

## **Prediksi *Rating Game* Menggunakan Algoritme C4.5 Berdasarkan *Entertainment Software Rating Board***

**Rahmat Alfanza<sup>1\*</sup>, Sani Shalihamidiq<sup>2</sup>, Ratna Mufidah<sup>3</sup>, Betha Nurina Sari<sup>4</sup>**  
Teknik Informatika, Universitas Singaperbangsa Karawang, Karawang, Indonesia  
\*Corresponding Author: rahmat.alfanza18095@student.unsika.ac.id

### **Abstract**

*Games can be played by all ages including children. If the game being played is not in accordance with the child's developmental period, it will have a negative impact on the child. Therefore, the rating on the game is very influential because if there is an error in rating the game, minors can play games that are not in accordance with their developmental needs. The purpose of this research is to create a machine learning model to predict game ratings using data from the ESRB (Entertainment Software Rating Board). This study uses the C4.5 classification algorithm and the python programming language. The data used in this study is game rating data taken from 2020 to 2022. The results of this study indicate that the machine learning model created can predict game ratings with a ratio of 70% training data and 30% testing data, with an accuracy rate of 86%.*

**Keywords:** *Game; Data Mining; Classification; Algorithm C4.5*

### **Abstrak**

*Game dapat dimainkan oleh semua kalangan usia termasuk usia anak-anak. Jika game yang dimainkan tidak sesuai dengan masa kembang anak maka akan berdampak negatif kepada anak. Oleh sebab itu rating pada game sangat berpengaruh karena apabila terjadi kesalahan terhadap pemberian rating pada game anak dibawah umur dapat memainkan game yang tidak sesuai dengan kebutuhan tumbuh kembangnya. Tujuan penelitian ini adalah membuat model machine learning untuk memprediksi rating pada game dengan menggunakan data dari ESRB (Entertainment Software Rating Board). Penelitian ini menggunakan algoritme klasifikasi C4.5 dan bahasa pemrograman python. Data yang digunakan pada penelitian ini adalah data rating game yang diambil dari tahun 2020 sampai 2022. Hasil dari penelitian ini menunjukkan model machine learning yang dibuat dapat memprediksi rating game dengan perbandingan 70% data training dan 30% data testing, dengan tingkat akurasi sebesar 86%.*

**Kata kunci:** *Game; Data Mining; Klasifikasi; Algoritme C4.5*

### **1. Pendahuluan**

*Game* merupakan sebuah media hiburan yang digemari oleh semua kalangan umur dimulai dari anak-anak, remaja, sampai dewasa. *Game* dimainkan untuk memuaskan motif seperti kompetisi, tantangan, sosial, interaksi, pemenuhan fantasi, dan penambah gairah [1]. Dahulu *game* dimainkan dengan cara tradisional seperti catur, permainan kartu, dan lainnya. Dengan kemajuan teknologi, permainan tersebut dikembangkan secara modern yang sekarang dapat dimainkan di komputer, konsol, bahkan *smartphone*. *Game* juga dapat dijadikan sarana pembelajaran seperti sejarah [2], edukasi lingkungan [3], kritik politik [4], dan isu sosial [5].

Terdapat 2,69 miliar *gamer* di seluruh dunia pada tahun 2020. Angka tersebut akan meningkat menjadi 3,07 miliar pada tahun 2023 [6]. berdasarkan perkiraan pertumbuhan tahun ke tahun 5,6%. Yang paling menarik bahwa *platform* yang paling banyak digunakan adalah *mobile game* seperti *smartphone* dan Nintendo. Dimulai pada awalnya sebagai bagian yang sangat kecil dari pendapatan pasar game global. Pada tahun 2016, *game mobile* menjadi platform terkemuka, dan pada tahun 2021 *mobile game* mengambil 59% dari pasar [7]. *Game smartphone* dan tablet akan menghasilkan pendapatan \$106,4 miliar. Konsol dan PC akan berbagi 41% dari pasar dan total pendapatan di semua *platform* diperkirakan menjadi \$ 180,1

miliar. Indonesia menjadi negara dengan jumlah *gamer* terbanyak ketiga di dunia. Laporan tersebut mencatat ada 94,5% pengguna internet berusia 16 hingga 64 tahun di Indonesia yang memainkan *video game* [8].

