

ANALISIS PERBANDINGAN ALGORITMA APRIORI DAN FP-GROWTH DALAM MENEMUKAN POLA PENGGUNAAN AI YANG BERPOTENSI MENYEBABKAN BRAINROT

Ayu Cahya Ningrum, Ali Nur Ikhsan

Informatika, Universitas Amikom Purwokerto

Jl. Letjen Pol. Soemarto No 127, Purwokerto Utara, Jawa Tengah, Indonesia

cahyaningrum3000@gmail.com

ABSTRAK

Pesatnya integrasi *Artificial Intelligence* (AI) dalam aktivitas akademik memicu risiko degradasi kognitif atau *brainrot* akibat ketergantungan digital yang ekstrem. Penelitian ini mengevaluasi performa algoritma Apriori dan FP-Growth dalam mengekstraksi pola penggunaan AI yang berdampak pada penurunan daya kritis mahasiswa. Data diperoleh dari 110 responden melalui instrumen tervalidasi dengan *Cronbach's Alpha* 0,931. Hasil pengujian pada *minimum support* 0,2 dan *confidence* 0,6 menunjukkan kedua algoritma menghasilkan 76 itemset dan 134 aturan. Dari aspek efisiensi, Apriori unggul dengan waktu eksekusi 0,0072 detik, lebih cepat dibanding FP-Growth 0,0528 detik. Pengujian beban pada *support* 0,05 memicu lonjakan 8.128 *itemset*, dimana Apriori bekerja 53,8 kali lebih cepat (0,2021 detik) dibandingkan FP-Growth (10,8814 detik). Melalui analisis *association rule*, ditemukan bahwa jalur pemicu utama *brainrot* adalah kombinasi Ketenangan Emosional (P9) dan Generalisasi Tugas (P4) yang bermuara pada Degradasi Berpikir Kritis (P20) dengan nilai *Lift Ratio* 1,57. Temuan tambahan menunjukkan bahwa perilaku Substitusi Referensi (P5), atau kecenderungan mengganti literatur ilmiah dengan AI, menjadi faktor pengunci yang mempercepat penurunan ketajaman analisis mandiri. Penelitian ini berkontribusi empiris bagi institusi dalam merumuskan kebijakan literasi AI guna menjaga integritas intelektual mahasiswa di era transformasi digital.

Kata kunci : *Artificial Intelligence, Apriori, FP-Growth, Brainrot, Berpikir Kritis, Data Mining*

1. PENDAHULUAN

Pesatnya kemajuan teknologi kecerdasan buatan (AI) ini telah merombak fundamental cara masyarakat mengakses data dan menuntaskan tanggung jawab intelektual [1], [2]. Integrasi berbagai platform berbasis AI memungkinkan penyelesaian tugas kompleks dan pencarian jawaban instan yang dahulu memakan waktu lama [3]. Meski efisiensi kerja meningkat drastis, muncul diskursus mengenai dampak negatifnya terhadap ketajaman kognitif. Pemanfaatan AI dalam menyusun karya ilmiah mahasiswa telah menjadi fenomena yang signifikan [4], namun di sisi lain, Penggunaan teknologi ini memiliki kaitan erat terhadap perubahan kemampuan berpikir kritis mahasiswa [5].

Penurunan kualitas kognitif tersebut kini kerap diidentifikasi melalui fenomena *brainrot*, sebuah kondisi dimana ketergantungan ekstrem pada instrumen digital mengikis kapasitas individu dalam melakukan analisis, refleksi, serta pemecahan masalah secara mandiri. Fenomena ini dideskripsikan sebagai refleksi negative dari pola konsumsi teknologi yang tidak sehat di kalangan anak muda [6]. Secara ilmiah, fenomena ini berkaitan erat dengan konsep *Cognitive Offloading*, dimana individu menyerahkan tugas intelektual secara berlebihan kepada teknologi eksternal sehingga memicu degradasi fungsi eksekutif otak [5]. Ketergantungan ini menyebabkan terjadinya pemrosesan informasi yang dangkal (*shallow processing*), dimana kecepatan mendapatkan jawaban dari AI mengalahkan kedalaman pemahaman dan

analisis mandiri dari mahasiswa [7]. Dalam pemanfaatan kecerdasan buatan, degradasi ini muncul saat pengguna mengadopsi mentah-mentah output sistem tanpa adanya proses filtrasi atau evaluasi kritis. Penggunaan alat bantu seperti ChatGPT dalam pendidikan memerlukan analisis pola yang mendalam agar tidak menggantikan proses berpikir orisinal [7].

