

Implementasi K-Modes Clustering Untuk Pengelompokan Data Bermain Game Pada Mahasiswa Ditinjau Dari Durasi Belajarnya

Yoga Kustanto, Endah Ratna Arumi*, Dimas Sasongko, Emilya Ully Artha, Nugroho Agung Prabowo

Fakultas Teknik, Program Studi Teknik Informatika, Universitas Muhammadiyah Magelang, Magelang, Indonesia

Email: ¹yogalpha@gmail.com, ^{2,*}arumi@unimma.ac.id, ³dimassasongko@unimma.ac.id, ⁴ully@ummgl.ac.id,

⁵naprabowo@ummgl.ac.id

Email Penulis Korespondensi: arumi@unimma.ac.id

Abstrak—Perkembangan internet telah menciptakan sarana hiburan baru yaitu *game online*. Permasalahan dalam motivasi belajar di kalangan mahasiswa dapat dikaitkan dengan kecanduan bermain *game online*. Hal ini dapat dilihat dari mahasiswa yang kerap bermain *game* baik saat proses perkuliahan ataupun saat selesai perkuliahan. Permasalahan dalam motivasi belajar tersebut terdapat mahasiswa yang mengalami penurunan prestasi dan mengalami masalah dengan kepribadiannya sehingga penelitian ini bertujuan untuk mengelompokkan mahasiswa yang bermain game menurut durasi bermain game dan durasi belajar. Penelitian ini menggunakan metode *K-Modes Clustering* untuk menganalisis hubungan antara kecanduan game dan motivasi belajar berdasarkan durasi yang dihabiskan saat bermain game dan belajar. Data diperoleh melalui survei kuesioner online terhadap mahasiswa Universitas Muhammadiyah Magelang mencakup informasi tentang waktu yang dihabiskan mahasiswa untuk bermain game dan belajar. Hasil analisis pada 90 data mahasiswa menggunakan algoritma *k-modes clustering* mendapatkan hasil *clustering* yang baik. Jumlah *cluster* yang dihasilkan sebanyak 2 *cluster* dengan *cluster* 1 berjumlah 63 anggota sedangkan *cluster* 2 berjumlah 27 anggota dengan nilai *Cost* 323. Hasil *clustering* pada data bermain game perlu dilakukan penentuan *cluster* yang optimal sehingga penelitian ini menggunakan metode *Elbow* yang memperoleh jumlah *cluster* optimal sebanyak 6 *cluster* dengan nilai *cost* 250. Selain itu, hasil *clustering* dianalisis dengan melihat jarak dari masing-masing *cluster* menggunakan *Silhouette Score* yang nilainya adalah 0.1531955 serta hubungan antar variabel menggunakan matriks mendapatkan hasil negatif.

Kata Kunci: Internet; Game online; Motivasi Belajar; Clustering; Mahasiswa

Abstract—The development of the internet has created a new means of entertainment, namely online games. Problems in learning motivation among students can be related to addiction to playing online games. This can be seen from students who often play games both during the lecture process and when they have finished studying. The problem with learning motivation is that there are students who experience a decline in achievement and experience problems with their personality, so this research aims to group students who play games according to the duration of playing games and the duration of studying. This research uses the K-Modes Clustering method to analyze the relationship between game addiction and learning motivation based on the duration spent playing games and studying. Data obtained through an online questionnaire survey of Muhammadiyah University of Magelang students includes information about the time students spend playing games and studying. The results of analysis on 90 student data using the k-modes clustering algorithm obtained good clustering results. The number of clusters produced was 2 clusters with cluster 1 totaling 63 members while cluster 2 had 27 members with a Cost value of 323. The results of clustering on game playing data required determining optimal clusters so this research used the Elbow method which obtained the optimal number of clusters of 6 clusters, with a cost value of 250. Apart from that, the clustering results were analyzed by looking at the distance from each cluster using the Silhouette Score whose value was 0.1531955 and the relationship between variables using a matrix obtained negative results.

Keywords: Internet; Online Games; Motivation to Learn; Clustering; College Student

1. PENDAHULUAN

Pengaruh dari perkembangan teknologi di era saat ini adalah berkembangnya jaringan komunikasi internet yang telah memberikan perubahan yang signifikan di berbagai aspek kehidupan. Kemajuan teknologi dalam jaringan internet menjadikan terciptanya sarana hiburan baru yaitu *game online*. Melalui bantuan internet, *game* dapat dimainkan tanpa harus bertatap muka dengan lawan mainnya. *Game online* kini menjadi salah satu kegiatan yang dilakukan untuk menghibur diri dari rasa jenuh[1]. *Game online* di Indonesia telah membuat banyak perubahan, terutama di kalangan mahasiswa. Permasalahan dalam motivasi belajar pada era digital saat ini dapat dikaitkan dengan tingkat kecanduan bermain *game online*. Banyak mahasiswa yang gemar bermain game mengalami penurunan prestasi dan mengalami masalah dengan kepribadiannya dimana mahasiswa yang sering bermain game memiliki permasalahan belajar, misalnya malas dalam belajar, kurang siap dalam mengikuti perkuliahan, dan kurang fokus saat mengikuti kelas[2]. Waktu yang semestinya digunakan untuk belajar, telah disita demi bisa duduk berlama-lama untuk bermain game[3]. Dalam laporan yang dikemukakan oleh We Are Social, Indonesia menjadi negara dengan jumlah pemain *video game* terbanyak ketiga di dunia dengan catatan sebanyak 94,5% memainkan *video game* per Januari 2022 dengan rentang usia antara 16-64 tahun[4][5].

