



Optimasi Random Forest Menggunakan Domestic Cattle Optimization Algorithm (DCOA) Untuk Diagnosa Somnipati

Muhamad Toriq Aziz Firdaus*, Florentina Yuni Arini

Fakultas Matematika dan Ilmu Pengetahuan Alam, Prodi Teknik Informatika, Universitas Negeri Semarang, Semarang, Indonesia

Email: ^{1,*}toriqaziz@students.unnes.ac.id, ²floyuna@mail.unnes.ac.id

Email Penulis Korespondensi: toriqaziz@students.unnes.ac.id

Abstrak—Gangguan tidur seperti insomnia dan sleep apnea, yang dikenal sebagai somnipati, merupakan kondisi kesehatan yang dapat menurunkan kualitas hidup secara signifikan serta berkaitan dengan berbagai penyakit kronis. Namun, metode diagnosis konvensional seperti polisomnografi (PSG) memiliki keterbatasan dari segi biaya, waktu, dan aksesibilitas. Oleh karena itu, studi ini mengajukan metode berbasis *machine learning* untuk mengklasifikasikan gangguan tidur menggunakan kombinasi *Random Forest* dipadukan dengan SMOTE, dan DCOA. *Dataset* yang digunakan dalam penelitian ini berasal dari *Sleep Health and Lifestyle Dataset*, yang mencakup 374 data dengan 13 fitur yang merepresentasikan kondisi fisiologis serta gaya hidup individu. Permasalahan ketidakseimbangan data diatasi menggunakan SMOTE, sementara optimasi *hyperparameter* dilakukan menggunakan DCOA untuk meningkatkan performa model. Temuan studi menunjukkan bahwa model yang dikembangkan mampu mencapai akurasi sebesar 97,33%, dengan nilai *precision* 97,63%, *recall* 97,33%, dan *F1-score* sebesar 97,32%. Hasil ini menunjukkan peningkatan yang signifikan dibandingkan penelitian terdahulu yang menggunakan *dataset* yang sama. Dengan demikian, pendekatan yang diusulkan terbukti efektif dalam meningkatkan kinerja klasifikasi gangguan tidur serta memiliki potensi untuk diterapkan sebagai sistem pendukung diagnosis berbasis data yang optimal dan akurat. Meskipun demikian, mengingat ukuran *dataset* yang relatif terbatas, terdapat potensi risiko *overfitting* yang dapat memengaruhi kemampuan generalisasi model terhadap data baru.

Kata Kunci: Random Forest; SMOTE; DCOA; Klasifikasi Gangguan Tidur; Hyperparameter Optimization

Abstract—Sleep disorders such as insomnia and sleep apnea, collectively referred to as somnipathy, are health conditions that can significantly reduce quality of life and are associated with various chronic diseases. However, conventional diagnostic methods such as polysomnography (PSG) have limitations in terms of cost, time, and accessibility. Therefore, this study proposes a machine learning-based approach to classify sleep disorders using a combination of Random Forest integrated with the SMOTE and the DCOA. The dataset used in this study is the Sleep Health and Lifestyle Dataset, which consists of 374 records with 13 features representing individuals' physiological conditions and lifestyle factors. The issue of data imbalance is addressed using SMOTE, while hyperparameter optimization is performed using DCOA to enhance model performance. The findings indicate that the proposed model achieves an accuracy of 97.33%, precision of 97.63%, recall of 97.33%, and an F1-score of 97.32%. These results demonstrate a significant improvement compared to previous studies using the same dataset. Therefore, the proposed approach proves to be effective in improving sleep disorder classification performance and has strong potential to be implemented as an optimal and accurate data-driven decision support system for diagnosis. However, considering the relatively small dataset size, there is a potential risk of overfitting, which necessitates careful evaluation to ensure model generalization.

Keywords: Random Forest; SMOTE; DCOA; Sleep Disorder Classification; Hyperparameter Optimization

1. PENDAHULUAN

Kualitas tidur yang baik memiliki hubungan erat dengan stabilitas fungsi kognitif, regulasi emosional, serta proses pemulihan fisiologis tubuh [1]. Kualitas tidur yang buruk maupun durasi tidur yang tidak mencukupi sering dikaitkan dengan gangguan tidur, seperti insomnia dan *obstructive sleep apnea* (OSA) yang biasa disebut sebagai somnipati [2], telah menjadi salah satu isu kesehatan masyarakat global. Secara statistik, insomnia diketahui memengaruhi sekitar 10% hingga 30% populasi dunia, dengan estimasi global terbaru menunjukkan sekitar 16,2% orang dewasa mengalami insomnia kronis [3]. Selain itu, *sleep apnea* diperkirakan memengaruhi lebih dari satu miliar orang dewasa secara global, dengan sebagian besar kasus tidak terdiagnosis. Gangguan tidur tidak hanya berdampak negatif terhadap kualitas hidup, tetapi berkaitan dengan berbagai penyakit kronis, di antaranya seperti hipertensi, obesitas, gangguan metabolisme glukosa, serta meningkatkan risiko penyakit kardiovaskular dan mortalitas. Bahkan, individu dengan insomnia memiliki risiko 68% lebih tinggi mengalami serangan jantung dan 85% lebih tinggi mengalami stroke dibandingkan individu tanpa gangguan tidur [4]. Hal ini menunjukkan perlunya suatu metode atau alat untuk mendeteksi gejala gangguan tidur secara dini agar dapat dilakukan penanganan yang tepat.

Dalam praktik medis konvensional, metode utama yang digunakan untuk mendiagnosis somnipati adalah Polisomnografi (PSG) [5]. Metode ini memiliki tingkat akurasi yang tinggi karena mampu merekam berbagai parameter fisiologis, seperti aktivitas gelombang otak, pergerakan otot, dan pola pernapasan selama tidur. Namun, pelaksanaan PSG mengharuskan pasien menjalani pemantauan semalaman di laboratorium khusus dengan menggunakan berbagai sensor yang terpasang pada tubuh. Prosedur ini membutuhkan biaya yang tinggi, waktu yang relatif lama, serta ketersediaan fasilitas dan tenaga ahli yang terbatas [6]. Selain itu, hasil pemeriksaan PSG memerlukan analisis manual oleh tenaga medis, yang berpotensi menimbulkan kesalahan dan perbedaan interpretasi [7]. Keterbatasan tersebut berpotensi menyebabkan banyak individu dengan gangguan tidur yang belum terdiagnosis dan tidak mendapatkan penanganan yang tepat.

Seiring dengan keterbatasan metode konvensional, pendekatan berbasis *machine learning* [8] menjadi salah satu alternatif, diantaranya untuk mendeteksi dan mengklasifikasikan gangguan tidur. Melalui pemanfaatan data fisiologis dan gaya hidup, seperti durasi tidur, aktivitas fisik, detak jantung, dan indeks massa tubuh, pendekatan *machine learning* dapat



mengenali pola yang berkaitan dengan kondisi tidur secara lebih efisien [9]. Sejumlah algoritma, termasuk *Random Forest*, *Decision Tree*, *Support Vector Machine*, dan *Gradient Boosting*, menunjukkan performa yang cukup baik dalam klasifikasi gangguan tidur dengan skor metrik yang relatif tinggi [10]. Pendekatan ini juga memungkinkan proses prediksi dilakukan tanpa memerlukan peralatan medis yang kompleks, sehingga berpotensi meningkatkan akses terhadap deteksi dini gangguan tidur.

Sejumlah penelitian sebelumnya telah menerapkan *machine learning* dalam klasifikasi kesehatan tidur dengan berbagai pendekatan dan tingkat keberhasilan yang berbeda. Migliaccio *et al.* [11] menggunakan *dataset Sleep Health and Lifestyle* dengan model *Logistic Regression* dan memperoleh akurasi sebesar 86,9%, *precision* 87,7%, *recall* 87,5%, serta *F1-score* 87,1%. Selanjutnya, Rajesh *et al.* [12] menerapkan metode *ensemble learning* melalui *Voting Classifier* berbasis *Gradient Boosting* pada *dataset* yang sama dan berhasil mendapatkan akurasi di angka 0,88, *precision* 0,90, *recall* 0,86, serta *F1-score* 0,88. Pendekatan berbasis *deep learning* juga dikembangkan oleh Stephen & Islam [13] dengan menggunakan model hybrid CNN-LSTM, yang menghasilkan akurasi sebesar 0,856, *precision* 0,836, *recall* 0,765, dan *F1-score* 0,794. Sementara itu, Kumar *et al.* [14] menggunakan algoritma AdaBoost dan mendapatkan akurasi 91%, serta *precision* 90%, *recall* sebesar 87%, dan *F1-score* 88%. Selain itu, Taher & Ayon menerapkan tahap pra-proses berupa *label encoding* pada variabel kategorikal seperti gender, pekerjaan, *blood pressure*, dan BMI, serta normalisasi menggunakan *MinMax scaling*, kemudian menggunakan model *Random Forest* yang menghasilkan akurasi sebesar 90,26%, *precision* 91%, *recall* 89%, dan *F1-score* 90%.

