

Klasifikasi Tingkat Kecanduan Media Sosial dengan Menggunakan Algoritma Random Forest

Wahyu Setyanto¹, David Yoga Wicaksono²

^{1,2}Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri

E-mail: *¹wahyusetyanto60@gmail.com, ²davidyogawicaksono@gmail.com

Abstrak – Penelitian ini membahas Klasifikasi Tingkat Kecanduan Media Sosial dengan Menggunakan Algoritma Random Forest. Topik ini penting karena penggunaan media sosial yang berlebihan dapat memengaruhi konsentrasi, kesehatan mental, kualitas tidur, dan performa akademik. Data penelitian diambil dari dataset publik yang memuat variabel perilaku seperti durasi penggunaan harian, frekuensi akses, distraksi, kecemasan, perubahan mood, dan dampak akademik. Setelah melalui tahap pra-pemrosesan, termasuk pemilihan fitur, pembersihan data, dan pembagian data, model Random Forest dilatih untuk mengklasifikasikan tiga kategori kecanduan, yaitu rendah, sedang, dan tinggi. Evaluasi dilakukan menggunakan akurasi, precision, recall, F1-score, dan confusion matrix. Model mencapai akurasi 87,94% dengan performa sangat baik pada kelas rendah dan tinggi, sedangkan kelas sedang masih menunjukkan tumpang tindih perilaku. Hasil penelitian menunjukkan bahwa Random Forest mampu mengenali pola kecanduan digital dengan cukup stabil, dan sistem yang dikembangkan menghasilkan rekomendasi otomatis sesuai tingkat kecanduan sehingga dapat membantu mahasiswa memahami kondisi mereka dan mengambil langkah mitigasi. Temuan ini menegaskan bahwa pendekatan machine learning dapat diterapkan secara efektif untuk mendeteksi dan memetakan kecanduan media sosial.

Kata Kunci — klasifikasi, mahasiswa, media sosial, random forest

1. PENDAHULUAN

Perkembangan teknologi digital telah mengubah cara mahasiswa berinteraksi, belajar, dan memproses informasi dalam kehidupan sehari-hari [1]. Intensitas penggunaan media sosial yang meningkat mendorong perubahan pola perilaku yang berpotensi memengaruhi konsentrasi, kestabilan emosi, serta performa akademik pengguna [2]. Dalam berbagai penelitian, penggunaan media sosial yang berlebihan juga dikaitkan dengan gangguan tidur, meningkatnya distraksi, dan penurunan kemampuan fokus selama proses belajar [3].

Mekanisme platform media sosial turut memperkuat kecenderungan tersebut karena dirancang untuk mempertahankan perhatian pengguna melalui notifikasi, rekomendasi konten, dan umpan tanpa batas, sebagaimana dijelaskan dalam penelitian yang dipublikasikan pada *Generation Journal* terkait perilaku penggunaan media sosial mahasiswa [4]. Paparan konten berlebih dalam jangka panjang dapat memicu *information overload* yang berujung pada kelelahan digital dan menurunnya kontrol diri [2]. Hal ini semakin relevan pada mahasiswa yang sering mengakses media sosial untuk kebutuhan akademik maupun hiburan, sehingga durasi penggunaan yang tinggi berpotensi mendorong perilaku adiktif [1].

Aspek psikologis memiliki peran penting dalam pembentukan perilaku adiksi digital. Studi menunjukkan bahwa interaksi dan pengamatan sosial di platform digital dapat memicu respon emosional negatif seperti kecemasan, kecemburuan, dan distress emosional, terutama ketika pengguna terekspos pada konten *interpersonal* yang sensitif [5], [6]. Paparan berulang terhadap stimulus tersebut, apabila dikombinasikan dengan frekuensi penggunaan yang tinggi dan keterlibatan yang bersifat soliter, dapat membentuk pola penggunaan bermasalah yang menyerupai karakteristik adiksi perilaku, sebagaimana ditunjukkan oleh penelitian yang menekankan peran frekuensi, durasi, serta konteks sosial dalam meningkatkan risiko ketergantungan dan kesulitan mengendalikan penggunaan [7].

Selain pengaruh emosional, kompetensi sosial dan emosional individu juga berkontribusi pada bagaimana seseorang memproses paparan digital. Penelitian mengenai kompetensi sosial-emosional menyebutkan bahwa kemampuan mengatur emosi, empati, dan pengendalian impuls menentukan tingkat kerentanan seseorang terhadap perilaku adiktif berbasis teknologi [8]. Rendahnya regulasi diri dapat membuat pengguna lebih mudah terjebak dalam penggunaan berlebihan yang tidak disadari [3].