Dalam dunia *game*, *rating* sangatlah penting karena dapat memberitahu kepada konsumen apakah *game* ini cocok terhadap kita sebagai konsumen atau tidak. *Rating* sendiri memiliki beberapa aspek sebagai penilaiannya antara lain, kekerasan, tindakan dewasa dan lain sebagainya. Pemberi *rating* pada *game* dilakukan oleh beberapa instansi, salah satunya adalah *ESRB* (*Entertainment Software Rating Board*). Akan tetapi dari *rating game* sendiri terkadang masih memiliki beberapa kendala, misalnya salah satunya adalah kurang tepat memberikan label *rating* umur terhadap suatu *game*, yang mana seharusnya instansi memberikan *rating* 18+ untuk beberapa *game* akan tetapi *rating* yang diberikan adalah 13+ oleh instansi terkait.

Dari permasalahan yang telah diuraikan, dilakukan penelitian dengan membuat sebuah model *machine learning* untuk memprediksi *rating game* berdasarkan *ESRB* menggunakan teknik *data mining* klasifikasi. Metode klasifikasi yang paling banyak diterapkan adalah C4.5 karena langkahnya sederhana dan cepat sehingga keputusan dapat diambil dengan mudah. Metode ini dapat menghasilkan pohon keputusan yang sering disebut *decision tree*. Terdapat penelitian mengenai penentuan bantuan Covid-19 dengan menggunakan algoritme C4.5 [9]. Sambani dan Nuraeni pada tahun 2017 telah melakukan penelitian mengenai klasifikasi pola penjurusan siswa di Sekolah Menengah Kejuruan (SMK) di kota Tasikmalaya dengan menggunakan algoritme C4.5 [10]. Algoritme C4.5 memiliki langkah yang sederhana dan cepat sehingga keputusan dapat diambil dengan mudah. Metode C4.5 ini menghasilkan *decision tree* atau pohon keputusan [11], yang mana *decision tree* bertujuan untuk membentuk model dan kemudian memprediksi nilai dari variable target dengan memberikan beberapa input [12].

Pada penelitian ini akan dilakukan prediksi *rating game* menggunakan algoritme C4.5 dengan merujuk pada penelitian-penelitian terdahulu, dengan tujuan meningkatkan akurasi proses prediksi *rating game*.

## 2. Tinjauan Pustaka

Salah satu penelitian yang dilakukan oleh Jiow dkk menjelaskan bahwa orang tua merujuk pada hasil dari *video game rating* sebagai patokan untuk anak agar bisa bermain *game* dibanding dengan konten yang ada di dalam *game* tersebut. Maka dari itu mereka membuat *online* sistem bernama VGRP (*Video Games Repository for Parents*) yang berisi informasi lengkap tentang *game* yang diberi *rating* seperti durasi permainan, konten dalam *game*, dan juga efek *game* terhadap pemain. Tujuan dari penelitian tersebut adalah untuk menyoroti kekurangan lembaga pemberi *rating game* seperti *ESRB* terhadap kekhawatiran orang tua dalam perkembangan *game* [13].

Awalnya *rating* yang diberikan oleh *ESRB* mempunyai empat kategori: K-A (Anak-Dewasa), *Teen* atau Remaja (Usia 13+), *Mature* atau Dewasa (Usia 17+), dan *Adult Only* yaitu Khusus Dewasa (Usia 18+). Modifikasi peringkat segera dilakukan untuk membagi kategori K-A menjadi *Early Childhood* atau Anak Usia Dini (usia 3 tahun ke atas) dan *Everyone* (Semua Orang, cocok untuk usia 6+). Kategori *Everyone* dimodifikasi lebih lanjut pada tahun 2005 dengan penambahan peringkat E10+ (Semua orang berusia 10 tahun ke atas) [14]. *Content Descriptor* ditambahkan untuk memberikan gambaran umum kepada konsumen tentang tingkat kekerasan (*Violence*), bahasa yang tidak pantas (*Strong Language*), penggunaan narkoba yang terkandung dalam *game*, dan masih banyak yang lainnya.

Selanjutnya penelitian yang dilakukan oleh Thompson, Tepichin, dan Haninger tentang konten dalam *game* yang sudah diberi *rating teen* atau remaja oleh *ESRB* menyimpulkan bahwa dari 396 *game* dengan *rating teen* terdapat 373 (94%) *game* yang mempunyai konten *violence* atau kekerasan yang menandakan bahwa kekerasan dalam *game* masih dikategorikan wajar untuk *rating teen* yang mungkin bisa mengejutkan orang tua [15].

