P-ISSN : 2549-7480
E-ISSN : 2549-6301

JURNAL ILMIAH INFORMATIKA
E-ISSN : 2549-6301
ISSN : 2549-7480
Faculty of Sains and Technology, Ibrahimy University
S4-Accredited : 105/E/KPT/2022
Journal page is available to : https://journal.ibrahimy.ac.id/index.php/JIMI

KOMPARASI MODEL MACHINE LEARNING UNTUK KLASIFIKASI RISIKO INSOMNIA PADA MAHASISWA BERBASIS INSOMNIA SEVERITY INDEX (ISI)

Fransiska Setiawati Juhadin[1)], Risanto Darmawan[2] , Elmi Devia[3]

[1,2,3] *Program Studi Teknik Informatika, Fakultas Teknik, Universitas Krisnadwipayana, Jakarta, Indonesia*

email: [1] fransiskaaaa18@gmail.com , [2] risantodarmawan@unkris.ac.id , [3] elmidevia@unkris.ac.id

ARTICLE INFO

Article History:
Recieved : 03 Oktober 2026
Accepted : 23 Oktober 2026
Published : 10 November 2026

Keywords:
Insomnia;
Machine Learning;
Classification;
Insomnia Severity Index (ISI);
College Students;

IEEE style in citing this article:
F. S. Juhadin., R. Darmawan., E. Devia,"Komparasi Model Machine Learning untuk Klasifikasi Risiko Insomnia pada Mahasiswa Berbasis ISI," *jurnal.ilmiah.informatika*, vol. 11, no. 2, pp. 156-164, Des.2026.

Corresponding Author:
Fransiska Setiawati Juhadin
Risanto Darmawan
Elmi Devia
Universitas Krisnadwipayana

ABSTRACT

Insomnia is common among university students, so early detection of its severity is important. This study compares Support Vector Machine (SVM), Random Forest, and XGBoost for classifying insomnia risk into four categories (no insomnia, mild, moderate, severe) using the seven items of the Insomnia Severity Index (ISI) as the only instrument. Class weight and SMOTE are compared for handling class imbalance, and feature importance identifies the most influential ISI items. Models were trained on a public dataset of 1,047 respondents and evaluated internally (210 samples) and externally on primary data from 131 students not used in training. With class weight, SVM performed best, with an F1-macro of 0.9438 (internal) and 0.9164 (external). Random Forest had the highest internal accuracy (97.14%) but fell to 83.97% externally, and its recall for severe insomnia dropped to 0.6596 versus 0.9362 for SVM. Items 2, 4, and 7 were the most influential. External evaluation is therefore necessary, and SVM with class weight is suitable for ISI-based screening of student insomnia.

© 2026 Jurnal Ilmiah Informatika (Scientific Informatics Journal) with CC BY NC licence

P-ISSN : 2549-7480
F. S. Juhadin dkk/ JIMI 11 (2) pp. 156-164 E-ISSN : 2549-6301

1. PENDAHULUAN

Insomnia merupakan gangguan tidur yang prevalensinya terus meningkat dan menjadi masalah kesehatan masyarakat secara global; kondisi ini diperkirakan memengaruhi hingga 40% populasi umum.

insomnia pada mahasiswa sarjana mencapai 46,9% [2]. Kualitas tidur yang buruk pada mahasiswa berhubungan dengan menurunnya performa akademik, kesehatan mental, dan kualitas hidup [3]. Kondisi tersebut menunjukkan pentingnya deteksi dini insomnia sebelum kondisinya berkembang menjadi lebih berat.

Insomnia Severity Index (ISI) adalah kuesioner laporan mandiri yang terdiri atas tujuh butir untuk menilai tingkat keparahan insomnia, dengan skala Likert 0–4 dan skor total 0–28; semakin tinggi skor, semakin berat insomnia [4]. Skor total dikelompokkan menjadi empat kategori, yaitu tidak insomnia (0–7), insomnia ringan (8–14), insomnia sedang (15–21), dan insomnia berat (22–28). Pengelompokan ini sederhana, tetapi pendekatan *machine learning* (ML) dapat membantu mengklasifikasikan risiko secara lebih sistematis. Huang dan Huang menunjukkan bahwa model ML mampu memprediksi risiko insomnia sekaligus mengidentifikasi faktor risiko yang paling berpengaruh [5], dan model ML berbasis pohon keputusan telah digunakan untuk memprediksi insomnia pada mahasiswa [6].