Perilaku digital juga dapat dipengaruhi oleh sinyal sosial yang ditampilkan melalui profil media sosial. Studi eksperimental menunjukkan bahwa konten yang menggambarkan gaya hidup, minat, atau aktivitas sosial tertentu

dapat membentuk persepsi orang lain mengenai status sosial atau karakter individu, meskipun tidak berkaitan dengan konteks profesional [6]. Hal ini mencerminkan bahwa media sosial bukan hanya tempat interaksi, tetapi juga arena pembentukan persepsi yang dapat memengaruhi perilaku dan emosi pengguna [9].

Dengan kompleksitas fenomena perilaku digital tersebut, pendekatan komputasional mulai digunakan untuk mengidentifikasi pola adiksi secara objektif. Algoritma *Random Forest* terbukti mampu menangani data perilaku multidimensi dengan stabil dan akurat, baik dalam konteks klasifikasi dokumen, prediksi berbasis sensor sosial, maupun analisis perilaku pengguna [10], [11]. Keunggulan algoritma ini dalam mengolah data media sosial yang berskala besar, heterogen, dan sarat muatan emosional menjadikannya relevan untuk memetakan tingkat kecanduan media sosial secara komputasional, sebagaimana ditunjukkan oleh penelitian yang memanfaatkan analisis sentimen dan pengelompokan konten sosial untuk mengidentifikasi pola masalah perilaku dan emosional pengguna [12].

Selain itu, beberapa penelitian menunjukkan bahwa pola perilaku adiktif cenderung memiliki batas antar-kelas yang tidak tegas sehingga menghasilkan tumpang tindih perilaku, khususnya antara kategori sedang dan tinggi [13]. Kondisi ini menuntut penggunaan metode klasifikasi yang robust agar dapat mengenali pola halus dan fluktuatif pada perilaku mahasiswa [14].

Berdasarkan latar belakang tersebut, penelitian ini bertujuan mengklasifikasikan tingkat kecanduan media sosial pada mahasiswa menggunakan algoritma *Random Forest* serta menghasilkan rekomendasi penanganan sesuai tingkat kecanduan. Pendekatan ini diharapkan dapat memberikan gambaran komprehensif mengenai pola adiksi digital dan mendukung upaya mitigasi penggunaan media sosial secara lebih sehat [15].


2. METODE PENELITIAN

Metode penelitian ini dirancang untuk mengidentifikasi tingkat kecanduan media sosial pada mahasiswa menggunakan algoritma *Random Forest* sebagai metode klasifikasi utama [10]. Pendekatan ini dipilih karena *Random Forest* memiliki stabilitas tinggi pada data multidimensi serta mampu mengurangi risiko *overfitting*, terutama saat data bersifat kompleks dan menunjukkan pola perilaku yang bervariasi [11]. Tahapan penelitian meliputi pengumpulan data, pra-pemrosesan, pelatihan model, implementasi sistem, serta evaluasi, sehingga seluruh proses analisis berlangsung secara sistematis [4]. Penggunaan metode *machine learning* dalam konteks perilaku digital juga telah terbukti efektif dalam memetakan kecenderungan adiktif dan pola penggunaan media sosial yang berulang [1].

Alur metode penelitian disajikan pada Gambar 1, yang menunjukkan proses dari data mentah hingga hasil evaluasi model. Struktur alur tersebut mengikuti pola umum penelitian klasifikasi, khususnya pada studi yang melibatkan penanganan unbalanced dataset, representasi fitur perilaku, dan analisis faktor psikososial [4], [13]. Model alur seperti ini lazim digunakan dalam penelitian berbasis *machine learning* karena memberikan konsistensi dalam pemisahan tahapan pra-pemrosesan, pelatihan, dan evaluasi [2]. Keteraturan proses juga dibutuhkan agar hasil klasifikasi dapat direplikasi dan memiliki validitas yang kuat pada konteks perilaku digital [15].

2.1 Alur Penelitian

Alur penelitian terdiri dari lima tahapan utama, yaitu: (1) pengumpulan data, (2) pra-pemrosesan, (3) pelatihan model, (4) prediksi, dan (5) evaluasi. Struktur tahapan ini mengikuti praktik umum penelitian *machine learning* yang digunakan dalam analisis perilaku digital dan klasifikasi variabel psikologis [14]. Beberapa studi juga menegaskan bahwa pemodelan perilaku adiktif membutuhkan alur yang jelas untuk memastikan pola data dapat direpresentasikan dengan benar sebelum dilatih oleh model [13].



Gambar 1. Alur Penelitian

Tahapan alur yang terstruktur sebagaimana ditunjukkan pada Gambar 1 diperlukan agar model mampu mempelajari pola perilaku secara konsisten, dimulai dari pengolahan data mentah hingga menghasilkan keluaran berupa kategori tingkat kecanduan [4]. Pendekatan ini juga digunakan dalam penelitian mengenai dukungan psikososial dan respon emosional terhadap konten digital, karena perilaku manusia sering kali menampilkan pola yang tidak stabil dan perlu diolah secara hati-hati [3].

