



Pola Perilaku Pemain Roblox: Pemodelan Klasifikasi Berbasis Naïve Bayes

Risqi Nur Avianti*, Cucut Hariz Pratomo

Fakultas Sains dan Teknologi, Universitas Muhammadiyah Karanganyar, Karanganyar, Indonesia

Email: ^{1,*}risqinraa@gmail.com, ²chpratomo@umuka.ac.id

Email Penulis Korespondensi: risqinraa@gmail.com

Abstrak—Perkembangan teknologi digital telah mendorong pertumbuhan game online sebagai media hiburan, interaksi sosial, dan pengembangan kreativitas. Salah satu platform yang berkembang pesat adalah Roblox, yang memungkinkan pengguna bermain, berinteraksi, serta menciptakan konten digital. Keberagaman aktivitas tersebut menyebabkan karakteristik perilaku pemain menjadi semakin kompleks sehingga sulit diidentifikasi secara manual. Oleh karena itu, diperlukan pendekatan berbasis machine learning untuk mengklasifikasikan perilaku pemain secara lebih objektif dan sistematis. Penelitian ini bertujuan mengklasifikasikan perilaku pemain Roblox ke dalam empat kategori, yaitu pemain aktif, kasual, sosial, dan kreatif menggunakan algoritma Naïve Bayes. Algoritma ini dipilih karena memiliki proses komputasi yang sederhana, efisien, serta sesuai untuk data kuesioner yang telah ditransformasikan ke dalam bentuk numerik. Sebanyak 523 respons berhasil dikumpulkan, kemudian setelah proses seleksi dan preprocessing diperoleh 520 data yang digunakan sebagai dataset penelitian. Data diproses melalui tahap data cleaning, encoding, penanganan missing value, serta pembagian dataset menggunakan rasio 80% data latih dan 20% data uji. Hasil penelitian menunjukkan bahwa model menghasilkan akurasi sebesar 62,5%, dengan nilai precision 63%, recall 62%, dan F1-score 62%. Meskipun nilai akurasi yang diperoleh belum tinggi, hasil tersebut menunjukkan bahwa algoritma Naïve Bayes mampu digunakan sebagai baseline dalam klasifikasi perilaku pemain berbasis data kuesioner yang memiliki karakteristik subjektif dan kompleks. Temuan penelitian ini memberikan kontribusi berupa penyediaan model dasar (baseline) klasifikasi perilaku pemain Roblox berbasis data kuesioner serta informasi mengenai karakteristik pemain yang dapat menjadi referensi bagi pengembang dalam memahami perilaku pengguna sebagai dasar pengembangan fitur yang lebih adaptif dan sesuai dengan kebutuhan pemain.

Kata Kunci: Klasifikasi Perilaku; Data Mining; Machine Learning; Naïve Bayes; Roblox

Abstract—The development of digital technology has driven the growth of online gaming as a medium for entertainment, social interaction, and creativity development. One platform that has grown rapidly is Roblox, which allows users to play, interact, and create digital content. This diversity of activities causes player behavior characteristics to become increasingly complex, making them difficult to identify manually. Therefore, a machine learning-based approach is needed to classify player behavior more objectively and systematically. This study aims to classify Roblox player behavior into four categories, namely active, casual, social, and creative players, using the Naïve Bayes algorithm. This algorithm was chosen because it has a simple and efficient computational process and is suitable for questionnaire data that has been transformed into numerical form. A total of 523 responses were successfully collected, and after the selection and preprocessing stages, 520 data points were obtained to be used as the research dataset. The data were processed through data cleaning, encoding, missing value handling, and dataset splitting using an 80% training data and 20% test data. The results showed that the model achieved an accuracy of 62.5%. Evaluation using precision, recall, and F1-score metrics revealed that the results showed that the model produced an accuracy of 62.5%, with a precision value of 63%, recall of 62%, and F1-score of 62%. Although the accuracy obtained is not yet high, these results indicate that the Naïve Bayes algorithm can be used as a baseline in classifying player behavior based on questionnaire data that has subjective and complex characteristics. This study contributes by providing a baseline classification model for Roblox player behavior based on questionnaire data, along with insights into player characteristics that can serve as a reference for developers in understanding user behavior, thereby supporting the development of more adaptive features that better align with players' needs.

Keywords: Behavior Classification, Data Mining, Naïve Bayes, Gamer Behavior, Roblox

1. PENDAHULUAN

Perkembangan teknologi digital telah mendorong pertumbuhan industri *game online* sebagai salah satu bentuk hiburan yang banyak diminati masyarakat. *Game Online* merupakan permainan berbasis internet yang memungkinkan pemain berinteraksi secara langsung melalui berbagai aktivitas seperti komunikasi, kerja sama, dan kompetisi [1]. Selain berfungsi sebagai sarana hiburan, *game online* juga menjadi ruang sosial dan media pengembangan kreativitas yang mampu membentuk komunitas digital dengan karakteristik pengguna yang beragam [2], [3]. Aktivitas pemain yang semakin intens dalam lingkungan virtual menghasilkan berbagai pola perilaku yang menarik untuk dianalisis, sehingga pemahaman terhadap perilaku pemain menjadi aspek penting dalam pengembangan platform game modern [4]. Meskipun demikian, sebagian besar penelitian sebelumnya masih berfokus pada analisis sentimen, tingkat kecanduan, atau perilaku pemain pada game secara umum, sedangkan penelitian yang mengklasifikasikan perilaku pemain Roblox berdasarkan data kuesioner masih terbatas. Kondisi tersebut menunjukkan adanya research gap yang mendorong perlunya penelitian mengenai klasifikasi perilaku pemain Roblox menggunakan pendekatan machine learning.

Beberapa penelitian terdahulu telah menerapkan algoritma Naive Bayes pada berbagai persoalan klasifikasi, seperti analisis sentimen genre Roblox di Tiktok [5], klasifikasi perilaku pemain *game online* berbasis Particle Swarm Optimization [4], klasifikasi tingkat kecanduan internet pada remaja [6], serta sistem klasifikasi kecanduan *game online* berbasis website [7]. Studi-studi tersebut menunjukkan potensi Naive Bayes yang baik dalam berbagai konteks klasifikasi, namun masih berfokus pada analisis sentimen, perilaku pemain secara umum, atau tingkat kecanduan, sedangkan penelitian yang secara khusus mengklasifikasikan perilaku pemain Roblox ke dalam kategori aktif, sosial, kreatif, dan kasual berdasarkan data kuesioner yang masih terbatas.