Pada era digitalisasi sekarang ini, data dapat ditemukan dimana saja. Beragam jenis data tersebut dapat menghasilkan suatu informasi baru sehingga dapat membantu dalam menyimpulkan sebuah keputusan. membantu dalam menyimpulkan sebuah keputusan yang tepat berdasarkan data. Proses mengidentifikasi pola atau karakteristik dari setiap kelompok data untuk membantu dalam membuat keputusan dan memecahkan masalah disebut dengan *Data Mining*[6]. *Data Mining* adalah proses memperoleh pengetahuan dari kelompok data, yang mencakup pra-pemrosesan seperti ekstraksi, pembersihan, penggabungan, pengurangan data dan konstruksi fitur, serta langkah-langkah pasca-pemrosesan seperti interpretasi pola dan model[7]. Dalam *data mining* terdapat beberapa pengelompokan antara lain deskripsi, estimasi, prediksi, klasifikasi, pengklasteran dan asosiasi. Salah satu analisis pengklasteran merupakan suatu analisis

untuk mempartisi data menjadi beberapa kelompok dengan sifat homogen di dalam satu kelompok dan heterogen dengan kelompok lainnya. Pengelompokan data didasarkan pada perhitungan jarak minimum data terhadap pusat *cluster*. Analisis *clustering* banyak diterapkan di berbagai sektor seperti pada bidang pemasaran dengan melakukan segmentasi pasar/pelanggan atau pengelompokan produk, bidang kedokteran pada diagnosis medis atau bisa juga pada pemetaan genetik, segmentasi pengguna sosial media, segmentasi karyawan, dan juga analisis pengelompokan siswa berdasarkan pencapaian akademis atau karakteristik belajar. Penerapan metode clustering pada tingkat kecanduan game online sebelumnya telah diterapkan oleh Cindya pada penelitiannya tentang pengelompokan tingkat kecanduan game dengan validasi *cluster* menggunakan *Davies-Bouldin Index*(DBI)[8].

Analisis *cluster* biasanya dikaitkan dengan data yang bertipe *numerik* karena banyak algoritma yang memerlukan penghitungan jarak atau kesamaan antar data. Namun, terdapat salah satu pendekatan algoritma yang telah dikembangkan khusus untuk menangani data *kategorik* dimana variabelnya memiliki tipe data kategori atau label yaitu *K-Modes Clustering*. Analisis *cluster* menggunakan algoritma *k-modes* merupakan analisis pengelompokan data *kategorik* berdasarkan dengan pengukuran modus[9]. Algoritma *k-modes* merupakan modifikasi dari algoritma *k-means* yang memberikan solusi untuk analisis pengelompokan data yang bertipe *kategorik*. Beberapa algoritma lain yang cocok untuk data kategorikal atau data yang bersifat kualitatif, yaitu algoritma *Apriori* untuk menemukan hubungan antar atribut dalam data kategorikal, *Decision Trees* dapat membangun pohon keputusan untuk memprediksi kelas atau nilai atribut kategorikal, *Naïve Bayes* meskipun sering digunakan untuk data teks juga dapat diterapkan pada data kategorikal, *Random Forest* dapat menangani kategorikal maupun numerikal, *Logistic Regression* meskipun sering digunakan untuk data numerik juga dapat diterapkan untuk menangani variabel dependen kategorikal, dan *Neural Network* terutama *Deep Learning* dapat menangani data kategorikal untuk data yang sudah di-*encode* ke dalam numerik dengan teknik *One-Hot Encoding*. *K-Modes* tepat digunakan pada data kategorikal dan penggunaannya dapat membantu mengidentifikasi pola dan hubungan dalam dataset yang terdiri dari atribut kategorikal. Penelitian oleh Alphenia yang berjudul “Analisis K-Modes Clustering Dengan Metode Jarak Yuan” melakukan analisis cluster pada data kategorik yang diimplementasikan ke dalam perhitungan jarak Yuan pada data asuransi perjalanan[10]. Hasil dari implementasi algoritma *K-Modes Clustering* menggunakan perhitungan jarak Yuan dapat diimplementasikan ke dalam data asuransi perjalanan dengan pengguna jasa yang tidak memiliki asuransi membentuk kelompok sebanyak 4 kelompok dan nilai *Silhouette Coefficient* sebesar 0,00029477. Selanjutnya, penelitian oleh Fauzi tentang penerapan algoritma *K-Modes Clustering* dan C4.5 untuk memprediksi pemilihan jurusan pada siswa SMA Islam Ta'allamul Huda Bumiayu dalam prediksi jurusan di Universitas Peradaban menghasilkan nilai akurasi sebesar 87,5 %. Peneliti mengangkat permasalahan dalam pemilihan jurusan kuliah sebab pemilihan jurusan kuliah yang kurang tepat dapat mempengaruhi proses pembelajaran selama perkuliahan[11]. Penelitian lain oleh Dewi & Dwidasmara yang berjudul “Implementasi Algoritma K-Modes untuk Clustering Penyebab Stres pada Mahasiswa” melakukan pengelompokan faktor penyebab stress pada mahasiswa untuk melihat gambaran karakteristik masing-masing kelompok. Hasil dari klasterisasi menggunakan *K-Modes* diperoleh sebanyak 3 *cluster*.

Algoritma *k-modes clustering* dalam pengelompokkan data kategorikal memungkinkan sebuah platform untuk melakukan komputasi dalam analisis data. Salah satu platform untuk melakukan tahapan analisis pengelompokan data adalah *Jupyter*. *Jupyter* adalah antarmuka yang memungkinkan pengguna untuk mengkonfigurasi dan mengatur alur kerja dalam ilmu data, komputasi ilmiah, jurnalisme komputasi, dan pembelajaran mesin[12]. Dalam *jupyter*, memungkinkan pengguna untuk membuat *source code*, termasuk skrip *Python*, serta menyertakan visualisasi dan penjelasan. Bahasa pemrograman *Python* pada *Jupyter* memungkinkan perancangan, pengujian, dan memahami kode *Machine Learning* menjadi lebih mudah karena sintaksis *Python* yang fleksibel dengan berbagai teknologi dan dapat mengelola kompleksitas struktur data dalam proyek *Machine Learning*.


Berdasarkan uraian tentang kebiasaan bermain game online pada mahasiswa diatas, peneliti melakukan penelitian tentang pengelompokan kecanduan bermain game pada mahasiswa di Universitas Muhammadiyah Magelang. Penelitian ini bertujuan mengetahui cara pengumpulan dan pemrosesan data kecanduan *game online* serta bagaimana hasil interpretasi pengelompokkan kebiasaan bermain *game online* menggunakan algoritma *K-Modes Clustering*. Data yang diperoleh dalam penelitian ini bersifat kategorikal sehingga *K-Modes* merupakan algoritma yang tepat untuk analisis pengelompokan data. Pengelompokkan data kategorikal memungkinkan sebuah platform untuk melakukan analisis data sehingga *Jupyter* menjadi platform untuk analisis pengelompokan data dalam penelitian ini.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Tahapan penelitian yang dilakukan untuk analisis pengelompokan data disajikan pada Gambar 1. Langkah awal yang dilakukan adalah pengumpulan jurnal artikel dan analisis permasalahan tentang *game online* pada mahasiswa. Pada langkah selanjutnya, pengumpulan data diperoleh dari survei kuesioner online menggunakan Google Form. Data yang diperoleh juga dipastikan tidak ada yang bernilai kosong atau *null* agar dalam implementasi model dapat meningkatkan kinerja model saat proses pengolahan data. Sebelum data diolah oleh algoritma atau model, data tersebut dilakukan tahap pengolahan data awal dengan beberapa tahap *pre-processing*. Analisis data dalam penelitian ini dilakukan dengan menggunakan algoritma *K-Modes Clustering* yang dijalankan pada *software Jupyter Notebook* dengan bahasa pemrograman *Python*. Langkah terakhir, melakukan evaluasi terhadap klaster yang terbentuk, optimalisasi jumlah klaster