Penelitian yang dilakukan oleh Felini mengkritik lembaga pemberi *rating game* karena mereka tidak konsisten dalam memberi *rating*. Terdapat banyak kontradiksi dan kebingungan dalam memberi *rating* karena pandangan yang berbeda diantara beberapa lembaga tersebut dan juga dalam penentuan *rating* berdasarkan konten yang terdapat dalam *game* sehingga membuat orang tua semakin sulit memilih *game* yang cocok untuk anak dengan batasan usianya [16].

Lalu penelitian yang dilakukan oleh Alomari dkk dengan menggunakan metode GLM (*Generalized Linear Models*) dengan akurasi sebesar 92% untuk menentukan kategori yang paling berpengaruh dalam pemberian sebuah *rating game*. Hasil dari penelitian ini yaitu kategori yang paling berpengaruh untuk pemberian *rating game* adalah kekerasan, kata-kata kasar, darah, dan juga kekejaman [17].

*State of art* pada penelitian ini adalah penggunaan algoritme C4.5 dalam memprediksi *rating game* yang pada penelitian sebelumnya berfokus pada kategori yang paling berpengaruh dalam pemberian sebuah *rating* pada *game*. Perbedaan lainnya pada penelitian ini yaitu hasil akhir disajikan dalam bentuk *confusion matrix* agar bisa terlihat berapa banyak *game* yang benar diprediksi sesuai dengan kategori usianya.

**3. Metodologi**

**3.1 Objek Penelitian**

Objek atau fokus penelitian ini yaitu identifikasi *content descriptors* yang paling banyak muncul dalam data *rating game*, kategori umur yang paling banyak terdapat dalam data *rating game*, dan hasil prediksi *rating game* dengan menerapkan algoritme C4.5.

**3.2 Metodologi Penelitian**

Metodologi penelitian yang digunakan dalam artikel ilmiah ini adalah *CRISP-DM* yang mendukung menyelesaikan masalah untuk *data mining* [18]. Langkah metodologi *CRISP-DM* yang digunakan sebagai berikut:

1) *Business Understanding*

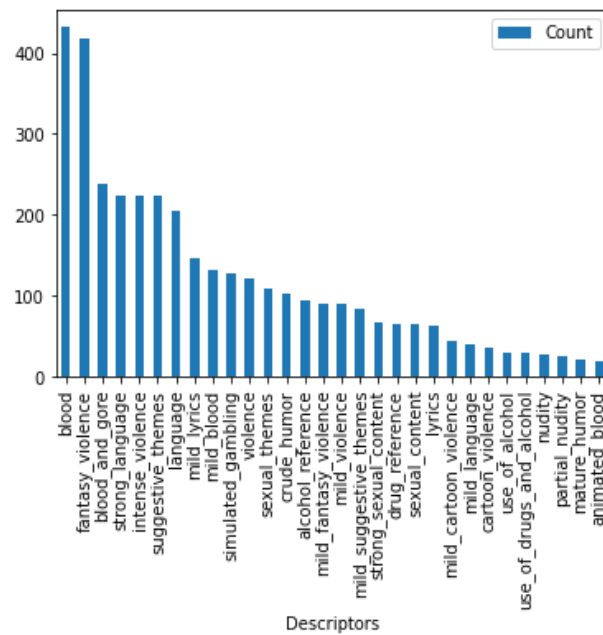
Tujuan data mining dalam penelitian ini adalah mengentahui model terbaik untuk memprediksi *rating* pada *game*. Selain dari itu, tujuan dari penelitian ini adalah untuk menggali atau mendapatkan penegtahuan yang baru dari data yang sudah diolah, sehingga dapat dijadikan dasar atau acuan bagi *developer game* untuk memberikan atau memilih konten didalam game mereka.

2) *Data Understanding*

Dataset diambil dari data *game* yang telah di *rating* oleh lembaga *ESRB* yang telah dikumpulkan dari rentang tahun 2020 hingga 2022 pada *website kaggle* dan juga *scraping data*. *Dataset* memiliki 2181 data dan 34 atribut hingga mulai judul hingga target kelas yaitu *rating* yang diberikan untuk *game* tersebut. Atribut yang tidak digunakan adalah *title* (judul), *console* (konsol), dan *esrb rating* (*rating* dari lembaga *ESRB*).