Kondisi ini menuntut adanya pemetaan pola perilaku yang sistematis melalui teknik data mining untuk menemukan hubungan antar-variabel perilaku mahasiswa. Dalam literatur penambangan data, algoritma Apriori dan FP-Growth merupakan dua metode yang paling menonjol untuk mengekstraksi aturan asosiasi. Pentingnya membandingkan kedua metode ini didasarkan pada karakteristik dataset kuesioner yang memiliki tingkat kerapatan data yang tinggi namun dengan jumlah atribut yang terbatas.

Secara teknis, algoritma Apriori sering kali terkendala oleh proses pemindaian database yang berulang dan pembentukan kandidat itemset yang massif, terutama saat menghadapi data dengan variasi pola yang tinggi [8]. Sebaliknya, algoritma FP-Growth menawarkan solusi melalui struktur FP-Tree yang memungkinkan ekstraksi pola tanpa harus membangkitkan kandidat secara eksplisit, yang secara teoritis lebih unggul dalam kecepatan pemrosesan [9]. Perbandingan kedua algoritma ini menjadi krusial karena beberapa studi literatur menunjukkan bahwa permasalahan efisiensi pada Apriori sering kali menjadi hambatan utama dalam analisis data berskala besar, sehingga evaluasi terhadap performa FP-Growth

diperlukan sebagai solusi alternatif yang lebih optimal [10]. Namun, efektivitas FP-Growth pada dataset kuesioner dengan jumlah responden yang spesifik masih memerlukan pengujian empiris untuk memastikan akurasi pola asosiasi yang dihasilkan.

Melalui penelitian berjudul “Analisis Perbandingan Algoritma Apriori dan FP-Growth dalam Menemukan Pola Penggunaan AI yang Berpotensi Menyebabkan Brainrot”, studi ini bertujuan mengevaluasi performa kedua algoritma penambangan data dalam membedah fenomena sosiopsikologis tersebut. Penelitian ini dilakukan dengan pendekatan kuantitatif yang menitikberatkan pada analisis komputasi dan kekuatan statistik pola asosiasi guna memastikan objektivitas temuan. Hasil penelitian ini diharapkan dapat memberikan kontribusi empiris bagi institusi pendidikan dalam merumuskan kebijakan penggunaan AI yang tetap menjunjung tinggi integritas intelektual mahasiswa.

2. TINJAUAN PUSTAKA

2.1. Teori Penerimaan Teknologi dan Adiksi Digital

Konsep kemudahan penggunaan teknologi yang awalnya dikemukakan oleh Davis [11] melalui *Technology Acceptance Model* (TAM), menjadi dasar mengapa mahasiswa sangat cepat mengadopsi AI dalam aktivitas akademik. Namun, penggunaan yang tidak terkontrol dapat mengarah pada pola adiksi dalam kerangka biopsikososial yang dijelaskan oleh Griffiths [12]. Dampak dari ketergantungan ini memunculkan fenomena *brainrot*, yaitu penurunan fungsi kognitif akibat konsumsi teknologi yang tidak sehat secara berulang [6]. Penelitian terbaru menunjukkan bahwa integrasi AI dalam pendidikan tinggi saat ini telah mengubah model pembelajaran menjadi lebih otonom, namun sekaligus menghadirkan tantangan besar terhadap etika dan kualitas kognitif mahasiswa jika tidak dikelola dengan bijak [1], [2]. Dalam perspektif neurosains kognitif, penggunaan AI yang tidak terkontrol berisiko melemahkan kemampuan memori kerja karena otak tidak lagi dilatih untuk melakukan sintesis informasi yang rumit [1], [2]. Hal ini menciptakan ‘jalur resistensi terendah’ bagi otak, dimana kenyamanan emosional saat dibantu AI secara perlahan mengikis motivasi untuk melakukan evaluasi kritis terhadap informasi yang diterima [5], [6].

