

Analisis Perbandingan Model Random Forest dan XGBoost untuk Klasifikasi Tingkat Kecanduan Media Sosial

DIAN AYU FAUZIAH, ATIK WINTARTI, DAN YUNI ROSITA DEWI*

Program Studi Sarjana Sains Data, Universitas Negeri Surabaya, Indonesia

Abstrak

Tingginya intensitas penggunaan media sosial yang tidak terkendali, khususnya pada remaja dan dewasa muda, dapat menyebabkan kecanduan media sosial yang berdampak pada fungsi kognitif dan prestasi akademik. Penelitian ini bertujuan untuk menganalisis kinerja serta membandingkan performa algoritma Random Forest dan XGBoost dalam klasifikasi tingkat kecanduan media sosial. Dataset yang digunakan adalah *Students Social Media Addiction* dengan jumlah 705 responden. Tahap pra-pemrosesan mencakup penghapusan atribut yang tidak relevan, pembentukan variabel target menggunakan metode *tertile* ke dalam kelas *Low*, *Medium*, dan *High*, serta *encoding* pada variabel kategorikal. Pengujian dilakukan melalui skenario pembagian data 70:30, 80:20, dan 90:10 dengan validasi *10-fold cross-validation*. Hasil penelitian menunjukkan bahwa kedua algoritma menghasilkan performa tinggi pada seluruh skenario. Pada skenario 80:20, Random Forest memperoleh *validation accuracy* sebesar 97,52%, *test accuracy* sebesar 98,58%, *F1-score macro* sebesar 98,61%, standar deviasi sebesar 0.028, dan *generalization gap* sebesar 0,0248. Sementara itu, XGBoost memperoleh *validation accuracy* sebesar 97,31%, *test accuracy* sebesar 98,58%, *F1-score macro* sebesar 98,59%, standar deviasi sebesar 0.025, dan *generalization gap* sebesar 0,0269. Random Forest memberikan nilai *validation accuracy*, *F1-score*, dan *generalization gap* yang lebih baik, sedangkan XGBoost memiliki standar deviasi lebih rendah yang menunjukkan bahwa model tersebut memiliki performa yang lebih konsisten pada setiap *fold* dalam proses *cross-validation*. Dengan demikian, kedua model dapat dinyatakan efektif dalam mengklasifikasikan tingkat kecanduan media sosial, dengan skenario pembagian data 80:20 sebagai skenario paling optimal.

Kata Kunci *kecanduan media sosial; klasifikasi; machine learning; Random Forest; XGBoost*

Abstract

The increasing intensity of uncontrolled social media use, particularly among adolescents and young adults, may lead to social media addiction, which negatively affects cognitive functioning and academic performance. This study aims to analyze and compare the performance of the Random Forest and XGBoost algorithms in classifying social media addiction levels. The dataset used in this study was the *Students Social Media Addiction* dataset, consisting of 705 respondents. The preprocessing stage included removing irrelevant attributes, constructing the target variable using the *tertile* method to form three classes (*Low*, *Medium*, and *High*), and encoding categorical variables. Model evaluation was conducted using three data-splitting scenarios (70:30, 80:20, and 90:10) combined with *10-fold cross-validation*. The results showed that both algorithms achieved high performance across all scenarios. Under the 80:20 data-splitting scenario, Random

*Corresponding author.Email: atikwintarti@unesa.ac.id or yunidewi@unesa.ac.id.

Forest achieved a validation accuracy of 97.52%, a test accuracy of 98.58%, a macro F1-score of 98.61%, a standard deviation of 0.028, and a generalization gap of 0.0248. Meanwhile, XGBoost achieved a validation accuracy of 97.31%, a test accuracy of 98.58%, a macro F1-score of 98.59%, a standard deviation of 0.025, and a generalization gap of 0.0269. Random Forest achieved higher validation accuracy, macro F1-score, and lower generalization gap, whereas XGBoost exhibited a lower standard deviation, indicating more consistent performance across the cross-validation folds. Overall, both models were found to be effective in classifying social media addiction levels, with the 80:20 data-splitting scenario identified as the optimal setting.

Keywords *social media addiction; classification; machine learning; Random Forest; XGBoost*

1 Pendahuluan

Perkembangan teknologi digital memberikan kemudahan dalam berbagai aspek kehidupan, termasuk pendidikan, tetapi juga menghadirkan risiko baru akibat penggunaan media yang berlebihan. Media sosial seperti *Facebook*, *Instagram*, *Twitter*, dan *TikTok* tidak hanya menjadi sarana interaksi, tetapi juga membentuk pola perilaku yang perlu dianalisis (Khalaf dkk., 2023). Di kalangan mahasiswa, media sosial bermanfaat untuk akses informasi dan literatur *online*, namun penggunaan yang tidak terkendali dapat memicu ketergantungan dan masalah penggunaan media interaktif atau *Problematic Interactive Media Use* (PIMU) (Drakel dkk., 2018; Digital Wellness Lab, 2024).

Penggunaan media digital secara berlebihan berkaitan dengan gangguan fungsi kognitif, konsentrasi, dan hasil akademik, khususnya pada remaja dan dewasa muda. Paparan layar pada malam hari dilaporkan berpengaruh terhadap penurunan kemampuan kognitif dan fokus perhatian (Shalash dkk., 2024), sedangkan fenomena “*brain rot*” mencerminkan kekhawatiran terhadap dampak konsumsi media digital yang berlebihan terhadap kemampuan mental (Context Dergi, 2024; Oxford University Press, 2024). Di Indonesia, rata-rata penggunaan media sosial mencapai 7 jam 42 menit per hari, yang menunjukkan tingginya intensitas interaksi digital masyarakat (Kemp, 2023). Sejumlah penelitian juga menunjukkan hubungan negatif antara tingkat kecanduan media sosial dan fungsi kognitif (Yazgan, 2025; Shalash dkk., 2024).