Sejumlah penelitian terdahulu telah menerapkan ML pada data tidur, tetapi masing-masing masih memiliki keterbatasan. Lee dkk. menyederhanakan ISI dengan model ML pada populasi pasien, bukan mahasiswa, tanpa membandingkan SVM, Random Forest, dan XGBoost [7]. Khasanah dkk. mengklasifikasikan gangguan tidur dengan Random Forest tanpa menggunakan ISI dan tanpa analisis *feature importance* [8]. Maruf dan Chowdhury melaporkan XGBoost sebagai model dengan akurasi tertinggi pada prediksi kualitas tidur multifaktor [9]. Yao dkk. memakai seleksi fitur LASSO pada data kualitas tidur mahasiswa tanpa membandingkan beberapa algoritma [10].

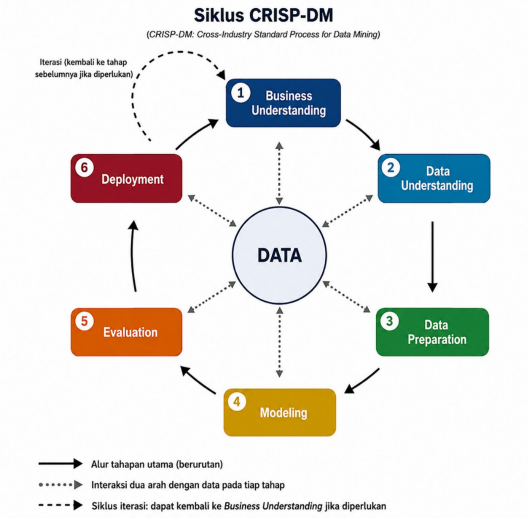
Penelitian yang paling dekat, Chowdhury dkk., menyasar mahasiswa dengan Random Forest dan XGBoost, tetapi ISI hanya satu dari tiga instrumen yang digunakan bersamaan, SVM tidak dilibatkan.

Penelitian ini menjawab tiga masalah. Pertama, data risiko insomnia tidak seimbang karena kelas sedang dan berat jauh lebih sedikit daripada kelas tidak insomnia dan ringan, sehingga model rawan bias ke kelas mayoritas. Kedua, Random Forest dan XGBoost bersifat *black box*, sehingga butir ISI yang paling menentukan hasil klasifikasi belum diketahui. Ketiga, performa model belum tentu konsisten antara data validasi internal dan data baru. Tujuan penelitian adalah (a) membandingkan model SVM, Random Forest, dan XGBoost berbasis skor ISI dengan dua skema penanganan ketidakseimbangan kelas, yaitu *class weight* dan SMOTE; (b) mengidentifikasi butir ISI yang paling berpengaruh melalui *feature importance*; dan (c) mengevaluasi *accuracy*, *precision*, *recall*, dan *F1-score* pada data uji internal maupun data kuesioner primer yang independen. Kebaruan penelitian ini terletak pada penggunaan ISI sebagai instrumen tunggal, perbandingan tiga algoritma dan dua skema penyeimbangan secara bersamaan pada populasi mahasiswa, evaluasi eksternal pada data primer, dan luaran berupa aplikasi pengujian berbasis Streamlit.

DOI : https://doi.org/10.35316/jimi.v11i2.156-164
© 2026 Jurnal Ilmiah Informatika with CC BY NC licence

2. METODE PENELITIAN

Penelitian mengikuti kerangka *Cross Industry Standard Process for Data Mining* (CRISP-DM) yang terdiri atas enam tahap, yaitu *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment* (Gambar 1). CRISP-DM dipilih karena sistematis, iteratif, dan sesuai untuk penelitian yang melibatkan dua sumber data serta perbandingan beberapa algoritma.



