

Evaluasi LightGBM pada Klasifikasi Tingkat Prokrastinasi Akademik Mahasiswa Berbasis Data Psikometrik

Hapsoro Wisnu Murti¹, Faisal Muttaqin², Fetty Tri Anggraeny³

^{1,2,3}Informatika, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional Veteran Jawa Timur, Indonesia
¹22081010073@student.upnjatim.ac.id, ²faisalmuttaqin.if@upnjatim.ac.id, ³fettyanggraeny.if@upnjatim.ac.id

Abstrak

Mahasiswa tingkat akhir menghadapi tuntutan akademik yang semakin kompleks, terutama saat menyelesaikan skripsi yang membutuhkan kemandirian, pengelolaan waktu, dan keteraturan belajar. Dalam kondisi tersebut, kesulitan menjaga proses belajar dapat mendorong munculnya prokrastinasi akademik, yaitu kecenderungan menunda pekerjaan akademik dan memilih aktivitas lain yang lebih menyenangkan, sehingga berpotensi menurunkan pencapaian belajar serta meningkatkan tekanan psikologis mahasiswa. Penelitian ini bertujuan untuk mengevaluasi kinerja algoritma *Light Gradient Boosting Machine* (LightGBM) dalam klasifikasi tingkat prokrastinasi akademik mahasiswa tingkat akhir berbasis data psikometrik. *Dataset* dikumpulkan melalui kuesioner daring terhadap 394 responden mahasiswa aktif minimal semester tujuh yang sedang menyelesaikan skripsi, menggunakan instrumen *Academic Procrastination Scale-Short Form* (APS-S), *Emotion Regulation Questionnaire* (ERQ), dan *Perceived Stress Scale-10* (PSS-10). Model diuji pada dua skenario pembagian data, yaitu 70:30 dan 80:20. Tahap pra-pemrosesan meliputi pemisahan fitur dan target, normalisasi data, serta penanganan ketidakseimbangan kelas menggunakan SMOTE-NC pada data latih. Model LightGBM dioptimalkan menggunakan *GridSearchCV* dengan *F1-score macro* sebagai acuan pemilihan model terbaik. Hasil pengujian menunjukkan bahwa skenario 70:30 memperoleh performa terbaik dengan *accuracy* 0,9076, *precision macro* 0,9066, *recall macro* 0,8950, dan *F1-score macro* 0,8984. Berdasarkan *classification report* dan *confusion matrix*, model lebih baik dalam mengklasifikasikan kelas rendah dan tinggi, sedangkan kelas sedang masih menjadi kelas yang paling sulit dikenali. Hasil ini menunjukkan bahwa LightGBM dapat diandalkan sebagai pendekatan berbasis data untuk mengidentifikasi tingkat prokrastinasi akademik dari respons instrumen psikometrik, sekaligus membuka peluang pengembangan lebih lanjut pada karakteristik *dataset* dan fitur psikometrik yang lebih beragam.

Kata kunci: LightGBM, Prokrastinasi Akademik, Data Psikometrik, Klasifikasi, SMOTE-NC, Mahasiswa Akhir.

1. Pendahuluan

Keberhasilan pendidikan tidak hanya dilihat dari tersampainya materi pembelajaran, tetapi juga dari terbentuknya peserta didik yang mampu mengelola proses belajarnya secara mandiri dan berkelanjutan (Brahma & Saikia, 2023). Dalam konteks pendidikan tinggi, kemampuan tersebut menjadi semakin penting karena mahasiswa dituntut untuk menyelesaikan berbagai kewajiban akademik dengan tanggung jawab, keteraturan, dan kemandirian belajar. Namun pada praktiknya, menjaga keteraturan perilaku belajar sering kali menjadi tantangan tersendiri bagi sebagian mahasiswa ketika menghadapi beban akademik yang semakin kompleks (Yuvita et al., 2024). Kesulitan dalam menjaga keteraturan belajar dapat berpotensi mendorong kebiasaan menunda kewajiban akademik. Kebiasaan tersebut merupakan bentuk prokrastinasi akademik yaitu kecenderungan menunda pekerjaan akademik seperti penundaan memulai atau menyelesaikan tugas serta memilih kegiatan lain yang lebih menyenangkan daripada tugas yang harus diselesaikan (Astri Tarigan et al., 2024). Prokrastinasi akademik dapat berdampak pada penurunan pencapaian akademik serta meningkatnya tekanan psikologis mahasiswa (Husain et al., 2023).

Dalam konteks pendidikan tinggi di Indonesia, prokrastinasi akademik masih menjadi persoalan yang banyak ditemukan pada mahasiswa. Data penelitian menunjukkan, dari populasi 349 mahasiswa dengan sampel 100 mahasiswa, perilaku prokrastinasi akademik memperoleh persentase sebesar 80,7%, dengan indikator tertinggi pada kecenderungan memilih aktivitas lain yang lebih menyenangkan daripada mengerjakan tugas sebesar 87% (Husain et al., 2023). Pada temuan lain yang melibatkan 233 responden mahasiswa, tingkat prokrastinasi akademik pada kategori tinggi tercatat sebesar 51,07%, sedangkan kategori sangat tinggi sebesar 7,73% (Saranga et al., 2025). Data tersebut menunjukkan bahwa prokrastinasi akademik bukan hanya kebiasaan menunda yang bersifat sementara, tetapi menjadi persoalan yang cukup kuat dalam proses be-

lajar mahasiswa.

Persoalan tersebut menjadi lebih penting pada mahasiswa tingkat akhir karena penyelesaian skripsi menuntut kemandirian, pengaturan waktu, dan konsistensi belajar (Fijannati, 2024). Mahasiswa perlu mengarahkan diri, menjaga disiplin, serta menyesuaikan strategi menghadapi hambatan selama proses skripsi agar penundaan akademik tidak semakin mudah muncul (Arwina et al., 2022). Di sisi lain, tuntutan akademik yang tinggi juga dapat menimbulkan stres akademik yang mengganggu pikiran, kondisi psikologis dan perilaku mahasiswa sehingga proses pengerjaan tugas menjadi kurang terarah (Yuvita et al., 2024). Kondisi psikologis tersebut dapat dikaji melalui instrumen pengukuran yang menghasilkan data psikometrik. Data psikometrik merupakan informasi kuantitatif yang diperoleh melalui respons individu terhadap instrumen pengukuran psikologis, seperti, survei, kuesioner atau, wawancara, untuk menggambarkan atribut kognitif, emosional, dan perilaku serta merepresentasikan konstruk psikologis yang tidak dapat diamati secara langsung (Janson et al., 2025; Stefana et al., 2024).

