

Sistem Klasifikasi Tingkat Resiko pada Pengguna Judi Online Berdasarkan Pola Perilaku dan Skor PGSI

Risk Level Classification System for Online Gambling Users Based on Behavioral Patterns and PGSI Scores

Andika Chandra Prasetyo¹, Toto Sudibyo², Moh Miftah³, Nurkhayati⁴

Universitas Bhamada Slawi, Jl. Cut Nyak Dien No. 16, Kalisapu, Kec. Slawi, Kab. Tegal, Jawa Tengah, 52416, (0283)6197570

E-mail : me@andikachandra.com¹, tototania@gmail.com², miftah4907@gmail.com³,
ayanunu85@gmail.com⁴

*Corresponding author

Received 19 January 2026; Revised 6 February 2026; Accepted 22 February 2026

Abstrak - Pertumbuhan pesat aktivitas perjudian online telah menimbulkan kekhawatiran signifikan karena dampak buruknya terhadap kesehatan mental, stabilitas finansial, dan fungsi sosial individu. Penelitian ini bertujuan untuk mengembangkan model klasifikasi berbasis pembelajaran mesin untuk membedakan tingkat risiko kecanduan judi di antara pengguna perjudian online dengan mengintegrasikan pola perilaku dan Problem Gambling Severity Index (PGSI). Pendekatan klasifikasi prediktif kuantitatif digunakan dengan data survei yang dikumpulkan dari 150 partisipan, di mana 138 respons awalnya dianggap valid. Setelah pra-pemrosesan data dan pemeriksaan kelengkapan, 3 respons dikeluarkan karena nilai yang hilang atau tidak konsisten, sehingga tersisa 135 sampel yang digunakan untuk pelatihan dan evaluasi model. Berdasarkan skor PGSI, tidak ada responden yang diklasifikasikan sebagai penjudi Non-Problem atau Low-Risk; oleh karena itu, tugas klasifikasi difokuskan secara eksklusif pada perbedaan individu Moderate-Risk dan High-Risk. Dua algoritma klasifikasi, Naïve Bayes dan Decision Tree, diimplementasikan dan dievaluasi menggunakan Stratified 5-Fold Cross-Validation. Kinerja model dinilai menggunakan Accuracy, Precision, Recall, F1-Score, Confusion Matrix, dan AUC-ROC. Hasil penelitian menunjukkan bahwa Naïve Bayes mengungguli Decision Tree, dengan akurasi 93% dan AUC-ROC sebesar 0,9601, sementara Decision Tree mencapai akurasi 91% dengan AUC-ROC sebesar 0,9021. Mengingat tidak adanya sampel Non-Problem dan Low-Risk, penelitian ini tidak merepresentasikan model deteksi dini untuk populasi umum, melainkan model stratifikasi risiko dalam sampel berisiko tinggi pengguna perjudian online. Temuan ini menyoroti potensi penggabungan indikator perilaku dan skor PGSI untuk mendukung pemantauan berbasis risiko serta strategi intervensi yang ditargetkan bagi individu dengan tingkat bahaya terkait perjudian yang tinggi.

Kata kunci – judi online, klasifikasi resiko, naïve bayes, decision tree, pgsi

Abstract – The rapid growth of online gambling activities has raised significant concerns due to their adverse impacts on individuals' mental health, financial stability, and social functioning. This study aims to develop a machine learning-based classification model to distinguish levels of gambling addiction risk among online gambling users by integrating behavioral patterns and the Problem Gambling Severity Index (PGSI). A quantitative predictive classification approach was employed using survey data collected from 150 participants, of which 138 responses were initially deemed valid. After data preprocessing and completeness checks, 3 responses were excluded due to missing or inconsistent values, resulting in 135 samples used for model training and evaluation. Based on PGSI scoring, no respondents were classified as Non-Problem or Low-Risk gamblers; therefore, the classification task focused exclusively on distinguishing Moderate-Risk and High-Risk individuals. Two classification algorithms, Naïve Bayes and Decision Tree were implemented and evaluated using Stratified 5-Fold Cross-Validation. Model performance was assessed using Accuracy, Precision, Recall, F1-Score, Confusion Matrix and AUC-ROC. The

results indicate that Naïve Bayes outperformed Decision Tree, achieving an accuracy of 93% and an AUC-ROC of 0.9601, while Decision Tree achieved an accuracy of 91% with an AUC-ROC of 0.9021. Given the absence of Non-Problem and Low-Risk samples, this study does not represent an early detection model for the general population, but rather a risk stratification model within a high-risk sample of online gambling users. The findings highlight the potential of combining behavioral indicators and PGSI scores to support risk-based monitoring and targeted intervention strategies for individuals with elevated levels of gambling-related harm.