Gambar 1. Siklus CRISP-DM yang digunakan dalam penelitian

2.1 Data Penelitian

Data primer dikumpulkan melalui kuesioner daring (Google Form) pada Mei 2026 dan menghasilkan 131 responden. Data sekunder adalah *dataset* terbuka dari repositori Zenodo berisi 1.047 baris dengan tujuh butir jawaban ISI (question1–question7), tujuh kolom waktu pengisian, dan label kategori. Kolom waktu pengisian dihapus karena tidak memiliki landasan teoretis sebagai indikator keparahan insomnia. Data sekunder digunakan untuk pelatihan dan uji internal, sedangkan data primer digunakan hanya sebagai uji eksternal dan tidak pernah dilibatkan dalam pelatihan. Distribusi kelas kedua data berbeda tajam (Tabel 1): data sekunder didominasi kelas tidak insomnia dan ringan, sedangkan data primer didominasi kelas sedang dan berat.

Tabel 1. Distribusi Kelas pada Data Sekunder dan Data Primer

Kelas	Sekunder (n=1.047)	Primer (n=131)
Tidak Insomnia	420 (40,11%)	28 (21,37%)
Insomnia Ringan	403 (38,49%)	10 (7,63%)
Insomnia Sedang	194 (18,53%)	46 (35,11%)
Insomnia Berat	30 (2,87%)	47 (35,88%)

2.2 Pra-pemrosesan dan Ekstraksi Fitur

Pemeriksaan menunjukkan tidak ada nilai kosong maupun data duplikat pada kedua data, dan seluruh label sesuai dengan titik potong skor ISI. Nilai yang terdeteksi sebagai *outlier* menurut metode IQR tetap dipertahankan karena masih berada dalam rentang skala resmi 0–4. Kelayakan instrumen diuji dengan korelasi Pearson antara skor butir dan skor total (validitas) serta Cronbach's Alpha (reliabilitas). Ekstraksi fitur memakai agregasi statistik mengikuti prinsip *summated rating scale*: skor total ISI dihitung dengan Persamaan (1), sedangkan rata-rata dan simpangan baku skor butir dipakai untuk eksplorasi data. Masukan model tetap tujuh butir asli (question1–question7) agar model mempelajari pola pada tingkat butir; kualitas rekayasa fitur diketahui berpengaruh besar terhadap performa model [16].

$$ISI_{total} = \sum_{i=1}^{7} x\, i, \quad x_i \in \{0,1,2,3,4\} \tag{1}$$

Data sekunder dibagi secara berstrata menjadi 80% data latih (837 baris) dan 20% data uji internal (210 baris). Standardisasi fitur dengan *StandardScaler* hanya di-*fit* pada data latih, lalu

P-ISSN : 2549-7480
F. S. Juhadin dkk/ JIMI 11 (2) pp. 156-164 E-ISSN : 2549-6301

diterapkan pada data uji internal dan data primer untuk mencegah *data leakage*. Label dikodekan menurut urutan keparahan.

2.3 Pemodelan

Tiga algoritma dilatih pada data latih yang sama dengan *random_state* = 42; XGBoost mengacu pada [11]. SVM memakai kernel *Radial Basis Function* dengan *probability* aktif. Random Forest dan XGBoost masing-masing memakai 200 pohon, dan XGBoost memakai *eval_metric* mlogloss. Dua skema penanganan ketidakseimbangan kelas dibandingkan. Pada Skema 1 (*class weight*), SVM dan Random Forest memakai *class_weight* = balanced, sedangkan XGBoost memakai *sample_weight* yang dihitung dengan *compute_sample_weight* skema balanced karena parameter *class_weight* tidak tersedia pada API scikit-learn-nya. Pada Skema 2, SMOTE diterapkan hanya pada data latih sehingga setiap kelas berjumlah 336 sampel (kelas Insomnia Berat naik dari 24 sampel). Eksperimen dijalankan di Google Colab dengan Python, Pandas, NumPy, Scikit-Learn, XGBoost, dan Imbalanced-learn.

2.4 Evaluasi

Kinerja diukur dengan *accuracy*, *precision*, *recall*, dan *F1-score* pada data uji internal (n = 210) dan data primer (n = 131). *Precision*, *recall*, dan *F1-score* dihitung dengan rata-rata makro agar kelas minoritas Insomnia Berat tetap diperhitungkan secara setara [12]–[14]. Rumusnya ditunjukkan pada Persamaan (2) sampai (5), dengan TP, TN, FP, dan FN masing-masing adalah *true positive*, *true negative*, *false positive*, dan *false negative*. Model terbaik ditentukan berdasarkan *F1-macro* pada evaluasi eksternal dan selisih performa antara evaluasi internal dan eksternal sebagai indikator kemampuan generalisasi.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+F} \quad (2)$$

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

$$Recall = \frac{TP}{TP+FN} \quad (4)$$

$$F1 - Score = 2\ x\ \frac{Precision\ x\ Recall}{Precision+Recal} \quad (5)$$

2.5 Penerapan Aplikasi Pengujian

Model terbaik diimplementasikan sebagai antarmuka pengujian berbasis Streamlit. Aplikasi ini tidak ditujukan sebagai sistem produksi, melainkan sebagai alat uji untuk memvalidasi prediksi model secara cepat.

