

Identifikasi Kecanduan Gadget pada Remaja Menggunakan Metode K-Nearest Neighbor

Ronaldus Hada Sogen¹, Bernadete Deta², Alvian Nara Weking³

^{1,2,3}Program Studi Teknik Informatika, Institut Keguruan dan Teknologi Lantuka, Indonesia

Corresponding Author: Bernadete Deta e-mail: auran8150@gmail.com

Published: Agust , 2025

ABSTRAK

Penelitian ini bertujuan untuk mengidentifikasi tingkat kecanduan gadget pada remaja di SMKN 1 Lantuka dengan menerapkan metode Machine Learning K-Nearest Neighbor (K-NN). Latar belakang penelitian ini didasari oleh meningkatnya intensitas penggunaan gadget di kalangan pelajar, yang berdampak signifikan terhadap penurunan prestasi akademik, perubahan perilaku sosial, gangguan pola tidur, hingga menurunnya kedisiplinan siswa dalam menjalani aktivitas sekolah. Data penelitian dikumpulkan melalui penyebaran kuesioner kepada siswa, yang terdiri dari 35 butir pernyataan yang menggambarkan pola penggunaan gadget serta dampaknya terhadap keseharian siswa. Setiap respon dianalisis dan diberikan skor untuk kemudian dilabeli menggunakan metode threshold berdasarkan nilai rata-rata, yang membagi data ke dalam dua kategori, yaitu “Tinggi” dan “Rendah”. Data selanjutnya dinormalisasi menggunakan Min-Max Scaler agar nilai fitur berada pada rentang yang sama. Proses pelatihan model dilakukan menggunakan algoritma K-NN, dengan pencarian parameter terbaik menggunakan GridSearchCV dan validasi silang 5-fold untuk meningkatkan keandalan hasil. Hasil pemodelan menunjukkan bahwa nilai k terbaik adalah 7, dengan rata-rata akurasi validasi sebesar 93%. Saat diuji menggunakan data uji, model menghasilkan akurasi sebesar 74%, dengan precision 0.80 untuk kelas “Rendah” dan 0.70 untuk kelas “Tinggi”. Confusion matrix menunjukkan tingkat keberhasilan model sebesar 74% dan tingkat kesalahan 26%. Hasil ini mengindikasikan bahwa model cukup mampu mengidentifikasi kecenderungan kecanduan gadget pada remaja, namun masih terdapat peluang untuk peningkatan akurasi melalui optimasi fitur maupun eksplorasi metode klasifikasi lainnya di masa mendatang.

Kata kunci : Kecanduan Gadget, Remaja, K-Nearest Neighbor, Klasifikasi, Machine Learning

ABSTRACT

This study aims to identify the level of gadget addiction among adolescents at SMKN 1 Lantuka by applying the K-Nearest Neighbor (K-NN) Machine Learning method. The background of this research is based on the increasing intensity of gadget usage among students, which significantly impacts academic performance, social behavior, sleep patterns, and overall discipline. Gadgets, which are intended to support learning activities, are often misused for excessive entertainment, such as gaming and social media access, leading to imbalanced student lifestyles. The data were collected through a questionnaire consisting of 35 items that reflect students' gadget usage patterns and their effects on daily activities. Each response was analyzed and assigned a score, which was then labeled using a threshold based on the average score to classify the data into two categories: “High” and “Low” levels of gadget addiction. The data were subsequently normalized using the Min-Max Scaler to ensure all features were on a comparable scale. The K-NN algorithm was used for model training, with optimal parameter selection performed through GridSearchCV and 5-fold cross-validation to enhance model reliability. The modeling results indicate that the optimal value of k is 7, with an average validation accuracy of 93%. When tested on unseen data, the model achieved an accuracy of 74%, with a precision of 0.80 for the “Low” addiction class and 0.70 for the “High” addiction class. The confusion matrix shows a model success rate of 74% and an error rate of 26%. These findings suggest that the model is reasonably effective in identifying gadget addiction tendencies among adolescents, although there remains potential for improvement through feature optimization or exploration of alternative classification algorithms in future studies.

Keywords: Gadget Addiction, Teenagers, K-Nearest Neighbor, Classification, Machine Learning

© The Author(s). 2021 Open Access This article is licensed under a Creative Commons Attribution 4.0 International License, which permits use, sharing, adaptation, distribution and reproduction in any medium or format, as long as you give appropriate credit to the original author(s) and the source, provide a link to the Creative Commons licence, and indicate if changes were made. The images or other third party material in this article are included in the article's Creative Commons licence, unless indicated otherwise in a credit line to the material. To view a copy of this licence, visit <http://creativecommons.org/licenses/by/4.0>

PENDAHULUAN

Perkembangan teknologi informasi telah melahirkan berbagai perangkat elektronik canggih, salah satunya adalah gadget. Gadget merupakan alat elektronik kecil dengan berbagai fungsi khusus yang kini sangat populer dan digunakan secara luas, baik oleh orang dewasa maupun anak-anak (Cholil et al., 2021). Kemudahan akses terhadap berbagai aplikasi dan layanan digital menjadikan gadget sebagai bagian tidak terpisahkan dari kehidupan sehari-hari. Di kalangan remaja, gadget telah menjadi media utama untuk berkomunikasi, mengakses informasi, hiburan, bahkan pembelajaran.