2.2. Dampak AI terhadap Berpikir Kritis Mahasiswa

Kemampuan berpikir kritis merupakan konsensus utama dalam penilaian edukasi yang didefinisikan oleh Facione [13] sebagai proses evaluasi mandiri yang reflektif. Meskipun teknologi AI menawarkan efisiensi, pemanfaatannya dalam penyusunan karya ilmiah menunjukkan pola ketergantungan yang signifikan pada hampir setiap

tahapan penulisan [4]. Penggunaan layanan berbasis AI secara instan tanpa proses filtrasi analitis berisiko menurunkan kemampuan berpikir mandiri dan kreativitas mahasiswa [2]. Selain itu, tantangan terkait orisinalitas dan degradasi nalar menjadi isu krusial yang menyertai adopsi teknologi pintar di era digital saat ini [3]. Degradasi nalar muncul saat mahasiswa mengadopsi luaran sistem AI secara mentah tanpa proses filtrasi. Kondisi ini menyebabkan hambatan analisis dan penurunan perspektif yang secara akumulatif bermuara pada penurunan daya kritis [3], [5]. Penambangan data melalui aturan asosiasi menjadi krusial untuk membuktikan bahwa fenomena ini bukan sekedar tren digital, melainkan pola perilaku yang terukur secara statistik [10].

2.3. Perbandingan Algoritma Apriori dan FP-Growth

Association Rule Mining digunakan untuk menemukan pola keterkaitan antar variabel perilaku mahasiswa dalam dataset besar. Efisiensi penemuan pola tersebut sangat bergantung pada algoritma yang digunakan dalam mengekstraksi *frequent itemset*:

1. Algoritma Apriori: Metode klasik ini bekerja dengan membangkitkan kandidat itemset secara iteratif. Meskipun akurat, Apriori memerlukan waktu eksekusi yang lebih lama dan penggunaan memori yang lebih besar karena harus memindai basis data secara berulang [14], [15].
2. Algoritma FP-Growth: Dirancang untuk menutupi kelemahan Apriori, algoritma ini menggunakan struktur FP-Tree. Penelitian sebelumnya membuktikan bahwa FP-Growth jauh lebih efisien dalam penggunaan memori dan kecepatan proses eksekusi dibandingkan Apriori karena tidak perlu membangkitkan kandidat secara eksplisit [16], [17].

3. METODE PENELITIAN

3.1. Populasi dan Sampel

Populasi dalam penelitian ini adalah mahasiswa aktif di Universitas Amikom Purwokerto. Teknik pengambilan sampel yang digunakan adalah *Simple Random Sampling*, dimana kuesioner disebarkan secara terbuka kepada mahasiswa dari berbagai program studi. Melalui teknik ini, diperoleh sampel sebanyak 110 responden, Batasan jumlah sampel ini ditentukan berdasarkan ketersediaan akses data primer selama periode penelitian, yang kemudian dikategorikan sebagai dataset skala menengah.

3.2. Instrumen Penelitian

Data penelitian dikumpulkan melalui kuesioner terstruktur yang terdiri dari 20 butir pernyataan. Instrumen ini dikembangkan berdasarkan indikator ketergantungan digital dan potensi degradasi kognitif [5]. Distribusi pernyataan dirancang untuk mengukur tiga variabel utama sebagaimana disajikan pada Tabel 1.

Tabel 1. Kisi-kisi Instrumen Penelitian

Variabel	Indikator Utama	Jumlah
Intensitas	Frekuensi dan durasi penggunaan harian.	6
Ketergantungan	Kepercayaan diri dan preferensi sumber AI.	6
Indikasi Brainrot	Penurunan daya kritis dan analisis mandiri	8

Instrumen penelitian pada Tabel 1 dirancang untuk mengukur tiga dimensi utama perilaku digital: aspek kuantitatif, aspek psikologis dan aspek kognitif. Bobot pernyataan lebih besar diberikan pada indikator brainrot untuk memperoleh kedalaman data sesuai tujuan utama penelitian.

Sebelum digunakan, instrumen telah melalui pengujian kualitas:

- Uji Validitas: Seluruh butir pernyataan dinyatakan valid berdasarkan korelasi *Pearson*, yang dibuktikan dengan adanya tanda signifikan pada level 0,01 atau 0,05.
- Uji Reliabilitas: Instrumen menunjukkan konsistensi yang sangat kuat dengan nilai *Cronbach's Alpha* sebesar 0,931, jauh melampaui standar minimal 0,60.