3. HASIL DAN PEMBAHASAN

3.1 Kelayakan Instrumen dan Karakteristik Data

Seluruh tujuh butir ISI valid pada kedua data. Pada data sekunder (n = 1.047), nilai r hitung berkisar 0,6923–0,8835 dengan Cronbach's Alpha 0,9141; pada data primer (n = 131), r hitung berkisar 0,816–0,947 dengan Cronbach's Alpha 0,946. Keduanya termasuk kategori sangat reliabel. Uji *Cronbach's Alpha if Item Deleted* pada data sekunder menunjukkan bahwa penghapusan question3 hanya menaikkan alpha menjadi 0,9165; butir tersebut tetap dipertahankan karena ISI merupakan instrumen baku yang telah divalidasi secara klinis [4]. Rata-rata skor total ISI meningkat monoton menurut kategori, yaitu 1,89 (tidak insomnia), 9,88 (ringan), 17,22 (sedang), dan 24,22 (berat), sehingga butir ISI mampu membedakan keempat kategori.

3.2 Kinerja Model dengan Class Weight

Tabel 2 merangkum hasil Skema 1. Pada evaluasi internal, Random Forest memiliki *accuracy* tertinggi (97,14%), sedangkan SVM memiliki *F1-macro* tertinggi (0,9438), diikuti Random Forest (0,9262) dan XGBoost (0,9252). Perbedaan

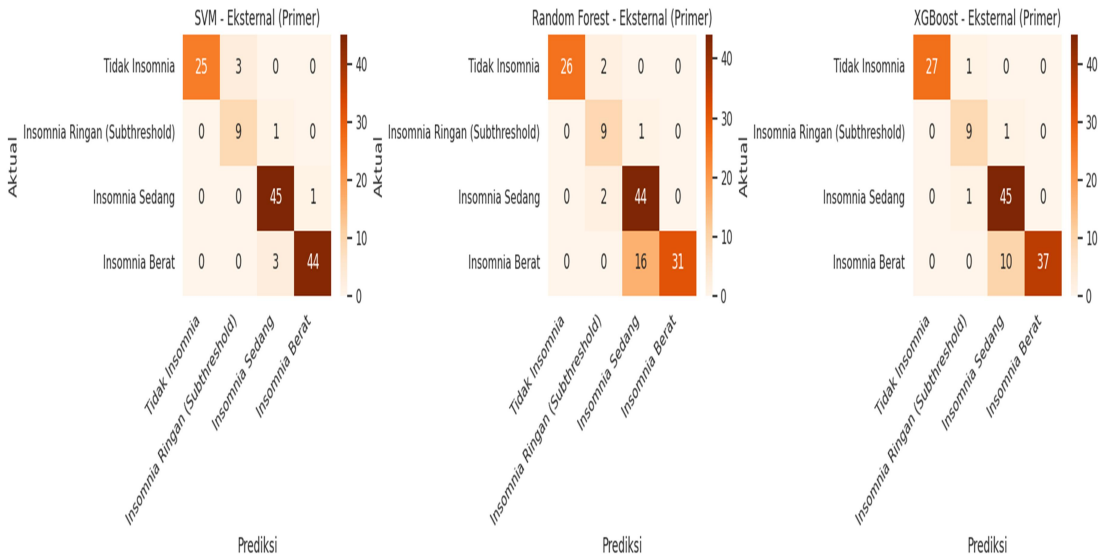
DOI : https://doi.org/10.35316/jimi.v11i2.156-164 © 2026 Jurnal Ilmiah Informatika with CC BY NC licence

ini terjadi karena Random Forest memiliki *recall*-macro paling rendah (0,8945), yaitu kurang mengenali kelas minoritas. Pada evaluasi eksternal, ketiga model menurun dengan besar yang berbeda. SVM tetap paling baik dengan *accuracy* 93,89% dan *F1-macro* 0,9164. XGBoost mencapai *F1-macro* 0,9006, sedangkan Random Forest turun paling jauh, dari *accuracy* 97,14% menjadi 83,97% (selisih 0,1317) dan *F1-macro* 0,8407. Selisih *accuracy* antara evaluasi internal dan eksternal pada SVM hanya 0,0182, dibandingkan XGBoost 0,0563.