dengan Metode *Elbow*, pengukuran seberapa baik algoritma *K-Modes* menggunakan *Silhouette Score*, dan mengetahui korelasi variabel dengan grafik *Correlation Matrix*.



Gambar 1. Tahapan Penelitian

2.2 Analisis Permasalahan

Penelitian diawali dengan pengumpulan jurnal artikel yang berhubungan dengan kecanduan *game online*. Selanjutnya melakukan analisis permasalahan pada mahasiswa Universitas Muhammadiyah Magelang terkait dengan *game online* dimana terdapat mahasiswa yang membentuk kelompok dan bermain game online bersama. Terkait dengan permasalahan tersebut, peneliti memiliki ide untuk melakukan analisis pengelompokan tingkat kecanduan game di kalangan mahasiswa sehingga algoritma yang digunakan dalam penelitian ini adalah *clustering K-Modes*. Selanjutnya, peneliti melakukan pengumpulan artikel relevan tentang implementasi penggunaan algoritma *K-Modes Clustering* di berbagai sumber pustaka yang memiliki kesamaan topik.

2.3 Pengumpulan Data

Populasi dalam penelitian ini adalah mahasiswa Universitas Muhammadiyah Magelang yang diperoleh dari survei secara online dengan membuat kuesioner penelitian menggunakan Google Form. Populasi yang diperoleh yaitu sebanyak 90 responden dengan rentang pengambilan data 4 – 30 November 2023. Adapun data jawaban yang diisi oleh responden tersebut merupakan kendala yang dialami saat bermain game pada satu semester sebelumnya atau pada enam bulan terakhir bermain game. Pertanyaan-pertanyaan pada kuesioner tersebut merupakan modifikasi dari dataset terdahulu yang diunggah dalam laman web zenodo.org yang berisi data siswa SMA terkait *game online*[13]. Data yang diperoleh mencakup aspek-aspek yang mempengaruhi tingkat ketergantungan terhadap *game online*, termasuk jumlah waktu yang dihabiskan untuk bermain game, jenis permainan yang lebih cenderung menarik minat mahasiswa, jumlah waktu yang digunakan untuk aktivitas belajar, dan penambahan beberapa variabel pertanyaan tentang pedoman skala bermain game yang digagas oleh Lemmens yaitu *Salience*, *Tolerance*, *Mood*, *Withdrawl*, *Relapse*, *Conflict*, dan *Problems*[14]. Adapun skala kecanduan game tersebut dapat dilihat pada Tabel 1.

Skala kecanduan game pada Tabel 1, berguna men-validasi korelasi terhadap waktu yang dihabiskan untuk bermain game. Durasi waktu yang dihabiskan untuk bermain game saja tidak cukup sebagai dasar dalam mengukur tingkat kecanduan game, sehingga skala tersebut menjadi pengukuran tingkat kecanduan game dan korelasinya terhadap motivasi belajar pada mahasiswa. *Tolerance* merupakan kriteria ketika pemain ingin bermain game secara terus-menerus dan menambah waktu bermain. *Problems* merupakan kriteria ketika mengalami masalah yang disebabkan oleh bermain game. *Salience* yaitu menjadikan game sebagai aktivitas paling penting dan utama. *Mood* adalah menjadikan game sebagai perubah suasana hati ketika sedang dalam masalah. *Withdrawl* merupakan emosi keinginan bermain game. *Relapse* adalah kecenderungan ingin bermain walaupun sudah diperingatkan. Terakhir, *Conflict* yaitu mengalami masalah yang disebabkan bermain game secara berlebihan. Durasi yang dihabiskan untuk bermain game antar individu bervariasi, beberapa mungkin melakukannya dengan waktu berjam-jam setiap hari tanpa menunjukkan tanda-tanda kecanduan. Sementara yang lain mungkin hanya bermain beberapa jam tapi telah memenuhi kriteria-kriteria kecanduan diatas.

Tabel 1. Skala Kecanduan Game

Pertanyaan Kuesioner	Kriteria
Apakah suatu saat durasi waktu yang kamu gunakan untuk bermain game akan bertambah? (Misalnya 1 jam menjadi 2 jam setiap kali bermain)	Tolerance
Setelah bermain game online, apakah ada rasa malas belajar efek dari bermain game tersebut?	Problems
Apakah kamu memikirkan game online sepanjang hari?	Salience
Ketika kamu sedang dalam masalah, apakah membuatmu ingin bermain game online untuk meredakan stress dari masalah tersebut?	Mood
Jika kamu tidak mengakses game online dalam sehari saja, apakah ada yang kurang dalam keseharianmu?	Withdrawal
Jika kamu diberitahu orang-orang terdekatmu untuk mengurangi waktu bermain game atau bahkan berhenti bermain game, apakah kamu akan berhenti bermain?	Relapse
Ketika kamu sering bermain game online, tanpa disadari keseringan bermain game mempengaruhi hubungan interaksi dengan orang-orang terdekatmu. Apakah kamu merasa game online membuat interaksi sosialmu lebih renggang?	Conflict

2.4 Pengolahan Data

2.4.1 Attribute Rename

Langkah awal pengolahan data atau yang disebut preprocessing data dalam penelitian ini yaitu mengubah nama atribut data yang diperoleh dari hasil survei kuesioner. Mengubah nama atribut dalam data mining merujuk pada proses kemudahan dalam analisis dan interpretasi data serta meningkatkan kualitas kinerja model pengelompokan data. Atribut data yang awalnya berisi pertanyaan-pertanyaan terkait data diri responden di-rename dengan nama baru yang lebih singkat agar meningkatkan analisis data.