Walaupun memiliki skor metrik evaluasi yang tinggi, utilitas dan kapabilitas prediksi dari algoritma *machine learning* saat dihadapkan pada rekaman medis dunia nyata sering kali terhambat oleh dua tantangan krusial, yakni, ketidakseimbangan distribusi probabilitas kelas dan kompleksitas konfigurasi *hyperparameter* yang optimal [15]. Permasalahan ketidakseimbangan kelas sering ditemukan pada *dataset* kesehatan, ketika jumlah sampel pada satu kategori jauh lebih besar dibanding kategori lainnya [16]. Dalam konteks *Sleep Health and Lifestyle Dataset*, sebagian besar data berasal dari individu tanpa gangguan tidur (*none*), sementara jumlah data untuk kondisi seperti *insomnia* dan *sleep apnea* relatif lebih sedikit. Kondisi ini dapat memengaruhi kinerja model *machine learning*, khususnya pada algoritma klasifikasi, karena model cenderung lebih sering memprediksi kelas mayoritas. Akibatnya, nilai akurasi dapat terlihat tinggi, tetapi kemampuan model dalam mendeteksi kelas minoritas menjadi rendah [17]. Hal ini menjadi masalah serius karena kegagalan mendeteksi kasus gangguan tidur dapat menghambat proses diagnosis dan penanganan yang tepat. Untuk mengurangi bias akibat ketidakseimbangan data, diperlukan teknik penyeimbangan distribusi, salah satunya melalui proses *oversampling* sebelum tahap pelatihan model. Hal ini dilakukan agar model dapat bekerja secara adil untuk setiap kelas atau kategori yang ada.

Selain itu, performa model *machine learning* secara signifikan dipengaruhi oleh proses optimasi *hyperparameter* [18]. Setiap algoritma memiliki parameter tertentu yang harus disesuaikan agar model dapat bekerja secara optimal dalam menangkap pola pada data. Dalam model yang berbasis pohon, seperti *Random Forest*, parameter seperti kedalaman pohon (*max_depth*), jumlah pohon (*n_estimators*), serta kriteria pemisahan (*split criterion*) menjadi faktor penting yang menentukan kualitas prediksi [19]. Meskipun berbagai metode optimasi seperti *Grid Search*, *Random Search*, maupun metaheuristik populer seperti *Genetic Algorithm* (GA) dan *Particle Swarm Optimization* (PSO) telah banyak digunakan, metode tersebut memiliki keterbatasan dalam menyeimbangkan eksplorasi dan eksploitasi pada ruang pencarian yang kompleks dan berdimensi tinggi. *Grid Search* cenderung bersifat eksklusif dan tidak efisien secara komputasi, sedangkan *Random Search* tidak menjamin konvergensi menuju solusi optimal [20]. Sementara itu, beberapa algoritma metaheuristik seperti PSO berpotensi mengalami *premature convergence* pada solusi lokal. *Domestic Cattle Optimization Algorithm* (DCOA) merupakan pendekatan metaheuristik terbaru yang dirancang dengan mekanisme adaptif dalam mengatur keseimbangan eksplorasi dan eksploitasi melalui perilaku kolektif kawanan. Karakteristik ini memungkinkan DCOA untuk menjelajahi ruang solusi secara lebih luas sekaligus mempertahankan kemampuan konvergensi yang stabil [21]. Oleh karena itu, DCOA dipilih dalam penelitian ini sebagai solusi untuk mengatasi keterbatasan metode optimasi konvensional, khususnya dalam konteks optimasi *hyperparameter* pada model dengan ruang pencarian yang kompleks seperti *Random Forest*.

Oleh karena itu, untuk mengatasi permasalahan ketidakseimbangan data dan kompleksitas ruang *hyperparameter*, penelitian ini mengusulkan suatu pendekatan terintegrasi dalam bentuk *pipeline* algoritma. Pendekatan ini dimulai dengan pembangunan model *Random Forest*. Selanjutnya, permasalahan ketidakseimbangan data ditangani dengan implementasi metode *Synthetic Minority Over-sampling Technique* (SMOTE) yang bertujuan meningkatkan jumlah data minoritas melalui proses interpolasi. Tahap berikutnya adalah optimasi *hyperparameter* menggunakan algoritma metaheuristik *Domestic Cattle Optimization Algorithm* (DCOA), yang bertujuan untuk mencari kombinasi parameter terbaik secara lebih efisien. Secara keseluruhan, penelitian ini bertujuan untuk merancang dan mengevaluasi sebuah sistem klasifikasi yang mampu mendeteksi gangguan tidur berdasarkan data fisiologis dan gaya hidup dengan tingkat akurasi yang lebih baik dibandingkan metode sebelumnya dengan menggunakan skor metrik konvensional seperti akurasi, *precision*, *recall*, serta *F1-score*.

2. METODOLOGI PENELITIAN

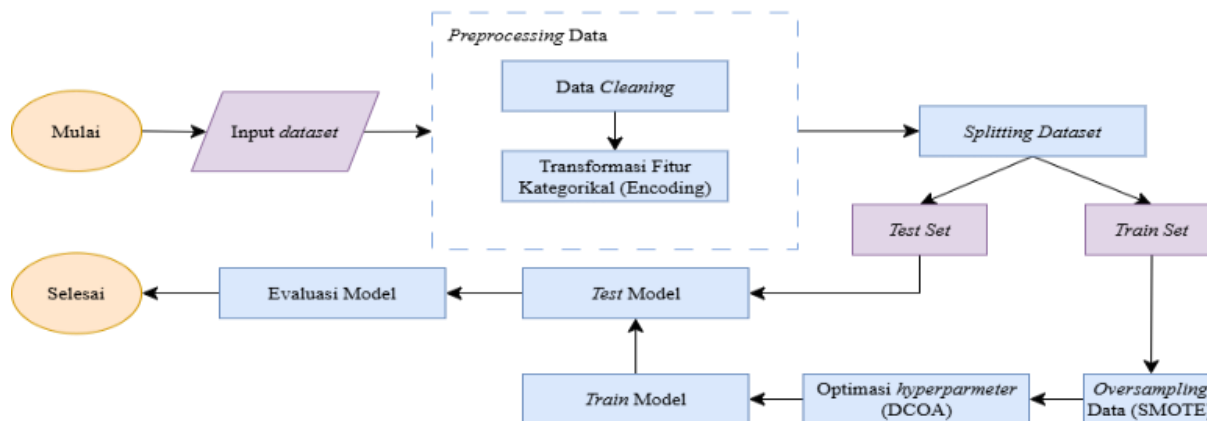
Bab ini menguraikan metode penelitian yang digunakan dalam pengembangan model klasifikasi gangguan tidur berbasis *Random Forest*. Untuk meningkatkan kinerja model, penelitian ini menerapkan *Synthetic Minority Over-sampling*



Technique (SMOTE) dalam mengatasi ketidakseimbangan kelas pada *dataset*, serta menggunakan *Domestic Cattle Optimization Algorithm* (DCOA) untuk optimasi *hyperparameter*. Pembahasan diawali dengan tahapan penelitian yang menggambarkan alur kerja sistem secara menyeluruh, mulai dari proses pengolahan data hingga tahap evaluasi model.

2.1 Tahapan Penelitian

Tahapan penelitian pada studi ini dilakukan secara sistematis untuk membangun model klasifikasi gangguan tidur yang optimal. Proses penelitian dimulai dari input data hingga evaluasi kinerja model. Secara keseluruhan, tahapan detail kajian yang dilakukan ditampilkan pada Gambar 1.



Gambar 1. Alur Penelitian

Proses dimulai dari tahap input *dataset* yang kemudian dilanjutkan dengan pembersihan data dilakukan untuk menjamin kualitas data yang digunakan seperti pengecekan data yang kosong atau yang tidak sesuai dengan format. Selanjutnya, dilakukan transformasi fitur kategorikal melalui proses *encoding* sehingga data dapat digunakan oleh algoritma *machine learning*. Setelah tahap *preprocessing*, *dataset* dibagi menjadi dua bagian, yaitu *train set* dan *test set*. Data latih (*train set*) digunakan dalam proses pembangunan model, yang diawali dengan penanganan *imbalance data* menggunakan metode *Synthetic Minority Over-sampling Technique* (SMOTE). Selanjutnya, dilakukan optimasi *hyperparameter* menggunakan algoritma *Domestic Cattle Optimization Algorithm* (DCOA) untuk memperoleh kombinasi parameter terbaik pada model *Random Forest*. Model kemudian dilatih menggunakan data latih yang telah diproses dan dioptimasi. Setelah tahap pelatihan selesai, model selanjutnya divalidasi menggunakan data yang tidak terlibat dalam proses *training* untuk menilai kemampuan klasifikasinya. Tahap terakhir pada studi ini berupa evaluasi performa model menggunakan metrik seperti akurasi, *precision*, *recall*, dan *F1-score* untuk menilai kemampuan deteksi gangguan tidur.

2.2 Sumber dan Deskripsi Data

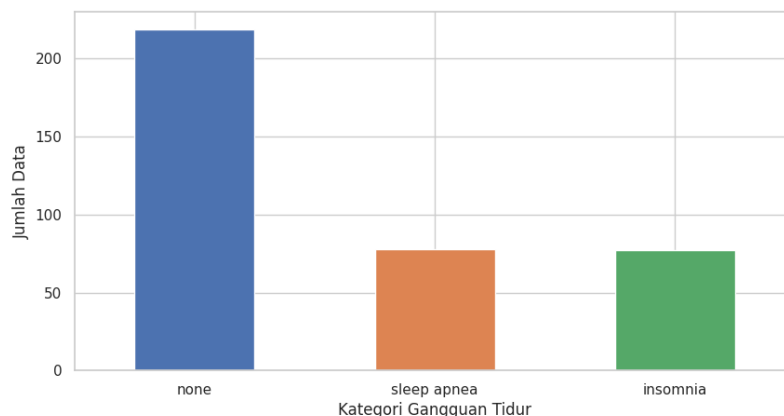
Dataset yang digunakan dalam penelitian ini diperoleh dari platform Kaggle dengan judul *Sleep Health and Lifestyle Dataset* yang dikembangkan oleh Laksika Tharmalingam. *Dataset* ini dapat diakses secara publik melalui tautan berikut: <https://www.kaggle.com/datasets/uom190346a/sleep-health-and-lifestyle-dataset>. *Dataset* tersebut digunakan dalam berbagai penelitian ilmiah, termasuk pada publikasi jurnal bereputasi, sehingga memiliki tingkat kredibilitas yang baik untuk digunakan dalam studi klasifikasi kesehatan tidur [11], [12]. *Dataset* ini memiliki 374 data dengan 13 kolom yang merepresentasikan berbagai aspek kesehatan, gaya hidup, dan kondisi tidur individu. Fitur-fitur dalam *dataset* mencakup informasi demografis, kebiasaan hidup, serta parameter fisiologis yang berkaitan dengan kualitas tidur. Variabel target pada *dataset* ini adalah *Sleep Disorder*, yang digunakan untuk mengelompokkan kondisi individu ke dalam kategori tanpa gangguan tidur (*none*), *insomnia*, atau *sleep apnea*, dengan proporsi masing-masing sebesar 59%, 20%, dan 21% seperti pada Gambar 2. Penjelasan lengkap mengenai fitur yang digunakan dalam penelitian ini dapat dilihat pada Tabel 1.

