

Klasifikasi Tingkat Kecanduan Media Sosial Mahasiswa Menggunakan Algoritma KNN

Classification of Students' Social Media Addiction Levels Using the K-Nearest Neighbor Algorithm

Daniela Ardiansyah¹, Dewi Yanti Arne², Putria Ningsih³

^{1,2,3}Program Studi S1 Teknik Informatika, Fakultas Teknik, Universitas Papua

E-mail : danielaardiansyah13@gmail.com*¹, dewiyantiarne@gmail.com²

ptriangsh036@gmail.com³

*Corresponding author

Received 6 May 2026; Revised 18 May 2026; Accepted 21 May 2026

Abstrak – Keterlibatan mahasiswa dengan media sosial telah meningkat secara signifikan dan kini menjadi aktivitas sehari-hari mereka. Namun, penggunaan berlebihan dan keterlibatan yang tidak menentu dapat mengakibatkan beberapa dampak negatif, seperti berkurangnya fokus saat belajar dan kualitas tidur yang buruk. Hal ini menyoroti pentingnya strategi yang dapat secara objektif menilai tingkat ketergantungan media sosial. Pendekatan ini menerapkan algoritma K-Nearest Neighbor (KNN) dalam mengkategorikan tingkat kecanduan di kalangan mahasiswa berdasarkan karakteristik data yang sama. Data yang digunakan berasal dari sumber sekunder di Kaggle, yang menampilkan variabel seperti waktu penggunaan, frekuensi akses, kualitas tidur, dan tingkat perhatian selama sesi belajar. Metodologi ini mencakup langkah-langkah seperti pembersihan data, normalisasi melalui teknik StandarScaler (Z-Score Standardization), membagi data menjadi set pelatihan dan pengujian, dan klasifikasi menggunakan berbagai skenario nilai K. Temuan menunjukkan bahwa metode yang digunakan mencapai hasil klasifikasi yang cukup andal dalam menilai tingkat kecanduan mahasiswa terhadap platform media sosial. Hasil ini menekankan bahwa pendekatan yang berfokus pada data dapat berfungsi sebagai dasar untuk memahami dan mengatasi efek negatif yang terkait dengan penggunaan media daring.

Kata Kunci - Kecanduan Media Sosial, Mahasiswa, Klasifikasi Data, K-Nearest Neighbor, Analisis Data

Abstract - The Student engagement with social media has increased significantly and has now become part of their daily activities. However, excessive and inconsistent use may lead to several negative impacts, such as reduced focus during learning activities and poor sleep quality. This highlights the importance of strategies that can objectively assess the level of social media dependence. This approach applies the K-Nearest Neighbor (KNN) algorithm to categorize the level of addiction among students based on similar data characteristics. The data used in this study is obtained from a secondary source on Kaggle, featuring variables such as usage time, access frequency, sleep quality, and attention level during study sessions. The methodology includes several steps, such as data cleaning, normalization using the StandardScaler (Z-Score Standardization) technique, splitting the dataset into training and testing sets, and classification using various K value scenarios. The findings indicate that the proposed method achieves a fairly reliable classification performance in assessing students' level of addiction to social media platforms. These results emphasize that a data-driven approach can serve as a foundation for understanding and addressing the negative effects associated with online media usage.

Keywords - Social Media Addiction, Students, Data Classification, K-Nearest Neighbor, Data Analysis

1. PENDAHULUAN

Kemajuan yang cepat dalam sektor teknologi digital yang pesat bisa mengakibatkan perubahan besar di kehidupan masyarakat, terutama dalam seorang individu berinteraksi dan mengakses informasi. Salah satu efek nyata dari kemajuan tersebut adalah bertambahnya aktivitas penggunaan media sosial oleh pelajar. Media daring bukan hanya dipakai menjadi alat komunikasi, namun juga untuk sarana hiburan, berbagi berita, serta mendukung kegiatan akademik. Tetapi, meskipun ada kemudahan yang diberikan, penggunaan media sosial yang berlebihan juga memunculkan berbagai masalah. Frekuensi penggunaan yang tinggi dapat mengakibatkan penurunan fokus dalam belajar, terganggunya pola tidur, serta berkurangnya produktivitas akademik mahasiswa. Kondisi ini berpotensi mengarah pada ketergantungan media sosial yang mempengaruhi kesejahteraan dan mutu pembelajaran.

Beberapa penelitian yang telah dilakukan sebelumnya mengindikasikan bahwa kecanduan media sosial memiliki hubungan yang signifikan dengan menurunnya prestasi akademik serta perubahan sikap di kalangan mahasiswa [1], [2]. Di samping itu, pemakaian media daring secara berlebihan juga berkaitan dengan rendahnya kemampuan manajemen waktu serta meningkatnya distraksi dalam proses belajar[3]. Kondisi ini menandakan bahwa permasalahan kecanduan media daring perlu dianalisis secara lebih sistematis dengan memanfaatkan pendekatan berbasis data. Seiring dengan berkembangnya teknologi pengolahan data, teknik data mining merupakan suatu metode yang banyak digunakan untuk menganalisis kecenderungan perilaku pengguna[4]. Melalui teknik ini, data yang besar dapat diolah untuk menemukan informasi yang relevan, termasuk dalam mengklasifikasikan tingkat kecanduan media sosial berdasarkan karakteristik tertentu. Metode yang diterapkan dalam tahapan pengelompokan adalah K-Nearest Neighbor (KNN). Metode ini bekerja dengan teknik mengklasifikasi kesamaan di antara data, dengan demikian mampu mengidentifikasi kategori tertentu secara efektif. Beberapa studi membuktikan bahwa metode KNN mempunyai kinerja yang baik dalam proses klasifikasi data berbasis perilaku[5].

