

OPTIMASI LIGHTGBM BERBASIS IMBALANCED LEARNING UNTUK PREDIKSI RISIKO DEPRESI REMAJA

Sudriyanto^{1,*}, Kamil Malik², Jamal³

^{1,2}Teknik Informatika, Universitas Nurul Jadid, Indonesia

³Program Studi, Akademi Manajemen Informatika dan Komputer Taruna, Indonesia

EMAIL: (sudriyanto@unuja.ac.id , nomor1001@gmail.com , Tanpade@gmail.com)

Diterima : 10 – Mei - 2026. Disetujui : 30 – Mei - 2026. Dipublikasikan : 05 – Juni - 2026.

ABSTRACT - Class imbalance is a major challenge in teen mental-health risk prediction because the minority class is often more important than the majority class. This study optimizes LightGBM using an imbalanced-learning approach to predict teen depression risk from the public Kaggle dataset *Social Media Impact on Teen Mental Health*. The dataset contains 1,200 adolescent records with demographic, social-media, sleep, academic, physical-activity, stress, anxiety, addiction, and depression-label variables. Only 31 records or 2.58% belong to the positive depression-risk class; therefore, stratified validation, class weighting, and minority-sensitive metrics were used. Several algorithms were compared, including Logistic Regression with SMOTE, Balanced Random Forest, HistGradientBoosting, XGBoost, CatBoost, and LightGBM. LightGBM achieved the strongest average PR-AUC of 0.995 and ROC-AUC of 1.000, while HistGradientBoosting produced the highest average F1-score of 0.969. Permutation importance indicated that stress level, sleep duration, anxiety level, and daily social-media duration were influential variables. The proposed model is promising as an analytical screening prototype, but

external validation is required before clinical or educational deployment.

Keywords : *Teen Mental Health, Social Media, Depression Risk, LightGBM, Imbalanced Learning*

ABSTRAK - Ketidakseimbangan kelas merupakan tantangan utama dalam prediksi risiko kesehatan mental remaja karena kelas minoritas sering kali lebih penting dibanding kelas mayoritas. Penelitian ini mengoptimasi LightGBM menggunakan pendekatan imbalanced learning untuk memprediksi risiko depresi remaja dari dataset publik Kaggle *Social Media Impact on Teen Mental Health*. Dataset terdiri dari 1.200 data remaja dengan variabel demografi, durasi media sosial, platform, tidur, akademik, aktivitas fisik, interaksi sosial, stres, kecemasan, adiksi, dan label depresi. Hanya 31 data atau 2,58% yang termasuk kelas positif risiko depresi; karena itu digunakan validasi berstrata, pembobotan kelas, serta metrik yang sensitif terhadap kelas minoritas. Algoritma yang dibandingkan meliputi Logistic Regression dengan SMOTE, Balanced Random Forest, HistGradientBoosting, XGBoost, CatBoost, dan LightGBM. LightGBM memperoleh rata-rata PR-AUC tertinggi sebesar 0,995 dan ROC-

AUC sebesar 1,000, sedangkan HistGradientBoosting menghasilkan rata-rata F1-score tertinggi sebesar 0,969. Hasil permutation importance menunjukkan bahwa tingkat stres, durasi tidur, tingkat kecemasan, dan durasi media sosial harian menjadi variabel berpengaruh. Model berpotensi sebagai prototipe analitik skrining, tetapi memerlukan validasi eksternal sebelum diterapkan secara klinis atau pendidikan..

Kata kunci : Kesehatan Mental Remaja, Media Sosial, Risiko Depresi, LightGBM, Imbalanced Learning

I. PENDAHULUAN

Media sosial telah menjadi bagian penting dalam kehidupan remaja modern karena menyediakan ruang untuk berkomunikasi, membangun identitas diri, memperoleh informasi, serta menjalin relasi sosial secara digital. Bagi remaja, media sosial tidak hanya berfungsi sebagai sarana hiburan, tetapi juga menjadi bagian dari proses perkembangan psikososial. Namun, intensitas penggunaan yang tinggi dan pola interaksi digital yang tidak sehat dapat berhubungan dengan gangguan tidur, tekanan psikologis, kecemasan, penurunan konsentrasi, rendahnya harga diri, hingga munculnya gejala depresi. WHO Regional Office for Europe melaporkan adanya peningkatan problematic social media use pada remaja dari 7% pada tahun 2018 menjadi 11% pada tahun 2022 [1]. Sejumlah kajian juga menegaskan bahwa relasi antara media sosial dan kesehatan mental remaja perlu dipahami secara hati-hati karena bukti ilmiah menunjukkan variasi pengaruh yang dipengaruhi konteks penggunaan, usia, gender, dan karakteristik individu [3], [4].