Salah satu platform *game online* yang mengalami perkembangan pesat adalah Roblox. Roblox tidak hanya berfungsi sebagai media permainan, tetapi juga sebagai ekosistem kreatif yang memungkinkan pengguna membuat dan memainkan game buatan sendiri melalui Roblox Studio [2], [8]. Platform ini mendukung berbagai aktivitas seperti interaksi sosial, pembuatan avatar, penyelenggaraan event virtual, hingga transaksi menggunakan Robux yang membentuk pengalaman bermain yang lebih personal dan berkelanjutan [9]. Karakteristik tersebut menjadikan Roblox sebagai platform dengan perilaku pengguna yang sangat beragam dan dinamis. Keberagaman fitur tersebut menyebabkan perilaku pemain sulit dianalisis secara manual karena setiap pemain dapat memiliki kombinasi aktivitas, preferensi, dan intensitas penggunaan yang berbeda. Oleh karena itu, diperlukan pendekatan analisis berbasis data yang mampu mengidentifikasi pola perilaku pemain secara lebih objektif.

Selain sebagai media hiburan, Roblox juga menyediakan berbagai fitur yang memungkinkan pemain membangun identitas virtual dan menjalin hubungan dengan pengguna lain. Sebagian besar aktivitas pemain tersimpan dalam sistem akun, seperti riwayat permainan, durasi bermain, interaksi sosial, serta penggunaan fitur kreatif yang tersedia pada platform. Data-data tersebut dapat memberikan gambaran mengenai kebiasaan dan preferensi pemain dalam menggunakan Roblox. Semakin beragam aktivitas yang dilakukan pengguna, semakin banyak pula informasi yang dapat dimanfaatkan untuk memahami pola perilaku pemain secara lebih mendalam [10].

Perilaku pemain Roblox dipengaruhi oleh berbagai faktor, seperti frekuensi bermain, durasi bermain, motivasi penggunaan, preferensi aktivitas, serta tingkat interaksi sosial selama bermain [4]. Perbedaan kombinasi faktor tersebut menyebabkan setiap pemain memiliki karakteristik yang berbeda sehingga tidak dapat di pandang sebagai kelompok yang homogen. Variasi perilaku tersebut menunjukkan pentingnya proses klasifikasi untuk mengidentifikasi karakteristik pemain secara lebih sistematis [7], [11].

Keberagaman karakteristik pemain menyebabkan proses identifikasi perilaku menjadi semakin kompleks apabila dilakukan secara manual. Banyaknya variasi aktivitas, preferensi, serta intensitas bermain menghasilkan data dengan pola yang sulit dikenali tanpa bantuan metode komputasi. Oleh karena itu, diperlukan pendekatan klasifikasi berbasis machine learning yang mampu mengolah data perilaku secara otomatis, objektif, dan konsisten sehingga dapat membantu pengembang dalam memahami karakteristik pengguna serta mendukung pengambilan keputusan berbasis data [12].

Pendekatan berbasis data dapat digunakan untuk memahami perilaku pemain secara lebih terukur melalui data kuesioner yang memuat informasi mengenai aktivitas bermain, frekuensi, durasi, interaksi sosial, motivasi, dan keterlibatan pemain dalam fitur kreatif Roblox [1]. Data tersebut kemudian dianalisis menggunakan *machine learning* untuk mengenali pola perilaku pemain secara otomatis. Dalam konteks klasifikasi perilaku *game*, *machine learning* mampu mempelajari hubungan antar karakteristik pemain sehingga proses pengelompokan menjadi lebih cepat, konsisten, dan objektif dibandingkan analisis manual [13].

Dalam penelitian ini digunakan pendekatan *supervised learning* karena data yang digunakan telah memiliki label kategori perilaku pemain. Pendekatan ini memungkinkan model untuk mempelajari hubungan antara fitur-fitur yang terdapat pada data dengan kategori perilaku yang telah ditentukan sebelumnya. Salah satu tugas utama dalam *supervised learning* adalah klasifikasi, yaitu proses mengelompokkan data ke dalam kategori tertentu berdasarkan pola yang dipelajari dari data sebelumnya [14]. Melalui proses klasifikasi, pemain Roblox dapat dikelompokkan ke dalam beberapa tipe perilaku seperti pemain aktif, kasual, sosial, dan kreatif, sehingga karakteristik serta kecenderungan perilaku pengguna dapat dipahami secara lebih terstruktur dan sistematis. Hasil klasifikasi tersebut juga dapat dimanfaatkan untuk membantu pengembang dalam memahami preferensi pemain dan mendukung pengambilan keputusan berbasis data [5].

Penelitian ini mengklasifikasikan pemain Roblox ke dalam empat kategori perilaku, yaitu pemain aktif, kasual, sosial, dan kreatif. Pengelompokan tersebut mengacu pada karakteristik aktivitas pemain yang banyak dijumpai pada penelitian mengenai perilaku pemain game online, meliputi intensitas bermain, tujuan bermain, interaksi sosial, dan aktivitas kreatif dalam permainan [4], [11]. Pemain aktif memiliki intensitas bermain yang tinggi dan cenderung sering mengikuti berbagai aktivitas dalam permainan. Pemain kasual bermain untuk tujuan hiburan tanpa berfokus pada pencapaian tertentu. Pemain sosial lebih menekankan aspek komunikasi dan interaksi dengan pemain lain, sedangkan pemain kreatif lebih banyak terlibat dalam pembuatan game dan pengembangan konten menggunakan Roblox Studio. Pengelompokan tersebut digunakan sebagai dasar dalam proses klasifikasi agar karakteristik perilaku pemain dapat dianalisis secara lebih sistematis.

Algoritma yang digunakan dalam penelitian ini adalah Naïve Bayes. Naïve Bayes merupakan metode klasifikasi berbasis probabilitas yang menggunakan Teorema Bayes dengan asumsi bahwa setiap fitur pada data bersifat independen satu sama lain [15]. Meskipun pada data perilaku asumsi independensi tidak selalu sepenuhnya terpenuhi, berbagai penelitian menunjukkan bahwa Naïve Bayes tetap mampu memberikan performa yang kompetitif pada data kuesioner karena memiliki proses komputasi yang sederhana, cepat, serta mampu bekerja dengan baik pada data kategorikal [12], [16]. Oleh karena itu, algoritma ini dipilih sebagai model dasar (*baseline*) untuk mengevaluasi kemampuan klasifikasi perilaku pemain Roblox.