Tabel 1. Bentuk Data *Rating Game*


No	title	console	alcohol_ reference	blood	...	use_of_ alcohol	violence	esrb_rating
1	Monster Jam Steel	1	0	0	...	0	0	E
2	Stray	1	0	0	...	0	0	ET
3	Asdivine Kamura	0	0	0	...	1	0	ET
4	Call of Duty®: Modern Warfare 2 Campaign Remastered	1	1	1	...	0	0	M
5	The Last of Us Part II	1	0	1	...	0	1	M
...	...	...	...	...	...	...	...	...
2180	MADiSON	1	0	0	...	0	1	M
2181	Still Time	1	0	1	...	0	0	T



Gambar 1. Komponen Paling Banyak Muncul

Komponen atau variabel yang paling banyak jumlahnya 3 teratas pada *dataset* yaitu deskripsi *blood* atau darah, *fantasy violence* yaitu tindakan kekerasan bersifat fantasi dan juga *no descriptors* yaitu *game* yang tidak memiliki deskripsi konten. Namun konten yang bersifat dewasa justru jumlahnya sedikit seperti *use of alcohol* yaitu penggunaan minuman beralkohol, *nudity* yaitu ketelanjangan dan juga *mature humor* yaitu humor dewasa. Diharapkan model dapat memprediksinya dengan benar.

Pada Gambar 1 terlihat bahwa atribut yang paling banyak muncul atau berpengaruh adalah *blood* yaitu darah dan *fantasy violence* yaitu kekerasan yang dibuat-buat atau kekerasan yang tidak mungkin terjadi di dunia nyata. Kedua atribut tersebut memiliki nilai lebih dari 400 yang artinya banyak *game* yang memiliki unsur darah dan kekerasan yang dibuat-buat.



Gambar 2. Plotting Label Rating Game

Selanjutnya adalah mencari distribusi data dari *rating game* dengan melihat kategori umur mana yang paling banyak muncul pada *dataset* untuk menambah informasi dengan menggunakan visualisasi data. Pada Gambar 2 terlihat bahwa label T yang berarti kategori T = Remaja adalah nilai yang paling banyak muncul dalam data dan ET = Awal Remaja.

3) *Data Preparation*

Data *rating game* yang didapatkan memiliki 34 atribut dengan total jumlah data sebanyak sebelum data diolah dan dimasukkan ke dalam metode algoritme yang telah ditentukan, pengecekan data diperlukan untuk mengetahui apakah ada atribut pada data yang salah pengejaan, data yang *null*, atau data dengan nama sama. Maka dari itu sebelum data dimasukkan ke model maka data akan diperbaiki terlebih dahulu.

Tabel 2. Atribut dalam *Dataset*

Title	Console	Alcohol_Reference	Blood
mild_lyrics	strong_language	mild_suggestive_themes	strong_sexual_content
animated_blood	intense_violence	mild_violence	suggestive_themes
fantasy_violence	language	nudity	no_descriptors
blood_and_gore	lyrics	partial_nudity	use_of_drugs_and_alcohol
cartoon_violence	mature_humor	sexual_content	mild_language
crude_humor	mild_blood	sexual_themes	simulated_gambling
drug_reference	mild_cartoon_violence	mild_fantasy_violence	use_of_alcohol
violence	esrb_ratings		

Hal yang dilakukan pada tahap ini adalah pengecekan *null values terhadap dataset*, pengecekan dilakukan dengan *syntax* berikut:

```
[ ] df.isnull().sum()
```

Gambar 3. Pengecekan *null values*

Setelah melakukan pengecekan, tidak ada *null values* pada data yang digunakan. Dataset yang sudah diketahui tidak memiliki *null values* kemudian dilakukan pengecekan terhadap keunikan data, apakah ada data yang memiliki judul sama dengan *syntax* berikut:

```
[14] df["title"].is_unique
True
```

Gambar 4. Cek keunikan data

Tidak ditemukan data dengan judul sama Setelah melakukan pengecekan terhadap keunikan data, artinya tidak ada redundansi data. Data yang sudah dilakukan pengecekan *null values* dan keunikan data selanjutnya bisa dimasukkan kedalam pemodelan dengan menggunakan algoritme C4.5.

4) *Modelling*

Model yang diusulkan untuk Memprediksi *Rating Game* Berdasarkan *Entertainment Software Rating Board* adalah algoritme *Decision Tree* C4.5. Tahapan *Algoritme Decision Tree* C4.5 [19] diantaranya:

- 1) Menyiapkan data training
- 2) Menentukan akar dari pohon.
- 3) Hitung nilai Gain:

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

Keterangan:

S= Himpunan kasus

n = jumlah partisi S

P<sub>i</sub> = proporsi S<sub>i</sub> terhadap S

4) Ulangi langkah ke-2 hingga semua tupel terpartisi

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

Keterangan:

S = Himpunan Kasus

A = Fitur

n = jumlah partisi atribut A

|S<sub>i</sub>| = Proporsi S<sub>i</sub> terhadap S

|S| = jumlah kasus dalam S

5) Proses partisi pohon keputusan akan berhenti saat:

- Semua record dalam simpul N mendapat kelas yang sama.
- Tidak ada atribut di dalam record yang dipartisi lagi.
- Tidak ada record di dalam cabang yang kosong.

