

PENGARUH SCREEN TIME BERDASARKAN TUJUAN PENGGUNAAN TERHADAP ADIKSI GADGET MENGGUNAKAN SUPPORT VECTOR MACHINE

Christian Angkasa, N P Dharshinni*, Anton, Stybert Cang Willgert

Teknik Informatika, Universitas Prima Indonesia

PUI-PT ITIK (Inovasi Teknologi Ilmu Komputer), Universitas Prima Indonesia, Medan, 20118

Jalan Sampul No. 3 Medan, Sumatera Utara, Indonesia

priyadharshinninaidu@gmail.com

ABSTRAK

Perkembangan teknologi digital telah meningkatkan penggunaan smartphone secara signifikan, terutama pada kalangan remaja. Meskipun memberikan berbagai kemudahan dalam aktivitas sehari-hari, penggunaan berlebihan dapat menimbulkan dampak negatif seperti masalah kesehatan mental, penurunan interaksi sosial, hingga munculnya perilaku adiktif. Penelitian ini bertujuan menganalisis pengaruh durasi serta tujuan penggunaan smartphone terhadap tingkat adiksi pada remaja, serta memprediksi kategori adiksi menggunakan algoritma machine learning Support Vector Machine (SVM). Data penelitian menggunakan dataset sekunder dari Kaggle berjudul “Teen Smartphone Usage and Addiction Impact Dataset,” yang memuat informasi mengenai screentime media sosial, bermain gim, edukasi, frekuensi pemeriksaan perangkat, serta skor tingkat adiksi. Penelitian dilakukan melalui dua proses analisis, yaitu pemodelan regresi menggunakan Support Vector Regression untuk memprediksi skor adiksi berdasarkan pola penggunaan harian, dan klasifikasi tingkat adiksi (rendah, sedang, tinggi) disertai perbandingan berdasarkan gender. Model dibangun dan divalidasi menggunakan Altair AI Studio melalui pendekatan supervised learning dengan skema pembagian data. Hasil penelitian menunjukkan bahwa durasi dan tujuan penggunaan smartphone berkontribusi terhadap tingkat adiksi, dan SVM mampu melakukan prediksi serta klasifikasi secara efektif. Temuan ini memberikan kontribusi bagi penelitian perilaku digital serta penerapan machine learning dalam deteksi dini adiksi gadget, sekaligus memberikan wawasan bagi pendidik, orang tua, dan masyarakat mengenai dampak penggunaan smartphone pada remaja.

Kata kunci : Adiksi, Remaja, Screen time, Support Vector Machine

1. PENDAHULUAN

Seiring perkembangan zaman, teknologi digital mengalami kemajuan pesat. Arus globalisasi mendorong peningkatan penggunaan gadget, khususnya smartphone, dalam berbagai aspek kehidupan manusia [1]. Manusia secara terus-menerus berinovasi dan menciptakan solusi untuk mempermudah pekerjaan. Dalam hal ini, gadget menjadi salah satu tanda kemajuan perkembangan teknologi saat ini [2]. Namun, di balik kemudahan yang ditawarkan, penggunaan smartphone berlebihan memunculkan masalah serius seperti penurunan kesehatan mental, kesejahteraan, dan berkurangnya interaksi sosial [3].

Kemudahan akses dan fungsionalitas smartphone menyebabkan peningkatan ketergantungan, terutama di kalangan remaja dan dewasa muda, yang ditandai dengan munculnya perilaku adiktif [4]. Dengan lebih dari setengah populasi dunia memiliki smartphone, adiksi gadget telah menjadi isu global. Penelitian di Tiongkok menunjukkan bahwa 25,1% mahasiswa keperawatan mengalami adiksi gadget [5]. Fenomena serupa juga terjadi di berbagai negara, di mana anak-anak dan remaja semakin bergantung pada perangkat elektronik, sehingga menimbulkan kekhawatiran terhadap perkembangan fisik dan kognitif mereka [6][7].

Penggunaan smartphone untuk media sosial dan permainan digital merupakan aktivitas paling dominan di kalangan remaja. Banyak remaja menunjukkan kecenderungan terhadap adiksi smartphone, terutama karena penggunaan media sosial, game, dan aplikasi hiburan [8]. Hal ini menunjukkan bahwa tujuan penggunaan gadget berpengaruh terhadap tingkat adiksi dan dampaknya pada kehidupan sosial remaja. Digitalisasi komunikasi memungkinkan interaksi instan dan berkelanjutan, namun juga meningkatkan risiko ketergantungan [9].

Pola penggunaan smartphone bervariasi menurut gender—laki-laki cenderung menggunakan untuk bermain game dan menonton video, sedangkan perempuan lebih sering menggunakan aplikasi sosial dan komunikasi [10]. Penggunaan gadget/smartphone yang berlebihan dapat berdampak buruk bagi Kesehatan fisik maupun mental [11]. Penggunaan gadget berlebihan dapat menimbulkan berbagai dampak negatif seperti fear of missing out (FoMO) [12], depresi dan kecemasan [13], gangguan emosional, serta masalah pada kesehatan mata [14].

