



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 4 No. 4 (2026) pp: 14842-14851

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Penerapan Metode Decision Tree untuk Memprediksi Dampak Kesehatan Akibat Penggunaan Gadget

Noperla Anjelisari Lumbanbatu¹, Yadi Limanta Maha², Sardo PardingotanSipayung³

^{1,2,3}Teknik Informatika, Fakultas Ilmu Komputer, Universitas Katolik Santo Thomas Medan

noverlaanjelii@gmail.com, Yadimaha05@gmail.com

Abstrak

Perkembangan teknologi informasi dan komunikasi yang semakin pesat telah mendorong peningkatan penggunaan gadget seperti smartphone, tablet, dan laptop dalam berbagai aktivitas kehidupan sehari-hari, mulai dari komunikasi, pekerjaan, pendidikan, hingga hiburan. Meskipun memberikan banyak kemudahan, penggunaan gadget dengan intensitas tinggi dan durasi yang panjang berpotensi menimbulkan berbagai dampak negatif terhadap kesehatan fisik maupun mental pengguna. Oleh karena itu, diperlukan suatu pendekatan berbasis data untuk menganalisis serta memprediksi tingkat dampak kesehatan akibat penggunaan gadget secara objektif dan sistematis. Penelitian ini bertujuan untuk menganalisis dan memprediksi dampak kesehatan pengguna gadget menggunakan algoritma Decision Tree. Metode penelitian yang digunakan adalah pendekatan kuantitatif dengan teknik data mining. Data yang digunakan merupakan data sekunder yang diperoleh dari platform Kaggle, yang mencakup beberapa variabel penting, yaitu usia, jenis kelamin, pekerjaan, mode kerja, dan durasi penggunaan layar harian. Proses klasifikasi dilakukan dengan membangun model Decision Tree berdasarkan perhitungan nilai entropy dan Information Gain untuk menentukan atribut yang paling berpengaruh dalam proses pengambilan keputusan. Hasil penelitian menunjukkan bahwa atribut mode kerja (work mode) merupakan faktor paling dominan dalam menentukan tingkat dampak kesehatan pengguna gadget, diikuti oleh durasi penggunaan layar serta karakteristik individu lainnya. Model Decision Tree yang dihasilkan mampu mengklasifikasikan dampak kesehatan ke dalam dua kategori, yaitu Low dan Good, dengan aturan keputusan yang jelas dan mudah dipahami. Penelitian ini menyimpulkan bahwa intensitas penggunaan gadget dan karakteristik pengguna memiliki pengaruh signifikan terhadap kondisi kesehatan, sehingga pengelolaan penggunaan gadget secara bijak sangat diperlukan untuk meminimalkan risiko dampak kesehatan yang merugikan.

Kata kunci: Penggunaan Gadget, Dampak Kesehatan, Data Mining, Decision Tree, Klasifikasi

1. Latar Belakang

Perkembangan teknologi informasi dan komunikasi yang pesat telah meningkatkan penggunaan perangkat digital seperti smartphone, tablet, dan laptop dalam kehidupan sehari-hari, yang berdampak pada perubahan perilaku aktivitas fisik masyarakat. Kajian menunjukkan bahwa semakin panjang durasi *screen time* atau waktu yang dihabiskan di depan layar berkaitan dengan peningkatan perilaku sedentari, yaitu aktivitas fisik yang rendah dan waktu duduk yang lebih lama, yang berimplikasi negatif terhadap kesehatan fisik anak dan remaja. Penelitian menemukan bahwa penggunaan perangkat digital yang berlebihan berkaitan dengan meningkatnya risiko obesitas dan pola hidup tidak aktif karena waktu yang seharusnya digunakan untuk aktivitas fisik digantikan oleh aktivitas berbasis layar digital [1].

Beberapa studi juga melaporkan hubungan antara durasi penggunaan gadget dengan kesehatan mental individu. Penelitian pada siswa menunjukkan bahwa durasi *screen time* berkorelasi positif dengan kondisi psikologis seperti stres dan kecemasan, dimana semakin tinggi durasi waktu layar maka kecenderungan masalah kesehatan mental juga meningkat. Hal ini sejalan dengan temuan bahwa lama penggunaan gadget berhubungan signifikan dengan gangguan emosional pada anak sekolah dasar [2].

Selain itu, penggunaan smartphone yang lama juga berkaitan dengan kondisi psikologis negatif lainnya seperti gejala depresi pada remaja, menunjukkan bahwa paparan layar digital dalam jangka panjang tidak hanya mempengaruhi kesehatan fisik tetapi juga kesejahteraan mental [3].