Perkembangan pemanfaatan data dalam bidang pendidikan mendorong penggunaan *machine learning* untuk mengkaji permasalahan akademik mahasiswa secara lebih sistematis (Muhammady et al., 2024). Melalui pendekatan ini, memungkinkan data akademik dapat dianalisis untuk mengenali pola yang berkaitan dengan kondisi dan performa mahasiswa. Beberapa metode seperti *K-Nearest Neighbor* (K-NN), *Light Gradient Boosting Machine* (LightGBM), dan *Extreme Gradient Boosting* (XGBoost) telah diterapkan dalam klasifikasi performa mahasiswa dengan evaluasi menggunakan *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix* (Junita Sari & Ulfa, 2025). Berdasarkan pendekatan tersebut, LightGBM dipilih menjadi salah satu algoritma yang potensial untuk digunakan dalam penelitian ini. Algoritma ini termasuk dalam kelompok *gradient boosting* berbasis *decision tree* yang membangun model secara bertahap melalui kombinasi beberapa pohon keputusan (Khaidar, 2025). LightGBM memiliki karakteristik pelatihan yang efisien karena menggunakan pendekatan *leaf-wise tree growth*, *Gradient-based One-Side Sampling*, dan *Exclusive Feature Bundling* untuk mempercepat proses pelatihan tanpa mengabaikan kemampuan model dalam mengenali pola data (Florek & Zagdański, 2023).

Dalam penelitian terdahulu, LightGBM menunjukkan kinerja yang baik pada data akademik. Pada klasifikasi performa mahasiswa, hasil terbaik LightGBM diperoleh pada pembagian data 60:40 dengan *accuracy* 96,84%, *precision* 93,87%, *recall* 96,84%, dan *F1-score* 95,31%. Hasil tersebut menunjukkan bahwa LightGBM mampu memberikan performa klasifikasi yang konsisten pada data performa mahasiswa (Junita Sari & Ulfa, 2025). Temuan lain pada pemodelan skor akademik akhir maha-

siswa juga menunjukkan bahwa LightGBM menghasilkan performa terbaik setelah *tuning*, dengan MAE 0,223, MSE 0,145, RMSE 0,381, dan R^2 0,8442, lebih baik dibandingkan XGBoost dan CatBoost pada metrik *error* yang digunakan (Muhammady et al., 2024). Temuan tersebut menunjukkan bahwa LightGBM tetap relevan digunakan dalam pemodelan data akademik, terutama ketika proses *tuning* diterapkan untuk memperoleh konfigurasi model yang lebih optimal.


Dalam konteks prokrastinasi akademik, LightGBM telah menunjukkan potensi sebagai model untuk mengklasifikasikan risiko prokrastinasi berdasarkan variabel fungsi eksekutif, motivasi, penggunaan smartphone, dan strategi belajar. Model yang dikembangkan pada 1.248 responden remaja di Jerman memperoleh akurasi 88,7%, *F1-score macro* 0,877, dan AUC-ROC 0,931, sehingga menunjukkan bahwa LightGBM memiliki kemampuan yang baik dalam membedakan kelompok risiko prokrastinasi akademik (Nkurunziza & Becker, 2026). Sejalan dengan temuan tersebut, penelitian ini diarahkan untuk mengevaluasi LightGBM pada konteks mahasiswa tingkat akhir di Indonesia yang sedang menyelesaikan skripsi, dengan memanfaatkan data psikometrik yang mencakup prokrastinasi akademik, regulasi diri, dan stres akademik untuk klasifikasi tingkat prokrastinasi akademik (Arwina et al., 2022).

Berdasarkan uraian tersebut, penelitian ini bertujuan untuk mengevaluasi kinerja LightGBM dalam klasifikasi tingkat prokrastinasi akademik mahasiswa tingkat akhir berbasis data psikometrik. Evaluasi dilakukan menggunakan *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*. Hasil penelitian ini diharapkan dapat menunjukkan kemampuan LightGBM dalam membedakan tingkat prokrastinasi akademik mahasiswa tingkat akhir berdasarkan pola respons instrumen psikometrik yang digunakan. Penelitian ini juga diharapkan dapat memberikan gambaran mengenai efektivitas LightGBM dalam pengolahan data psikometrik serta memperluas penerapan *machine learning* pada kajian perilaku akademik, khususnya sebagai pendekatan berbasis data untuk mendukung identifikasi tingkat prokrastinasi akademik mahasiswa.

2. Metode

Penelitian ini mengevaluasi kinerja LightGBM dalam klasifikasi tingkat prokrastinasi akademik mahasiswa tingkat akhir berbasis data psikometrik. Evaluasi dilakukan pada dua skenario pembagian data, yaitu 70:30 dan 80:20, untuk melihat kinerja model pada perbedaan proporsi data latih dan data uji. Pembagian data dilakukan secara stratified agar proporsi setiap kelas tetap terjaga. Tahapan penelitian mencakup pengumpulan *dataset*, pembagian data, pra-pemrosesan, pelatihan dan *tuning* LightGBM, serta evaluasi model. Pra-pemrosesan dilakukan melalui

pemisahan fitur dan target, normalisasi data, serta penanganan ketidakseimbangan kelas pada data latih. Model hasil pelatihan selanjutnya dievaluasi menggunakan data uji. Tahapan penelitian secara keseluruhan ditampilkan pada Gambar 1.



Gambar 1. Diagram Tahapan Penelitian

Alur pada Gambar 1 menunjukkan bahwa pembagian data dilakukan sebelum tahap pra-pemrosesan agar parameter normalisasi dan penanganan ketidakseimbangan kelas hanya dibentuk dari data latih. Selanjutnya, *tuning* dilakukan pada data latih, sedangkan data uji digunakan untuk evaluasi akhir model.


2.1 Pengumpulan Dataset

Dataset penelitian diperoleh melalui penyebaran kuesioner kepada mahasiswa tingkat akhir yang sedang menyelesaikan skripsi atau tugas akhir. Pengumpulan data dilakukan secara daring melalui jejaring mahasiswa berbasis media sosial menggunakan teknik *purposive sampling* dan *convenience sampling*. Responden penelitian ditentukan berdasarkan kriteria tertentu, yaitu mahasiswa aktif program sarjana minimal semester tujuh yang sedang menyelesaikan skripsi atau tugas akhir, sehingga data yang diperoleh sesuai dengan fokus penelitian. Cakupan responden dalam penelitian ini diarahkan pada mahasiswa UPN “Veteran” Jawa Timur dan diperluas secara daring pada mahasiswa dari perguruan tinggi lain yang memenuhi kriteria penelitian.

Data yang dikumpulkan mencakup data pendukung responden dan respons instrumen psikometrik. Data pendukung responden meliputi usia, jenis kelamin, dan semester, sedangkan instrumen psikometrik terdiri dari *Academic Procrastination Scale-Short Form* (APS-S), *Emotion Regulation Questionnaire* (ERQ), dan *Perceived Stress Scale-10* (PSS-10). APS-S digunakan untuk mengukur prokrastinasi akademik melalui lima butir pernyataan (Rasyid et al., 2023). PSS-10 digunakan untuk mengukur tingkat stres yang dirasakan melalui sepuluh butir pernyataan (A. R. Hakim et al., 2024). Sedangkan ERQ digunakan untuk mengukur regulasi diri melalui sepuluh butir pernyataan (Radde et al.,

Tabel 1. Contoh Struktur *Dataset*

Usia	JK	SMT	APS_1	...	ERQ_1	...	PSS_1	...	LABEL
21	L	7	3	...	1	...	1	...	0
22	P	7	1	...	7	...	3	...	0
21	L	7	1	...	7	...	0	...	0
22	L	7	3	...	6	...	2	...	1
21	L	7	1	...	6	...	3	...	0



Gambar 2. Distribusi Label Tingkat Prokrastinasi Akademik

2021). Ketiga instrumen telah melalui pengujian validitas dan reliabilitas dalam pengukuran konstruk psikologis yang sesuai dengan penelitian ini. Contoh struktur *dataset* penelitian ditampilkan pada Tabel 1.