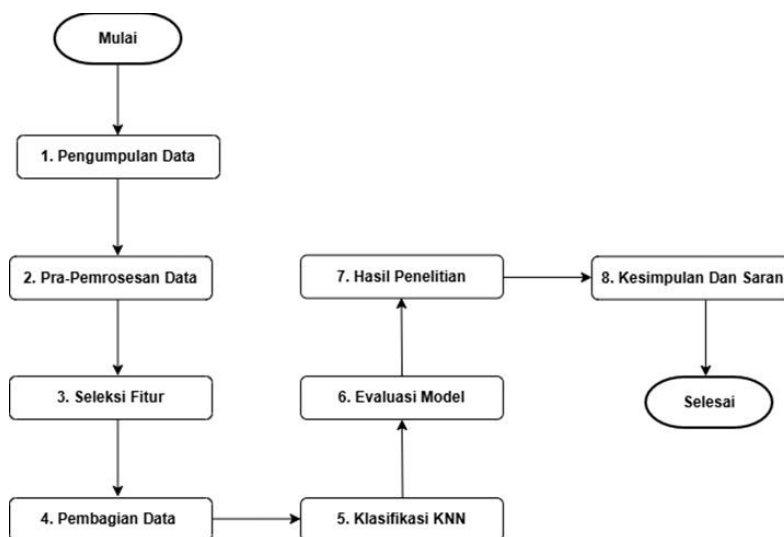
Sejumlah penelitian terdahulu telah berupaya mengkaji permasalahan kecanduan media sosial dari berbagai sudut pandang. Sutrisni et al. [1] menggunakan K-Means dan Decision Tree untuk menganalisis dampak kecanduan media sosial terhadap performa akademik mahasiswa dan menemukan adanya pola perilaku yang berkaitan dengan penurunan prestasi. Wahyudi dan Ruziq [5] menerapkan algoritma KNN untuk memprediksi tingkat kecanduan smartphone berdasarkan pola perilaku pengguna dan berhasil mencapai akurasi 95%, meskipun penelitian tersebut berfokus pada perangkat smartphone secara umum, bukan pada platform media sosial secara spesifik. Tegar et al. [6] mengembangkan aplikasi prediksi kecanduan media sosial berbasis Random Forest dan Streamlit yang mengintegrasikan variabel jam penggunaan harian, skor kesehatan mental, dan konflik akibat media sosial, dengan nilai R² yang sangat tinggi sebesar 0,9903. Di sisi lain, Rahadjeng et al. [7] mengembangkan model hybrid dua tahap menggunakan K-Means dan Support Vector Machine (SVM) pada dataset yang sama dari Kaggle untuk mengklasifikasikan dampak kecanduan media sosial mahasiswa sebagai system peringatan dini, dengan akurasi SVM mencapai 93,62%. Mahdi [2] melakukan studi tentang efek kecanduan media sosial terhadap kesejahteraan psikologi siswa sekolah menengah serta memperoleh hubungan negatif yang signifikan terhadap intensitas penggunaan media sosial dan kondisi mental secara keseluruhan. Agustian et al. [3] mengidentifikasi bahwa kecanduan media sosial berpengaruh langsung terhadap rendahnya manajemen waktu dan menurunnya prestasi akademik mahasiswa. Sementara itu, kajian yang dilakukan Ehsan et al. [8] menggunakan pendekatan machine learning untuk memprediksi kecanduan media sosial selama masa pandemi COVID-19 dan menyimpulkan bahwa variabel perilaku digital dapat dijadikan predictor yang handal. Salari et al. [9] dalam meta-analisis global mereka menegaskan bahwa kecanduan jejaring sosial secara konsisten berdampak negative terhadap prestasi akademik mahasiswa di berbagai negara. Ma et al. [10], Sahrañç et al. [11] menemukan bahwa kecanduan media sosial menurunkan kemampuan pengendalian diri mahasiswa sehingga berdampak pada hasil akademik yang lebih buruk. Lebih

lanjut, Abdulla et al. [12] menyoroti bahwa kualitas tidur yang buruk akibat penggunaan media sosial yang berlebihan memiliki kaitan erat dengan gangguan konsentrasi belajar. Penelitian Zhuang et al. [13] juga menemukan bahwa kecanduan media sosial berhubungan tidak langsung dengan keterlibatan akademik mahasiswa melalui mediasi kualitas tidur dan kelelahan. Meskipun berbagai metode telah digunakan dalam penelitian sebelumnya, kajian mengenai klasifikasi tingkat kecanduan media sosial mahasiswa dengan memanfaatkan beberapa variabel perilaku secara terintegrasi masih terbatas [5], [6]. Sebagian besar penelitian yang ada juga belum secara eksplisit membandingkan pengaruh nilai parameter K terhadap kinerja klasifikasi, serta belum mengevaluasi ketidakseimbangan distribusi kelas yang kerap terjadi pada data perilaku mahasiswa. Selain itu, studi yang mengintegrasikan variabel kualitas tidur, skor kesehatan mental, dan konflik akibat media sosial secara bersamaan dalam satu model klasifikasi berbasis KNN masih sangat jarang dilakukan. Kesenjangan tersebut menjadi dasar penelitian ini dilakukan. Oleh karena itu, penelitian ini menawarkan pendekatan klasifikasi menggunakan metode KNN dengan mempertimbangkan kombinasi variabel perilaku yang lebih komprehensif, sehingga diharapkan menghasilkan klasifikasi yang lebih representatif dan dapat digunakan sebagai dasar intervensi berbasis data bagi institusi pendidikan.

Analisis ini memiliki tujuan untuk mengklasifikasikan tingkat ketergantungan media daring pada mahasiswa berdasarkan data perilaku penggunaan, serta mengevaluasi kinerja metode KNN dalam menghasilkan klasifikasi yang akurat. Hasil analisis ini diharapkan menghasilkan gambaran yang lebih mendalam mengenai pola penggunaan media daring serta menjadi dasar untuk upaya mengurangi dampak negatif yang ditimbulkan.

2. METODE PENELITIAN

Algoritma K-Nearest Neighbor (KNN) diterapkan dalam penelitian ini untuk mengklasifikasikan tingkat kecanduan media sosial mahasiswa berdasarkan data perilaku penggunaan. Alur penelitian dilakukan melalui beberapa tahapan, yaitu pengumpulan data, pra-pemrosesan data, pembagian data, klasifikasi menggunakan KNN, dan evaluasi model, sebagaimana diilustrasikan pada Gambar 1.