Studi terbaru menunjukkan bahwa hubungan antara penggunaan media sosial, kesehatan mental, dan kualitas tidur tidak bersifat sederhana atau linear. Durasi penggunaan media sosial yang lebih tinggi dilaporkan berasosiasi dengan peningkatan risiko depresi pada remaja [5], sedangkan problematic social media use berkaitan dengan gejala depresi, kecemasan, dan stres [6]. Studi longitudinal juga menunjukkan bahwa pengaruh penggunaan media sosial terhadap kesehatan mental dapat dimediasi oleh faktor psikososial seperti harga diri dan

keterhubungan sosial [7]. Selain itu, representasi sampel dalam penelitian tentang depresi remaja dan media sosial masih menjadi tantangan karena banyak studi belum cukup menggambarkan keragaman populasi remaja [8]. Kajian sistematis pada sampel klinis dan komunitas memperlihatkan bahwa asosiasi penggunaan media sosial dengan gejala internalisasi tetap perlu dianalisis secara kontekstual [9], [10]. Oleh karena itu, pendekatan pembelajaran mesin pada data tabular dapat digunakan sebagai pendekatan eksploratif untuk menemukan pola risiko, bukan sebagai alat diagnosis klinis.

Permasalahan utama dalam penelitian ini adalah bagaimana membangun model prediksi risiko depresi remaja berdasarkan atribut aktivitas media sosial dan indikator perilaku pendukung pada dataset publik Kaggle Social Media Impact on Teen Mental Health [2]. Tantangan penting dalam dataset ini adalah distribusi kelas yang sangat tidak seimbang. Dari total 1.200 data, hanya terdapat 31 data positif yang merepresentasikan remaja dengan indikasi risiko depresi. Kondisi ini dapat menyebabkan model pembelajaran mesin cenderung bias terhadap kelas mayoritas, sehingga menghasilkan akurasi tinggi tetapi gagal mengenali kelas minoritas. Dalam konteks kesehatan mental, kegagalan mendeteksi kelas minoritas menjadi persoalan penting karena individu yang berada pada kelompok berisiko justru merupakan fokus utama dari sistem prediksi. Literatur imbalanced learning menekankan bahwa pemilihan strategi resampling, pembobotan kelas, model klasifikasi, dan metrik evaluasi harus disesuaikan dengan tingkat ketidakseimbangan data [14]-[18], [19].

Oleh sebab itu, penelitian ini menekankan penerapan strategi imbalanced learning untuk meningkatkan kemampuan model dalam mengenali kelas minoritas. Strategi yang digunakan meliputi validasi terstratifikasi, penerapan teknik resampling seperti SMOTE, penggunaan class weighting, serta pengaturan bobot kelas pada model berbasis gradient boosting. Evaluasi model tidak hanya didasarkan pada akurasi, tetapi juga menggunakan precision, recall, F1-score, ROC-AUC, dan PR-AUC agar performa deteksi kelas positif dapat diukur secara lebih objektif [14], [16], [20]. Kontribusi penelitian ini meliputi: penyusunan pipeline pra-pemrosesan data tabular untuk dataset kesehatan mental remaja;

penerapan strategi imbalanced learning dalam klasifikasi risiko depresi; perbandingan beberapa algoritma klasifikasi populer dan terkini; analisis variabel berpengaruh; serta rekomendasi pengembangan berbasis CatBoost, TabPFN, dan interpretabilitas SHAP. Penggunaan model tabular modern menjadi relevan karena survei terbaru menunjukkan bahwa data tabular tetap menjadi domain penting dalam pembelajaran mesin, sementara model foundation seperti TabPFN mulai menjadi tren baru untuk dataset kecil-menengah [22], [23].

II. TEORI DASAR

2.1 Media Sosial dan Kesehatan Mental Remaja

Kesehatan mental remaja merupakan isu penting karena masa remaja adalah periode perkembangan psikologis, sosial, dan biologis yang rentan. Penggunaan media sosial dapat menghadirkan manfaat berupa koneksi sosial dan dukungan emosional, tetapi juga dapat memunculkan risiko ketika penggunaan menjadi kompulsif, mengganggu tidur, atau memperkuat perbandingan sosial negatif [3], [4], [6]. Studi terbaru pada remaja menunjukkan bahwa pengalaman digital perlu dianalisis bersama faktor usia, gender, kondisi psikologis, dan konteks sosial agar interpretasi hubungan media sosial dan kesehatan mental tidak bersifat simplistik [9]-[13].