Beberapa penelitian terdahulu telah menerapkan algoritma Naïve Bayes pada berbagai permasalahan klasifikasi. Salah satunya adalah penelitian [5] yang menerapkan algoritma Naïve Bayes untuk analisis sentimen terhadap genre Roblox di TikTok. Selain itu, algoritma Naïve Bayes juga telah diterapkan untuk klasifikasi perilaku pemain game online berbasis *Particle Swarm Optimization* [4], klasifikasi tingkat kecanduan *game online* pada mahasiswa [6], serta klasifikasi kecanduan bermain *game online* berbasis website [7]. Hasil penelitian-penelitian tersebut menunjukkan bahwa algoritma Naïve Bayes memiliki potensi yang baik dalam berbagai permasalahan klasifikasi perilaku. Namun, penelitian yang secara khusus mengklasifikasikan perilaku pemain Roblox berdasarkan data kuesioner ke dalam kategori pemain aktif,




kasual, sosial, dan kreatif masih terbatas. Oleh karena itu, penelitian ini mengisi celah tersebut dengan menerapkan algoritma Naïve Bayes sebagai model dasar (*baseline*) dalam klasifikasi perilaku pemain Roblox.

Berdasarkan uraian tersebut, penelitian ini bertujuan untuk mengklasifikasikan perilaku pemain Roblox menggunakan algoritma Naïve Bayes berdasarkan data kuesioner yang diperoleh dari responden. Proses klasifikasi dilakukan untuk mengidentifikasi dan mengelompokkan pemain ke dalam kategori perilaku tertentu berdasarkan karakteristik aktivitas yang dimiliki. Kontribusi penelitian ini terletak pada penyediaan model dasar (*baseline*) klasifikasi perilaku pemain Roblox yang dapat menjadi referensi bagi penelitian selanjutnya dalam pengembangan analisis perilaku pengguna berbasis machine learning [16]. Selain itu, hasil penelitian juga diharapkan dapat membantu pengembang game dalam memahami karakteristik dan preferensi pengguna secara lebih mendalam, sehingga dapat mendukung pengembangan platform yang lebih adaptif, menarik, serta sesuai dengan kebutuhan dan pengalaman bermain para pemain [9], [17].

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Alur penelitian dilakukan secara sistematis untuk memastikan setiap tahapan berjalan terstruktur dan dapat dipertanggungjawabkan secara metodologis. Proses diawali dengan identifikasi masalah dan penetapan tujuan penelitian, dilanjutkan dengan studi literatur mengenai perilaku pemain game, platform Roblox, teknik klasifikasi, serta algoritma Naïve Bayes. Berdasarkan kajian tersebut, disusun instrumen kuesioner yang divalidasi melalui expert judgment serta uji validitas dan reliabilitas, sebelum disebarkan secara daring kepada responden. Data yang terkumpul kemudian melalui tahap pengumpulan dan seleksi, dilanjutkan dengan *preprocessing* meliputi data cleaning, encoding, dan pembagian dataset, sebelum diproses menggunakan algoritma Gaussian Naïve Bayes untuk membangun model klasifikasi. Tahap akhir meliputi evaluasi performa model serta interpretasi hasil dan penyusunan laporan sebagai bentuk dokumentasi keseluruhan proses penelitian. Tahapan-tahapan tersebut disajikan pada Gambar 1 dan dirancang agar proses penelitian berlangsung secara terstruktur serta dapat direplikasi pada penelitian selanjutnya [4].



Gambar 1. Diagram Alir Prosedur Penelitian

2.2 Jenis dan Pendekatan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode deskriptif dan komputasional. Pendekatan kuantitatif dipilih karena data yang dianalisis berupa data numerik hasil kuesioner, sehingga memungkinkan dilakukan pengolahan statistik secara objektif dan sistematis. Pendekatan ini umum digunakan dalam penelitian perilaku pengguna karena mampu merepresentasikan fenomena sosial dalam bentuk data yang terstruktur dan dapat diolah secara komputasional [4], [18], [19]. Metode deskriptif digunakan untuk menggambarkan karakteristik perilaku pemain berdasarkan variabel seperti frekuensi bermain, durasi bermain, interaksi sosial, serta aktivitas kreatif. Selain itu, penelitian ini juga menerapkan pendekatan komputasional melalui teknik *Machine Learning* untuk membangun model klasifikasi otomatis menggunakan algoritma Naïve Bayes. Kombinasi kedua pendekatan tersebut diharapkan mampu menghasilkan analisis perilaku pemain yang lebih terstruktur dan akurat [12].

2.3 Sumber dan Pengumpulan Data

Data penelitian ini merupakan data primer yang diperoleh melalui penyebaran kuesioner daring menggunakan Google Form. Kuesioner disebarkan melalui beberapa platform digital seperti WhatsApp, Twitter (X), dan komunitas pemain Roblox untuk memperoleh responden secara luas. Instrumen penelitian disusun berdasarkan indikator perilaku pemain game online, meliputi frekuensi bermain, durasi bermain, preferensi aktivitas, motivasi, interaksi sosial, serta aktivitas



kreatif [2], [13]. Data dikumpulkan menggunakan skala Likert dan pilihan ganda untuk mempermudah proses pengolahan. Responden kemudian dikategorikan ke dalam tipe perilaku pemain aktif, kasual, sosial, atau kreatif yang digunakan sebagai label dalam proses klasifikasi. Sebelum digunakan sebagai instrumen penelitian, kuesioner terlebih dahulu diuji validitas dan reliabilitasnya. Uji validitas dilakukan menggunakan korelasi *Pearson Product Moment* untuk mengetahui tingkat keterkaitan setiap butir pertanyaan terhadap skor total, sedangkan uji reliabilitas dilakukan menggunakan Cronbach's Alpha. Instrumen dinyatakan layak digunakan apabila setiap butir pertanyaan memenuhi kriteria valid dan nilai Cronbach's Alpha lebih dari 0,70 sehingga mampu menghasilkan data yang konsisten sebagai masukan dalam proses klasifikasi menggunakan algoritma Naïve Bayes.

2.4 Populasi dan Sampel

Populasi penelitian ini adalah pemain Roblox di wilayah Solo Raya. Wilayah tersebut dipilih sebagai batasan penelitian karena memudahkan proses penyebaran kuesioner serta memperoleh responden yang sesuai dengan kriteria penelitian. Pembatasan wilayah juga dilakukan agar karakteristik responden lebih homogen sehingga analisis dapat dilakukan sesuai dengan ruang lingkup penelitian. Teknik pengambilan sampel menggunakan purposive sampling karena penelitian memerlukan responden yang memiliki pengalaman bermain Roblox dan mampu memberikan informasi sesuai variabel penelitian.