Keywords – online gambling, risk classification, naïve bayes, decision tree, pgsi

1. PENDAHULUAN

Perkembangan teknologi informasi telah mempermudah akses terhadap perjudian online yang kini menjadi masalah serius di Indonesia dengan jumlah pemain mencapai 3,5 juta orang dan perputaran dana terakumulasi sebesar Rp13,2 triliun pada semester pertama tahun 2024[1], [2], [3]. Fenomena ini membawa dampak negatif yang luas, mulai dari masalah kesehatan mental seperti depresi, kecemasan dan isolasi sosial, hingga konsekuensi sosial-ekonomi yang substansial seperti kerugian finansial, utang dan peningkatan tindak kriminal[3], [4], [5], [6], [7]. Kecanduan judi online tidak hanya merugikan individu secara pribadi, tetapi juga mengganggu stabilitas keluarga dan lingkungan sosial, menjadikannya isu kesehatan masyarakat yang mendesak untuk ditangani[3].

Salah satu tantangan dalam menangani masalah ini adalah identifikasi tingkat resiko masalah perjudian pada pengguna, mengingat banyak individu tidak menyadari bahwa mereka telah kecanduan hingga mencapai tahap yang parah[8], [9], [10]. Metode pencegahan konvensional yang disediakan oleh platform perjudian, seperti batasan kerugian atau tombol darurat dinilai tidak efektif karena sangat bergantung pada kemauan pemain untuk berhenti[8], [9], [10]. Meskipun instrumen Problem Gambling Severity Index (PGSI) telah terbukti valid dan reliabel sebagai alat ukur tingkat keparahan masalah perjudian melalui laporan mandiri, penggunaannya perlu dikombinasikan dengan data objektif lain agar mampu memberikan gambaran komprehensif mengenai resiko kecanduan seseorang[10], [11], [12], [13], [14].

Pola perilaku digital pengguna, seperti frekuensi login, durasi sesi bermain, dan jumlah transaksi dapat menjadi indikator awal kecanduan yang efektif jika dianalisis menggunakan teknologi machine learning[15], [16], [17], [18]. Namun, implementasi machine learning dalam konteks ini masih terbatas. Penelitian terdahulu sering kali hanya berfokus pada data transaksi keuangan, menggunakan data yang tidak lengkap karena pemain menggunakan banyak platform atau menggunakan dataset usang yang tidak lagi relevan dengan dinamika judi online saat ini[8], [19], [20]. Selain itu, belum ada studi di Indonesia yang mengintegrasikan PGSI dengan model klasifikasi Naïve Bayes dan Decision Tree serta data perilaku pengguna untuk keperluan klasifikasi tingkat resiko[8], [13], [14].

Urgensi permasalahan tersebut mendorong perlunya pendekatan kuantitatif berbasis data yang mampu mengintegrasikan indikator perilaku dan psikososial ke dalam model klasifikasi resiko, sehingga analisis dapat dilakukan secara sistematis dan terukur menggunakan metode machine learning.

2. METODE PENELITIAN

Penelitian ini menerapkan pendekatan kuantitatif dengan desain studi klasifikasi prediktif yang bertujuan untuk membangun model klasifikasi tingkat resiko kecanduan judi online. Model dikembangkan untuk membedakan individu dengan tingkat resiko Moderate Risk dan High risk berdasarkan skor PGSI dan pola perilaku perjudian. Mengingat tidak ditemukannya responden pada kategori Non-Problem dan Low Risk, penelitian ini tidak dimaksudkan sebagai model deteksi dini pada populasi umum, melainkan sebagai pendekatan risk stratification pada sampel pengguna judi online dengan intensitas tinggi. Subjek penelitian difokuskan pada individu dewasa

yang aktif melakukan aktivitas perjudian online dalam kurun waktu 12 bulan terakhir, dengan target sampel sebanyak 150 responden yang berdomisili di Jawa Tengah. Teknik pengambilan sampel menggunakan metode purposive sampling, dimana data dikumpulkan secara daring melalui platform Google Forms selama periode bulan Juni hingga Juli 2025.