Remaja sebagai kelompok usia yang aktif menjadi pengguna dominan gadget. Meski membawa dampak positif seperti kemudahan dalam mengakses informasi pembelajaran dan komunikasi, penggunaan gadget secara berlebihan juga menimbulkan dampak negatif yang signifikan, termasuk gangguan kesehatan mental dan fisik, penurunan prestasi akademik, isolasi sosial, rendahnya keterampilan sosial, serta peningkatan perilaku mudah marah (Putri et al., 2024). Kondisi ini menunjukkan bahwa penggunaan gadget pada remaja tidak hanya berdampak secara individual, tetapi juga memiliki konsekuensi sosial yang lebih luas.

Lebih jauh, pengaruh gadget terhadap moral remaja juga sangat mencolok, seperti menurunnya kedisiplinan, malas beraktivitas, berkurangnya waktu belajar, hingga meninggalkan kewajiban beribadah (Putri et al., 2024). Paparan konten yang tidak sesuai usia, kebiasaan bermain game daring secara berlebihan, serta kecenderungan menjadikan gadget sebagai pelarian dari tekanan emosional turut memperburuk situasi ini. Berdasarkan survei World Health Organization (WHO), sebanyak 59,93% remaja di Asia Tenggara mengalami kecanduan berat terhadap gadget, sementara di Indonesia angkanya mencapai 40% dan terus meningkat setiap tahunnya (Sinaga, 2018).

Data dari Asosiasi Penyelenggara Jasa Internet Indonesia (APJII) menunjukkan bahwa 143,26 juta atau 54,68% penduduk Indonesia menggunakan internet, dengan penetrasi tertinggi pada kelompok usia 13–18 tahun sebesar 75,50%, di mana 44,16% mengakses internet melalui gadget (Ummanah & Heryati, 2021). Kondisi ini memperkuat temuan bahwa penggunaan gadget tidak hanya meluas, tetapi juga mendalam dari sisi keterikatan psikologis dan perilaku.

Fenomena ini juga terjadi di SMKN 1 Larantuka. Berdasarkan hasil wawancara dengan pihak sekolah, dari 941 siswa, sekitar 98% di antaranya menggunakan gadget. Bahkan tidak sedikit dari mereka yang menggunakan gadget lebih dari lima jam per hari di luar kegiatan pembelajaran. Kondisi ini berdampak pada penurunan prestasi akademik, dari rata-rata nilai 88,99 pada tahun ajaran 2022/2023 menjadi 80,00 pada tahun ajaran 2023/2024. Penurunan ini tidak hanya dipengaruhi oleh faktor kognitif siswa, tetapi juga faktor eksternal seperti kurangnya kontrol penggunaan gadget dan lemahnya pengawasan orang tua.

Dalam menghadapi tantangan ini, diperlukan suatu sistem yang tidak hanya bersifat reaktif tetapi juga preventif dalam mengidentifikasi risiko kecanduan gadget. Teknologi kecerdasan buatan

(Artificial Intelligence/AI) dan pembelajaran mesin (Machine Learning) menjadi solusi yang potensial. Salah satu algoritma Machine Learning yang memiliki tingkat akurasi yang cukup tinggi dan proses implementasi yang sederhana adalah K-Nearest Neighbor (K-NN). Algoritma ini bekerja dengan mengklasifikasikan data berdasarkan kedekatan jarak antar titik data, tanpa memerlukan proses pelatihan model yang kompleks seperti pada algoritma lain (Cholil et al., 2021; Dinata et al., 2020).

K-NN telah banyak digunakan dalam berbagai studi klasifikasi, termasuk klasifikasi kesehatan mental, pemilihan jurusan siswa, evaluasi prestasi, dan deteksi kecanduan perilaku digital (Deta & Mauritsius, 2022; Saputra & Nugroho, 2020). Algoritma ini dinilai efektif karena kesederhanaannya dalam mengelola data numerik dan kategorik, serta fleksibel dalam menghadapi berbagai pola perilaku pengguna. Dalam konteks deteksi kecanduan gadget, K-NN dapat digunakan untuk mengelompokkan siswa ke dalam beberapa kategori kecanduan misalnya rendah, sedang, dan tinggi berdasarkan parameter seperti durasi penggunaan gadget, frekuensi akses aplikasi hiburan, intensitas komunikasi daring, serta penurunan performa akademik.