Berdasarkan latar belakang tersebut, dapat disimpulkan rumusan permasalahan dalam penelitian ini yaitu apakah terdapat pengaruh signifikan antara screen time berdasarkan tujuan penggunaan terhadap tingkat adiksi gadget?, bagaimana performa algoritma Support Vector Machine dalam memprediksi tingkat

adiksi gadget berdasarkan data screen time dan tujuan penggunaannya?, dan fitur tujuan penggunaan apa saja yang paling berkontribusi dalam mempengaruhi klasifikasi adiksi gadget?

Adapun tujuan dari penelitian ini adalah untuk menganalisis pengaruh screentime berdasarkan tujuan penggunaan terhadap tingkat adiksi gadget, menguji klasifikasi tingkat adiksi gadget menggunakan metode Support Vector Machine, dan menentukan fitur-fitur utama (jenis tujuan penggunaan) yang paling berkontribusi terhadap tingkat adiksi gadget.

Penelitian ini diharapkan dapat membantu dalam penyelesaian terhadap masalah yang telah dijabarkan dengan cara menganalisis pengaruh screentime berdasarkan tujuan penggunaan gadget terhadap tingkat adiksi gadget, menguji klasifikasi tingkat adiksi gadget menggunakan metode Support Vector Machine, dan menentukan faktor-faktor yang paling berpengaruh terhadap tingkat adiksi gadget pada seseorang.

2. TINJAUAN PUSTAKA

Algoritma machine learning telah banyak dimanfaatkan dalam penyelesaian berbagai permasalahan klasifikasi data di berbagai bidang penelitian. Teknologi ini terus mengalami perkembangan yang pesat dan kini digunakan secara luas di berbagai disiplin ilmu [15], Salah satu contoh penerapannya adalah dalam memprediksi permasalahan adiksi, termasuk adiksi terhadap gadget [16]. Salah satu algoritma yang sering digunakan dalam klasifikasi adalah Support Vector Machine (SVM).


Secara dasar, SVM merupakan algoritma klasifikasi biner linear yang berfungsi untuk menentukan batas pemisah antara dua kelas data [17]. contohnya seperti dapat mengkategorikan orang yang memiliki adiksi terhadap gadget dan yang tidak, ataupun dapat mengklasifikasikan tingkat adiksi seseorang [18]. Support Vector Machine (SVM) juga dikenal sebagai salah satu teknik pembelajaran mesin (machine learning) paling mutakhir setelah metode pembelajaran mesin sebelumnya yang dikenal dengan Neural Network (NN) [16].

Metode Support Vector Machine (SVM) banyak dimanfaatkan dalam penelitian berbasis data karena kemampuannya mengklasifikasi data linear maupun non-linear secara efisien [19]. Pada dasarnya, Support Vector Machine (SVM) didasarkan pada prinsip linear. Namun, seiring perkembangannya, SVM kini mampu menangani permasalahan yang bersifat non-linear melalui penerapan konsep kernel. Konsep ini bekerja dengan memetakan data ke dalam ruang

berdimensi tinggi, sehingga pemisahan antar kelas dapat dilakukan menggunakan bidang pemisah atau hyperplane yang optimal di ruang tersebut [20].

SVM memiliki keunggulan karena dapat menemukan batas pemisah antara dua kelompok data yang berbeda [21]. Algoritma Support Vector Machine (SVM) juga memiliki keunggulan berupa dasar teori yang kuat, kemampuan optimasi global, adaptabilitas tinggi, serta kemampuan generalisasi yang baik karena didasarkan pada Statistical Learning Theory (SLT). SVM telah menjadi topik penting dalam penelitian machine learning modern, dengan penerapan yang luas di berbagai bidang seperti pemisahan modern, prediksi protein, dan deteksi wajah. Keunggulan ini menunjukkan bahwa SVM mampu memberikan performa yang stabil dalam berbagai jenis permasalahan klasifikasi dan prediksi [22].

3. METODE PENELITIAN



Gambar 1. Metodologi Penelitian

3.1. Jenis Penelitian

Jenis penelitian ini adalah kuantitatif eksperimental, dengan pendekatan supervised learning melalui algoritma Support Vector Machine (SVM). Penelitian dilakukan menggunakan perangkat lunak Altair AI Studio 2025.1 untuk mengolah dan menganalisis data terkait diksi penggunaan gadget pada remaja.

3.2. Sumber Data

Data yang digunakan bersumber dari situs Kaggle dengan nama dataset :“Teen Smartphone Usage and Addiction Impact Dataset” Dataset ini berisi informasi penggunaan smartphone oleh remaja, termasuk durasi media sosial, gaming, edukasi, dan tingkat adiksi yang diukur dalam skala numerik 1–10. Label Addiction_Level ini dikonversi menjadi kategori Low, Moderate, dan High berdasarkan rentang nilai tertentu untuk kepentingan klasifikasi.