2.2 Pengumpulan Data

Data penelitian bersumber dari *dataset* publik “Students Social Media Addiction Dataset” yang tersedia di platform *Kaggle*. Struktur dan contoh isi dataset tersebut ditunjukkan pada Gambar 2, yang memuat berbagai variabel perilaku mahasiswa seperti durasi penggunaan harian media sosial, frekuensi akses, tingkat distraksi, kecemasan, perubahan suasana hati, kualitas tidur, serta performa akademik [13]. Penggunaan *dataset* publik lazim dilakukan dalam penelitian klasifikasi karena memberikan data yang terstruktur dan memiliki variasi perilaku yang relevan untuk analisis [11]. Selain itu, variabel-variabel dalam dataset ini memiliki keterkaitan langsung dengan aspek psikologis dan emosional yang telah dibahas pada berbagai studi mengenai distress digital dan respon sosial pengguna [5].

Dataset kemudian disintesis untuk meningkatkan jumlah sampel dan memperbaiki ketidakseimbangan kelas. Teknik sintesis berbasis pola statistik digunakan agar distribusi data tetap mencerminkan kondisi sebenarnya tanpa menghilangkan karakteristik perilaku pengguna [4]. Pendekatan ini sejalan dengan penelitian yang menekankan pentingnya distribusi yang seimbang dalam klasifikasi perilaku manusia, terutama ketika kategori tidak memiliki batas tegas [13]. Selain itu, penggunaan sintesis data diperkuat oleh temuan empiris yang menunjukkan bahwa karakteristik perilaku berisiko cenderung saling tumpang tindih antar kelompok, dipengaruhi oleh faktor frekuensi, durasi, serta konteks penggunaan, sehingga augmentasi data diperlukan untuk membantu model mempelajari pola kompleks dan meningkatkan kemampuan generalisasi [7].

A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
Student_ID	Age	Gender	Academic	Country	Avg_Daily_Most_Use	Affects_Ac	Sleep_Hou	Mental_Hc	Relationsh	Conflicts	Addicted_Level	Mental_Hc	Adjusted_Level	Addiction_Level	
1	19	Female	Undergrad	Bangladesh	5,2	Instagram	Yes	6,5	6	In Relatior	3	8	normal	8	2
2	22	Male	Graduate	India	2,1	Twitter	No	7,5	8	Single	0	3	happy	2	0
3	20	Female	Undergrad	USA	6	TikTok	Yes	5	5	Complicat	4	9	normal	9	2
4	18	Male	High Schoc	UK	3	YouTube	No	7	7	Single	1	4	normal	4	1
5	21	Male	Graduate	Canada	4,5	Facebook	Yes	6	6	In Relatior	2	7	normal	7	2

Gambar 2. Dataset

Dari *dataset* pada gambar 2 ini dipilih beberapa fitur utama, sedangkan variabel target adalah *Addiction_Level*, yaitu tingkat kecanduan media sosial mahasiswa.

2.3 Pra-pemrosesan

Pra-pemrosesan bertujuan memastikan kualitas data sebelum digunakan dalam pelatihan model. Tahap ini mengikuti standar pemrosesan data pada penelitian *machine learning* yang mencakup seleksi fitur, pembersihan data, dan pembagian dataset [2]. Proses ini juga mempertimbangkan teori psikososial yang menunjukkan bahwa variabel emosional dan sosial dapat berinteraksi secara kompleks sehingga perlu disiapkan dengan baik sebelum dianalisis [8].

2.3.1 Pemilihan Fitur (Feature Selection)

Fitur yang digunakan meliputi variabel perilaku dan psikologis seperti *Hours_Per_Day*, *Usage_Frequency*, *Night_Usage*, *Concentration_Impact*, *Anxiety_Level*, *Mood_Changes*, *Sleep_Disruption*, dan *Academic_Performance*. Pemilihan fitur dilakukan untuk mengurangi *noise* dan meningkatkan performa klasifikasi [14]. Selain itu, fitur-fitur ini berkaitan erat dengan aspek emosional dan sosial yang telah terbukti memengaruhi perilaku adiktif pada berbagai studi psikologi digital [5], [6].

2.3.2 Pembersihan Data

Pembersihan data dilakukan untuk memastikan tidak terdapat *missing values*, duplikasi, maupun nilai ekstrem yang berpotensi mengganggu performa model. Tahapan ini merupakan prosedur fundamental dalam analisis data perilaku digital, khususnya ketika data bersumber dari media sosial yang bersifat tidak terstruktur, bervolume besar, dan mengandung *noise* tinggi, sehingga kesalahan input dapat berdampak langsung pada validitas hasil analisis [12]. Praktik ini juga lazim digunakan dalam penelitian terkait persepsi sosial dan analisis psikososial yang mengandalkan akurasi variabel perilaku [9].

