

Prediksi Performa Akademik Mahasiswa Berdasarkan Kebiasaan Gaming Menggunakan CatBoost Regressor

Pradipta Aryasetya^{1*}, Iqbal Abdul Aziz², Berkah Yordan Santoso³, Achmad Ichwani⁴, Aprilisa Arum Sari⁵

¹Fakultas Ilmu Komputer
Universitas Duta Bangsa

^{1*}230103147@mhs.udb.ac.id

²Fakultas Ilmu Komputer
Universitas Duta Bangsa

²230103270@mhs.udb.ac.id

³Fakultas Ilmu Komputer
Universitas Duta Bangsa

³230103128@mhs.udb.ac.id

⁴Fakultas Ilmu Komputer
Universitas Duta Bangsa
⁴230103256@mhs.udb.ac.id

⁵Fakultas Ilmu Komputer
Universitas Duta Bangsa
⁵aprilisa_arumsari@udb.ac.id

Abstrak— Penelitian ini menyajikan pendekatan machine learning untuk memprediksi performa akademik mahasiswa berdasarkan kebiasaan bermain game dan faktor gaya hidup terkait menggunakan CatBoost Regressor. Penelitian ini menggunakan dataset Gaming vs Academic Performance yang terdiri atas 8.000 data dan 14 variabel yang merepresentasikan karakteristik mahasiswa, perilaku bermain game, kebiasaan belajar, durasi tidur, kehadiran, tingkat stres, dan nilai akademik. Dalam penelitian ini, nilai akademik digunakan sebagai variabel target, sedangkan prediktor yang dipilih meliputi jam belajar, jam bermain game, jam tidur, kehadiran, addiction score, dan tingkat stres yang telah diencode. Tahap preprocessing meliputi standardisasi nama kolom, pembatasan nilai maksimum grades menjadi 100, serta pembentukan fitur rasio belajar terhadap bermain game untuk menangkap keseimbangan antara aktivitas akademik dan gaming. Optimasi hyperparameter dilakukan menggunakan Optuna, sedangkan performa model dievaluasi menggunakan 5-fold cross-validation dengan metrik Root Mean Square Error, Mean Absolute Error, dan R^2 score. Hasil eksperimen menunjukkan bahwa model yang diusulkan mencapai rata-rata RMSE sebesar 5,5145, MAE sebesar 4,3139, dan nilai R^2 sebesar 0,9384, yang menunjukkan akurasi prediksi yang tinggi serta kemampuan penjelasan model yang kuat. Temuan ini menunjukkan bahwa variabel terkait gaming dan gaya hidup akademik memiliki kontribusi yang bermakna dalam prediksi nilai mahasiswa, serta menegaskan bahwa CatBoost Regressor efektif untuk tugas prediksi performa akademik pada konteks ini.

Kata kunci— prediksi performa akademik, CatBoost Regressor, kebiasaan gaming, nilai mahasiswa, machine learning.

Abstract— This paper presents a machine learning approach for predicting student academic performance based on gaming habits and related lifestyle factors using CatBoost Regressor. The study employed the Gaming vs Academic Performance dataset, which contains 8,000 records and 14 variables representing student characteristics, gaming behavior, study habits, sleep duration, attendance, stress level, and academic grades. In this study, grades were used as the target variable, while selected predictors included study hours, gaming hours, sleep hours, attendance, addiction score, and encoded stress level. The preprocessing stage involved standardizing column names, limiting the maximum grade value to 100, and constructing a study-to-gaming ratio feature to better capture the balance between academic and gaming activities. Hyperparameter optimization was conducted using Optuna, and model performance was evaluated through 5-fold cross-validation using Root Mean Square Error, Mean Absolute Error, and R^2 score. The experimental results demonstrate that the proposed model achieved an average RMSE of 5.5145, an MAE of 4.3139, and an R^2 score of 0.9384, indicating high predictive accuracy and strong explanatory power. These findings show that gaming-related and academic lifestyle variables contribute meaningfully to the prediction of student grades and suggest that CatBoost Regressor is an effective model for academic performance prediction in this context.

Keywords— academic performance prediction, CatBoost Regressor, gaming habits, student grades, machine learning.

