribution to the development of sleep disorder classification systems based on imbalanced data and can be used as a reference in artificial intelligence-based medical decision support systems.*

**Keyword:** *sleep disorder, classification, machine learning, SMOTE, imbalanced data.*

### **Abstrak**

Gangguan tidur merupakan masalah kesehatan yang semakin umum terjadi dan berdampak signifikan terhadap kualitas hidup seseorang. Deteksi dan klasifikasi gangguan tidur secara dini menjadi sangat penting untuk mendukung diagnosis yang tepat dan pengambilan keputusan klinis yang efektif. Namun, proses klasifikasi gangguan tidur sering menghadapi tantangan akibat ketidakseimbangan distribusi data, di mana jumlah data dari kelas mayoritas jauh lebih banyak dibandingkan kelas minoritas. Hal ini menyebabkan model prediktif cenderung bias terhadap kelas mayoritas, sehingga menurunkan performa klasifikasi secara keseluruhan. Penelitian ini bertujuan untuk mengoptimalkan kinerja klasifikasi gangguan tidur pada dataset tidak seimbang dengan menerapkan SMOTE sebagai metode penyeimbang data, serta mengevaluasi efektivitas beberapa algoritma machine learning dalam mendeteksi gangguan tidur. Algoritma yang digunakan meliputi Random Forest, Neural Network, Naive Bayes, K-Nearest Neighbor, Support Vector Machine, dan Logistic Regression, baik sebelum maupun sesudah penerapan SMOTE. Evaluasi performa dilakukan menggunakan metrik akurasi, presisi, *recall*, dan *F1-score* untuk memastikan hasil yang komprehensif. Hasil penelitian menunjukkan bahwa penerapan SMOTE secara konsisten meningkatkan kinerja seluruh algoritma yang diuji. Model Neural Network dengan SMOTE menghasilkan performa tertinggi dengan akurasi sebesar 92,00%, presisi 91,88%, *recall* 92,00%, dan *F1-score* 91,91%. Sementara itu, algoritma Random Forest dengan SMOTE memberikan *F1-score* tertinggi sebesar 93,18%, menunjukkan kestabilan performa yang unggul dalam klasifikasi. Peningkatan performa ini menegaskan bahwa penggabungan teknik *oversampling* dengan algoritma pembelajaran mesin mampu mengatasi ketidakseimbangan data dan menghasilkan prediksi yang lebih akurat dan andal. Penelitian ini memberikan kontribusi signifikan terhadap pengembangan sistem klasifikasi gangguan tidur berbasis data tidak seimbang dan dapat dijadikan referensi dalam sistem pendukung keputusan medis berbasis kecerdasan buatan.

**Kata Kunci:** Gangguan Tidur, Klasifikasi, Machine Learning, SMOTE, Ketidakseimbangan Data.



## 1. PENDAHULUAN

Gangguan tidur merupakan masalah kesehatan yang semakin sering ditemukan di masyarakat modern. Pola hidup yang tidak teratur, stress [1], serta penggunaan perangkat elektronik secara berlebihan menjadi beberapa faktor penyebab utama meningkatnya prevalensi gangguan tidur. Dampak dari gangguan tidur tidak hanya terbatas pada kelelahan dan penurunan konsentrasi, tetapi juga berhubungan erat dengan risiko penyakit kronis seperti diabetes, depresi, dan penyakit kardiovaskular. Oleh karena itu, deteksi dini gangguan tidur menjadi langkah penting dalam upaya pencegahan dan penanganan yang lebih efektif.

Perkembangan teknologi kecerdasan buatan, khususnya *machine learning*, telah memberikan peluang besar dalam bidang analisis data kesehatan. Berbagai algoritma *machine learning* telah digunakan untuk mendeteksi pola dalam data gangguan tidur, termasuk Random Forest, Naive Bayes, K-Nearest Neighbor, Support Vector Machine, Logistic Regression, dan Neural Network. Algoritma-algoritma tersebut memiliki karakteristik dan pendekatan berbeda dalam memproses data, sehingga evaluasi performa masing-masing algoritma menjadi hal yang penting untuk dilakukan guna menemukan metode klasifikasi yang paling efektif.

Namun, tantangan utama dalam penerapan *machine learning* untuk klasifikasi gangguan tidur adalah adanya ketidakseimbangan kelas dalam dataset. Data yang merepresentasikan individu dengan gangguan tidur seringkali berjumlah lebih sedikit dibandingkan data individu tanpa gangguan tidur. Ketidakseimbangan distribusi antar kelas pada dataset merupakan permasalahan yang kerap ditemui dalam penelitian klasifikasi, khususnya di bidang medis [2], [3], [4]. Kondisi ini menyebabkan model pembelajaran mesin lebih cenderung memprediksi kelas mayoritas, sehingga menurunkan kemampuan model dalam mengenali kelas minoritas yang sering kali memuat informasi krusial bagi pengambilan keputusan klinis. Oleh karena itu, penanganan terhadap ketimpangan data menjadi salah satu aspek penting yang perlu diperhatikan dalam klasifikasi. *Synthetic Minority Over-sampling Technique* (SMOTE) menjadi solusi dalam menangani ketidakseimbangan data. SMOTE bekerja dengan menciptakan sampel sintesis dari kelas minoritas berdasarkan data yang sudah ada, sehingga distribusi antar kelas menjadi lebih seimbang. Dengan demikian, algoritma *machine learning* dapat belajar secara lebih merata dan menghasilkan performa klasifikasi yang lebih baik, khususnya dalam mengenali data dari kelas yang sebelumnya terpinggirkan.