Tabel 1. Deskripsi Fitur *Dataset*

No.	Nama Fitur	Deskripsi Fitur
1	Person ID	Identitas unik untuk setiap individu
2	Gender	Jenis kelamin individu (Male/Female)
3	Age	Usia individu dalam tahun
4	Occupation	Pekerjaan atau profesi individu
5	Sleep Duration	Durasi tidur per hari (jam)
6	Quality of Sleep	Kualitas tidur (skala 1–10)
7	Physical Activity level	Aktivitas fisik per hari (menit)
8	Stress Level	Tingkat stres (skala 1–10)
9	BMI Category	Kategori indeks massa tubuh (Underweight, Normal, Overweight)
10	Blood Pressure	Tekanan darah (sistolik/diastolik)

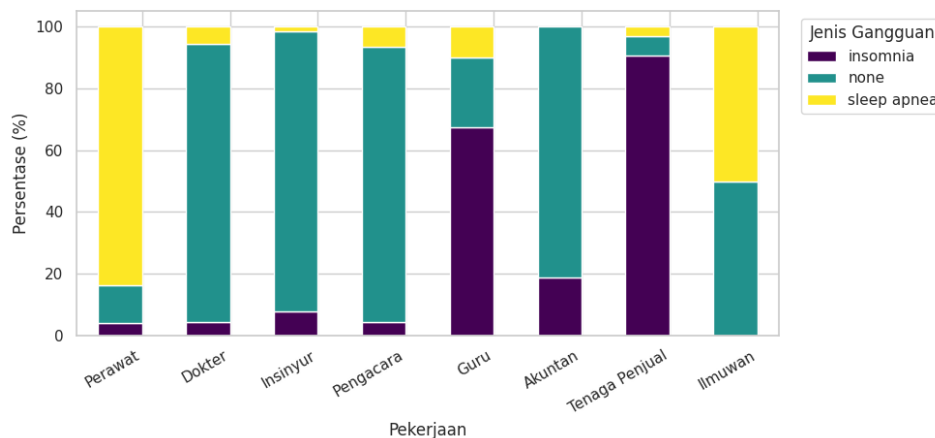


No.	Nama Fitur	Deskripsi Fitur
11	Heart Rate	Detak jantung (bpm)
12	Daily Steps	Jumlah langkah per hari



Gambar 2. Distribusi Kelas Variabel Target

Deskripsi lebih lanjut pada *dataset Sleep Health and Lifestyle* dilakukan dengan mengeksplorasi distribusi gangguan tidur berdasarkan fitur *Occupation* (jenis pekerjaan), sebagaimana ditunjukkan pada Gambar 3. Fitur ini mencakup berbagai profesi, seperti *salesperson* (tenaga penjual), *teacher* (guru), *nurse* (perawat), *scientist* (ilmuwan), *doctor* (dokter), *engineer* (insinyur), dan *lawyer* (pengacara). Hasil visualisasi menunjukkan adanya variasi proporsi gangguan tidur yang cukup kontras antarprofesi. Tenaga penjual dan guru memiliki dominasi *insomnia* yang tinggi, yang mengindikasikan potensi pengaruh tekanan kerja dan beban mental. Sebaliknya, pada profesi perawat dan ilmuwan, proporsi *sleep apnea* terlihat signifikan, yang dapat dikaitkan dengan pola kerja seperti sistem *shift* atau gaya hidup sedentari. Di sisi lain, profesi seperti dokter, insinyur, dan pengacara didominasi oleh individu tanpa gangguan tidur (*none*), meskipun hal ini tidak menutup kemungkinan adanya kondisi yang tidak terdeteksi (*underreported*). Pola ini menunjukkan bahwa jenis pekerjaan tidak hanya berkorelasi dengan keberadaan gangguan tidur, tetapi juga dengan jenis gangguan yang dialami. Namun demikian, hubungan tersebut tidak dapat diinterpretasikan sebagai hubungan kausal secara langsung dan masih memerlukan analisis lebih lanjut untuk menghindari potensi bias, khususnya dalam konteks pemodelan prediktif.



Gambar 3. Proporsi Gangguan Tidur Berdasarkan Pekerjaan

2.3 Preprocessing Data

Tahap prapemrosesan data dilakukan untuk menyiapkan *dataset* agar dapat dimanfaatkan secara optimal dalam proses pelatihan model *machine learning* [22]. Proses ini bertujuan untuk meningkatkan kualitas data serta memastikan seluruh fitur dapat diproses oleh algoritma yang digunakan.

Langkah pertama yang dilakukan adalah *data cleaning*, yaitu pengecekan terhadap adanya nilai yang hilang (*missing values*) maupun inkonsistensi data. Pada *dataset* yang digunakan, tidak terdapat nilai yang hilang sehingga seluruh data dapat langsung diproses pada tahap berikutnya. Langkah berikutnya adalah transformasi fitur kategorikal melalui proses *encoding*. Fitur-fitur yang memiliki tipe data kategorikal, seperti *Gender*, *Occupation*, dan *BMI Category*, diubah menjadi representasi numerik menggunakan metode *label encoding*. Terdapat fitur yang perlu di *parsing* yakni fitur "Blood Pressure" yang dipecah menjadi fitur "Systolic" dan "Diastolic". Proses ini diperlukan karena algoritma *machine learning*, termasuk *Random Forest*, hanya mampu mengolah data dalam format numerik. Perubahan nilai sebelum dan sesudah proses *encoding* ditunjukkan pada Tabel 2.

**Tabel 2.** Transformasi fitur kategorikal Encoding

Nama Fitur	Sebelum <i>Encoding</i>	Sesudah <i>Encoding</i>
Gender	Female, Male	0,1
Occupation	Accountant, Doctor, Engineer, Lawyer, Manager, Nurse, Sales Representative, Salesperson, Scientist, Software Engineer, Teacher	0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10
BMI Category	Normal, Normal Weight, Obese, Overweight	0, 1, 2, 3

Selanjutnya, dilakukan eksplorasi distribusi data untuk memahami karakteristik masing-masing fitur serta distribusi kelas pada variabel target. Hasil eksplorasi menunjukkan bahwa distribusi kelas pada variabel *Sleep Disorder* mengalami *imbalance class*, di mana jumlah data dengan kelas *none* lebih dominan dibandingkan kelas *insomnia* dan *sleep apnea*. Kondisi ini menjadi dasar dilakukannya penanganan ketidakseimbangan data pada tahap berikutnya. Setelah proses transformasi selesai, *dataset* kemudian dibagi menjadi data latih (*train set*) dan data uji (*test set*). Pembagian ini bertujuan untuk memastikan bahwa evaluasi model dilakukan secara objektif terhadap data yang belum pernah dipelajari sebelumnya. Data latih digunakan untuk proses pelatihan dan optimasi model, sementara data uji dimanfaatkan untuk menilai kinerja akhir model.

2.4 Penanganan Ketidakseimbangan Data (SMOTE)

Ketidakeimbangan data (*imbalanced data*) merupakan permasalahan umum dalam *dataset* kesehatan, termasuk pada *Sleep Health and Lifestyle Dataset* yang digunakan dalam penelitian ini. Pada *dataset* tersebut, jumlah data pada kelas mayoritas (*none*) jauh lebih banyak dibandingkan kelas minoritas seperti *insomnia* dan *sleep apnea*. Kondisi ini dapat menyebabkan model *machine learning* cenderung bias terhadap kelas mayoritas dan menurunkan kemampuan dalam mendeteksi kelas minoritas. Untuk mengurangi dominasi kelas mayoritas, penelitian ini menerapkan pendekatan *oversampling* berbasis interpolasi sintesis melalui metode SMOTE dimana data minoritas diperbanyak secara sintesis menggunakan pendekatan interpolatif agar distribusi kelas menjadi lebih proporsional [23]. Secara matematis, proses pembentukan data sintesis pada SMOTE dapat dirumuskan sebagaimana tertulis pada Persamaan 1.

$$x_{new} = x_i + rand(0,1) \times (x_{nn} - x_i) \quad (1)$$

Melalui proses tersebut, data baru (*synthetic sample*) dihasilkan di sepanjang garis yang menghubungkan dua titik data minoritas, sehingga distribusi data menjadi lebih seimbang tanpa melakukan duplikasi data secara langsung. Dalam penelitian ini, SMOTE diterapkan hanya pada data latih (*train set*) setelah proses pembagian data (*data splitting*). Hal ini dilakukan untuk menghindari terjadinya data *leakage* yang dapat memengaruhi validitas evaluasi model. Dengan penerapan SMOTE, model *Random Forest* berpotensi mampu mempelajari pola dari kelas minoritas secara lebih baik dan meningkatkan performa klasifikasi, khususnya pada metrik *recall* dan *F1-score*.