2.4.2 Labelling

Proses labeling dalam penelitian ini berguna untuk menentukan rentang durasi bermain game dan durasi belajar dengan memberikan label pada setiap masing-masing kategori durasi. Proses labeling dalam menginterpretasikan nilai pada penelitian ini mengacu pada penelitian sebelumnya oleh Doli Fancius[15]. Adapun labeling pada durasi bermain game dapat dilihat pada Tabel 2.

Tabel 2. Labelling Variabel Durasi Bermain Game

Intensitas	Rentang Waktu	Label
Sangat Rendah	Kurang dari 1 jam per hari	0
Rendah	1 – 3 jam per hari	1
Sedang	4 – 6 jam per hari	2
Tinggi	7 – 9 jam per hari	3
Sangat Tinggi	Lebih dari 9 jam per hari	4

Tabel 2 diatas merupakan proses labelling yang dilakukan dengan memberikan nilai angka berupa angka 0 sampai 4 pada masing-masing kategori durasi. Angka yang kurang dari 2 untuk mengkategorikan intensitas rendah yaitu rentang waktu kurang dari 3 jam per hari. Sebaliknya, angka yang lebih dari 2 akan dikategorikan intensitas tinggi karena rentang waktu lebih dari 4 jam per hari.

Adapun labelling pada durasi belajar dapat dilihat pada Tabel 3.

Tabel 3. Labelling Variabel Durasi Belajar

Intensitas	Rentang Waktu	Label
Sangat Rendah	Kurang dari 1 jam per hari	0
Rendah	1 – 2 jam per hari	1
Sedang	3 – 4 jam per hari	2
Tinggi	5 – 6 jam per hari	3
Sangat Tinggi	Lebih dari 6 jam per hari	4

Tabel 3 merupakan labelling pada variabel durasi belajar mahasiswa. Sama halnya dengan labelling pada variabel durasi bermain game namun sedikit berbeda pada durasi yang dihabiskan untuk belajar.

2.4.3 Cleaning

Pembersihan data atau cleaning dilakukan pada data mentah dengan menyeleksi ulang data sebelum melakukan tahap pengolahan data dan membersihkan data dengan cara menghapus data-data yang tidak digunakan dalam tahap analisis clustering.[16]. Hal ini dilakukan agar menghindari kesalahpahaman dalam penggunaan atribut yang tidak dibutuhkan pada proses pengelompokan data ketika menganalisis data tersebut.

2.5 Metode yang diusulkan

Algoritma yang diusulkan dalam penelitian ini adalah algoritma pengelompokan atau *clustering*. Terdapat beberapa prosedur dalam clustering data, salah satunya adalah *K-Modes Clustering*. *K-Modes Clustering* merupakan modifikasi *K-Means*, dimana algoritma ini digunakan dalam pengelompokan saat data tersebut bersifat kategorikal[17]. Sedangkan data pada penelitian ini memiliki parameter label yang bersifat kategorik sehingga penggunaan metode *k-modes* lebih sesuai diterapkan pada penelitian ini dibandingkan metode *k-means*. Pengukuran antara titik *centroid* pada *k-modes* berbeda dengan *k-means*, dimana pada algoritma ini menggunakan modus pengukuran nilai kategori antara dua titik data. Langkah-langkah pada *k-modes* tetap sama dengan algoritma *k-means* yang dijelaskan sebagai berikut:

- Inisialisasi cluster dengan memilih secara acak *k* centroid awal dari dataset.
- Hitung jarak atau kesamaan antara setiap titik data dengan centroid. Tentukan cluster yang memiliki jarak mode terdekat dari setiap titik data dengan rumus:

$$d_1(X,Y) = \sum_{j=1}^m \delta(x_j, y_j) \quad (1)$$

Dimana

$$\delta(x_j, y_j) = \begin{cases} 0 & (x_j = y_j) \\ 1 & (x_j \neq y_j) \end{cases}$$

Keterangan:

$d(x, y)$ = jarak dari data *x* ke *y*


x_j = nilai fitur *j* dari *x*

y_j = nilai fitur *j* dari *y*

m = jumlah fitur

- Setelah cluster terbentuk, periksa nilai ketidaksamaan setiap atribut menggunakan modus atau objek yang sering muncul.
- Ulangi langkah 2 dan 3 hingga tidak ada objek cluster yang berubah.

Berikut merupakan diagram alur atau flowchart metode pengelompokan data dengan algoritma *K-Modes* yang ditampilkan pada Gambar 2.



Gambar 2. Flowchart atau Alur *K-Modes Clustering*

2.6 Evaluasi

Dalam tahap evaluasi, analisis pengelompokkan data dengan algoritma *K-Modes* dinilai seberapa baik hasil dari klasterisasi dengan tujuan mengidentifikasi *cluster* yang terbentuk sehingga mendapatkan informasi baru terhadap data yang dianalisis. Proses klasterisasi dengan algoritma *K-Modes* juga diukur seberapa baik pengelompokkan *cluster* yang terbentuk dengan menggunakan *Silhouette Score*. Selain itu, penggunaan Metode *Elbow* pada penelitian ini dapat membantu menentukan jumlah klaster optimal yang baik digunakan pada dataset kecanduan game pada mahasiswa. Terakhir, evaluasi terhadap hubungan kecanduan game online dengan durasi belajar mahasiswa menggunakan grafik *Correlation Matrix*.

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Hasil pengumpulan data memperoleh data sebanyak 90 data mahasiswa yang bermain game online. Data ini terdiri dari beberapa atribut, termasuk cap waktu, jenis kelamin, semester, status bermain, nama game, internet untuk akses game, rata-rata jam bermain game, tempat bermain game, dll yang dapat dilihat pada Gambar 3. Namun, dalam analisis pengelompokan data yang dilakukan, tidak semua atribut dipakai dalam tahap pengklasteran. Beberapa atribut yang tidak penting atau tidak perlu dicantumkan sebagai parameter *clustering* salah satunya cap waktu atau *timestamp* yang merupakan tanggal dan waktu pengisian kuesioner.