I. PENDAHULUAN

Perkembangan teknologi digital telah mengubah pola aktivitas mahasiswa, salah satunya melalui meningkatnya penggunaan video game sebagai media hiburan. Kemudahan akses melalui komputer, konsol, maupun perangkat bergerak menjadikan aktivitas bermain game sebagai bagian dari kehidupan sehari-hari. Di sisi lain, performa akademik merupakan indikator

penting dalam mengevaluasi keberhasilan proses pembelajaran di perguruan tinggi. Berbagai penelitian menunjukkan bahwa aktivitas bermain game dapat memberikan dampak yang beragam terhadap pencapaian akademik mahasiswa. Bermain game secara proporsional berpotensi meningkatkan kemampuan kognitif, pemecahan masalah, dan pengambilan keputusan, sedangkan intensitas bermain yang berlebihan dapat

mengurangi waktu belajar, menurunkan kualitas tidur, meningkatkan tingkat stres, serta berdampak negatif terhadap performa akademik [9], [10], [12].

Prediksi performa akademik merupakan salah satu topik yang berkembang pesat dalam bidang Educational Data Mining (EDM) dan Learning Analytics. Tujuan utama penelitian pada bidang ini adalah mengidentifikasi mahasiswa yang berpotensi mengalami penurunan prestasi sedini mungkin sehingga institusi pendidikan dapat memberikan intervensi yang tepat. Berbagai systematic literature review menunjukkan bahwa penerapan machine learning pada prediksi performa akademik terus meningkat karena mampu memodelkan hubungan yang kompleks antar variabel dan menghasilkan akurasi yang lebih baik dibandingkan pendekatan statistik konvensional [1], [3]. Selain itu, penelitian terdahulu juga menunjukkan bahwa model prediksi berbasis machine learning dapat dimanfaatkan sebagai sistem pendukung keputusan untuk membantu institusi pendidikan dalam meningkatkan kualitas pembelajaran dan mengurangi risiko kegagalan akademik mahasiswa [4], [5].

Berbagai algoritma, seperti Decision Tree, Random Forest, Support Vector Machine, XGBoost, hingga LightGBM telah digunakan dalam prediksi performa akademik dengan tingkat akurasi yang beragam. Namun belum terdapat konsensus mengenai algoritma yang paling efektif karena performa sangat dipengaruhi karakteristik dataset [2]. Hasil tinjauan sistematis menunjukkan bahwa sebagian besar penelitian masih memanfaatkan atribut akademik konvensional sebagai variabel prediktor, seperti nilai sebelumnya, tingkat kehadiran, aktivitas pembelajaran, dan karakteristik demografis mahasiswa [1], [3], [8]. Di sisi lain, penelitian mengenai hubungan antara aktivitas bermain game dan performa akademik menunjukkan bahwa faktor seperti durasi bermain, kualitas tidur, pengelolaan waktu, tingkat stres, serta kecenderungan problematic gaming memiliki pengaruh terhadap pencapaian

akademik mahasiswa [9], [10], [12]. Meskipun CatBoost telah menunjukkan performa yang kompetitif pada prediksi performa akademik [11], sebagian besar penelitian masih memanfaatkan variabel akademik konvensional. Integrasi faktor perilaku digital seperti kebiasaan bermain game, tingkat kecanduan game, dan keseimbangan waktu belajar terhadap model prediksi berbasis CatBoost masih sangat terbatas. Kondisi tersebut menunjukkan adanya peluang untuk mengembangkan model prediksi yang tidak hanya mempertimbangkan faktor akademik, tetapi juga perilaku digital mahasiswa.

Salah satu algoritma yang menunjukkan performa tinggi pada berbagai permasalahan prediksi berbasis data tabular adalah CatBoost Regressor. CatBoost merupakan algoritma gradient boosting yang menggunakan mekanisme Ordered Boosting dan penanganan variabel kategorikal secara efisien sehingga mampu mengurangi prediction shift serta meningkatkan kemampuan generalisasi model [6]. Penelitian terbaru juga menunjukkan bahwa CatBoost memiliki performa yang kompetitif dalam prediksi performa akademik mahasiswa dibandingkan beberapa algoritma machine learning lainnya [11]. Untuk memperoleh konfigurasi model yang optimal, penelitian ini memanfaatkan Optuna sebagai metode optimasi hiperparameter karena mampu melakukan pencarian parameter secara adaptif dan lebih efisien dibandingkan metode pencarian konvensional [7].