Berdasarkan hubungan antara *screen time*, perilaku sedentari, dan dampaknya terhadap kesehatan fisik serta mental tersebut, pendekatan berbasis analisis data menjadi penting untuk memahami dan memprediksi pola pengaruh durasi penggunaan gadget terhadap kesehatan. Metode seperti *data mining* dan algoritma klasifikasi

telah banyak diterapkan untuk mengevaluasi data kesehatan yang besar dan membuat prediksi risiko kesehatan yang dapat diinterpretasikan secara efektif. Dengan demikian, penerapan algoritma Decision Tree dalam penelitian ini diarahkan untuk mengidentifikasi tingkat risiko kesehatan yang berkaitan dengan intensitas penggunaan gadget, sehingga diharapkan dapat memberikan gambaran yang lebih jelas dan mendukung strategi pengelolaan penggunaan perangkat digital secara bijak [4][5].

1. Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode *data mining* untuk memprediksi dampak kesehatan yang ditimbulkan oleh intensitas penggunaan gadget. Pendekatan kuantitatif dipilih karena memungkinkan pengolahan dan analisis data secara terstruktur guna mengidentifikasi pola, kecenderungan, serta hubungan antarvariabel yang dapat digunakan dalam proses prediksi [6].

Metode *data mining* banyak diterapkan dalam bidang kesehatan karena mampu mengekstraksi pengetahuan tersembunyi dari kumpulan data berukuran besar dan mendukung pengambilan keputusan berbasis data. Menurut Han, Kamber, dan Pei, data mining merupakan proses penting untuk menemukan pola yang bermakna dan informasi baru dari basis data yang kompleks, termasuk data yang berkaitan dengan perilaku dan kondisi kesehatan manusia [7].

Algoritma yang digunakan dalam penelitian ini adalah *Decision Tree*. Algoritma *Decision Tree* dipilih karena mampu menghasilkan model klasifikasi yang mudah dipahami dan diinterpretasikan, baik oleh peneliti maupun pengguna non-teknis. Selain itu, algoritma ini dapat diterapkan pada data dengan tipe kategorikal maupun numerik, sehingga sesuai dengan karakteristik data penggunaan gadget dan dampak kesehatan [8]. Model klasifikasi yang dihasilkan disajikan dalam bentuk struktur pohon keputusan yang merepresentasikan aturan-aturan keputusan secara sistematis dan jelas.

Berdasarkan data yang telah dikumpulkan, model *Decision Tree* dibangun dengan melakukan perhitungan nilai *entropy* dan *Information Gain* untuk menentukan atribut yang paling berpengaruh dalam proses klasifikasi. *Information Gain* digunakan sebagai kriteria pemilihan atribut karena mampu mengukur seberapa besar suatu atribut dapat mengurangi tingkat ketidakpastian data setelah dilakukan pemisahan [9].

2.1. Pengumpulan Data

Pengumpulan data merupakan tahap awal dalam penelitian yang bertujuan untuk memperoleh data yang relevan dengan tujuan penelitian. Dalam penelitian ini, data yang digunakan merupakan data sekunder yang diperoleh dari platform Kaggle, yaitu sebuah platform penyedia dataset terbuka yang banyak digunakan dalam penelitian akademik di bidang *data mining* dan *machine learning* [10][11]. Dataset yang digunakan berisi data terkait perilaku penggunaan gadget, seperti durasi penggunaan harian, frekuensi penggunaan, jenis aktivitas yang dilakukan menggunakan gadget, serta keluhan atau kondisi kesehatan yang dilaporkan oleh pengguna. Kaggle menyediakan berbagai dataset yang telah terstruktur dan dapat diakses secara bebas oleh peneliti untuk keperluan eksplorasi data, pemodelan, serta pengujian algoritma pembelajaran mesin. Data ini digunakan sebagai dasar dalam proses analisis dan klasifikasi untuk memprediksi tingkat dampak kesehatan akibat intensitas penggunaan gadget.

2.2. Pemodelan Decision Tree

Pemodelan *Decision Tree* merupakan salah satu metode *supervised learning* yang digunakan untuk melakukan klasifikasi dengan membangun struktur pohon berdasarkan atribut-atribut input. Setiap simpul (node) pada pohon keputusan merepresentasikan pengujian terhadap suatu atribut, cabang menunjukkan hasil dari pengujian tersebut, sedangkan simpul daun (leaf node) merepresentasikan kelas atau label hasil klasifikasi [13]. Pendekatan ini memungkinkan penelitian untuk secara sistematis memetakan aturan keputusan berdasarkan karakteristik data, sehingga mempermudah interpretasi hasil analisis.