Penelitian mengenai klasifikasi gangguan tidur dengan menggunakan algoritma *machine learning* telah mengalami perkembangan pesat dalam beberapa tahun terakhir. Berbagai algoritma seperti Random Forest, Support Vector Machine, Neural Network (NN), hingga metode berbasis genetika telah diterapkan untuk mengidentifikasi gangguan tidur. Beberapa penelitian tentang klasifikasi gangguan tidur menghasilkan tingkat akurasi mencapai 81%-88% [5], [6], [7]. Namun dalam penelitian tersebut belum menerapkan teknik ketidakseimbangan kelas (*imbalance class*) yang muncul dalam dataset gangguan tidur. Data gangguan tidur memiliki distribusi kelas yang tidak seimbang, di mana jumlah data dari kelas *none* jauh lebih banyak dibanding kelas yang memiliki gangguan tidur. Kondisi ini dapat menyebabkan model klasifikasi menjadi bias terhadap kelas mayoritas dan mengabaikan akurasi prediksi pada kelas minoritas yang justru lebih krusial secara klinis. Penelitian yang mencoba mengatasi permasalahan ini dengan menggunakan teknik SMOTE untuk menyeimbangkan data dan menunjukkan adanya peningkatan akurasi yang cukup signifikan [8], [9], [10]. Namun, penelitian tersebut masih terbatas pada kombinasi algoritma tertentu. Selain itu, terdapat perbedaan dalam metode pembagian data antar penelitian, yang menyulitkan dalam melakukan perbandingan hasil secara objektif. Misalnya, beberapa studi menggunakan metode *split data* dengan rasio yang bervariasi, sementara yang lain menggunakan *cross validation*.

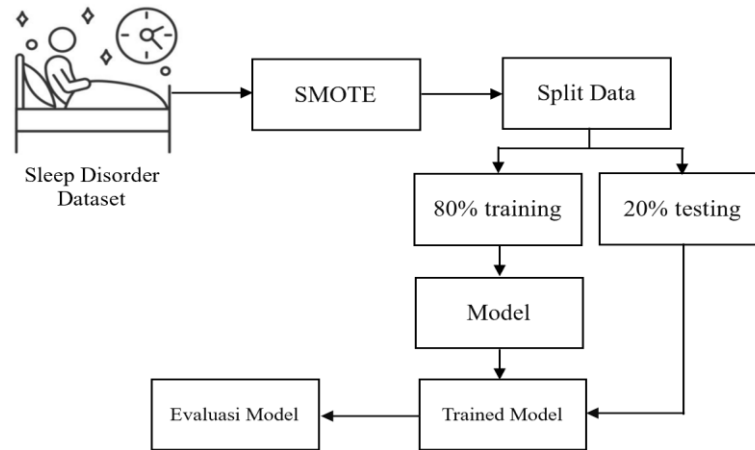
Berdasarkan hal tersebut, penelitian ini dilakukan untuk mengisi kesenjangan yang ada dengan cara melakukan evaluasi terhadap kinerja beberapa algoritma klasifikasi termasuk Random Forest, Naive Bayes, K-Nearest Neighbors, SVM, Logistic Regression, dan Neural Network dengan data tidak seimbang yang ditangani dengan SMOTE. Penelitian ini juga menggunakan pembagian data 80%:20% yang konsisten pada setiap algoritma yang digunakan untuk menjaga validitas perbandingan performa antar model. Penelitian ini bertujuan untuk mengevaluasi efektivitas metode SMOTE dalam mengatasi ketidakseimbangan kelas pada dataset gangguan tidur serta membandingkan kinerja beberapa algoritma *machine learning* dalam proses klasifikasi. Dengan melakukan eksperimen terhadap data yang telah diseimbangkan, diharapkan diperoleh model klasifikasi yang optimal dan mampu digunakan sebagai dasar dalam pengembangan sistem deteksi gangguan tidur berbasis data. Penelitian ini juga diharapkan dapat memberikan kontribusi terhadap literatur terkait klasifikasi pada data medis tidak seimbang.

## 2. METODE PENELITIAN

Data terlebih dahulu melalui tahap pra proses dengan menghapus nilai yang hilang, kemudian dinormalisasi menggunakan teknik *Standard Scaler*. Setelah itu, diterapkan teknik SMOTE untuk mengatasi ketidakseimbangan kelas dalam dataset. Selanjutnya, berbagai algoritma *machine learning* diterapkan pada dataset yang telah diproses, dan hasil



prediksi dari masing-masing model dievaluasi menggunakan metrik performa klasifikasi. Tujuan utama dari proses ini adalah untuk mengidentifikasi algoritma yang memberikan hasil klasifikasi paling optimal terhadap dataset yang digunakan. Gambar 1 menunjukkan tahapan penelitian yang dilakukan.