2.5 Model Klasifikasi (Random Forest)

Pada penelitian ini, *Random Forest* digunakan karena kemampuannya dalam menangani data multidimensi serta mengurangi risiko *overfitting* melalui mekanisme *ensemble* antar pohon keputusan. Algoritma ini bekerja dengan membangun sejumlah pohon keputusan (*decision tree*) secara independen, kemudian menggabungkan hasil prediksi dari setiap pohon untuk menghasilkan keputusan akhir melalui mekanisme *majority voting*. Pada proses pembentukan model, *Random Forest* menggunakan teknik *bootstrap aggregating (bagging)*, yaitu dengan mengambil sampel data secara acak dengan pengembalian (*sampling with replacement*) dari *dataset* pelatihan untuk membangun setiap pohon. Selain itu, pada setiap proses pemisahan node, hanya sebagian fitur yang dipilih secara acak untuk meningkatkan keragaman antar pohon dan mengurangi risiko *overfitting*. Dalam pembentukan pohon keputusan, digunakan fungsi impurity untuk menentukan kualitas pemisahan data. Salah satu metode yang umum digunakan adalah Gini Index, yang dirumuskan pada Persamaan 2.

$$Gini = 1 - \sum_{i=1}^C p_i^2 \quad (2)$$

Di mana p_i adalah proporsi data pada kelas ke- i , C adalah jumlah kelas. Semakin kecil nilai Gini, maka semakin baik kualitas pemisahan data pada node tersebut. Selain Gini Index, metode lain yang dapat digunakan adalah Entropy, yang dirumuskan pada Persamaan 3.

$$Entropy = - \sum_{i=1}^C p_i \log_2 p_i \quad (3)$$

Nilai entropy yang lebih rendah menunjukkan bahwa data pada node tersebut lebih homogen. Setelah seluruh pohon terbentuk, prediksi akhir pada *Random Forest* ditentukan berdasarkan mayoritas suara dari seluruh pohon keputusan, yang secara matematis dapat dinyatakan sebagaimana Persamaan 4.

$$\hat{y} = \text{mode}(h_1(x), h_2(x), \dots, h_n(x)) \quad (4)$$



Di mana $h_i(x)$ adalah prediksi dari pohon ke- i , n adalah jumlah pohon dalam model. Parameter utama yang digunakan dalam model ini meliputi jumlah pohon ($n_estimators$), kedalaman maksimum pohon (max_depth), jumlah minimum sampel untuk melakukan pemisahan ($min_samples_split$), serta jumlah minimum sampel pada daun ($min_samples_leaf$). Parameter-parameter tersebut selanjutnya dioptimasi menggunakan algoritma DCOA untuk memperoleh performa model yang optimal.

2.6 Optimasi Hyperparameter (DCOA)

Optimasi *hyperparameter* merupakan tahap penting dalam meningkatkan performa model *machine learning*. Pemilihan nilai *hyperparameter* yang tidak optimal dapat menyebabkan model mengalami *underfitting* atau *overfitting*. Metode konvensional seperti *Grid Search* dan *Random Search* memiliki keterbatasan dalam mengeksplorasi ruang pencarian yang besar, terutama pada permasalahan dengan kompleksitas tinggi. Untuk mengatasi hal tersebut, penelitian ini mengadopsi pendekatan metaheuristik berbasis *swarm intelligence*, yaitu *Domestic Cattle Optimization Algorithm (DCOA)*. DCOA merupakan algoritma optimasi yang terinspirasi dari perilaku kawanan sapi dalam mencari sumber makanan, yang melibatkan mekanisme eksplorasi dan eksploitasi secara adaptif dalam ruang pencarian solusi [24]. Pada penelitian ini, DCOA digunakan untuk mengoptimasi *hyperparameter* pada model *Random Forest*. Setiap individu dalam populasi merepresentasikan satu kandidat solusi berupa kombinasi nilai *hyperparameter*, seperti $n_estimators$, max_depth , $min_samples_split$, $min_samples_leaf$, dan $max_features$. Nilai-nilai tersebut direpresentasikan dalam bentuk vektor kontinu dalam rentang $[0,1]$, yang kemudian dikonversi menjadi parameter diskrit melalui proses *decoding*.

Fungsi objektif (*fitness function*) yang digunakan untuk mengevaluasi kualitas solusi dirumuskan sebagai kombinasi dari metrik *accuracy* dan *F1-score*, yang dinyatakan pada Persamaan 5.

$$Fitness = \alpha \cdot Accuracy + (1 - \alpha) \cdot F1-Score \quad (5)$$

Di mana α merupakan bobot yang digunakan untuk mengatur kontribusi masing-masing metrik. Dalam penelitian ini digunakan nilai $\alpha = 0.4$, sehingga *F1-score* memiliki kontribusi lebih besar untuk meningkatkan kemampuan model dalam menangani data yang tidak seimbang. Proses optimasi dilakukan secara iteratif dengan memperbarui posisi setiap individu dalam populasi berdasarkan informasi dari individu terbaik (*global best*) dan individu unggulan (*leaders*). Mekanisme pembaruan posisi dalam DCOA yang diadaptasi dalam penelitian ini dapat dirumuskan sebagaimana tertuang pada Persamaan 6.

$$X_i^{t+1} = X_i^t + r_1(X_{leader} - X_i^t) + r_2(X_{best} - X_i^t) + \epsilon \quad (6)$$

Di mana X_i^t adalah posisi individu ke- i pada iterasi ke- t , X_{leader} adalah posisi individu terbaik dalam kelompok leader, X_{best} adalah solusi terbaik global, r_1, r_2 adalah bilangan acak dalam rentang $[0,1]$, ϵ adalah komponen eksplorasi berupa noise acak. Mekanisme tersebut memungkinkan algoritma untuk menyeimbangkan proses eksplorasi (mencari solusi baru) dan eksploitasi (memperbaiki solusi terbaik yang sudah ada), sehingga dapat menghindari jebakan pada solusi lokal (*local optimum*). Setelah proses iterasi selesai, diperoleh kombinasi *hyperparameter* terbaik yang selanjutnya digunakan untuk melatih model *Random Forest* secara final. Dengan pendekatan ini, diharapkan model mampu mencapai performa yang lebih optimal dibandingkan penggunaan metode optimasi konvensional.

2.7 Evaluasi Model

Evaluasi kinerja model dilakukan untuk mengukur kemampuan model dalam melakukan klasifikasi gangguan tidur secara akurat dan konsisten. Proses evaluasi dilakukan menggunakan data uji (*test set*) yang tidak digunakan selama proses pelatihan maupun optimasi model, sehingga hasil evaluasi dapat mencerminkan performa model terhadap data baru. Dalam penelitian ini, digunakan beberapa metrik evaluasi yang umum digunakan dalam tugas klasifikasi, yaitu akurasi, *precision*, *recall*, dan *F1-score*. Selain itu, digunakan juga *confusion matrix* untuk memberikan gambaran yang lebih rinci mengenai hasil klasifikasi model.

2.7.1 Confusion Matrix

Confusion matrix merupakan tabel yang digunakan untuk mengevaluasi performa model dengan membandingkan hasil prediksi dan nilai sebenarnya. Tabel ini terdiri dari empat komponen utama, yaitu, *True Positive (TP)* yaitu data yang diprediksi benar sebagai kelas positif, *True Negative (TN)* yaitu data yang diprediksi benar sebagai kelas negatif *False Positive (FP)* yaitu data yang salah diprediksi sebagai kelas positif, *False Negative (FN)* yaitu data yang salah diprediksi sebagai kelas negatif.

2.7.2 Akurasi

Akurasi mengukur proporsi jumlah prediksi yang benar terhadap seluruh data, yang dirumuskan sebagai Persamaan 7.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (7)$$

2.7.3 Precision

Precision mengukur tingkat ketepatan model dalam memprediksi kelas positif, yang dirumuskan sebagai Persamaan 8.

$$Precision = \frac{TP}{TP+FP} \quad (8)$$

2.7.4 Recall

Recall mengukur kemampuan model dalam mendeteksi seluruh data yang benar-benar positif, yang dirumuskan sebagai Persamaan 9.

$$Recall = \frac{TP}{TP+FN} \quad (9)$$

2.7.5 F1-score

F1-score merupakan rata-rata harmonik dari *precision* dan *recall*, yang dirumuskan sebagaimana Persamaan 10.

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (10)$$

Dalam konteks dataset yang tidak seimbang, metrik seperti *precision*, *recall*, dan *F1-score* menjadi lebih penting dibandingkan *accuracy*, karena mampu memberikan gambaran yang lebih representatif terhadap performa model dalam mendeteksi kelas minoritas. Oleh karena itu, penelitian ini memberikan perhatian khusus pada nilai *F1-score* sebagai indikator utama dalam mengevaluasi kualitas model yang dihasilkan.