Tabel 2. Hasil Evaluasi Internal dan Eksternal (Skema Class Weight)

Model	Evaluasi	Accuracy	Precision Macro	Recall Macro	F1-Macro
SVM	Internal (n=210)	0,9571	0,9592	0,9341	0,9438
Random Forest	Internal (n=210)	0,9714	0,9751	0,8945	0,9262
XGBoost	Internal (n=210)	0,9571	0,9315	0,9208	0,9252
SVM	Eksternal (n=131)	0,9389	0,9115	0,9268	0,9164
Random Forest	Eksternal (n=131)	0,8397	0,8534	0,8612	0,8407
XGBoost	Eksternal (n=131)	0,9008	0,9054	0,9074	0,9006

Rincian kesalahan terlihat pada *confusion matrix* evaluasi eksternal (Gambar 2). Dari 47 responden Insomnia Berat, SVM mengenali 44 (*recall* 0,9362), XGBoost 37 (0,7872), dan Random Forest hanya 31 (0,6596). Kesalahan Random Forest dan XGBoost hampir seluruhnya berupa prediksi kelas Insomnia Sedang (masing-masing 16 dan 10 responden), padahal kelas Insomnia Berat adalah kelas yang paling penting dikenali pada skrining. Pada ketiga model, *precision* kelas Insomnia Ringan juga paling rendah pada data primer, yang menunjukkan bahwa batas antara kelas Tidak Insomnia dan Insomnia Ringan relatif tipis pada data tersebut.



Gambar 2. Confusion matrix evaluasi eksternal (data primer, n = 131) untuk SVM, Random Forest, dan XGBoost

P-ISSN : 2549-7480
F. S. Juhadin dkk/ JIMI 11 (2) pp. 156-164 E-ISSN : 2549-6301

3.3 Perbandingan Class Weight dan SMOTE

Tabel 3 membandingkan *F1-macro* eksternal kedua skema. SMOTE sedikit lebih baik untuk SVM (0,9217 dibanding 0,9164) dan Random Forest (0,8465 dibanding 0,8407), tetapi selisihnya di bawah 0,01. Pada XGBoost, *class weight* justru lebih baik (0,9006 dibanding 0,8668). Karena selisihnya kecil dan tidak konsisten, kedua skema dapat dianggap setara secara praktis. Penelitian ini memilih *class weight* untuk penerapan karena tidak menambah jumlah data latih dan tidak membentuk kombinasi jawaban sintetis yang belum tentu merepresentasikan pola respons klinis yang valid pada instrumen skrining.

Tabel 3. F1-Macro Eksternal pada Class Weight dan SMOTE

Model	Class Weight	SMOTE	Lebih Unggul
SVM	0,9164	0,9217	SMOTE
Random Forest	0,8407	0,8465	SMOTE
XGBoost	0,9006	0,8668	Class Weight

3.4 Butir ISI yang Paling Berpengaruh

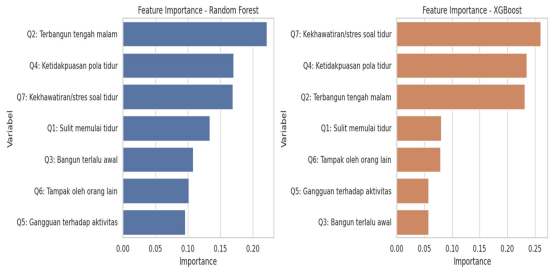
Analisis *feature importance* pada Random Forest dan XGBoost (Tabel 4, Gambar 3) menunjukkan bahwa question2 (terbangun di tengah malam), question4 (ketidakpuasan terhadap pola tidur), dan question7 (kekhawatiran atau stres tentang masalah tidur) adalah tiga butir dengan kontribusi terbesar pada kedua model, meskipun urutannya berbeda: question2 tertinggi pada Random Forest (0,2213) dan question7 tertinggi pada XGBoost (0,2599). Question5 (gangguan terhadap aktivitas) berada pada posisi terendah di kedua model, dan question3 (bangun terlalu awal) terendah pada XGBoost serta berada di peringkat kelima pada Random Forest. Hasil ini menunjukkan bahwa gangguan kontinuitas tidur, ketidakpuasan terhadap tidur, dan kekhawatiran tentang tidur paling menentukan tingkat keparahan insomnia pada data penelitian ini.