**Gambar 1.** Tahapan Penelitian

**2.1 Dataset**

Data yang digunakan berupa data *Sleep Health and Lifestyle* terdiri dari 374 record dan 13 atribut, yang mencakup berbagai atribut tentang tidur dan kebiasaan sehari-hari. Kumpulan data ini mencakup detail seperti jenis kelamin, usia, pekerjaan, durasi tidur, kualitas tidur, tingkat aktivitas fisik, tingkat stres, kategori BMI, tekanan darah, detak jantung, langkah harian, dan ada atau tidaknya gangguan tidur. Pemilihan atribut dalam penelitian ini didasarkan pada pentingnya atribut-atribut tersebut dalam memprediksi gangguan tidur. Atribut pada dataset ditunjukkan pada Tabel 1 digunakan dalam penelitian ini.

**Tabel 1.** Deskripsi Dataset

No	Atribut	Tipe Data	Deskripsi
1	Person ID	Numerik	Pengenal untuk setiap individu
2	Gender	Kategorikal	Jenis kelamin terdiri dari pria dan Wanita
3	Age	Numerik	Usia
4	Occupation	Kategorikal	Pekerjaan
5	Sleep Duration	Numerik	Durasi tidur per hari (dalam jam)
6	Quality of Sleep	Numerik	Kualitas tidur (0 sampai 10)
7	Physical Activity Level	Numerik	Aktivitas Fisik setiap hari (dalam menit)
8	Stress Level	Numerik	Tingkat stres (0 sampai 10)
9	BMI Category	Kategorikal	Kategori Indeks Massa Tubuh (berat badan kurang, normal, berat badan berlebih)
10	Blood Pressure	Numerik	Tekanan darah
11	Heart Rate	Numerik	Denyut jantung per menit
12	Daily Steps	Numerik	Jumlah langkah per hari
13	Gangguan Tidur	Kategorikal	Gangguan tidur ( <i>none, sleep apnea, insomnia</i> )

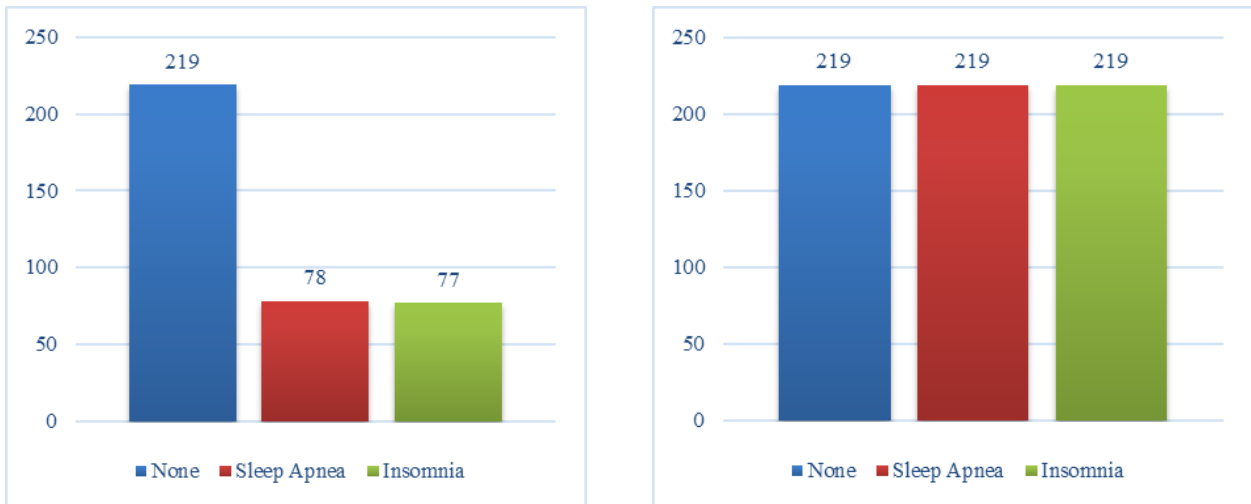
Tabel 1 juga menjelaskan makna dari masing-masing atribut serta hubungannya dengan kemungkinan terjadinya gangguan tidur. Dari 13 atribut tersebut, hanya 11 atribut digunakan dalam proses prediksi dan 1 atribut pengenal tidak digunakan dalam proses prediksi. Atribut target digunakan sebagai variabel *output* yang menunjukkan apakah seseorang mengalami gangguan tidur atau tidak. Sebelum model klasifikasi diterapkan, dataset diproses terlebih dahulu melalui beberapa tahap pra pemrosesan. Pertama, data dinormalisasi ke dalam rentang 0 hingga 1 untuk meningkatkan kinerja model. Target berupa *multiclass*, yaitu *none* yang menunjukkan tidak ada gangguan tidur, *insomnia* menunjukkan gangguan tidur yang menyebabkan seseorang kesulitan untuk tidur sehingga kualitas tidur tidak memadai (buruk), dan



*sleep apnea* menunjukkan gangguan tidur yang disebabkan oleh jeda dalam bernapas saat tidur sehingga mengakibatkan pola tidur terganggu dan potensi risiko kesehatan.