Literatur menunjukkan bahwa pengaruh media sosial tidak selalu linear. Penggunaan moderat dapat membantu koneksi sosial, sedangkan penggunaan intens, problematik, atau dilakukan menjelang waktu tidur dapat berkaitan dengan gangguan tidur, gejala internalisasi, dan depresi [5]-[7]. Studi longitudinal pada remaja awal juga menunjukkan bahwa peningkatan waktu penggunaan media sosial dapat mendahului peningkatan gejala depresi, meskipun besaran pengaruh dan mekanismenya tetap bergantung pada konteks individu [11]. Oleh karena itu, penelitian ini memosisikan model prediksi sebagai alat eksploratif untuk mengidentifikasi pola risiko awal, bukan

sebagai pengganti asesmen psikologis atau diagnosis klinis.

2.2 Imbalanced Learning pada Klasifikasi Data Tabular

Data penelitian berbentuk tabular, yaitu baris mewakili responden dan kolom mewakili fitur. Pada data tabular, pendekatan ensemble berbasis pohon dan gradient boosting masih banyak digunakan karena mampu menangani hubungan nonlinear, interaksi antarfitur, serta kombinasi variabel numerik dan kategorikal [22]. Namun, perkembangan terbaru menunjukkan bahwa model tabular modern dan foundation model seperti TabPFN mulai menjadi arah riset baru, terutama untuk dataset kecil-menengah [23].

Ketidakseimbangan kelas terjadi ketika jumlah data pada salah satu kelas jauh lebih sedikit dibanding kelas lain. Kondisi ini ditemukan pada dataset penelitian, yaitu hanya 31 data positif dari 1.200 data. Pada kondisi seperti ini, model dapat memperoleh akurasi tinggi hanya dengan memprediksi kelas mayoritas. Karena itu, penelitian imbalanced learning merekomendasikan kombinasi validasi terstratifikasi, resampling, pembobotan kelas, dan metrik yang sensitif terhadap kelas minoritas seperti recall, F1-score, ROC-AUC, dan PR-AUC [14]-[18].

2.3 Algoritma yang Digunakan

Logistic Regression digunakan sebagai baseline karena sederhana dan mudah diinterpretasikan. SMOTE dan variasi oversampling digunakan untuk menambah representasi kelas minoritas pada data latih, sementara class weighting digunakan untuk memberi penalti lebih besar terhadap kesalahan prediksi kelas positif [14], [15], [18], [21]. Strategi ini penting karena beberapa penelitian menunjukkan bahwa pemilihan teknik penanganan data tidak seimbang dapat memengaruhi stabilitas model dan performa kelas minoritas [16], [17].

Random Forest dan HistGradientBoosting digunakan sebagai model ensemble berbasis

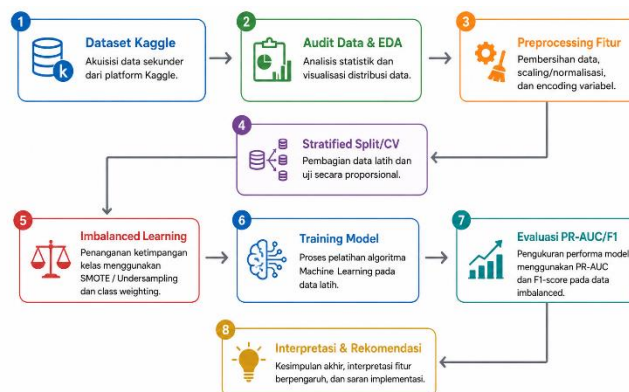
pohon. Random Forest menurunkan variansi dengan menggabungkan banyak pohon keputusan, sedangkan HistGradientBoosting menerapkan boosting secara bertahap untuk mengurangi error residual.

XGBoost dan LightGBM digunakan sebagai model gradient boosting modern yang populer untuk data tabular. Model boosting dipilih karena umumnya kuat dalam menangkap pola nonlinear dan interaksi antarvariabel. Pada penelitian ini, LightGBM dijadikan model utama karena mendukung pengaturan bobot kelas sehingga sesuai untuk skenario data tidak seimbang. Sebagai arah pengembangan terbaru, model tabular foundation seperti TabPFN dapat ditambahkan pada penelitian lanjutan karena dilaporkan kompetitif pada dataset tabular kecil-menengah [22], [23].

Sebagai rekomendasi pengembangan terbaru, penelitian lanjutan dapat membandingkan LightGBM dengan CatBoost, TabPFN, dan pendekatan pembelajaran mendalam untuk data tabular. Perbandingan tersebut perlu dilengkapi interpretabilitas model agar pola risiko yang ditemukan tidak hanya akurat secara numerik, tetapi juga dapat dijelaskan secara metodologis dan substantif [22], [23].

III. RANCANGAN SISTEM

Penelitian ini menggunakan pendekatan kuantitatif eksperimental berbasis Machine Learning (ML). Metode penelitian disusun dalam bentuk pipeline eksperimen untuk mengolah dataset tabular, menangani ketidakseimbangan kelas, melatih beberapa model klasifikasi, mengevaluasi performa model, dan menginterpretasikan variabel yang berpengaruh terhadap prediksi risiko depresi remaja. Pendekatan ini sesuai dengan karakter penelitian yang berfokus pada pembangunan model prediktif berbasis data, bukan pada pengembangan sistem informasi operasional.