Teknik ini dipilih berdasarkan kriteria tertentu sehingga data yang diperoleh lebih relevan dengan tujuan penelitian, meskipun hasil penelitian belum dapat digeneralisasikan kepada seluruh populasi pemain Roblox. Kriteria responden meliputi pernah memainkan Roblox dalam satu bulan terakhir, mengisi kuesioner secara lengkap, serta bersedia berpartisipasi dalam penelitian. Berdasarkan proses pengumpulan data, berhasil dikumpulkan sebanyak 523 respons melalui penyebaran kuesioner. Setelah dilakukan proses seleksi berdasarkan kriteria penelitian dan tahap preprocessing, sebanyak 520 data dinyatakan layak digunakan sebagai dataset penelitian. [4] Jumlah tersebut dinilai cukup representatif untuk mendukung proses analisis dan pelatihan model klasifikasi.

2.5 Preprocessing Data

Tahapan *preprocessing* menjadi bagian penting dalam penerapan *Machine Learning* karena kualitas data yang digunakan akan berpengaruh terhadap kinerja dan hasil prediksi model yang dibangun. Tahapan *preprocessing* yang dilakukan dalam penelitian ini meliputi *data cleaning*, yaitu menghapus data duplikat serta menangani data kosong atau tidak valid, di mana data kosong diisi menggunakan nilai modus karena sebagian besar variabel penelitian merupakan data kategorikal, penggunaan modus dipilih untuk mempertahankan kategori yang paling sering muncul sehingga perubahan distribusi data dapat diminimalkan dan konsistensi dataset tetap terjaga. Selanjutnya dilakukan *encoding data*, yaitu mengubah data kategorikal menjadi bentuk numerik agar dapat diproses oleh algoritma klasifikasi, serta transformasi data untuk menyesuaikan format data agar sesuai dengan kebutuhan dan kompatibilitas algoritma yang digunakan. Tahap terakhir adalah pembagian dataset menjadi 80% data latih dan 20% data uji untuk mengurangi risiko overfitting serta menguji kemampuan model dalam melakukan prediksi terhadap data baru [4].

2.6 Metode Klasifikasi Naïve Bayes

Metode klasifikasi yang digunakan dalam penelitian ini adalah algoritma Naïve Bayes, yaitu metode klasifikasi berbasis probabilitas yang didasarkan pada Teorema Bayes. Algoritma ini memiliki asumsi bahwa setiap fitur bersifat independen terhadap fitur lainnya, sehingga proses perhitungan probabilitas menjadi lebih sederhana. Secara matematis, Naive Bayes dirumuskan berdasarkan Teorema Bayes sebagai berikut:

$$P(C | X) = \frac{P(X|C)P(C)}{P(X)} \quad (1)$$

Pada Persamaan (1), CC merupakan kelas yang diprediksi, XX adalah data masukan, $P(C|X)P(C|X)$ merupakan probabilitas *posterior*, $P(C)P(C)$ adalah probabilitas *prior*, $P(X|C)P(X|C)$ adalah probabilitas *likelihood*, sedangkan $P(X)P(X)$ merupakan probabilitas *evidence* yang bernilai konstan sehingga kelas dengan probabilitas terbesar dipilih sebagai hasil klasifikasi. Dalam penelitian ini digunakan Gaussian Naïve Bayes karena data hasil kuesioner telah ditransformasikan ke dalam bentuk numerik, sehingga lebih sesuai dibandingkan varian Multinomial maupun Bernoulli Naïve Bayes). Probabilitas Gaussian dihitung menggunakan persamaan berikut:

$$P(x_i | C) = \frac{1}{\sqrt{2\pi\sigma_c^2}} \exp\left(-\frac{(x_i - \mu_c)^2}{2\sigma_c^2}\right) \quad (2)$$

Pada Persamaan (2), μ_c merupakan nilai rata-rata fitur pada kelas C, σ_c^2 merupakan varians fitur pada kelas C, sedangkan x_i merupakan nilai fitur yang akan dihitung probabilitasnya. Algoritma ini menghitung probabilitas suatu data termasuk ke dalam kelas tertentu berdasarkan distribusi normal dari setiap fitur. Proses klasifikasi dilakukan melalui beberapa tahap, yaitu menghitung probabilitas prior untuk setiap kelas, menghitung probabilitas likelihood untuk setiap fitur terhadap kelas, menghitung probabilitas posterior menggunakan Teorema Bayes, kemudian menentukan kelas dengan probabilitas tertinggi sebagai hasil klasifikasi. Algoritma ini dipilih karena memiliki keunggulan dalam kesederhanaan model, efisiensi komputasi, serta kemampuan dalam menangani dataset dengan jumlah fitur yang cukup banyak.

2.7 Evaluasi Model

Evaluasi model dilakukan untuk mengetahui tingkat kinerja algoritma dalam proses klasifikasi perilaku pemain. Tahap evaluasi ini bertujuan untuk mengukur kemampuan serta keandalan model dalam menghasilkan prediksi terhadap data baru[20].


Adapun beberapa metrik evaluasi yang digunakan dalam penelitian ini meliputi *confusion matrix*, yang digunakan untuk menganalisis perbandingan antara hasil prediksi model dengan kelas aktual pada data. *accuracy*, yang digunakan untuk mengetahui persentase keseluruhan prediksi yang berhasil diklasifikasikan dengan benar oleh model. *precision*, yang digunakan untuk mengukur tingkat ketepatan model dalam memprediksi suatu kategori tertentu. *recall*, yang digunakan untuk mengetahui kemampuan model dalam mengidentifikasi seluruh data yang termasuk dalam suatu kategori. serta *f1-score*, yang digunakan sebagai nilai gabungan antara *precision* dan *recall* untuk memberikan penilaian performa model yang lebih seimbang. Penggunaan beberapa metrik evaluasi tersebut dilakukan agar dapat memberikan gambaran yang lebih menyeluruh mengenai performa model, khususnya ketika menghadapi kondisi distribusi data yang tidak seimbang[15].

3. HASIL DAN PEMBAHASAN

Pada bagian ini dilakukan penyajian hasil penelitian serta pembahasan terhadap performa model klasifikasi yang telah dibangun. Hasil yang diperoleh dianalisis berdasarkan pengujian menggunakan algoritma Naïve Bayes untuk mengetahui kemampuan model dalam mengklasifikasikan perilaku pemain Roblox ke dalam beberapa kategori. Pembahasan dilakukan dengan menginterpretasikan hasil evaluasi model menggunakan berbagai metrik pengukuran, sehingga dapat diketahui kelebihan maupun keterbatasan model yang digunakan.

3.1 Hasil

Berdasarkan hasil penyebaran kuesioner diperoleh 523 respons. Setelah melalui tahap seleksi dan preprocessing, sebanyak 520 data dinyatakan layak digunakan sebagai dataset penelitian, sedangkan 3 data tidak digunakan karena tidak memenuhi kriteria penelitian. Dataset tersebut kemudian dibagi menjadi 416 data latih (80%) dan 104 data uji (20%) untuk membangun dan menguji model klasifikasi Naïve Bayes.