Model yang telah ditentukan pada penelitian ini akan diterapkan pada data *rating game* dengan menggunakan bahasa pemrograman *python*. Atribut dari data tersebut berjumlah 34 dan akan ditentukan dahulu mana atribut yang ingin digunakan. Tes pengujian yang digunakan pada penelitian ini adalah *test percentage split* yaitu data dibagi menjadi 4 skenario dimulai dari pembagian 60% data latih dan 40% data uji sampai 90% data latih dan 10% data uji lalu skenario terbaik akan dipilih.

6) Evaluasi Model

Evaluasi dilakukan dengan menganalisa hasil klasifikasi. Pengukuran data dilakukan dengan *confusion matrix* untuk mengevaluasi hasil dari algoritme *Decision Tree C4.5*.

Tabel 3. *Confusion Matrix*

		Predicted	
		Positive	Negative
Actual	Positive	TP	FN
	Negative	FP	TN

Sebuah *confusion matrix* memvisualisasikan dan merangkum kinerja algoritme klasifikasi [20]. *Confusion matrix* terdiri dari empat karakteristik dasar (angka) yang digunakan untuk menentukan metrik pengukuran pengklasifikasi. "TP" adalah singkatan dari *True Positive* yang menunjukkan jumlah contoh positif (benar) yang diklasifikasikan secara akurat. Demikian pula, *Output* "TN" adalah singkatan dari *True Negative* yang menunjukkan jumlah contoh negatif yang diklasifikasikan secara akurat. Istilah "FP" menunjukkan nilai Positif Palsu, yaitu jumlah contoh negatif aktual yang diklasifikasikan sebagai positif; dan "FN" berarti nilai Negatif Palsu yang merupakan jumlah contoh positif aktual yang diklasifikasikan sebagai negatif. Salah satu metrik yang paling umum digunakan saat melakukan klasifikasi adalah akurasi [21].

$$Accuracy = \frac{TN+TP}{TN+FP+FN+TP} \dots\dots\dots (3)$$

Rumus diatas berfungsi untuk menghitung keakuratan model (melalui *confusion matrix*) dihitung menggunakan rumus yang diberikan. Karena data yang digunakan memiliki *multi-class* maka maka *confusion matrix* mengikuti kelas dari kelas target data yaitu 4 kelas.

## 4. Hasil dan Pembahasan

### 4.1 Pengujian model

Pengujian model dilakukan dengan menggunakan algoritme C4.5 yang disebut *decision tree* pada bahasa pemrograman *python*. Sebanyak 2181 data diuji dengan skenario pembagian data dimulai dari 60% data latih 40% data uji, lalu 70% data latih 30 % data uji, selanjutnya 80% data latih 20% data uji, yang terakhir adalah 90% data latih 10% data uji. Skenario yang dilakukan menunjukan pembagian *data testing* dan *training* dalam algoritme C4.5 memberikan pengaruh dalam hasil yang didapatkan. Berikut merupakan hasil algoritme C4.5 mengenai nilai akurasi, *precision*, *recall*, *f-measure*, serta *support* yang dapat dilihat pada Tabel 4.

Tabel 4. Hasil pengujian data 4 skenario

Skenario	Akurasi	Precision	Recall	F-measure	Support
60% training : 40% testing	85,57%	0,864	0,855	0,853	873
70% training : 30% testing	86,56%	0,862	0,864	0,861	655
80% training : 20% testing	83,07%	0,833	0,851	0,834	437
90% training : 10% testing	83,24%	0,845	0,832	0,831	219

hampir semua skenario pembagian data berjalan dengan cukup baik dengan akurasi hanya terpaut kurang lebih 3% diantara semua skenario. Skenario yang bisa dikatakan terbaik adalah pembagian 70% data training dan 30% data testing.