Gambar 1. Alur Kerangka Penelitian

3.1 Pengumpulan Dataset

Pipeline penelitian dimulai dari akuisisi dataset publik Social Media Impact on Teen Mental Health dari Kaggle, kemudian dilanjutkan dengan audit data untuk memeriksa jumlah atribut, tipe data, nilai kosong, duplikasi, rentang nilai, serta distribusi label. Setelah karakteristik data diketahui, dataset dipisahkan menjadi fitur prediktor dan target klasifikasi. Target penelitian adalah depression_label, sedangkan fitur prediktor mencakup atribut demografis, durasi penggunaan media sosial, kualitas tidur, tingkat stres, kecemasan, harga diri, dukungan orang tua, interaksi sosial, dan indikator perilaku digital lain yang tersedia pada dataset.

Pipeline penelitian dibuat modular agar setiap tahap eksperimen dapat dikontrol dan direplikasi. Tahap pra-pemrosesan, resampling, pelatihan model, dan evaluasi ditempatkan dalam satu alur eksperimen agar risiko data leakage dapat diminimalkan. Dengan demikian, setiap teknik penanganan data tidak seimbang hanya diterapkan pada data latih, sedangkan data validasi dan data uji tetap dibiarkan mengikuti distribusi asli.

Tabel 1. Tahapan metode penelitian ML

Tahap	Proses	Keluaran
Akuisisi data	Menggunakan dataset publik Kaggle dan membaca file CSV	Dataset tabular penelitian
Audit dan eksplorasi	Memeriksa ukuran data, tipe fitur, nilai	Ringkasan karakteristik data

	kosong, duplikasi, dan distribusi label	
Pra-pemrosesan	Encoding fitur kategorikal, pemisahan fitur-target, dan penyusunan pipeline transformasi	Data siap latih
Validasi berstrata	Membagi data dengan stratified split dan stratified k-fold	Proporsi kelas tetap terjaga
Imbalanced learning	Menerapkan class weighting, SMOTE, dan pengaturan scale_pos_weight pada model boosting	Representasi kelas minoritas lebih terukur
Pelatihan model	Melatih Logistic Regression, Random Forest, HistGradientBoosting, XGBoost, dan LightGBM	Model pembandingan dan model utama
Evaluasi model	Menggunakan precision, recall, F1-score, ROC-AUC, PR-AUC, dan confusion matrix	Kinerja model pada kelas minoritas
Interpretasi	Menganalisis permutation importance dan arah hubungan fitur	Variabel berpengaruh dan rekomendasi

3.2 Desain Input, Output, dan Target Prediksi

Input sistem berupa data tabular yang berisi atribut responden dan indikator perilaku yang berkaitan dengan aktivitas media sosial serta kondisi psikologis pendukung. Setiap baris data merepresentasikan satu responden remaja, sedangkan setiap kolom merepresentasikan fitur yang digunakan untuk membangun model klasifikasi. Output sistem adalah prediksi kelas risiko depresi, yaitu kelas negatif dan kelas positif. Kelas positif menjadi fokus utama karena jumlahnya sangat kecil dibandingkan kelas negatif, tetapi memiliki nilai penting dalam konteks deteksi dini risiko kesehatan mental.

Berdasarkan hasil audit dataset, terdapat 1.200 data dengan 31 data positif dan 1.169 data negatif. Rasio kelas mayoritas terhadap kelas minoritas adalah sekitar 37,71:1. Ketimpangan ini menunjukkan bahwa model dapat memperoleh akurasi tinggi hanya dengan memprediksi sebagian besar data sebagai kelas mayoritas. Oleh karena itu, desain eksperimen

lebih menekankan kemampuan model mengenali kelas positif melalui recall, F1-score, dan PR-AUC.

3.3 Pra-pemrosesan Data dan Pencegahan Data Leakage

Pra-pemrosesan data dilakukan dengan memeriksa nilai kosong, duplikasi, konsistensi tipe data, serta rentang nilai pada fitur numerik. Fitur kategorikal seperti gender, platform_usage, dan social_interaction_level diubah menjadi representasi numerik melalui encoding agar dapat diproses oleh algoritma ML. Pada model berbasis pohon, transformasi skala tidak menjadi kebutuhan utama, sedangkan pada model linear seperti Logistic Regression, standarisasi dapat digunakan agar setiap fitur berada pada skala yang sebanding.