Dataset yang berhasil dikumpulkan dalam penelitian ini terdiri dari 394 data responden. Proses pengumpulan data hingga tahap skoring dan pembentukan label dikonsultasikan dengan akademisi di bidang psikologi untuk memastikan ketepatan pengolahan dan kualitas data. Target klasifikasi berupa tingkat prokrastinasi akademik yang dibentuk berdasarkan skor total APS-S menggunakan perhitungan norma ideal dan dikategorikan menjadi tiga kelas, yaitu rendah (0), sedang (1), dan tinggi (2). Distribusi data kelas prokrastinasi akademik pada *dataset* ditampilkan pada Gambar 2.

Berdasarkan Gambar 2, Distribusi data kelas rendah memiliki jumlah responden terbanyak, yaitu 154 responden atau 39,1% dari total data. Kelas tinggi terdiri dari 130 responden atau 33,0%, sedangkan kelas sedang memiliki jumlah paling sedikit, yaitu 110 responden atau 27,9%. Distribusi ini menunjukkan adanya ketidakseimbangan jumlah data antar kelas, sehingga penanganan ketidakseimbangan kelas dilakukan pada tahap pra-pemrosesan data (Septiana Rizky et al., 2022).

2.2 Pembagian Data

Pembagian data dilakukan untuk memisahkan *dataset* menjadi data latih dan data uji. Data latih digunakan pada proses pembelajaran model, sedangkan data uji digunakan untuk menilai kinerja model terhadap data yang tidak dilibatkan selama proses pelatihan. Tahap ini penting agar performa model dapat dinilai secara lebih objektif berdasarkan kemampuan model dalam mengklasifikasikan data baru. Dalam penelitian ini, pembagian data dilakukan menggunakan dua skenario, yaitu rasio 70:30 dan 80:20. Ske-

Tabel 2. Skenario Pembagian Data

Skenario	Data Latih	Data Uji	Total
70:30	275	119	394
80:20	315	79	394

nario 70:30 membagi data menjadi 70% data latih dan 30% data uji, sedangkan skenario 80:20 membagi data menjadi 80% data latih dan 20% data uji. Kedua skenario tersebut digunakan untuk melihat kinerja LightGBM pada perbedaan proporsi data latih dan data uji.

Pembagian data dilakukan dengan menggunakan parameter *stratify* pada label target. *Stratified split* digunakan untuk mempertahankan proporsi setiap kelas pada data latih dan data uji agar tetap merepresentasikan distribusi label pada *dataset* awal. Hal ini penting karena target klasifikasi terdiri dari tiga kelas, yaitu rendah, sedang, dan tinggi, dengan jumlah data yang tidak sepenuhnya seimbang. Rincian jumlah data pada setiap skenario pembagian data ditunjukkan pada Tabel 2.

Setelah data dibagi, tahap berikutnya adalah pra-pemrosesan data yang mencakup pemisahan fitur dan target, normalisasi data, serta penanganan ketidakseimbangan kelas. Pra-pemrosesan dilakukan setelah pembagian data agar proses normalisasi dan penanganan *class imbalance* hanya diterapkan berdasarkan data latih, sehingga kondisi asli data uji tetap dipertahankan pada tahap evaluasi model.

2.3 Pra-Pemrosesan Data

Pra-pemrosesan data dilakukan setelah proses pembagian *dataset* menjadi data latih dan data uji. Tahap ini dilakukan untuk menyesuaikan struktur data sebelum digunakan dalam proses pelatihan model LightGBM. Secara umum, pra-pemrosesan diperlukan agar data yang digunakan dalam pemodelan telah memiliki format yang sesuai dan siap diproses pada tahap analisis lanjutan. Pada penelitian ini, pra-pemrosesan mencakup pemisahan fitur dan target, normalisasi data, serta penanganan ketidakseimbangan kelas. Tahapan tersebut dijelaskan sebagai berikut.

a. Pemisahan Fitur dan Target

Tahap pertama dalam pra-pemrosesan adalah pemisahan fitur dan target. Fitur masukan terdiri dari data pendukung responden dan respons instrumen psikometrik yaitu, APS_1 sampai APS_5, ERQ_1 sampai ERQ_10 dan PSS_1 sampai PSS_10, sedangkan target klasifikasi berupa label tingkat prokrastinasi akademik. Label tersebut terdiri dari tiga kelas, yaitu rendah, sedang, dan tinggi. Pemisahan ini dilakukan agar variabel yang digunakan sebagai input model tidak tercampur dengan variabel target yang menjadi hasil klasifikasi.

b. Normalisasi Data

Setelah pemisahan data fitur dan target, tahap berikutnya adalah normalisasi data. Normalisasi dilakukan karena data psikometrik memiliki rentang skor yang berbeda sesuai dengan skala masing-masing instrumen. Proses ini menggunakan *StandardScaler* untuk menyeragamkan skala fitur numerik berdasarkan nilai rata-rata dan standar deviasi (Kumar & Bhardwaj, 2025). Dalam penelitian ini, *StandardScaler* diterapkan dengan menghitung nilai rata-rata dan standar deviasi dari data latih dan nilai tersebut selanjutnya digunakan untuk mentransformasikan data latih serta data uji. Dengan demikian, informasi dari data uji tidak digunakan dalam pembentukan parameter normalisasi. Proses standardisasi pada setiap fitur numerik dinyatakan melalui Persamaan (1) (Wongoutong, 2024).

$$z_{ij} = \frac{x_{ij} - \mu_j}{\sigma_j} \quad (1)$$

dengan x_{ij} menunjukkan nilai fitur ke- j pada data ke- i , μ_j menyatakan nilai rata-rata fitur ke- j , σ_j sebagai standar deviasi fitur ke- j , dan z_{ij} merupakan nilai hasil standardisasi. Nilai rata-rata dan standar deviasi yang dihitung dari data latih kemudian digunakan dalam untuk mentransformasikan data latih dan data uji.