**2.2 SMOTE**

SMOTE adalah metode oversampling dan telah banyak digunakan untuk menangani data kelas yang tidak seimbang [11]. Penelitian ini menerapkan SMOTE yang ditunjukkan pada Gambar 2, dimana kelas *none*, *sleep apnea*, dan *insomnia* yang sebelumnya tidak seimbang menjadi seimbang dengan masing-masing 219 data.



**Gambar 2.** Distribusi Kelas Sebelum dan Setelah SMOTE

**2.3 Model Machine Learning**

Penelitian ini menggunakan enam algoritma *machine learning*, yaitu:

- a. Random Forest (RF)  
 Random Forest adalah algoritma yang membangun struktur pohon keputusan dengan menerapkan proses pemisahan biner secara berulang hingga mencapai simpul akhir, berdasarkan prinsip kerja pohon klasifikasi dan regresi [12], [13], [14].
- b. Naive Bayes (NB)  
 Naive Bayes merupakan algoritma klasifikasi berbasis probabilistik [15], bekerja dengan menghitung kemungkinan suatu kelas berdasarkan fitur-fitur yang dimiliki oleh data, dengan asumsi bahwa setiap fitur tidak saling bergantung satu sama lain [16], [17].
- c. K-Nearest Neighbor (KNN)  
 K-Nearest Neighbor (K-NN) adalah algoritma klasifikasi non-parametrik [18] yang mengelompokkan data baru berdasarkan kedekatannya dengan sejumlah data terdekat di ruang fitur [19].
- d. Support Vector Machine (SVM)  
 Support Vector Machine merupakan algoritma klasifikasi yang mencari hyperplane optimal [20], [21] untuk memaksimalkan jarak antara titik data terdekat dari masing-masing kelas [22].
- e. Logistic Regression (LR)  
 Logistic Regression merupakan algoritma klasifikasi yang memodelkan hubungan antara variabel input dan probabilitas suatu kelas dengan menggunakan fungsi logistik (sigmoid) [23].
- f. Neural Network (NN)  
 Neural Network adalah arsitektur algoritma *machine learning* yang menggunakan lapisan-lapisan neuron buatan, di mana setiap neuron menerima input, mengalikannya dengan bobot, menjumlahkannya, menerapkan fungsi aktivasi, dan meneruskan hasilnya ke neuron lain [24], [25].

**2.4 Evaluasi Model**

Model yang telah dilatih diuji menggunakan data uji. Evaluasi performa dilakukan dengan menggunakan matrik klasifikasi sesuai Tabel 2.



**Tabel 2.** Matrik Klasifikasi

Matrik	Deskripsi
Akurasi [26], [27], [28]	proporsi prediksi yang benar terhadap total data
<i>Precision</i> [23], [24]	proporsi prediksi positif yang benar terhadap seluruh prediksi positif
<i>Recall</i> [23], [24]	proporsi data positif yang berhasil diprediksi dengan benar
F1-Score [23], [24]	harmonisasi antara <i>precision</i> dan <i>recall</i>

### 3. HASIL DAN PEMBAHASAN

Dataset yang digunakan dalam penelitian ini adalah dataset *Sleep Health and Lifestyle*. Dataset yang diunduh dari situs web Kaggle [29]. Dataset dataset asli mencakup 374 data dan 13 kolom. Setiap data pengamatan mewakili keadaan tidur yang sebenarnya. Data ini dapat dikategorikan menjadi 13 variabel yang relevan dengan tidur dan kebiasaan sehari-hari, seperti jenis kelamin, usia, pekerjaan, durasi tidur, dan kualitas tidur. Kolom 13 menyajikan gangguan tidur untuk setiap orang. Tabel 3 menyajikan contoh dari dataset.

**Tabel 3.** Dataset Gangguan Tidur

ID	Gender	Age	Occupation	SD	QoS	PAL	SL	BMI Category	BP	HR	Daily Steps	Sleep Disorder
1	Male	27	Software Engineer	6.1	6	42	6	Overweight	126/83	77	4200	None
2	Male	28	Doctor	6.2	6	60	8	Normal	125/80	75	10000	None
4	Male	28	Sales Representative	5.9	4	30	8	Obese	140/90	85	3000	Sleep Apnea
19	Female	29	Nurse	6.5	5	40	7	Normal Weight	132/87	80	4000	Insomnia
33	Female	31	Nurse	7.9	8	75	4	Normal Weight	117/76	69	6800	None

Penelitian ini melakukan analisis komparatif terhadap berbagai algoritma machine learning yang terdiri dari Random Forest, Neural Network, Naive Bayes, K-Nearest Neighbor, Support Vector Machine, dan Logistic Regression. Algoritma *machine learning* diterapkan untuk menganalisis kinerja model. Data dibagi menjadi data latih dan data uji dengan perbandingan 80:20. Rasio ini banyak digunakan dalam berbagai penelitian untuk tugas klasifikasi karena dianggap efektif dalam mencegah overfitting [11], [30]. Kinerja dari masing-masing model klasifikasi dievaluasi menggunakan berbagai metrik pengukuran performa. Tabel 4 menyajikan hasil evaluasi berdasarkan metrik akurasi, presisi, recall, dan F1-score.