Penelitian ini bertujuan untuk menerapkan metode K-NN dalam mengidentifikasi tingkat kecanduan gadget pada siswa SMKN 1 Larantuka, menganalisis pengaruh penggunaan gadget terhadap prestasi akademik, serta mengoptimalkan parameter K-NN untuk meningkatkan akurasi klasifikasi. Penentuan nilai K yang optimal sangat krusial agar sistem klasifikasi tidak mengalami overfitting maupun underfitting (Rizqi & Yuliana, 2020). Dengan demikian, penelitian ini tidak hanya menawarkan analisis perilaku digital remaja, tetapi juga memberikan kontribusi pada pengembangan sistem pendukung keputusan berbasis data dalam konteks pendidikan menengah.

Hasil dari penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem deteksi kecanduan gadget berbasis Machine Learning, yang berguna bagi pihak sekolah dan orang tua dalam mengambil langkah preventif maupun intervensi. Selain itu, temuan ini juga dapat dijadikan dasar untuk penyusunan kebijakan sekolah dalam pengaturan penggunaan gadget di lingkungan akademik, termasuk dalam menyusun strategi literasi digital, edukasi penggunaan sehat teknologi, serta penguatan peran guru sebagai pembimbing digital.


Dengan meningkatnya urgensi untuk memahami dinamika penggunaan gadget di kalangan remaja, penelitian ini diharapkan mampu menjawab kebutuhan akan sistem deteksi yang tidak hanya akurat tetapi juga aplikatif. Sebab, pendidikan tidak hanya bertujuan untuk mentransfer ilmu pengetahuan, tetapi juga membentuk karakter dan kebiasaan positif dalam penggunaan teknologi secara sehat dan bertanggung jawab.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif deskriptif yang bertujuan untuk mengidentifikasi tingkat kecanduan gadget pada remaja berdasarkan data numerik yang dapat dianalisis secara statistik. Metode yang digunakan adalah survei dengan instrumen kuesioner sebagai alat utama pengumpulan data, yang selanjutnya dianalisis menggunakan algoritma K-Nearest Neighbor (K-NN). Algoritma K-Nearest Neighbor (K-NN) merupakan metode klasifikasi berbasis jarak yang menentukan kelas suatu data baru dengan membandingkan fitur-fitur data tersebut terhadap data latih terdekat, menggunakan metrik seperti Eudidean atau Manhattan Distance (Dinata et al., 2020). Penelitian ini dilaksanakan di SMK Negeri 1 Larantuka, Kabupaten Flores Timur, Provinsi Nusa Tenggara Timur, selama tiga bulan, mencakup seluruh tahapan mulai dari pengumpulan data hingga analisis hasil.

Populasi dalam penelitian ini adalah seluruh siswa kelas X yang berjumlah 302 orang, dengan teknik pengambilan sampel secara random sampling untuk memberikan peluang yang sama bagi seluruh anggota populasi. Jumlah sampel ditentukan menggunakan rumus Slovin dengan tingkat kepercayaan 95%, sehingga diperoleh 172 responden. Variabel dalam penelitian ini terdiri dari variabel bebas (X) berupa gejala-gejala penggunaan gadget yang dikelompokkan dalam empat kategori utama, yaitu perubahan perilaku, fisik, emosional, dan kognitif, serta variabel terikat (Y) yaitu tingkat kecanduan gadget yang diklasifikasikan menjadi dua kelas: tinggi dan rendah. Pengumpulan data dilakukan melalui penyebaran kuesioner dengan 35 item pertanyaan menggunakan skala Likert 5 poin, serta dilengkapi dengan observasi perilaku siswa dan wawancara dengan guru BK dan wali kelas untuk memperkuat temuan.

Teknik analisis data mencakup proses *preprocessing* data, pembagian dataset menjadi data pelatihan (80%) dan data pengujian (20%), perhitungan nilai K optimal, perhitungan jarak Eudidean, klasifikasi menggunakan K-NN, dan evaluasi performa model dengan metrik seperti akurasi, *confusion matrix*, *precision*, *recall*, dan F1-score. Interpretasi hasil dilakukan dengan menentukan kelas output berdasarkan total skor kuesioner, dengan skor 35–101 dikategorikan sebagai kecanduan rendah dan 102–175 sebagai kecanduan tinggi.



Gambar 1. Tahapan Penelitian

1. Pengumpulan dan Persiapan Data

Tahapan pertama dalam implementasi algoritma K-NN adalah pengumpulan dan persiapan data. Dalam penelitian ini, data diperoleh dari hasil penyebaran kuesioner kepada 172 responden. Kuesioner tersebut dirancang untuk mengukur tingkat kecanduan gadget berdasarkan 35 indikator gejala kecanduan, yang masing-masing dinilai menggunakan skala Likert. Data mentah yang diperoleh kemudian dihimpun dan disusun dalam format tabel agar siap diproses lebih lanjut dalam tahap analisis.