3.3. Variabel Penelitian

Berikut Adalah variable yang akan digunakan dalam model Altair AI Studio

Tabel 1. Variabel

No	Variabel	Tipe Data	Keterangan
1	Daily_Usage_Hours	Numerik	Total Screentime/hari
2	Time_on_Social_Media	Numerik	Screentime di Sosial Media
3	Time_on_Gaming	Numerik	Screentime di Gaming
4	Time_on_Education	Numerik	Screentime di Pendidikan

No	Variabel	Type Data	Keterangan
5	Phone_Checks_Per_Day	Numerik	Frekuensi memeriksa Smartphone/hari
6	Gender	Nominal	Jenis Kelamin
7	Addiction_Level	Numerik	Tingkat Adiksi (1-10)
8	Addiction_Category	Nominal	Kategori Adiksi

3.4. Alat dan Platform

Penelitian ini menggunakan Altair AI Studio, platform analisis data berbasis visual yang memungkinkan pemrosesan data, pelatihan model, machine learning, serta evaluasi performa secara terstruktur dan efisien.

3.5. Prosedur Penelitian

Mengklasifikasikan Tingkat adiksi gadget berdasarkan kebiasaan penggunaan smartphone, seperti penggunaan media sosial, game, edukasi, dan total durasi harian.

3.6. Proses 1 : Prediksi Tingkat Adiksi Berdasarkan Durasi dan Tujuan Penggunaan

Proses pertama dalam penelitian ini bertujuan untuk memprediksi skor numerik dari tingkat adiksi terhadap gadget (Addiction_Level) yang berkisar antara 1 hingga 10. Pemodelan dilakukan dengan pendekatan regresi menggunakan algoritma Support Vector Machine dalam mode Support Vector Regression (SVR). Pendekatan ini dipilih karena variabel target (Addiction_Level) bersifat numerik kontinu, sehingga metode klasifikasi tidak dapat digunakan secara langsung.

Pada proses ini, yang dianalisis adalah pengaruh durasi penggunaan smartphone berdasarkan tujuan penggunaannya, yaitu untuk media sosial, bermain game, pendidikan, serta durasi total penggunaan dan frekuensi pemeriksaan ponsel harian terhadap skor adiksi remaja.

Variabel Input (Fitur) yang Digunakan:

- Time_on_Social_Media : Durasi harian penggunaan media sosial (dalam jam).
- Time_on_Gaming : Durasi harian penggunaan untuk bermain gim (dalam jam).
- Time_on_Education : Durasi harian penggunaan untuk tujuan edukasi (dalam jam).
- Daily_Usage_Hours : Total waktu penggunaan smartphone per hari (dalam jam).
- Phone_Checks_Per_Day : Frekuensi rata-rata dalam sehari pengguna memeriksa smartphone.

Label Target (Output) :

- Addiction_Level : Skor tingkat adiksi berdasarkan rentang 1-10.

Langkah-Langkah Proses di Altair AI Studio :

Penelitian ini diimplementasikan dalam perangkat lunak Altair AI Studio dengan tahapan sebagai berikut:

- Retrieve Dataset
- Select Attributes

- Generate Attributes
- Set Role
- Split Data
- Weight by Correlation
- Support Vector Machine (SVM)
- Apply Model
- Performance (Regression)

3.7. Proses 2 : Klasifikasi Tingkat Adiksi Berdasarkan Gender

Tujuan dari proses kedua adalah untuk mengetahui dan membandingkan jumlah remaja laki-laki dan perempuan yang mengalami tingkat adiksi gadget berbeda (Low, Moderate, dan High). Proses ini bertujuan menjawab rumusan masalah mengenai gender mana yang lebih cenderung mengalami tingkat adiksi gadget tertinggi. Proses ini dilakukan secara deskriptif menggunakan operator Pivot pada Altair AI Studio.

Langkah Konversi Label :

Atribut Addiction_Level pada dataset awal berupa angka dengan skala 1–10. Untuk keperluan klasifikasi, dilakukan proses discretization menggunakan operator Generate Attributes di Altair AI Studio dengan kriteria sebagai berikut:

- $Addiction_Level \geq 7 \rightarrow \text{High}$
- $Addiction_Level \geq 5 \text{ dan } < 7 \rightarrow \text{Moderate}$
- $Addiction_Level < 5 \rightarrow \text{Low}$

Hasil konversi ini disimpan dalam atribut baru bernama Addiction_Category, yang kemudian digunakan sebagai label klasifikasi dalam proses ini.