3.3. Implementasi Algoritma dan Parameter Evaluasi

Eksperimen dijalankan pada lingkungan Python menggunakan platform Google Colab. Tahapan implementasi dimulai dari pra-pemrosesan data hasil kuesioner skala Likert menjadi format transaksi biner melalui teknik *thresholding*, dimana skor lebih dari 4 dikonversi menjadi nilai 1 (True), dan skor kurang dari 4 menjadi nilai 0 (False). Proses ini krusial agar algoritma dapat mengidentifikasi keterkaitan antar variabel secara akurat. Selanjutnya, data diolah menggunakan algoritma Apriori dan FP-Growth untuk mengekstraksi *frequent itemset* dan aturan asosiasi. Untuk menghasilkan analisis yang sistematis, metode evaluasi dibagi menjadi beberapa bagian utama:

- Penentuan Parameter Algoritma
Penentuan nilai parameter dalam penelitian ini dilakukan melalui dua pendekatan:

- Minimum Support:** Ditentukan melalui pengujian beban (stress test) dengan rentang nilai 0,3 hingga 0,05. Pengujian pada nilai support rendah bertujuan untuk mengukur skalabilitas dan ketahanan algoritma terhadap lonjakan jumlah pola.
 - Minimum Confidence:** Ditetapkan secara konsisten sebesar 0,6 (60%) sebagai ambang batas untuk menjamin bahwa aturan asosiasi yang dihasilkan memiliki tingkat kepastian yang kuat secara statistik.
- Metrik Evaluasi Performa Komputasi**
Evaluasi dilakukan untuk membandingkan efisiensi kedua algoritma berdasarkan dua metrik:
 - Waktu Eksekusi:** Mengukur kecepatan komputasi dari tahap awal hingga terbentuknya aturan asosiasi pada setiap level minimum support.
 - Jumlah Itemset dan Aturan:** Memastikan konsistensi hasil antara kedua algoritma sebagai indikator akurasi logika pemrograman.
 - Prosedur Analisis Kualitas Aturan**
Setelah aturan asosiasi terbentuk, dilakukan prosedur interpretasi pola yang terbagi menjadi:
 - Analisis Pola Hubungan Umum:** Mengidentifikasi tren kebiasaan harian responden dalam penggunaan AI secara luas.
 - Analisis Dampak Kognitif:** Melakukan pemfilteran aturan secara khusus pada variabel akibat yang merujuk pada indikator P13-P20 untuk menemukan pemicu degradasi nalar.

4. HASIL DAN PEMBAHASAN

4.1. Definisi Operasional dan Kamus Indikator Data

Penelitian ini menggunakan 20 indikator (P1-P20) yang dirancang untuk mengukur interaksi mahasiswa dengan AI. Untuk memberikan batasan yang jelas, variabel-variabel tersebut dikategorikan ke dalam tiga utama sebagaimana disajikan pada Tabel 2.

Tabel 2. Kamus Indikator Variabel

Klaster Variabel	Kode	Definisi Operasional	Makna Variabel dalam Analisis
Aktivitas Dasar (Intensitas & Kebiasaan)	P1	Menggunakan AI hampir setiap hari.	Frekuensi Rutin
	P2	Penggunaan tinggi	Intensitas Tinggi
	P3	Langsung membuka AI saat mendapat tugas baru	Habit Instan
	P4	Menggunakan AI untuk hampir semua mata kuliah	Generalisasi Tugas
	P5	Lebih sering menggunakan AI dibanding buku/jurnal	Substitusi Referensi
	P6	Menggunakan AI untuk tugas yang bisa dikerjakan sendiri	Eksplotasi Fitur
Motivasi & Mental (Ketergantungan Psikologis)	P7	Kurang percaya diri mengerjakan tugas tanpa AI	Krisis Efikasi
	P8	Kesulitan menyelesaikan tugas jika AI tidak dapat diakses	Ketergantungan Akses
	P9	Merasa lebih tenang saat dibantu AI	Ketenangan Emosional
	P10	Meminta AI menjelaskan ulang dibanding membaca modul	Pasivitas Belajar
	P11	Lebih cepat menyerah jika tidak menggunakan AI	Degradasi Resiliensi
	P12	Mulai merasa sulit belajar tanpa bantuan AI	Hambatan Belajar Mandiri

Klaster Variabel	Kode	Definisi Operasional	Makna Variabel dalam Analisis
Dampak Kognitif	P13	Kesulitan menganalisis masalah tanpa bantuan AI	Hambatan Analisis
	P14	Jarang mengevaluasi kembali jawaban dari AI	Kurangnya Validasi
	P15	Kurang percaya diri dalam berpikir mandiri	Krisis Kepercayaan Diri
	P16	Jarang mengembangkan solusi alternatif sendiri	Keterbatasan Kreativitas
	P17	Jarang mempertimbangkan sudut pandang lain tanpa AI	Penurunan Perspektif
	P18	Merasa kemampuan refleksi diri menurun	Degradasi Refleksi
	P19	Lebih cepat menerima informasi tanpa analisis mendalam	Penerimaan Instan
	P20	Ketergantungan AI memengaruhi berpikir kritis.	Degradasi Berpikir Kritis