Tabel 5. Hasil skenario 70% data latih 30% data uji

	precision	recall	f1-score	support
E	0.91	0.96	0.93	161
ET	0.76	0.82	0.79	137
M	0.91	0.92	0.91	138
T	0.87	0.78	0.82	219
accuracy			0.86	655
macro avg	0.86	0.87	0.86	655
weighted avg	0.86	0.86	0.86	655

Pada Tabel 5 dapat dilihat bahwa hasil yang di peroleh dari pemodelan menggunakan Algoritme C 4.5 dengan menggunakan pembagian data 70:30 mendapatkan nilai presentase seperti berikut:

$$Akurasi = \frac{155+113+128+171}{655} 100\% = \frac{567}{655} 100\% = 86,5648\%$$

$$Laju\ eror = \frac{6+24+10+48}{655} 100\% = \frac{88}{655} 100\% = 13,4351\%$$

Bisa terlihat bahwa akurasi yang didapat pada model dengan pembagian data 70:30 adalah sekitar 86% dengan laju eror sebesar 13%. Dari 655 data yang diuji 567 data berhasil diklasifikasi dengan benar dan 88 data tidak diklasifikasi dengan benar.

#### 4.2 Evaluasi Model

Hasil evaluasi dapat terlihat pada tabel 5 dengan menggunakan *confusion matrix multi-class* karena mengikuti kelas target data yaitu 4 kelas.

Tabel 5. Hasil Evaluasi Model

		Predicted Table			
		E	ET	M	T
Actual Table	E	155	5	0	1
	ET	10	113	0	13
	M	0	1	128	9
	T	0	31	12	171

Pada Tabel 5 terlihat bahwa visualisasi dibagi menjadi 4 kategori yaitu E untuk *Everyone* yang artinya semua umur, lalu ada ET untuk *Early Teenager* yang artinya awal

remaja (10+), M yaitu *Mature* yang artinya dewasa (17+), dan yang terakhir T yaitu *Teen* yang artinya remaja (13+). Terlihat bahwa kategori umur yang paling banyak diprediksi benar adalah kategori T atau untuk remaja sebanyak 171 data dikarenakan distribusi jumlah kategori yang paling banyak adalah remaja. Diikuti oleh E atau untuk semua umur sebanyak 155 data. Lalu ada M yaitu untuk dewasa sebanyak 128 data dan yang terakhir adalah ET yaitu untuk awal remaja sebanyak 113 data.

Selanjutnya data yang diprediksi salah paling banyak berada pada kategori remaja dengan diprediksi untuk awal remaja sebanyak 13 data, dan diprediksi untuk dewasa sebanyak 9 data. Untuk kategori dewasa, data diprediksi salah sebanyak 12 data pada kategori remaja. Terlihat dari visualisasi kategori semua umur tidak ada data yang diprediksi dewasa dan juga pada kategori dewasa tidak ada data yang diprediksi untuk semua umur yang berarti bahwa model yang digunakan sudah sangat baik walaupun masih ada beberapa kesalahan terutama pada kategori remaja.

Prediksi rating game dengan menggunakan algoritme C4.5 berjalan dengan sangat baik untuk semua skenario sehingga mendapatkan akurasi diatas 80%. Dengan penelitian ini bisa didapatkan pengetahuan baru yang melanjutkan penelitian dari [17] bahwa lembaga pemberi *rating game* sendiri yaitu *ESRB* terkadang masih memberi *rating* yang tidak sesuai dengan batasan usia. Terlihat pada Tabel 5 tabel prediksi yang masih banyak terjadi kesalahan walaupun data latih sudah dibagi menjadi 4 skenario namun karena *ESRB* terkadang memberi *rating* tidak sesuai dengan batasan usia maka dari itu model juga salah memprediksi dikarenakan data *rating game* yang dilatih tidak konsisten.

Penelitian ini mendukung penelitian lainnya yang dilakukan oleh [15] bahwa masih banyak konten kekerasan pada game dengan rating remaja yang menandakan bahwa kekerasan dalam *game* masih dikategorikan wajar. Juga halnya mendukung penelitian yang dilakukan oleh [16] yang mengkritik lembaga pemberi *rating game* seperti *ESRB* dan *PEGI* dikatakan bahwa terdapat banyak kontradiksi dan kebingungan dalam memberi *rating* karena pandangan yang berbeda diantara beberapa lembaga tersebut.