Keunggulan utama algoritma *Decision Tree* adalah tingkat interpretabilitasnya yang tinggi. Struktur pohon keputusan yang dihasilkan dapat dibaca dan dipahami oleh peneliti maupun pengguna non-teknis, berbeda dengan metode *black box* lain seperti *neural network*. Selain itu, algoritma ini fleksibel dalam menangani data dengan tipe numerik maupun kategorikal, sehingga sesuai dengan karakteristik dataset penelitian ini yang mencakup durasi penggunaan gadget, jenis aktivitas, dan kondisi kesehatan pengguna [14]. Dengan kemampuannya tersebut, *Decision Tree* menjadi metode populer dalam penelitian data mining, khususnya untuk prediksi dampak kesehatan berdasarkan intensitas penggunaan gadget.

Dalam membangun model *Decision Tree*, pemilihan atribut yang paling berpengaruh dilakukan menggunakan *Information Gain*. *Information Gain* dihitung berdasarkan nilai *entropy*, yang mengukur tingkat ketidakpastian atau ketidakhomogenan data dalam suatu dataset. Atribut dengan *Information Gain* tertinggi dipilih sebagai titik pemisahan pada setiap node, karena mampu mengurangi ketidakpastian secara maksimal, sehingga memperkuat kemampuan model dalam mengklasifikasikan data dengan akurat [15].

Entropy dihitung menggunakan Persamaan 1.

$$Entropy(S) = \sum_{i=1}^n -P_i * \log_2 P_i \quad (1)$$

Dimana :

S merupakan himpunan data (dataset),

P_i merupakan proporsi data yang termasuk dalam kelas ke-i

n merupakan jumlah kelas dalam dataset.

Selanjutnya, nilai *Information Gain* digunakan untuk menentukan atribut terbaik dalam membagi data, yaitu atribut yang mampu memberikan pengurangan ketidakpastian terbesar setelah data dipisahkan.

Information Gain dihitung menggunakan Persamaan 2.

$$Entropy(S, A) = Entropy(S) - \sum_{i=1}^n \frac{|S_i|}{|S|} * Entropy(S_i) \quad (2)$$

Dimana :

S merupakan dataset awal,

A merupakan atribut yang dipilih,

S_i merupakan subset data hasil pemisahan berdasarkan Atribut A,

S merupakan jumlah seluruh data dalam dataset.

Dengan menggunakan *Information Gain* sebagai dasar pemilihan atribut, model *Decision Tree* yang dihasilkan diharapkan mampu menghasilkan klasifikasi yang akurat dan mudah diinterpretasikan dalam memprediksi dampak kesehatan akibat penggunaan gadget.

3. Hasil dan Pembahasan

Bagian ini menyajikan hasil penelitian dan pembahasan yang diperoleh dari proses pengolahan dan analisis data menggunakan metode *Decision Tree*. Hasil penelitian disajikan secara sistematis, dimulai dari pengumpulan data, deskripsi karakteristik data, hingga hasil klasifikasi dampak kesehatan yang disebabkan oleh intensitas penggunaan gadget. Selanjutnya, pembahasan dilakukan untuk menginterpretasikan hasil klasifikasi yang diperoleh serta mengaitkannya dengan tujuan penelitian.

3.1. Pengumpulan Data

Pada penelitian ini, dataset yang digunakan untuk memprediksi dampak kesehatan akibat penggunaan gadget diperoleh dari repositori terbuka Kaggle. Dataset tersebut terdiri dari beberapa atribut, yaitu usia (*Age*), jenis kelamin (*Gender*), pekerjaan (*Occupation*), mode kerja (*Work Mode*), dan durasi penggunaan layar (*Screen Time Hours*). Atribut-atribut tersebut berperan sebagai variabel prediktor yang digunakan untuk mengklasifikasikan pengguna ke dalam dua tingkat dampak kesehatan, yaitu *Low* dan *Good*.

Tabel 1. Data Awal Penggunaan Gadget

Name	age	gender	occupation	work_mode	screen_time_hours	healt
Aditi	33	Female	Employed	Remote	11	Low
Anjali	28	Female	Employed	In-person	8	Good
Priya	35	Female	Employed	Hybrid	10	Low
Kavya	42	Male	Employed	Hybrid	12	Low
Sneha	28	Male	Student	Remote	14	Low
Nisha	28	Female	Self-employed	Hybrid	10	Low
Riya	42	Female	Unemployed	Remote	7	Low
Shreya	36	Male	Employed	In-person	7	Low