Tabel 2 ini berfungsi sebagai rujukan operasional untuk menginterpretasikan kode variabel (P1-P20) pada hasil ekstraksi algoritma. Pembagian ini mempermudah identifikasi hubungan sebab-akibat, dimana kluster Aktivitas dan Motivasi (P1-P12) dianalisis pengaruhnya terhadap kluster Dampak kognitif (P13-P20) sebagai indikator utama *brainrot*.

4.2. Pra-pemrosesan dan Transformasi Data

Data primer yang diperoleh dari 110 responden mahasiswa Universitas Amikom Purwokerto melalui tahap pra-pemrosesan. Skala Likert (1-5) dikonversi menjadi format biner (0 dan 1). Nilai 1 ditetapkan untuk skor lebih dari 3 guna merepresentasikan perilaku penggunaan AI yang intens, sementara skor kurang dari 4 dikategorikan sebagai 0. Proses diskritisasi ini krusial agar algoritma dapat mengidentifikasi keterkaitan antar variabel (P1 – P20) secara akurat.

4.3. Implementasi dan Analisis Performa Komputasi

Tahap pertama analisis dilakukan dengan membandingkan efisiensi waktu eksekusi kedua algoritma menggunakan parameter *minimum support* 0,2 dan *minimum confidence* 0,6. Parameter ini dipilih secara empiris untuk menyeimbangkan antara jumlah aturan yang dihasilkan dengan relevansi pola yang ditemukan.

Tabel 3. Statistik Performa Algoritma

Metrik Pengujian	Apriori	FP-Growth
Frequent Itemset	76	76
Association Rule	134	134
Waktu Proses (detik)	0,0072	0,0528

Berdasarkan Tabel 3, Apriori terbukti lebih efisien dengan waktu eksekusi 7,3 kali lebih cepat. Hal ini terjadi karena beberapa factor teknis:

- Overhead FP-Tree:** Pada skala 110 transaksi, biaya komputasi untuk membangun struktur pohon (*FP-Tree*) pada FP-Growth jauh lebih tinggi dibandingkan manfaat efisiensinya. Proses pemindaian data berulang untuk membangun *node* dan header table menciptakan beban (*overhead*) yang tidak ditemukan pada iterasi langsung Apriori.
- Kerapatan data:** Dataset ini memiliki tingkat kerapatan yang tinggi pada variabel tertentu. Pada kondisi ini, FP-Growth dipaksa membangun jalur kondisional yang sangat kompleks, sedangkan

Apriori hanya perlu melakukan pencarian kandidat secara horizontal yang lebih ringan pada memori.


4.4. Evaluasi Skalabilitas (Stress Test)

Untuk menguji batas kemampuan kedua algoritma, dilakukan penurunan *support* 0,05. Penurunan ini memicu ledakan jumlah pola yang harus diproses oleh CPU.

Tabel 4. Hasil Pengujian Beban

Support	Itemsets	Waktu Apriori	Waktu FP-Growth
0,3	16	0,0055	0,0115
0,2	76	0,0072	0,0528
0,15	179	0,0107	0,1356
0,10	924	0,0539	0,3989
0,05	8128	0,2021	10,8814

Pada Tabel 4 hasil *stress test*, ditemukan bahwa Apriori secara konsisten lebih efisien dibandingkan FP-Growth pada dataset ini. Menariknya, keunggulan efisiensi Apriori meningkat secara signifikan seiring dengan penurunan nilai *minimum support*. Pada ambang batas 0,2, Apriori bekerja 7,3 kali lebih cepat, namun pada beban komputasi tinggi (Support 0,05), Apriori mampu bekerja hingga 53,8 kali lebih cepat dibandingkan FP-Growth.



Gambar 1. Grafik perbandingan skalabilitas waktu Apriori vs FP-Growth

Visualisasi pada Gambar 1 menunjukkan lonjakan waktu eksponensial pada FP-Growth saat jumlah pola mencapai 8.128 itemset, sementara Apriori tetap Stabil. Hal ini membuktikan bahwa pada dataset 110 responden ini, *overhead* Pembangunan struktur *FP-Tree* jauh lebih tinggi dibandingkan efisiensi iterasi langsung yang dilakukan oleh Apriori.