Berdasarkan latar belakang tersebut, penelitian ini mengusulkan penerapan CatBoost Regressor untuk memprediksi performa akademik mahasiswa berdasarkan kebiasaan bermain game menggunakan Gaming vs Academic Performance Dataset yang terdiri atas 8.000 data mahasiswa. Variabel yang digunakan meliputi study hours, gaming hours, sleep hours, attendance, stress level, dan gaming addiction score, serta ditambahkan fitur study-to-gaming ratio untuk merepresentasikan keseimbangan antara aktivitas belajar dan bermain game. Kinerja model dievaluasi menggunakan 5-fold

cross-validation dengan metrik Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan koefisien determinasi (R^2). Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan model prediksi performa akademik yang lebih akurat melalui integrasi faktor perilaku gaming ke dalam model prediksi berbasis CatBoost Regressor, sekaligus memperluas pemanfaatan faktor perilaku digital dalam bidang Educational Data Mining.

II. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan machine learning untuk memprediksi performa akademik mahasiswa berdasarkan kebiasaan bermain game menggunakan algoritma CatBoost Regressor. Tahapan penelitian meliputi pengumpulan data, pra-pemrosesan, feature engineering, optimasi hiperparameter, pelatihan model, serta evaluasi performa. Seluruh proses penelitian dilakukan menggunakan bahasa pemrograman Python dengan memanfaatkan pustaka CatBoost, Scikit-learn, dan Optuna.

Gambar 1. Alur Penelitian



A. Dataset

Penelitian ini menggunakan Gaming vs Academic Performance Dataset yang diperoleh melalui platform Kaggle menggunakan pustaka KaggleHub. Dataset terdiri atas 8.000 data mahasiswa yang memuat informasi mengenai aktivitas belajar, kebiasaan bermain game, pola tidur, tingkat kehadiran, tingkat stres, gaming addiction score, dan nilai akademik. Variabel grades digunakan sebagai variabel target,

sedangkan variabel prediktor terdiri atas study hours, gaming hours, sleep hours, attendance, stress level, dan gaming addiction score. Pemilihan variabel tersebut didasarkan pada keterkaitannya dengan aktivitas akademik maupun perilaku gaming yang diduga mempengaruhi performa akademik mahasiswa.

Tabel 1. Contoh Sampel Data

study_h ours	gaming _hours	sleep_ hours	attend ance	stress_ level	addicti on_sco re	grades
8.78	7.23	6.96	91.44	0	14.69	86.46
8.72	0.07	7.63	63.63	1	2.47	98.23
9.56	1.73	4.40	83.26	2	4.73	90.56
1.68	6.62	7.83	75.04	0	14.54	32.67
5.83	5.36	5.55	65.57	0	12.48	58.71
6.84	7.16	8.03	68.11	0	18.75	57.52
7.40	0.46	6.55	91.25	1	1.74	94.00
6.79	4.78	5.37	66.46	1	11.75	62.11
7.93	4.55	8.76	72.50	1	11.04	80.94
4.24	0.29	7.83	71.39	1	4.72	82.35

B. Pra-pemrosesan dan Feature Engineering

Tahap pra-pemrosesan dilakukan untuk memastikan kualitas data sebelum digunakan pada proses pelatihan model. Seluruh nama kolom terlebih dahulu distandarkan ke dalam format huruf kecil untuk menjaga konsistensi penamaan atribut. Selanjutnya, nilai pada variabel target grades dibatasi hingga maksimum 100 agar sesuai dengan rentang penilaian akademik. Variabel kategorikal stress level kemudian ditransformasikan ke dalam bentuk numerik menggunakan teknik ordinal encoding dengan urutan Low, Medium, dan High sehingga dapat diproses oleh algoritma regresi.

Selain proses pra-pemrosesan, penelitian ini juga menerapkan feature engineering dengan membangun variabel baru berupa study-to-gaming ratio, yaitu perbandingan antara jumlah

jam belajar dengan jumlah jam bermain game. Fitur ini dirancang untuk merepresentasikan keseimbangan antara aktivitas akademik dan aktivitas bermain game sebagai salah satu faktor yang diduga mempengaruhi pencapaian akademik mahasiswa. Perhitungan fitur tersebut dinyatakan pada Persamaan (1).

$$\text{StudyToGamingRatio} = \frac{\text{StudyHours}}{\text{GamingHours} + 0.1} \quad (1)$$

Penambahan konstanta sebesar 0,1 pada penyebut bertujuan untuk menghindari pembagian dengan nol ketika mahasiswa tidak memiliki waktu bermain game.