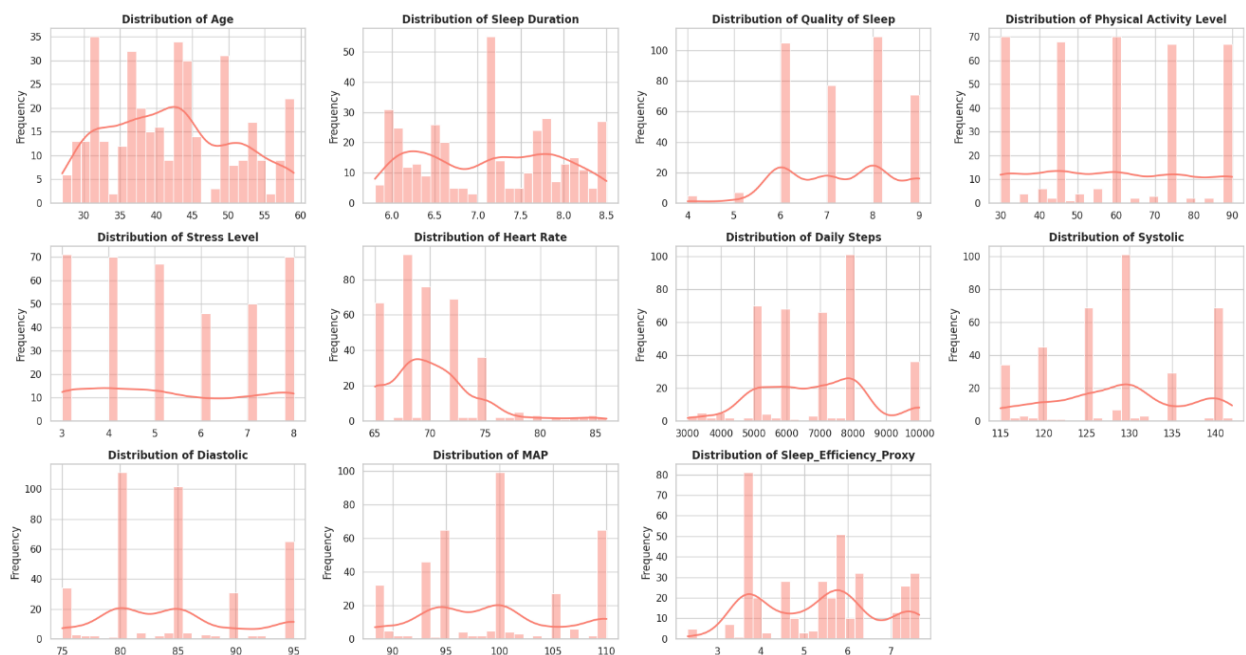
3. HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil dari proses penelitian yang telah dilakukan, mulai dari tahap pengolahan data hingga evaluasi model klasifikasi gangguan tidur. Selain itu, bab ini juga membahas analisis terhadap hasil yang diperoleh untuk memahami kinerja model serta pengaruh metode yang digunakan dalam penelitian.

3.1 Exploratory Data Analysis (EDA)

Tahap awal dalam analisis dilakukan dengan memahami karakteristik dataset melalui eksplorasi data. Proses ini bertujuan untuk mengidentifikasi pola, distribusi data, serta hubungan antar fitur yang dapat memengaruhi performa model klasifikasi.

Berdasarkan dataset *Sleep Health and Lifestyle*, terdapat fitur *Sleep Disorder* yang terdiri atas tiga kategori, yaitu *none* (tidak terdapat gangguan tidur), *insomnia* (kesulitan dalam memulai atau mempertahankan tidur), dan *sleep apnea* (gangguan pernapasan yang terjadi selama tidur). Distribusi variabel target mengindikasikan adanya ketidakseimbangan kelas (*imbalanced data*), di mana kategori *none* memiliki jumlah sampel yang jauh lebih besar dibandingkan kategori *sleep apnea* dan *insomnia*, masing-masing sebanyak 220 sampel, 79 sampel, dan 75 sampel. Temuan ini menunjukkan bahwa sebagian besar individu dalam dataset tidak mengalami gangguan tidur. Ketidakseimbangan distribusi kelas tersebut berpotensi menyebabkan model pembelajaran mesin cenderung bias terhadap kelas mayoritas, sehingga menurunkan kemampuan model dalam mengidentifikasi kelas minoritas secara akurat. Oleh karena itu, diperlukan penerapan teknik penanganan ketidakseimbangan data, seperti *Synthetic Minority Over-sampling Technique* (SMOTE), yang akan dibahas pada tahap selanjutnya.



Gambar 4. Distribusi Fitur Numerik pada Dataset Sleep Health and Lifestyle




Untuk melengkapi pemahaman terhadap karakteristik *dataset*, dilakukan analisis distribusi pada seluruh fitur numerik menggunakan visualisasi histogram yang dipadukan dengan kurva *Kernel Density Estimation* (KDE), sebagaimana ditunjukkan pada Gambar 4. Visualisasi ini mencakup berbagai variabel penting, seperti *Age*, *Sleep Duration*, *Quality of Sleep*, *Physical Activity Level*, *Stress Level*, *Heart Rate*, *Daily Steps*, *Systolic*, *Diastolic*, *MAP*, serta *Sleep Efficiency Proxy*.

Berdasarkan Gambar 4, terlihat bahwa sebagian besar fitur memiliki pola distribusi yang tidak sepenuhnya normal, dengan beberapa variabel menunjukkan kecenderungan *skewness* ke arah tertentu, seperti pada *Daily Steps* dan *Heart Rate* yang memiliki distribusi miring ke kanan. Selain itu, fitur seperti *Quality of Sleep* dan *Stress Level* cenderung bersifat diskrit karena berada dalam rentang skala penilaian tertentu, sehingga menghasilkan pola distribusi yang tersegmentasi. Variasi karakteristik distribusi ini menunjukkan bahwa setiap fitur memiliki sifat statistik yang berbeda, yang berpotensi memengaruhi proses pembelajaran model. Oleh karena itu, hasil analisis ini menjadi dasar penting dalam menentukan langkah prapemrosesan data, seperti normalisasi atau transformasi fitur, guna meningkatkan stabilitas dan performa model klasifikasi pada tahap selanjutnya.

Selanjutnya, dilakukan analisis korelasi antar fitur numerik menggunakan *heatmap*, seperti yang ditunjukkan pada Gambar 5. Hasil analisis menunjukkan beberapa hubungan yang signifikan antar variabel. Korelasi positif yang kuat ditemukan antara *Sleep Duration* dan *Quality of Sleep* ($r \approx 0.88$), yang menunjukkan bahwa semakin lama durasi tidur, maka kualitas tidur cenderung meningkat. Sebaliknya, *Stress Level* memiliki korelasi negatif yang kuat terhadap *Quality of Sleep* ($r \approx -0.90$) dan *Sleep Duration* ($r \approx -0.81$), yang menunjukkan bahwa tingkat stres yang tinggi berhubungan dengan penurunan kualitas dan durasi tidur.

Selain itu, ditemukan korelasi positif antara *Physical Activity Level* dan *Daily Steps* ($r \approx 0.77$), yang menunjukkan konsistensi antara aktivitas fisik dan jumlah langkah harian. Variabel *Stress Level* juga memiliki korelasi positif dengan *Heart Rate* ($r \approx 0.67$), yang mengindikasikan bahwa peningkatan stres dapat berhubungan dengan peningkatan detak jantung. Sebaliknya, *Quality of Sleep* memiliki korelasi negatif terhadap *Heart Rate* ($r \approx -0.66$), yang menunjukkan bahwa kualitas tidur yang baik cenderung berkaitan dengan kondisi fisiologis yang lebih stabil.



Gambar 5. Heatmap Korelasi Fitur Numerik

Berdasarkan analisis korelasi tambahan yang dipaparkan pada Tabel 3, ditemukan bahwa variabel turunan seperti *Mean Arterial Pressure* (MAP) memiliki korelasi yang sangat tinggi dengan *Systolic* ($r \approx 0.990$) dan *Diastolic* ($r \approx 0.996$), yang menunjukkan adanya redundansi informasi antar fitur tersebut. Selain itu, variabel *Sleep Efficiency Proxy* memiliki korelasi yang sangat kuat dengan *Quality of Sleep* ($r \approx 0.978$) dan *Sleep Duration* ($r \approx 0.958$), serta korelasi negatif yang kuat dengan *Stress Level* ($r \approx -0.886$). Hal ini menunjukkan bahwa kualitas tidur tidak hanya dipengaruhi oleh durasi tidur, tetapi juga oleh kondisi psikologis individu.

Secara keseluruhan, hasil eksplorasi data menunjukkan bahwa *dataset* memiliki karakteristik yang kompleks dengan hubungan yang saling berkaitan antar fitur. Selain itu, adanya ketidakseimbangan kelas dan korelasi yang kuat antar beberapa variabel menjadi pertimbangan penting dalam proses pemodelan. Temuan ini menjadi dasar dalam penerapan teknik SMOTE untuk mengatasi ketidakseimbangan data serta penggunaan algoritma yang mampu menangani kompleksitas hubungan antar fitur, seperti *Random Forest*.

Tabel 3. Pasangan Fitur dengan Nilai Korelasi Tertinggi (|r|)

NoFitur 1	Fitur 2	Nilai Korelasi (r)
1 Diastolic	MAP	0.996
2 Systolic	MAP	0.990

NoFitur 1	Fitur 2	Nilai Korelasi (r)
3 Quality of Sleep	Sleep Efficiency Proxy	0.978
4 Systolic	Diastolic	0.973
5 Sleep Duration	Sleep Efficiency Proxy	0.958
6 Quality of Sleep	Stress Level	-0.899
7 Stress Level	Sleep Efficiency Proxy	-0.886
8 Sleep Duration	Quality of Sleep	0.883
9 Sleep Duration	Stress Level	-0.811
10 Physical Activity Level	Daily Steps	0.773
11 Stress Level	Heart Rate	0.670
12 Quality of Sleep	Heart Rate	-0.660

3.2 Hasil Preprocessing Data

Tahap *preprocessing data* dilakukan untuk memastikan data siap digunakan dalam proses pemodelan serta untuk mengurangi potensi bias yang dapat memengaruhi kinerja model. Pada penelitian ini, *preprocessing* meliputi pembagian data, transformasi fitur, serta penanganan ketidakseimbangan kelas menggunakan SMOTE.