4.5. Analisis Pola Hubungan Umum


Analisis ini memetakan perilaku penggunaan AI yang paling sering terjadi secara bersamaan dikalangan responden. Data diambil dari 5 aturan dengan nilai *Lift Ratio* tertinggi tanpa batasan variabel akibat (*consequent*).

Tabel 5. Top 5 Pola Asosiasi Perilaku Umum

No	Antecedents	Consequents	Lift Ratio
1	[P9, P2]	[P1, P3]	2,07
2	[P4, P3]	[P1, P9]	2,05
3	[P3, P2]	[P1, P9]	2,05
4	[P4, P9]	[P1, P3]	2,00
5	[P1, P3]	[P4, P2]	1,99

Berdasarkan hasil ekstraksi aturan asosiasi pada Tabel 5, ditemukan lima pola hubungan dengan nilai *Lift Ratio* tertinggi yang menggambarkan perilaku rutin mahasiswa. Pola pertama menunjukkan bahwa mahasiswa dengan Ketenangan Emosional (P9) dan Intensitas Tinggi (P2) memiliki kecenderungan 2,07 kali lebih kuat untuk melakukan Frekuensi Rutin (P1) dan Habit Instan (P3) dalam mengerjakan tugas. Hal ini mengindikasikan bahwa kenyamanan psikologis menjadi pendorong utama terbentuknya kebiasaan penggunaan AI secara spontan setiap kali ada tugas baru.

Keterkaitan ini dipertegas pada pola lainnya, di mana penggunaan AI untuk Hampir Semua Mata Kuliah (P4) berhubungan erat dengan Habit Instan (P3) dan Ketenangan Emosional (P9). Secara keseluruhan, kelima pola ini membuktikan bahwa penggunaan AI di kalangan mahasiswa telah menjadi ekosistem kebiasaan yang mapan. Nilai *Lift Ratio* yang konsisten di atas 1,90 menunjukkan bahwa hubungan antara rasa nyaman emosional dan ketergantungan fungsional harian merupakan pola perilaku nyata yang saling mengunci satu sama lain



Gambar 2. Heatmap matriks kekuatan hubungan antar variabel

Heatmap pada Gambar 2 memberikan representasi visual terhadap kekuatan hubungan (*Lift Ratio*) antar variabel penggunaan AI. Gradasi warna merah yang semakin pekat menunjukkan tingkat ketergantungan yang semakin kuat antar indikator.

Titik interaksi tertinggi terlihat pada kombinasi Ketenangan Emosional (P9) dan Intensitas Tinggi (P2) yang memicu terbentuknya Habit Instan (P3) dan Frekuensi Rutin (P1) dengan nilai *Lift* 2,07. Hal ini secara visual mengonfirmasi bahwa kenyamanan psikologis merupakan faktor kunci yang mengunci mahasiswa dalam siklus penggunaan AI harian

4.6. Analisis Pola Pemicu Penurunan Kognitif (*Brainrot Impact*)


Berbeda dengan analisis umum, bagian ini memfokuskan observasi pada aturan yang berakibat langsung pada variabel P13-P20. Analisis ini bertujuan menemukan faktor pemicu utama terjadinya degradasi nalar atau *brainrot*.

Tabel 6. Pola Penyebab Gejala Brainrot

No	Antecedents	Consequents	Lift Ratio
1	[P9, P4]	[P20]	1,57
2	[P1, P9]	[P20]	1,50
3	[P1, P5]	[P20]	1,43
4	[P9]	[P20]	1,43
5	[P5]	[P20]	1,39

Berdasarkan hasil ekstraksi data Tabel 6, ditemukan lima pola hubungan teratas yang menunjukkan bagaimana penggunaan AI yang secara signifikan berujung pada Degradasi Berpikir Kritis (P20). Pemilihan lima pola ini didasarkan pada nilai *Lift Ratio* tertinggi, yang merepresentasikan hubungan paling kuat antara perilaku mahasiswa dengan penurunan daya kritis.

Pola pertama dengan nilai *Lift* 1,57 menunjukkan bahwa kombinasi antara Generalisasi Tugas (P4) dan Ketenangan Emosional (P9) merupakan pemicu utama terjadinya penurunan kemampuan analisis. Hal ini mengonfirmasi bahwa penggunaan AI di hampir semua mata kuliah yang didorong oleh rasa nyaman secara psikologis memiliki dampak paling nyata terhadap kualitas kognitif mahasiswa.