## 5. Kesimpulan

Hasil dari prediksi *rating game* menggunakan algoritme C4.5 yaitu dengan memilih akurasi terbaik skenario model ke 2 dengan pembagian 70% *data training* dan 30% *data testing* sehingga hasil penelitian menjadi optimal dan sesuai dengan yang diharapkan. Hasil yang diharapkan pada penelitian sudah seperti yang diharapkan namun masih ada kesalahan terjadi pada kategori umur T (remaja) yang masih banyak diprediksi sebagai M (dewasa) dan juga sebaliknya kategori M (dewasa) diprediksi sebagai kategori umur T (remaja). Diharapkan untuk para *developer game* meninjau kembali konten yang akan dimasukkan kedalam *game* terutama *game* untuk kategori dewasa yang ternyata masih diberi *rating* remaja atau yang lainnya oleh lembaga pemberi *rating game* *ESRB* dan dapat diambil kesimpulan bahwa mereka masih tidak konsisten dalam memberikan *rating game* sesuai umur.

*Model machine learning* yang dikembangkan dalam paper ini dapat dimanfaatkan oleh *developer game* terutama lokal untuk menilai elemen atau konten apa yang harus dimasukkan dalam sebuah *game* untuk mendapatkan *rating* yang diinginkan untuk menjangkau target audiens serta dalam *testing* oleh *game publisher*. Pada penelitian selanjutnya diharapkan dapat menerapkan algoritme lain dalam klasifikasi seperti *random forest* untuk mendapatkan hasil seperti algoritme C4.5 namun dengan akurasi yang lebih tinggi. Selain itu, penelitian selanjutnya diharapkan bisa mendapatkan bentuk data yang lebih baik lagi sehingga bisa mendapatkan *rules* dari algoritme lainnya dan mempermudah dalam mengambil kesimpulan dalam penelitian yang dijalankan.

## Daftar Referensi

- [1] J. B. Funk, M. Chan, J. Brouwer, and K. Curtiss, "A biopsychosocial analysis of the video game-playing experience of children and adults in the United States," *SIMILE*, vol. 6, no. 3, p. 1, 2016, doi: 10.3138/sim.6.3.001.
- [2] G. Aroni, "The Architecture of Assassin's Creed II's Florence," *Well Play. A J. Video Games, Values, Mean. (Connected Learn. Summit Spec. Issue)*, vol. 8, no. 1, pp. 13–26, 2019, [Online]. Available: <http://press.etc.cmu.edu/>.
- [3] K. M. Shihab, S. Sussi, R. Munadi, R. R. Prasojoe, and N. Fitriyanti, "Pembuatan Game Online BoMCleaN sebagai Media Pembelajaran Kebersihan Lingkungan," *J. Edukasi dan*