Gambar 2. Distribusi Kategori Perilaku Pemain Roblox berdasarkan jawaban Responden

Gambar 2 menunjukkan distribusi kategori perilaku pemain Roblox berdasarkan hasil kuesioner. Mayoritas responden termasuk kategori pemain kasual (41,3%), diikuti pemain aktif (33,7%), pemain sosial (18,2%), dan pemain kreatif dengan persentase terendah.


Model klasifikasi kemudian dibangun menggunakan data yang telah melalui tahap *preprocessing*. Hasil evaluasi model pada Tabel 1 menunjukkan bahwa algoritma Naïve Bayes memperoleh akurasi sebesar 62,5% dengan nilai *precision*, *recall*, dan *F1-score* yang bervariasi pada setiap kelas. Hasil tersebut menunjukkan bahwa model cukup mampu mengklasifikasikan perilaku pemain meskipun masih terdapat beberapa kesalahan klasifikasi.

Tabel 1. Hasil Evaluasi Model Naive Bayes

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
0	0.67	0.50	0.57	36
1	0.68	0.80	0.74	40
2	0.50	0.33	0.40	9
3	0.50	0.63	0.56	19

Berdasarkan Tabel 1, kelas 1 memiliki performa terbaik nilai *recall* 0,80 dan *F1-score* 0,74, sedangkan kelas 2 memiliki performa terendah dengan *recall* 0,33 dan *F1-score* 0,40. Nilai *macro average F1-score* sebesar 0,57 dan

weighted average F1-score sebesar 0,62 menunjukkan bahwa performa model masih dipengaruhi oleh ketidakseimbangan distribusi data.



Gambar 3. Visualisasi Performa Model Naive Bayes

Gambar 3 memberikan visualisasi performa model berdasarkan metrik evaluasi. Terlihat bahwa *accuracy*, *precision*, *recall*, dan *F1-score* memiliki nilai yang relatif berdekatan sehingga menunjukkan performa model yang cukup konsisten secara keseluruhan.

Secara keseluruhan diperoleh nilai *macro average F1-score* sebesar 0,57, sedangkan *weighted average F1-score* sebesar 0,62. Nilai *macro average* yang lebih rendah menunjukkan bahwa performa model belum merata pada seluruh kelas, sedangkan *weighted average* yang lebih tinggi menunjukkan bahwa model lebih baik mengenali kelas dengan jumlah data yang lebih besar. Analisis lebih lanjut dilakukan menggunakan *confusion matrix* berikut:

Tabel 2. Confusion Matrix Hasil Klasifikasi Naïve Bayes

Actual \ Predicted	Aktif	Kasual	Sosial	Kreatif
Aktif	18	10	2	6
Kasual	4	32	0	4
Sosial	3	1	3	2
Kreatif	2	4	1	12

Berdasarkan Tabel 2, baris menunjukkan kelas aktual (*actual label*), sedangkan kolom menunjukkan hasil prediksi (*predicted label*). Keempat label kelas terdiri atas pemain aktif, kasual, sosial, dan kreatif.

Berdasarkan *confusion matrix*, nilai pada diagonal utama lebih besar dibandingkan nilai di luar diagonal, yang menunjukkan sebagian besar prediksi model sudah sesuai dengan label sebenarnya. Namun, masih terdapat kesalahan klasifikasi pada beberapa kelas yang memiliki karakteristik mirip, sehingga model mengalami kesulitan dalam membedakan kelas secara tepat.

Berdasarkan hasil penelitian, algoritma Naïve Bayes dapat diterapkan untuk melakukan klasifikasi perilaku pemain Roblox ke dalam empat kategori, yaitu pemain aktif, kasual, sosial, dan kreatif. Model klasifikasi yang dibangun berdasarkan data kuesioner menghasilkan nilai akurasi sebesar 62,5%. Perolehan nilai tersebut menunjukkan bahwa model mampu mengidentifikasi pola perilaku pemain berdasarkan fitur-fitur yang digunakan dalam penelitian. Walaupun tingkat akurasi yang diperoleh masih dapat ditingkatkan, penerapan metode Machine Learning dengan algoritma Naïve Bayes menunjukkan hasil yang cukup baik sebagai pendekatan awal dalam melakukan analisis dan pengelompokan karakteristik perilaku pemain Roblox.

Berdasarkan distribusi data responden, mayoritas pemain termasuk dalam kategori pemain kasual dengan persentase sebesar 41,3%. Hasil ini menunjukkan bahwa sebagian besar pengguna Roblox memanfaatkan platform tersebut sebagai sarana hiburan ringan untuk mengisi waktu luang. Karakteristik Roblox yang menyediakan banyak pilihan permainan dengan tingkat kesulitan yang beragam memungkinkan pemain bermain tanpa harus memiliki komitmen tinggi terhadap suatu permainan tertentu. Kondisi tersebut menyebabkan kategori pemain kasual mendominasi dibandingkan kategori lainnya.

Kategori pemain aktif menempati posisi kedua dengan persentase sebesar 33,7%. Jumlah tersebut menunjukkan bahwa cukup banyak pemain yang memiliki intensitas bermain tinggi dan aktif mengikuti berbagai aktivitas dalam platform Roblox. Pemain aktif umumnya memiliki frekuensi bermain yang lebih tinggi, sering mencoba berbagai jenis permainan, serta mengikuti perkembangan fitur maupun event yang tersedia. Karakteristik yang relatif konsisten pada kelompok ini memudahkan model dalam mengenali pola perilaku mereka dibandingkan kelompok lain yang memiliki karakteristik lebih beragam.



Sementara itu, kategori pemain sosial memiliki persentase sebesar 18,2%. Kelompok ini lebih berfokus pada aktivitas komunikasi dan interaksi dengan pemain lain. Pemain sosial memanfaatkan fitur komunitas, pertemanan, maupun permainan berbasis roleplay sebagai sarana berinteraksi. Karakteristik pemain sosial sering kali memiliki kemiripan dengan pemain kasual karena keduanya sama-sama tidak selalu berorientasi pada pencapaian tertentu. Kemiripan inilah yang menjadi salah satu faktor penyebab terjadinya kesalahan klasifikasi pada beberapa data.

Kategori pemain kreatif memiliki jumlah paling sedikit dibandingkan kategori lainnya. Hasil ini menunjukkan bahwa tidak semua pemain Roblox tertarik untuk menggunakan Roblox Studio atau membuat konten digital secara mandiri. Aktivitas kreatif membutuhkan kemampuan teknis, waktu, dan minat yang lebih spesifik dibandingkan aktivitas bermain biasa. Oleh karena itu, jumlah pemain kreatif cenderung lebih rendah dibandingkan pemain yang hanya memanfaatkan Roblox sebagai sarana hiburan atau interaksi sosial.