Kompleksitas perilaku penggunaan media sosial mendorong perlunya pendekatan analisis berbasis data untuk mengidentifikasi pola dan tingkat adiksi secara prediktif. Berbeda dari penelitian yang berfokus pada hubungan korelasional antara kecanduan media sosial dengan kesehatan mental atau hasil belajar, penelitian ini mengoptimalkan model klasifikasi menggunakan algoritma Random Forest dan XGBoost. Dataset yang digunakan berasal dari repositori publik *Kaggle* dan memuat variabel relevan seperti durasi penggunaan harian, jam tidur, skor kesehatan mental, serta skor kecanduan.

Penelitian sebelumnya menunjukkan bahwa pendekatan pembelajaran mesin mampu mendeteksi kecanduan media sosial dengan performa tinggi. Ehsan dan Basit (2024) memperoleh akurasi 88,6% menggunakan Random Forest classifier, Izhari (2025) melaporkan akurasi 97,9% menggunakan XGBoost, dan Lee dan Kim (2021) menunjukkan bahwa Random Forest mencapai akurasi tertinggi 82,5% dalam prediksi kecanduan *smartphone*. Namun, evaluasi pada penelitian tersebut umumnya masih terbatas pada satu skenario pembagian data atau satu kali pengujian. Oleh karena itu, penelitian ini membandingkan konsistensi dan stabilitas performa Random Forest dan XGBoost melalui beberapa skenario pembagian data untuk klasifikasi tingkat kecanduan media sosial.

2 Metode

2.1 Dataset

Dataset yang digunakan dalam penelitian ini adalah data *Student Social Media Addiction* yang diambil dari repositori data publik *Kaggle*. Dataset ini dipublikasikan oleh [Shamim \(2025\)](#) pada tahun 2022. Data tersebut berisi 705 jawaban responden yang berasal dari berbagai negara, termasuk Indonesia, sehingga merepresentasikan karakteristik pengguna media sosial pada rentang usia remaja hingga dewasa awal. Data yang digunakan pada penelitian ini bersifat kuantitatif dan berbentuk tabular. Selain itu, dataset ini juga menyediakan variabel *Addicted_Score* yang merepresentasikan tingkat kecanduan media sosial dalam bentuk skor numerik hasil pengukuran survei. Sebagian isi dari data *Student Social Media Addiction* yang mencakup 13 variabel ditampilkan pada 1, dengan penjelasan pada berikut:

Tabel 1: Sebagian Isi Data *Student Social Media Addiction*


Student ID	Age	Gender	Academic Level	Country	Avg. Daily Usage Hours	Most Used Platform	Affects Academic Performance	Sleep Hours Per Night	Mental Health Score	Relationship Status	Conflicts Over Social Media	Addicted Score
1	19	Female	Under graduate	Bangladesh	5.2	Instagram	Yes	6.5	6	In Relationship	3	8
2	22	Male	Graduate	India	2.1	Twitter	No	7.5	8	Single	0	3
3	20	Female	Under graduate	USA	6.0	TikTok	Yes	5.0	5	Complicated	4	9
4	18	Male	High School	UK	3.0	YouTube	No	7.0	7	Single	1	4
5	21	Male	Graduate	Canada	4.5	Facebook	Yes	6.0	6	In Relationship	2	7
...	...	...	...	...	...	...	...	...	...	...	...	...
703	21	Female	Under graduate	China	5.6	WeChat	Yes	6.7	6	In Relationship	3	7
704	24	Male	Graduate	Japan	4.3	Twitter	No	7.5	8	Single	2	4
705	19	Female	Under graduate	Poland	6.2	Facebook	Yes	6.3	5	Single	4	8

2.2 Alur Penelitian

Penelitian diawali dengan pengambilan dataset *Students Social Media Addiction* dari *Kaggle* yang memuat 705 data responden. Data tersebut terlebih dahulu ditinjau melalui analisis eksploratif untuk melihat karakteristik variabel dan menentukan atribut yang digunakan. Setelah itu, dilakukan pra-pemrosesan berupa penghapusan atribut yang tidak relevan, pembentukan kelas target dengan metode *tertile* menjadi kategori *Low*, *Medium*, dan *High*, pengkodean atribut kategorikal menggunakan *label encoding*, serta standarisasi fitur numerik dengan *StandardScaler*.

Dataset hasil pra-pemrosesan kemudian dibagi ke dalam tiga skenario, yaitu 70:30, 80:20, dan 90:10. Pada setiap skenario, model Random Forest dan XGBoost dilatih serta divalidasi menggunakan *10-fold cross-validation* agar penilaian performa tidak bergantung pada satu pembagian data saja. Evaluasi dilakukan berdasarkan *validation accuracy*, *test accuracy*, *precision*, *recall*, *F1-score macro*, standar deviasi, dan *generalization gap*. Seluruh hasil tersebut dibandingkan untuk menentukan model dan skenario pembagian data yang paling baik dalam mengklasifikasikan

tingkat kecanduan media sosial. Alur penelitian ditampilkan pada Gambar 1.



Gambar 1: Alur Penelitian Analisis Perbandingan Model

2.3 Pra-pemrosesan

Data *Student Social Media Addiction* terlebih dahulu melalui tahap pra-pemrosesan agar sesuai untuk kebutuhan pemodelan. Pemeriksaan awal dilakukan melalui analisis eksploratif. Atribut yang tidak digunakan dalam pemodelan, seperti *Country*, dihapus karena tidak memberikan pengaruh signifikan terhadap variabel target dan memiliki kardinalitas yang sangat tinggi, sedangkan kolom *Student ID* diatur menjadi indeks sehingga tidak ada data duplikat pada saat pengecekan duplikasi data dikarenakan indeks diikutsertakan dalam proses pengecekan. Selanjutnya, skor pada variabel *Addicted_Score* diubah menjadi tiga kategori tingkat kecanduan menggunakan metode *tertile*. Pemilihan metode ini didasarkan pada kebutuhan penelitian untuk membentuk tiga kelas target, yaitu rendah (*Low*), sedang (*Medium*), dan tinggi (*High*), serta hasil percobaan awal yang menunjukkan bahwa pembagian berbasis kuartil menghasilkan distribusi kelas yang kurang seimbang pada dataset penelitian ini. Pada penelitian sebelumnya, pembagian kategori