2. Preprocessing data

Setelah data terkumpul, dilakukan proses preprocessing untuk memastikan kualitas data yang akan digunakan dalam pelatihan dan pengujian model. (Deta & Mauritsius, 2022) Langkah pertama adalah membersihkan data dari nilai-nilai kosong atau tidak konsisten (data cleaning). Kemudian dilakukan normalisasi agar setiap fitur memiliki skala yang seragam, menghindari dominasi fitur tertentu karena perbedaan satuan atau rentang nilai. Jika terdapat data kualitatif, konversi ke bentuk numerik dilakukan agar data tersebut dapat diproses oleh algoritma K-NN secara efektif.

3. Pembagian Dataset

Dataset yang telah diproses kemudian dibagi menjadi dua bagian utama, yaitu data latih (training data) dan data uji (testing data). Pembagian ini dilakukan dengan proporsi 80% data digunakan sebagai data latih, sementara sisanya, yaitu 20%, digunakan sebagai data uji. Tujuan dari pembagian ini adalah agar algoritma dapat belajar dari pola-pola pada data latih, lalu diuji kemampuannya dalam mengklasifikasi data baru menggunakan data uji yang belum pernah dikenali sebelumnya.

4. Pemodelan

Pada tahap pemodelan, dua aspek penting dalam algoritma K-Nearest Neighbor (K-NN) perlu diperhatikan, yaitu pemilihan nilai K yang optimal pada perhitungan jarak antar data. Penentuan nilai K merupakan proses untuk mencari jumlah tetangga terdekat yang digunakan sebagai acuan dalam mengklasifikasikan data baru. Nilai K tidak boleh terlalu kecil maupun terlalu besar; nilai K yang terlalu kecil (misalnya $K=1$) cenderung sensitif terhadap noise atau data anomali, sedangkan nilai K yang terlalu besar dapat mengaburkan batas antar kelas karena mempertimbangkan terlalu banyak tetangga dari kelas berbeda. Dalam penelitian ini, dilakukan eksperimen dengan mencoba beberapa nilai K, seperti $K=3, 5, 7$ dan 9 . Tujuannya adalah untuk menemukan nilai K yang menghasilkan tingkat akurasi klasifikasi terbaik berdasarkan hasil evaluasi terhadap data uji. Setelah nilai K ditentukan, langkah berikutnya dalam pemodelan adalah perhitungan jarak antar data. Algoritma K-NN menentukan tetangga terdekat berdasarkan kedekatan jarak, dan dalam penelitian ini digunakan metode Euclidean Distance.

5. Evaluasi

Tahap akhir dalam implementasi algoritma adalah evaluasi model untuk mengetahui seberapa baik kinerja K-NN dalam mengklasifikasi data. Evaluasi dilakukan menggunakan beberapa metrik, antara lain: akurasi (persentase klasifikasi yang benar), confusion matrix (tabel yang menunjukkan distribusi prediksi benar dan salah), precision (tingkat ketepatan prediksi positif), recall (kemampuan mendeteksi seluruh kasus positif), dan F1-score (harmonisasi antara precision dan recall). Metrik-metrik ini memberikan gambaran menyeluruh mengenai keefektifan model dalam menyelesaikan tugas klasifikasi.


6. Interpretasi Hasil

Langkah terakhir adalah interpretasi hasil klasifikasi dan evaluasi. Hasil klasifikasi K-NN dianalisis untuk mengetahui sejauh mana algoritma berhasil membedakan tingkat kecanduan gadget berdasarkan indikator gejala. Jika akurasi model tinggi dan distribusi prediksi pada confusion matrix seimbang, maka dapat disimpulkan bahwa K-NN efektif dalam mengidentifikasi pola kecanduan. Interpretasi ini tidak hanya fokus pada metrik evaluasi, tetapi juga mencerminkan relevansi dan makna hasil klasifikasi terhadap kondisi nyata responden.

HASIL DAN PEMBAHASAN

Pemodelan

Pada tahap pemodelan, data kuesioner dari 172 responden diolah melalui proses *preprocessing* termasuk pembersihan data, normalisasi dengan Min-Max, serta pembagian menjadi data latih (80%) dan data uji (20%). Tujuan utama dari tahap ini adalah membangun model klasifikasi menggunakan algoritma K-Nearest Neighbor (K-NN) untuk mengidentifikasi tingkat kecanduan gadget. Nilai K ditentukan menggunakan rumus $K = \sqrt{N}$ (dengan N sebagai jumlah data latih), lalu disesuaikan menjadi angka ganjil agar sesuai dengan dua kelas. Pemodelan menggunakan perhitungan jarak Eudidean untuk menentukan kedekatan antar data, menghasilkan model K-NN yang siap digunakan untuk mengklasifikasikan data uji.



Gambar 2. Hasil Pemodelan dengan Skenario Cross-Validation


Berdasarkan hasil pencarian parameter terbaik menggunakan teknik GridSearchCV yang dipadukan dengan validasi silang (cross-validation) sebanyak lima lipatan (5-fold), diperoleh bahwa nilai k optimal dalam algoritma K-Nearest Neighbor (K-NN) adalah 7. Nilai ini menunjukkan performa terbaik dibandingkan dengan nilai k lainnya yang turut diuji, yaitu $k = 3, 5$, dan 9. Nilai $k = 7$ menghasilkan skor akurasi masing-masing sebesar 0.89 pada lipatan pertama, 0.96 pada lipatan kedua, 0.93 pada lipatan ketiga, 0.89 pada lipatan keempat, dan 1.00 pada lipatan kelima. Rata-rata dari kelima skor tersebut adalah 0.93, yang merupakan skor rata-rata tertinggi di antara semua konfigurasi nilai k yang diuji.