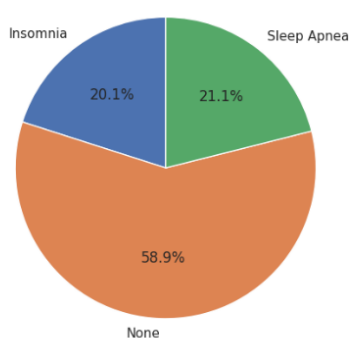
3.2.1 Hasil Pembagian Data

Dataset dibagi menjadi data latih (*training set*) dan data uji (*testing set*) dengan rasio 80:20. Pembagian ini dilakukan untuk memastikan bahwa model dilatih menggunakan sebagian besar data, sementara sisanya digunakan untuk mengevaluasi performa model secara objektif terhadap data yang belum pernah dilihat sebelumnya. Penggunaan rasio 80:20 dipilih karena memberikan keseimbangan antara jumlah data pelatihan yang cukup besar untuk pembelajaran model dan data pengujian yang representatif untuk evaluasi. Selain itu, pembagian data dilakukan dengan mempertahankan proporsi kelas (*stratified sampling*) agar distribusi kelas tetap konsisten antara data latih dan data uji.

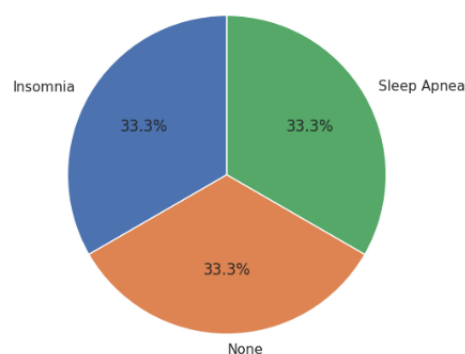
3.2.2 Hasil Implementasi SMOTE

Setelah pembagian data, ditemukan bahwa distribusi kelas pada data latih masih tidak seimbang, sebagaimana ditunjukkan pada Gambar 6 (sebelum SMOTE). Kelas *none* mendominasi dengan proporsi sekitar 58,9%, sedangkan kelas *insomnia* dan *sleep apnea* masing-masing hanya sekitar 20–21%. Ketidakseimbangan ini berpotensi menyebabkan model lebih cenderung memprediksi kelas mayoritas.

Untuk mengatasi permasalahan tersebut, diterapkan metode *Synthetic Minority Over-sampling Technique* (SMOTE) pada data latih. Hasil penerapan SMOTE ditunjukkan pada Gambar 6 (setelah SMOTE), di mana distribusi kelas menjadi seimbang dengan masing-masing kelas memiliki proporsi sekitar 33,3%. Penerapan SMOTE dilakukan hanya pada data latih untuk menghindari *data leakage*, sehingga data uji tetap merepresentasikan kondisi data asli. Dengan distribusi data yang lebih seimbang, model diharapkan mampu mempelajari pola dari setiap kelas secara lebih adil dan meningkatkan kemampuan dalam mendeteksi kelas minoritas



Gambar 6a. Perbandingan Distribusi Kelas Sebelum Penerapan SMOTE



Gambar 6b. Perbandingan Distribusi Kelas Setelah Penerapan SMOTE

Berdasarkan Gambar 6a dan Gambar 6b, terlihat bahwa penerapan metode SMOTE berhasil meningkatkan jumlah data pada kelas minoritas tanpa mengurangi jumlah data pada kelas mayoritas. Pada Gambar 6a (sebelum SMOTE), distribusi kelas menunjukkan ketidakseimbangan yang cukup signifikan, di mana kelas *none* mendominasi dengan proporsi sebesar 58,9%, sedangkan kelas *sleep apnea* dan *insomnia* masing-masing hanya sebesar 21,1% dan 20,1%. Setelah dilakukan oversampling menggunakan SMOTE pada Gambar 6b, distribusi data menjadi seimbang dengan proporsi yang sama pada setiap kelas, yaitu masing-masing sebesar 33,3%. Kondisi ini penting karena model *machine learning* sangat sensitif terhadap distribusi data. Dengan distribusi yang lebih seimbang, model tidak lagi cenderung bias terhadap kelas mayoritas, sehingga berpotensi meningkatkan performa model, khususnya dalam mengklasifikasikan kelas minoritas seperti *insomnia* dan *sleep apnea*.



3.3 Hasil Optimasi DCOA

Pada tahap ini dilakukan optimasi *hyperparameter* model *Random Forest* menggunakan algoritma *Domestic Cattle Optimization Algorithm* (DCOA). Tujuan dari proses ini adalah untuk menemukan kombinasi *hyperparameter* yang paling optimal sehingga dapat meningkatkan performa model klasifikasi. Dalam penelitian ini, setiap individu pada populasi DCOA direpresentasikan sebagai vektor kontinu dalam rentang [0,1], yang kemudian dikonversi menjadi nilai diskrit melalui proses *decoding*. Rentang nilai *hyperparameter* yang digunakan disajikan pada Tabel 4.

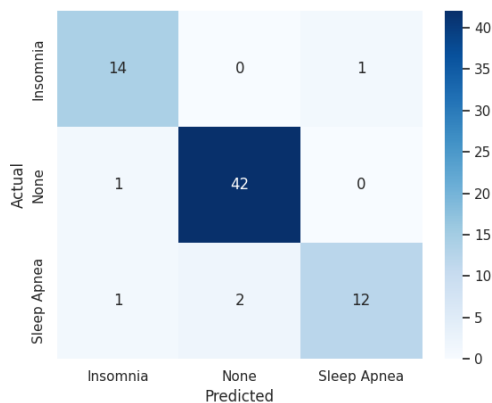
Tabel 4. Rentang *Hyperparameter Random Forest*

No	Hyperparameter	Rentang Nilai	Keterangan
1	n_estimators	20 – 100	Jumlah pohon dalam model
2	max_depth	4 – 18	Kedalaman maksimum pohon
3	min_samples_split	2 – 10	Minimum sampel untuk split
4	min_samples_leaf	1 – 5	Minimum sampel pada daun
5	max_features	{sqrt, log2}	Jumlah fitur yang dipilih


Berdasarkan hasil proses optimasi menggunakan DCOA, diperoleh kombinasi *hyperparameter* terbaik sebagai berikut: {'n_estimators': 49, 'max_depth': 16, 'min_samples_split': 7, 'min_samples_leaf': 4, 'max_features': 'sqrt'}. Hasil tersebut menunjukkan bahwa model tidak memerlukan jumlah pohon yang terlalu besar untuk mencapai performa optimal, melainkan lebih dipengaruhi oleh kedalaman pohon dan pengaturan jumlah sampel minimum pada proses pemisahan.

3.4 Hasil Evaluasi Model

Setelah dilakukan proses optimasi *hyperparameter* menggunakan DCOA, model *Random Forest* dilatih menggunakan data latih yang telah melalui proses penyeimbangan kelas dengan SMOTE. Selanjutnya, evaluasi model dilakukan pada data yang tidak terlibat selama proses pelatihan guna menilai kemampuan klasifikasi secara objektif, dengan hasil yang divisualisasikan dalam bentuk *confusion matrix* pada Gambar 7b. Jika dibandingkan dengan model *baseline Random Forest* tanpa optimasi dan tanpa penyeimbangan data (Gambar 7a), terlihat adanya peningkatan performa yang signifikan. Pada Gambar 7b, model mampu mengklasifikasikan hampir seluruh data dengan sangat akurat, ditunjukkan oleh nilai diagonal yang dominan (13 insomnia, 44 none, dan 16 sleep apnea) serta tidak adanya kesalahan klasifikasi pada kelas "None" dan "Sleep Apnea". Sebaliknya, pada Gambar 7a masih terdapat beberapa kesalahan prediksi, seperti data insomnia yang salah diklasifikasikan sebagai *sleep apnea*, serta data *sleep apnea* yang keliru diprediksi sebagai insomnia dan none. Selain itu, jumlah prediksi benar pada kelas "None" juga sedikit menurun dibandingkan model yang telah dioptimasi. Hal ini menunjukkan bahwa kombinasi DCOA dan SMOTE tidak hanya meningkatkan akurasi keseluruhan, tetapi juga memperbaiki kemampuan model dalam membedakan antar kelas, terutama pada kelas minoritas yang sebelumnya lebih rentan terhadap misklasifikasi.



Gambar 7a. *Confusion Matrix Model RF Baseline*



Gambar 7b. *Confusion Matrix Model RF + DCOA dan SMOTE*

Berdasarkan Gambar 7a dan 7b, dapat diamati bahwa model memiliki kemampuan klasifikasi yang sangat baik, terutama setelah melalui proses optimasi dan penyeimbangan data. Pada Gambar 7b, model mampu mengklasifikasikan seluruh data pada kelas *None* dengan sempurna, yaitu sebanyak 44 data tanpa kesalahan prediksi (perfect classification). Temuan tersebut mengindikasikan bahwa model mampu mengenali kelas mayoritas dengan tingkat ketepatan yang sangat baik. Selain itu, performa pada kelas *sleep apnea* juga sangat optimal, di mana seluruh 16 data berhasil diprediksi dengan benar tanpa adanya misklasifikasi. Sementara itu, pada kelas insomnia, terdapat 2 data yang salah diklasifikasikan sebagai *sleep apnea* dari total 15 data, yang mengindikasikan masih adanya sedikit ambiguitas dalam membedakan kedua kelas tersebut. Kemungkinan hal ini disebabkan oleh kemiripan karakteristik fitur antara insomnia dan *sleep apnea*, sehingga batas keputusan (decision boundary) model belum sepenuhnya optimal dalam memisahkan keduanya.