C. Pengembangan Model CatBoost Regressor

Model prediksi dikembangkan menggunakan algoritma CatBoost Regressor. CatBoost merupakan algoritma *gradient boosting* yang membangun model secara bertahap dengan menggabungkan beberapa pohon keputusan lemah menjadi model prediktif yang lebih kuat. Algoritma ini dipilih karena memiliki kemampuan yang baik dalam memodelkan hubungan nonlinier pada data tabular dan mampu menghasilkan performa prediksi yang stabil pada berbagai jenis variabel. Dalam penelitian ini, variabel *grades* digunakan sebagai target prediksi, sedangkan variabel *study hours*, *gaming hours*, *sleep hours*, *attendance*, *stress level*, *gaming addiction score*, dan *study-to-gaming ratio* digunakan sebagai variabel masukan. Model dilatih untuk mempelajari pola hubungan antara kebiasaan belajar, kebiasaan bermain game, kondisi gaya hidup, dan nilai akademik mahasiswa. Pendekatan regresi digunakan karena hasil prediksi yang diinginkan berupa nilai numerik, bukan kategori kelas.

D. Optimasi Hiperparameter

Optimasi hiperparameter dilakukan menggunakan Optuna untuk memperoleh konfigurasi model yang memberikan performa terbaik. Optuna digunakan karena mampu melakukan pencarian parameter secara adaptif berdasarkan hasil percobaan sebelumnya, sehingga proses optimasi dapat dilakukan lebih efisien dibandingkan pencarian manual. Fungsi

objektif dalam proses optimasi adalah minimisasi nilai *Root Mean Square Error* (RMSE), karena RMSE mampu memberikan penalti lebih besar terhadap kesalahan prediksi yang tinggi. Proses optimasi dilakukan sebanyak 20 *trial*. Hiperparameter yang dioptimasi meliputi *learning rate*, *depth*, dan *L2 leaf regularization*. Parameter *learning rate* mengatur besar pembaruan model pada setiap iterasi, *depth* menentukan kedalaman pohon keputusan, sedangkan *L2 leaf regularization* digunakan untuk mengurangi risiko *overfitting*. Parameter lain ditetapkan secara tetap, yaitu jumlah iterasi sebanyak 150, fungsi kerugian RMSE, dan *random seed* sebesar 42 agar hasil eksperimen lebih konsisten.

E. Evaluasi Model

Evaluasi model dilakukan menggunakan metode *5-fold cross-validation*. Pada metode ini, dataset dibagi menjadi lima bagian dengan ukuran yang relatif seimbang. Pada setiap iterasi, empat bagian digunakan sebagai data latih dan satu bagian digunakan sebagai data uji. Proses tersebut dilakukan secara bergantian hingga seluruh bagian data pernah digunakan sebagai data uji. Penggunaan *cross-validation* bertujuan untuk memperoleh estimasi performa yang lebih stabil dan mengurangi ketergantungan hasil terhadap satu pembagian data tertentu. Kinerja model dievaluasi menggunakan tiga metrik, yaitu *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan koefisien determinasi (R^2). RMSE digunakan untuk mengukur besar kesalahan prediksi dengan penalti lebih besar pada kesalahan yang tinggi. MAE digunakan untuk mengukur rata-rata selisih absolut antara nilai aktual dan nilai prediksi. Sementara itu, R^2 digunakan untuk mengukur kemampuan model dalam menjelaskan variasi nilai akademik mahasiswa berdasarkan variabel prediktor yang digunakan.

Perhitungan RMSE ditunjukkan pada Persamaan (2).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

(2)
Perhitungan MAE ditunjukkan pada Persamaan (3).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

Perhitungan R^2 ditunjukkan pada Persamaan (4).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

Pada persamaan tersebut, y_i merupakan nilai aktual, $\hat{y}$ merupakan nilai prediksi, $\bar{y}$ merupakan rata-rata nilai aktual, dan n merupakan jumlah data. Sebelum proses evaluasi dilakukan, nilai prediksi yang berada di luar rentang penilaian akademik dibatasi pada rentang 0 – 100 agar sesuai dengan karakteristik variabel target.