Tingkat akurasi sebesar 62,5% menunjukkan bahwa model mampu mengklasifikasikan lebih dari setengah jumlah data uji dengan benar. Dalam penelitian berbasis data kuesioner, nilai tersebut dapat dikategorikan cukup baik karena data yang digunakan bersifat subjektif dan dipengaruhi oleh persepsi masing-masing responden. Berbeda dengan data transaksi atau data sensor yang memiliki pola lebih konsisten, data perilaku manusia umumnya memiliki variasi yang tinggi sehingga proses klasifikasi menjadi lebih kompleks. Oleh karena itu, nilai akurasi pada penelitian ini tidak dijadikan sebagai satu-satunya tolak ukur, tetapi juga didukung oleh evaluasi menggunakan *precision*, *recall*, dan *F1-score* untuk memberikan gambaran performa model secara lebih menyeluruh.

Hasil evaluasi menggunakan *precision*, *recall*, dan *F1-score* menunjukkan bahwa performa model tidak sama pada setiap kelas. Kelas 1 memiliki performa terbaik dengan nilai *recall* sebesar 0,80 dan *F1-score* sebesar 0,74. Tingginya nilai *recall* menunjukkan bahwa model mampu mengenali sebagian besar data pada kelas tersebut. Selain itu, nilai *F1-score* yang relatif tinggi menunjukkan adanya keseimbangan antara *precision* dan *recall* sehingga hasil klasifikasi pada kelas ini dapat dikatakan cukup baik.

Performa yang baik pada kelas 1 mengindikasikan bahwa karakteristik pemain dalam kategori tersebut lebih mudah dibedakan dibandingkan kategori lainnya. Variabel seperti frekuensi bermain, durasi bermain, dan tingkat keterlibatan pemain kemungkinan memiliki pola yang lebih konsisten sehingga dapat dikenali dengan baik oleh algoritma Naïve Bayes. Semakin jelas perbedaan karakteristik suatu kelas, maka semakin mudah model melakukan proses klasifikasi secara akurat.

Sebaliknya, kelas 2 menunjukkan performa terendah dengan nilai *recall* sebesar 0,33 dan *F1-score* sebesar 0,40. Nilai tersebut menunjukkan bahwa sebagian besar data pada kelas tersebut tidak berhasil dikenali dengan baik oleh model. Rendahnya performa dapat disebabkan oleh jumlah data yang lebih sedikit dibandingkan kelas lain sehingga model memiliki informasi yang terbatas untuk mempelajari karakteristik kelas tersebut.

Selain faktor jumlah data, rendahnya performa pada kelas tertentu juga dapat disebabkan oleh adanya overlap atau tumpang tindih karakteristik antar kategori pemain. Dalam praktiknya, perilaku pemain tidak selalu dapat dikelompokkan secara tegas ke dalam satu kategori tertentu. Seorang pemain dapat memiliki karakteristik sebagai pemain kasual sekaligus sosial, atau pemain aktif sekaligus kreatif. Kondisi ini menyebabkan batas antar kelas menjadi kurang jelas sehingga meningkatkan kemungkinan terjadinya kesalahan klasifikasi.

Hasil confusion matrix menunjukkan bahwa sebagian besar nilai berada pada diagonal utama, yang menandakan bahwa model telah menghasilkan prediksi yang sesuai dengan label sebenarnya pada sebagian besar data. Namun demikian, masih terdapat sejumlah data yang salah diklasifikasikan ke kategori lain. Kesalahan klasifikasi tersebut menunjukkan bahwa beberapa kategori perilaku memiliki kemiripan karakteristik yang cukup tinggi sehingga sulit dibedakan secara sempurna oleh model.

Berdasarkan Tabel 2, sebagian besar kesalahan klasifikasi terjadi antara kategori pemain kasual dan pemain sosial. Kondisi tersebut menunjukkan adanya *false positive* dan *false negative* yang disebabkan oleh kemiripan karakteristik kedua kelompok. Sebagian pemain kasual tetap melakukan interaksi sosial selama bermain, sedangkan pemain sosial juga dapat bermain secara santai tanpa berfokus pada aktivitas komunikasi. Kemiripan tersebut menyebabkan model kesulitan membedakan kedua kategori secara tegas.

Nilai *macro average F1-score* sebesar 0,57 menunjukkan bahwa kinerja model belum sepenuhnya optimal dan masih terdapat ketidakseimbangan performa antar kelas. Beberapa kategori mampu menghasilkan prediksi dengan tingkat ketepatan yang lebih baik, sedangkan kategori lainnya menunjukkan hasil evaluasi yang lebih rendah. Kondisi tersebut menunjukkan bahwa model masih mengalami keterbatasan dalam mengidentifikasi kategori dengan jumlah data yang lebih sedikit maupun kategori yang memiliki karakteristik data yang kurang spesifik.

Sementara itu, *weighted average F1-score* sebesar 0,62 menunjukkan bahwa performa model cenderung lebih baik pada kelas yang memiliki jumlah data lebih besar. Kondisi ini menunjukkan adanya pengaruh ketidakseimbangan distribusi data terhadap hasil klasifikasi. Model lebih mudah mempelajari pola dari kelas mayoritas dibandingkan kelas minoritas karena jumlah contoh data yang tersedia lebih banyak.

Selain distribusi data, performa model juga dipengaruhi oleh asumsi independensi fitur yang digunakan dalam algoritma Naïve Bayes. Algoritma ini mengasumsikan bahwa setiap fitur tidak saling berkaitan satu sama lain. Pada kenyataannya, beberapa variabel perilaku pemain memiliki hubungan yang cukup kuat. Sebagai contoh, pemain dengan frekuensi bermain tinggi cenderung memiliki durasi bermain yang lebih lama. Ketergantungan antar fitur tersebut tidak sepenuhnya dapat direpresentasikan oleh model Naïve Bayes sehingga memengaruhi hasil klasifikasi.

Dominasi pemain kasual menunjukkan bahwa sebagian besar pengguna memanfaatkan Roblox sebagai media hiburan ringan. Temuan ini dapat menjadi masukan bagi pengembang Roblox untuk memprioritaskan pengembangan



fitur yang mudah diakses oleh pemain baru, menyediakan rekomendasi permainan yang sesuai dengan preferensi pengguna, serta meningkatkan aktivitas komunitas agar pemain kasual dapat berinteraksi lebih aktif dan berpotensi berkembang menjadi pemain sosial maupun kreatif.