Sebelum pengisian kuesioner, seluruh partisipan diberikan informasi penelitian yang menjelaskan tujuan penelitian, jenis data yang dikumpulkan, potensi resiko serta hak partisipan. Responden diinformasikan bahwa mereka dapat menolak atau menghentikan partisipasi kapan saja tanpa konsekuensi. Persetujuan partisipan diperoleh secara eksplisit melalui pertanyaan persetujuan pada halaman awal survei sebelum responden dapat mengakses instrumen penelitian. Kuesioner disusun menggunakan bahasa yang netral dan tidak menghakimi. Penelitian ini tidak dimaksudkan sebagai alat diagnosis klinis, melainkan sebagai kajian akademik berbasis klasifikasi tingkat resiko. Pada bagian akhir survei, responden diberikan informasi umum mengenai pentingnya mencari bantuan profesional atau layanan kesehatan mental apabila mereka merasa mengalami tekanan psikologis atau dampak negatif akibat aktivitas perjudian.

Penelitian ini tidak mengumpulkan data identitas pribadi seperti nama, alamat, nomor identitas, nomor rekening, akun perjudian atau informasi lain yang dapat mengarah pada identifikasi individu secara langsung. Seluruh data bersifat anonim dan hanya direpresentasikan dalam bentuk agregat untuk keperluan analisis statistik dan pemodelan. Data hasil survei disimpan dalam format digital pada media penyimpanan terlindungi dengan akses terbatas dan hanya dapat diakses oleh peneliti. Data digunakan secara eksklusif untuk kepentingan akademik dan penelitian, serta tidak dibagikan kepada pihak ketiga di luar konteks publikasi ilmiah dan akan dihapus secara permanen setelah masa penelitian berakhir.

Penelitian ini dikategorikan sebagai penelitian dengan resiko minimal karena tidak melibatkan intervensi klinis, manipulasi perilaku, ataupun eksperimen yang dapat mempengaruhi kondisi psikologis responden secara langsung. Data dikumpulkan melalui survei daring berbasis laporan mandiri. Berdasarkan karakteristik tersebut, persetujuan etik formal dinilai tidak diwajibkan, namun seluruh prinsip etika penelitian tetap diterapkan secara ketat untuk melindungi kesejahteraan partisipan.

Instrumen pengumpulan data terdiri dari dua segmen utama, yaitu survei perilaku perjudian dan kuesioner Problem Gambling Severity Index. Variabel perilaku yang direkam mencakup frekuensi bermain, durasi rata-rata per sesi, jumlah platform yang digunakan, total nominal taruhan, frekuensi dan jumlah deposit tertinggi, estimasi kerugian bersih, serta perilaku mengejar kekalahan. Skor total dari sembilan item PGSI kemudian digunakan sebagai variabel dependen untuk mengklasifikasikan responden ke dalam empat tingkat resiko: Non-Problem, Low Risk, Moderate Risk dan High Risk.

Tabel 1. Instrumen Penelitian

Item survey	Pilihan jawaban
Perilaku perjudian	
Berapa hari aktif (berbeda) Anda bertaruh atau bermain judi dalam 30 hari terakhir?[8]	Tuliskan jumlah hari
Berapa rata-rata durasi waktu (dalam jam) yang Anda habiskan untuk berjudi dalam satu sesi?[8]	<1jam / 1-3 jam /3-6 jam / >6jam
Berapa banyak jenis permainan atau platform judi online yang berbeda yang Anda gunakan?[8]	1 jenis / 2-3 jenis / 4 jenis atau lebih
Berapa perkiraan total jumlah taruhan yang Anda pasang dalam 30 hari terakhir?[8]	Masukan total uang taruhan:
Berapa kali Anda melakukan deposit (setoran uang) ke akun judi Anda dalam 30 hari terakhir?[8]	Masukan nilai (angka):
Berapa jumlah tertinggi (dalam rupiah) yang pernah Anda depositkan dalam satu hari (24 jam)?[8]	Masukan nilai (angka):