Gambar 1 Alur Penelitian

2.1 Pengumpulan Data

Data pada analisis dalam kajian ini yaitu kumpulan data sekunder yang didapatkan dari platform Kaggle dengan judul "Students Social Media Addiction". Dataset ini dipilih karena relevan dengan topik penelitian dan tersedia secara publik untuk keperluan akademik [14]. Dataset terdiri dari 705 record dengan 13 atribut, meliputi usia (Age), jenis kelamin (Gender), jenjang

pendidikan (*Academic_Level*), negara asal (*Country*), rata-rata jam penggunaan media sosial per hari (*Avg_Daily_Usage_Hours*), platform yang paling sering dipakai (*Most_Used_Platform*), pengaruh terhadap performa akademik (*Affects_Academic_Performance*), jam tidur per malam (*Sleep_Hours_Per_Night*), skor kesehatan mental (*Mental_Health_Score*), status hubungan (*Relationship_Status*), dan jumlah konflik akibat media sosial (*Conflicts_Over_Social_Media*). Atribut target yang digunakan sebagai label klasifikasi adalah *Addicted_Score* dengan rentang nilai 1 hingga 10, yang kemudian dikonversi menjadi tiga kategori tingkat kecanduan yaitu Rendah (1–3), Menengah (4–6), dan Tinggi (7–10).

2.2 Pra-Pemrosesan Data

Langkah awal sebelum proses data bertujuan guna menjamin data berkualitas baik sebelum dimasukkan ke dalam model[4]. Proses ini mencakup pemeriksaan dan pengelolaan nilai yang hilang (*missing values*), menghapus data duplikat, serta konversi atribut *Addicted_Score* dibagi menjadi tiga kategori yaitu Rendah (skor 1–3), Menengah (skor 4–6), dan Tinggi (skor 7–10)[15]. Selain itu, label encoding digunakan untuk mengubah atribut kategorikal seperti gender, *academic_level*, dan *dampak_akademik_prestasi* menjadi nilai numerik.

Kemudian proses normalisasi data menggunakan metode *StandardScaler* atau *Z-Score Standardization*. Untuk menyamakan skala setiap fitur numerik agar memiliki rata-rata mendekati 0 dan standar deviasi sebesar 1. Normalisasi ini penting karena algoritma *K-Nearest Neighbor* (KNN) sensitif terhadap perbedaan skala data antar fitur. Persamaan *Standard Scaling* ditunjukkan sebagai berikut:

$$Z = \frac{x - \mu}{\sigma}$$

2.3 Seleksi Fitur

Tidak semua atribut dalam dataset digunakan sebagai fitur klasifikasi. Atribut *Student_ID* dan *Country* dihapus karena tidak relevan secara analitis. Atribut *Most_Used_Platform* dan *Relationship_Status* juga tidak diikutsertakan karena bersifat nominal dengan banyak kategori yang tidak berkontribusi signifikan terhadap klasifikasi[4]. Fitur yang digunakan dalam proses klasifikasi meliputi durasi penggunaan media daring harian, jam tidur per malam, skor kesehatan mental, jumlah konflik akibat media sosial, dan pengaruh penggunaan media sosial terhadap performa akademik.

2.4 Pembagian Data

Dataset dibagi menggunakan metode holdout dengan perbandingan 80% data Latihan sejumlah 564 record serta 20% data pengujian sejumlah 141 record. Proses Pengelompokan diterapkan secara acak sambil mempertahankan distribusi kelas yang proporsional pada kedua subset (*stratified split*)[4].

2.5 Klasifikasi Menggunakan Algoritma KNN

K-Nearest Neighbor (KNN) termasuk metode klasifikasi berbasis pada instance, di mana data uji ditentukan menurut label terbanyak dari *K* tetangga terdekat[14]. Jarak antar data diukur dengan menggunakan persamaan *Euclidean Distance*:

$$d(x, y) = \sqrt{\sum (x_i - y_i)^2}$$

Dalam penelitian ini dilakukan percobaan dengan variasi nilai *K* = 3, 5, 7, dan 9 untuk menentukan nilai *K* yang menghasilkan akurasi terbaik.

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

3.1.1 Pengumpulan Data dari Kaggle

Kumpulan data sekunder yang diambil dari platform Kaggle dengan judul "**Students Social Media Addiction**" digunakan dalam studi ini, yang terdiri dari 705 data dengan total 13

atribut yang berisi informasi terkait perilaku penggunaan media sosial. Dataset dapat diakses secara publik melalui situs kaggle.com. Dalam penelitian ini hanya digunakan 5 atribut utama yang dianggap relevan terhadap proses klasifikasi, yaitu rata-rata waktu pemakaian media daring harian (*Avg_Daily_Usage_Hours*), jumlah jam tidur per malam (*Sleep_Hours_Per_Night*), skor kesehatan mental (*Mental_Health_Score*), jumlah konflik akibat media sosial (*Conflicts_Over_Social_Media*), serta tingkat kecanduan (*Addicted_Score*) sebagai variabel target. Pemilihan atribut tersebut didasarkan pada keterkaitannya dengan tingkat kecanduan media sosial [5], [6], sehingga diharapkan dapat meningkatkan akurasi dalam mengklasifikasikan data melalui penerapan algoritma *K-Nearest Neighbor* (KNN).

3.2 Pra Pemrosesan Data

Tahap Pra pemrosesan data yaitu fase awal yang utama dalam analisis sebelum pengolahan dilakukan pemodelan menggunakan algoritma klasifikasi. Fokus utama dari tahap ini yaitu untuk memperbaiki kualitas data agar lebih bersih, konsisten, dan siap dipakai pada proses pembelajaran mesin, sehingga bisa menghasilkan algoritma yang lebih akurat dan reliabel [16].

3.2.1 Seleksi Atribut

Seleksi atribut dipakai untuk memilih fitur yang penting sehingga proses pengelompokan dapat menghasilkan kinerja model dan menyederhanakan kerumitan data. Atribut yang digunakan dalam penelitian ini meliputi *Avg_Daily_Usage_Hours*, *Sleep_Hours_Per_Night*, *Mental_Health_Score*, dan *Conflicts_Over_Social_Media* sebagai variabel independen, serta *Addicted_Score* sebagai variabel target.

Tahap ini dilakukan untuk menghindari penggunaan atribut yang tidak terkait sehingga hasil yang digunakan semakin representatif. Hasil seleksi atribut direduksi menjadi lima atribut utama yang digunakan pada tahap selanjutnya.