Sebagai perbandingan, pada nilai $k = 9$, model mencatat skor akurasi individual sebesar 0.93, 0.86, 0.89, 0.93, dan 1.00, dengan rata-rata 0.92. Meskipun hasilnya juga cukup tinggi dan mendekati nilai $k = 7$, konsistensinya sedikit lebih rendah pada lipatan kedua dengan skor hanya 0.86. Sementara itu, pada nilai $k = 5$, diperoleh rata-rata skor 0.89, dengan performa individu di kisaran 0.82 hingga 0.93. Terakhir, konfigurasi dengan nilai $k = 3$ menunjukkan performa yang paling rendah, dengan rata-rata hanya 0.87, dan skor terendah sebesar 0.74 terjadi pada lipatan ketiga. Hal ini mengindikasikan bahwa penggunaan k yang terlalu kecil dapat menyebabkan model terlalu sensitif terhadap noise pada data, sehingga berdampak pada akurasi yang tidak stabil.

Secara umum, pemilihan nilai k yang optimal sangat krusial dalam algoritma K-NN karena secara langsung memengaruhi hasil klasifikasi. Nilai k yang terlalu kecil berpotensi menimbulkan *overfitting* sedangkan nilai k yang terlalu besar dapat menyebabkan *underfitting*. Oleh karena itu, nilai $k = 7$ dipilih karena tidak hanya memberikan skor akurasi tertinggi, tetapi juga menunjukkan konsistensi performa yang baik di setiap lipatan validasi. Dengan demikian, parameter ini digunakan dalam pemodelan akhir untuk mengidentifikasi tingkat kecanduan gadget siswa dengan tingkat akurasi yang tinggi dan kestabilan yang baik.

Pengujian (Evaluasi Model)

Setelah model K-NN terbentuk, proses pengujian dilakukan untuk mengukur performa dan akurasi model dalam mengklasifikasikan data uji. Data uji yang terdiri dari 20% sampel digunakan untuk menilai kemampuan generalisasi model terhadap data baru yang belum pernah dilatih sebelumnya. Evaluasi model dilakukan dengan menghitung metrik-metrik performa seperti akurasi, precision, recall, dan F1-score. Selain itu, confusion matrix digunakan untuk menganalisis secara lebih rinci hasil prediksi model dalam bentuk True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). Dari hasil evaluasi ini, diperoleh pemahaman mengenai sejauh mana model mampu membedakan antara siswa yang memiliki tingkat kecanduan gadget tinggi dan rendah. Evaluasi ini juga menjadi dasar dalam menyimpulkan efektivitas pendekatan K-NN dalam mendeteksi gejala kecanduan gadget berdasarkan data gejala yang telah diklasifikasikan sebelumnya.



Gambar 3. Hasil confusion matrix pengujian

Berdasarkan hasil confusion matrix dari pengujian model K-Nearest Neighbor (K-NN), dapat dilakukan analisis terhadap performa klasifikasi secara lebih mendalam. Tabel confusion matrix menampilkan empat kategori utama hasil prediksi: True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN), yang masing-masing memberikan gambaran tentang tingkat keberhasilan dan kesalahan model dalam mengklasifikasikan data.

Dari matrix tersebut, diketahui bahwa terdapat 12 data yang diklasifikasikan dengan benar sebagai kelas “Rendah” (0) — ini merupakan nilai True Negative (TN), karena model berhasil mengenali data yang benar-benar rendah. Selanjutnya, terdapat 14 data yang juga berhasil diklasifikasikan secara akurat ke dalam kelas “Tinggi” (1) — ini adalah True Positive (TP). Kedua kategori ini mencerminkan prediksi yang sesuai dengan label sebenarnya, dan secara keseluruhan menunjukkan bahwa model mampu mengklasifikasikan dengan benar sebanyak 26 data dari total 35 data uji.

Namun, masih terdapat 6 data dari kelas aktual “Rendah” yang salah diprediksi sebagai “Tinggi” — ini disebut sebagai False Positive (FP), dan menunjukkan kesalahan model dalam memprediksi siswa yang sebenarnya memiliki tingkat kecanduan rendah, namun dikategorikan tinggi

oleh model. Di sisi lain, terdapat 3 data dari kelas aktual “Tinggi” yang salah diprediksi sebagai “Rendah” — ini merupakan False Negative (FN), yaitu model gagal mendeteksi siswa yang sebenarnya menunjukkan tanda-tanda kecanduan gadget tinggi.