Setelah normalisasi, dilakukan *label encoding* pada variabel kategorikal. Pada penelitian ini, variabel jenis kelamin diubah ke dalam bentuk numerik agar dapat diproses sebagai masukan oleh algoritma *machine learning*. Proses *encoding* dilakukan dengan menetapkan aturan konversi yaitu nilai 0 untuk laki-laki dan nilai 1 untuk perempuan (Bolikulov et al., 2024). Dengan demikian, variabel jenis kelamin memiliki representasi numerik yang konsisten pada seluruh data yang digunakan dalam pemodelan.

c. Penanganan Class Imbalance

Penanganan ketidakseimbangan kelas dilakukan karena hasil distribusi label target menunjukkan adanya ketidakseimbangan ringan (*mild imbalance*). Kondisi ini tetap perlu diperhatikan karena perbedaan jumlah data antar kelas dapat memengaruhi proses pembelajaran model, khususnya pada kelas yang memiliki jumlah data lebih sedikit. Untuk mengurangi pengaruh tersebut, penelitian ini menggunakan *Synthetic Minority Over-sampling Technique-Nominal Continuous* (SMOTE-NC) pada data latih. SMOTE-NC merupakan teknik *oversampling* yang dapat digunakan pada *dataset* dengan fitur nominal dan kontinu (Islahulhaq et al., 2021). Dalam SMOTE-NC, penentuan tetangga terdekat dilakukan dengan menyesuaikan perhitungan jarak terhadap fitur numerik dan kategorikal. Perhitungan jarak tersebut dinyatakan pada Persamaan (2).

$$d(X, Z) = \sqrt{\sum_{j=1}^q (X_j - Z_j)^2 + mM_{med}^2} \quad (2)$$

pada persamaan (2), X dan Z merupakan dua data pada kelas minoritas, q merupakan jumlah fitur numerik, M_{med} merupakan median standar deviasi fitur numerik pada kelas minoritas, dan m merupakan jumlah fitur kategorikal yang memiliki nilai berbeda antara X dan Z .

Setelah tetangga terdekat diperoleh, nilai sintetis pada fitur numerik dibentuk melalui interpolasi antara data kelas minoritas dan salah satu tetangga terdekatnya. Proses tersebut dinyatakan pada Persamaan (3).

$$X_{baru,j} = X_{i,j} + \lambda (X_{n,j} - X_{i,j}), \quad \lambda \in [0, 1] \quad (3)$$

pada persamaan (3), $X_{baru,j}$ merupakan nilai fitur numerik sintetis, $X_{i,j}$ merupakan nilai fitur dari data kelas minoritas, $X_{n,j}$ merupakan nilai fitur dari tetangga terdekat, dan λ merupakan bilangan acak pada rentang 0 sampai 1. Sementara itu, nilai pada fitur kategorikal ditentukan berdasarkan kategori yang paling banyak muncul pada tetangga terdekat (Yousefimehr et al., 2026).

Pada penelitian ini, variabel jenis kelamin yang telah melalui *label encoding* tetap ditandai sebagai fitur kategorikal saat proses SMOTE-NC dilakukan. Proses ini hanya diterapkan pada data latih, sedangkan data uji dipertahankan sesuai kondisi aslinya agar evaluasi model tidak dipengaruhi oleh data sintetis.

2.4 Pelatihan dan Tuning Model

Pelatihan model dilakukan menggunakan algoritma LightGBM pada data latih yang telah melalui tahap pra-pemrosesan. LightGBM merupakan algoritma berbasis *Gradient Boosting Decision Tree* (GBDT) yang membangun model secara bertahap melalui sejumlah pohon keputusan (Pardede et al., 2025). Model ini memiliki mekanisme pembentukan pohon secara *leaf-wise*, yaitu memperluas daun yang menghasilkan penurunan *loss* terbesar, sehingga proses pelatihan dapat berjalan lebih efisien dalam mempelajari pola data yang kompleks. Secara umum, proses optimasi pada LightGBM dilakukan dengan meminimalkan fungsi objektif yang terdiri dari fungsi *loss* dan komponen regularisasi (Khaidar, 2025). Fungsi objektif tersebut ditunjukkan pada Persamaan (4).

$$\mathcal{L}^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t) \quad (4)$$

$\mathcal{L}^{(t)}$ merupakan fungsi objektif pada iterasi ke- t , l merupakan fungsi *loss*, y_i adalah label aktual, $\hat{y}_i^{(t-1)}$ adalah hasil model pada iterasi sebelumnya, $f_t(x_i)$ adalah pohon baru yang ditambahkan pada iterasi ke- t dan $\Omega(f_t)$ digunakan sebagai komponen regularisasi.

Dalam pembentukan pohon, LightGBM menen-

Tabel 3. Ruang Hyperparameter Tuning LightGBM

Parameter	Nilai Diuji
learning_rate	0.01, 0.05, 0.1
max_depth	3, 5, 7
n_estimators	100, 200, 300
num_leaves	7, 31
subsample	0.8, 1.0

tukan percabangan berdasarkan nilai *gain*, yang digunakan untuk mengukur penurunan *loss* yang diperoleh ketika sebuah *node* dibagi menjadi cabang kiri dan kanan (Florek & Zagdański, 2023). Rumus *gain* ditunjukkan pada Persamaan (5).

$$Gain = \frac{1}{2} \left[\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right] - \gamma \quad (5)$$

Nilai *gain* dihitung dari perubahan gradien (G) dan hessian (H) setelah *node* dipecah. Regularisasi dan penalti split digunakan untuk mengontrol kompleksitas model. Semakin besar nilai *gain*, semakin baik pemecahan *node* dalam menurunkan *loss*, sehingga diprioritaskan dalam pembentukan pohon LightGBM.

Pada penelitian ini, LightGBM digunakan untuk klasifikasi multikelas dengan target berupa tingkat prokrastinasi akademik rendah, sedang, dan tinggi. Untuk memperoleh konfigurasi model yang optimal, dilakukan juga proses *tuning* hyperparameter menggunakan *GridSearchCV* (Nailendra et al., 2025). Proses *tuning* dilakukan dengan validasi silang *Stratified K-Fold Cross Validation* agar proporsi kelas pada setiap *fold* tetap terjaga selama proses validasi. *GridSearchCV* bekerja dengan menguji setiap kombinasi parameter yang telah ditentukan, kemudian memilih kombinasi dengan performa terbaik berdasarkan hasil validasi. Ruang pencarian *hyperparameter* yang digunakan dalam penelitian ini ditunjukkan pada Tabel 3.

Berdasarkan ruang pencarian parameter yang telah ditetapkan, proses *GridSearchCV* menghasilkan 108 kombinasi *hyperparameter* yang diuji pada setiap skenario pembagian data (Zou et al., 2023). Model terbaik dipilih berdasarkan *F1-score macro* agar penilaian kinerja tidak hanya berfokus pada kelas dengan jumlah data lebih besar, tetapi juga mempertimbangkan performa pada seluruh kelas target. Kombinasi *hyperparameter* terbaik kemudian digunakan untuk melatih kembali model LightGBM final menggunakan seluruh data latih pada masing-masing skenario.