Cap waktu	Jenis Kelamin	Mahasiswa semester berapa?	Apakah saat ini masih bermain game online?	Sebutkan Game Online Mobile yang disukai! (Maks 3 Game)	Fasilitas internet apa yang sering kamu gunakan untuk bermain game online?	Berapa rata-rata durasi bermain game online setiap hari?	Tempat yang paling sering untuk bermain game online?	Saat di kampus, kapan kamu bermain game online? (Centang bagian yang pernah kamu lakukan)	Saat kamu belajar di rumah, rata-rata jam belajar sehari?	Alasan kamu bermain game online? (Centang bagian yang sesuai denganmu)	Apakah suatu saat durasi waktu yang kamu gunakan untuk bermain game akan bertambah? (Misalnya 1 jam menjadi 2 jam setiap kali main)	Setelah bermain game online, apakah ada rasa kantuk atau kekurangan jam tidur efek dari bermain game tersebut?
0 2023/11/04 9:48:14 AM GMT+7	Laki-laki	8	Ya	Mobile legend, pubg, coc	Wifi	1-3 Jam/Hari	Rumah	Bermain game saat jam kosong;Bermain game saat...	1-2 Jam/Hari	Mencari kesenangan	Tidak	Tidak
1 2023/11/04 9:53:11 AM GMT+7	Laki-laki	3	Ya	fortnite, minecraft, chess.com	Wifi	Kurang dari 1 Jam/Hari	Rumah	Bermain game saat jam istirahat	1-2 Jam/Hari	Mencari kesenangan	Tidak	Ya
2 2023/11/04 10:00:27 AM GMT+7	Laki-laki	5	Ya	Mobile Legend, PUBG, E-Football	Wifi	1-3 Jam/Hari	Rumah	Bermain game saat jam istirahat	1-2 Jam/Hari	Lingkungan pergaulan gamer	Ya	Ya
3 2023/11/04 10:09:51 AM GMT+7	Laki-laki	Semester 9	Tidak	PUBG, Mobile Legends, Clash of Clans	Internet Mobile Data (Kuota Internet Pribadi)	Kurang dari 1 Jam/Hari	Rumah	Bermain game saat jam istirahat	1-2 Jam/Hari	Mencari kesenangan	Tidak	Ya
4 2023/11/04 10:18:46 AM GMT+7	Laki-laki	3	Ya	Mobile Legends, PUBG Mobile, eFootball	Wifi	1-3 Jam/Hari	Rumah	Bermain game saat jam istirahat	3-4 Jam/Hari	Mencari kesenangan	Ya	Ya

Gambar 3. Data Mahasiswa

Data mahasiswa yang dapat dilihat pada Gambar 3, menunjukkan data mentah yang diperoleh dari hasil kuesioner Google Form. Nama atribut masih dalam bentuk pertanyaan-pertanyaan yang sesuai dengan kuesioner online.

3.2 Pengolahan Data

3.2.1 Attribute Rename

	time	sex	sem	pg	game	if	mhog	place	pgoc	mhos	reason	tolerance	problem
0	2023/11/04 9:48:14 AM GMT+7	Laki-laki	8	Ya	Mobile legend, pubg, coc	Wifi	1-3 Jam/Hari	Rumah	Bermain game saat jam kosong;Bermain game saat...	1-2 Jam/Hari	Mencari kesenangan	Tidak	Tidak
1	2023/11/04 9:53:11 AM GMT+7	Laki-laki	3	Ya	fortnite, minecraft, chess.com	Wifi	Kurang dari 1 Jam/Hari	Rumah	Bermain game saat jam istirahat	1-2 Jam/Hari	Mencari kesenangan	Tidak	Ya
2	2023/11/04 10:00:27 AM GMT+7	Laki-laki	5	Ya	Mobile Legend, PUBG, E-Football	Wifi	1-3 Jam/Hari	Rumah	Bermain game saat jam istirahat	1-2 Jam/Hari	Lingkungan pergaulan gamer	Ya	Ya
3	2023/11/04 10:09:51 AM GMT+7	Laki-laki	Semester 9	Tidak	PUBG, Mobile Legends, Clash of Clans	Internet Mobile Data (Kuota Internet Pribadi)	Kurang dari 1 Jam/Hari	Rumah	Bermain game saat jam istirahat	1-2 Jam/Hari	Mencari kesenangan	Tidak	Ya
4	2023/11/04 10:18:46 AM GMT+7	Laki-laki	3	Ya	Mobile Legends, PUBG Mobile, eFootball	Wifi	1-3 Jam/Hari	Rumah	Bermain game saat jam istirahat	3-4 Jam/Hari	Mencari kesenangan	Ya	Ya

Gambar 4. Atribut baru pada data mahasiswa

Proses mengubah nama atribut pada dataset dilakukan untuk memberikan nama yang awalnya dalam bentuk pertanyaan-pertanyaan tentang data diri mahasiswa berdasarkan pengalaman pribadi dalam bermain game online. Atribut yang jelas dan deskriptif sangat penting dalam data mining karena meningkatkan pemahaman, keterbacaan, dan kualitas analisis data[18]. Perubahan nama atribut dapat memudahkan pemahaman tentang informasi dan mengurangi kesalahpahaman atribut yang ambigu atau tidak jelas ketika melakukan analisis data. Nama atribut yang lebih deskriptif dapat membantu analisis data dalam memahami pola dan hubungan dalam data saat algoritma analisis diterapkan sehingga meningkatkan kinerja model. Nama atribut yang jelas dapat menghasilkan hasil analisis yang lebih baik, memperkuat interpretasi, serta membantu memudahkan dalam pengambilan kesimpulan yang lebih jelas. Pada Gambar 4 menunjukkan bahwa data yang awalnya memiliki atribut yang kompleks telah diubah ke dalam atribut yang lebih singkat agar lebih mudah saat analisis data.


3.2.2 Labeling

Proses hasil labelling pada masing-masing variabel dapat dilihat pada Gambar 4

mhog	place	pgoc	mhos
1	Kampus	Bermain game saat jam istirahat	2
1	Lain-lain (Cafe, Tempat nongkrong, dll)	Bermain game saat jam perkuliahan	4
3	Lain-lain (Cafe, Tempat nongkrong, dll)	Bermain game saat jam perkuliahan	3
1	Rumah	Bermain game saat jam istirahat	1
0	Rumah	Bermain game saat jam kosong	1


Gambar 5. Hasil Labelling

Hasil dari proses labeling pada Gambar 5, mengkategorikan data rata-rata durasi bermain game online (Mean Hours of Game/mhog) dan rata-rata durasi belajar (Mean Hours of Study/mhos) menjadi lima kategori yang dapat dilihat pada Gambar 5. Durasi bermain game online yang kurang dari satu jam per hari dapat diberi label (0) sebagai intensitas sangat rendah, satu sampai tiga jam per hari diberi label (1) sebagai kategori rendah, empat sampai enam jam per hari bermain sebagai label (2) dengan intensitas sedang, tujuh sampai sembilan jam per hari sebagai intensitas tinggi diberi label (3), dan label (4) jika durasi bermain game lebih dari sembilan jam per hari yaitu intensitasnya sangat tinggi. Sedangkan visualisasi jumlah data mahasiswa berdasarkan rata-rata durasi bermain game dijelaskan pada Gambar 6.