Pola ini sejalan dengan model hiperaktivasi, yaitu kewaspadaan berlebih yang dipicu kekhawatiran terhadap tidur memperburuk insomnia [15]. Ketiga butir tersebut berpotensi menjadi kandidat indikator prioritas untuk instrumen skrining yang lebih ringkas, seperti arah penyederhanaan ISI pada [7], tetapi hal ini perlu diuji pada penelitian lanjutan.

DOI : https://doi.org/10.35316/jimi.v11i2.156-164 © 2026 Jurnal Ilmiah Informatika with CC BY NC licence

Tabel 4. Feature Importance Random Forest dan XGBoost

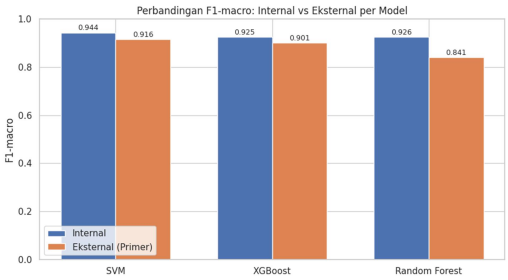
No	Random Forest	Importance	XGBoost	Importance
1	Q2 – Terbangun tengah malam	0,2213	Q7 – Kekhawatiran/stres soal tidur	0,2599
2	Q4 – Ketidakpuasan pola tidur	0,1704	Q4 – Ketidakpuasan pola tidur	0,2348
3	Q7 – Kekhawatiran/stres soal tidur	0,1692	Q2 – Terbangun tengah malam	0,2311
4	Q1 – Sulit memulai tidur	0,1335	Q1 – Sulit memulai tidur	0,0805
5	Q3 – Bangun terlalu awal	0,1083	Q6 – Tampak oleh orang lain	0,0792
6	Q6 – Tampak oleh orang lain	0,1015	Q5 – Gangguan terhadap aktivitas	0,0573
7	Q5 – Gangguan terhadap aktivitas	0,0957	Q3 – Bangun terlalu awal	0,0572



Gambar 3. Feature importance Random Forest (kiri) dan XGBoost (kanan)

3.5 Penentuan Model Terbaik

Berdasarkan *F1-macro* eksternal, SVM berada di peringkat pertama (0,9164; internal 0,9438), diikuti XGBoost (0,9006; 0,9252) dan Random Forest (0,8407; 0,9262) (Gambar 4). Selisih *F1-macro* internal–eksternal Random Forest paling besar (0,0855), sedangkan SVM (0,0274) dan XGBoost (0,0246) jauh lebih kecil dan hampir sama. Dengan demikian, keunggulan SVM terutama terletak pada skor eksternal yang tertinggi dan *recall* kelas Insomnia Berat yang tetap tinggi, bukan pada selisih F1 yang paling kecil. Karena kelas ini paling penting pada skrining, SVM dengan *class weight* ditetapkan sebagai model akhir.



Gambar 4. Perbandingan F1-macro internal dan eksternal ketiga model

Penurunan Random Forest dan XGBoost pada kelas Insomnia Berat dapat dijelaskan oleh dua faktor yang saling berkaitan. Pertama, kelas ini hanya memiliki 24 sampel dari 837 data latih, sehingga model berbasis pohon cenderung menyesuaikan diri dengan pola data latih yang didominasi tingkat keparahan ringan. Kedua, data primer memiliki distribusi kelas yang berbeda, dengan 35,88% responden berada pada kelas Insomnia Berat, sehingga terjadi pergeseran distribusi (*distribution shift*). SVM dengan kernel RBF membentuk batas keputusan berdasarkan margin maksimum antarkelas, dan skor tujuh butir ISI meningkat konsisten menurut kategori, sehingga batas antarkelas relatif jelas dan lebih stabil pada data baru.