3.2.2 Cleaning Data

Proses *data cleaning* diterapkan sebelum data digunakan untuk pemodelan, proses pembersihan data dilakukan untuk memastikan kualitas data. Proses pembersihan termasuk pemeriksaan nilai kosong (*missing values*), penghapusan data yang memiliki nilai kosong, serta penghapusan data duplikat.

Tabel 1 Cleaning Data

| Keterangan | Sebelum Cleaning | Sesudah Cleaning |
|---------------|------------------|------------------|
| Jumlah Data | 705 | 528 |
| Missing Value | 0 | 0 |
| Data Duplikat | 177 | 0 |

Berdasarkan pada tabel 1, seluruh atribut menunjukkan nilai 0, yang berarti tidak terdapat *missing values* sehingga tidak diperlukan proses penghapusan data kosong. Selanjutnya, dilakukan penghapusan data duplikat menggunakan fungsi `drop_duplicates()` untuk menghindari redundansi data. Hasilnya, jumlah data berkurang dari 705 record menjadi 528 record, sementara jumlah atribut tetap sebanyak 5 kolom. Dengan demikian, dataset yang digunakan telah bersih dan siap untuk tahap selanjutnya.

3.2.3 Target Transformasi

Transformasi target dilakukan untuk mengubah variabel *Addicted_Score* yang semula berbentuk numerik menjadi kategori kelas. Proses ini bertujuan untuk menyesuaikan data dengan kebutuhan metode klasifikasi yang digunakan.

Dalam penelitian ini, variabel *Addicted_Score* yang semula berupa data numerik dengan rentang nilai 1–10 ditransformasikan menjadi tiga kategori kelas, yaitu rendah (≤ 3), sedang (4–

6), dan tinggi (≥ 7). Proses transformasi dilakukan dengan menggunakan fungsi pemetaan untuk mengelompokkan setiap nilai ke dalam kategori yang sesuai berdasarkan interval yang telah ditentukan. Perubahan ini bertujuan untuk mengubah permasalahan dari prediksi numerik menjadi klasifikasi multikelas, sehingga sesuai dengan penerapan algoritma K-Nearest Neighbor (KNN), dimana variabel target telah berbentuk kategorikal dan siap digunakan dalam proses klasifikasi.

3.2.4 Encoding Label

Tahap encoding label dilakukan untuk mentransformasikan data berbentuk kategorikal ke dalam bentuk angka agar dapat dianalisis oleh algoritma *K-Nearest Neighbor* (KNN), yang berbasis pada perhitungan jarak antar data. Variabel yang dilakukan proses encoding pada penelitian ini adalah atribut Kategori, yang sebelumnya berbentuk teks hasil dari proses transformasi target. Proses encoding dilakukan menggunakan metode *Label Encoding* dengan bantuan pustaka *scikit-learn*, yaitu melalui fungsi `LabelEncoder()`. Metode ini mengubah setiap kategori unik menjadi bilangan bulat dengan cara sistematis.

Tabel 2 Encoding Label

| <u>Avg_Daily_Usage_Hours</u> | <u>Sleep_Hours_Per_Night</u> | <u>Mental_Health_Score</u> | <u>Conflicts_Over_Social_Media</u> | <u>Kategori</u> |
|------------------------------|------------------------------|----------------------------|------------------------------------|-----------------|
| 5.2 | 6.5 | 6 | 3 | 2 |
| 2.1 | 7.5 | 8 | 0 | 0 |
| 6.0 | 5.0 | 5 | 4 | 2 |
| 3.0 | 7.0 | 7 | 1 | 1 |
| 4.5 | 6.0 | 6 | 2 | 1 |

Berdasarkan tabel 2, kategori *rendah*, *sedang*, dan *tinggi* masing-masing direpresentasikan menjadi nilai 0, 1, dan 2. Perubahan ini mempertahankan informasi kelas dalam bentuk yang lebih terstruktur dan dapat diolah secara komputasional. Selain itu, atribut lainnya seperti *Avg_Daily_Usage_Hours*, *Sleep_Hours_Per_Night*, *Mental_Health_Score*, dan *Conflicts_Over_Social_Media* telah berbentuk numerik, sehingga tidak memerlukan proses encoding tambahan. Dengan demikian, seluruh dataset yang terdapat dalam format numerik yang konsisten dan siap digunakan pada tahap pemodelan KNN.

3.2.5 Pisahkan Fitur dan Target

Tahap pemisahan fitur dan target merupakan bagian penting dalam proses pra-pemodelan untuk mempersiapkan data sebelum diterapkan algoritma klasifikasi. Fase ini membagi dataset menjadi dua komponen yaitu *variable independent* (fitur) dan *variable deependen* (target). Pemisahan ini bertujuan agar sistem mampu mempelajari keterkaitan atribut masukan dan label yang akan diprediksi.

Proses pemisahan dilakukan dengan menghapus atribut kategori dari dataset untuk membentuk variabel X sebagai data fitur, sedangkan atribut Kategori digunakan sebagai variabel y sebagai target. Hasilnya menunjukkan bahwa X berisi atribut *Avg_Daily_Usage_Hours*, *Sleep_Hours_Per_Night*, *Mental_Health_Score*, dan *Conflicts_Over_Social_Media*, sementara y berisi label kategori yang telah melalui proses encoding. Dengan demikian, data telah terstruktur dengan baik sehingga dapat diterapkan pada proses pemodelan melalui algoritma klasifikasi.

3.2.6 Normalisasi Data

Proses normalisasi data berfungsi untuk menyetarakan skala antar atribut sehingga tidak terjadi ketimpangan nilai pada fitur tertentu dalam proses perhitungan jarak. Tahap ini mempunyai peran penting dalam algoritma kategorisasi seperti *K-Nearest Neighbor* (KNN) yang sensitif terhadap perbedaan skala data.