Pooja	26	Male	Student	In-person	7	Good
Meera	34	Male	Employed	Hybrid	10	Low
Sanya	26	Male	Student	Remote	10	Low
Divya	26	Female	Unemployed	Hybrid	5	Low
Ayesha	31	Female	Student	Remote	13	Low
Neha	16	Female	Employed	Remote	8	Low
Smita	16	Male	Employed	Hybrid	10	Low
Radhika	25	Male	Employed	Hybrid	14	Low
Ananya	21	Female	Employed	In-person	9	Good
Isha	32	Male	Self- employed	Hybrid	8	Low
Swati	22	Male	Student	Hybrid	9	Good
Jyoti	18	Female	Student	Remote	11	Low
Kiran	41	Female	Student	Remote	11	Low
Sapna	28	Male	Unemployed	Remote	8	Low
Alka	30	Male	Self- employed	In-person	8	Good
Rekha	18	Male	Employed	Remote	6	Low
Mansi	25	Male	Unemployed	In-person	9	Low
Pallavi	30	Male	Employed	Hybrid	8	Low
Bhavna	20	Male	Student	Remote	12	Low
Sheetal	33	Male	Unemployed	In-person	7	Low
Nupur	25	Male	Employed	Hybrid	8	Good
Charu	27	Female	Employed	In-person	10	Low
Rajat	25	Female	Employed	In-person	7	Good
Nishant	44	Female	Student	Remote	15	Low
Pranav	29	Male	Student	Remote	7	Low
Aryan	21	Male	Employed	Hybrid	12	Low
ameya	36	Male	Student	In-person	14	Low
devansh	20	Female	Employed	Remote	8	Low
harshit	31	Female	Student	Hybrid	10	Low
Ravi	16	Female	Employed	Hybrid	9	Low
Ajay	19	Female	Employed	In-person	8	Good
laksh	31	Male	Employed	Remote	9	Low
Harsh	35	Female	Employed	In-person	6	Good
Shivam	31	Female	Employed	In-person	10	Low
Ayush	29	Male	Employed	Remote	8	Low
Tejas	27	Female	Employed	Remote	12	Low
Veer	18	Female	Employed	In-person	7	Good
Abhiram	24	Male	Unemployed	Remote	7	Low
Rajesh	26	Female	Employed	In-person	8	Good
hariom	38	Male	Student	Remote	15	Low
rohit	32	Male	Student	Remote	10	Low
anurag	16	Male	Employed	In-person	14	Good
chetan	32	Female	Employed	Hybrid	7	Low
abhijeet	26	Male	Student	Remote	11	Low
divan	24	Female	Employed	Hybrid	9	Low
akilesh	34	Female	Employed	Hybrid	11	Low
sanjay	38	Female	Employed	Remote	10	Low
dheeraj	37	Male	Employed	Hybrid	8	Low
vishal	23	Female	Student	In-person	7	Good
azhar	27	Female	Student	Remote	8	Low
ankit	32	Male	Employed	Hybrid	12	Low
pradumman	37	Female	Employed	Hybrid	9	Low
ritesh	26	Female	Employed	In-person	11	Low
shekhar	28	Female	Employed	Remote	10	Low
vishal	21	Female	Student	In-person	12	Good
parvind	20	Female	Self- employed	Hybrid	8	Good
dharam	36	Female	Employed	Remote	7	Low
vijay	40	Male	Employed	Remote	6	Low
ajay	29	Female	Employed	Remote	12	Low
ujjwaal	38	Female	Employed	Hybrid	9	Low
jayram	32	Male	Employed	Hybrid	7	Low
kaushal	24	Female	Student	In-person	9	Good
daksh	32	Male	Unemployed	Hybrid	8	Low