Pencegahan data leakage menjadi aspek penting dalam rancangan penelitian. Teknik resampling seperti SMOTE tidak diterapkan sebelum pembagian data, karena hal tersebut dapat membuat informasi dari data uji secara tidak langsung masuk ke proses pelatihan. Oleh karena itu, resampling hanya diterapkan pada data latih di dalam pipeline validasi silang. Data uji dan data validasi tetap dipertahankan pada distribusi asli agar evaluasi performa model lebih realistis.

3.4 Strategi Penanganan Data Tidak Seimbang

Strategi imbalanced learning diterapkan untuk mengurangi bias model terhadap kelas mayoritas. Penelitian ini menggunakan tiga pendekatan utama, yaitu stratified validation, class weighting, dan resampling. Stratified validation digunakan untuk menjaga proporsi kelas pada setiap fold validasi. Class weighting memberikan bobot kesalahan yang lebih besar pada kelas minoritas sehingga model tidak mengabaikan kelas positif selama pelatihan. Pada model boosting, pengaturan bobot kelas seperti scale_pos_weight digunakan berdasarkan rasio jumlah data negatif terhadap data positif.

Selain class weighting, teknik SMOTE digunakan sebagai pendekatan oversampling

untuk membentuk sampel sintetis pada kelas minoritas. Teknik ini bertujuan memperluas representasi kelas positif sehingga batas keputusan model dapat dipelajari dengan lebih baik. Namun, karena ukuran kelas positif sangat kecil, hasil resampling tetap harus dievaluasi secara hati-hati menggunakan metrik yang sensitif terhadap kelas minoritas. Oleh sebab itu, PR-AUC dipilih sebagai salah satu metrik utama karena lebih informatif dibandingkan akurasi pada kasus distribusi kelas yang sangat tidak seimbang [14]-[18].

3.5 Desain Model dan Validasi Eksperimen

Model yang digunakan terdiri atas algoritma baseline dan algoritma pembanding. Logistic Regression digunakan sebagai baseline karena sederhana dan mudah diinterpretasikan. Random Forest digunakan sebagai ensemble berbasis bagging, sedangkan HistGradientBoosting, XGBoost, dan LightGBM digunakan sebagai model boosting untuk data tabular. LightGBM dipilih sebagai model utama karena efisien, mendukung pembobotan kelas, dan umum digunakan pada permasalahan klasifikasi tabular. Sebagai arah pengembangan, penelitian juga merekomendasikan perbandingan dengan CatBoost dan TabPFN karena keduanya relevan untuk riset data tabular modern [22], [23].

Validasi eksperimen dilakukan menggunakan stratified k-fold cross-validation agar setiap fold tetap memiliki perwakilan kelas positif. Selain itu, hold-out test digunakan untuk menguji model terbaik pada data yang tidak digunakan selama pelatihan. Rancangan validasi ini bertujuan mengukur kemampuan generalisasi model, khususnya dalam mengenali kelas minoritas.

3.6 Evaluasi dan Interpretasi Model

Evaluasi model menggunakan accuracy, precision, recall, F1-score, ROC-AUC, PR-AUC, dan confusion matrix. Accuracy tetap dilaporkan sebagai informasi umum, tetapi tidak dijadikan metrik utama karena dapat menyesatkan pada dataset yang tidak seimbang. Recall digunakan untuk mengukur kemampuan

model menemukan data positif, precision digunakan untuk mengukur ketepatan prediksi positif, sedangkan F1-score digunakan sebagai keseimbangan antara precision dan recall. PR-AUC diprioritaskan karena lebih merepresentasikan performa model pada kelas minoritas.

Setelah model terbaik diperoleh, interpretasi dilakukan menggunakan permutation importance untuk mengetahui fitur yang paling memengaruhi keputusan model. Interpretasi ini penting agar hasil penelitian tidak hanya berhenti pada performa prediksi, tetapi juga memberikan pemahaman mengenai indikator perilaku dan psikologis yang berkontribusi terhadap risiko depresi remaja. Pada penelitian lanjutan, SHAP dapat digunakan untuk memberikan interpretasi lokal dan global yang lebih rinci terhadap kontribusi masing-masing fitur.

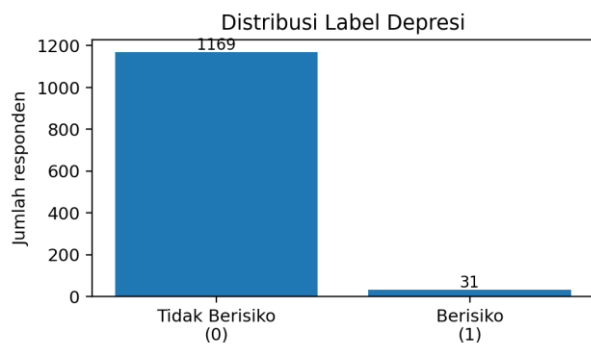
3.7 Luaran Penelitian

Luaran dari metode penelitian ini meliputi model klasifikasi terbaik, hasil perbandingan performa antaralgoritma, analisis dampak strategi imbalanced learning, confusion matrix, serta daftar fitur yang paling berpengaruh terhadap prediksi risiko depresi. Luaran tersebut diharapkan dapat mendukung kajian eksploratif mengenai kesehatan mental remaja berbasis data digital. Namun, hasil model tetap diposisikan sebagai alat analisis awal dan bukan sebagai pengganti diagnosis klinis oleh tenaga profesional.