Gambar 3. Network graph jalur pemicu dampak penurunan kognitif

Selain itu, Substitusi Referensi (P5) atau kebiasaan mengganti buku/jurnal dengan AI juga

muncul sebagai faktor pemicu yang konsisten. Secara keseluruhan, kelima pola ini membuktikan bahwa perilaku penggunaan AI yang tidak terkendali dikalangan mahasiswa berkontribusi langsung pada degradasi kemampuan berpikir kritis secara mandiri.

Berdasarkan visualisasi pada Gambar 3, terlihat bahwa pola penggunaan AI mahasiswa secara konsisten bermuara pada satu dampak utama, yaitu P20 (Penurunan Berpikir Kritis). Hal ini ditunjukkan oleh arah panah dari variabel kebiasaan dominan yang seluruhnya terhubung ke titik P20 sebagai akibat (*consequent*).

Visualisasi ini membuktikan bahwa di antara berbagai potensi dampak kognitif yang diteliti, penurunan daya kritis merupakan dampak yang paling kuat dan signifikan kemunculannya secara statistik. Jalur utama yang terbentuk dari kombinasi ketergantungan psikologis dan penggunaan AI secara masif menunjukkan adanya hubungan erat yang mempercepat terjadinya fenomena penurunan kognitif di kalangan mahasiswa

4.7. Limitasi Penelitian

Batasan utama penelitian ini terletak pada ketergantungan hasil terhadap karakteristik dataset primer. Penggunaan 20 variabel biner (P1-P20) menyebabkan hasil asosiasi bersifat homogen dan berpusat pada variabel dominan (P20). Selain itu, karena volume data terbatas pada 110 responden, temuan mengenai efisiensi algoritma bersifat spesifik pada skala ini dan mungkin menunjukkan perilaku berbeda jika diimplementasikan pada *Big Data* dengan jutaan transaksi.

5. KESIMPULAN DAN SARAN

Penelitian ini menyimpulkan bahwa algoritma Apriori memiliki efisiensi komputasi yang lebih unggul dibandingkan FP-Growth pada dataset 110 responden, dengan keunggulan kecepatan hingga 53,8 kali lipat pada pengujian beban tinggi (support 0,05). Analisis pola asosiasi berhasil mengidentifikasi lima indikator kunci pemicu *brainrot*, di mana Ketenangan Emosional (P9) dan Generalisasi Tugas (P4) menjadi pemicu utama yang bermuara pada Degradasi Berpikir Kritis (P20) dengan nilai *Lift Ratio* 1,57. Temuan ini diperkuat oleh pola Frekuensi Rutin (P1) dan tren Substitusi Referensi (P5), yang membuktikan bahwa kecenderungan mahasiswa mengganti penggunaan buku atau jurnal dengan AI secara masif berkontribusi langsung terhadap penurunan ketajaman analisis mandiri. Secara visual, seluruh jalur asosiasi terbaik secara konsisten menunjuk pada P20 sebagai dampak kognitif paling dominan. Sebagai saran, mahasiswa diharapkan membatasi substitusi referensi total dengan tetap melakukan validasi manual, sementara institusi pendidikan perlu mengintegrasikan literasi AI dalam kurikulum untuk menjaga integritas intelektual, dan peneliti selanjutnya dapat memperluas cakupan dataset untuk menguji ambang batas skalabilitas algoritma pada populasi yang lebih besar.