P-ISSN : 2549-7480
F. S. Juhadin dkk/ JIMI 11 (2) pp. 156-164 E-ISSN : 2549-6301

Penjelasan ini merupakan interpretasi dari hasil, bukan hasil pengujian terpisah.

Temuan ini berbeda dari laporan Maruf dan Chowdhury yang menempatkan XGBoost sebagai model paling akurat pada prediksi kualitas tidur multifaktor [9]. Perbedaannya wajar karena data, fitur, dan skema evaluasi berbeda: penelitian ini hanya memakai tujuh butir ISI dan menguji pada data primer yang independen. Temuan ini juga mendukung penekanan pada kevalidan faktor risiko untuk populasi mahasiswa [6], serta menunjukkan bahwa *accuracy* internal yang tinggi tidak cukup untuk memilih model. Hal ini sejalan dengan peringatan bahwa *accuracy* dapat menyesatkan pada data tidak seimbang [12], [14].

3.6 Aplikasi Skrining Berbasis Streamlit

Pada aplikasi Streamlit berisi formulir tujuh butir ISI dengan pilihan jawaban 0–4, Model SVM terpilih diimplementasikan pada Streamlit. Aplikasi menampilkan kategori risiko insomnia, skor total ISI dari maksimum 28, probabilitas setiap kategori melalui *predict_proba()*, dan pernyataan bahwa hasilnya hanya skrining awal, bukan diagnosis medis. Perlu dicatat bahwa berkas model (.pkl) belum dimuat langsung; aplikasi saat ini melatih ulang SVM dari *dataset* sekunder setiap server dijalankan dan menyimpannya pada *cache* sesi. Pengujian dilakukan di Google Colab dengan akses sementara, sehingga aplikasi belum berupa layanan permanen.

4. UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada seluruh responden yang telah mengisi kuesioner serta kepada Program Studi Teknik Informatika, Fakultas Teknik, Universitas Krisnadwipayana atas dukungan selama penelitian.

5. KESIMPULAN

Penelitian ini membandingkan SVM, Random Forest, dan XGBoost untuk klasifikasi empat tingkat risiko insomnia mahasiswa berbasis tujuh butir ISI. Dengan *class weight*, SVM terbaik dengan *F1-macro* 0,9438 pada evaluasi internal dan 0,9164 pada evaluasi eksternal. Random Forest memiliki *accuracy* internal tertinggi (97,14%) tetapi turun paling jauh pada data primer (*accuracy* 83,97%, *F1-macro* 0,8407), dengan *recall* Insomnia Berat 0,6596 dibanding 0,9362 pada SVM. *Class weight* dan SMOTE memberi hasil yang hampir setara, sehingga *class weight* yang lebih sederhana dipilih. Butir question2, question4, dan question7 paling berpengaruh pada kedua model berbasis pohon. Implikasinya, evaluasi pada data independen perlu dilakukan sebelum model skrining digunakan, dan SVM dengan *class weight* layak menjadi dasar alat skrining awal insomnia mahasiswa.

Penelitian ini memiliki keterbatasan. Data primer hanya 131 responden dengan distribusi kelas yang tidak seimbang (kelas Insomnia Ringan hanya 10 responden), kelas Insomnia Berat pada data sekunder hanya 30 baris (6 pada data uji internal), parameter model belum dioptimasi, dan aplikasi belum diterapkan sebagai layanan permanen. Penelitian lanjutan disarankan menambah jumlah responden dari berbagai institusi dengan distribusi kelas yang lebih seimbang, menambahkan variabel di luar ISI seperti usia, jenis kelamin, kebiasaan merokok, dan konsumsi alkohol, melakukan optimasi *hyperparameter* (*Grid Search*, *Random Search*, atau *Bayesian Optimization*), serta men-*deploy* aplikasi pada layanan permanen dengan memperhatikan keamanan dan privasi data pengguna.

DOI : https://doi.org/10.35316/jimi.v11i2.156-164
© 2026 Jurnal Ilmiah Informatika with CC BY NC licence

REFERENSI

[1] S. Ha et al., "Predicting the risk of sleep disorders using a machine learning-based simple questionnaire: Development and validation study," *Journal of Medical Internet Research*, vol. 25, no. 1, 2023, doi: 10.2196/46520.