berbasis kuartil digunakan dengan letak kuartil ke- i pada data terurut dapat dinyatakan sebagai berikut (Ehsan dan Basit, 2024):

$$L_{Q_i} = \frac{i(n+1)}{4}, \quad (1)$$

secara konsep, *tertile* merupakan bentuk diskretisasi berbasis kuantil yang membagi skor numerik menjadi tiga kelompok dengan proporsi relatif seimbang (Han dkk., 2011). Oleh karena itu, rumus letak tertile diperoleh dengan mengadaptasi prinsip letak kuantil tersebut, yaitu mengganti pembagi 4 pada kuartil menjadi 3. Dengan demikian, letak tertile ke- i dirumuskan sebagai berikut:

$$L_{T_i} = \frac{i(n+1)}{3}, \quad (2)$$

pada persamaan tersebut, L_{T_i} menunjukkan letak *tertile* ke- i , dengan $i = 1, 2$, sedangkan n merupakan jumlah sampel penelitian, yaitu 705 responden. Nilai T_1 dan T_2 yang diperoleh dari perhitungan tersebut kemudian digunakan sebagai batas kategori sebagaimana ditampilkan pada Tabel 2.

Tabel 2: Kriteria Kategorisasi Tingkat Kecanduan Media Sosial

Kategori	Kriteria Skor
Rendah (<i>Low</i>)	Skor $\leq T_1$
Sedang (<i>Medium</i>)	$T_1 < \text{Skor} \leq T_2$
Tinggi (<i>High</i>)	Skor $> T_2$

Kriteria pada Tabel 2 digunakan untuk menempatkan setiap responden ke dalam kelompok kecanduan berdasarkan posisi skornya terhadap T_1 dan T_2 . Setelah variabel target terbentuk, atribut kategorikal dikonversi menggunakan *label encoding* agar dapat diproses oleh algoritma pembelajaran mesin. Fitur numerik kemudian distandardisasi dengan *StandardScaler* sehingga perbedaan skala antarvariabel tidak mendominasi proses pelatihan model.

2.4 Pemodelan

Dataset yang telah melewati tahap pra-pemrosesan digunakan sebagai masukan pada proses pemodelan. Untuk melihat pengaruh komposisi data terhadap performa model, penelitian ini menerapkan tiga skenario pembagian data, yaitu 70:30, 80:20, dan 90:10. Pada setiap skenario, model dilatih dan divalidasi menggunakan *10-fold cross-validation* agar estimasi performa lebih stabil dan tidak bergantung pada satu pembagian data latih saja. Setiap skenario diterapkan pada dua algoritma, yaitu Random Forest classifier dan XGBoost, sehingga kinerja model dapat dibandingkan berdasarkan proporsi data latih dan data uji yang berbeda.

Pemilihan beberapa rasio pembagian data didasarkan pada temuan penelitian terdahulu yang menunjukkan bahwa proporsi data latih dan data uji dapat memengaruhi akurasi, representativitas *subset*, serta stabilitas evaluasi model. Nugroho (2022) dan Anjani dkk. (2023) melaporkan bahwa rasio dengan data latih lebih besar cenderung memberikan hasil lebih tinggi pada model berbasis pohon keputusan, sedangkan Kahloot dan Ekler (2021) menekankan pentingnya keseimbangan antara kemampuan generalisasi dan reliabilitas pengujian. Dengan pertimbangan tersebut, ketiga skenario pembagian data digunakan untuk memperoleh gambaran performa yang lebih menyeluruh, bukan hanya bergantung pada satu komposisi data.

2.4.1 Random Forest

Random Forest digunakan sebagai salah satu model klasifikasi karena sesuai untuk data tabular dan relatif stabil terhadap variasi data latih. Algoritma ini membangun sejumlah pohon keputusan dari sampel data dan fitur yang dipilih secara acak, kemudian menentukan kelas akhir berdasarkan suara terbanyak dari seluruh pohon (Breiman, 2001; Dinata dkk., 2021). Menurut Breiman (2001), performa Random Forest dipengaruhi oleh kekuatan masing-masing pohon dan tingkat korelasi antarpohon. Secara matematis, batas atas kesalahan generalisasi pada Random Forest dapat dituliskan sebagai berikut:

$$PE^* \leq \frac{\bar{\rho}(1 - s^2)}{s^2}, \quad (3)$$

dengan $\bar{\rho}$ menunjukkan rata-rata korelasi antarpohon dan s menunjukkan kekuatan (*strength*) kumpulan pohon. Persamaan tersebut menunjukkan bahwa kesalahan prediksi dapat ditekan ketika pohon-pohon penyusun model memiliki kekuatan prediksi yang tinggi dan korelasi yang rendah.

Pada penelitian ini, Random Forest dilatih menggunakan 10 fitur masukan yang terdiri atas lima variabel numerik (*Avg_Daily_Usage_Hours*, *Sleep_Hours_Per_Night*, *Mental_Health_Score*, *Conflicts_Over_Social_Media*, dan *Age*) serta lima variabel kategorikal yang telah dikodekan (*Gender*, *Academic_Level*, *Most_Used_Platform*, *Affects_Academic_Performance*, dan *Relationship_Status*). Setiap pohon dilatih menggunakan sampel *bootstrap* dari data pelatihan. Pada setiap simpul pemisahan, kandidat pemisahan terbaik dipilih dari subset fitur yang ditentukan secara acak. Prediksi akhir ditentukan melalui mekanisme *majority voting* untuk mengklasifikasikan tingkat kecanduan media sosial ke dalam kategori *Low*, *Medium*, dan *High*. Model dijalankan pada skenario pembagian data 70:30, 80:20, dan 90:10, kemudian dievaluasi menggunakan *10-fold cross-validation*.