Secara proporsi, model memiliki kecenderungan untuk lebih sensitif terhadap kelas “Tinggi”, sebagaimana terlihat dari jumlah TP (14) yang lebih tinggi dibandingkan TN (12), serta jumlah FN (3) yang lebih rendah dibandingkan FP (6). Hal ini sejalan dengan hasil *recall* pada kelas “Tinggi” yang tinggi (0.82), menandakan bahwa model cukup andal dalam mengidentifikasi siswa yang benar-benar kecanduan gadget. Namun, model masih perlu diperbaiki dalam mengurangi kesalahan prediksi untuk siswa yang tidak terlalu kecanduan namun diklasifikasikan secara keliru.

Secara keseluruhan, confusion matrix ini menunjukkan bahwa model K-NN memiliki kemampuan klasifikasi yang cukup baik, tetapi terdapat ruang untuk perbaikan, khususnya dalam menurunkan jumlah False Positive agar tidak terjadi overestimasi terhadap tingkat kecanduan gadget di kalangan siswa. Upaya perbaikan bisa dilakukan melalui optimasi parameter, penambahan data pelatihan, atau eksplorasi fitur yang lebih representatif terhadap karakteristik masing-masing kelas.

Tabel 1. Hasil Pengukuran Akurasi, Presisi, *Recall* dan F1-Score pada Evaluasi Model (Pengujian)

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
0	0.80	0.67	0.73
1	0.70	0.82	0.76
Macro Avg	0.75	0.75	0.74
Weighted Avg	0.75	0.74	0.74
<i>Accuracy</i>			0.74

Hasil evaluasi model klasifikasi menggunakan algoritma K-Nearest Neighbor (K-NN) menunjukkan bahwa model memiliki performa yang cukup baik dalam mengklasifikasikan tingkat kecanduan gadget ke dalam dua kelas, yaitu kelas 0 (“Rendah”) dan kelas 1 (“Tinggi”). Berdasarkan metrik evaluasi, nilai *accuracy* atau tingkat ketepatan klasifikasi model terhadap data uji adalah sebesar 74%, yang berarti bahwa 74% dari seluruh prediksi yang dilakukan oleh model sesuai dengan label sebenarnya.

Secara lebih rinci, performa model pada masing-masing kelas ditunjukkan melalui nilai *precision*, *recall*, dan F1-score. Untuk kelas 0 (kategori “Rendah”), nilai *precision* sebesar 0.80 menunjukkan bahwa dari seluruh prediksi model terhadap kelas “Rendah”, 80% adalah benar. Sementara itu, nilai *recall* sebesar 0.67 mengindikasikan bahwa dari seluruh data yang sebenarnya termasuk dalam kelas “Rendah”, hanya 67% yang berhasil diidentifikasi dengan benar oleh model. Nilai F1-score sebesar 0.73 mencerminkan keseimbangan antara *precision* dan *recall* pada kelas ini.

Sedangkan pada kelas 1 (kategori “Tinggi”), nilai *precision* tercatat sebesar 0.70, yang berarti 70% dari prediksi kelas “Tinggi” adalah benar. Nilai *recall* yang lebih tinggi, yaitu 0.82, menunjukkan bahwa model cukup sensitif dalam mengenali individu yang benar-benar masuk kategori “Tinggi”, dengan keberhasilan deteksi sebesar 82%. Nilai F1-score sebesar 0.76 menunjukkan performa yang relatif stabil dan baik dalam menyeimbangkan ketepatan dan kelengkapan prediksi untuk kelas ini.

Selain itu, nilai *macro average* dan *weighted average* pada ketiga metrik juga bernilai sekitar 0.74–0.75, yang mendukung kesimpulan bahwa model cukup seimbang dalam menangani kedua kelas. *Macro average* menghitung rata-rata performa tanpa mempertimbangkan proporsi jumlah data di tiap kelas, sedangkan *weighted average* mempertimbangkan proporsi tersebut. Keseluruhan hasil ini menunjukkan bahwa model K-NN yang dibangun memiliki kinerja yang cukup andal, meskipun terdapat peluang peningkatan, khususnya dalam memperbaiki nilai *recall* pada kelas “Rendah” dan *precision* pada kelas “Tinggi”. Upaya lanjutan seperti optimasi fitur, penambahan data, atau eksplorasi algoritma lain dapat dilakukan untuk meningkatkan akurasi dan generalisasi model.