2.3.3 Pembagian Data (Train–Test Split)

Dataset dibagi menjadi 80% data latih dan 20% data uji. Teknik *train–test split* digunakan untuk menguji kemampuan model pada data yang belum pernah dilihat sebelumnya sehingga hasil evaluasi lebih objektif [10]. Pembagian ini juga mengikuti struktur penelitian klasifikasi lain yang menekankan pentingnya pemisahan data untuk menghindari data *leakage* dan menjaga reliabilitas model [11].

2.4 Latih Model

Model *Random Forest* dilatih menggunakan parameter dasar dengan membangun banyak pohon keputusan yang kemudian digabungkan melalui mekanisme voting mayoritas. Metode *ensemble* ini efektif dalam mengurangi *overfitting* serta memberikan kestabilan pada data yang memiliki variasi perilaku yang besar [10]. *Random Forest* telah digunakan secara luas dalam penelitian berbasis sensor sosial, analisis dokumen, dan klasifikasi perilaku sehingga relevan untuk konteks kecanduan media sosial [11], [12]. Selain itu, penelitian mengenai sinyal sosial digital menunjukkan bahwa perilaku manusia sering kali tidak linier sehingga model berbasis *ensemble* lebih adaptif dalam mengenali pola yang kompleks [6].

Random Forest tersusun dari kumpulan pohon keputusan. Prediksi kelas akhir diperoleh melalui voting mayoritas, dengan rumus:

$$\hat{y} = \text{mode}(h_1(x), h_2(x), \dots, h_T(x)) \dots\dots\dots(1)$$

dengan:

$h_t(x)$ = prediksi pohon ke- t

T = jumlah pohon dalam hutan

$\hat{y}$ = hasil prediksi akhir

Setiap pohon dibangun dari subset data melalui *bootstrap sampling*, yaitu pengambilan contoh secara acak dengan pengembalian:

$$D_t = \text{Bootstrap}(D) \dots\dots\dots(2)$$

Model memilih fitur terbaik berdasarkan nilai *Gini Impurity*, dengan rumus:

$$\text{Gini} = 1 - \sum_{i=1}^K p_i^2 \dots\dots\dots(3)$$

di mana:

p_i = proporsi kelas ke- i pada node

K = jumlah kelas

Rumus (1)–(3) merupakan formulasi yang umum digunakan untuk menjelaskan mekanisme *Random Forest* [7], [13].

2.5 Hasil

Tahap ini menghasilkan keluaran berupa prediksi tingkat kecanduan media sosial pada setiap sampel data uji, sebagaimana ditunjukkan pada Gambar 3, yang memperlihatkan perbandingan antara label aktual (y_{true}) dan hasil prediksi model (y_{pred}) berdasarkan sejumlah fitur perilaku digital yang dianalisis..

	A	B	C	D	E	F	G
1	platform	daily_us...	sleep_ho...	Affects_Academic_Performance	mental_health_mapp...	y_true	y_pred
2	TikTok	5.5	5.4	1	1	2	2
3	TikTok	3.7	8.3	0	0	0	0
4	Instagr...	5.7	6.7	1	1	2	2
5	Instagr...	4.7	7.5	1	1	1	2
6	TikTok	5.4	5.7	1	1	2	2
7	Whats...	7.3	5.5	1	1	2	2

Gambar 3. Hasil Prediksi

2.6 Evaluasi

Evaluasi model dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*. Metrik-metrik ini digunakan dalam penelitian perilaku digital untuk melihat seberapa baik model mengenali setiap kategori kelas [4]. Studi pemodelan adiktif menunjukkan bahwa kelas sedang sering kali menampilkan tumpang tindih perilaku sehingga memerlukan analisis metrik yang menyeluruh untuk mengidentifikasi kesalahan model [13]. Penggunaan *confusion matrix* juga direkomendasikan dalam penelitian psikososial dan analisis respon emosional karena memberikan gambaran mengenai pola kesalahan antar kelas [3], [5].

2.6.1 Rumus Evaluasi

a. Accuracy

Mengukur proporsi prediksi yang benar terhadap seluruh data uji:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots(4)$$

b. Precision

Mengukur ketepatan model dalam memprediksi kelas tertentu:

$$Precision = \frac{TP}{TP+FP} \dots\dots\dots(5)$$

c. Recall

Mengukur kemampuan model menemukan seluruh data relevan pada suatu kelas:

$$Recall = \frac{TP}{TP+FN} \dots\dots\dots(6)$$

d. F1-Score

Merupakan rata-rata harmonik antara precision dan recall:

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \dots\dots\dots(7)$$

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil penelitian yang diperoleh dari proses pemodelan menggunakan algoritma *Random Forest* sebagaimana dijelaskan pada bagian metode penelitian sebelumnya. Evaluasi model ditampilkan dalam bentuk nilai *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix* sebagai gambaran kemampuan model dalam mengklasifikasikan tingkat kecanduan media sosial mahasiswa [4], [13].