2.4.2 XGBoost

XGBoost digunakan sebagai model pembandingan karena menerapkan mekanisme *boosting* yang membangun pohon keputusan secara bertahap. Pada setiap iterasi, pohon baru ditambahkan untuk memperbaiki kesalahan prediksi dari model sebelumnya, sehingga model akhir terbentuk dari gabungan beberapa pohon yang saling melengkapi (Syukron dkk., 2020; Salam Patrous, 2018). Berbeda dari pembentukan pohon secara tunggal, XGBoost mengoptimalkan fungsi objektif yang memadukan nilai kesalahan prediksi dan regularisasi model. Fungsi objektif tersebut dituliskan sebagai berikut:

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

dengan $L^{(t)}$ merupakan fungsi objektif pada iterasi ke- t , l menunjukkan fungsi kerugian, $\hat{y}_i^{(t-1)}$ adalah prediksi pada iterasi sebelumnya, dan $f_t(x_i)$ merupakan pohon baru yang ditambahkan. Komponen regularisasi $\Omega(f_t)$ digunakan untuk mengontrol kompleksitas pohon dan dinyatakan sebagai berikut:

$$\Omega(f_t) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2, \quad (5)$$

pada persamaan tersebut, T menunjukkan jumlah *leaf*, w_j merupakan bobot pada *leaf* ke- j , sedangkan γ dan λ berperan sebagai parameter regularisasi. Dalam penelitian ini, XGBoost diterapkan pada dataset hasil pra-pemrosesan untuk mengklasifikasikan tingkat kecanduan media sosial ke dalam kategori *Low*, *Medium*, dan *High*. Model dijalankan pada skenario pembagian data (data latih: data uji) 70:30, 80:20, dan 90:10, kemudian dievaluasi menggunakan *10-fold cross-validation*.

Pada dataset ini, XGBoost menerima fitur masukan yang sama dengan Random Forest. Berbeda dari metode *bagging*, XGBoost membangun pohon secara sekuensial dengan memanfaatkan gradien dan Hessian dari fungsi kerugian. Setiap pohon baru ditambahkan untuk memperbaiki kesalahan prediksi model pada iterasi sebelumnya. Komponen regularisasi $\Omega(f_t)$ pada Persamaan (5) membatasi kompleksitas pohon sehingga membantu mengurangi risiko *overfitting* dan meningkatkan kemampuan generalisasi model.

2.5 Metrik Evaluasi

Evaluasi dilakukan untuk menilai kemampuan Random Forest dan XGBoost dalam mengklasifikasikan tingkat kecanduan media sosial. Pada data latih, performa model diukur menggunakan *10-fold cross-validation* dengan pendekatan stratifikasi agar proporsi kelas *Low*, *Medium*, dan *High* tetap terjaga pada setiap *fold* (Kohavi, 1995). Dari proses ini diperoleh nilai rata-rata *validation accuracy* (μ) dan standar deviasi (σ), yang masing-masing digunakan untuk melihat kinerja validasi dan kestabilan model pada pembagian data yang berbeda.

Setelah proses validasi, model dilatih kembali menggunakan seluruh data latih dan diuji pada data uji. Tahap ini digunakan untuk melihat kemampuan model pada data yang belum dilibatkan dalam pelatihan. Hasil prediksi terlebih dahulu disajikan dalam bentuk *confusion matrix* multi kelas, yaitu tabel yang membandingkan kelas aktual dan kelas hasil prediksi. Dari matriks tersebut, kinerja model kemudian dihitung menggunakan metrik evaluasi berupa *accuracy*, *precision*, *recall*, dan *F1-score*. Gambar 2 menunjukkan bentuk umum *confusion matrix* untuk permasalahan *multi-class classification* dengan tiga kelas (A, B, dan C). Komponen dalam matriks tersebut adalah:

1. TP_A, TP_B, TP_C (*True Positive*): Jumlah data yang berhasil diprediksi dengan benar untuk masing-masing kelas.
2. E_{ij} (*Error*): Jumlah kesalahan klasifikasi di mana data yang seharusnya termasuk kelas j (kolom) diprediksi sebagai kelas i (baris).
3. Sebagai contoh, E_{BA} menunjukkan jumlah data yang sebenarnya merupakan kelas B, namun salah diprediksi sebagai kelas A.

Berdasarkan notasi tersebut, komponen evaluasi untuk setiap kelas dapat diturunkan sebagai berikut. Untuk setiap kelas i , *True Positive* (TP_i) merupakan jumlah data kelas i yang diprediksi dengan benar. *False Positive* (FP_i) adalah jumlah data dari kelas lain yang salah diprediksi sebagai kelas i , yang dinyatakan sebagai $FP_i = \sum_{j \neq i} E_{ij}$. *False Negative* (FN_i) merupakan jumlah data kelas i yang salah diprediksi sebagai kelas lain, yang dinyatakan sebagai $FN_i = \sum_{j \neq i} E_{ji}$. Sementara itu, *True Negative* (TN_i) adalah jumlah data yang bukan kelas i dan tidak diprediksi sebagai kelas i . Nilai-nilai tersebut digunakan sebagai dasar perhitungan *precision*, *recall*, dan *F1-score* pada Persamaan (7)–(9).