III. HASIL DAN PEMBAHASAN

Model CatBoost Regressor dikembangkan untuk memprediksi performa akademik mahasiswa berdasarkan kebiasaan bermain game menggunakan Gaming vs Academic Performance Dataset. Sebelum pelatihan model dilakukan, diterapkan feature engineering dengan membentuk variabel study-to-gaming ratio untuk merepresentasikan keseimbangan antara waktu belajar dan waktu bermain game. Model kemudian dioptimalkan menggunakan Optuna dan dievaluasi melalui 5-fold cross-validation. Hasil pengujian menunjukkan bahwa model memperoleh nilai RMSE sebesar 5,5145, MAE sebesar 4,3139, dan R^2 sebesar 0,9384. Nilai RMSE dan MAE yang rendah serta R^2 yang tinggi menunjukkan bahwa CatBoost Regressor mampu memprediksi nilai akademik dengan baik. Hasil ini sejalan dengan penelitian [11] yang menunjukkan bahwa CatBoost memiliki performa yang kompetitif pada prediksi performa akademik, serta mendukung temuan [1] dan [3] mengenai efektivitas algoritma gradient boosting dalam bidang *Educational Data Mining*.


Tabel 2. Hasil Evaluasi Model CatBoost Regressor

Metrik Evaluasi	Nilai Rata-rata
-----------------	-----------------

RMSE	5,5145
MAE	4,3139
R^2	0,9384


Gambar 2 menunjukkan hubungan antara nilai aktual dan hasil prediksi model. Sebagian besar titik berada di sekitar garis diagonal yang merepresentasikan kondisi prediksi ideal, sehingga menunjukkan bahwa hasil prediksi memiliki kedekatan yang baik dengan nilai aktual. Sebaran titik yang relatif rapat di sekitar garis tersebut mengindikasikan bahwa model mampu mempelajari hubungan antara variabel prediktor dan performa akademik secara konsisten.

Gambar 2. Scatter Plot Aktual vs Prediksi




Untuk mengevaluasi kesalahan prediksi, dilakukan analisis residual sebagaimana ditunjukkan pada Gambar 3. Residual tersebar secara acak di sekitar garis nol tanpa membentuk pola tertentu. Hal ini menunjukkan bahwa model tidak mengalami bias sistematis dan mampu menangkap hubungan pada data dengan baik. Selain itu, penyempitan sebaran residual pada nilai prediksi yang mendekati 100 terjadi karena rentang nilai akademik dibatasi pada skala 0–100, sehingga ruang kesalahan prediksi menjadi lebih kecil.

Gambar 3. Residual Plot Catboost Regressor



Analisis feature importance pada Gambar 4 menunjukkan bahwa *study-to-gaming ratio* merupakan variabel yang paling berpengaruh, diikuti oleh *study hours*, *sleep hours*, dan *gaming hours*. Hasil ini menunjukkan bahwa keseimbangan antara waktu belajar dan waktu bermain game lebih berpengaruh terhadap performa akademik dibandingkan durasi bermain game saja. Temuan tersebut mendukung penelitian [9] yang menyatakan bahwa aktivitas bermain game tidak selalu berdampak negatif apabila dilakukan secara proporsional.

Gambar 4. Feature Importance CatBoost Regressor



Di sisi lain, variabel gaming addiction score, stress level, dan attendance memiliki kontribusi yang relatif lebih kecil terhadap model. Hal ini menunjukkan bahwa pada dataset yang digunakan, keseimbangan aktivitas belajar dan bermain game lebih mampu menjelaskan variasi performa akademik dibandingkan indikator kecanduan bermain game. Hasil tersebut juga sejalan dengan tinjauan sistematis [12] yang

menyatakan bahwa dampak gaming terhadap prestasi akademik lebih dipengaruhi oleh pola penggunaan daripada intensitas bermain semata.

Secara keseluruhan, hasil penelitian menunjukkan bahwa CatBoost Regressor mampu menghasilkan model prediksi yang baik untuk memprediksi performa akademik mahasiswa. Selain itu, penerapan feature engineering melalui variabel *study-to-gaming ratio* memberikan kontribusi penting dalam meningkatkan kemampuan prediksi model. Temuan ini menunjukkan bahwa keseimbangan antara aktivitas belajar dan bermain game merupakan faktor yang lebih berpengaruh dibandingkan hanya mengukur durasi bermain game, sehingga dapat menjadi pertimbangan dalam pengembangan model prediksi performa akademik pada penelitian selanjutnya.