Berapa perkiraan total kerugian bersih Anda dalam 30 hari terakhir?[8]	Masukan nilai (angka):
Dalam 30 hari terakhir, seberapa sering Anda melakukan deposit berulang dalam waktu singkat setelah mengalami kekalahan besar?[8]	Masukan nilai (angka):
Apakah jumlah taruhan Anda seringkali bervariasi secara signifikan (misalnya, tiba-tiba menaikkan jumlah taruhan setelah kalah)?[8]	Masukan nilai (angka):
PGSI	
Apakah Anda pernah bertaruh lebih dari yang benar-benar mampu Anda tanggung kerugiannya?[10]	0 Tidak pernah 1 Kadang 2 Sering 4 Selalu
Apakah Anda perlu bertaruh dengan jumlah uang yang lebih besar untuk mendapatkan sensasi kegembiraan yang sama?[10]	0 Tidak pernah 1 Kadang 2 Sering 4 Selalu
Ketika Anda berjudi, apakah Anda kembali di hari lain untuk mencoba memenangkan kembali uang yang telah hilang?[10]	0 Tidak pernah 1 Kadang 2 Sering 4 Selalu
Apakah Anda pernah meminjam uang atau menjual sesuatu untuk mendapatkan uang untuk berjudi?[10]	0 Tidak pernah 1 Kadang 2 Sering 4 Selalu
Apakah Anda merasa bahwa Anda mungkin memiliki masalah dengan perjudian?[10]	0 Tidak pernah 1 Kadang 2 Sering 4 Selalu
Apakah perjudian pernah menyebabkan masalah kesehatan, termasuk stres atau kecemasan bagi Anda?[10]	0 Tidak pernah 1 Kadang 2 Sering 4 Selalu
Apakah orang lain pernah mengkritik taruhan Anda atau memberi tahu bahwa Anda memiliki masalah perjudian, terlepas dari apakah Anda menganggap itu benar atau tidak?[10]	0 Tidak pernah 1 Kadang 2 Sering 4 Selalu
Apakah perjudian Anda menyebabkan masalah keuangan bagi Anda atau rumah tangga Anda?[10]	0 Tidak pernah 1 Kadang 2 Sering 4 Selalu
Apakah Anda merasa bersalah tentang cara Anda berjudi atau apa yang terjadi ketika Anda berjudi?[10]	0 Tidak pernah 1 Kadang 2 Sering 4 Selalu

Sebelum memasuki tahap pemodelan, data mentah melalui proses pre-processing yang ketat, termasuk pembersihan data untuk menangani nilai yang hilang atau tidak valid. Transformasi fitur dilakukan menggunakan teknik normalisasi seperti min-max scaling atau z-score untuk menyetarakan skala data numerik, sementara data kategorikal diubah menjadi format numerik menggunakan teknik label encoding. Langkah ini dilakukan agar data dapat diproses secara optimal oleh algoritma machine learning.

Proses pembangunan model klasifikasi dilakukan menggunakan pendekatan Stratified K-Fold Cross-Validation dengan jumlah lipatan (n_splits) sebesar 5, guna menjaga proporsi kelas Moderate Risk dan High Risk pada setiap lipatan data. Pendekatan ini dipilih untuk meningkatkan reliabilitas evaluasi model pada dataset berukuran terbatas. Penelitian ini mengimplementasikan dan membandingkan dua algoritma utama: Gaussian Naïve Bayes digunakan karena kesesuaiannya dengan fitur numerik kontinu yang telah melalui proses normalisasi, dengan asumsi distribusi normal pada setiap fitur. serta Decision Tree yang membangun struktur keputusan berdasarkan Gini Impurity. Gaussian Naïve Bayes diimplementasikan menggunakan parameter bawaan dari scikit-learn, termasuk nilai `var_smoothing` default untuk menjaga

stabilitas numerik, sedangkan Decision Tree diimplementasikan menggunakan Decision Tree Classifier dengan kriteria pemisahan Gini Impurity dan $\text{random_state} = 42$ untuk menjamin reproduktibilitas hasil. Seluruh parameter lainnya menggunakan konfigurasi bawaan tanpa proses hyperparameter tuning, sehingga perbandingan performa kedua algoritma mencerminkan karakteristik dasar masing-masing metode.

Kinerja model dievaluasi menggunakan berbagai metrik statistik, termasuk Accuracy, Precision, Recall, F1-Score, Confusion Matrix dan AUC-ROC. Accuracy dan AUC-ROC digunakan untuk menggambarkan performa klasifikasi secara global, sedangkan metrik Recall pada kategori Moderate Risk dan High Risk menjadi perhatian khusus dalam interpretasi hasil mengingat konteks penelitian ini menekankan identifikasi individu dengan tingkat resiko yang lebih tinggi. Feature Importance digunakan untuk melihat fitur spesifik yang memiliki kontribusi paling signifikan dalam memprediksi tingkat resiko. Untuk mengukur kontribusi fitur terhadap performa model Gaussian Naïve Bayes, digunakan permutation importance. Pendekatan ini dipilih karena algoritma Gaussian Naïve Bayes tidak memiliki mekanisme feature importance bawaan seperti pada Decision Tree. Permutation importance dihitung berdasarkan penurunan nilai accuracy pada data evaluasi, sehingga mencerminkan pengaruh relatif setiap fitur terhadap kemampuan klasifikasi model. Hasil evaluasi ini digunakan untuk menentukan algoritma mana yang paling efektif dan akurat dalam melakukan stratifikasi resiko kecanduan judi online.