Berdasarkan nilai-nilai pada *confusion matrix multiclass* tersebut, metrik evaluasi yang digunakan dalam penelitian ini dijelaskan sebagai berikut:

		True Class		
		A	B	C
Predicted Class	A	TP_A	E_{BA}	E_{CA}
	B	E_{AB}	TP_B	E_{CB}
	C	E_{AC}	E_{BC}	TP_C

Gambar 2: *Confusion Matrix Multi-class Classification* (Tharwat, 2020)

- a. **Accuracy**, mengukur rasio prediksi benar terhadap keseluruhan data.

$$Accuracy = \frac{TP_A + TP_B + TP_C}{N}. \quad (6)$$

- b. **Precision**, mengukur proporsi prediksi positif yang benar dari seluruh data yang diprediksi sebagai positif.

$$Precision = \frac{TP}{TP + FP}. \quad (7)$$

- c. **Recall**, mengukur proporsi data positif yang berhasil dikenali dengan benar oleh model.

$$Recall = \frac{TP}{TP + FN}. \quad (8)$$

- d. **F1-Score**, nilai keseimbangan antara *precision* dan *recall*.

$$F1 = \frac{2 \times (Precision \times Recall)}{Precision + Recall}, \quad (9)$$

Pada rumus tersebut, TP menyatakan jumlah prediksi benar pada kelas positif, TN menyatakan jumlah prediksi benar pada kelas negatif, FP menyatakan jumlah data negatif yang salah diprediksi sebagai positif, dan FN menyatakan jumlah data positif yang salah diprediksi sebagai negatif. Dalam klasifikasi multikelas, perhitungan dilakukan per kelas dengan memperlakukan satu kelas sebagai kelas positif dan kelas lainnya sebagai kelas negatif.

3 Hasil dan Pembahasan

3.1 Kinerja Random Forest

Model Random Forest dijalankan pada tiga skenario pembagian data untuk melihat perubahan kinerja terhadap proporsi data latih dan data uji. Pengujian dilakukan dengan parameter bawaan *scikit-learn* dan *random_state*=42 agar hasil setiap skenario dapat dibandingkan secara konsisten. Ringkasan performa model berdasarkan *training accuracy*, *validation accuracy*, *standard deviation*, *test accuracy*, *generalization gap*, dan waktu komputasi disajikan pada Tabel 3.

Tabel 3: Performa Random Forest pada Tiap Skenario

Rasio	Train Acc	Val Acc	Std Dev	Test Acc	Generalization Gap	Waktu (det)
70:30	1.000	0.971	0.018	0.981	0.028	1.89
80:20	1.000	0.975	0.028	0.985	0.024	2.91
90:10	1.000	0.971	0.019	1.000	0.028	1.99

Berdasarkan Tabel 3, seluruh skenario menghasilkan performa yang tinggi. Nilai *training accuracy* mencapai 1.000 pada semua rasio, sedangkan *validation accuracy* berada pada kisaran 0.971–0.975. Skenario 80:20 memberikan *validation accuracy* tertinggi sebesar 0.975 dan *test accuracy* sebesar 0.985, dengan *generalization gap* paling kecil yaitu 0.024. Hasil ini menunjukkan bahwa rasio 80:20 memberikan keseimbangan yang lebih baik antara kemampuan model dalam mempelajari data latih dan mempertahankan kinerja pada data uji.

Evaluasi juga dilakukan pada masing-masing kelas untuk melihat apakah model hanya unggul pada kelas tertentu atau mampu mengenali seluruh tingkat kecanduan secara merata. Nilai *precision*, *recall*, dan *F1-score* untuk kelas *Low*, *Medium*, dan *High* ditampilkan pada Tabel 4.

Tabel 4: Metrik Evaluasi Per Kelas Model Random Forest

Skenario	Kelas	Precision	Recall	F1-Score
70:30	Low	1.00	0.98	0.99
	Medium	0.96	1.00	0.98
	High	0.99	0.96	0.97
80:20	Low	1.00	0.97	0.99
	Medium	0.98	1.00	0.99
	High	0.98	0.98	0.98
90:10	Low	1.00	1.00	1.00
	Medium	1.00	1.00	1.00
	High	1.00	1.00	1.00

Berdasarkan Tabel 4, Random Forest menunjukkan kinerja yang konsisten pada ketiga kelas. Pada skenario 70:30 dan 80:20, nilai *F1-score* setiap kelas berada pada rentang 0.97–0.99, sedangkan skenario 90:10 memperoleh nilai 1.00 pada seluruh kelas. Meskipun demikian, hasil sempurna pada rasio 90:10 perlu dibaca bersama ukuran data uji yang lebih kecil. Dengan mempertimbangkan validasi, akurasi uji, dan *generalization gap*, skenario 80:20 menjadi konfigurasi yang lebih seimbang untuk model Random Forest.

3.2 Kinerja XGBoost

Model XGBoost diuji pada skenario pembagian data yang sama untuk memperoleh pembandingan terhadap Random Forest. Konfigurasi model menggunakan parameter bawaan pustaka XGBoost dengan penetapan *random_state=42*, *use_label_encoder=False*, dan *eval_metric='mlogloss'*. Ringkasan hasil pengujian berdasarkan *training accuracy*, *validation accuracy*, *standard deviation*, *test accuracy*, *generalization gap*, dan waktu komputasi ditampilkan pada Tabel 5.

Tabel 5: Performa XGBoost pada Tiap Skenario

Rasio	Train Acc	Val Acc	Std Dev	Test Acc	Generalization Gap	Waktu (det)
70:30	1.000	0.969	0.020	0.976	0.030	0.59
80:20	1.000	0.973	0.025	0.985	0.026	1.95
90:10	1.000	0.973	0.017	1.000	0.026	0.70

Berdasarkan Tabel 5, XGBoost menghasilkan performa tinggi pada seluruh skenario. Nilai *training accuracy* mencapai 1.000, sedangkan *validation accuracy* berada pada kisaran 0.969–0.973. Skenario 80:20 dan 90:10 memperoleh *validation accuracy* yang sama, yaitu 0.973, tetapi skenario 80:20 memberikan ukuran data uji yang lebih memadai dengan *test accuracy* sebesar 0.985. Sementara itu, rasio 90:10 menghasilkan *test accuracy* 1.000, namun hasil tersebut perlu dipertimbangkan bersama jumlah data uji yang lebih kecil.