**Tabel 4.** Hasil Pengujian Tanpa SMOTE

Model	Accuracy	Precision	Recall	F1-Score
RF	89.33 %	89.33 %	89.33 %	89.23 %
NN	89.33 %	89.33 %	89.33 %	89.23 %
NB	86.67 %	87.48 %	86.67 %	86.87 %
KNN	85.33 %	86.95 %	85.33 %	85.28 %
SVM	86.67 %	88.38 %	86.67 %	86.87 %
LR	86.67 %	87.40 %	86.67 %	86.55 %

Berdasarkan Tabel 4, model Random Forest dan Neural Network mencatatkan performa terbaik secara keseluruhan dengan akurasi tertinggi sebesar 89,33 %, serta nilai presisi, recall, dan F1-score yang konsisten tinggi (89,23 % untuk F1-score). Hal ini menunjukkan kemampuan kedua model dalam menghasilkan prediksi yang stabil dan andal dalam prediksi gangguan tidur. Model Naive Bayes dan Support Vector Machine menunjukkan performa yang juga cukup baik, masing-masing dengan akurasi sebesar 86,67 % dan nilai F1-score sebesar 86,87 %. Meskipun SVM memiliki presisi yang relatif lebih tinggi (88,38 %), nilai metrik lainnya setara dengan model NB. Model K-Nearest



Neighbors memiliki akurasi dan F1-score yang sedikit lebih rendah dibandingkan model lainnya, yaitu 85,33 % dan 85,28 %, namun masih dalam kategori cukup baik. Sementara itu, Logistic Regression juga menunjukkan performa yang kompetitif dengan nilai akurasi sebesar 86,67 % dan F1-score sebesar 86,55 %.

**Tabel 5.** Parameter Model

Algoritma	Parameter
RF	RandomForestClassifier(n_estimators=100, max_depth=None, max_features=None)
NN	MLPClassifier(hidden_layer_sizes=(100, 50), random_state=42)
NB	GaussianNB()
KNN	KNeighborsClassifier(n_neighbors=3)
SVM	SVC(kernel='linear', random_state=42)
LR	LogisticRegression(random_state=42)

Setiap model diujikan menggunakan parameter yang telah dimodifikasi untuk mengoptimalkan kinerja klasifikasi. Rincian parameter yang digunakan pada masing-masing algoritma ditampilkan pada Tabel 5. Optimasi ini dilakukan dalam rangka meningkatkan performa klasifikasi gangguan tidur pada dataset yang seimbang.

Berdasarkan Tabel 6, model Random Forest dengan SMOTE menunjukkan performa terbaik dengan akurasi mencapai 93,33%, presisi 93,26%, recall 93,33%, dan F1-Score sebesar 93,18%. Hal ini mengindikasikan bahwa RF dengan Smote mampu melakukan klasifikasi dengan baik, baik dalam mengenali data positif maupun negatif secara seimbang. Performanya yang unggul kemungkinan disebabkan oleh kemampuan Random Forest dalam menangani data yang kompleks serta mengurangi risiko overfitting melalui ensemble learning. Model Neural Network dengan SMOTE juga menunjukkan hasil yang cukup baik dengan akurasi 92,00%, presisi 91,88%, recall 92,00%, dan F1-Score 91,91%. Ini menunjukkan bahwa jaringan saraf mampu mempelajari pola data dengan cukup efektif setelah penanganan ketidakseimbangan menggunakan SMOTE. Sementara itu, K-Nearest Neighbor dengan SMOTE menghasilkan akurasi sebesar 90,67% dengan presisi 91,66%, recall 90,67%, dan F1-Score 90,74%, yang juga tergolong baik meskipun sedikit di bawah performa RF dan NN. Model Logistic Regression dengan SMOTE memiliki akurasi 89,33%, presisi 90,13%, recall 89,33%, dan F1-Score 89,52%, yang menunjukkan performa yang cukup stabil pada prediksi gangguan tidur. Di sisi lain, Naive Bayes dan Support Vector Machine menunjukkan performa yang serupa, dengan akurasi dan recall sebesar 88,00%, serta F1-Score masing-masing 88,17%. Performa kedua model ini sedikit lebih rendah dibandingkan model lain, yang mungkin disebabkan oleh asumsi dasar NB yang sederhana serta sensitivitas parameter SVM terhadap pengaturan kernel dan margin.