3. HASIL DAN PEMBAHASAN

Hasil penelitian yang dilakukan melalui survei daring menjangkau 138 responden valid dari total 150 partisipan dengan dominasi demografi laki-laki sebanyak 102 orang dan perempuan 48 orang. Pada tahap ini, tiga responden dikeluarkan dari analisis karena memiliki data yang tidak lengkap pada variabel perilaku utama yang digunakan dalam pemodelan. Dengan demikian, jumlah data akhir yang digunakan dalam proses pelatihan dan evaluasi model adalah 135 responden. Berdasarkan pengukuran menggunakan instrumen PGSI, tidak ditemukan responden pada kategori Non-Problem dan Low Risk, yang mengindikasikan bahwa sampel penelitian merupakan individu dengan intensitas perjudian yang tinggi. Temuan ini tidak merepresentasikan fase awal atau pra-kecanduan, melainkan mencerminkan kondisi kelompok pengguna yang telah mengalami resiko masalah perjudian pada tingkat menengah hingga tinggi. Distribusi tingkat resiko terpusat pada dua kategori, Moderate Risk sebanyak 88 responden dan High Risk sebanyak 47 responden. Data ini menunjukkan mayoritas responden telah mengalami konsekuensi negatif dari perjudian atau bahkan telah mengalami gangguan fungsi sosial dan finansial yang signifikan.

Tabel 2. Jumlah Responden Klasifikasi PGSI


Klasifikasi PGSI	Jumlah Responden
Non-Problem (Skor 0)	0
Low Risk (Skor 1-2)	0
Moderate Risk (Skor 3-7)	88
High Risk (Skor >8)	47

Evaluasi kinerja model klasifikasi menggunakan metode Stratified 5-Fold Cross Validation menunjukkan bahwa algoritma Naïve Bayes mengungguli Decision Tree dalam mendeteksi kecanduan judi online. Secara keseluruhan, Naïve Bayes mencatat akurasi yang lebih tinggi, mencapai 93% dalam kesimpulan akhir, dibandingkan Decision Tree yang berada di angka 91%. Keunggulan Naïve Bayes semakin terlihat pada analisis kurva ROC, dimana model ini mencapai nilai AUC-ROC sebesar 0,9601 yang mengindikasikan kemampuan diskriminasi yang sangat baik dalam membedakan antara kategori resiko tinggi dan sedang pada berbagai ambang batas. Sebaliknya, Decision Tree mencatat nilai AUC-ROC sebesar 0,9021, yang meskipun masih

dalam kategori baik, menunjukkan keterbatasan model berbasis aturan yang cenderung lebih kaku dibandingkan pendekatan probabilistik.


Tabel 3. Klasifikasi Algoritma

Algoritma	Resiko Kecanduan	Precision	Recall	F1-Score	Support
Naïve Bayes	High Risk	0,93	0,85	0,89	47
	Moderate Risk	0,92	0,97	0,94	88
	Accuracy	0,93			135
	Macro Avg	0,93	0,91	0,92	135
	Weighted Avg	0,93	0,93	0,93	135
	AUC-ROC	0,9601			
Decision Tree	High Risk	0,87	0,87	0,87	47
	Moderate Risk	0,93	0,93	0,93	88
	Accuracy	0,91			135
	Macro Avg	0,90	0,90	0,90	135
	Weighted Avg	0,91	0,91	0,91	135
	AUC-ROC	0,9021			



Gambar 1. Perbandingan Kurva ROC: Deteksi High Risk

Analisis mendalam melalui Confusion Matrix memperlihatkan karakteristik spesifik kedua model dalam menangani kesalahan klasifikasi. Decision Tree memiliki sensitivitas (recall) sedikit lebih tinggi untuk kategori High Risk (87,2%) dibandingkan Naïve Bayes (85,1%), yang berarti Decision Tree sedikit lebih baik dalam meminimalisir False Negative. Namun, Naïve Bayes menunjukkan kinerja yang jauh lebih seimbang dengan nilai presisi yang lebih tinggi (93%) dan False Positive yang sangat rendah (hanya 3 kasus) dibandingkan Decision Tree (6 kasus). Kemampuan Naïve Bayes untuk menjaga keseimbangan antara mendeteksi risiko tinggi tanpa memberikan terlalu banyak False Positive menjadikannya model yang lebih direkomendasikan untuk sistem pemantauan risiko berbasis data yang efisien.