2.5 Evaluasi Model

Evaluasi model dilakukan untuk mengetahui kemampuan LightGBM dalam mengklasifikasikan tingkat prokrastinasi akademik mahasiswa tingkat

akhir pada data uji. Tahap ini dilakukan setelah model memperoleh kombinasi parameter terbaik dari proses *hyperparameter tuning*, sehingga evaluasi difokuskan pada kinerja model akhir. Data uji yang digunakan merupakan data asli yang tidak melalui proses SMOTE-NC, sehingga hasil evaluasi tetap merepresentasikan kondisi data sebenarnya. Evaluasi dilakukan pada dua skenario pembagian data, yaitu 70:30 dan 80:20, dengan metrik *accuracy*, *precision*, *recall*, dan *F1-score* (A. Al Hakim et al., 2026).

Selain itu, *classification report* digunakan untuk melihat kinerja model pada masing-masing kelas, sedangkan *confusion matrix* digunakan untuk mengetahui jumlah data yang diklasifikasikan dengan benar maupun salah (Mazdadi et al., 2026). Perhatian utama diberikan pada *F1-score macro* karena metrik ini menghitung rata-rata kinerja seluruh kelas dengan bobot yang sama, sehingga sesuai untuk *dataset* dengan tiga kelas target yang distribusinya tidak sepenuhnya seimbang.


3. Hasil dan Pembahasan

Bagian ini menyajikan hasil implementasi model LightGBM dalam klasifikasi tingkat prokrastinasi akademik mahasiswa tingkat akhir berbasis data psikometrik. Pembahasan dilakukan berdasarkan dua skenario pembagian data, yaitu 70:30 dan 80:20. Hasil yang dianalisis mencakup proses *hyperparameter tuning*, kinerja model pada data uji, serta interpretasi *confusion matrix* untuk mengetahui kemampuan model dalam mengklasifikasikan kelas rendah, sedang, dan tinggi. Evaluasi dilakukan menggunakan *accuracy*, *precision*, *recall*, dan *F1-score*, dengan perhatian utama pada *F1-score macro* karena metrik tersebut menilai kinerja model secara seimbang pada setiap kelas target.

3.1 Hasil Hyperparameter Tuning

Hyperparameter tuning dilakukan untuk memperoleh konfigurasi parameter LightGBM yang menghasilkan kinerja terbaik pada proses validasi. Proses *tuning* dilakukan menggunakan *GridSearchCV* dengan ruang pencarian parameter yang telah ditentukan sebelumnya. Setiap kombinasi parameter dievaluasi menggunakan *Stratified K-Fold Cross Validation*, kemudian kombinasi terbaik dipilih berdasarkan nilai *F1-score macro*. Hasil *tuning* diamati melalui perbandingan antara *training score* dan *validation score* pada skenario pembagian data 70:30 dan 80:20. Hasil proses *tuning* pada skenario 70:30 ditampilkan pada Gambar 3.


Pada Gambar 3, Grafik menunjukkan bahwa *training score* berada pada performa tinggi sejak awal pengujian kombinasi parameter dan semakin stabil mendekati nilai 1,00. Sementara itu, *validation score* menunjukkan nilai rentang sekitar 0,80 hingga 0,93 dengan pola yang relatif stabil. Meskipun terdapat



Gambar 3. Grafik Train-Validation Skenario 70:30

Tabel 4. Kombinasi Parameter Terbaik Skenario 70:30

Parameter	Nilai Diuji
learning_rate	0.1
max_depth	5
n_estimators	200
num_leaves	7
subsample	0.8



Gambar 4. Grafik Train-Validation Skenario 80:20

selisih antara *training score* dan *validation score*, nilai validasi tetap berada pada tingkat yang baik. Hal ini menunjukkan bahwa model mampu mempelajari pola data latih dengan kuat, tetapi masih dapat mempertahankan performa pada proses validasi silang. Kombinasi parameter terbaik ditandai dengan garis putus-putus, yang dipilih oleh *GridSearchCV* berdasarkan nilai *F1-score macro* tertinggi. Kombinasi *hyperparameter* terbaik pada skenario 70:30 ditunjukkan pada Tabel 4.

Pada Tabel 4 menunjukkan bahwa pada pembagian data 70:30, *GridSearchCV* menghasilkan kombinasi parameter terbaik dengan *learning_rate* 0,1, *max_depth* 5, *n_estimators* 200, *num_leaves* 7, dan *subsample* 0,8. Kombinasi tersebut memperoleh nilai *F1-score macro* terbaik sebesar 0,9287. Hasil ini menunjukkan bahwa model LightGBM mampu menghasilkan performa validasi yang baik pada data latih dengan proporsi 70%. Nilai *learning_rate* 0,1 menunjukkan bahwa model dapat mempelajari pola data dengan laju pembelajaran yang cukup efektif, sedangkan, *num_leaves* 7 menunjukkan bahwa struktur pohon yang relatif sederhana sudah mampu memberikan hasil validasi yang baik pada skenario ini.

Setelah hasil pada skenario 70:30 diperoleh, proses *tuning* juga dilakukan pada skenario 80:20 un-

Tabel 5. Kombinasi Parameter Terbaik Skenario 80:20

Parameter	Nilai Diuji
learning_rate	0.05
max_depth	5
n_estimators	300
num_leaves	31
subsample	0.8

tuk melihat kinerja LightGBM ketika proporsi data latih diperbesar. Hasil *train-validation* pada skenario 80:20 disajikan pada Gambar 4.

Pada Gambar 4 dengan pembagian data 80:20, grafik *train-validation* menunjukkan pola performa yang lebih stabil. *Training score* tetap berada pada nilai tinggi dan mendekati 1,00 pada sebagian besar kombinasi parameter. Sementara itu, *validation score* bergerak pada rentang sekitar 0,87 hingga 0,95 dan terlihat lebih konsisten dibandingkan pembagian data 70:30. Pola tersebut menunjukkan bahwa penambahan proporsi data latih membantu model memperoleh informasi yang lebih banyak selama proses *tuning*, sehingga performa validasi dapat meningkat. Walaupun masih terdapat jarak antara *training score* dan *validation score*, nilai validasi yang tinggi menunjukkan bahwa model tetap mampu mempertahankan kinerja yang baik pada proses validasi silang. Kombinasi *hyperparameter* terbaik pada skenario 80:20 ditunjukkan pada Tabel 5.

Pada Tabel 5 menunjukkan bahwa pada pembagian data 80:20, kombinasi parameter terbaik diperoleh dengan *learning_rate* 0,05, *max_depth* 5, *n_estimators* 300, *num_leaves* 31, dan *subsample* 0,8. Kombinasi tersebut memperoleh nilai *F1-score macro* tertinggi sebesar 0,9488. Nilai ini melampaui hasil pada pembagian data 70:30, sehingga menunjukkan bahwa model memperoleh performa validasi yang lebih baik ketika jumlah data latih lebih besar. Penggunaan *learning_rate* 0,05 menunjukkan bahwa model bekerja dengan laju pembelajaran yang lebih bertahap, sedangkan *n_estimators* 300 membantu proses *boosting* dilakukan melalui jumlah iterasi yang lebih banyak.