Pembahasan dilakukan dengan menginterpretasikan hasil tersebut secara teoritik, baik secara kuantitatif maupun kualitatif, serta mengaitkannya dengan karakteristik perilaku pengguna yang sering menunjukkan pola tidak stabil akibat faktor emosional dan sosial [3], [5]. Interpretasi ini juga mempertimbangkan temuan pada literatur mengenai respon psikologis terhadap paparan digital dan fenomena tumpang tindih antar kategori perilaku adiktif [1], [6], [8].

Diagram, tabel, dan visualisasi lainnya disertakan untuk memperjelas performa model dan pola kesalahan klasifikasi. Penyajian visual ini diperlukan agar kekuatan dan keterbatasan model dapat terlihat dengan jelas sesuai standar penelitian berbasis *machine learning* [10], [11].

3.1 Hasil

Pada tahap ini disajikan hasil evaluasi model *Random Forest* menggunakan data uji sebanyak 141 sampel. Evaluasi mencakup akurasi, *classification report*, serta *confusion matrix* untuk melihat performa model dalam mengklasifikasikan tingkat kecanduan media sosial mahasiswa.

3.2.1 Akurasi Model

Model *Random Forest* mencapai nilai akurasi sebesar 87.94%

3.2.2 Confusion Matrix

Tabel 1 Confusion Matrix			
	Pred 0	Pred 1	Pred 2
Actual 0	19	0	0
Actual 1	3	31	6
Actual 2	0	8	74

Temuan ini secara keseluruhan sejalan dengan sifat data perilaku manusia yang sering tidak memiliki batas yang tegas, serta cenderung membentuk kontinum perilaku daripada kategori yang sepenuhnya terpisah.

3.2.3 Classification Report

Tabel 2 Classification Report			
Kelas	Precision	Recall	F1-score
0 (rendah)	0.864	1.000	0.927
1 (sedang)	0.795	0.775	0.785
2 (tinggi)	0.925	0.902	0.914

Hasil ini menunjukkan bahwa distribusi data dan pemilihan fitur berpengaruh terhadap performa tiap kelas. Kelas sedang yang tidak sejelas kelas rendah atau tinggi menyebabkan beberapa kesalahan klasifikasi.

3.2 Pembahasan

Pembahasan pada bagian ini bertujuan untuk menginterpretasikan hasil evaluasi model secara menyeluruh, baik dari sudut pandang performa kuantitatif maupun relevansi teoritis. Analisis dilakukan dengan membandingkan nilai *accuracy*, *precision*, *recall*, dan *F1-score* antar kelas, serta meninjau pola klasifikasi yang ditunjukkan oleh *confusion matrix*. Selain itu, pembahasan ini mengaitkan temuan penelitian dengan karakteristik perilaku penggunaan media sosial mahasiswa, serta dengan hasil penelitian terdahulu yang menggunakan pendekatan serupa. Dengan demikian, bagian ini memberikan pemahaman mendalam mengenai efektivitas model *Random Forest* dalam mengidentifikasi tingkat kecanduan media sosial dan faktor-faktor yang memengaruhi performanya.

3.2.1 Analisis Akurasi

Nilai akurasi 87.94% menunjukkan bahwa *Random Forest* dapat mempelajari pola perilaku pengguna media sosial dengan cukup baik. Hasil ini konsisten dengan karakter *Random Forest* yang kuat terhadap *overfitting* dan efektif untuk data tabular [4]. Nilai akurasi juga sejalan dengan penelitian terdahulu mengenai penggunaan *Random Forest* untuk klasifikasi perilaku digital [2].

3.2.2 Analisis Confusion Matrix

Berdasarkan *confusion matrix* yang bisa dilihat dalam Tabel 1:

a. Kelas 0 → 19 benar (100%)

Model tidak pernah salah dalam memprediksi kategori rendah.

b. Kelas 1 → sebagian salah ke kelas 2 (6 sampel) dan ke kelas 0 (3 sampel)

Ini menunjukkan adanya kemiripan pola perilaku antara pengguna kelas sedang dan kelas lain.

c. Kelas 2 → 74 benar, 8 salah sebagai kelas 1

Kesalahan ini wajar karena perilaku kelas tinggi dapat overlap dengan kelas sedang, terutama pada variabel kecemasan dan mood.

Temuan ini sejalan dengan sifat data perilaku manusia yang sering tidak memiliki batas yang tegas [1].

3.2.3 Analisis Classification Report

Berdasarkan Tabel 3 bisa kita lakukan analisis untuk classification report

Tabel 3 Analisis Classification Report	
Kelas	Analisis
0 (rendah)	Model sangat baik dalam mengenali kategori rendah. Tidak ada sampel kelas rendah yang salah prediksi.
1 (sedang)	Kategori yang paling menantang karena perilaku kelas sedang sering tumpang tindih dengan kelas rendah dan tinggi.
2 (tinggi)	Model mengenali kategori tinggi dengan sangat baik karena ciri perilaku yang lebih jelas dan konsisten.