Variabel Input (Fitur) yang digunakan :

- Gender : Male atau Female

Label Target :

- Addiction_Category (nominal : Low, Moderate, High)

Langkah-langkah Proses di Altair AI Studio :

- Retrieve Dataset
- Select Attribute
- Generate Attribute
- Set Role
- Pivot

3.8. Teknik Pengumpulan Data

- Dataset diperoleh dari Kaggle - Teen Smartphone Usage and Addiction Impact Dataset (<https://www.kaggle.com/datasets/sumedh1507/teen-phone-addiction>)

- b. Data bersifat sekunder dan diperoleh dalam format CSV
- c. Pengumpulan dilakukan secara daring tanpa manipulasi data mentah

3.9. Teknik Analisis Data

Metode analisis data yang digunakan : Menggunakan algoritma Support Vector Machine, Proses analisis dilakukan dalam dua proses seperti yang telah dijelaskan sebelumnya, dan Evaluasi model dilakukan dengan kriteria regresi (RMSE, correlation, R²) dan klasifikasi (jumlah kemunculan per kelas hasil pivot).

3.10. Teknik Validasi

Model divalidasi menggunakan metode Split Data (80:20), dan tidak menggunakan cross-validation karena focus pada eksplorasi hasil prediksi dan pengelompokan

4. HASIL DAN PEMBAHASAN

4.1. Pre-processing Data

Pada tahap ini dilakukan Langkah Langkah berikut :

- a. Select Attributes
Operator ini digunakan untuk memilih atribut yang relevan bagi proses pemodelan. Atribut kategorikal yang tidak diperlukan dalam perhitungan regresi, seperti addiction_category, dihilangkan karena prediksi dilakukan terhadap nilai numerik addiction_level.
- b. Generate Attributes
- c. Tahap ini digunakan apabila terdapat kebutuhan untuk membuat atribut baru atau mengubah representasi atribut tertentu. Pada dataset ini, konversi nilai kategori menjadi label numerik dilakukan sebelumnya sehingga operator ini digunakan untuk validasi struktur atribut.
- d. Set Role
- e. Operator Set Role digunakan untuk menentukan peran atribut target (label) yaitu addiction_level sehingga dikenali sebagai variabel dependen dalam proses regresi.

4.2. Normalisasi Data

Normalisasi merupakan tahap yang sangat penting untuk algoritma SVM karena SVM sensitif terhadap perbedaan skala antar fitur. Pada penelitian ini digunakan operator Normalize dengan metode: Range Transformation (-1 sampai +1). Normalisasi dilakukan menggunakan rumus transformasi linier berikut:

$$x' = \frac{(X - X_{min})}{(X_{max} - X_{min})} \times (b - a) + a$$

Dengan :

x' = nilai hasil normalisasi

x = nilai asli

x_{min} = nilai minimum atribut

x_{max} = nilai maksimum atribut

$a = -1, b = 1$ (batas skala baru)

Row No.	Addiction Le...	Daily Usage ...	Time on Soc...	Time on Ga...	Time on Edu...	Depression ...
1	10	-1.053	-0.824	-1.075	-1.192	-1.198
2	10	-1.008	-1.224	-0.500	-1.126	-1.235
3	9	-0.998	-1.352	-1.125	-1.205	-1.296
4	9	-1.080	-0.904	-1.100	-1.046	-1.123
5	8	-1.098	-0.984	-1.275	-1.073	-1.284
6	8	-1.055	-0.792	-1.500	-1.086	-1.259
7	10	-0.983	-1.112	-0.825	-1.112	-1.198
8	8	-1.020	-1.032	-1.100	-1.007	-1.222
9	7	-1.083	-0.968	-0.950	-0.954	-1.259
10	9	-1.056	-0.968	-1.400	-1.086	-1.235
11	10	-1.026	-0.904	-1.350	-1.179	-1.272
12	9	-1.126	-1.096	-0.825	-1.033	-1.136
13	10	-0.950	-0.712	-1.400	-1.231	-1.198
14	10	-0.911	-0.728	-1.175	-0.914	-1.235
15	10	-0.980	-0.800	-1.200	-1.364	-1.235
16	10	-1.041	-1.048	-1.125	-0.914	-1.136
17	10	-1.011	-0.984	-1.175	-0.914	-1.210
18	10	-1.083	-0.920	-1.025	-1.152	-1.296
19	10	-0.935	-1.048	-1.025	-1.179	-1.272
20	10	-1.011	-1.144	-1.250	-1.139	-1.247

Gambar 2. Normalisasi Data

Transformasi ini mengubah seluruh atribut numerik ke rentang -1 hingga +1, yang bertujuan:


- a. Menyamakan skala data agar SVM bekerja lebih optimal
- b. Menghindari dominasi fitur dengan skala besar
- c. Meningkatkan stabilitas perhitungan kernel

4.3. Pembagian Data (Split Data)

Data dibagi menjadi dua bagian dengan 3 pengujian yaitu Training Set sebesar 60%, Testing Set sebesar 40%, Training Set sebesar 70%, Testing Set sebesar 30%, dan juga Training Set sebesar 80%, dan Testing Set sebesar 20%. Pembagian ini bertujuan untuk memungkinkan evaluasi performa model pada data yang tidak ikut dilatih, sehingga hasil evaluasi menjadi lebih representatif.