[2] S. Spyridonidis, D. Lad, H. Peters, J. Ellis, and L. J. Robinson, "Global prevalence of insomnia symptoms in undergraduate university students: a systematic review and meta-analysis," *SLEEP Advances*, vol. 6, no. 4, 2025, doi: 10.1093/sleepadvances/zpaf083.

[3] K. Kaewpradit, P. Ngamchaliew, and N. Buathong, "Digital screen time usage, prevalence of excessive digital screen time, and its association with mental health, sleep quality, and academic performance among Southern University students," *Frontiers in Psychiatry*, vol. 16, 2025, doi: 10.3389/fpsyt.2025.1535631.

[4] C. H. Bastien, A. Vallières, and C. M. Morin, "Validation of the Insomnia Severity Index as an outcome measure for insomnia research," *Sleep Medicine*, vol. 2, no. 4, pp. 297–307, 2001.

[5] A. A. Huang and S. Y. Huang, "Use of machine learning to identify risk factors for insomnia," *PLoS ONE*, vol. 18, no. 4, 2023, doi: 10.1371/journal.pone.0282622.

[6] A. H. Chowdhury, D. Rad, and M. S. Rahman, "Predicting anxiety, depression, and insomnia among Bangladeshi university students using tree-based machine learning models," *Health Science Reports*, vol. 7, no. 4, 2024, doi: 10.1002/hsr2.2037.

[7] W. Lee et al., "The simplification of the insomnia severity index and Epworth sleepiness scale using machine learning models," *Scientific Reports*, vol. 13, no. 1, 2023, doi: 10.1038/s41598-023-33474-8.

[8] N. Khasanah, D. Uki Eka Saputri, F. Aziz, and T. Hidayat, "Studi perbandingan algoritma Random Forest dan K-Nearest Neighbors (KNN) dalam klasifikasi gangguan tidur," *Co-Science*, vol. 5, no. 1, 2025.

[9] H. Ahmad Maruf and M. H. Chowdhury, "A multi-factor based sleep quality prediction system using machine learning," *International Journal of Education and Management Engineering*, vol. 15, no. 1, pp. 25–43, 2025, doi: 10.5815/ijeme.2025.01.03.

[10] L. Yao et al., "Novel insight into prediction model for sleep quality among college students: a LASSO-derived sleep evaluation," *Frontiers in Psychiatry*, vol. 16, 2025, doi: 10.3389/fpsyt.2025.1585732.

[11] T. Chen and C. Guestrin, "XGBoost: A scalable tree boosting system," in *Proc. ACM SIGKDD Int. Conf. Knowledge Discovery and Data Mining*, 2016, pp. 785–794, doi: 10.1145/2939672.2939785.

[12] D. Chicco and G. Jurman, "The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation," *BMC Genomics*, vol. 21, no. 1, 2020, doi: 10.1186/s12864-019-6413-7.

[13] A. Tharwat, "Classification assessment methods," *Applied Computing and Informatics*, vol. 17, no. 1, pp. 168–192, 2021, doi: 10.1016/j.aci.2018.08.003.

[14] M. Grandini, E. Bagli, and G. Visani, "Metrics for multi-class classification: An overview," 2020. [Online]. Tersedia: http://arxiv.org/abs/2008.05756

DOI : https://doi.org/10.35316/jimi.v11i2.156-164 © 2026 Jurnal Ilmiah Informatika with CC BY NC licence

P-ISSN : 2549-7480
F. S. Juhadin dkk/ JIMI 11 (2) pp. 156-164 E-ISSN : 2549-6301

[15] R. J. Dressle and D. Riemann, "Hyperarousal in insomnia disorder: Current evidence and potential mechanisms," *Journal of Sleep Research*, vol. 32, no. 6, 2023, doi: 10.1111/jsr.13928.

[16] W. Zheng et al., "Prediction models for sleep quality among college students during the COVID-19 outbreak: Cross-sectional study based on the internet new media," *Journal of Medical Internet Research*, vol. 25, 2023, doi: 10.2196/45721.

DOI : https://doi.org/10.35316/jimi.v11i2.156-164 © 2026 Jurnal Ilmiah Informatika with CC BY NC licence