Pembahasan

Berdasarkan hasil pemodelan serta pengujian yang diperoleh, dapat dijelaskan sebagai berikut:

- a. Pada tahap pemodelan, algoritma K-Nearest Neighbor (K-NN) digunakan sebagai pendekatan utama untuk mengklasifikasikan tingkat kecanduan gadget pada siswa SMKN 1 Larantuka. Untuk memperoleh performa terbaik, pemilihan parameter jumlah tetangga terdekat (k) dilakukan menggunakan teknik *GridSearchCV* dengan validasi silang (*cross-validation*) sebanyak lima lipatan (5-fold). Hasil eksplorasi parameter menunjukkan bahwa nilai $k = 7$ memberikan performa paling optimal, dengan rata-rata akurasi validasi mencapai 93%. Nilai ini lebih tinggi dibandingkan parameter lainnya seperti $k = 3, 5$, atau 9 . Hal ini mengindikasikan bahwa pada jumlah tetangga sebanyak 7, model mampu menangkap pola klasifikasi yang lebih stabil dan konsisten pada data latih. Selain itu, pemilihan nilai ganjil seperti 7 juga penting untuk menghindari kemungkinan hasil klasifikasi imbang pada dua kelas yang seimbang.
- b. Analisis *confusion matrix* pada data uji memberikan gambaran tentang sejauh mana model mampu mengklasifikasikan data dengan benar. Dari total 35 data uji, model berhasil mengklasifikasikan 12 data aktual “Rendah” secara tepat sebagai “Rendah” dan 14 data aktual “Tinggi” secara tepat sebagai “Tinggi”. Ini berarti terdapat 26 prediksi yang benar, terdiri dari 12 True Negative (TN) dan 14 True Positive (TP). Namun demikian, masih terdapat 6 data aktual “Rendah” yang salah diklasifikasikan sebagai “Tinggi” (False Positive), serta 3 data aktual “Tinggi” yang salah diklasifikasikan sebagai “Rendah” (False Negative). Dari matrix ini, dapat disimpulkan bahwa model sedikit lebih andal dalam mengidentifikasi kelas “Tinggi” dibandingkan kelas “Rendah”, yang sejalan dengan hasil evaluasi metrik *recall* dan *precision* pada pengujian.

- c. Pengujian model terhadap data uji menghasilkan nilai akurasi sebesar 74%, yang menunjukkan bahwa sebagian besar prediksi model sesuai dengan label aktual data. Dari sisi evaluasi metrik lainnya, model menghasilkan nilai precision sebesar 0.80 untuk kelas “Rendah” dan 0.70 untuk kelas “Tinggi”. Ini menunjukkan bahwa prediksi kelas “Rendah” cenderung lebih tepat sasaran dibandingkan kelas “Tinggi”. Nilai recall untuk kelas “Rendah” adalah 0.67, sedangkan kelas “Tinggi” mencapai 0.82, yang berarti model lebih mampu mendeteksi siswa yang benar-benar kecanduan gadget. Selain itu, nilai F1-score yang merupakan rata-rata harmonis dari precision dan recall, masing-masing tercatat sebesar 0.73 untuk “Rendah” dan 0.76 untuk “Tinggi”. Rata-rata keseluruhan (macro average dan weighted average) F1-score berada pada angka 0.74, yang memperkuat temuan bahwa model tergolong cukup baik dalam mengklasifikasikan dua kelas secara seimbang. Meskipun performa model tidak sempurna, hasil ini menunjukkan bahwa K-NN merupakan metode yang layak digunakan untuk identifikasi awal tingkat kecanduan gadget, dengan potensi peningkatan akurasi melalui optimasi lanjutan atau eksplorasi fitur tambahan.

KE SIMPULAN

Penelitian ini bertujuan untuk mengidentifikasi tingkat kecanduan gadget pada remaja dengan menerapkan algoritma Machine Learning K-Nearest Neighbor (K-NN) sebagai metode klasifikasi. Berdasarkan hasil pengolahan data kuesioner dari 172 responden, dilakukan preprocessing data yang meliputi normalisasi, pelabelan menggunakan metode threshold, serta pembagian data menjadi data latih dan data uji.

Melalui proses pemodelan dan pengujian, diperoleh parameter terbaik yaitu $k = 7$, dengan rata-rata akurasi validasi silang sebesar 93%, yang menunjukkan bahwa model memiliki kemampuan yang cukup tinggi dalam mempelajari pola data pelatihan. Saat diuji pada data uji, model menghasilkan akurasi sebesar 74%, dengan precision 0.80 untuk kelas “Rendah” dan 0.70 untuk kelas “Tinggi”. Nilai recall dan F1-score juga mendukung performa model yang seimbang pada kedua kelas.

Confusion matrix menunjukkan bahwa dari total 35 data uji, sebanyak 26 data berhasil diklasifikasikan dengan benar, sementara 9 data mengalami kesalahan klasifikasi. Hal ini menunjukkan bahwa meskipun model sudah menunjukkan performa yang cukup baik, masih terdapat ruang untuk perbaikan, khususnya dalam menurunkan tingkat kesalahan prediksi.

Secara keseluruhan, dapat disimpulkan bahwa algoritma K-NN cukup efektif digunakan dalam mengklasifikasikan tingkat kecanduan gadget pada remaja, dan hasil penelitian ini dapat dijadikan dasar untuk pengembangan sistem pemantauan atau intervensi dini oleh pihak sekolah maupun orang tua dalam mengatasi permasalahan kecanduan gadget di kalangan pelajar.