Untuk melihat kemampuan model pada setiap tingkat kecanduan, evaluasi per kelas dilakukan menggunakan *precision*, *recall*, dan *F1-score*. Hasil evaluasi tersebut disajikan pada Tabel 6.

Tabel 6: Metrik Evaluasi Per Kelas Model XGBoost

Skenario	Kelas	Precision	Recall	F1-Score
70:30	Low	0.98	0.98	0.98
	Medium	0.96	1.00	0.98
	High	0.99	0.95	0.97
80:20	Low	0.98	1.00	0.99
	Medium	0.98	1.00	0.99
	High	1.00	0.96	0.98
90:10	Low	1.00	1.00	1.00
	Medium	1.00	1.00	1.00
	High	1.00	1.00	1.00

Berdasarkan Tabel 6, XGBoost mampu mengenali ketiga kelas dengan baik. Pada skenario 70:30 dan 80:20, nilai *F1-score* berada pada rentang 0.97–0.99, sedangkan skenario 90:10 mencapai nilai 1.00 pada seluruh kelas. Secara umum, hasil ini menunjukkan bahwa XGBoost memiliki performa klasifikasi yang stabil, dengan skenario 80:20 sebagai konfigurasi yang lebih seimbang jika mempertimbangkan validasi, akurasi uji, dan ukuran data pengujian.

3.3 Perbandingan Kinerja Random Forest dan XGBoost

Perbandingan model difokuskan pada skenario 80:20 karena rasio tersebut memberikan keseimbangan terbaik antara hasil validasi, akurasi pengujian, dan ukuran data uji. Ringkasan performa terbaik Random Forest dan XGBoost disajikan pada Tabel 7. Berdasarkan tabel tersebut, kedua model memperoleh *train accuracy* sebesar 1.0000 dan *test accuracy* sebesar 0.9858. Perbedaan terlihat pada *generalization gap* dan standar deviasi. Random Forest memiliki *generalization gap* lebih kecil, yaitu 0.0248, sedangkan XGBoost sebesar 0.0269. Nilai tersebut menunjukkan bahwa keduanya memiliki kemampuan generalisasi yang baik karena selisih antara performa pelatihan dan validasi relatif kecil (Valdenegro-Toro dan Sabatelli, 2022). Keunggulan kecil pada

Random Forest dapat dikaitkan dengan mekanisme *bagging* yang membantu menekan varians dan mengurangi risiko *overfitting* (Loreggia dkk., 2021).

Tabel 7: Perbandingan Model Optimal pada Skenario Terbaik (80:20)

Model	<i>Train Accuracy</i>	<i>Test Accuracy</i>	<i>Standard Deviation</i>	<i>Generalization Gap</i>
Random Forest	1.0000	0.9858	0.0286	0.0248
XGBoost	1.0000	0.9858	0.0253	0.0269

Di sisi lain, XGBoost memperoleh standar deviasi lebih rendah dibandingkan Random Forest, yaitu 0.0253 berbanding 0.0286. Nilai ini menunjukkan bahwa performa XGBoost sedikit lebih konsisten pada setiap *fold* dalam proses *cross-validation*. Karakter tersebut sejalan dengan mekanisme *boosting*, yang membangun model secara berurutan untuk memperbaiki kesalahan prediksi sebelumnya, serta penggunaan regularisasi untuk mengontrol kompleksitas model (Baker dkk., 2020; Pekar dkk., 2026).

Secara keseluruhan, kedua model menunjukkan performa yang sangat dekat pada klasifikasi tingkat kecanduan media sosial. Random Forest sedikit lebih unggul dari sisi *generalization gap*, sedangkan XGBoost lebih stabil berdasarkan standar deviasi antar *fold*. Dengan mempertimbangkan seluruh metrik, skenario 80:20 dapat dinyatakan sebagai konfigurasi paling seimbang dalam penelitian ini.

3.4 Perbandingan dengan Penelitian Sebelumnya

Perbandingan dengan penelitian terdahulu dilakukan untuk menempatkan hasil penelitian ini dalam konteks studi klasifikasi kecanduan media sosial yang sudah ada. Perbandingan disajikan berdasarkan metrik utama yang dilaporkan pada masing-masing penelitian, meskipun perbedaan dataset, jumlah fitur, karakteristik responden, dan skenario pengujian tetap perlu diperhatikan. Ringkasan perbandingan tersebut ditampilkan pada Tabel 8.

Tabel 8: Perbandingan Performa dengan Penelitian Terdahulu

Peneliti	Tahun Terbit	Model	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Lee & Kim	2021	XGBoost	0.80	-	0.81	-
		Random Forest	0.82	-	0.80	-
Ehsan dkk	2024	Random Forest	0.88	0.88	0.88	0.88
Izhari	2025	XGBoost	0.97	0.99	0.98	0.99
Penelitian ini	2026	Random Forest	0.99	0.99	0.99	0.99
		XGBoost	0.99	0.98	0.99	0.99

Berdasarkan Tabel 8, model yang digunakan dalam penelitian ini menghasilkan performa

yang kompetitif dibandingkan penelitian sebelumnya. Random Forest dan XGBoost sama-sama memperoleh akurasi 0.99 pada skenario terbaik, dengan nilai *precision*, *recall*, dan *F1-score* yang juga berada pada kisaran tinggi. Hasil tersebut melampaui beberapa studi terdahulu, seperti penelitian Lee dan Kim serta Ehsan dkk., dan sedikit lebih tinggi dibandingkan hasil yang dilaporkan oleh Izhari (2025). Temuan ini menunjukkan bahwa kombinasi pra-pemrosesan data, pembentukan kelas target, dan pengujian melalui beberapa skenario pembagian data mampu menghasilkan performa klasifikasi yang kuat. Namun, perbandingan ini tetap bersifat kontekstual karena setiap penelitian menggunakan sumber data, distribusi kelas, fitur, dan prosedur evaluasi yang tidak sepenuhnya sama.