3.2 Pembahasan

Temuan penelitian ini menunjukkan bahwa akurasi model Naïve Bayes sebesar 62,5% berada di bawah performa yang dilaporkan pada beberapa penelitian terdahulu yang juga menerapkan algoritma yang sama. Dermawan dkk. [5] misalnya melaporkan akurasi sebesar 77,78% dalam menganalisis sentimen ulasan pengguna Roblox di TikTok ke dalam tiga kategori (positif, negatif, dan netral). Perbedaan performa ini kemungkinan disebabkan oleh karakteristik permasalahan yang berbeda; analisis sentimen umumnya memiliki batas antar kelas yang lebih jelas karena didasarkan pada pola kata atau frasa tertentu, sedangkan klasifikasi perilaku pemain pada penelitian ini bergantung pada data kuesioner yang bersifat subjektif dan rawan tumpang tindih antar kategori, seperti yang telah dibahas sebelumnya pada kesalahan klasifikasi antara pemain kasual dan sosial.

Perbandingan juga dilakukan terhadap penelitian Heristian dkk. [4] yang menerapkan Naïve Bayes untuk mengklasifikasikan perilaku pemain game online secara umum, dengan akurasi model dasar sebesar 75,09% yang kemudian meningkat menjadi 95,28% setelah dioptimasi menggunakan Particle Swarm Optimization. Selisih akurasi yang cukup besar terhadap penelitian ini mengindikasikan bahwa penerapan teknik optimasi fitur dapat menjadi salah satu upaya untuk meningkatkan performa model pada penelitian selanjutnya, mengingat penelitian ini masih menggunakan Naïve Bayes tanpa proses optimasi tambahan.

Sementara itu, penelitian Fikri dkk. [6] yang mengklasifikasikan tingkat kecanduan internet ke dalam empat kategori memperoleh rata-rata akurasi sebesar 93% melalui skema 10-fold cross validation, dan penelitian Pania dkk. [7] yang mengklasifikasikan tingkat kecanduan bermain game online ke dalam tiga kategori memperoleh akurasi tertinggi sebesar 93% pada perbandingan data latih dan data uji 40:60. Tingginya akurasi pada kedua penelitian tersebut diduga terkait dengan karakteristik variabel yang digunakan, yaitu tingkat kecanduan yang cenderung memiliki hubungan yang lebih linear dan terukur terhadap indikator seperti durasi dan frekuensi bermain, sehingga batas antar kelasnya lebih mudah dikenali oleh model dibandingkan kategori perilaku pemain (aktif, kasual, sosial, dan kreatif) yang digunakan dalam penelitian ini.

Berdasarkan perbandingan tersebut, dapat disimpulkan bahwa performa Naïve Bayes pada penelitian ini masih tergolong wajar mengingat kompleksitas permasalahan klasifikasi perilaku pemain yang bersifat multikelas dan memiliki karakteristik antar kategori yang saling berdekatan. Meskipun demikian, hasil ini tetap menegaskan bahwa algoritma Naïve Bayes layak digunakan sebagai model dasar (baseline) dalam penelitian ini, sekaligus membuka peluang bagi penelitian selanjutnya untuk meningkatkan performa klasifikasi melalui penambahan data, seleksi fitur, maupun penerapan algoritma optimasi seperti yang digunakan pada penelitian Heristian dkk [4].

4. KESIMPULAN

Penelitian ini bertujuan mengklasifikasikan perilaku pemain Roblox ke dalam empat kategori, yaitu pemain aktif, kasual, sosial, dan kreatif, menggunakan algoritma Gaussian Naïve Bayes berdasarkan data kuesioner yang disebarkan kepada pemain Roblox di wilayah Solo Raya. Dari 523 respons yang berhasil dikumpulkan, sebanyak 520 data dinyatakan layak digunakan sebagai dataset penelitian setelah melalui tahap seleksi dan preprocessing meliputi data cleaning, encoding, dan pembagian dataset menjadi 80% data latih dan 20% data uji, dan hasil pengujian menunjukkan model memperoleh akurasi sebesar 62,5% dengan nilai precision, recall, dan F1-score yang bervariasi antar kategori, di mana kategori dengan karakteristik lebih spesifik dan konsisten cenderung menghasilkan performa prediksi yang lebih baik dibandingkan kategori yang memiliki kemiripan karakteristik dengan kategori lain. Variasi performa tersebut turut dipengaruhi oleh ketidakseimbangan distribusi data antar kelas serta asumsi independensi fitur yang menjadi ciri khas algoritma Naïve Bayes, sehingga model belum sepenuhnya mampu menangkap keterkaitan kompleks antar variabel perilaku pemain. Meskipun demikian, hasil tersebut menunjukkan bahwa Naïve Bayes dapat digunakan sebagai model dasar (baseline) dalam klasifikasi perilaku pemain Roblox berbasis data kuesioner sekaligus memberikan gambaran awal mengenai karakteristik dan kecenderungan aktivitas pemain yang dapat menjadi referensi bagi pengembang dalam merancang fitur yang lebih adaptif dan sesuai kebutuhan pengguna, sehingga untuk penelitian selanjutnya disarankan menggunakan jumlah data yang lebih besar dan beragam, menerapkan teknik penanganan ketidakseimbangan kelas, menambahkan fitur yang lebih representatif, serta membandingkan performa Naïve Bayes dengan algoritma lain seperti Decision Tree, Random Forest, atau Support Vector Machine yang mampu memodelkan hubungan antar fitur secara lebih kompleks untuk meningkatkan akurasi klasifikasi perilaku pemain di masa mendatang.

REFERENCES

- [1] I. Sopiandi and D. Susanti, "Menganalisis Informasi Metaverse Pada Game Online Roblox Secara Garis Besar," *Jurnal PETISI*, vol. 3, no. 1, pp. 1–4, 2022, Accessed: Jul. 22, 2026. [Online]. Available: <https://ejournal.unimudasorong.ac.id/index.php/jurnalpetisi/article/view/797>
- [2] A. F. Alkindi and N. Nasution, "Analisis Sentimen Ulasan Pengguna pada Game Roblox dengan Metode Support Vector Machine dan Naive Bayes," *J-Com (Journal of Computer)*, vol. 4, no. 2, pp. 164–177, Jul. 2024, doi: 10.33330/j-com.v4i2.3319.