Secara keseluruhan, proses *hyperparameter tuning* LightGBM menghasilkan performa validasi yang baik pada kedua skenario pembagian data. Skenario 80:20 memperoleh nilai *F1-score macro* validasi tertinggi sebesar 0,9488, sedangkan skenario 70:30 memperoleh nilai sebesar 0,9287. Meskipun demikian, hasil validasi belum cukup untuk menentukan model terbaik secara akhir, sehingga model LightGBM dari masing-masing skenario tetap dievaluasi menggunakan data uji asli pada tahap berikutnya.

3.2 Hasil Evaluasi Model

Setelah kombinasi parameter terbaik diperoleh dari proses *hyperparameter tuning*, model LightGBM

Classification Report:				
	precision	recall	f1-score	support
Rendah	0.90	0.98	0.94	47
Sedang	0.89	0.76	0.82	33
Tinggi	0.93	0.95	0.94	39
accuracy			0.91	119
macro avg	0.91	0.90	0.90	119
weighted avg	0.91	0.91	0.91	119

Gambar 5. Classification Report Skenario 70:30



Gambar 6. Confusion Matrix Skenario 70:30

final kemudian dievaluasi menggunakan data uji asli. Evaluasi dilakukan pada dua skenario pembagian data, yaitu 70:30 dan 80:20. Hasil evaluasi disajikan melalui *classification report* dan *confusion matrix* untuk melihat kinerja model pada kelas rendah, sedang, dan tinggi. Tahap ini digunakan untuk menilai kemampuan model terhadap data yang belum digunakan selama proses pelatihan.

Pada skenario 70:30, evaluasi dilakukan menggunakan data uji sebanyak 119 data. Dengan jumlah data uji per kelas yang menjadi dasar evaluasi terdiri dari 47 data kelas rendah, 33 data kelas sedang, dan 39 data kelas tinggi. Hasil *classification report* model LightGBM pada skenario 70:30 ditampilkan pada Gambar 5.


Berdasarkan Gambar 5, model LightGBM pada skenario 70:30 memperoleh *accuracy* sebesar 0,91. Kinerja terbaik terlihat pada kelas rendah dan tinggi dengan *F1-score* masing-masing sebesar 0,94, sedangkan kelas sedang memiliki *F1-score* paling rendah sebesar 0,82. Rincian hasil klasifikasi pada skenario 70:30 selanjutnya dianalisis melalui *confusion matrix* yang ditampilkan pada Gambar 6.

Berdasarkan Gambar 6 melalui *confusion matrix*, 46 data kelas rendah berhasil diklasifikasikan dengan benar oleh model, sedangkan 1 data kelas rendah diklasifikasikan sebagai kelas sedang. Pada kelas sedang, sebanyak 25 data berhasil diklasifikasikan dengan benar, sedangkan 5 data diklasifikasikan sebagai kelas rendah dan 3 data sebagai kelas tinggi. Pada kelas tinggi, sebanyak 37 data berhasil diklasifikasikan dengan benar, sedangkan 2 data diklasifikasikan masuk sebagai kelas sedang. Pola pada *confusion matrix* menunjukkan bahwa kesalahan klasifikasi paling banyak terjadi pada kelas sedang. Hasil

Classification Report:

	precision	recall	f1-score	support
Rendah	0.91	0.97	0.94	31
Sedang	0.89	0.73	0.80	22
Tinggi	0.89	0.96	0.93	26
accuracy			0.90	79
macro avg	0.90	0.89	0.89	79
weighted avg	0.90	0.90	0.90	79

Gambar 7. Classification Report Skenario 80:20



Gambar 8. Confusion Matrix Skenario 80:20

ini memperkuat temuan pada *classification report* yang menunjukkan bahwa model lebih baik dalam mengklasifikasikan kelas rendah dan tinggi, namun kelas sedang masih menjadi kategori yang relatif sulit dibedakan karena pola responsnya cenderung berada di antara dua kelas lainnya.

Pada skenario 80:20, evaluasi dilakukan menggunakan 79 data uji yang mencakup 31 data kelas rendah, 22 data kelas sedang, dan 26 data kelas tinggi. Hasil *classification report* model LightGBM untuk skenario 80:20 ditunjukkan pada Gambar 7.

Berdasarkan Gambar 7, model LightGBM pada skenario 80:20 memperoleh *accuracy* sebesar 0,90. Kinerja terbaik terlihat pada kelas rendah dengan *F1-score* sebesar 0,94 dan kelas tinggi sebesar 0,93, sedangkan kelas sedang memperoleh *F1-score* paling rendah sebesar 0,80. Perbedaan nilai tersebut menunjukkan bahwa kinerja model belum merata pada seluruh kelas. Pola hasil klasifikasi pada skenario 80:20 selanjutnya dapat dianalisis melalui *confusion matrix* yang ditampilkan pada Gambar 8.

Berdasarkan Gambar 8, *confusion matrix* menunjukkan bahwa model berhasil mengklasifikasikan dengan benar 30 data kelas rendah, sedangkan 1 data sebagai kelas sedang. Pada kelas tinggi sebanyak 25 data berhasil diklasifikasikan dengan benar, sedangkan 1 data sebagai kelas sedang. Sementara itu, sebanyak 16 data kelas sedang berhasil diklasifikasikan secara benar, tetapi kesalahan klasifikasi masih paling banyak ditemukan, yaitu sebagian data diklasifikasikan sebagai kelas rendah maupun tinggi. Hasil ini menunjukkan bahwa pada skenario 80:20, model mampu mengklasifikasikan kelas rendah dan tinggi dengan baik, tetapi kelas sedang tetap menjadi kategori yang paling sulit dibedakan karena pola respon-

Tabel 6. Perbandingan Hasil Evaluasi Model

Model	Skenario	Accuracy	Precision Macro	Recall Macro	F1-Score Macro
LightGBM	70:30	0.9076	0.9066	0.8950	0.8984
	80:20	0.8987	0.8969	0.8855	0.8878

snya lebih dekat dengan dua kelas lainnya.

Hasil *confusion matrix* pada skenario 80:20 memperlihatkan pola yang serupa dengan skenario 70:30, yaitu kesalahan klasifikasi paling banyak terjadi pada kelas sedang, meskipun proporsi data latih pada skenario 80:20 lebih besar. Secara umum, LightGBM menunjukkan kinerja yang baik pada kedua skenario, terutama dalam mengklasifikasikan kelas rendah dan tinggi.

3.3 Analisis Perbandingan Hasil Evaluasi Model

Analisis perbandingan hasil evaluasi dilakukan untuk melihat perbedaan kinerja LightGBM pada dua skenario pembagian data, yaitu 70:30 dan 80:20. Perbandingan ini didasarkan pada nilai *accuracy*, *precision macro*, *recall macro*, dan *F1-score macro* sebagai dasar penilaian. Rekapitulasi hasil evaluasi model LightGBM pada kedua skenario ditunjukkan pada Tabel 6.