3.5 Analisis Contoh Klasifikasi pada Data Uji

Untuk memperjelas kemampuan model dalam mengenali pola data, berikut disajikan beberapa contoh data uji beserta hasil prediksinya pada skenario 80:20. Tabel 9 memuat tiga data uji yang berhasil diklasifikasikan dengan benar oleh kedua model, masing-masing satu dari kelas *Low*, *Medium*, dan *High*.

Tabel 9: Contoh Klasifikasi Benar pada Data Uji (Skenario 80:20)

Avg. Daily Usage (jam)	Sleep Hours (jam)	Mental Health Score	Conflicts	Label Asli	Pred. RF	Pred. XGBoost
4.7	7.2	7	2	Low	Low	Low
4.5	6.0	6	2	Medium	Medium	Medium
5.6	5.6	5	3	High	High	High

Berdasarkan Tabel 9, pola yang berhasil dikenali oleh kedua model cukup konsisten. Responden kelas *Low* memiliki durasi penggunaan media sosial yang relatif singkat (4,7 jam), jam tidur yang cukup (7,2 jam), skor kesehatan mental yang baik (7), serta konflik rendah (2). Pada kelas *Medium*, seluruh nilai fitur berada di rentang tengah, sedangkan responden kelas *High* menunjukkan durasi penggunaan lebih panjang (5,6 jam), jam tidur lebih pendek (5,6 jam), skor kesehatan mental lebih rendah (5), dan konflik yang lebih tinggi (3). Pola tersebut sejalan dengan hasil analisis korelasi antarvariabel pada tahap eksplorasi data, di mana durasi penggunaan harian berkorelasi positif kuat dengan skor kecanduan, sedangkan kesehatan mental berkorelasi negatif kuat terhadap skor yang sama.

Selain contoh klasifikasi yang benar, Tabel 10 menyajikan data uji yang mengalami kesalahan prediksi pada masing-masing model.

Tabel 10: Contoh Klasifikasi Salah pada Data Uji (Skenario 80:20)

Avg. Daily Usage (jam)	Sleep Hours (jam)	Mental Health Score	Conflicts	Label Asli	Pred. RF	Pred. XGBoost
3.8	6.6	7	2	Medium	Low	Low
4.2	7.4	5	4	High	Medium	High

Berdasarkan Tabel 10, terdapat dua data uji yang mengalami kesalahan prediksi. Pada data pertama, responden dengan label asli *Medium* diprediksi sebagai *Low* oleh kedua model. Hal ini terjadi karena profil responden tersebut — durasi penggunaan 3,8 jam per hari, jam tidur 6,6 jam, skor kesehatan mental 7, dan konflik hanya 2 — sangat menyerupai karakteristik kelas *Low*.

Responden ini merupakan *boundary case*, yaitu data yang posisi skornya berada di sekitar titik potong tertile pertama ($T_1 = 5$), sehingga pola fiturnya tidak cukup kuat untuk dibedakan dari kelas yang berdekatan.

Pada data kedua, responden dengan label asli *High* diprediksi sebagai *Medium* oleh Random Forest, sedangkan XGBoost berhasil mengklasifikasikannya dengan benar. Meskipun durasi penggunaan responden ini tergolong rendah untuk ukuran kelas *High* (4,2 jam) dan jam tidurnya relatif panjang (7,4 jam), nilai konflik yang tinggi (4) dan skor kesehatan mental yang rendah (5) menjadi sinyal utama kelas *High*. Perbedaan hasil antara kedua model pada kasus ini menunjukkan bahwa XGBoost lebih sensitif dalam menangkap kombinasi sinyal *Conflicts_Over_Social_Media* dan *Mental_Health_Score* pada data yang berada di zona ambang batas.

Secara keseluruhan, kesalahan klasifikasi yang terjadi pada kedua model hanya berjumlah 2 dari 141 data uji dan seluruhnya terjadi antara kelas yang berdekatan (*Low-Medium* atau *Medium-High*), bukan antara kelas yang berjauhan (*Low-High*). Kondisi ini mengindikasikan bahwa kesalahan model bersifat lokal dan tidak sistematis, melainkan hanya terjadi pada data yang posisi skornya sangat dekat dengan titik potong tertile (T_1 atau T_2).

4 Kesimpulan

Berdasarkan temuan penelitian, model Random Forest dan XGBoost menunjukkan kemampuan yang baik dalam mengklasifikasikan tingkat kecanduan media sosial pada dataset *Students Social Media Addiction*. Pengujian dengan metode *10-fold cross-validation* memperlihatkan bahwa kedua model mampu menghasilkan akurasi yang tinggi pada setiap skenario pembagian data yang digunakan, yaitu 70:30, 80:20, dan 90:10. Pada model Random Forest, pembagian data 80:20 memberikan hasil paling baik, dengan *validation accuracy* sebesar 0.975, *test accuracy* sebesar 0.985, serta nilai *generalization gap* terendah, yaitu 0.024.

Temuan serupa juga diperoleh pada model XGBoost, yang mencapai performa terbaik pada skenario 80:20 dengan *validation accuracy* sebesar 0.973, *test accuracy* sebesar 0.985, dan *generalization gap* sebesar 0.026. Meskipun skenario 90:10 untuk kedua model mencapai akurasi sebesar 1.00 perlu ditafsirkan secara cermat, mengingat ukuran data uji pada skenario tersebut lebih terbatas dibandingkan dengan skenario pembagian data lainnya. Evaluasi berdasarkan metrik *precision*, *recall*, dan *F1-score* mengindikasikan bahwa kedua model memiliki kemampuan yang konsisten dalam melakukan klasifikasi multikelas pada setiap kategori tingkat kecanduan media sosial.