4.4. Implementasi Support Vector Machine

Pada tahap ini, proses pemodelan dilakukan menggunakan algoritma Support Vector Machine (SVM) Regression yang diimplementasikan melalui operator SVM pada Altair AI Studio. SVM Regression dipilih karena kemampuannya menghasilkan model prediktif yang stabil pada data non-linear melalui penggunaan fungsi kernel.



Gambar 3. Rancangan Altair AI Studio

Model dilatih menggunakan data yang telah melalui tahapan praproses, termasuk seleksi atribut, pembuatan atribut turunan, pengaturan peran label, serta normalisasi Range Transformation (-1 sampai

+1). Setelah itu, data dilewatkan ke operator SVM dengan konfigurasi parameter sebagai berikut :

- a. Kernel type : Radial (RBF Kernel)
Fungsi kernel didefinisikan sebagai :
 $K = (x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$
Parameter yang digunakan :
 - Kernel type : radial
 - Kernel gamma : 0.01
- b. Parameter Regularisasi
Parameter C = 100.0 berfungsi sebagai pengatur keseimbangan antara margin yang lebar dan error prediksi. Nilai C yang cukup besar membuat model memberikan penalti lebih besar pada error sehingga model lebih “ketat” dalam menyesuaikan data.
- c. Parameter Konvergensi dan Iterasi
Untuk memastikan proses pelatihan berjalan optimal, digunakan : Convergence epsilon : 0.01
Nilai ini mengatur toleransi terhadap perubahan error pada iterasi model. Lalu Max iterations = 5000, Memberikan cukup ruang bagi algoritma untuk menemukan solusi optimal.
- d. Parameter ϵ pada SVM Regression
Pada SVM Regression, parameter epsilon (ϵ) mengontrol lebar epsilon-insensitive tube, yaitu area di mana kesalahan tidak akan dikenakan penalti.
Parameter yang digunakan :
 - Epsilon = 0.001
 - Epsilon plus = 0.001
 - Epsilon minus = 0.001
 Nilai epsilon yang kecil membuat model lebih sensitif terhadap variasi data sehingga dapat meningkatkan akurasi prediksi.
- e. Parameter L pos dan L neg
Nilai :
 - L pos = 1.0
 - L neg = 1.0
 digunakan untuk memberikan bobot seimbang pada nilai positif dan negatif dalam fungsi loss, karena data tidak menunjukkan ketidakseimbangan distribusi target yang signifikan.

4.5. Evaluasi Model

Evaluasi dilakukan menggunakan operator Performance (Regression) yang menghasilkan Metrik:

- a. Root Mean Squared Error (RMSE)
- b. Correlation
- c. Squared Correlation (R2)

Dengan 3 pengujian yang berbeda hasil sebagai berikut :

PerformanceVector

```
PerformanceVector:
root_mean_squared_error: 1.084 +/- 0.000
correlation: 0.803
squared_correlation: 0.645
```

Gambar 4. Performa Model 1

Model 1 (Split 60:40) :

Model 1 menghasilkan RMSE sebesar 1.084, yang berarti rata-rata kesalahan prediksi model berada di sekitar ± 1 poin dari nilai sebenarnya. Nilai ini merupakan yang paling tinggi di antara ketiga model, sehingga akurasinya paling rendah karena data training lebih sedikit. Nilai korelasi sebesar 0.803 menunjukkan hubungan yang kuat antara prediksi dan nilai aktual, namun masih lebih rendah dibanding Model 3. Nilai r^2 sebesar 0.645 berarti Model 1 mampu menjelaskan 64,5% variasi tingkat adiksi. Angka ini tergolong cukup baik, namun paling rendah di antara ketiga model.

PerformanceVector

```
PerformanceVector:
root_mean_squared_error: 1.071 +/- 0.000
correlation: 0.803
squared_correlation: 0.646
```

Gambar 5. Performa Model 2

Model 2 (Split 70:30)

Model 2 menghasilkan RMSE sebesar 1.071, sedikit lebih baik dibanding Model 1. Rata-rata kesalahan prediksi tetap sekitar ± 1 poin, tetapi lebih stabil karena porsi data training lebih besar. Nilai korelasi tetap 0.803, sama dengan Model 1, yang menunjukkan bahwa peningkatan jumlah data training belum terlalu mempengaruhi kekuatan hubungan prediksi. Nilai r^2 sebesar 0.646, menunjukkan kemampuan model menjelaskan 64,6% variansi data. Hasil ini hanya sedikit meningkat dibanding Model 1.

PerformanceVector

```
PerformanceVector:
root_mean_squared_error: 0.937 +/- 0.000
correlation: 0.859
squared_correlation: 0.738
```


Gambar 6. Performa Model 3

Model 3 (Split 80:20)

Model 3 memberikan performa terbaik dengan RMSE sebesar 0.937, yang merupakan nilai terendah. Hal ini menunjukkan bahwa model melakukan prediksi dengan kesalahan paling kecil. Nilai korelasi meningkat menjadi 0.859, menunjukkan hubungan yang sangat kuat antara prediksi dan nilai asli. Model 3 lebih mampu mengikuti pola data karena mendapatkan data training paling banyak. Nilai r^2 sebesar 0.738, yang berarti Model 3 dapat menjelaskan 73,8% variansi tingkat adiksi, jauh lebih tinggi daripada Model 1 dan Model 2.