Berdasarkan Tabel 6, skenario 70:30 memperoleh hasil evaluasi yang lebih tinggi dibandingkan skenario 80:20 pada seluruh metrik. Pada skenario 70:30, LightGBM memperoleh *accuracy* sebesar 0,9076, *precision macro* sebesar 0,9066, *recall macro* sebesar 0,8950, dan *F1-score macro* sebesar 0,8984. Sementara itu, pada skenario 80:20 diperoleh *accuracy* sebesar 0,8987, *precision macro* sebesar 0,8969, *recall macro* sebesar 0,8855, dan *F1-score macro* sebesar 0,8878. Berdasarkan nilai tersebut, skenario 70:30 menunjukkan kinerja yang lebih baik dalam mengklasifikasikan tingkat prokrastinasi akademik mahasiswa tingkat akhir.

Jika dibandingkan dengan penelitian terdahulu (Nkurunziza & Becker, 2026), yang memperoleh *accuracy* sebesar 88,7% dan *F1-score macro* sebesar 0,877 pada klasifikasi risiko prokrastinasi remaja, hasil skenario 70:30 pada penelitian ini menunjukkan nilai evaluasi yang sedikit lebih tinggi. Temuan ini menunjukkan bahwa LightGBM mampu menghasilkan kinerja yang baik dalam mengklasifikasikan tingkat prokrastinasi akademik mahasiswa tingkat akhir berdasarkan data instrumen psikometrik. Namun, hasil perbandingan tersebut perlu dipahami dengan mempertimbangkan perbedaan karakteristik responden, fitur yang digunakan, dan pembentukan kelas pada masing-masing penelitian.

Perbedaan performa tersebut menunjukkan bahwa penambahan proporsi data latih pada skenario 80:20 tidak selalu meningkatkan performa evaluasi model pada data uji. Jumlah data uji yang lebih kecil

membuat setiap kesalahan klasifikasi lebih berpengaruh terhadap nilai evaluasi, sedangkan skenario 70:30 memiliki data uji yang lebih banyak sehingga variasi data dapat terwakili dengan lebih baik. Berdasarkan *classification report*, skenario 70:30 memperoleh *accuracy* 0,91 dan *F1-score macro* 0,90, sedangkan skenario 80:20 memperoleh *accuracy* 0,90 dan *F1-score macro* 0,89. Namun, kelas sedang masih memiliki *F1-score* paling rendah, yaitu 0,82 pada skenario 70:30 dan 0,80 pada skenario 80:20, sejalan dengan *confusion matrix* yang menunjukkan bahwa kesalahan klasifikasi paling banyak terjadi pada kelas sedang.

4. Kesimpulan

Penelitian ini mengevaluasi kinerja LightGBM dalam klasifikasi tingkat prokrastinasi akademik mahasiswa tingkat akhir berbasis data psikometrik dari respons APS-S, ERQ, dan PSS-10. Model diuji pada skenario pembagian data 70:30 dan 80:20 dengan *hyperparameter tuning* menggunakan *Grid-SearchCV*, serta *F1-score macro* sebagai acuan pemilihan model terbaik. Hasil evaluasi menunjukkan bahwa LightGBM memperoleh performa terbaik pada skenario 70:30 dengan *accuracy* 0,9075, *precision macro* 0,9066, *recall macro* 0,8950, dan *F1-score macro* 0,8983. Sementara itu, skenario 80:20 memperoleh *accuracy* 0,8987 dan *F1-score macro* 0,8878.

Berdasarkan *classification report* dan *confusion matrix*, model lebih baik dalam mengklasifikasikan kelas rendah dan tinggi, sedangkan kelas sedang masih menjadi kelas yang paling sulit dikenali karena sebagian data diklasifikasi sebagai kelas lain. Temuan ini menunjukkan bahwa LightGBM dapat digunakan untuk klasifikasi tingkat prokrastinasi akademik berdasarkan pola respons instrumen psikometrik. Pengembangan penelitian selanjutnya dapat diarahkan pada pengujian model terhadap *dataset* dengan karakteristik responden yang berbeda, sehingga konsistensi kinerja LightGBM dapat diamati pada konteks yang lebih luas. Selain itu, penelitian berikutnya dapat menguji algoritma lain, terutama pendekatan klasifikasi tabular, serta menambahkan fitur psikometrik yang relevan untuk meningkatkan kemampuan model dalam membedakan kelas yang memiliki pola respons berdekatan, khususnya pada kelas sedang.

Daftar Pustaka

- Al Hakim, A., Muttaqin, F., & Maulana, H. (2026): *Klasifikasi Kendaraan Bermotor Berdasarkan Jumlah Gandar Menggunakan Adaptive Minimal Ensemble*, Jurnal Computer Science and Information Technology (CoSciTech), 7(1), 58–64. <https://doi.org/10.37859/coscitech.v7i1.11239>
- Arwina, A., Fadilah, R., & Murad, A. (2022): *Hubungan Regulasi Diri dan Stres Akademik dengan Prokrastinasi Akademik pada Mahasiswa Fakultas Psikologi Universitas Medan Area*, Journal of Education, Humaniora and Social Sciences (JEHSS), 4(4), 1981–1991. <https://doi.org/10.34007/jehss.v4i4.988>
- Astri Tarigan, B., Karuna Salim, A., Tanary, C., Ar-sandi, E., Elvinawanty, R., & Afni Safarina, N. (2024): *Prokrastinasi Akademik Ditinjau dari Self Regulated Learning dan Dukungan Sosial pada Mahasiswa*, Jurnal Penelitian Pendidikan, Psikologi dan Kesehatan (J-P3K), 5(1), 203–210. <https://doi.org/10.51849/j-p3k.v5i1.295>
- Bolikulov, F., Nasimov, R., Rashidov, A., Akhmedov, F., & Cho, Y. I. (2024): *Effective Methods of Categorical Data Encoding for Artificial Intelligence Algorithms*, Mathematics, 12(16). <https://doi.org/10.3390/math12162553>
- Brahma, B., & Saikia, P. (2023): *Influence of Self-Regulated Learning on the Academic Procrastination of College Students*, Journal of Education and Health Promotion, 12(1), 182. https://doi.org/10.4103/jehp.jehp_1106_22
- Fijannati, S. P. (2024): *Motivasi Belajar, Self Efficacy dan Prokrastinasi Akademik pada Mahasiswa Tingkat Akhir yang Sedang Mengerjakan Skripsi*, JIIP (Jurnal Ilmiah Ilmu Pendidikan), 7(4), 3918–3923. <https://doi.org/10.54371/jiip.v7i4.4271>
- Florek, P., & Zagdański, A. (2023): *Benchmarking State-of-the-Art Gradient Boosting Algorithms for Classification*, 2023 International Conference on Business Analytics for Technology and Security (ICBATS). <http://arxiv.org/abs/2305.17094>
- Hakim, A. R., Mora, L., Leometa, C. H., & Dimala, C. P. (2024): *Psychometric Properties of the Perceived Stress Scale (PSS-10) in Indonesian Version*, Jurnal Pengukuran Psikologi dan Pendidikan Indonesia, 13(2), 117–129. <https://doi.org/10.15408/jp3i.v13i2.35482>
- Husain, A. R., Wantu, T., & Pautina, M. R. (2023): *Perilaku Prokrastinasi Akademik dan Faktor Penyebabnya pada Mahasiswa*, Student Journal of Guidance and Counseling, 2(2), 145–157.
- Islahulhaq, Wibowo, W., & Ratih, I. D. (2021): *Classification of Non-Performing Financing Using Logistic Regression and Synthetic Minority Over-Sampling Technique-Nominal Continuous (SMOTE-NC)*, International Journal of Advances in Soft Computing and Its Applications, 13(3), 115–128. <https://doi.org/10.15849/ijasca.211128.09>
- Janson, K., Gottfried, K., Reis, O., Kornhuber, J., Eichler, A., Deuschle, M., Banaschewski, T., & Nees, F. (2025): *ItemComplex: A Python-Based Visualization Framework for Ex-Post Organization and Integration of Large Language-Based Datasets*, European Psychiatry, 68(1), e75. <https://doi.org/10.1192/j.eurpsy.2025.2457>
- Junita Sari, W., & Ulfa, F. (2025): *Enhancing Student*