Gambar 6. Mean Hour of Game (mhog)

Gambar 6, menunjukkan frekuensi durasi rata-rata bermain game online (*Mean Hours of Game/mhog*) paling tinggi berada pada rentang waktu 1-3 jam per hari. Diinterpretasikan bahwa durasi bermain game antara satu hingga tiga jam per hari dapat dikatakan sebagai durasi yang cukup umum sebagian orang. Namun, penting untuk diingat bahwa implikasi dari durasi bermain game dapat bervariasi antarindividu, seperti usia, banyaknya aktivitas lain, dan dampak dari kecanduan game online itu sendiri[19].



Gambar 7. Mean Hour of Study (mhos)

Sedangkan pada Gambar 7, frekuensi durasi rata-rata belajar per hari (*Mean Hours of Study/mhos*) paling tinggi berada pada kisaran 1-2 jam per hari. Durasi tersebut diinterpretasikan sebagai rentang waktu yang standar atau normal dalam mengalokasikan waktu belajar dalam sehari. Namun efisiensi dari durasi belajar dapat dikatakan bervariasi tergantung pada tingkat pendidikan, subjek yang dipelajari, dan efektivitas waktu yang dihabiskan[20].

3.2.3 Cleaning

Pembersihan data dilakukan untuk menghilangkan atribut yang tidak digunakan sebagai parameter klusterisasi data kecanduan game online. Pembersihan data sebelum clustering dapat meningkatkan kualitas hasil clustering dengan meminimalkan dampak dari data yang tidak lengkap atau tidak relevan. Beberapa atribut yang tidak digunakan atau dibersihkan seperti atribut “*time*”, “*sem*”, “*game*”, “*if*”, “*pgoc*”, dan “*reason*”. Atribut-atribut tersebut bukan merupakan parameter kecanduan game online sehingga perlu dihilangkan sebelum tahap analisis clustering. Data yang sudah dilakukan tahap cleaning dapat dilihat pada Gambar 8 yang menunjukkan hasil pembersihan atribut-atribut yang tidak digunakan dalam proses klusterisasi data. Atribut tersebut dihilangkan karena bukan merupakan data yang bertipe kategorikal.

	sex	pg	mhog	place	mhos	tolerance	problem	salience	mood	withdrawl	relapse	conflict
0	Laki-laki	Ya	1	Rumah	1	Tidak	Tidak	Tidak	Tidak	Tidak	Berhenti dan membatasi waktu bermain	Tidak
1	Laki-laki	Ya	0	Rumah	1	Tidak	Ya	Tidak	Tidak	Tidak	Berhenti dan membatasi waktu bermain	Ya
2	Laki-laki	Ya	1	Rumah	1	Ya	Ya	Tidak	Tidak	Ya	Berhenti dan membatasi waktu bermain	Ya
3	Laki-laki	Tidak	0	Rumah	1	Tidak	Ya	Tidak	Tidak	Tidak	Berhenti dan membatasi waktu bermain	Ya
4	Laki-laki	Ya	1	Rumah	2	Ya	Ya	Tidak	Tidak	Tidak	Berhenti dan membatasi waktu bermain	Tidak

Gambar 8. Hasil Cleaning

3.3 Metode yang diusulkan

```
[ ] import pandas as pd
import matplotlib.pyplot as plt
from kmodes.kmodes import KModes

# Membaca data dari file CSV yang telah dienkoded
data = pd.read_csv('C:/Users/user/Documents/Kuliah/Skripsi/Coding/cleaned.csv')

# Menentukan jumlah cluster yang optimal
num_clusters = 2

# Melakukan fitting K-Modes dengan jumlah cluster
km=KModes(n_clusters=num_clusters, max_iter=20)
clusters=km.fit_predict(data, categorical=[0, 2])

[ ] print(km.cluster_centroids_)

[['Laki-laki' 'Ya' '1' 'Rumah' '1' 'Ya' 'Ya' 'Ya' 'Ya' 'Ya'
'Berhenti dan membatasi waktu bermain' 'Ya']
['Perempuan' 'Ya' '0' 'Rumah' '1' 'Tidak' 'Tidak' 'Tidak' 'Tidak'
'Tidak' 'Berhenti dan membatasi waktu bermain' 'Tidak']]
```

Gambar 9. Hasil Centroid yang terbentuk

Hasil kinerja model clustering menggunakan k-modes pada atribut-atribut kategorikal dengan cluster yang ditentukan sebanyak 2 cluster dan maksimum iterasi adalah dua puluh percobaan iterasi dengan nilai k centroid awal adalah data ke-0 dan ke-2 didapatkan hasil pengelompokan yang dapat dilihat pada Gambar 9.

Hasil percobaan iterasi yang dijelaskan pada Gambar 9 menghasilkan 2 cluster. Hasil kluster tersebut terdapat 2 centroid yang masing-masing memiliki karakteristik kelompok yang berbeda. Pada Tabel 4, dijelaskan identifikasi karakteristik masing-masing kluster yang diperoleh dari hasil klusterisasi menggunakan algoritma k-modes.

Tabel 4. Identifikasi Cluster

Klaster	Penjelasan
Klaster 1	Klaster 1 merupakan klaster yang mempunyai anggota lebih banyak dengan jumlah 63 anggota. Cluster ini berisi kelompok mahasiswa yang mayoritas berjenis kelamin laki-laki. Pada klaster ini, mahasiswa masih bermain game online pada enam bulan terakhir dan diantaranya bermain game di rumah masing-masing. Durasi yang dihabiskan untuk bermain game pada klaster 1 berada pada kisaran 1-3 jam per hari, sedangkan durasi belajarnya antara 1-2 jam per harinya. Durasi bermain game tersebut dapat bertambah sewaktu-waktu. Selain itu, pada klaster ini terdapat mahasiswa yang semakin malas belajar dan lebih mementingkan game. Pada klaster ini, alasan mahasiswa bermain game dikarenakan ingin meredakan stress dan jika dalam waktu sehari saja tidak mengakses game ada sesuatu yang kurang dalam kesehariannya. Meskipun pada klaster ini didominasi mahasiswa yang sering mengakses game setiap hari, namun tetap mengurangi dan membatasi bermain game.