4.6. Pembahasan

Berdasarkan hasil evaluasi, dapat disimpulkan bahwa SVM Regression mampu memprediksi tingkat kecanduan ponsel remaja dengan performa yang cukup baik. Nilai korelasi yang tinggi dan RMSE yang rendah menunjukkan bahwa model memiliki kemampuan generalisasi yang baik.



Gambar 7. Pengaruh berdasarkan tujuan penggunaan

Daily Usage Hours (Weight = 1.00)

Weight = 1.00 artinya faktor ini dijadikan pembanding utama (100%). Atribut ini memiliki pengaruh paling tinggi terhadap kecanduan gadget. Nilai bobot 1.00 menunjukkan bahwa semakin lama durasi penggunaan smartphone per hari, semakin tinggi kemungkinan seseorang mengalami kecanduan. Ini menjadi faktor dominan yang menjelaskan perilaku adiktif.

Time on Social Media (Weight ≈ 0.29), Aktivitas di media sosial memiliki pengaruh sekitar 29% dari kekuatan faktor utama (Daily Usage Hours). Waktu penggunaan media sosial juga memiliki pengaruh cukup kuat. Nilai ini menunjukkan bahwa aktivitas di media sosial menjadi salah satu pemicu signifikan kecanduan, meskipun tidak sedominan durasi total penggunaan harian.

Time on Gaming (Weight ≈ 0.23), Angka 0.23 menunjukkan bahwa bermain game memberikan pengaruh 23% dibanding faktor utama. Bermain game memiliki hubungan yang cukup jelas dengan kecanduan gadget. Pengaruhnya berada sedikit di bawah media sosial, namun tetap menjadi faktor penting. Individu yang menghabiskan lebih banyak waktu untuk gaming menunjukkan kecenderungan kecanduan yang lebih tinggi.

Phone Checks/day (Weight ≈ 0.17), Kebiasaan sering cek HP (mengecek notifikasi, unlock HP, dll) memiliki pengaruh 17%. Frekuensi pengecekan HP per hari juga berpengaruh, meskipun tidak sekuat tiga variabel sebelumnya. Semakin sering seseorang memeriksa smartphone, semakin besar indikasi adanya perilaku kompulsif yang terkait dengan kecanduan.


Time on Education, Time on Education memiliki bobot mendekati 0, mengindikasikan bahwa variabel ini tidak memberikan pengaruh signifikan terhadap tingkat adiksi. Setelah mendapatkan hasil dari pengaruh tujuan penggunaan terhadap adiksi, selanjutnya adalah membahas tingkat adiksi berdasarkan gender untuk mengetahui apakah ada faktor yang membedakan tingkat adiksi antara gender Male dan Female.

Hasil Pivot menunjukkan distribusi kategori sebagai berikut :

Tabel 2. Tingkat adiksi berdasarkan gender

Gender	Low	Moderate	High
Female	25	105	877
Male	34	119	863
Other	37	99	841

Setiap kategori gender menunjukkan kecenderungan dominan pada kategori "High", menandakan bahwa adiksi smartphone yang tinggi pada seluruh kelompok.




Gambar 8. Faktor yang mempengaruhi adiksi pada gender (male)

Hasil pengujian Weight by Correlation untuk responden laki-laki menunjukkan bahwa Time_on_Social_Media adalah faktor yang paling berpengaruh terhadap tingkat kecanduan gadget, dengan bobot tertinggi yaitu 1.0. Artinya, durasi penggunaan media sosial memiliki hubungan paling kuat dengan peningkatan tingkat kecanduan pada laki-laki.

Faktor kedua adalah Time_on_Gaming, yang memiliki bobot 0.895. Nilai ini menunjukkan bahwa aktivitas bermain game juga berkontribusi besar terhadap kecanduan. Hal ini konsisten dengan pola penggunaan gadget laki-laki yang cenderung menghabiskan lebih banyak waktu untuk bermain game.

Sementara itu, Time_on_Education memiliki bobot 0, yang berarti aktivitas pendidikan tidak memberikan pengaruh signifikan terhadap kecanduan gadget pada laki-laki. Penggunaan gadget untuk tujuan belajar cenderung tidak memicu perilaku adiktif. Secara keseluruhan, kecanduan gadget pada laki-laki paling banyak dipengaruhi oleh penggunaan media sosial, diikuti oleh aktivitas gaming, sedangkan

penggunaan untuk pendidikan tidak memberikan kontribusi yang berarti.