Tabel 3 Normalisasi Data

| Avg_Daily_Usage_Hours | Sleep_Hours_Per_Night | Mental_Health_Score | Conflicts_Over_Social_Media |
|-----------------------|-----------------------|---------------------|-----------------------------|
| 0.2058 | -0.2583 | -0.1682 | 0.1351 |
| -2.1798 | 0.5847 | 1.6085 | -2.9213 |
| 0.8214 | -1.5228 | -1.0566 | 1.1538 |
| -1.4872 | 0.1632 | 0.7201 | -1.9025 |
| -0.3329 | -0.6798 | -0.1682 | -0.8837 |

Berdasarkan output pemrosesan data yang pada tabel 3, metode *StandardScaler* digunakan untuk normalisasi data. Ini mengubah data sehingga rata-ratanya mendekati 0 dan standar deviasinya sebesar 1. Hasil transformasi ditunjukkan dalam bentuk nilai numerik baru pada variabel X_{scaled} , dimana setiap atribut telah berada pada skala yang sebanding. Dengan demikian, data yang telah dinormalisasi siap digunakan pada tahap pemodelan menggunakan algoritma KNN.

3.3 Penerapan Algoritma K-Nearest Neighbor (KNN)

Penerapan algoritma *K-Nearest Neighbor* (KNN) dilakukan buat mengklasifikasikan tingkat kecanduan media sosial mahasiswa berdasarkan kemiripan karakteristik data. Algoritma dibangun menggunakan data fitur yang telah melalui tahap pre-processing, termasuk encoding dan normalisasi.

3.3.1 Data Split

Melalui tahap data *splitting*, dataset dikelompokkan ke dalam kategori *training* dan *testing*. Pemisahan ini berfungsi dalam pelatihan model pada sekumpulan data tertentu, lalu pengujian kinerjanya pada sisa data yang belum dikenali oleh model untuk memastikan akurasi yang lebih valid.

Tabel 4 Data Split

| Dataset | Jumlah | Persentase |
|------------|--------|------------|
| Data Latih | 422 | 80% |
| Data Uji | 106 | 20% |

Mengacu pada output pemrosesan data yang ditampilkan pada tabel 4 tersebut, dataset dibagi menggunakan fungsi *train_test_split* dengan komposisi 80% sebagai data latihan dan 20% guna pengujian (*test_size = 0.2*). Hasilnya menunjukkan bahwa data latihan (X_{train}) berjumlah 422 data dengan 4 atribut, sedangkan data uji (X_{test}) berjumlah 106 data dengan 4 atribut. Pembagian ini terdapat proses pengacakan data menggunakan parameter *random_state = 42* agar hasil yang diperoleh tetap konsisten. Oleh karena itu, dataset telah siap dipakai untuk fase pelatihan dan pengujian model KNN.

3.3.2 Model KNN

Tahap pembentukan sistem dilakukan untuk mengimplementasikan penerapan *K-Nearest Neighbor* (KNN) dalam tahap pengelompokan data berdasarkan data latihan yang sudah disiapkan. Tahapan ini bertujuan agar model dapat mengidentifikasi pola serta keterkaitan antara variabel fitur dan label kelas.

Model KNN diinisialisasi menggunakan fungsi *K-NeighborsClassifier* dengan parameter *n_neighbors = 5*, yang menunjukkan bahwa proses klasifikasi didasarkan pada 5 tetangga terdekat. Selanjutnya, model pelatihan memakai data latihan melalui fungsi *fit(X_train, y_train)*. Hasil yang diperoleh menunjukkan bahwa proses pelatihan berjalan dengan baik tanpa adanya

kesalahan. Dengan demikian, model yang sudah terbentuk siap dipakai untuk memprediksi data uji.

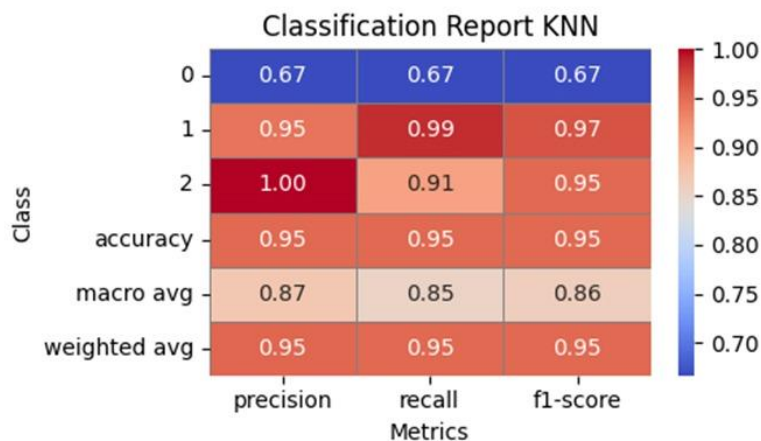
3.3.3 Prediksi

Tahap prediksi dilakukan untuk menguji kinerja algoritma K-Nearest Neighbor (KNN) dalam mengelompokkan data yang belum dipakai. tahap ini memanfaatkan data pengujian (*testing data*) yang sebelumnya sudah dipisahkan.

Hasil prediksi menunjukkan adanya perbandingan antara nilai sebenarnya (*Actual*) dan hasil klasifikasi (*Predicted*) dari sistem KNN terhadap sebagian data uji. Sebagian besar hasil prediksi memiliki kesesuaian dengan nilai sebenarnya, yang menandakan bahwa sistem dapat melakukan klasifikasi dengan optimal. Perbandingan ini digunakan sebagai gambaran awal terhadap performa sistem sebelum dilakukan pengujian lebih lanjut melalui penerapan metrik seperti akurasi, *confusion matrix*, dan *classification report*.

3.4 Evaluasi Model

Tahap evaluasi model bertujuan agar dapat mengetahui kinerja algoritma *K-Nearest Neighbor* (KNN) dalam mengelompokkan tingkat kecanduan media sosial. Evaluasi dilakukan memakai metrik akurasi, *confusion matrix*, serta *classification report* yang meliputi nilai *precision*, *recall*, dan *f1-score*.



Gambar 2 Model Evaluasi

Output pada Gambar tersebut menandakan bahwa sistem tersebut mencapai nilai akurasi sebesar 0,9528 atau sekitar 95,28%, yang mengindikasikan tingkat ketepatan klasifikasi yang tinggi. *Confusion matrix* memperlihatkan bahwa sebagian besar data dapat dikelompokkan secara tepat, dengan benar, namun masih terdapat beberapa kesalahan klasifikasi pada masing-masing kelas. Selain itu, *classification report* menunjukkan bahwa kelas 1 dan 2 memiliki nilai *precision*, *recall*, dan *f1-score* yang tinggi, sedangkan kelas 0 memiliki nilai yang lebih rendah akibat jumlah data yang relatif sedikit. Berdasarkan hasil evaluasi, secara umum menunjukkan bahwa sistem KNN mempunyai kinerja yang bagus serta mampu mengklasifikasikan dengan tingkat akurasi lebih tinggi.