DAFTAR PUSTAKA

- Cholil, S. R., Handayani, T., Prathivi, R., & Ardianita, T. (2021). Implementasi algoritma klasifikasi K-Nearest Neighbor (KNN) untuk klasifikasi seleksi penerima beasiswa. *IJCIT (Indonesian Journal on Computer and Information Technology)*, 6(2). <https://doi.org/10.31294/ijcit.v6i2.10438>
- Deta, B., & Mauritsius, T. (2022). Implementation of data mining to determine student majors using the machine learning. *Journal of Theoretical and Applied Information Technology*, 100(11), 3798–3809.
- Dewi, R. A., & Setiadi, R. (2019). Penerapan K-Nearest Neighbor (K-NN) dalam menentukan jenis pelanggan. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, 6(5), 509–516. <https://doi.org/10.25126/jtiik.2019651046>
- Dinata, R. K., Akbar, H., & Hasdyna, N. (2020). Algoritma K-Nearest Neighbor dengan Euclidean Distance dan Manhattan Distance untuk klasifikasi transportasi bus. *ILKOM Jurnal Ilmiah*, 12(2), 104–111. <https://doi.org/10.33096/ilkom.v12i2.539.104-111>
- Hanifah, N., & Fauzan, R. (2023). Efektivitas pembelajaran berbasis teknologi terhadap perubahan perilaku remaja. *Jurnal Pendidikan dan Teknologi*, 5(2), 90–97.
- Kurniawan, A. D., & Yuniar, R. (2023). Penerapan data mining dalam sistem rekomendasi peminatan siswa SMA. *Jurnal Teknologi dan Sistem Informasi*, 11(1), 14–20.
- Lestari, P., & Riyadi, A. (2022). Dampak gadget terhadap kesehatan mental remaja. *Jurnal Kesehatan Jiwa*, 10(1), 23–29.
- Nugroho, H. W., & Priyanto, R. (2020). Implementasi K-NN untuk menentukan jurusan siswa baru SMA. *Jurnal Teknologi dan Sistem Komputer*, 8(3), 130–136. <https://doi.org/10.14710/jtsiskom.8.3.2020.130-136>
- Nuraini, A. F., & Asmara, M. (2021). Pengaruh intensitas penggunaan gadget terhadap kualitas tidur dan konsentrasi belajar. *Jurnal Kesehatan Masyarakat*, 10(2), 112–119.
- Prasetyo, T., & Sari, P. R. (2020). Klasifikasi data mahasiswa menggunakan algoritma KNN. *Jurnal Ilmu Komputer dan Sistem Informasi*, 8(1), 77–83.
- Putri, J. N., Sumiatin, T., Su'udi, & Yunariyah, B. (2024). Penggunaan gadget dan perubahan perilaku remaja di Sekolah Menengah Atas Tuban. *Jurnal Ilmiah Kesehatan Mandira Cendikia*, 3(8), 376–383.
- Rizqi, A. S., & Yuliana, S. (2020). Perbandingan akurasi algoritma K-NN dan Naïve Bayes untuk prediksi kelulusan mahasiswa. *Jurnal Informatika Universitas Pamulang*, 5(2), 87–92.
- Saputra, H., & Nugroho, H. (2020). Prediksi peminatan siswa menggunakan algoritma KNN. *Jurnal Teknologi Informasi dan Komputer*, 6(2), 45–51.
- Sinaga, D. (2018). Dampak candu gadget pada remaja dan tips mengatasinya. *CNNIndonesia.com*. <https://www.cnnindonesia.com/gaya-hidup/20180129101604-284-272524/dampak-candu-gadget-pada-remaja-dan-tips-mengatasinya>
- Ummanah, N. A., & Heryati, E. (2021). Dampak komunikasi psiko-sosial era informasi sosial media. *Jurnal Ilmiah Ilmu Komunikasi*, 18(2), 121–133. <https://doi.org/10.47007/jkomu.v18i02.361>

- Wahyuningsih, S., & Kurniawan, R. (2021). Pola penggunaan media sosial dan perilaku sosial remaja. *Jurnal Ilmu Komunikasi UPN Veteran Yogyakarta*, 17(1), 12–21.
- Wahyuni, S., & Nurhadi, D. (2020). Analisis pengaruh penggunaan media sosial terhadap perilaku sosial remaja. *Jurnal Psikologi Insight*, 2(1), 33–40.
- Wicaksono, D. A., & Yuliana, S. (2021). Penggunaan KNN dalam klasifikasi tingkat stres mahasiswa. *Jurnal Sistem Informasi dan Teknik Informatika*, 8(1), 56–62.
- Wulandari, D., & Astuti, M. (2022). Dampak gadget terhadap perkembangan sosial anak dan remaja: Tinjauan psikologis. *Jurnal Psikologi Pendidikan dan Konseling*, 8(1), 55–62.
- Yulianto, F., & Rachman, A. (2022). Analisis sentimen pengguna gadget di kalangan remaja menggunakan text mining. *Jurnal Ilmiah Informatika*, 9(3), 110–116.