Gambar 9. Faktor yang mempengaruhi adiksi pada gender (female)

Berdasarkan pengujian Weight by Correlation pada data responden perempuan, diperoleh bahwa *Time_on_Social_Media* merupakan faktor yang paling berpengaruh terhadap tingkat kecanduan gadget, dengan bobot tertinggi yaitu 1.0. Hal ini menunjukkan bahwa semakin besar durasi penggunaan media sosial, semakin tinggi tingkat kecanduan yang muncul.

Faktor kedua yang berpengaruh Adalah *Time_on_Gaming* dengan bobot 0.789, yang berarti aktivitas bermain game juga berkontribusi cukup kuat terhadap kecanduan, meskipun tidak sebesar media sosial.

Sementara itu, *Time_on_Education* memperoleh bobot 0, menunjukkan bahwa aktivitas pendidikan tidak memiliki pengaruh signifikan terhadap kecanduan gadget pada responden perempuan. Secara keseluruhan, hasil ini menegaskan bahwa media sosial adalah faktor utama penyebab kecanduan, diikuti oleh aktivitas gaming, sedangkan penggunaan gadget untuk tujuan pendidikan tergolong aman dan tidak memicu kecanduan.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian mengenai prediksi tingkat adiksi gadget pada remaja menggunakan algoritma Support Vector Machine (SVM) serta analisis pengaruh tujuan penggunaan smartphone, maka dapat ditarik beberapa kesimpulan sebagai berikut : Durasi penggunaan smartphone per hari merupakan faktor paling dominan dalam mempengaruhi tingkat adiksi dengan (Weight = 1.00), tujuan penggunaan smartphone seperti media sosial dan gaming memberikan pengaruh yang cukup signifikan dengan (Weight $\pm$ 0.29, dan $\pm$ 0.23), dan frekuensi seseorang memeriksa smartphone juga cukup berpengaruh terhadap tingkat adiksi (Weight $\pm$ 0.17).

Bagi peneliti selanjutnya agar dapat munakan dataset yang lebih beragam dan bandingkan dengan algoritma lain agar hasil lebih akurat, dan bagi pengembang teknologi agar dapat mengembangkan fitur atau aplikasi monitoring penggunaan gadget untuk membantu pengguna mengontrol kebiasaan digital.

DAFTAR PUSTAKA

- [1] E. Management, T. Masfufah, and M. & D. Darmawan, "The Role of Parents in Preventing Gadget Addiction in Early Childhood," *ISSE Int. J. Serv. Sci.*, vol. 3, no. 3, pp. 33–38, 2023.
- [2] R. Saputra, "Pengaruh Penggunaan Smartphone Terhadap Kesehatan Remaja (Literature Review)," *J. Kesehat. Lentera 'Aisyiyah*, vol. 6, no. 2, pp. 774–779, 2023, [Online]. Available: <https://backup.politasumbar.ac.id/index.php/jl/article/view/177>
- [3] S. Y. Yang, Y. C. Wang, Y. C. Lee, Y. L. Lin, P. L. Hsieh, and P. H. Lin, "Does Smartphone Addiction, Social Media Addiction, and/or Internet Game Addiction Affect Adolescents' Interpersonal Interactions?," *Healthc.*, vol. 10, no. 5, 2022, doi: 10.3390/HEALTHCARE10050963.
- [4] H. W. Huang *et al.*, "Classification of internet addiction using machine learning on electroencephalography synchronization and functional connectivity," *Psychol. Med.*, vol. 55, 2025, doi: 10.1017/S0033291725001035.
- [5] J. Liu, X. Yu, L. Kong, and X. Zhou, "Prevalence and factors associated with smartphone addiction among nursing postgraduates during the COVID-19 pandemic: a multilevel study from China's mainland," *BMC Psychiatry*, vol. 23, no. 1, pp. 1–11, 2023, doi: 10.1186/s12888-023-05369-5.
- [6] Y. Wacks and A. M. Weinstein, "Excessive Smartphone Use Is Associated With Health Problems in Adolescents and Young Adults," *Front. Psychiatry*, vol. 12, no. May, pp. 1–7, 2021, doi: 10.3389/fpsyt.2021.669042.
- [7] M. M. Liza *et al.*, "Gadget addiction among school-going children and its association to cognitive function: A cross-sectional survey from Bangladesh," *BMJ Paediatr. Open*, vol. 7, no. 1, pp. 1–7, 2023, doi: 10.1136/bmjpo-2022-001759.
- [8] A. Arora, P. Chakraborty, M. P. S. Bhatia, and A. Puri, "Intelligent Model for Smartphone Addiction Assessment in University Students using Android Application and Smartphone Addiction Scale," *Int. J. Educ. Manag. Eng.*, vol. 13, no. 1, pp. 29–34, 2023, doi: 10.5815/ijeme.2023.01.04.
- [9] A. H. Bahagianti Sajidah, I. Jayanti, N. Rahman, and A. Yulianto, "Differences in Smartphone Addiction between Male and Female Adolescents," *J. Ment. Heal. Issues Behav.*, no. 44, pp. 1–7, 2024, doi: 10.55529/jmhib.44.1.7.
- [10] Y. Y. Wu and W. H. Chou, "Smartphone addiction, gender and interpersonal attachment: A cross-sectional analytical survey in Taiwan," *Digit. Heal.*, vol. 9, 2023, doi: 10.1177/20552076231177134.
- [11] E. Wahyudi, Z. Saam, N. Nofrizal, J. Juandi, and T. Thamrin, "The Effects of