3.4.1 Pengujian Variasi Nilai K

Uji variasi nilai K dilaksanakan guna menganalisis dampak parameter K pada performa penerapan *K-Nearest Neighbor* (KNN) ketika proses pengelompokan. Nilai K menentukan banyaknya tetangga terdekat yang digunakan sebagai dasar dalam pengambilan keputusan kelas.

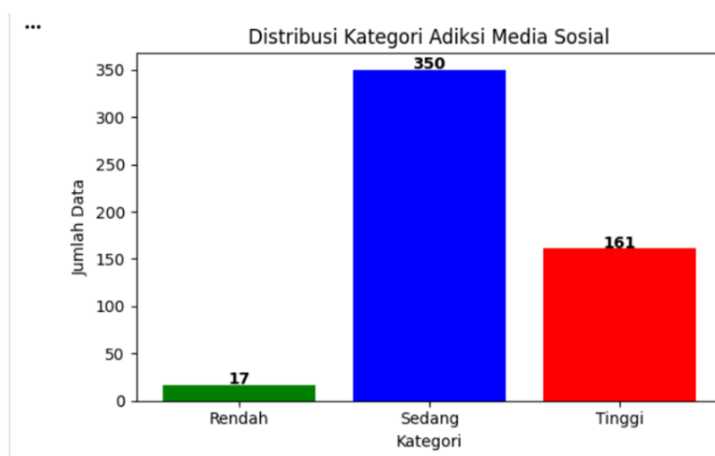
Tabel 5 Pengujian Variasi Nilai K

| Nilai K | Akurasi |
|---------|---------|
| 3 | 0.9433 |
| 5 | 0.9528 |
| 7 | 0.9622 |
| 9 | 0.9622 |

Hasil pengujian yang ditampilkan pada Gambar tersebut menunjukkan penggunaan beberapa nilai K, yaitu 3, 5, 7, dan 9. Setiap nilai K menghasilkan tingkat akurasi yang berbeda, dimana K = 3 menghasilkan akurasi sebesar 0,9433, K = 5 sebesar 0,9528, serta K = 7 dan K = 9 masing-masing menghasilkan akurasi tertinggi sebesar 0,9622. Hasil ini menunjukkan bahwa peningkatan nilai K cenderung memberikan performa yang lebih baik hingga mencapai titik optimal. Dengan demikian, nilai K terbaik pada penelitian yang dilakukan yaitu 7 atau 9, karena mampu menghasilkan tingkat akurasi tertinggi.

3.4.2 Distribusi Kategori Tingkat Kecanduan Media Sosial

Visualisasi distribusi data dilakukan untuk mengetahui proporsi jumlah data pada setiap kategori tingkat kecanduan media sosial. Hal ini bertujuan untuk melihat keseimbangan data (*data distribution*) yang dapat mempengaruhi kinerja model klasifikasi.



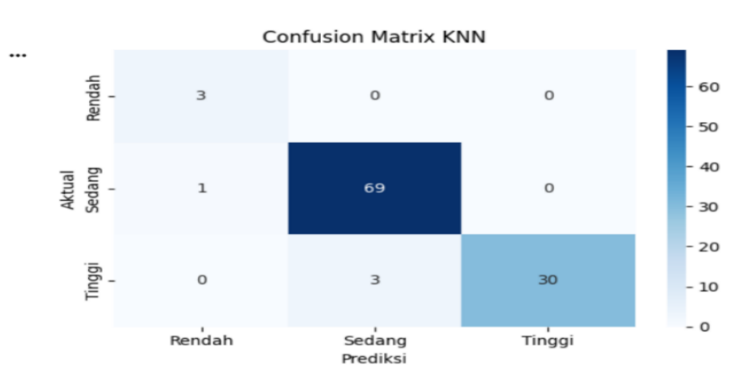
Gambar 3 Distribusi Kategori Tingkat Kecanduan Media Sosial

Hasil visualisasi pada Gambar tersebut menunjukkan bahwa kategori Sedang memiliki jumlah data terbanyak yaitu 350 data, diikuti oleh kategori Tinggi sebanyak 161 data, dan kategori Rendah sebanyak 17 data. Perbedaan jumlah data yang cukup signifikan ini menunjukkan adanya ketidakseimbangan data (*imbalanced data*), terutama pada kategori rendah yang mengandung data dalam jumlah jauh lebih sedikit dibandingkan kategori yang lain. Kondisi ini bisa mempengaruhi kinerja sistem dalam mengklasifikasikan kelas yang memiliki jumlah data yang kecil. Oleh karena itu, distribusi data ini perlu diperhatikan dalam proses analisis dan evaluasi model.

Meskipun model memperoleh tingkat akurasi yang tinggi, distribusi data yang tidak seimbang dapat mempengaruhi hasil klasifikasi. Kategori sedang mendominasi jumlah data dibandingkan kategori rendah yang hanya memiliki sedikit sampel. Kondisi ini membuat model menjadi semakin banyak mengenali pola pada kelas mayoritas sehingga potensi bias klasifikasi terhadap kelas minoritas masih dapat terjadi. Pada data pengujian, kategori rendah hanya memiliki sedikit data sehingga kemampuan model dalam mengenali kategori tersebut belum dapat dievaluasi secara optimal. Oleh karena itu, hasil penelitian ini masih memiliki keterbatasan dalam melakukan generalisasi model terhadap distribusi data yang tidak seimbang.

3.4.3 Confusion Matrix Model K-Nearest Neighbor (KNN) untuk Klasifikasi Tingkat Kecanduan Media Sosial

Analisis *confusion matrix* dilakukan untuk menilai performa sistem pengelompokan dengan menganalisis hasil klasifikasi terhadap nilai sebenarnya pada setiap kategori. Visualisasi ini memberikan gambaran detail mengenai jumlah data yang diklasifikasikan dengan benar maupun yang mengalami kesalahan klasifikasi.