suresh	42	Female	Student	Remote	14	Low
Arjun	29	Female	Unemployed	Hybrid	6	Low
Binod	42	Female	Employed	In-person	9	Low
harsh	16	Female	Student	Remote	10	Low
yug	36	Female	Employed	Remote	10	Low
astitva	30	Female	Self-employed	Remote	7	Low
sparsh	27	Female	Employed	In-person	4	Good
aniket	30	Female	Self-employed	Hybrid	12	Low
kartik	16	Female	Employed	Hybrid	8	Good
Aditya	28	Female	Employed	In-person	10	Low
Rahul	32	Female	Self-employed	In-person	6	Good
Karan	41	Female	Student	Remote	10	Low
Siddharth	25	Male	Employed	In-person	9	Good
Ankit	23	Female	Student	Remote	8	Good
Vikram	25	Male	Unemployed	Remote	7	Low
Arjun	37	Male	Unemployed	Remote	11	Low
Rohan	32	Female	Student	Remote	10	Low
Manish	25	Male	Employed	Hybrid	9	Low
Abhishek	34	Male	Unemployed	In-person	6	Low
Nikhil	30	Female	Student	Remote	10	Low
Pranav	37	Female	Employed	Remote	10	Low
Sameer	24	Male	Unemployed	Hybrid	8	Low
Sanjay	27	Male	Student	In-person	8	Good
Rohit	26	Female	Employed	Hybrid	8	Low
Ajay	18	Female	Employed	Hybrid	11	Low
Deepak	32	Female	Unemployed	Remote	8	Low
Rajesh	32	Female	Unemployed	Remote	10	Low
Amit	30	Male	Unemployed	In-person	4	Good
Anil	28	Female	Employed	In-person	8	Good
Suresh	18	Female	Self-employed	Remote	10	Low
Vijay	26	Male	Self-employed	In-person	9	Low
Mohit	27	Female	Employed	Hybrid	8	Low
Harish	23	Female	Self-employed	In-person	5	Good
Gaurav	28	Male	Student	Remote	13	Low
Ashish	33	Male	Employed	Hybrid	5	Good
Tarun	45	Female	Student	Remote	12	Low
Naveen	31	Male	Student	Hybrid	11	Low
Vinay	32	Female	Student	Remote	14	Low
Ravindra	29	Female	Employed	Remote	13	Low
Aakriti	16	Male	Unemployed	Hybrid	7	Low
Aarav	29	Female	Employed	In-person	12	Low
Aashish	30	Female	Student	Remote	12	Low
Abhinav	49	Female	Employed	Hybrid	11	Low
Aditya	28	Female	Employed	In-person	12	Low
Ajay	32	Female	Employed	Remote	8	Low
Akash	29	Female	Employed	Hybrid	12	Low
Akshay	20	Female	Employed	Hybrid	9	Low
Ankit	39	Female	Self-employed	In-person	1	Good
Ankur	36	Male	Employed	Remote	11	Low

3.2. Pemodelan Decision Tree

Setelah data dikumpulkan dan dipersiapkan, langkah berikutnya dalam penelitian ini adalah membangun model *Decision Tree* untuk mengklasifikasikan tingkat dampak kesehatan berdasarkan intensitas penggunaan gadget. Tahap awal dalam pemodelan adalah menentukan atribut yang paling berpengaruh dalam proses klasifikasi. Proses ini dilakukan dengan menghitung nilai *entropy* pada simpul awal (*root node*) dan menghitung *Information Gain* untuk masing-masing atribut.

Nilai *entropy* digunakan untuk mengukur tingkat ketidakpastian atau keragaman kelas dalam dataset. Semakin tinggi nilai *entropy*, semakin tidak homogen data dalam satu *node*, sehingga perlu dilakukan pemisahan menggunakan atribut yang relevan. Selanjutnya, *Information Gain* dihitung untuk setiap atribut sebagai indikator seberapa besar atribut tersebut mampu mengurangi ketidakpastian data setelah dilakukan pemisahan. Atribut dengan nilai *Information Gain* tertinggi akan dipilih sebagai simpul pemisah (*splitting node*) karena memberikan pengurangan ketidakpastian terbesar [16].

Proses pemilihan atribut dilakukan secara berulang pada setiap subset data yang dihasilkan hingga memenuhi kriteria berhenti, misalnya seluruh data pada *node* berada dalam kelas yang sama atau tidak ada atribut lain yang dapat digunakan untuk pemisahan. Dengan cara ini, pohon keputusan terbentuk secara sistematis, di mana setiap simpul internal merepresentasikan atribut keputusan, cabang menunjukkan nilai atribut, dan simpul daun (*leaf node*) menunjukkan kelas hasil akhir, yaitu tingkat dampak kesehatan *Low* atau *Good* [17].

Setelah perhitungan *entropy* dan *Information Gain* dilakukan, hasilnya disajikan dalam bentuk tabel *node* untuk mempermudah interpretasi dan pemilihan atribut pada setiap tahap pemodelan. Tabel ini menunjukkan distribusi data pada setiap kategori atribut, nilai *entropy* masing-masing, serta nilai *Information Gain* yang diperoleh. Dengan adanya tabel ini, dapat dianalisis atribut mana yang memberikan kontribusi terbesar terhadap klasifikasi dan bagaimana proses pemisahan data berlangsung pada setiap *node*.