Selain itu, hasil *confusion matrix* memperlihatkan bahwa kesalahan klasifikasi yang dihasilkan oleh kedua model tergolong rendah. Hasil perbandingan antarmodel menunjukkan bahwa Random Forest dan XGBoost memiliki kinerja yang sama-sama baik dalam mengklasifikasikan tingkat kecanduan media sosial. Ditinjau dari hasil *10-fold cross-validation*, XGBoost memperlihatkan tingkat stabilitas yang sedikit lebih unggul melalui nilai standar deviasi yang lebih rendah (0.0253), sedangkan Random Forest menunjukkan kecenderungan generalisasi yang lebih baik melalui nilai *generalization gap* yang lebih rendah (0.0248). Dengan mempertimbangkan aspek akurasi dan generalisasi model, skenario pembagian data 80:20 dapat dinilai sebagai pilihan yang paling sesuai bagi kedua model.

Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada Program Studi Sarjana Sains Data Universitas Negeri Surabaya serta seluruh pihak yang telah memberikan dukungan dan masukan selama pelaksanaan penelitian ini.

Daftar Pustaka

- Anjani, A. F., Anggraeni, D., dan Tirta, I. M. (2023). Implementasi random forest menggunakan smote untuk analisis sentimen ulasan aplikasi sister for students unej. *Jurnal Nasional Teknologi dan Sistem Informasi*, 9(2):163–172.
- Baker, H., Hollowell, M. R., dan Tixier, A. J.-P. (2020). Ai-based prediction of independent construction safety outcomes from universal attributes. *Automation in Construction*, 118:103146.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1):5–32.
- Context Dergi (2024). Dijital Çağın sessiz tehdidi: Brainrot. Erişim Tarihi: 15 Ocak 2026.
- Digital Wellness Lab (2024). Family guide to problematic interactive media use (pimu). [urlhttps://digitalwellnesslab.org/family-guides/family-guide-to-problematic-interactive-media-use-pimu/](https://digitalwellnesslab.org/family-guides/family-guide-to-problematic-interactive-media-use-pimu/). Accessed: 2026-01-13.
- Dinata, R. K., Hasdyna, N., dan Alif, M. (2021). Applied of information gain algorithm for culinary recommendation system in lhokseumawe. *Journal of Informatics and Telecommunication Engineering*, 5(1).
- Drakel, W. J., Pratiknjo, M. H., dan Mulianti, T. (2018). Perilaku mahasiswa dalam menggunakan media sosial di universitas sam ratulangi manado. *HOLISTIK, Journal of Social and Culture*.
- Ehsan, T. dan Basit, J. (2024). Machine learning for detecting social media addiction patterns: Analyzing user behavior and mental health data. *International Journal of Innovations in Science and Technology*, 6:1789–1807.
- Han, J., Kamber, M., dan Pei, J. (2011). *Data Mining: Concepts and Techniques*. Morgan Kaufmann, Waltham, MA, 3 edition.
- Izhari, F. (2025). Pemodelan perilaku penggunaan media sosial mahasiswa dengan algoritma xgboost. *Jurnal Minfo Polgan*, 14(1):1303–1308.
- Kahlout, K. M. dan Ekler, P. (2021). Algorithmic splitting: A method for dataset preparation. *IEEE Access*, 9:125229–125237.
- Kemp, S. (2023). Digital 2023: Global overview report. DataReportal. In partnership with Meltwater and We Are Social.
- Khalaf, A. M., Alubied, A. A., Khalaf, A. M., dan Rifaey, A. A. (2023). The impact of social media on the mental health of adolescents and young adults: A systematic review. *Cureus*, 15(8):e42990.
- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. In *Proceedings of the Fourteenth International Joint Conference on Artificial Intelligence*, pages 1137–1145.
- Lee, J. dan Kim, W. (2021). Prediction of problematic smartphone use: A machine learning approach. *International Journal of Environmental Research and Public Health*, 18(12).
- Loreggia, A., Passarelli, A., dan Pini, M. S. (2021). The effects of air quality on the spread of the COVID-19 pandemic in Italy: An artificial intelligence approach. *arXiv preprint arXiv:2104.12546*.
- Nugroho, A. (2022). Analisa splitting criteria pada decision tree dan random forest untuk

- klasifikasi evaluasi kendaraan. *JSITIK: Jurnal Sistem Informasi dan Teknologi Informasi Komputer*, 1:41–49.
- Oxford University Press (2024). 'brain rot' named oxford word of the year 2024. url<https://corp.oup.com/news/brain-rot-named-oxford-word-of-the-year-2024/>. Accessed: 2026-01-13.
- Pekar, A., Plny, R., dan Hynek, K. (2026). Tutorial on flow-based network traffic classification using machine learning. Under review.
- Salam Patrous, Z. (2018). Evaluating xgboost for user classification by using behavioral features extracted from smartphone sensors.
- Shalash, R. J., Arumugam, A., Qadah, R. M., dan Al-Sharman, A. (2024). Night screen time is associated with cognitive function in healthy young adults: A cross-sectional study. *Journal of Multidisciplinary Healthcare*, 17:2093–2104.
- Shamim, A. (2025). Students' social media addiction: A cross-country survey of usage patterns, academic impact, and relationship. <https://www.kaggle.com/datasets/adilshamim8/social-media-addiction-vs-relationships>. Kaggle dataset, CC BY 4.0.
- Syukron, M., Santoso, R., dan Widiharih, T. (2020). Perbandingan metode smote random forest dan smote xgboost untuk klasifikasi tingkat penyakit hepatitis c pada imbalance class data. *Jurnal Gaussian*, 9(3):227–236.
- Tharwat, A. (2020). Classification assessment methods. *Applied Computing and Informatics*, 17(1):168–192.
- Valdenegro-Toro, M. dan Sabatelli, M. (2022). Machine learning students overfit to overfitting. *Proceedings of the 2nd Teaching in Machine Learning Workshop*.
- Yazgan, A. M. (2025). The problem of the century: Brain rot. *OPUS Journal of Society Research*, 22(2):211–221.