**Tabel 6.** Hasil Pengujian dengan SMOTE

Model	Accuracy	Precision	Recall	F1-Score
RF+Smote	93.33 %	93.26 %	93.33 %	93.18 %
NN+Smote	92.00 %	91.88 %	92.00 %	91.91 %
NB+Smote	88.00 %	88.50 %	88.00 %	88.17 %
KNN+Smote	90.67 %	91.66 %	90.67 %	90.74 %
SVM+Smote	88.00 %	88.50 %	88.00 %	88.17 %
LR+Smote	89.33 %	90.13 %	89.33 %	89.52 %

Dari hasil yang diperoleh, Random Forest merupakan algoritma terbaik dalam melakukan klasifikasi pada dataset gangguan tidur karena kemampuannya dalam mencapai keseimbangan antara presisi dan recall serta nilai F1 yang tinggi. Penggunaan metode SMOTE terbukti meningkatkan kinerja sebagian besar model klasifikasi pada dataset yang tidak seimbang. Model Random Forest dengan SMOTE menunjukkan performa terbaik dengan nilai *accuracy* sebesar 93.33%, diikuti oleh Neural Network dengan SMOTE dengan 92%. Peningkatan signifikan terlihat pada semua metrik, terutama pada nilai *recall* dan *F1-score*, yang penting dalam konteks klasifikasi data tidak seimbang. Sebaliknya, hasil tanpa SMOTE menunjukkan performa yang lebih rendah, terutama pada algoritma seperti KNN dan NB. Hal ini mengindikasikan bahwa ketidakseimbangan kelas mempengaruhi efektivitas model dalam mengenali kelas minoritas.



**Tabel 7.** Perbandingan dengan Penelitian Terdahulu

Tahun	Referensi	Imbalance Class (SMOTE)	Pembagian Data	Algoritma	Akurasi	
2023	[5]	Tidak	Split Data	Random Forest	88%	
2024	[7]	Tidak	Tidak	SVM	90.1%	
2024	[6]	Tidak	menyebutkan	Neural Network	91.2%	
			Split Data	KNN	83.19%	
			70%:30%	SVM	92.04%	
				Random Forest	88.50%	
				Decision Tree	91.15%	
2025	[8]	Ya	Split Data	Random Forest	92.7%	
2025	[31]	Tidak	Cross Validation	SVM	91.5%	
				Decision Tree + Algoritma Genetika	95,54%	
Hasil Penelitian		Ya	Split Data	80%:20%	Random Forest	93.33 %
					Neural Network	92.00 %
					Naïve Bayes	88.00 %
					KNN	90.67 %
					SVM	88.00 %
		Logistic Regression	89.33 %			

Berdasarkan Tabel 7, terlihat bahwa penelitian ini menunjukkan hasil yang kompetitif dibandingkan dengan penelitian-penelitian sebelumnya dalam hal akurasi klasifikasi. Penggunaan teknik penyeimbangan kelas (SMOTE) serta pembagian data sebesar 80% untuk pelatihan dan 20% untuk pengujian tampaknya berkontribusi pada peningkatan kinerja model. Random Forest dan Neural Network masing-masing mencapai akurasi sebesar 93.33% dan 92.00%, yang lebih tinggi dibandingkan dengan penelitian [1], [2], [3], dan [4], serta sebanding bahkan melampaui hasil dari penelitian [5] dan [7]. Penelitian [7] memang mencatat akurasi tertinggi yaitu 95.54% menggunakan kombinasi Decision Tree dan algoritma genetika, namun metode tersebut lebih kompleks. Selain itu, hasil penelitian ini menunjukkan performa yang stabil di berbagai algoritma lain seperti Naïve Bayes, KNN, SVM, dan Logistic Regression dengan akurasi yang cukup tinggi, menunjukkan bahwa pendekatan yang digunakan efektif untuk menangani ketidakseimbangan data dan menghasilkan model prediktif yang andal.

#### 4. KESIMPULAN

Hasil penelitian ini menunjukkan bahwa penggunaan SMOTE secara efektif mampu memperbaiki performa model, terutama mengatasi ketimpangan distribusi data yang condong ke kelas mayoritas. Teknik ini terbukti meningkatkan matrik evaluasi seperti akurasi, presisi, *recall*, dan F1-score di semua algoritma yang diuji. Model Neural Network yang dikombinasikan dengan SMOTE menunjukkan kinerja paling seimbang dan konsisten dengan nilai akurasi 92.00 %, *precision* 91.88 %, *recall* 92.00 %, dan F1-score 91.91 %, sedangkan Random Forest dengan SMOTE mencatatkan nilai akurasi tertinggi 93.33 % dan F1-score tertinggi sebesar 93.18 %, yang mencerminkan kemampuannya dalam mengenali data dari berbagai kelas secara lebih tepat. Temuan ini menunjukkan bahwa penanganan data secara tepat sebelum proses pelatihan model memiliki peran krusial, terutama saat menghadapi data medis dengan distribusi kelas yang tidak merata. Penggabungan antara teknik penyeimbangan data seperti SMOTE dengan algoritma *machine learning* terbukti menjadi pendekatan yang efektif dalam meningkatkan performa sistem klasifikasi gangguan tidur. Melalui strategi ini, sistem menjadi lebih akurat dalam mengenali jenis gangguan, sehingga dapat memberikan dukungan yang lebih cepat dan tepat dalam pengambilan keputusan klinis. Namun, penelitian ini masih memiliki keterbatasan karena hanya berfokus pada algoritma klasifikasi tradisional dan belum mencakup pendekatan *deep learning*. Oleh karena itu, penelitian selanjutnya disarankan untuk mengintegrasikan metode *deep learning* seperti *Convolutional Neural Network* (CNN) atau *Long Short-Term Memory* (LSTM) yang memiliki kemampuan lebih tinggi dalam mengenali pola kompleks pada data. Penggabungan antara *deep learning* dan teknik penyeimbangan data seperti SMOTE berpotensi memberikan hasil yang lebih akurat.