Gambar 2. Confusion Matrix (Naïve Bayes vs Decision Tree)

Hasil analisis kontribusi fitur menggunakan Permutation Importance menunjukkan bahwa beberapa indikator perilaku memiliki pengaruh yang lebih besar terhadap performa kalsifikasi model Gaussian Naïve Bayes. Fitur perkiraan total kerugian bersih dalam 30 hari terakhir menunjukkan penurunan kinerja terbesar ketika nilainya diacak, yang mengindikasikan perannya sebagai prediktor paling berkontribusi dalam membedakan kategori Moderate Risk dan High Risk. Selain itu, fitur total jumlah taruhan dalam 30 hari terakhir dan jumlah deposit tertinti dalam satu hari juga menunjukkan kontribusi yang relatif signifikan, yang mencerminkan peran intensitas dan skala transaksi finansial dalam stratifikasi resiko kecanduan.

Tabel 4. Feature Importance

Fitur	Naïve Bayes (Permutation Importance)	Decision Tree (Gini Impurity)
Berapa perkiraan total kerugian bersih Anda dalam 30 hari terakhir? (dalam rupiah)	0,159259	0,078608
Berapa perkiraan total jumlah taruhan yang Anda pasang dalam 30 hari terakhir? (dalam rupiah)	0,134074	0,788358
Berapa kali Anda melakukan deposit (setoran uang) ke akun judi Anda dalam 30 hari terakhir?	0,037037	0,003921
Berapa jumlah tertinggi (dalam rupiah) yang pernah Anda depositkan dalam satu hari (24 jam)?	0,034074	0,029673
Berapa aktif (berbeda) Anda bertaruh atau bermain judi dalam 30 hari terakhir? (jawab dalam angka)	0,020000	0,043452
Apakah jumlah taruhan Anda seringkali bervariasi secara signifikan (misalnya, tiba-tiba menaikkan jumlah taruhan setelah kalah)?	0,011111	0,016320
Berapa rata-rata durasi waktu (dalam jam) yang Anda habiskan untuk berjudi dalam satu sesi permainan?	0,008148	0,000000
Dalam 30 hari terakhir, seberapa sering Anda melakukan deposit berulang (misalnya, beberapa kali) dalam waktu singkat setelah mengalami kekalahan besar?	0,006667	0,028010
Berapa banyak jenis permainan atau platform judi online yang berbeda yang Anda gunakan?	0,002222	0,011657

Sebaliknya, fitur-fitur yang berkaitan dengan pola penggunaan secara umum, seperti jumlah platform judi online yang digunakan dan rata-rata durasi waktu bermain per sesi,

menunjukkan nilai permutation importance yang lebih rendah. Temuan ini mengindikasikan bahwa pada model Gaussian Naïve Bayes, variabel yang merepresentasikan konsekuensi finansial langsung lebih berpengaruh terhadap performa klasifikasi dibandingkan karakteristik penggunaan yang bersifat deskriptif. Pola kontribusi fitur yang berkaitan dengan peningkatan kerugian finansial dan intensitas transaksi menunjukkan keselarasan konseptual dengan perilaku chasing losses yang sering dibahas dalam literatur gangguan perjudian, termasuk dalam kerangka DSM-5[21]. Namun demikian, temuan ini tidak dimaksudkan sebagai identifikasi atau pemenuhan kriteria diagnostik klinis, melainkan sebagai indikasi perilaku yang secara empiris berasosiasi dengan tingkat resiko perjudian yang lebih tinggi.

Pada model Decision Tree, hasil analisis menunjukkan dominasi yang sangat kuat dari fitur total jumlah taruhan dalam 30 hari terakhir, yang memiliki nilai gini importance jauh lebih tinggi dibandingkan fitur lainnya. Pola ini menunjukkan bahwa Decision Tree cenderung membangun aturan klasifikasi berbasis ambang batas nominal transaksi, dimana besarnya total taruhan menjadi faktor pemisah utama antara kategori resiko. Fitur-fitur lain, seperti jumlah hari aktif bermain dan frekuensi deposit ulang setelah mengalami kekalahan berperan sebagai pemisah tambahan namun dengan kontribusi yang relatif lebih kecil.