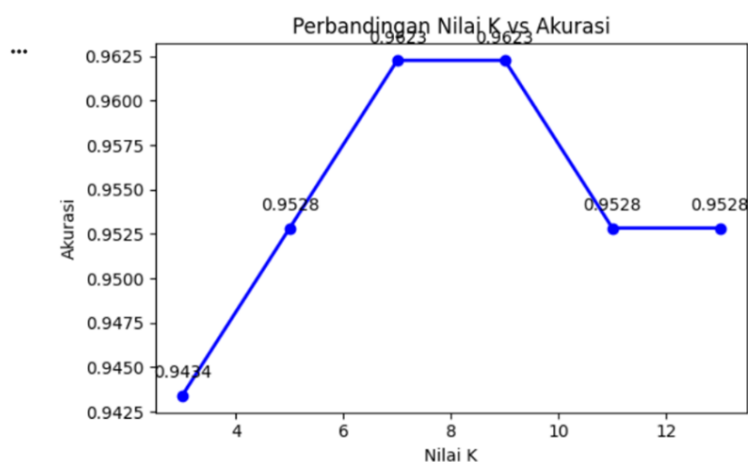


Gambar 4 Confusion Matrix

Visualisasi pada Gambar tersebut menampilkan bahwa mayoritas data telah dikelompokkan secara tepat, yang terlihat dari hasil diagonal utama. Pada kategori Rendah, seluruh data sebanyak 3 berhasil diprediksi dengan tepat. Pada kategori Sedang, sejumlah 69 data dapat dikelompokkan secara tepat, meskipun terdapat 1 data yang salah diklasifikasikan ke kategori Rendah. Di sisi lain, pada kategori Tinggi, sejumlah 30 data dapat diprediksi dengan tepat, dengan 3 data salah diklasifikasikan ke kategori Sedang. Berdasarkan keseluruhan hasil, dapat disimpulkan bahwa sistem mempunyai tingkat akurasi yang tinggi, dengan ketidaktepatan prediksi yang relatif kecil dan hanya terjadi pada beberapa data tertentu. Meskipun seluruh data kategori rendah pada data uji berhasil diklasifikasikan dengan benar, jumlah sampel yang sangat sedikit belum cukup untuk memastikan kemampuan generalisasi model secara menyeluruh.

3.4.4 Perbandingan Nilai K terhadap Akurasi pada Algoritma K-Nearest Neighbor (KNN)

Visualisasi hubungan antara nilai parameter K dan tingkat akurasi dilakukan untuk menganalisis pengaruh variasi nilai K pada kualitas penerapan *K-Nearest Neighbor* (KNN). Grafik ini membantu guna menentukan nilai K dengan optimal berdasarkan performa model.

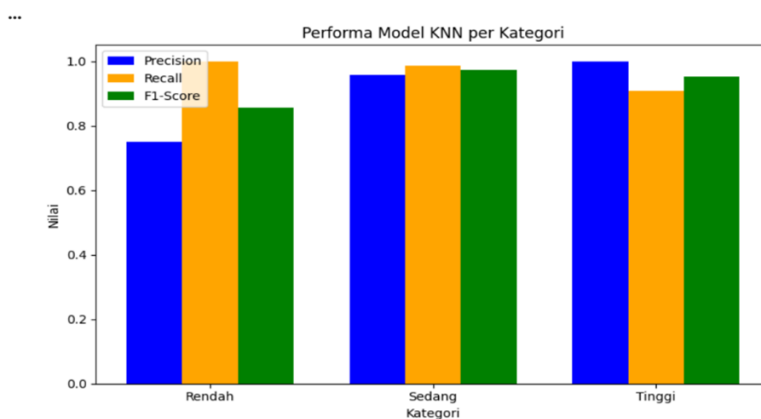


Gambar 5 Perbandingan Nilai K Terhadap Akurasi Pada Algoritma KNN

Grafik pada Gambar tersebut menunjukkan bahwa nilai akurasi meningkat seiring dengan kenaikan nilai K dari 3 ke 7, dimana akurasi mencapai nilai tertinggi sebesar 0,9623 pada K = 7 dan K = 9. Setelah itu, akurasi mengalami penurunan pada K = 11 dan K = 13 menjadi sekitar 0,9528. Sementara itu, nilai akurasi terendah terjadi pada K = 3 sebesar 0,9434. Pola ini menunjukkan bahwa pemilihan nilai K yang terlalu rendah maupun terlalu tinggi dapat berdampak terhadap kinerja model. Maka dari itu, nilai K yang optimal pada penelitian ini berada dalam kisaran 7 sampai 9, karena memberikan hasil akurasi tertinggi.

3.4.5 Performa Model K-Nearest Neighbor (KNN) Berdasarkan Metrik Precision, Recall, dan F1-Score per Kategori

Analisis performa model per kategori dilakukan untuk menilai kemampuan algoritma *K-Nearest Neighbor* (KNN) dalam mengelompokkan setiap kelas secara lebih rinci. Evaluasi ini memakai metrik *precision*, *recall*, dan *f1-score* untuk setiap kategori.



Gambar 6 Performa Model KNN

Berdasarkan Metrik Precision, Recall, dan F1-Score per Kategori visualisasi pada Gambar tersebut menunjukkan bahwa kategori Sedang dan Tinggi memiliki nilai performa yang tinggi pada seluruh metrik, dimana nilai *precision*, *recall*, dan *f1-score* mendekati 1,0, yang menunjukkan kemampuan sistem dalam mengklasifikasikan kedua kategori tersebut sangat baik. Sementara itu, pada kategori Rendah, nilai *recall* mencapai 1,0, namun nilai *precision* dan *f1-score* relatif lebih rendah daripada kategori lainnya. Kondisi ini menunjukkan dimana meskipun seluruh data kategori rendah berhasil terdeteksi, masih terdapat kesalahan prediksi yang mempengaruhi ketepatan klasifikasi.

Secara menyeluruh, temuan ini menandakan model KNN mempunyai kinerja yang memuaskan dalam mengklasifikasikan sebagian besar kategori, meskipun masih terdapat sedikit kelemahan pada kategori dengan jumlah data yang lebih kecil.

4. KESIMPULAN DAN SARAN

Penelitian ini berhasil menerapkan algoritma K-Nearest Neighbor (KNN) untuk mengklasifikasikan tingkat kecanduan media sosial mahasiswa berdasarkan karakteristik perilaku penggunaan media sosial. Proses klasifikasi dilakukan melalui beberapa tahapan, yaitu preprocessing data, transformasi target, encoding label, normalisasi data menggunakan StandardScaler, pembagian data, hingga evaluasi model.