- Performance Classification Through Dimensionality Reduction and Feature Selection in Machine Learning*, Indonesian Journal of Artificial Intelligence and Data Mining (IJAIDM), 8(3), 717–727. <https://doi.org/10.24014/ijaidm.v8i3.37783>
- Khaidar, A. (2025): *Single Tuition Fee Classification Using Light Gradient Boosting Machine with Confusion Matrix Analysis*, Journal of Artificial Intelligence and Software Engineering, 5(4), 1444–1454. <https://doi.org/10.30811/jaise.v5i4.8479>
- Kumar, M., & Bhardwaj, V. (2025): *Evaluating Label Encoding and Preprocessing Techniques for Breast Cancer Prediction Using Machine Learning Algorithms*, International Journal of Computational Intelligence Systems, 18(1). <https://doi.org/10.1007/s44196-025-00957-7>
- Mazdadi, M. I., Saragih, T. H., Budiman, I., & Anshory, M. N. (2026): *Peningkatan Akurasi Model Boosting pada Prediksi Kesehatan Tidur Menggunakan Optuna*, JIP (Jurnal Informatika Polinema), 12(2). <https://doi.org/10.33795/jip.v12i2.8878>
- Muhammady, D. N., Nugraha, H. A. E., Nastiti, V. R. S., & Aditya, C. S. K. (2024): *Students Final Academic Score Prediction Using Boosting Regression Algorithms*, Jurnal Ilmiah Teknik Elektro Komputer dan Informatika, 10(1), 154. <https://doi.org/10.26555/jiteki.v10i1.28352>
- Nailendra, S. Y., Witanti, W., & Abdillah, G. (2025): *Optimasi Prediksi Penjualan Retail Online Menggunakan LightGBM dan Hyperparameter Tuning*, Jurnal Algoritma, 22(2). <https://doi.org/10.33364/algoritma/v.22-2.2551>
- Nkurunziza, J.-P., & Becker, L. (2026): *LightGBM Classification of Academic Procrastination Risk Among Adolescents Based on Executive Function, Motivation, Smartphone Use, and Learning Strategy Variables*, Journal of Adolescent and Youth Psychological Studies, 7(6), 1–12. <https://doi.org/10.61838/kman.jayps.5445>
- Pardede, E. E., Anggraeny, F. T., & Junaidi, A. (2025): *Prophet-LightGBM Hybrid Model Implementation in Cafe Menu Sales Prediction*, Jati Emas (Jurnal Aplikasi Teknik dan Pengabdian Masyarakat), 9(4).
- Radde, H. A., Nurrahmah, N., Nurhikmah, N., & Saudi, A. N. A. (2021): *Uji Validitas Konstrak dari Emotion Regulation Questionnaire Versi Bahasa Indonesia dengan Menggunakan Confirmatory Factor Analysis*, Jurnal Psikologi Karak-
ter, 1(2), 152–160. <https://doi.org/10.56326/jpk.v1i2.1284>
- Rasyid, A. F., Putra, A., Wangsya, D., Aryanti, D., & Putri, D. (2023): *Indonesian Adaptation of Academic Procrastination-Short Form (APS-S): Validity and Reliability*, Gadjah Mada Journal of Professional Psychology (GamaJPP), 9(1), 25–34. <https://doi.org/10.22146/gamajpp.76717>
- Saranga, R., Pangemanan, D. H. C., & Tompodung, L. M. (2025): *Hubungan Prokrastinasi Akademik dengan Indeks Prestasi Kumulatif (IPK) pada Mahasiswa Angkatan 2023 Program Studi Pendidikan Dokter Fakultas Kedokteran Universitas Sam Ratulangi*, Medical Scope Journal, 8(1), 24–30. <https://doi.org/10.35790/msj.v8i1.61338>
- Septiana Rizky, P., Haiban Hirzi, R., & Hidayatur-rohman, U. (2022): *Perbandingan Metode Light-GBM dan XGBoost dalam Menangani Data dengan Kelas Tidak Seimbang*, J Statistika, 15(2), 228–236. <https://doi.org/10.36456/jstat.vol15.no2.a5548>
- Stefana, A., Damiani, S., Granziol, U., Provenzani, U., Solmi, M., Youngstrom, E. A., & Fusar-Poli, P. (2024): *Psychological, Psychiatric, and Behavioral Sciences Measurement Scales: Best Practice Guidelines for Their Development and Validation*, Frontiers in Psychology, 15. <https://doi.org/10.3389/fpsyg.2024.1494261>
- Wongoutong, C. (2024): *The Impact of Neglecting Feature Scaling in K-Means Clustering*, PLoS ONE, 19(12). <https://doi.org/10.1371/journal.pone.0310839>
- Yousefimehr, B., Ghatee, M., Fazli, J., Ghaffari, S., Rafei, Z., Seifi, M. A., Tavakoli, S., Nikahd, A., Gandomani, M. R., Orouji, A., Kashani, R. M., Heshmati, S., & Mousavi, N. S. (2026): *Data Balancing Strategies: A Systematic Survey of Resampling and Augmentation Methods*, Machine Learning and Knowledge Extraction, 7(8). <https://doi.org/10.3390/make8070211>
- Yuvita, S., Hestari, S. E., Prasetya, H. B., & Hadid, A. (2024): *Hubungan Stres Akademik dengan Prokrastinasi Mahasiswa Tingkat Akhir Psikologi UNP*, Causalita: Journal of Psychology, 2(1), 135–140. <https://doi.org/10.62260/causalita.v2i1.191>
- Zou, F., Wang, W., Cai, Q., Guo, F., & Shi, R. (2023): *Dynamic Generation Method of Highway ETC Gantry Topology Based on LightGBM*, Mathematics, 11(15). <https://doi.org/10.3390/math11153413>