Tabel 2. Nilai Entropy dan Information Gain pada Node Akar

node awal					
	jumlah	low	good	entropi	gain
total	120	93	27	0.7692	
			age		
≤ 30	72	49	23	0.903776	0.061
>30	48	44	4	0.413817	
			gender		
female	73	55	18	0.805805	0.003
male	47	38	9	0.704577	
			occupation		
employed	62	48	14	0.770629	0.081
student	31	24	7	0.770629	
self-employed	11	6	5	0.99403	
Unemployed	16	15	0	0	
			work_mode		
remote	48	47	1	0.146094	0.261
in-person	34	13	21	0.959687	
hybrid	38	33	5	0.561753	
			screen_time_hours		
≤ 5 jam	6	1	5	0.650022	0.140
6 – 8 jam	45	29	16	0.938932	
> 8 jam	69	63	6	0.426229	

Tabel 3. Nilai Entropy dan Information Gain pada Node 2

node 1					
	jumlah	low	good	entropi	gain
total	72	46	26	0.9436	
			age		
≤ 30	47	25	22	0.997059	0.07
>30	25	21	4	0.63431	
			gender		
female	42	25	17	0.973668	0.01
male	30	21	9	0.881291	
			occupation		
employed	45	31	14	0.894452	0.15
student	9	3	6	0.918296	
self-employed	9	4	5	0.991076	
Unemployed	9	8	0	0	
			work_mode		
in-person	34	13	21	0.959687	0.19
hybrid	38	33	5	0.561753	
			screen_time_hours		
≤ 5 jam	6	1	5	0.650022	0.16

node 5					
	jumlah	low	good	entropi	gain
in-person	14	8	6	0.985228	
		age			
≤ 30	10	4	6	0.970951	0.292
>30	4	4	0	0	
		gender			
female	10	6	4	0.970951	0.006
male	4	2	2	1	
		occupation			
employed	10	7	3	0.881291	0.159
student	3	1	2	0.918296	
self-employed	1	0	1	0	
		screen_time_hours			
> 8 jam	14	8	6	0.985228	

Tabel 8. Nilai Entropy dan Information Gain pada Node 6.

node 6					
	jumlah	low	good	entropi	gain
in-person	10	4	6	0.970951	
		age			
≤ 30	10	4	6	0.970951	
		gender			
female	7	3	4	0.985228	0.006
male	3	1	2	0.918296	
		occupation			
employed	7	4	3	0.985228	0.281
student	2	0	2	0	
self-employed	1	0	1	0	
		screen_time_hours			
> 8 jam	10	4	6	0.970951	

Tabel 9. Nilai Entropy dan Information Gain pada Node 7.

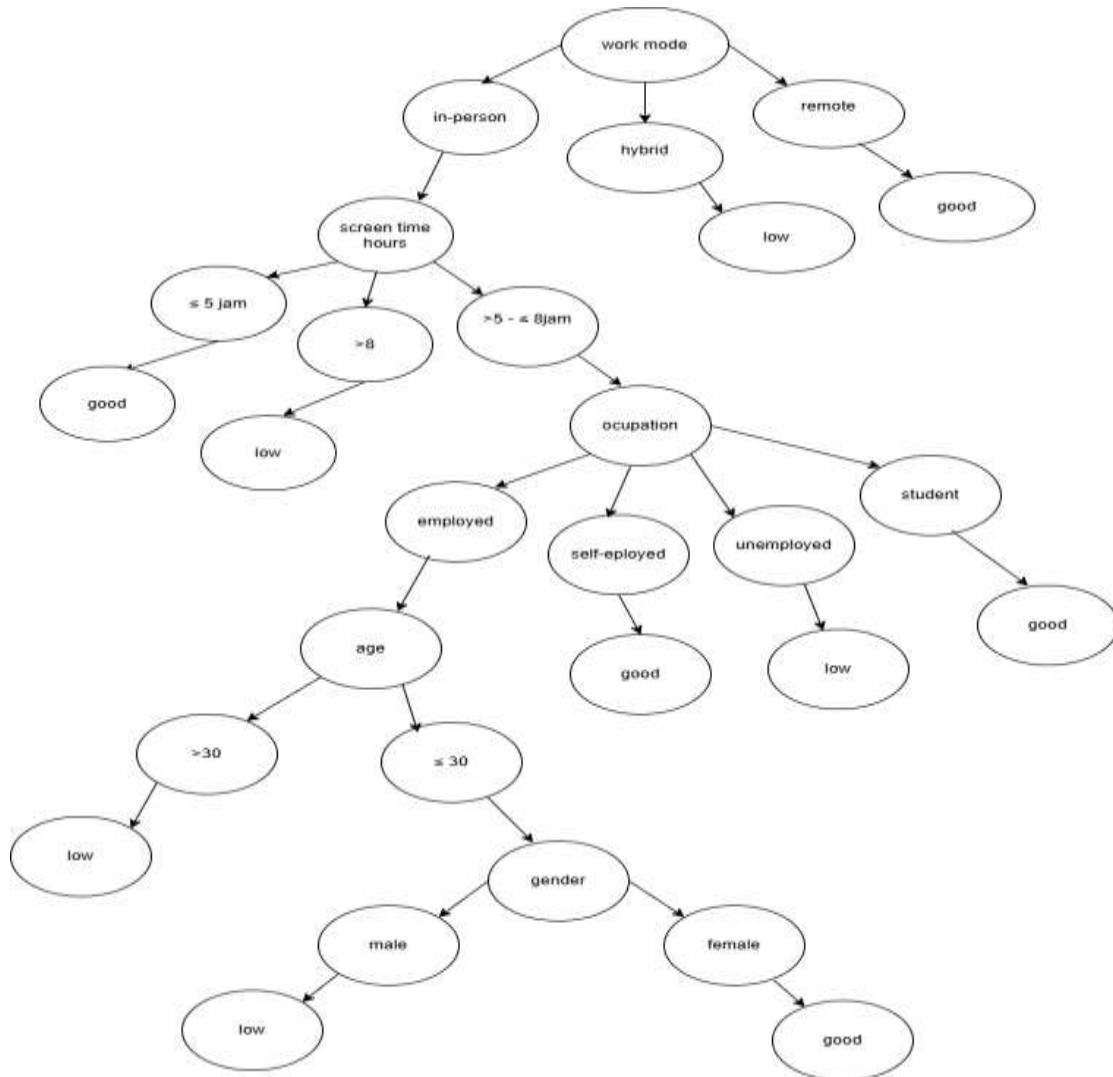
node 7					
	jumlah	low	good	entropi	gain
in-person	7	4	3	0.985228	
		age			
≤ 30	7	4	3	0.985228	
		gender			
female	6	3	3	1	0.128
male	1	1	0	0	
		occupation			
employed	7	4	3	0.985228	
		screen_time_hours			
> 8 jam	7	4	3	0.985228	