Hasil ini menunjukkan bahwa distribusi data dan pemilihan fitur berpengaruh terhadap performa tiap kelas. Kelas sedang yang tidak sejelas kelas rendah atau tinggi menyebabkan beberapa kesalahan klasifikasi.

3.2.4 Analisis Feature Importance

Model *Random Forest* juga menghasilkan nilai *feature importance* yang menunjukkan kontribusi relatif setiap variabel dalam proses klasifikasi. Hasil analisis menunjukkan bahwa variabel terkait intensitas penggunaan, seperti *Hours_Per_Day* dan *Usage_Frequency*, memiliki pengaruh terbesar dalam membedakan kategori kecanduan. Temuan ini sejalan dengan penelitian terdahulu yang menegaskan bahwa durasi penggunaan merupakan prediktor kuat terhadap tingkat ketergantungan digital pada mahasiswa.

Variabel lain seperti *Anxiety_Level*, *Mood_Changes*, dan *Sleep_Disruption* juga memiliki kontribusi signifikan, yang mengindikasikan bahwa faktor emosional dan kesehatan fisik memainkan peran penting dalam pembentukan perilaku adiktif. Kontribusi yang cukup tinggi pada fitur-fitur psikologis menguatkan argumen bahwa kecanduan media sosial bukan hanya fenomena perilaku, tetapi melibatkan dinamika emosional yang kompleks. Hal ini menjelaskan mengapa kategori sedang cenderung tumpang tindih dengan kategori lain, karena variabel emosional sering kali *fluktuatif* dan tidak memiliki batas yang tegas. Analisis *feature importance* ini memberikan dasar teoritis dan empiris untuk memahami pola kecanduan media sosial secara lebih menyeluruh.

3.2.5 Contoh Pengujian Model

Untuk memberikan gambaran yang lebih konkret mengenai performa model *Random Forest*, dilakukan analisis berbasis contoh pada beberapa sampel data uji. Contoh ini menunjukkan bagaimana model memproses fitur-fitur perilaku pengguna, seperti durasi penggunaan harian, kualitas tidur, dampak terhadap performa akademik, dan kondisi kesehatan mental, hingga menghasilkan prediksi tingkat kecanduan media sosial. Sebagian cuplikan hasil pengujian model pada data uji ditampilkan pada Gambar 4, yang memperlihatkan perbandingan antara label aktual (y_{true}) dan hasil prediksi model (y_{pred}) pada setiap sampel.

	A	B	C	D	E	F	G
1	platform	daily_us...	sleep_ho...	Affects_Academic_Performance	mental_health_mapp...	y_true	y_pred
2	TikTok	5.5	5.4	1	1	2	2
3	TikTok	3.7	8.3	0	0	0	0
4	Instagr...	5.7	6.7	1	1	2	2
5	Instagr...	4.7	7.5	1	1	1	2
6	TikTok	5.4	5.7	1	1	2	2

Gambar 4. Hasil Pengujian Model

3.2.6 Analisis Contoh Kasus

Analisis ini dilakukan untuk mengamati bagaimana model *Random Forest* memprediksi tingkat kecanduan pada beberapa sampel data uji. Tabel 4 menampilkan contoh kasus nyata beserta analisis kesesuaian prediksi dengan kondisi sebenarnya. Melalui pendekatan ini, dapat diamati bagaimana model merespon variasi perilaku pengguna terhadap media sosial.

Tabel 4 Analisis Kasus

No	y true	y pred	Analisis
1	2	2	Prediksi benar. Pola penggunaan berat dan adanya dua faktor gangguan konsisten dengan ciri kecanduan tinggi. Model mengenali pola kelas 2 dengan baik.
2	0	0	Prediksi benar. Perilaku penggunaan sehat tanpa indikasi gangguan sesuai dengan kategori kecanduan rendah. Model menunjukkan sensitivitas baik terhadap ciri kelas 0.
3	2	2	Prediksi benar. Aktivitas intensif dan adanya dua indikator gangguan mengarah pada kecanduan tinggi. Model mendeteksi pola kategori 2 secara konsisten.
4	1	2	Prediksi salah. Model menaikkan kategori ke kelas tinggi karena dua faktor gangguan cukup dominan. Hal ini menunjukkan kelas 1 memiliki karakteristik tumpang tindih dengan kelas 2.
5	2	2	Prediksi benar. Fitur intensitas tinggi dan dua gangguan dominan membuat model yakin terhadap kategori tinggi. Perilaku sangat representatif untuk kelas 2.

Berdasarkan Tabel 4, terlihat bahwa model mampu mengenali pola kecanduan tinggi dan rendah dengan baik, namun masih mengalami kesulitan pada kategori sedang (kelas 1). Hal ini konsisten dengan hasil *confusion matrix* yang menunjukkan beberapa kesalahan klasifikasi silang pada kelas tersebut.