IV. IMPLEMENTASI

4.1 Eksplorasi Data

Eksplorasi data menunjukkan rata-rata usia responden adalah 15,93 tahun. Rata-rata durasi penggunaan media sosial harian adalah 4,54 jam, rata-rata durasi tidur 6,45 jam, dan rata-rata screen time sebelum tidur 1,74 jam. Label risiko depresi sangat jarang, yaitu 31 responden dari 1.200 data.



Gambar 2. Distribusi kelas depression_label

Tabel 2. Statistik deskriptif variabel numerik

Variabel	Mean	Std	Min	Max
age	15.93	2.02	13.00	19.00
daily_social_media_hours	4.54	2.03	1.00	8.00
sleep_hours	6.45	1.44	4.00	9.00
screen_time_before_sleep	1.74	0.72	0.50	3.00
academic_performance	2.99	0.58	2.00	4.00
physical_activity	1.01	0.58	0.00	2.00
stress_level	5.45	2.90	1.00	10.00
anxiety_level	5.64	2.86	1.00	10.00
addiction_level	5.57	2.83	1.00	10.00


4.2 Hasil Perbandingan Model

Tabel 3 menyajikan hasil validasi silang. LightGBM berbasis class weighting memperoleh PR-AUC tertinggi sebesar 0,995 dan ROC-AUC sebesar 1,000. HistGradientBoosting menghasilkan F1-score tertinggi sebesar 0,969. Logistic Regression dengan SMOTE memiliki recall tinggi sebesar 0,833, tetapi precision lebih rendah, yang menunjukkan lebih banyak prediksi positif palsu dibanding model boosting. Temuan ini menunjukkan bahwa strategi imbalanced learning penting untuk mengevaluasi kelas minoritas secara lebih adil.

Tabel 3. Hasil validasi silang berstrata lima fold

Model	Accuracy	Precision	Recall	F1-score	ROC-AUC	PR-AUC
Logistic Regression + SMOTE	0.950	0.322	0.833	0.464	0.983	0.717
Random Forest Balanced	0.988	0.800	0.514	0.621	0.998	0.978
HistGradient Boosting	0.998	0.971	0.971	0.969	0.996	0.976

XGBoost	0.998	1.000	0.938	0.966	0.996	0.976
LightGBM	0.998	1.000	0.938	0.966	1.000	0.995



Gambar 3. Perbandingan F1-score dan PR-AUC antar model

4.3 Evaluasi Hold-out Model Terbaik

Pada hold-out test 20%, LightGBM menghasilkan accuracy 1.000, precision 1.000, recall 1.000, F1-score 1.000, ROC-AUC 1.000, dan PR-AUC 1.000. Confusion matrix menunjukkan 234 true negative, 0 false positive, 0 false negative, dan 6 true positive. Walaupun hasil ini sangat tinggi, jumlah kelas positif pada data uji hanya 6 dari 240 data sehingga generalisasi perlu dibuktikan dengan validasi eksternal dan pengujian pada data nyata yang lebih beragam.

Tabel 4. Confusion matrix LightGBM pada hold-out test

	Prediksi 0	Prediksi 1
Aktual 0	234	0
Aktual 1	0	6


4.4 Analisis Variabel Berpengaruh

Korelasi sederhana terhadap label menunjukkan hubungan negatif terbesar pada sleep_hours dan hubungan positif pada daily_social_media_hours, stress_level, serta anxiety_level. Analisis permutation importance pada LightGBM memperlihatkan bahwa stress_level, sleep_hours, anxiety_level, dan daily_social_media_hours menjadi variabel yang paling banyak menurunkan PR-AUC ketika nilainya diacak.