Tabel 10. Nilai Entropy dan Information Gain pada Node 8.

node 8					
	jumlah	low	good	entropi	gain
in-person	6	3	3	1	
		age			
≤ 30	6	3	3	1	
		gender			
female	6	3	3	1	
occupation					
employed	6	3	3	1	
		screen_time_hours			
> 8 jam	6	3	3	1	

Berdasarkan hasil perhitungan nilai *Entropy* dan *Information Gain* pada setiap *node*, dapat disimpulkan bahwa atribut *Work Mode* merupakan faktor paling berpengaruh dan dipilih sebagai simpul akar (*root node*) dalam pembentukan model *Decision Tree*. Selanjutnya, atribut *Screen Time Hours*, *Occupation*, *Age*, dan *Gender* digunakan sebagai atribut pemisah pada *node-node* berikutnya hingga terbentuk simpul akhir (*leaf node*) yang menghasilkan klasifikasi tingkat dampak kesehatan, yaitu *Low* dan *Good*.

Proses pembentukan pohon keputusan dilakukan secara bertahap dengan memilih atribut yang memiliki nilai *Information Gain* tertinggi pada setiap *node*, sehingga mampu mengurangi tingkat ketidakpastian data secara optimal. Untuk memperjelas proses klasifikasi serta hubungan antaratribut dalam menentukan dampak kesehatan akibat penggunaan gadget, struktur lengkap model *Decision Tree* disajikan dalam bentuk diagram pohon keputusan. Diagram ini menunjukkan alur pengambilan keputusan mulai dari simpul akar hingga simpul akhir, sehingga memudahkan pembaca dalam memahami pola klasifikasi yang dihasilkan oleh model.



Gambar 1. Struktur *Decision Tree* untuk Klasifikasi Dampak Kesehatan

4. Kesimpulan

Berdasarkan hasil pemodelan menggunakan algoritma *Decision Tree* (ID3), dapat disimpulkan bahwa mode kerja (*work mode*) merupakan atribut paling berpengaruh dalam menentukan klasifikasi dampak kesehatan akibat penggunaan gadget dan ditetapkan sebagai simpul akar pada diagram pohon keputusan. Hal ini menunjukkan bahwa perbedaan pola kerja, seperti *in-person*, *remote*, dan *hybrid*, memiliki peran penting dalam membedakan tingkat dampak kesehatan pengguna gadget. Pada cabang *remote* dan *hybrid*, proses klasifikasi berhenti lebih awal karena data pada masing-masing *node* telah memenuhi kondisi penghentian, sehingga keputusan akhir ditentukan