Namun demikian, hasil ini tidak mengindikasikan hubungan kausal maupun proses psikologis laten, melainkan mencerminkan kontribusi relatif fitur terhadap kinerja prediktif model. Model klasifikasi yang dikembangkan dalam penelitian ini memiliki ruang lingkup terbatas pada pengguna judi online dengan tingkat keterlibatan tinggi, sebagaimana tercermin dari distribusi skor PGSI yang hanya mencakup kategori Moderate Risk dan High Risk. Tidak ditemukannya responden pada kategori Non-Problem dan Low Risk menyebabkan model tidak dilatih untuk mendeteksi fase awal atau pra-kecanduan, sehingga hasil penelitian ini tidak dapat digeneralisasikan sebagai sistem deteksi dini untuk populasi umum. Oleh karena itu, model klasifikasi ini diposisikan sebagai alat stratifikasi resiko untuk mendukung pemantauan dan intervensi terarah pada kelompok resiko tinggi.

Secara konseptual, hasil klasifikasi resiko yang dihasilkan oleh model ini berpotensi dimanfaatkan sebagai komponen pendukung dalam sistem pemantauan resiko berbasis data, misalnya untuk menghasilkan rekomendasi notifikasi atau pembatasan aktivitas secara bertahap. Namun, penerapan mekanisme tersebut memerlukan integrasi dengan sistem operasional yang bersifat real-time serta pertimbangan etika dan regulasi yang berada di luar lingkup penelitian ini. Temuan ini membuktikan bahwa kombinasi data jejak digital perilaku, khususnya kerugian dan taruhan bulanan dengan instrumen PGSI dapat menciptakan klasifikasi resiko sebagai alat pendukung untuk mengidentifikasi tingkat resiko yang lebih tinggi dan memfasilitasi intervensi yang lebih terarah, tanpa mengklaim kemampuan untuk memodelkan progresi kecanduan secara temporal.

4. KESIMPULAN

Penelitian ini menyimpulkan bahwa algoritma Gaussian Naïve Bayes menunjukkan kinerja yang lebih baik dibandingkan Decision Tree dalam mengklasifikasikan tingkat resiko kecanduan judi online pada sampel pengguna dengan tingkat keterlibatan tinggi. Berdasarkan metrik Accuracy dan AUC-ROC, Naïve Bayes lebih sesuai digunakan sebagai model stratifikasi resiko untuk membedakan kategori Moderate Risk dan High Risk sebagaimana tercermin pada nilai Recall. Mengingat keterbatasan distribusi data yang tidak mencakup kategori Non-Problem dan Low Risk, model yang dikembangkan tidak ditujukan sebagai sistem deteksi dini pada populasi umum, melainkan sebagai pendekatan pendukung dalam konteks pemantauan dan mitigasi resiko pada kelompok pengguna beresiko tinggi. Oleh karena itu, temuan penelitian ini perlu diinterpretasikan secara hati-hati dan tidak digeneralisasikan di luar lingkup sampel penelitian.

Sebagai tindak lanjut, mengingat keterbatasan penelitian yang masih mengandalkan data self-reported dan sampel terbatas di Jawa Tengah, disarankan agar penelitian mendatang memperluas cakupan demografi, menggunakan data transaksi riil dari platform, serta

membandingkan algoritma lain seperti Random Forest atau XGBoost untuk meningkatkan validitas ekologis. Bagi pembuat kebijakan dan praktisi kesehatan mental, temuan mengenai signifikansi indikator perilaku, khususnya kerugian berulang dan frekuensi bermain disarankan untuk diadopsi menjadi panduan skrining klinis. Sinergi antara pendekatan psikologis dan pemantauan digital ini diharapkan mampu menghasilkan intervensi yang lebih cepat, terarah dan efektif dalam menekan dampak negatif perjudian online di masyarakat.