Jika dibandingkan dengan Gambar 7a sebagai model *baseline Random Forest*, terlihat bahwa tingkat kesalahan klasifikasi masih lebih tinggi. Pada model *baseline*, kesalahan tidak hanya terjadi pada kelas *insomnia*, tetapi juga pada kelas *sleep apnea* yang mengalami misklasifikasi ke kelas *none* dan *insomnia*. Selain itu, pada kelas *none* juga terdapat kesalahan prediksi, meskipun jumlahnya relatif kecil. Hal ini menunjukkan bahwa tanpa optimasi *hyperparameter* dan penyeimbangan data, model cenderung mengalami penurunan performa, terutama dalam membedakan kelas-kelas yang memiliki distribusi tidak seimbang.

Sebagai pembandingan, hasil evaluasi model *baseline* disajikan pada Tabel 5. Berdasarkan tabel tersebut, model memperoleh nilai akurasi sebesar 93%, yang menunjukkan bahwa model sudah memiliki performa yang cukup baik dalam melakukan klasifikasi. Nilai *precision*, *recall*, dan *F1-score* pada masing-masing kelas juga berada pada kisaran yang relatif tinggi. Namun demikian, masih terdapat ketidakseimbangan performa antar kelas, khususnya pada kelas *sleep apnea* yang memiliki nilai *recall* sebesar 0,80, yang mengindikasikan bahwa sebagian data pada kelas tersebut belum terdeteksi dengan optimal. Kondisi ini menunjukkan bahwa performa model dasar masih dipengaruhi oleh ketidakseimbangan data sehingga kemampuan klasifikasinya terhadap kelas minoritas belum maksimal.

Sementara itu, hasil evaluasi model *Random Forest* yang telah dipadukan dengan SMOTE dan DCOA secara kuantitatif disajikan pada Tabel 5. Berdasarkan tabel tersebut, model memperoleh nilai *accuracy* sebesar 97,33%, yang menunjukkan tingkat ketepatan prediksi yang sangat tinggi. Nilai *precision* pada seluruh kelas berada pada kisaran tinggi, bahkan mencapai 100% pada kelas *Insomnia* dan *None*, yang menunjukkan bahwa model sangat jarang melakukan kesalahan dalam memprediksi kelas tersebut.

Tabel 5. Hasil Evaluasi Model *Random Forest* (*Baseline*)

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	Support
Insomnia	0.88	0.93	0.90	15
None	0.95	0.98	0.97	43
Sleep Apnea	0.92	0.80	0.86	15
Accuracy			0.93	73
Macro Avg	0.92	0.90	0.91	73
Weighted Avg	0.93	0.93	0.93	73

Di lain sisi, hasil evaluasi model yang telah dioptimasi menggunakan SMOTE dan DCOA secara kuantitatif disajikan pada Tabel 6. Berdasarkan tabel tersebut, model memperoleh nilai akurasi sebesar 97,33%, dengan *precision* 97,63%, *recall* 97,33%, dan *F1-score* sebesar 97,32%. Nilai-nilai tersebut menunjukkan adanya peningkatan performa dibandingkan model *baseline*. Selain itu, distribusi performa antar kelas menjadi lebih seimbang, di mana nilai *recall* pada kelas minoritas seperti *sleep apnea* meningkat secara signifikan. Hal ini mengindikasikan bahwa penerapan SMOTE dan optimasi DCOA berkontribusi dalam meningkatkan kemampuan model dalam mendeteksi seluruh kelas secara lebih optimal.

Tabel 6. Hasil Evaluasi Model *Random Forest*

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	Support
Insomnia	1.000	0.867	0.929	15
None	1.000	1.000	1.000	44
Sleep Apnea	0.889	1.000	0.941	16
Accuracy			0.973	75
Macro Avg	0.963	0.956	0.957	75
Weighted Avg	0.976	0.973	0.973	75

Jika dibandingkan dengan model *baseline Random Forest*, pendekatan yang diusulkan menunjukkan peningkatan performa yang konsisten pada seluruh metrik evaluasi. Akurasi model meningkat dari 93% pada *baseline* menjadi 97,33% setelah penerapan SMOTE dan optimasi DCOA. Peningkatan juga terlihat pada nilai *precision*, *recall*, dan *F1-score*, yang masing-masing mencapai 97,63%, 97,33%, dan 97,32%. Secara khusus, perbaikan yang signifikan terjadi pada kemampuan model dalam mendeteksi kelas minoritas, seperti *sleep apnea*, yang sebelumnya memiliki nilai *recall* sebesar 0,80 pada model *baseline* dan meningkat hingga mencapai performa yang lebih optimal pada model usulan. Hal ini menunjukkan bahwa penerapan SMOTE efektif dalam mengatasi ketidakseimbangan distribusi data, sehingga model dapat mempelajari pola pada kelas minoritas dengan lebih baik. Di sisi lain, optimasi *hyperparameter* menggunakan DCOA berkontribusi dalam menemukan konfigurasi model yang lebih sesuai dengan karakteristik data, sehingga meningkatkan kemampuan generalisasi model secara keseluruhan. Meskipun demikian, peningkatan performa ini tetap perlu diinterpretasikan secara hati-hati mengingat ukuran dataset yang relatif terbatas, sehingga potensi *overfitting* masih mungkin terjadi.

3.5 Analisis Perbandingan dengan Peneliti Terdahulu

Untuk menilai efektivitas metode yang diusulkan, dilakukan perbandingan dengan beberapa penelitian terdahulu yang menggunakan dataset *Sleep Health and Lifestyle*. Ringkasan perbandingan performa model disajikan pada Tabel 7.

**Tabel 7.** Perbandingan Performa Model dengan Penelitian Terdahulu

NoPeneliti	Metode	Accuracy	Precision	Recall	F1-Score
1 [11] Migliaccio et al.	Logistic Regression	86.9%	87.7%	87.5%	87.1%
2 [12] Rajesh et al.	Voting Classifier (GB)	88%	90%	86%	88%
3 [13] Stephen & Islam	CNN-LSTM	85.6%	83.6%	76.5%	79.4%
4 [14] Kumar et al.	AdaBoost	91%	90%	87%	88%
5 [25] Taher et al.	Random Forest	90.26%	91%	89%	90%
6 Penelitian ini	RF + SMOTE + DCOA	97.33%	97.63%	97.33%	97.32%

Sejumlah penelitian sebelumnya telah mengkaji penerapan *machine learning* dalam klasifikasi kesehatan tidur dengan berbagai pendekatan dan tingkat keberhasilan yang berbeda. Migliaccio et al. [11] menggunakan model *Logistic Regression* dan memperoleh akurasi sebesar 86,9%, *precision* 87,7%, *recall* 87,5%, serta *F1-score* 87,1%. Selanjutnya, Rajesh T. et al. [12] menerapkan metode *ensemble learning* melalui *Voting Classifier* berbasis *Gradient Boosting* dan mencapai akurasi sebesar 88%, *precision* 90%, *recall* 86%, serta *F1-score* 88%. Pendekatan berbasis *deep learning* juga dikembangkan oleh Stephen dan Islam [13] menggunakan model *hybrid CNN-LSTM*, yang menghasilkan akurasi sebesar 85,6%, *precision* 83,6%, *recall* 76,5%, dan *F1-score* 79,4%. Sementara itu, Kumar et al. [14] menggunakan algoritma *AdaBoost* dan memperoleh akurasi sebesar 91%, *precision* 90%, *recall* 87%, dan *F1-score* 88%. Selain itu, Taher dan Ayon [25] menerapkan *preprocessing* berupa *label encoding* dan normalisasi *MinMax*, kemudian menggunakan model *Random Forest* yang menghasilkan akurasi sebesar 90,26%, *precision* 91%, *recall* 89%, dan *F1-score* 90%.

Jika dibandingkan dengan penelitian-penelitian tersebut, model yang diusulkan dalam penelitian ini menunjukkan performa yang lebih unggul dengan akurasi sebesar 97,33%, *precision* 97,63%, *recall* 97,33%, dan *F1-score* 97,32%. Peningkatan ini cukup signifikan, terutama jika dibandingkan dengan metode klasik seperti *Logistic Regression* maupun pendekatan *deep learning* seperti *CNN-LSTM* yang memiliki performa lebih rendah. Keunggulan performa model dalam penelitian ini tidak terlepas dari kombinasi beberapa pendekatan yang digunakan secara terintegrasi. Pertama, penerapan *SMOTE* terbukti mampu mengatasi permasalahan ketidakseimbangan data, sehingga model dapat belajar secara lebih optimal terhadap kelas minoritas seperti *insomnia* dan *sleep apnea*. Hal ini berkontribusi langsung terhadap peningkatan nilai *recall* dan *F1-score* dibandingkan penelitian sebelumnya yang tidak secara eksplisit menangani *imbalanced data*. Kedua, optimasi *hyperparameter* menggunakan *DCOA* memberikan kontribusi dalam menemukan konfigurasi model yang lebih optimal dibandingkan metode konvensional. Berbeda dengan pendekatan seperti *Grid Search* atau *Random Search* yang bersifat eksplorasi terbatas, *DCOA* menunjukkan potensi dalam menemukan konfigurasi *hyperparameter* yang efektif pada penelitian ini.