Tabel 5. Delapan fitur teratas berdasarkan permutation importance

Peringkat	Fitur	Importance Mean
1	stress_level	0.711

2	sleep_hours	0.628
3	anxiety_level	0.603
4	daily_social_media_hours	0.584
5	platform_usage	0.000
6	gender	0.000
7	age	0.000
8	screen_time_before_sleep	0.000



Gambar 4. Feature importance model LightGBM

4.5 Pembahasan

Performa tinggi model boosting mengindikasikan bahwa pola fitur dalam dataset relatif mudah dipisahkan. Hal ini dapat terjadi karena label depresi pada dataset publik kemungkinan dibentuk dari kombinasi indikator perilaku yang juga menjadi fitur prediktor. Oleh karena itu, hasil harus ditafsirkan secara hati-hati sebagai eksperimen komputasional pada dataset publik, bukan sebagai bukti klinis langsung. Kajian terbaru menegaskan bahwa hubungan antara media sosial dan kesehatan mental remaja dipengaruhi oleh mekanisme psikologis, konteks sosial, dan perbedaan individu [3], [4], [9]-[13].

Dari sisi metodologis, LightGBM layak dijadikan model utama karena menghasilkan PR-AUC tertinggi pada validasi silang dan mendukung pembobotan kelas untuk menangani distribusi target yang tidak seimbang. Literatur imbalanced learning menunjukkan bahwa penggunaan akurasi saja dapat menyesatkan ketika kelas minoritas sangat kecil, sehingga PR-AUC, recall, dan F1-score lebih sesuai digunakan sebagai dasar interpretasi performa [14]-[18].

Secara substantif, fitur penting yang muncul sesuai dengan literatur: gangguan tidur, stres, kecemasan, dan intensitas penggunaan media sosial merupakan indikator yang sering

dikaitkan dengan risiko kesehatan mental remaja [5]-[7], [11]. Namun, model tetap perlu diuji pada dataset eksternal dan data survei lokal agar generalisasi temuan dapat dinilai secara lebih kuat..

V. KESIMPULAN

Penelitian ini berhasil mengoptimasi LightGBM berbasis imbalanced learning untuk memprediksi risiko depresi remaja menggunakan dataset publik Kaggle Social Media Impact on Teen Mental Health. Dataset terdiri dari 1.200 data dengan 12 fitur prediktor dan satu label target. Kondisi kelas target sangat tidak seimbang, yaitu hanya 31 data positif atau 2,58%, sehingga evaluasi menggunakan metrik F1-score, ROC-AUC, dan PR-AUC.

Hasil validasi silang menunjukkan bahwa LightGBM dengan pembobotan kelas menjadi model terbaik berdasarkan PR-AUC sebesar 0,995 dan ROC-AUC sebesar 1,000, sedangkan HistGradientBoosting memperoleh F1-score tertinggi sebesar 0,969. Fitur paling berpengaruh adalah tingkat stres, durasi tidur, tingkat kecemasan, dan durasi penggunaan media sosial harian. Hasil ini menunjukkan bahwa pendekatan imbalanced learning dapat membantu model lebih memperhatikan kelas minoritas pada prediksi risiko depresi remaja.

Untuk pengembangan penelitian, disarankan menggunakan validasi eksternal dari dataset nyata atau survei lokal, menambahkan analisis fairness berdasarkan gender dan usia, menguji threshold tuning, serta membandingkan LightGBM dengan TabPFN, CatBoost, dan model AutoML. Model yang dihasilkan sebaiknya diposisikan sebagai alat bantu analitik awal, bukan sebagai diagnosis klinis.

REFERENSI

- [1] World Health Organization Regional Office for Europe, "Teens, screens and mental health," WHO, 2024.