3.2.7 Analisis Prediksi Individual

Analisis prediksi individual dilakukan untuk memahami bagaimana model *Random Forest* mengambil keputusan berdasarkan kombinasi fitur pada setiap sampel data uji. Pendekatan ini memberikan gambaran lebih rinci mengenai perilaku model ketika berhadapan dengan variasi karakteristik pengguna, terutama pada kategori sedang yang menunjukkan pola perilaku tumpang tindih dengan kategori rendah dan tinggi. Beberapa contoh prediksi yang ditampilkan pada Tabel 4 memperlihatkan bahwa model mampu mengenali pola kecanduan tinggi dengan konsisten, terutama ketika durasi penggunaan harian dan indikator emosional menunjukkan nilai yang menonjol.

Pada sampel dengan tingkat kecanduan rendah, model menghasilkan prediksi yang akurat karena ciri-ciri perilaku yang stabil dan minim gangguan psikologis. Hal ini memperlihatkan bahwa fitur seperti *Hours_Per_Day* dan *Usage_Frequency* menjadi pembeda utama antara kategori rendah dan kategori lainnya. Sementara itu, kesalahan prediksi lebih sering terjadi pada kategori sedang, yang kerap menunjukkan distribusi nilai fitur yang tidak ekstrem. Kondisi ini menunjukkan bahwa pola perilaku kategori sedang berada pada wilayah transisi sehingga sulit dibedakan secara tegas oleh model.

Temuan dari analisis individual ini menguatkan hasil evaluasi sebelumnya bahwa kelas sedang merupakan tantangan utama dalam klasifikasi tingkat kecanduan. Selain itu, analisis ini memberikan pemahaman empiris bahwa interaksi antara fitur perilaku dan emosional memainkan peran penting dalam menghasilkan prediksi, sehingga perlu dipertimbangkan dalam pengembangan model lanjutan. Dengan demikian, analisis prediksi individual tidak hanya melengkapi evaluasi statistik, tetapi juga memberikan gambaran lebih komprehensif mengenai karakteristik data dan cara model merespon variasi perilaku pengguna.

4. SIMPULAN

Berdasarkan hasil penelitian dan analisis yang telah dilakukan, dapat disimpulkan beberapa hal sebagai berikut:

- 1) Model *Random Forest* mampu mengklasifikasikan tingkat kecanduan media sosial mahasiswa dengan performa yang baik. Model menghasilkan akurasi 87,94% dan menunjukkan kemampuan yang stabil dalam membedakan kategori rendah dan tinggi. Hal ini menegaskan bahwa *Random Forest* efektif digunakan untuk memetakan pola perilaku digital berdasarkan variabel perilaku, psikologis, dan akademik yang digunakan dalam penelitian.
- 2) Kelas sedang menunjukkan pola yang tumpang tindih sehingga menjadi kategori yang paling sulit diklasifikasikan. Kesalahan prediksi yang lebih tinggi pada kelas ini mengindikasikan bahwa perilaku pengguna dengan tingkat kecanduan sedang memiliki karakteristik yang *fluktuatif* dan tidak memiliki batas tegas, sehingga memengaruhi sensitivitas model dalam proses klasifikasi.
- 3) Variabel perilaku seperti durasi penggunaan, frekuensi akses, distraksi, kecemasan, perubahan mood, dan kualitas tidur berkontribusi signifikan terhadap pembentukan pola kecanduan digital. Temuan ini menunjukkan bahwa kecanduan media sosial merupakan fenomena multidimensi yang dipengaruhi oleh interaksi antara faktor psikologis, sosial, dan aktivitas penggunaan media sosial pada mahasiswa.
- 4) Sistem rekomendasi yang dihasilkan mampu memberikan saran penanganan sesuai tingkat kecanduan untuk mendukung pengelolaan penggunaan media sosial secara lebih adaptif. Integrasi klasifikasi dengan rekomendasi membantu mahasiswa mengenali kondisi penggunaan mereka dan memberikan panduan praktis untuk meminimalkan dampak negatif media sosial terhadap kesehatan mental dan performa akademik.

5. SARAN

Penelitian ini masih dapat dikembangkan lebih lanjut dengan memperluas cakupan variabel perilaku dan psikologis yang digunakan agar mampu menggambarkan pola kecanduan digital secara lebih komprehensif. Pengumpulan data primer melalui survei atau kuesioner terstruktur juga menjadi peluang pengembangan agar karakteristik responden lebih sesuai dengan konteks lokal mahasiswa. Selain itu, pengujian dengan beberapa algoritma pembandingan dapat menunjang evaluasi kinerja model dan memberikan gambaran yang lebih objektif mengenai efektivitas metode klasifikasi yang digunakan. Pada tahap implementasi, sistem rekomendasi yang telah dibangun dapat dikembangkan menjadi fitur yang lebih adaptif sehingga mampu memberikan saran yang lebih personal sesuai kondisi pengguna. Dengan pengembangan tersebut, penelitian ini berpotensi memberikan kontribusi yang lebih luas dalam upaya memahami dan mengelola kecanduan media sosial pada kalangan mahasiswa.