- Penelit. Inform.*, vol. 5, no. 1, p. 113, 2019, doi: 10.26418/jp.v5i1.29874.
- [4] M. Wragg, *the playful citizen: civic engagement in a mediatized culture*: edited by R. Glas, S. Lammes, M. de Lange, J. Raessens, and I. de Vries, Amsterdam, Amsterdam University Press, 2020,
- [5] T. Wibowo and K. Limanda, "Penggunaan Naratif Dalam Video Game Sebagai Media Edukasi Isu Dunia : Studi Kasus Detroit Become Human Use of Narrative in Video Games as Educational Media World Issue : Case Study Detroit Become Human," *J. Ilm. Komput. Graf.*, vol. 13, no. 2, pp. 1–6, 2020.
- [6] S. M. K. Al and D. Panceng, "Pengaruh Intensitas Bermain Game terhadap Konsentrasi Belajar Siswa A . Pendahuluan Belajar adalah kegiatan yang berproses dan merupakan unsur yang sangat mendasar dalam penyelenggaraan setiap jenis dan jenjang pendidikan . 1 Sehingga tanpa belajar sesung," vol. 01, no. 02, pp. 112–119, 2020.
- [7] B. A. T. Atmoko, & J. Ellyawati, "Determinant of In-App Mobile Game Purchase Intention: An Empirical Study of Indonesian Mobile Gamer. In *ICEBE 2020: Proceedings of the First International Conference of Economics, Business & Entrepreneurship, ICEBE 2020, 1st October 2020, Tangerang, Indonesia* (p. 209). European Alliance for Innovation, 2021
- [8] V. A. Dihni, "Jumlah Gamers Indonesia Terbanyak Ketiga di Dunia," *Katadata*, 2022. [https://databoks.katadata.co.id/datapublish/2022/02/16/jumlah-gamers-indonesia-terbanyak-ketiga-di-dunia?utm\\_source=dable&utm\\_campaign=dable\\_Pilihan](https://databoks.katadata.co.id/datapublish/2022/02/16/jumlah-gamers-indonesia-terbanyak-ketiga-di-dunia?utm_source=dable&utm_campaign=dable_Pilihan) Editor Widget&utm\_source=dable.
- [9] S. Badriah, M. Fajar, E. Nugroho, N. Sanjaya, and I. Rismawati, "Klasifikasi Algoritme C4 . 5 dalam Menentukan Penerima Bantuan Covid-19 ( Studi Kasus : Desa di Karawang ) ,"  
*JIP (Jurnal Inform. Polinema*, vol. 7, no. 3, pp. 23–28, 2019.
- [10] E. B. Sambani and F. Nuraeni, "Penerapan Algoritme C4.5 Untuk Klasifikasi Pola Penjurusan di Sekolah Menengah Kejuruan (SMK) Kota Tasikmalaya," *CSRID (Computer Sci. Res. Its Dev. Journal)*, vol. 9, no. 3, p. 144, Mar. 2018, doi: 10.22303/CSRID.9.3.2017.144-152.
- [11] A. Arora, B. Gupta, P. Uttarakhand, and I. A. Rawat, "Analysis of Various Decision Tree Algorithms for Classification in Data Mining Cite this paper Related papers Analysis of Classification Techniques in Data Mining. ijesrt journal Data Mining Application in Enrollment Management : A Case Study Saurabh," *Int. J. Comput. Appl.*, vol. 163, no. 8, pp. 975–8887, 2017.
- [12] S. Umadevi and K. S. J. Marseline, "A survey on data mining classification algorithms," *Proc. IEEE Int. Conf. Signal Process. Commun. ICSPC 2017*, vol. 2018-Janua, no. July, pp. 264–268, 2018, doi: 10.1109/CSPC.2017.8305851.
- [13] H. J. Jiow, R. Athwa, L. L. Chew, M. H. Elias, N. Lim, and K. Woo, "Revisiting video game ratings: Shift from content-centric to parent-centric approach," *SHS Web Conf.*, vol. 33, p. 00065, 2017, doi: 10.1051/shsconf/20173300065.
- [14] D. A. Gentile, J. Humphrey, and D. A. Walsh, "Media ratings for movies, music, video games, and television: A review of the research and recommendations for improvements," *Adolesc. Med. Clin.*, vol. 16, no. 2 SPEC. ISS., pp. 427–446, 2015, doi: 10.1016/j.admecli.2005.02.006.
- [15] K. M. Thompson, K. Tepichin, and K. Haninger, "Content and ratings of mature-rated video games," *Arch. Pediatr. Adolesc. Med.*, vol. 160, no. 4, pp. 402–410, 2016, doi: 10.1001/archpedi.160.4.402.
- [16] D. Felini, "Beyond today's video game rating systems: A critical approach to PEGI and ESRB, and proposed improvements," *Games Cult.*, vol. 10, no. 1, pp. 106–122, 2015, doi: 10.1177/1555412014560192.
- [17] K. M. Alomari, A. Q. Alhamad, H. O. Mbaidin, and S. Salloum, "Prediction of the digital game rating systems based on the ESRB [Predicción de los sistemas de clasificación de juegos digitales basados en el sistema de calificación ESRB]," *Opcion*, vol. 35, no. Special Issue 19, pp. 1368–1393, 2019, [Online]. Available: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85068870131&partnerID=40&md5=646bdf7f8ad25726e514d0a48fb1818a>.
- [18] P. C. Ncr *et al.*, "Crisp-Dm," *SPSS inc*, vol. 78, pp. 1–78, 2000, [Online]. Available: <http://www.crisp-dm.org/CRISPWP-0800.pdf>.
- [19] R. S. Putra, "Klasifikasi Penyebaran Covid-19 Menggunakan Algoritme C4.5 Kota Pagar Alam," *Jukomika*, vol. 4, no. 1, pp. 23–35, 2021.

- [20] P. Singh, N. Singh, K. K. Singh, and A. Singh, "Diagnosing of disease using machine learning," *Mach. Learn. Internet Med. Things Healthc.*, pp. 89–111, 2021, Academic press, doi: 10.1016/B978-0-12-821229-5.00003-3.
- [21] A. Kulkarni, D. Chong, and F. A. Batarseh, "Foundations of data imbalance and solutions for a data democracy," *Data Democr. Nexus Artif. Intell. Softw. Dev. Knowl. Eng.*, pp. 83–106, Jan. 2020, doi: 10.1016/B978-0-12-818366-3.00005-8.