DAFTAR PUSTAKA

- [1] G. A. Saragih, “Stop Judi Online: Bekerja Dengan Jujur dan Tekun Berdasarkan Amsal 13:11,” *Vox Divina: Jurnal Teologi dan Pendidikan Kristen*, vol. 2, pp. 1–17, 2024.
- [2] PPATK, “Laporan Semester Tahun 2024 PPATK,” Jakarta, 2024.
- [3] M. W. Griffiths, “Sociodemographic correlates of internet gambling: Findings from the 2007 British Gambling Prevalance Survey,” *CyberPsychology & Behavior*, vol. 12, no. 2, pp. 199–202, 2009.
- [4] N. F. Juhara, N. Amalia, and A. Mulyana, “Efektifitas Penegakan Hukum Terhadap Judi Online di Indonesia: Analisis Yuridis dan Sosiologis,” *Journal of Contemporary Law Studies*, vol. 2, pp. 153–164, 2025.
- [5] D. F. Hidayah, “Menelaah Fenomena Judi Online (Slot) di Kalangan Mahasiswa Dalam Perspektif Hukum Islam di Indonesia,” *Tashdiq: Jurnal Kajian Agama dan Dakwah*, vol. 2, no. 3, pp. 1–18, 2024.
- [6] D. Sahputra, A. Afifa, A. M. Salwa, N. Yudhistira, and L. A. Lingga, “Dampak Judi Online Terhadap Kalangan Remaja (Studi Kasus Tebing Tinggi),” *Islamic Counseling: Jurnal Bimbingan dan Konseling Islam*, vol. 6, pp. 139–156, 2022.
- [7] A. Laras, N. Salvabillah, C. Caroline, F. Dinda, and M. Finanto, “Analisis Dampak Judi Online di Indonesia,” *Concept: Journal of Social Humanities and Education*, vol. 3, no. 2, pp. 320–331, 2024.
- [8] N. Tsykunov, “Early Detection of Online Gambling Addiction,” 2020.
- [9] J. W. Ferris, “The Canadian Problem Gambling Index: Final Report,” *Canadian Centre on Substance Abuse*, 2001.
- [10] J. Ferris and H. Wynne, “The Canadian Problem Gambling Index: Final Report,” *Canadian Centre on Substance Abuse*, 2001.
- [11] L. Hitcham, R. Tunney, J. E. Tillsley, H. Kim, and R. J. E. James, “A comprehensive test of measurement invariance in problem gambling assessments,” Jul. 2023.
- [12] M. R. Auer, “Development of the Online Problem Gaming Behavior Index: A New Scale Based on Actual Problem Gambling Behavior Rather Than The Consequences of it,” *Eval. Health Prof.*, vol. 47, pp. 81–92, 2024.
- [13] N. Hopfgartner, M. Auer, D. Helic, and M. D. Griffiths, “Using Artificial Intelligence Algorithms to Predict Self-Reported Problem Gambling Among Online Casino Gamblers from Different Countries Using Account-Based Player Data,” *Int. J. Ment. Health Addict.*, 2024.
- [14] W. S. Murch, S. Kairouz, and M. French, “Establishing the temporal stability of machine learning models that detect online gambling-related harms,” *Computers in Human Behavior Reports*, vol. 14, 2024.
- [15] I. Rossow, M. B. Hansen, and E. E. Storvoll, “Changes in youth gambling after the removal of slot machines in Norway,” *Nordic Studies on Alcohol and Drugs*, vol. 30, no. 4, pp. 317–330, 2013.
- [16] H. Hagfors, S. Castren, and A. H. Salonen, “How gambling motives are associated with socio-demographics and gambling behavior: A Finnish population study,” *J. Behav. Addict.*, vol. 11, no. 1, pp. 63–74, 2022.

- [17] N. Greer, N. Hing, M. Rockloff, M. Browne, and D. L. King, “Motiations for Esports Betting and Skin Gambling and Their Association with Gambling Frequency, Problems and Harm,” *J. Gambl. Stud.*, vol. 39, no. 1, pp. 339–362, 2022.
- [18] B. Lelonek-Kuleta, R. P. Bartczuk, M. Wiechetek, J. Chwaszcz, and I. Niewiadomska, “The prevalence of e-gambling and problem e-gambling in Poland,” *Int. J. Environ. Res. Public Health*, vol. 17, no. 2, 2020.
- [19] K. Škařupová, T. Vlach, and V. Mravčík, “Early intervention and identification of gambling disorder: a systematic literature review of strategies implemented by gambling operators,” *Cent. Eur. J. Public Health*, vol. 28, no. 1, pp. 18–23, Mar. 2020, doi: 10.21101/cejph.a5849.
- [20] S. Andersson, K. Lyon, M. Bermell, and P. Lindner, “Insights into the temporal dynamics of identifying problem gambling on an online casino: A machine learning study on routinely collected individual account data,” *J. Behav. Addict.*, vol. 14, no. 1, pp. 490–500, 2025.
- [21] S. Jiménez-Murcia *et al.*, “Video Game Addiction in Gambling Disorder: Clinical, Psychopathological, and Personality Correlates,” *Biomed Res. Int.*, vol. 2014, pp. 1–11, 2014, doi: 10.1155/2014/315062.