Klaster 2 Klaster 2 mempunyai anggota sebanyak 27 anggota yang didominasi oleh jenis kelamin perempuan. Meskipun pada klaster ini dapat dikatakan masih mengakses game online selama enam bulan terakhir, namun durasi yang dihabiskan untuk bermain game terbilang sedikit yaitu kurang dari 1 jam per harinya. Pada klaster ini, durasi belajar berada berkisar antara 1 hingga 2 jam per hari dan tidak memikirkan game online. Walaupun pada klaster ini tidak mengakses game online dalam waktu sehari saja, mereka tidak memiliki keinginan untuk bermain dan mengakses game meski dalam kondisi stress.


Hasil centroid di atas, mengidentifikasi dua jenis klaster yang terbentuk dari proses analisis klastering sehingga klaster yang diperoleh dari algoritma k-modes tersebut dapat dilihat pada Gambar 10.

	sex	pg	mhog	place	mos	tolerance	problem	saliance	mood	withdrawal	relapse	conflict	cluster
0	Laki-laki	Ya	1	Rumah	1	Tidak	Tidak	Tidak	Tidak	Tidak	Berhenti dan membatasi waktu bermain	Tidak	1
1	Laki-laki	Ya	0	Rumah	1	Tidak	Ya	Tidak	Tidak	Tidak	Berhenti dan membatasi waktu bermain	Ya	1
2	Laki-laki	Ya	1	Rumah	1	Ya	Ya	Tidak	Tidak	Ya	Berhenti dan membatasi waktu bermain	Ya	0
3	Laki-laki	Tidak	0	Rumah	1	Tidak	Ya	Tidak	Tidak	Tidak	Berhenti dan membatasi waktu bermain	Ya	1
4	Laki-laki	Ya	1	Rumah	2	Ya	Ya	Tidak	Tidak	Tidak	Berhenti dan membatasi waktu bermain	Tidak	0
5	Laki-laki	Ya	1	Rumah	1	Tidak	Ya	Ya	Ya	Ya	Berhenti dan membatasi waktu bermain	Ya	0
6	Perempuan	Ya	0	Rumah	2	Ya	Tidak	Tidak	Ya	Tidak	Berhenti dan membatasi waktu bermain	Tidak	1
7	Laki-laki	Ya	1	Rumah	1	Tidak	Ya	Tidak	Ya	Ya	Berhenti dan membatasi waktu bermain	Tidak	0
8	Laki-laki	Ya	1	Rumah	1	Ya	Tidak	Tidak	Ya	Tidak	Berhenti dan membatasi waktu bermain	Tidak	0
9	Laki-laki	Ya	2	Rumah	0	Ya	Ya	Tidak	Ya	Ya	Tetap bermain game tanpa mementingkan waktu be...	Ya	0
10	Perempuan	Tidak	0	Rumah	0	Tidak	Tidak	Tidak	Tidak	Tidak	Berhenti dan membatasi waktu bermain	Tidak	1
11	Perempuan	Tidak	0	Rumah	0	Tidak	Tidak	Tidak	Tidak	Tidak	Berhenti dan membatasi waktu bermain	Tidak	1
12	Laki-laki	Ya	1	Rumah	2	Ya	Ya	Tidak	Ya	Tidak	Berhenti dan membatasi waktu bermain	Ya	0
13	Laki-laki	Ya	2	Rumah	0	Ya	Ya	Ya	Ya	Ya	Tetap bermain game tanpa mementingkan waktu be...	Tidak	0
14	Perempuan	Tidak	0	Rumah	2	Tidak	Tidak	Tidak	Tidak	Tidak	Berhenti dan membatasi waktu bermain	Tidak	1

Gambar 10. Data Clustering

3.4 Evaluasi

Hasil analisis klastering menggunakan algoritma k-modes tersebut perlu dilakukan analisis sehingga pada tahap evaluasi ini menjelaskan informasi baru yang diperoleh dari beberapa tahapan yang sudah dilakukan diatas. Kinerja algoritma klastering k-modes pada 12 atribut diatas mendapatkan hasil klaster yang baik. Hasil klastering pada penelitian ini menghasilkan klaster sebanyak 2 kelompok klaster. Jumlah klaster yang digunakan pada tahap klastering harus ditentukan dengan menentukan jumlah klaster optimal agar mendapatkan hasil yang optimal pula sehingga dalam menentukan jumlah klaster optimal pada penelitian ini menggunakan Metode Elbow yang dapat dilihat pada Gambar 11.




Gambar 11. Metode Elbow

Metode Elbow membantu dalam menentukan jumlah klaster optimal yang digunakan dalam suatu data. Pada Gambar 11 diatas, grafik siku berada pada titik 6 dengan nilai cost kurang dari 250 sehingga jumlah klaster optimal yang diperoleh dari penerapan metode elbow adalah 6 cluster.

Berdasarkan analisis klastering pada data tingkat kecanduan game dan hubungannya dengan motivasi belajar menggunakan algoritma k-modes memberikan pandangan objektif mengenai seberapa baik suatu pengelompokan dapat memisahkan kelompok sehingga dalam menilai seberapa valid pengelompokan tersebut, Silhouette Score membantu untuk mengukur sejauh mana pemisahan masing-masing kelompok. Silhouette Score pada klastering kecanduan game

mendapatkan hasil sebesar 0,1531 dan hubungan antara durasi bermain game dengan durasi belajar pada mahasiswa dapat dilihat pada Gambar 12 sebagai berikut.



Gambar 12. Correlation Matrix

Gambar 12 menunjukkan matriks korelasi anatara variabel durasi bermain game dan variabel durasi belajar. Hubungan yang diperoleh dari hasil clustering menggunakan matriks korelasi mendapatkan hasil negatif sehingga tidak terdapat hubungan antara durasi yang dihabiskan untuk bermain game dan durasi belajar mahasiswa.