- [2] M. Shahzad, "Social Media Impact on Teen Mental Health," Kaggle Dataset, n.d.
- [3] P. M. Valkenburg, A. Meier, and I. Beyens, "Social media use and its impact on adolescent mental health: An umbrella review of the evidence," *Current Opinion in Psychology*, vol. 44, pp. 58-68, 2022, doi: 10.1016/j.copsyc.2021.08.017.
- [4] A. Orben, A. K. Przybylski, S.-J. Blakemore, and R. A. Kievit, "Windows of developmental sensitivity to social media," *Nature Communications*, vol. 13, no. 1, art. 1649, 2022, doi: 10.1038/s41467-022-29296-3.
- [5] M. Liu, K. E. Kamper-DeMarco, J. Zhang, J. Xiao, D. Dong, and P. Xue, "Time spent on social media and risk of depression in adolescents: A dose-response meta-analysis," *International Journal of Environmental Research and Public Health*, vol. 19, no. 9, art. 5164, 2022, doi: 10.3390/ijerph19095164.
- [6] H. Shannon, K. Bush, P. J. Villeneuve, K. G. C. Hellems, and S. Guimond, "Problematic social media use in adolescents and young adults: Systematic review and meta-analysis," *JMIR Mental Health*, vol. 9, no. 4, e33450, 2022, doi: 10.2196/33450.
- [7] R. Plackett, J. Sheringham, and J. Dykxhoorn, "The longitudinal impact of social media use on UK adolescents' mental health: Longitudinal observational study," *Journal of Medical Internet Research*, vol. 25, e43213, 2023, doi: 10.2196/43213.
- [8] S. Ghai, L. Fassi, F. Awadh, and A. Orben, "Lack of sample diversity in research on adolescent depression and social media use: A scoping review and meta-analysis," *Clinical Psychological Science*, vol. 11, no. 5, pp. 759-772, 2023, doi: 10.1177/21677026221114859.
- [9] L. Fassi, K. Thomas, D. A. Parry, A. Leyland-Craggs, T. J. Ford, and A. Orben, "Social media use and internalizing symptoms in clinical and community adolescent samples: A systematic review and meta-analysis," *JAMA Pediatrics*, vol. 178, no. 8, pp. 814-822, 2024, doi: 10.1001/jamapediatrics.2024.2078.
- [10] L. Fassi, A. M. Ferguson, A. K. Przybylski, T. J. Ford, and A. Orben, "Social media use in adolescents with and without mental health conditions," *Nature Human Behaviour*, vol. 9, pp. 1283-1299, 2025, doi: 10.1038/s41562-025-02134-4.
- [11] J. M. Nagata, C. D. Otmar, J. Shim, P. Balasubramanian, C. M. Cheng, E. J. Li, et al., "Social media use and depressive symptoms during early adolescence," *JAMA Network Open*, vol. 8, no. 5, e2511704, 2025, doi: 10.1001/jamanetworkopen.2025.11704.
- [12] J. Chhabra, V. Pilkington, R. Benakovic, M. J. Wilson, L. La Sala, and Z. Seidler, "Social media and youth mental health: Scoping review of platform and policy recommendations," *Journal of Medical Internet Research*, vol. 27, e72061, 2025, doi: 10.2196/72061.
- [13] N. Agyapong-Opoku, F. Agyapong-Opoku, and A. J. Greenshaw, "Effects of social media use on youth and adolescent mental health: A scoping review of reviews," *Behavioral Sciences*, vol. 15, no. 5, art. 574, 2025, doi: 10.3390/bs15050574.
- [14] W. Chen, K. Yang, Z. Yu, Y. Shi, and C. L. P. Chen, "A survey on imbalanced learning: Latest research, applications and future directions," *Artificial Intelligence Review*, vol. 57, art. 137, 2024, doi: 10.1007/s10462-024-10759-6.
- [15] T. Wongvorachan, S. He, and O. Bulut, "A comparison of undersampling, oversampling, and SMOTE methods for dealing with imbalanced classification in educational data mining," *Information*, vol. 14, no. 1, art. 54, 2023, doi: 10.3390/info14010054.
- [16] P. Thölke, G. Mantilla-Ramos, A. Abdelhedi, Y. Maschke, A. Dehgan, Y. Harel, et al., "Class imbalance should not throw you off balance: Choosing the right classifiers and performance metrics for brain decoding with imbalanced data," *NeuroImage*, vol. 277, art. 120253, 2023, doi: 10.1016/j.neuroimage.2023.120253.
- [17] L. Dube and T. Verster, "Enhancing classification performance in imbalanced datasets: A comparative analysis of machine

- learning models," *Data Science in Finance and Economics*, vol. 3, no. 4, pp. 354-379, 2023, doi: 10.3934/DSFE.2023021.
- [18] Y. Li, Y. Yang, P. Song, L. Duan, and R. Ren, "An improved SMOTE algorithm for enhanced imbalanced data classification by expanding sample generation space," *Scientific Reports*, vol. 15, art. 23521, 2025, doi: 10.1038/s41598-025-09506-w.
- [19] S. N. Almuayqil, M. Humayun, N. Z. Jhanjhi, M. F. Almufareh, and D. Javed, "Framework for improved sentiment analysis via random minority oversampling for user tweet review classification," *Electronics*, vol. 11, no. 19, art. 3058, 2022, doi: 10.3390/electronics11193058.
- [20] C. Suhaeni and H.-S. Yong, "Mitigating class imbalance in sentiment analysis through GPT-3-generated synthetic sentences," *Applied Sciences*, vol. 13, no. 17, art. 9766, 2023, doi: 10.3390/app13179766.
- [21] 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, 2022, doi: 10.30812/matrik.v21i3.1726.
- [22] V. Borisov, T. Leemann, K. Seßler, J. Haug, M. Pawelczyk, and G. Kasneci, "Deep neural networks and tabular data: A survey," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 35, no. 6, pp. 7499-7519, 2024, doi: 10.1109/TNNLS.2022.3229161.
- [23] N. Hollmann, S. Müller, K. Eggensperger, F. Hutter, et al., "Accurate predictions on small data with a tabular foundation model," *Nature*, vol. 637, no. 8045, pp. 319-326, 2025, doi: 10.1038/s41586-024-08328-6.

Halaman ini sengaja dikosongkan