- Smartphones/Gadgets Use on Senior High School Students in Padang City,” *Open Access Maced. J. Med. Sci.*, vol. 11, no. E, pp. 249–256, 2023, doi: 10.3889/oamjms.2023.11395.
- [12] “Prediction of Electronic Gadget Addiction Among Students Using Machine Learning,” *Int. Res. J. Mod. Eng. Technol. Sci.*, vol. 13, no. 6, pp. 618–637, 2025, doi: 10.56726/irjmets70217.
- [13] A. Children, “(Jurnal Keperawatan Jiwa) ANALYSIS OF SMARTPHONE ADDICTION WITH ANXIETY IN SCHOOL-,” vol. 6, no. 1, 2024.
- [14] A. K. S. K. Gupta, P. S. B. Singh, and A. K. S. Krishak, “Smartphone addiction: impact on health and well-being,” *Int. J. Community Med. Public Heal.*, vol. 11, no. 5, pp. 2100–2106, 2024, doi: 10.18203/2394-6040.ijcmph20241213.
- [15] N. H. Ovirianti, M. Zarlis, and H. Mawengkang, “Support Vector Machine Using A Classification Algorithm,” *Sinkron*, vol. 7, no. 3, pp. 2103–2107, 2022, doi: 10.33395/sinkron.v7i3.11597.
- [16] S. Likhith, C. Chitteti, M. Dharani, V. Nivedhitha, N. G. Geethika, and V. Godwin, “Machine Learning Model for Prediction of Smartphone Addiction,” *Proc. - 2024 Int. Conf. Expert Clouds Appl. ICOECA 2024*, pp. 924–929, 2024, doi: 10.1109/ICOECA62351.2024.00163.
- [17] M. Sheykhmousa, M. Mahdianpari, H. Ghanbari, F. Mohammadimanesh, P. Ghamisi, and S. Homayouni, “Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review,” *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 13, pp. 6308–6325, 2020, doi: 10.1109/JSTARS.2020.3026724.
- [18] M. H. Almaspoor, A. Safaei, A. Salajegheh, and B. Minaei-Bidgoli, “Support Vector Machines in Big Data Classification: A Systematic Literature Review,” *ResearchSquare*, pp. 1–34, 2021, [Online]. Available: <https://www.researchsquare.com/article/rs-663359/v1>
- [19] S. Muawanah, U. Muzayanah, M. G. R. Pandin, M. D. S. Alam, and J. P. N. Trisnaningtyas, “Stress and Coping Strategies of Madrasah’s Teachers on Applying Distance Learning During COVID-19 Pandemic in Indonesia,” *Qubahan Acad. J.*, vol. 3, no. 4, pp. 206–218, 2023, doi: 10.48161/Issn.2709-8206.
- [20] M. Gayathri, P. Gowtham, M. Shankar, and M. Hemanth, “Prediction of Electronic Gadget Addiction Among Students Using Machine Learning,” *Int. Res. J. Mod. Eng. Technol. Sci.*, no. 03, pp. 7661–7668, 2025, doi: 10.56726/irjmets70217.
- [21] A. Rahmah, N. Sepriyanti, M. H. Zikri, I. Ambarani, and M. Y. bin Shahr, “Implementation of Support Vector Machine and Random Forest for Heart Failure Disease Classification,” *Public Res. J. Eng. Data Technol. Comput. Sci.*, vol. 1, no. 1, pp. 34–40, 2023, doi: 10.57152/predatecs.v1i1.816.
- [22] Z. Jun, “The Development and Application of Support Vector Machine,” *J. Phys. Conf. Ser.*, vol. 1748, no. 5, 2021, doi: 10.1088/1742-6596/1748/5/052006.
- [23] C. Anderl, M. K. Hofer, and F. S. Chen, “Directly-measured smartphone screen time predicts well-being and feelings of social connectedness,” *J. Soc. Pers. Relat.*, vol. 41, no. 5, pp. 1073–1090, 2024, doi: 10.1177/02654075231158300.
- [24] A. M. Rodman, J. A. Burns, G. K. Cotter, Y. G. B. Ohashi, R. K. Rich, and K. A. McLaughlin, “Within-Person Fluctuations in Objective Smartphone Use and Emotional Processes During Adolescence: An Intensive Longitudinal Study,” *Affect. Sci.*, vol. 5, no. 4, pp. 332–345, 2024, doi: 10.1007/s42761-024-00247-z.
- [25] M. Anshori and G. Pangestu, “Support vector model to predict smartphone addiction in early adolescents,” *AIP Conf. Proc.*, vol. 2927, no. 1, pp. 5–12, 2024, doi: 10.1063/5.0192301.