Hasil penelitian menunjukkan bahwa algoritma KNN mampu menghasilkan performa klasifikasi yang baik dengan tingkat akurasi tertinggi sebesar 96,22% pada nilai K sebesar 7 dan 9. Nilai tersebut menunjukkan bahwa pemilihan parameter K mempengaruhi performa model

dalam proses klasifikasi. Kemudian, hasil confusion matrix dan classification report menunjukkan bahwa mayoritas data mampu diklasifikasikan secara tepat pada setiap kategori.

Meskipun demikian, penelitian ini masih memiliki keterbatasan pada distribusi data yang tidak seimbang, di mana kategori rendah memiliki jumlah data yang jauh lebih sedikit dibandingkan kategori sedang dan tinggi. Kondisi tersebut dapat mempengaruhi kemampuan model dalam mengenali pola pada kelas minoritas secara optimal. Pada data pengujian, kategori rendah hanya memiliki sedikit sampel sehingga performa model terhadap kategori tersebut belum sepenuhnya merepresentasikan kemampuan klasifikasi yang sebenarnya.

Secara keseluruhan, algoritma K-Nearest Neighbor (KNN) dapat digunakan untuk metode klasifikasi yang cukup baik dalam mengidentifikasi tingkat kecanduan media sosial mahasiswa berdasarkan data perilaku penggunaan media sosial. Untuk penelitian selanjutnya, disarankan menggunakan teknik penanganan data tidak seimbang seperti SMOTE atau class weighting guna meningkatkan performa model pada kelas minoritas.

DAFTAR PUSTAKA

- [1] D. S. Sutrisni, M. I. Alisyahbana, and M. L. Al-hakim, "Journal of Artificial Intelligence An Analysis of the Impact of Social Media Addiction on Students Academic Performance Using K-Means and Decision Tree," vol. 1, no. 1, pp. 1–10, 2025.
- [2] A. N. Mahdi, "A study of the effects of social media addiction on psychological well-being among secondary school students in Al-Emara city," *J. Med. Life Sci.*, vol. 6, no. 3, pp. 429–442, 2024, doi: 10.21608/jmals.2024.383359.
- [3] K. Agustian, H. Suherti, and R. R. S. Nurdianti, "The Effect Of Social Media Addiction and Time Management On The Learning Achievement Of Economics Education Students:(Survey on Students of the Department of Economic Education, Siliwangi University Class of 2019)," *Rev. Multidiscip. Educ. Cult. Pedagog.*, vol. 2, no. 2, pp. 64–77, 2023.
- [4] J. H. M. K. J. Pei, *Data mining: Concepts and techniques*, vol. 10, no. 559–569. 2006.
- [5] M. R. Wayahdi and F. Ruziq, "Predicting Smartphone Addiction Levels with K-Nearest Neighbors Using User Behavior Patterns"," *J. Tek. Inform.*, vol. 6, no. 5, pp. 3379–3391, 2025, doi: 10.52436/1.jutif.2025.6.5.4905.
- [6] A. T. B. S. Tegar, H. Hasanah, and I. Oktaviani, "Predicting Social Media Addiction Using Machine Learning and Interactive Visualization with Streamlit," *bit-Tech*, vol. 8, no. 1, pp. 778–788, 2025, doi: 10.32877/bt.v8i1.2715.
- [7] K. Kunci, "KLASIFIKASI DAMPAK KECANDUAN MEDIA SOSIAL MAHASISWA DENGAN SVM DAN K-MEANS Abstraksi Keywords : Pendahuluan Tinjauan Pustaka," vol. 7, no. 2, 2026.
- [8] T. Ehsan and J. Basit, "Machine Learning for Detecting Social Media Addiction Patterns: Analyzing User Behavior and Mental Health Data," *Ijst*, vol. 6, no. 4, pp. 1789–1807, 2024.
- [9] N. Salari, H. Zarei, S. Rasoulpoor, H. Ghasemi, A. Hosseinian-Far, and M. Mohammadi, "The impact of social networking addiction on the academic achievement of university students globally: A meta-analysis," *Public Heal. Pract.*, vol. 9, no. December 2024, p. 100584, 2025, doi: 10.1016/j.puhip.2025.100584.
- [10] W. Y. Ma *et al.*, "Self-control and social support in the link between academic pressure anxiety depression and social media addiction in college students," *Sci. Rep.*, vol. 16, no. 1, pp. 1–21, 2026, doi: 10.1038/s41598-026-37112-x.
- [11] Ü. SAHRANÇ and E. DUÇ URHUN, "A Study on the Relationship between Social Media Addiction and Self-Regulation Processes among University Students," *Int. J. Psychol. Educ. Stud.*, vol. 8, no. 4, pp. 96–109, 2021, doi: 10.52380/ijpes.2021.8.4.546.
- [12] M. Rahman *et al.*, "Associations between social media addiction, social media fatigue, fear of missing out, and sleep quality among university students in Bangladesh: a cross-

- sectional study,” *J. Heal. Popul. Nutr.*, vol. 44, no. 1, pp. 1–16, 2025, doi: 10.1186/s41043-025-00896-1.
- [13] J. Zhuang *et al.*, “A serial mediation model of social media addiction and college students’ academic engagement: the role of sleep quality and fatigue,” *BMC Psychiatry*, vol. 23, no. 1, pp. 1–10, 2023, doi: 10.1186/s12888-023-04799-5.
- [14] C. M. Bishop and N. M. Nasrabadi, *Pattern recognition and machine learning*, vol. 4, no. 4. Springer, 2006.
- [15] K. Lavangnananda and S. Chattanachot, “Study of discretization methods in classification,” *2017 9th Int. Conf. Knowl. Smart Technol. Crunching Inf. Everything, KST 2017*, pp. 50–55, 2017, doi: 10.1109/KST.2017.7886082.
- [16] C. Zhen and Y. Zhang, “A Survey of Data Preprocessing in Data Mining,” *Int. Core J. Eng.*, vol. 5, no. 9, pp. 133–137, 2019, doi: 10.6919/ICJE.201908.