DAFTAR PUSTAKA

- [1] L. Zhao, “The impact of social media use types and social media addiction on subjective well-being of college students: A comparative analysis of addicted and non-addicted students,” *Computers in Human Behavior Reports*, vol. 4, p. 100122, 2021, doi: <https://doi.org/10.1016/j.chbr.2021.100122>.
- [2] O. Tyrväinen, H. Pirkkalainen, M. Salo, and H. Karjalainen, “Overloaded yet addicted? A meta-analysis of the outcomes of social media overload,” *Telematics and Informatics*, vol. 98, p. 102247, 2025, doi: <https://doi.org/10.1016/j.tele.2025.102247>.
- [3] Z. Peng, X. Su, and Y. Hou, “How do GenAI and social media provide psychosocial information support for cancer survivors and professionals? An analysis using structural topic modeling for exploration and comparison,” *European Journal of Oncology Nursing*, vol. 79, p. 103018, 2025, doi: <https://doi.org/10.1016/j.ejon.2025.103018>.
- [4] D. Bagus Reknadi, M. Ghofar Rohman, and A. Fraga Listyo Utomo, “Adaptation of Contrastive Learning and Augmentation for Indonesian Product Review Classification on Unbalanced Data Using Deep Learning and NLP.”
- [5] T. C. Marshall, “Social media observation of ex-partners is associated with greater breakup distress, negative affect, and jealousy,” *Comput Human Behav*, vol. 176, p. 108869, 2026, doi: <https://doi.org/10.1016/j.chb.2025.108869>.
- [6] D. R. Galos and J. Frese, “Online social class cues and employability: Experimental evidence from Germany,” *Soc Sci Res*, vol. 133, p. 103258, 2026, doi: <https://doi.org/10.1016/j.ssresearch.2025.103258>.
- [7] K. Battista, S. Haddad, S. T. Leatherdale, and R. Bélanger, “Characteristics of adolescent cannabis use and social context predicting problematic use: A decision tree analysis,” *Addictive Behaviors*, vol. 170, p. 108445, 2025, doi: <https://doi.org/10.1016/j.addbeh.2025.108445>.
- [8] H. Kupermintz, E. K. Tesler, H. Gleit, and D. Kopelman-Rubin, “Measuring Adults’ Social and Emotional Competencies: Development and Validation of a New Self-report Questionnaire – Social and Emotional Competencies Questionnaire - Hebrew (SECQ-H),” *Social and Emotional Learning: Research, Practice, and Policy*, p. 100168, 2025, doi: <https://doi.org/10.1016/j.sel.2025.100168>.
- [9] L. Boltanski, “The social uses of the body,” *Soc Sci Med*, vol. 385, p. 118141, 2025, doi: <https://doi.org/10.1016/j.socscimed.2025.118141>.
- [10] Y. Qu, C. Yu, C. Li, and Y. Yang, “Laser-Printed Document Classification Using Random Forest and Grey Prediction Models,” *iScience*, p. 114131, 2025, doi: <https://doi.org/10.1016/j.isci.2025.114131>.
- [11] H. Hara, Y. Fujita, and K. Tsuda, “Population estimation by random forest analysis using Social Sensors,” *Procedia Comput Sci*, vol. 176, pp. 1893–1902, 2020, doi: <https://doi.org/10.1016/j.procs.2020.09.229>.
- [12] A. Gutiérrez, J. Aguilar, A. Ortega, and E. Montoya, “Sentiment analysis on social networks for defining innovation problems in organizations,” *Technol Soc*, vol. 81, p. 102804, 2025, doi: <https://doi.org/10.1016/j.techsoc.2024.102804>.
- [13] M. Kamal, Md. Al Amin, M. Ahmed, P. Ahmed, and Md. A. Islam, “Mathematical modeling and optimal control of social media addiction with stability and sensitivity analysis,” *Franklin Open*, vol. 12, p. 100354, 2025, doi: <https://doi.org/10.1016/j.fraope.2025.100354>.

- [14] D. Jitoku *et al.*, “Psychophysiological response of individuals with internet gaming disorder to gaming content from social media,” *Addictive Behaviors Reports*, vol. 22, p. 100641, 2025, doi: <https://doi.org/10.1016/j.abrep.2025.100641>.
- [15] F. Z. Allahverdi, N. Bayer, and M. Kart, “Perceived social media addiction explained through perceived organizational support, burnout subscales, and the number of years on the job,” *Acta Psychol (Amst)*, vol. 255, p. 104976, 2025, doi: <https://doi.org/10.1016/j.actpsy.2025.104976>.