berdasarkan kelas dominan. Sementara itu, pada cabang *in-person*, data masih bersifat heterogen sehingga diperlukan pemisahan lanjutan menggunakan atribut *screen time hours*. Selanjutnya, proses klasifikasi berlanjut dengan mempertimbangkan atribut *occupation*, *age*, dan *gender* hingga mencapai simpul akhir yang menghasilkan klasifikasi *Low* atau *Good*. Diagram pohon keputusan menunjukkan bahwa durasi penggunaan layar menjadi faktor penting setelah mode kerja, terutama pada pengguna dengan sistem kerja tatap muka. Selain itu, karakteristik individu seperti jenis pekerjaan, usia, dan jenis kelamin turut memengaruhi hasil klasifikasi pada node-node lanjutan. Dengan demikian, kombinasi antara mode kerja, durasi penggunaan gadget, dan karakteristik individu berkontribusi terhadap tingkat dampak kesehatan yang dialami pengguna. Secara keseluruhan, model *Decision Tree* yang dihasilkan mampu menyajikan aturan klasifikasi yang jelas dan mudah dipahami melalui diagram pohon keputusan. Hal ini membuktikan bahwa algoritma *Decision Tree* (ID3) efektif digunakan untuk menganalisis dan memprediksi dampak kesehatan akibat intensitas penggunaan gadget berdasarkan data yang tersedia.

Referensi

1. B. Sukma, "Hubungan screen time, aktivitas fisik, pola konsumsi minuman berpemanis, dan asupan energi dengan status gizi lebih pada anak sekolah dasar," *Jurnal Kesehatan Tambusai*, 2025. DOI: <https://doi.org/10.31004/jkt.v5i3.30733>
2. A. D. Puspitasari, M. Ridwan, & T. Hidayat, "Hubungan aktivitas fisik dan waktu layar terhadap kesehatan mental," *Jurnal Pendidikan Indonesia*, vol. 6, no. 8, 2025. DOI: <https://doi.org/10.59141/japendi.v6i8.8545>
3. N. A. T. Hatmojo et al., "Hubungan lama screen time pada gadget dengan tingkat depresi pada pasien usia remaja," *Jurnal Kesehatan Tambusai*, 2025. DOI: <https://doi.org/10.31004/jkt.v6i4.49857>
4. The Impact of Digital Screen Time on Dietary Habits and Physical Activity in Children and Adolescents," *MDPI Nutrients*, 2023. [Online]. Available: <https://www.mdpi.com/2072-6643/14/14/2985>
5. S. Ziliwu & A. Pratiwi, "Hubungan durasi penggunaan gadget terhadap gangguan mental emosional anak usia sekolah," *Jurnal Kesehatan*, 2025. [Online]. Available: jurnal.uym.ac.id
6. R. Kurniawan & D. Santosa, "Pendekatan kuantitatif dalam analisis data kesehatan," *Jurnal Metodologi Penelitian*, vol. 5, no. 2, pp. 45–58, 2021.
7. J. Han, M. Kamber, & J. Pei, *Data Mining: Concepts and Techniques*, 3rd ed., Morgan Kaufmann, 2011, ISBN: 978-0123814807.
8. Decision tree learning," Wikipedia, 2025. [Online]. Available: https://en.wikipedia.org/wiki/Decision_tree_learning
9. Information gain (decision tree), Wikipedia, 2025. [online]. Available: https://en.wikipedia.org/wiki/Information_gain_%28decision_tree
10. Kaggle, "Open datasets for machine learning research," 2025. [Online]. Available: <https://www.kaggle.com/datasets>
11. A. Sutrisno & L. Fitriani, "Pemanfaatan dataset Kaggle dalam penelitian klasifikasi kesehatan berbasis *Decision Tree*," *Jurnal INSAN*, vol. 8, no. 1, pp. 12–24, 2023.
12. J. Han, M. Kamber, & J. Pei, *Data Mining: Concepts and Techniques*, 3rd ed., Morgan Kaufmann, 2011, ISBN: 978-0123814807.
13. I. D. Mienye & N. R. Jere, "A Survey of Decision Trees: Concepts, Algorithms, and Applications," *IEEE Access*, vol. PP, pp. 1–1, 2024, doi:10.1109/ACCESS.2024.3416838.
14. Information gain (decision tree), Wikipedia, 2025. [online]. Available: https://en.wikipedia.org/wiki/Information_gain_%28decision_tree
15. Han, M. Kamber, & J. Pei, *Data Mining: Concepts and Techniques*, 3rd ed., Morgan Kaufmann, 2011, ISBN: 978-0123814807.
16. T. M. Mitchell, *Machine Learning*, McGraw-Hill, 1997, ISBN: 978-0070428072.
17. Decision tree learning," Wikipedia, 2025. [Online]. Available: https://en.wikipedia.org/wiki/Decision_tree_learning