#### DAFTAR PUSTAKA

- [1] A. U. M. Hadori *et al.*, *Kesehatan Mental Dalam Kehidupan Masyarakat Modern: Manajemen Stres Dan Beberapa Fenomena Umum*. Jakarta: Salemba Humanika, 2024.
- [2] A. M. A. Rahim, I. Y. R. Pratiwi, and M. A. Fikri, “Klasifikasi Penyakit Jantung Menggunakan Metode



- Synthetic Minority Over-Sampling Technique Dan Random Forest Classifier,” *Indonesian Journal of Computer Science*, vol. 12, no. 5, Nov. 2023, doi: 10.33022/ijcs.v12i5.3413.
- [3] A. X. Wang, V.-T. Le, H. N. Trung, and B. P. Nguyen, “Addressing imbalance in health data: Synthetic minority oversampling using deep learning,” *Comput Biol Med*, vol. 188, p. 109830, Apr. 2025, doi: 10.1016/j.compbimed.2025.109830.
- [4] L. Hussain, K. J. Lone, I. A. Awan, A. A. Abbasi, and J.-R. Pirzada, “Detecting congestive heart failure by extracting multimodal features with synthetic minority oversampling technique (SMOTE) for imbalanced data using robust machine learning techniques,” *Waves in Random and Complex Media*, vol. 32, no. 3, pp. 1079–1102, May 2022, doi: 10.1080/17455030.2020.1810364.
- [5] 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, Aug. 2023, doi: 10.20895/dinda.v3i2.1215.
- [6] T. S. Alshammari, “Applying Machine Learning Algorithms for the Classification of Sleep Disorders,” *IEEE Access*, vol. 12, pp. 36110–36121, 2024, doi: 10.1109/ACCESS.2024.3374408.
- [7] D. Sari, “Prediksi Gangguan Tidur pada Sleep Health and Lifestyle Menggunakan Support Vector Machine dan Neural Network,” *JAVIT : Jurnal Vokasi Informatika*, pp. 36–42, Mar. 2024, doi: 10.24036/javit.v4i1.168.
- [8] M. A. C. Candrakasih, D. Krisbiantoro, and R. Waluyo, “Perbandingan Random Forest dan Support Vector Machine Untuk Klasifikasi Sleep Apnea,” *Technologia : Jurnal Ilmiah*, vol. 16, no. 2, p. 337, Apr. 2025, doi: 10.31602/tji.v16i2.18555.
- [9] Y. Anusha, R. Visalakshi, and K. Srinivas, “Imbalanced data classification using improved synthetic minority over-sampling technique,” *Multiagent and Grid Systems*, vol. 19, no. 2, pp. 117–131, Oct. 2023, doi: 10.3233/MGS-230007.
- [10] G. Wei, W. Mu, Y. Song, and J. Dou, “An improved and random synthetic minority oversampling technique for imbalanced data,” *Knowl Based Syst*, vol. 248, p. 108839, Jul. 2022, doi: 10.1016/j.knosys.2022.108839.
- [11] E. Erlin, Y. Desnelita, N. Nasution, L. Suryati, and F. Zoromi, “Dampak SMOTE terhadap Kinerja Random Forest Classifier berdasarkan Data Tidak seimbang,” *MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, vol. 21, no. 3, pp. 677–690, Jul. 2022, doi: 10.30812/matrik.v21i3.1726.
- [12] Yoga Religia, Agung Nugroho, and Wahyu Hadikristanto, “Klasifikasi Analisis Perbandingan Algoritma Optimasi pada Random Forest untuk Klasifikasi Data Bank Marketing,” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 1, pp. 187–192, Feb. 2021, doi: 10.29207/resti.v5i1.2813.
- [13] R. G. McClarren, “Decision Trees and Random Forests for Regression and Classification,” in *Machine Learning for Engineers*, Cham: Springer International Publishing, 2021, pp. 55–82. doi: 10.1007/978-3-030-70388-2\_3.
- [14] H. A. Salman, A. Kalakech, and A. Steiti, “Random Forest Algorithm Overview,” *Babylonian Journal of Machine Learning*, vol. 2024, pp. 69–79, Jun. 2024, doi: 10.58496/BJML/2024/007.
- [15] R. Justo-Silva, A. Ferreira, and G. Flintsch, “Review on Machine Learning Techniques for Developing Pavement Performance Prediction Models,” *Sustainability*, vol. 13, no. 9, p. 5248, May 2021, doi: 10.3390/su13095248.
- [16] L. M. Sinaga, Sawaluddin, and S. Suwilo, “Analysis of classification and Naïve Bayes algorithm k-nearest neighbor in data mining,” *IOP Conf Ser Mater Sci Eng*, vol. 725, no. 1, p. 012106, Jan. 2020, doi: 10.1088/1757-899X/725/1/012106.
- [17] S. Budiyanto and I. Pratama, “Classification of Network Status in Academic Information Systems using Naive Bayes Algorithm Method,” in *2020 2nd International Conference on Broadband Communications, Wireless Sensors and Powering (BCWSP)*, IEEE, Sep. 2020, pp. 107–112. doi: 10.1109/BCWSP50066.2020.9249398.
- [18] R. Ehsani and F. Drabløs, “Robust Distance Measures for KNN Classification of Cancer Data,” *Cancer Inform*, vol. 19, Jan. 2020, doi: 10.1177/1176935120965542.
- [19] S. Zhang, “Challenges in KNN Classification,” *IEEE Trans Knowl Data Eng*, vol. 34, no. 10, pp. 4663–4675, Oct. 2022, doi: 10.1109/TKDE.2021.3049250.
- [20] L. Mohan, J. Pant, P. Suyal, and A. Kumar, “Support Vector Machine Accuracy Improvement with Classification,” in *2020 12th International Conference on Computational Intelligence and Communication Networks (CICN)*, IEEE, Sep. 2020, pp. 477–481. doi: 10.1109/CICN49253.2020.9242572.
- [21] A. V. Joshi, “Support Vector Machines,” in *Machine Learning and Artificial Intelligence*, Cham: Springer International Publishing, 2023, pp. 89–99. doi: 10.1007/978-3-031-12282-8\_8.
- [22] H. Li, “Support Vector Machine,” in *Machine Learning Methods*, Singapore: Springer Nature Singapore, 2024, pp. 127–177. doi: 10.1007/978-981-99-3917-6\_7.
- [23] A. Purnama and D. Hamidin, “Metode Algoritma Logistic Regression dalam Klasifikasi Email Spam,” *Journal Software, Hardware and Information Technology*, vol. 5, no. 1, pp. 39–47, Jan. 2025, doi:





- 10.24252/shift.v5i1.159.
- [24] I. I. Ridho, G. Mahalisa, D. R. Sari, and I. Fikri, “Metode Neural Network Untuk Penentuan Akurasi Prediksi Harga Rumah,” *Technologia : Jurnal Ilmiah*, vol. 13, no. 1, p. 56, Feb. 2022, doi: 10.31602/tji.v13i1.6252.
  - [25] B. Kumaraswamy, “Neural Networks for Data Classification,” in *Artificial Intelligence in Data Mining*, Elsevier, 2021, pp. 109–131. doi: 10.1016/B978-0-12-820601-0.00011-2.
  - [26] F. Sutomo *et al.*, “Optimization Of The K-Nearest Neighbors Algorithm Using The Elbow Method on Stroke Prediction,” *Jurnal Teknik Informatika (Jutif)*, vol. 4, no. 1, pp. 125–130, Feb. 2023, doi: 10.52436/1.jutif.2023.4.1.839.
  - [27] K. Gupta, N. Jiwani, N. Afreen, and D. D, “Liver Disease Prediction using Machine learning Classification Techniques,” in *2022 IEEE 11th International Conference on Communication Systems and Network Technologies (CSNT)*, IEEE, Apr. 2022, pp. 221–226. doi: 10.1109/CSNT54456.2022.9787574.
  - [28] W. Andriani, Gunawan, and N. N. P. W. Naja, “Analisis perbandingan machine learning untuk prediksi kelayakan kredit perbankan pada Bank BRI Tegal,” *IT-Explore: Jurnal Penerapan Teknologi Informasi dan Komunikasi*, vol. 4, no. 1, pp. 82–92, Feb. 2025, doi: 10.24246/itexplore.v4i1.2025.pp82-92.
  - [29] L. Tharmalingam, “Sleep Health and Lifestyle Dataset.” [Online]. Available: <https://www.kaggle.com/datasets/uom190346a/sleep-health-and-lifestyle-dataset>
  - [30] J. Pardede and M. F. Raspati, “Gated Recurrent Units dalam Mendeteksi Obstructive Sleep Apnea,” *MIND Journal*, vol. 6, no. 2, pp. 221–235, Dec. 2021, doi: 10.26760/mindjournal.v6i2.221-235.
  - [31] W. D. Septiani, “Klasifikasi Gangguan Tidur Menggunakan Metode Decision Tree dan Algoritma Genetika,” *Jurnal Minfo Polgan*, vol. 13, no. 2, pp. 2668–2675, Feb. 2025, doi: 10.33395/jmp.v13i2.14585.