IV. KESIMPULAN

Penelitian ini berhasil menerapkan CatBoost Regressor untuk memprediksi performa akademik mahasiswa berdasarkan kebiasaan bermain game dan faktor gaya hidup terkait. Dengan menggunakan dataset *Gaming vs Academic Performance* yang terdiri atas 8.000 data mahasiswa, model dibangun melalui tahapan pra-pemrosesan data, transformasi variabel kategorikal, pembentukan fitur *study-to-gaming ratio*, optimasi hiperparameter menggunakan Optuna, serta evaluasi menggunakan *5-fold cross-validation*. Hasil eksperimen menunjukkan bahwa model mencapai rata-rata RMSE sebesar 5,5145, MAE sebesar 4,3139, dan R^2 sebesar 0,9384. Nilai tersebut menunjukkan bahwa CatBoost Regressor mampu menghasilkan prediksi nilai akademik dengan tingkat kesalahan yang rendah dan kemampuan penjelasan yang tinggi. Hasil penelitian ini menunjukkan bahwa kombinasi variabel akademik, kebiasaan gaming, dan faktor gaya hidup dapat digunakan sebagai prediktor yang relevan dalam memodelkan performa akademik mahasiswa. Penambahan fitur *study-to-gaming ratio* juga memberikan representasi yang lebih baik mengenai keseimbangan antara aktivitas belajar dan

bermain game. Dengan demikian, tujuan penelitian untuk memprediksi performa akademik mahasiswa berdasarkan kebiasaan gaming menggunakan CatBoost Regressor telah tercapai. Ke depan, penelitian ini dapat dikembangkan dengan melakukan perbandingan terhadap algoritma lain, memperluas sumber data, serta menerapkan metode interpretabilitas model agar hasil prediksi lebih mudah dipahami dan dimanfaatkan oleh institusi pendidikan.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada seluruh pihak yang telah memberikan dukungan dalam penyusunan penelitian ini. Ucapan terima kasih juga disampaikan kepada penyedia dataset *Gaming vs Academic Performance* yang telah menyediakan data sehingga dapat digunakan dalam proses eksperimen dan evaluasi model. Selain itu, penulis berterima kasih kepada pihak akademik yang telah memberikan arahan, masukan, dan dukungan selama proses penyusunan artikel ini.

REFERENSI

- [1] Alalawi, K., Athauda, R., & Chiong, R. (2023). Contextualizing the current state of research on the use of machine learning for student
- [2] performance prediction: A systematic literature review. *Engineering Reports*, 5(12), e12699.
- [3] Alsariera, Y. A., Baashar, Y., Alkawsi, G., Mustafa, A., Alkahtani, A. A., & Ali, N. A. (2022). Assessment and evaluation of different machine learning algorithms for predicting student performance. *Computational intelligence and neuroscience*, 2022(1), 4151487.
- [4] Roslan, M. B., & Chen, C. (2022). Educational data mining for student performance prediction: A systematic literature review (2015-2021). *International Journal of Emerging Technologies in Learning (iJET)*, 17(5), 147-179.
- [5] Tjandra, E., Kusumawardani, S. S., & Ferdiana, R. (2022, April). Student performance prediction in higher education: A comprehensive review. In *AIP conference proceedings* (Vol. 2470, No. 1, p. 050005). AIP Publishing LLC.
- [6] Romero, C., & Ventura, S. (2020). Educational data mining and learning analytics: An updated survey. *Wiley interdisciplinary reviews: Data mining and knowledge discovery*, 10(3), e1355.
- [7] Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A. V., & Gulin, A. (2018). CatBoost: unbiased boosting with categorical features. *Advances in neural information processing systems*, 31.
- [8] Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019, July). Optuna: A next-generation hyperparameter optimization framework. In *Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining* (pp. 2623-2631).
- [9] Chaka, C. (2021). Educational data mining, student academic performance prediction, prediction methods, algorithms and tools: An overview of reviews.
- [10] Halbrook, Y. J., O'Donnell, A. T., & Msetfi, R. M. (2019). When and how video games can be good: A review of the positive effects of video games on well-being. *Perspectives on Psychological Science*, 14(6), 1096-1104.
- [11] Burgess, S. R., Stermer, S. P., & Burgess, M. C. (2012). Video game playing and academic performance in college students. *College Student Journal*, 46(2), 376-388.
- [12] Fan, Z., Gou, J., & Weng, S. (2025). Complementary CatBoost based on residual error for student performance prediction. *Pattern Recognition*, 161, 111265.
- [13] Alzahrani, A. K. D., & Griffiths, M. D. (2025). Problematic gaming and students' academic performance: A systematic review. *International Journal of Mental Health and Addiction*, 23(5), 4062-4095