4. KESIMPULAN

Berdasarkan hasil dan pembahasan yang telah disampaikan dalam pengelompokan data bermain game online pada mahasiswa Universitas Muhammadiyah Magelang, dapat ditarik kesimpulan sebanyak 90 data mahasiswa yang diperoleh merupakan hasil survei kuesioner online pada pengalaman pribadi mahasiswa dalam bermain game selama enam bulan terakhir. Pengklasteran data bermain game pada mahasiswa menggunakan algoritma k-modes, sebelumnya dilakukan preprocessing terlebih dahulu agar nantinya dapat diklastering dengan baik. Jumlah klaster yang digunakan pada penelitian ini sebanyak 2 klaster dengan hasil klaster 1 berjumlah 63 anggota sedangkan klaster 2 berjumlah 27 anggota. Berdasarkan Metode Elbow dalam menentukan jumlah klaster optimal, grafik siku berada pada titik 6 dengan nilai cost kurang dari 250 sehingga jumlah klaster optimal yang diperoleh adalah 6 cluster. Selain itu, hasil cluster juga dilihat jarak masing-masing klaster dengan menggunakan Silhouette Score yang hasilnya adalah 0,1531 dan dalam menentukan hubungan antar variabel cluster dengan matriks korelasi mendapatkan hasil -0,10 yang berarti korelasi negatif.

REFERENCES

- [1] P. A. Yudhanto, "Perancangan Promosi Produk Edu-Games Melalui Event," 2010, Bandung.
- [2] H. Sama and J. Junanto, "Analisis Pengaruh Game Online Dan Motivasi Bermain Terhadap Minat Belajar Siswa Sd," *Jevon Junanto J. Ilm. Betrik*, vol. 13, no. 03, pp. 348–355, 2022.
- [3] G. L. Ondang, B. J. Mokal, and S. Y. V. I. Goni, "Dampak Game Online Terhadap Motivasi Belajar Mahasiswa Jurusan Sosiologi Fispol Unsrat," *J. holistik*, vol. 13, no. 2, pp. 1–15, 2020.
- [4] V. A. Dihni, "Jumlah Gamers Indonesia Terbanyak Ketiga di Dunia Title," *databoks*, 2022. <https://databoks.katadata.co.id/datapublish/2022/02/16/jumlah-gamers-indonesia-terbanyak-ketiga-di-dunia>
- [5] "Gaming Disorder," *World Health Organization (WHO)*.
- [6] A. Muhammad and E. Budianita, "Pengelompokan Tingkat Kecanduan Game Online Menggunakan Algoritma Fuzzy C-Means," *J. Nas. Komputasi dan Teknol. Inf.*, vol. 5, no. 4, pp. 601–610, 2022, doi: 10.32672/jnkti.v5i4.4511.
- [7] Z. Nabila, A. Rahman Isnain, and Z. Abidin, "Analisis Data Mining Untuk Clustering Kasus Covid-19 Di Provinsi Lampung Dengan Algoritma K-Means," *J. Teknol. dan Sist. Inf.*, vol. 2, no. 2, p. 100, 2021, [Online]. Available: <http://jim.teknokrat.ac.id/index.php/JTSI>
- [8] Z. Cindya Dwyne, D. Nur Aini, T. Ayunita Pertiwi, and D. Pramana, "SENTIMAS: Seminar Nasional Penelitian dan Pengabdian Masyarakat Cluster Level of Online Game Addiction in Students of the Faculty of Science and Technology and its Correlation with Learning Interest Cluster Tingkat Kecanduan Game Online Pada Mahasiswa Fak," pp. 126–132, 2023, [Online]. Available: <https://journal.irpi.or.id/index.php/sentimas>
- [9] C. Liu *et al.*, "A Moving Shape-based Robust Fuzzy K-modes Clustering Algorithm for Electricity Profiles," *Electr. Power Syst. Res.*, vol. 187, p. 106425, 2020, doi: <https://doi.org/10.1016/j.epsr.2020.106425>.
- [10] S. Alphenia, "Analisis K-Modes Clustering Dengan Metode Jarak Yuan," pp. 1–127, 2022.
- [11] A. Fauzi, N. M. Saraswati, R. Cipta, and S. Hariyono, "(Studi Kasus : S MA Islam Ta ' allumul Huda Bumiayu)," vol. 1, no. 2, pp. 57–64, 2020.
- [12] Jupyter, "Jupyter." jupyter.org, tanggal akses 02 Januari 2024

- [13] D. R. Fathony, Sulthan Alif Secca Ramadhani, Vincentian Michael Anton Poetra, and Nur Aini Rakhmawati, "Respon data siswa SMA terkait game online," *Zenodo*, 2020. <https://zenodo.org/record/4255028>
- [14] J. S. Lemmens, P. M. Valkenburg, and J. Peter, "Development and validation of a game addiction scale for adolescents," *Media Psychol.*, vol. 12, no. 1, pp. 77–95, 2009, doi: 10.1080/15213260802669458.
- [15] Doli Fancius, Elvia Budianita, Iwan Iskandar, and Fadhilah Syafria, "Tingkat Kecanduan Game Online Menggunakan Algoritma X-Means Clustering," pp. 135–145, 2022.
- [16] M. K. Khoirul Insan, U. Hayati, and O. Nurdian, "Analisis Sentimen Aplikasi Brimo Pada Ulasan Pengguna Di Google Play Menggunakan Algoritma Naive Bayes," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 7, no. 1, pp. 478–483, 2023, doi: 10.36040/jati.v7i1.6373.
- [17] E. R. Susanto, A. Syarif, K. Muludi, R. R. W. Perdani, and A. Wantoro, "Implementation of Fuzzy-based Model for Prediction of Thalassemia Diseases," *J. Phys. Conf. Ser.*, vol. 1751, no. 1, 2021, doi: 10.1088/1742-6596/1751/1/012034.
- [18] Q. Z. Yang, X. S., & Wu, "A Method to Deal with the Attribute Names of Data in Data Mining," *Appl. Mech. Mater.*, 2015.
- [19] R. Sahara and T. Y. . Pristya, "Jurnal Ilmiah Kesehatan 2022 Jurnal Ilmiah Kesehatan 2022," *J. Ilm. Kesehat.*, vol. 21, no. 1, pp. 14–19, 2022.
- [20] M. V. A. Kumar, "Study Time Investment in Students at Tertiary Level of Education: A Comparative Study," 2019.