Secara keseluruhan, hasil perbandingan menunjukkan bahwa pendekatan yang diusulkan dalam penelitian ini, yaitu kombinasi *SMOTE*, *DCOA*, dan *Random Forest*, mampu memberikan peningkatan performa yang signifikan dibandingkan metode yang telah digunakan pada penelitian sebelumnya. Hasil penelitian menunjukkan bahwa metode yang diusulkan memiliki prospek yang menjanjikan dalam pengembangan sistem deteksi gangguan tidur berbasis data.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, pendekatan yang diusulkan dalam penelitian ini, yaitu kombinasi *Random Forest*, *Synthetic Minority Over-sampling Technique (SMOTE)*, dan *Domestic Cattle Optimization Algorithm (DCOA)*, menunjukkan potensi dalam meningkatkan kinerja model klasifikasi gangguan tidur atau somnipati. Penerapan *SMOTE* membantu mengatasi ketidakseimbangan distribusi kelas, sementara *DCOA* berperan dalam mengoptimalkan *hyperparameter* sehingga berkontribusi terhadap peningkatan performa model. Hasil evaluasi menunjukkan bahwa model mencapai nilai akurasi sebesar 97,33%, *precision* 97,63%, *recall* 97,33%, dan *F1-score* sebesar 97,32%. Nilai-nilai tersebut mengindikasikan bahwa model memiliki kemampuan yang baik dalam mengklasifikasikan data pada seluruh kelas, termasuk dalam mendeteksi kelas minoritas. Namun demikian, mengingat ukuran *dataset* yang relatif terbatas, hasil yang diperoleh perlu diinterpretasikan secara hati-hati karena masih terdapat potensi *overfitting* yang dapat memengaruhi kemampuan generalisasi model terhadap data baru. Oleh karena itu, temuan dalam penelitian ini lebih tepat dipandang sebagai indikasi awal terhadap efektivitas pendekatan yang diusulkan. Penelitian selanjutnya disarankan untuk melakukan validasi menggunakan *dataset* yang lebih besar dan lebih beragam, serta membandingkan dengan metode optimasi lainnya guna memperoleh pemahaman yang lebih komprehensif terhadap kinerja model.

REFERENCES

- [1] J. M. Dzierzewski et al., "Lifestyle Factors and Sleep Health across the Lifespan," *Public Health*, vol. 18, p. 6626, 2021, doi: 10.3390/ijerph18126626.
- [2] L. Sun, L. Zhuang, M. Dai, and Y. Zhou, "Intelligent automatic sleep staging model based on CNN and LSTM," *Frontiers (Boulder)*, Jul. 2022, doi: 10.3389/fpubh.2022.946833.
- [3] M. Santilli et al., "Prevalence of Obstructive Sleep Apnea Syndrome: A Single-Center Retrospective Study," *Public Health*, vol. 18, p. 10277, 2021, doi: 10.3390/ijerph181910277.
- [4] C. Haddad, H. Sacre, S. Tawil, P. Salameh, and S. A. Bahous, "The triangulation of multimorbidity: A systematic review of primary sleep disorders, hypertension, and psychiatric disorders," *PLOS Global Public Health*, vol. 5, no. 10 October, Oct. 2025, doi: 10.1371/journal.pgph.0005216.



- [5] C. Olivera-López, A. Jiménez-Genchi, D. Ortega-Robles, M. Valencia-Flores, S. Cansino, and J. Salvador-Cruz, "Polysomnographic parameters associated with cognitive function in patients with major depression and insomnia," *CNS Spectr.*, vol. 29, no. 3, pp. 197–205, Jun. 2024, doi: 10.1017/S1092852924000257.
- [6] A. A. Alhussan, E. S. M. El-Kenawy, D. S. Khafaga, and M. M. Eid, "Enhancing sleep disorder classification using machine learning and metaheuristic optimization techniques," *Biomed. Signal Process. Control*, vol. 110, Dec. 2025, doi: 10.1016/j.bspc.2025.108204.
- [7] V. Mansouri *et al.*, "Human Gene Expression Profile Analysis of Insomnia and Pre-insomnia Disorders: A Cellular Study," *Basic Clin. Neurosci.*, vol. 16, no. 5, pp. 929–940, Sep. 2025, doi: 10.32598/bcn.2025.6876.4.
- [8] F. Y. Arini, L. A. Djuanda, A. H. P. Kristianto, M. N. Tiadah, A. P. Wicaksono, and F. A. A. Putra, "Performance Evaluation of Gradient Boosting Techniques for Predicting Customer Purchase Decisions," *Jurnal Teknik Informatika (JUTIF)*, vol. 7, no. 2, pp. 2723–3863, 2026, doi: 10.52436/1.jutif.2026.7.2.5461.
- [9] T. Alshammari, "Applying Machine Learning Algorithms for the Classification of Sleep Disorders," *IEEE Access*, Mar. 2024, doi: 10.1109/ACCESS.2023.0322000.
- [10] T. Allahviranloo, F. H. Lotfi, and Z. Moghaddas, "Decision Making in Healthcare Systems," in *Studies in System, Decision and Control 513*, Springer, 2024, pp. 257–266. doi: 10.1007/978-3-031-46735-6.
- [11] M. Migliaccio, A. Abate, C. Bisogni, and L. Cimmino, "Machine Learning-Driven Stress Prediction: A Comparative Analysis and Web Application Using the Sleep Health and Lifestyle Dataset," in *Proceedings - 6th International Conference on Bio-Engineering for Smart Technologies, BioSMART 2025*, Institute of Electrical and Electronics Engineers Inc., 2025. doi: 10.1109/BioSMART66413.2025.11046172.
- [12] T. R. Rajesh, G. Sravani, B. Lavanya, K. Mithila, and R. Surendran, "Exploring Sleep Disorder and Lifestyle Analysis Through Data Preprocessing and Ensemble Learning Techniques," in *2nd International Conference on Sustainable Computing and Smart Systems, ICSCSS 2024 - Proceedings*, Institute of Electrical and Electronics Engineers Inc., 2024, pp. 791–795. doi: 10.1109/ICSCSS60660.2024.10625498.
- [13] C. V. Stephen and T. Islam, "Lifestyle to Sleep Health: A CNN-LSTM Approach for Predicting Sleep Quality and Disorders," in *2024 International Conference on Intelligent Cybernetics Technology and Applications, ICICYTA 2024*, Institute of Electrical and Electronics Engineers Inc., 2024, pp. 1222–1227. doi: 10.1109/ICICYTA64807.2024.10912866.
- [14] M. Kumar, B. Ahmed, H. M. Mishra, A. K. Jha, P. K. Sikarwal, and S. Rampal, "Predictive Sleep Disorder Modelling: Using Machine Learning with Lifestyle and Sleep Health Data," in *Proceedings - 3rd International Conference on Advances in Computing, Communication and Applied Informatics, ACCAI 2024*, Institute of Electrical and Electronics Engineers Inc., 2024. doi: 10.1109/ACCAI61061.2024.10602153.
- [15] F. Y. Arini, F. R. N. Saputra, Liafathra, R. D. R. Artama, and S. Pichai, "Optimizing Heart Disease Prediction: A Collaborative Approach of Support Vector Regression and Grey Wolf Optimizer," in *2025 International Conference on Smart Computing, IoT and Machine Learning, SIML 2025*, Institute of Electrical and Electronics Engineers Inc., 2025. doi: 10.1109/SIML65326.2025.11080978.
- [16] K. Ghosh, C. Bellinger, R. Corizzo, P. Branco, B. Krawczyk, and N. Japkowicz, "The class imbalance problem in deep learning," *Mach. Learn.*, vol. 113, no. 7, pp. 4845–4901, Jul. 2024, doi: 10.1007/s10994-022-06268-8.
- [17] A. V. Benjafeld *et al.*, "Estimation of the global prevalence and burden of insomnia: a systematic literature review-based analysis," Aug. 01, 2025, *W.B. Saunders Ltd*. doi: 10.1016/j.smr.2025.102121.
- [18] A. Kalkanis, D. Lenkens, P. Steiropoulos, and D. Testelmans, "Sleep regularity as an important component of sleep hygiene: a systematic review," Dec. 01, 2025, *W.B. Saunders Ltd*. doi: 10.1016/j.smr.2025.102203.
- [19] G. Stavropoulos, R. van Voorstenbosch, F. J. van Schooten, and A. Smolinska, "Random Forest and Ensemble Methods," in *Comprehensive Chemometrics: Chemical and Biochemical Data Analysis, Second Edition: Four Volume Set*, vol. 3, Elsevier, 2020, pp. 661–672. doi: 10.1016/B978-0-12-409547-2.14589-5.
- [20] F. T. Endomba, P. Y. Tchebegna, E. Chiabi, D. L. Angong Wouna, C. Guillet, and J. C. Chauvet-Gélinier, "Epidemiology of insomnia disorder in older persons according to the Diagnostic and Statistical Manual of Mental Disorders: a systematic review and meta-analysis," Dec. 01, 2023, *Springer Science and Business Media Deutschland GmbH*. doi: 10.1007/s41999-023-00862-2.
- [21] H. D. Purnomo, T. Gonsalves, E. Mailoa, F. Y. Santoso, and M. R. Pribadi, "Metaheuristics Approach for Hyperparameter Tuning of Convolutional Neural Network," *Jurnal RESTI*, vol. 8, no. 3, pp. 340–345, Jun. 2024, doi: 10.29207/resti.v8i3.5730.
- [22] Z. Koscova *et al.*, "From sleep patterns to heart rhythm: Predicting atrial fibrillation from overnight polysomnograms," *J. Electrocardiol.*, vol. 86, Sep. 2024, doi: 10.1016/j.jelectrocard.2024.153759.
- [23] K. Kim, "Noise Avoidance SMOTE in Ensemble Learning for Imbalanced Data," *IEEE Access*, vol. 9, pp. 143250–143265, Oct. 2021, doi: 10.1109/ACCESS.2021.3120738.
- [24] J. Zhang, "Domestic Cattle Optimization Algorithm," *Preprint*, Aug. 2025, doi: 10.13140/RG.2.2.15151.04009.
- [25] A. Taher and W. I. Z. Ayon, "Exploring Sleep Disorders: A Comparative Analysis of Machine Learning Algorithms on Sleep Health and Lifestyle Data," in *PEEIACON 2024 - International Conference on Power, Electrical, Electronics and Industrial Applications*, Institute of Electrical and Electronics Engineers Inc., 2024, pp. 71–75. doi: 10.1109/PEEIACON63629.2024.10800593.