- [3] E. A. Setiani and A. G. J. Nasution, "Analisis Pengaruh Game Online Terhadap Hasil Belajar Siswa," *Aulad: Journal on Early Childhood*, vol. 6, no. 2, pp. 244–250, Aug. 2023, doi: 10.31004/aulad.v6i2.508.
- [4] S. Heristian, R. S. Anwar, and H. A. Al Kautsar, "Klasifikasi Perilaku Pemain Game Online Menggunakan Naïve Bayes Berbasis Particle Swarm Optimization," *Computer Science (CO-SCIENCE)*, vol. 4, no. 2, pp. 151–156, 2024, doi: 10.31294/coscience.v4i2.4433.
- [5] K. J. Dermawan, N. A. Sabrina, G. F. Michelle, and A. T. Ayunda, "Sentiment Analysis of Roblox Genres on TikTok: Roleplay, RPG, and Horror using Naïve Bayes," *Jurnal Ilmiah Sistem Informasi*, vol. 5, no. 1, pp. 425–438, Jan. 2026, doi: 10.51903/pkbfwq48.
- [6] M. I. Fikri, E. Budianita, I. Iskandar, and E. P. Cynthia, "Klasifikasi Tingkat Kecanduan Internet terhadap Remaja Pekanbaru Melalui Pendekatan Algoritma Naïve Bayes," *Jurnal Sistem Informasi*, vol. 6, no. 2, pp. 424–436, 2024, doi: 10.31849/zn.v6i2.20191.
- [7] T. S. Pania, R. Hidayati, and Kasliono, "Klasifikasi Kecanduan Bermain Game online Pada Remaja Menggunakan Metode Naïve Bayes Classifier Berbasis Website," *KLIK: Kajian Ilmiah Informatika dan Komputer*, vol. 4, no. 5, pp. 2518–2526, 2024, doi: 10.30865/klik.v4i5.1782.
- [8] G. Marullana, N. Rahaningsih, I. Ali, and A. R. Rinaldi, "Klasifikasi Sentimen Ulasan Pengguna Aplikasi Roblox di Google Play Store Menggunakan Machine Learning Supervised," *Journal of Computer Science and Artificial Intelligence (JCSAI)*, vol. 3, no. 04, pp. 1–5, 2026, Accessed: Jul. 22, 2026. [Online]. Available: <https://ruangjurnal.or.id/index.php/jcsai/article/view/328>
- [9] Ferdiansyah and R. R. Suryono, "Sentiment Classification of Indonesian-Language Roblox Reviews Using IndoBERT with SMOTE Optimization," *Journal of Applied Informatics and Computing (JAIC)*, vol. 9, no. 4, p. 1868, 2025, doi: 10.30871/jaic.v9i4.10155.
- [10] Moh. I. I. Jauhar, A. A. Bayu P, A. Ristyawan, and E. Daniati, "Klasifikasi Penggunaan Video Game Dengan Menggunakan Metode Algoritma Naïve Bayes," *Prosiding SEMNAS INOTEK (Seminar Nasional Inovasi Teknologi)*, vol. 8, no. 4, pp. 910–918, 2024, doi: 10.29407/inotek.v8i2.5020.
- [11] S. N. Matutina, E. Umar, and F. Bani, "Klasifikasi Tingkat Kecanduan Game Online pada Mahasiswa STIMIKOM Menggunakan Algoritma Naïve Bayes," *Jurnal Ilmu Komputer dan Bisnis*, vol. 15, no. 1, pp. 176–186, May 2024, doi: 10.47927/jikb.v15i1.730.
- [12] V. Fazrian, T. Suprpti, and R. Narasati, "Penerapan Algoritma Naïve Bayes terhadap Analisis Sentimen Aplikasi Game Multiplayer Online Battle Arena (Studi Kasus: Mobile Legend)," *Jurnal Mahasiswa Teknik Informatika*, vol. 8, no. 1, pp. 1005–1012, 2024, doi: 10.36040/jati.v8i1.8432.
- [13] J. Sihombing, "Klasifikasi Data Antropometri Individu Menggunakan Algoritma Naïve Bayes Classifier," *BIOS: Jurnal Teknologi Informasi dan Rekayasa Komputer*, vol. 2, no. 1, pp. 1–10, Mar. 2021, doi: 10.37148/bios.v2i1.15.
- [14] M. Haikal, Martanto, and U. Hayati, "Analisis Sentimen terhadap Penggunaan Aplikasi Game Online PUBG Mobile Menggunakan Algoritma Naïve Bayes," *Jurnal Mahasiswa Teknik Informatika*, vol. 7, no. 6, pp. 3275–3281, 2023, doi: 10.36040/jati.v7i6.8174.
- [15] R. S. Wibowo, M. Rakan, W. Ramadhan, J. B. Nugroho, and M. Arifin, "Analisis Sentimen Menggunakan Support Vector Machine dan Naïve Bayes Pengguna Game Roblox," *Jurnal Ilmu Komputer dan Informatika (JUKOMIKA)*, vol. 8, no. 2, pp. 106–112, 2025, doi: 10.54650/jukomika.v8i2.618.
- [16] A. Al-Mashhour and A. Alhogail, "Machine-Learning-based User Behavior Classification for Improving Security Awareness Provision," *IJACSA International Journal of Advanced Computer Science and Applications*, vol. 14, no. 8, pp. 166–178, 2023, doi: 10.14569/IJACSA.2023.0140819.
- [17] D. Nafisah, Y. Rada, and D. A. Sitaniapessy, "Analisis Sentimen Terhadap Ulasan Penggunaan Aplikasi Game Online Playerunknown's Battlegrounds (PUBG) Mobile Menggunakan Algoritma Naïve Bayes," *Jurnal INOVATIF WIRA WACANA*, vol. 04, no. 02, pp. 211–221, 2025, doi: 10.30865/json.v5i3.7264.
- [18] A. Haris, A. Hananto, and F. Nurapriani, "Penerapan Algoritma Naïve Bayes untuk Klasifikasi Sentimen Ulasan Pengguna Aplikasi PIDI UMKM dengan Pembobotan Fitur TF-IDF," *Jurnal Mahasiswa Teknik Informatika*, vol. 9, no. 5, pp. 8457–8462, 2025, doi: 10.36040/jati.v9i5.15019.
- [19] H. Rahmayanti, M. Dwi Nurmala, A. W. Handoyo, U. Sultan, and A. Tirtayasa, "Pengaruh Kecanduan Game Online Mobile Legends terhadap Prestasi Akademik Siswa," *Guidance: Jurnal Bimbingan dan Konseling*, vol. 21, no. 1, pp. 129–136, 2024, doi: 10.34005/guidance.v21i01.3523.
- [20] Rosalina, C. H. Pratomo, and O. Fathurohman SW, "Implementation of the K-Means Algorithm to Cluster Digital Transaction Preferences of Muhammadiyah Students," *Journal of Scientech Research and Development*, vol. 7, no. 2, pp. 330–337, 2025, Accessed: Jul. 25, 2026. [Online]. Available: <https://idm.or.id/JSCR/index.php/JSCR/article/view/1415>