DAFTAR PUSTAKA

- [1] S. Rifky, "The Impact of Using Artificial Intelligence on Higher Education," *Indones. J. Multidiscip. Soc. Technol.*, vol. 2, no. 1, pp. 37–42, 2024, doi: 10.31004/ijmst.v2i1.287.
- [2] Noperliani Gea, Arozatulo Bawamenewi, Mentari Telaumbanua, Lasmi Zalukhu, and Isihati Nehe, "Dampak Artificial Intelligence (Ai) Dalam Pendidikan: Peluang Dan Tantangan Di Era Digital," *J. Educ. Dev.*, vol. 13, no. 1, pp. 637–644, 2025.
- [3] M. Fauziddin and M. Agustin, "Symantic Literature Review: Manfaat Artificial Intelligence (AI) pada Pendidikan Anak Usia Dini di Indonesia," *J. Obs. J. Pendidik. Anak Usia Dini*, vol. 8, no. 6, pp. 1475–1488, 2024, doi: 10.31004/obsesi.v8i6.6236.
- [4] E. N. Taib, "Pola dan Tahapan Pemanfaatan Artificial Intelligence (AI) dalam Penyusunan Karya Ilmiah Mahasiswa," *Pros. Semin. Nas. Bitik 2023*, vol. 12, no. 1, pp. 91–101, 2024.
- [5] F. R. Fiani, J. A. Alim, and Z. Ulya, "Dampak Penggunaan Artificial Intelligence (AI) terhadap Kemampuan Berpikir Kritis Mahasiswa," *J. Teknol. Pendidik. dan Pembelajaran*, vol. 03, no. 2, pp. 260–267, 2025.
- [6] R. R. Al-Hakim, R. Ardianto, R. Suryani, and H. Jayusman, "Journal of Law, Economics, and Engineering ISSN XXX XXX Fenomena Brain Rot di Kalangan Anak Muda: Refleksi Penggunaan Teknologi dan Revitalisasi Peran Kepemudaan The Brain Rot Phenomenon Among Young People: Reflections on Technology Use and the Revitaliza," vol. 1, no. 1, pp. 30–34, 2025.
- [7] Y. Bachtiar, M. Ardiansyah, and A. L. Nulhakim, "ChatGPT sebagai Alat Pendidikan : " Analisis Pola Jurnal Insan Peduli Pendidikan (JIPENDIK)," vol. 7231, pp. 74–78, 2024.
- [8] M. Qamal, H. A. K. Aidilof, and Juanda, "Analisis perbandingan algoritma fp–growth dan apriori untuk menentukan pola kecelakaan lalu lintas di Wilayah Polres Lhokseumawe," *JTINFO J. Tek. Inform.*, vol. 4, no. 1, pp. 175–185, 2025.
- [9] Irgi Sena Fajar Lukerti, M. F. Asnawi, and Nulngafan, "Perbandingan Akurasi Algoritma Apriori Dan Fp-Growth Untuk Mengetahui Pola Penyebab Gangguan Indihome Area Wonosobo," *STORAGE J. Ilm. Tek. dan Ilmu Komput.*, vol. 3, no. 4, pp. 213–219, 2024, doi: 10.55123/storage.v3i4.4444.
- [10] K. I. Lestari, S. Putra, and E. Rilvani, "Permasalahan Efisiensi Algoritma Apriori dan Evaluasi Fp-Growth Berdasarkan Studi Literatur," *J. Media Akad.*, vol. 3, no. 7, pp. 1–15, 2025.
- [11] F. D. Davis, "Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology," *MIS Q.*, vol. 13, no. 3, pp. 319–

- 340, Sep. 1989, doi: 10.2307/249008.
- [12] M. Griffiths, "A 'components' model of addiction within a biopsychosocial framework," *J. Subst. Use*, vol. 10, no. 4, pp. 191–197, Jan. 2005, doi: 10.1080/14659890500114359.
- [13] P. A. Facione, "Critical Thinking : A Statement of Expert Consensus for Purposes of Educational Assessment and Instruction Executive Summary " The Delphi Report," *Calif. Acad. Press*, vol. 423, no. c, pp. 1–19, 1990, [Online]. Available: [http://www.insightassessment.com/pdf_files/DE Xadobe.PDF](http://www.insightassessment.com/pdf_files/DE%20Adobe.PDF)
- [14] N. Purwati, Y. Pedliyansah, H. Kurniawan, S. Karnila, and R. Herwanto, "Komparasi Metode Apriori dan FP-Growth Data Mining Untuk Mengetahui Pola Penjualan," *J. Inform. J. Pengemb. IT*, vol. 8, no. 2, pp. 155–161, 2023, doi: 10.30591/jpit.v8i2.4876.
- [15] D. Dwiputra, A. Mulyo Widodo, H. Akbar, and G. Firmansyah, "Evaluating the Performance of Association Rules in Apriori and FP-Growth Algorithms: Market Basket Analysis to Discover Rules of Item Combinations," *J. World Sci.*, vol. 2, no. 8, pp. 1229–1248, 2023, doi: 10.58344/jws.v2i8.403.
- [16] A. Harahap, A. L. R. Perangin-Angin, K. Kumar, and S. P. Parsaoran, "Analisis Penerapan Data Mining Dalam Penentuan Tata Letak Barang Menggunakan Algoritma Apriori Dan Fp-Growth," *J. Tek. Inf. dan Komput.*, vol. 5, no. 2, p. 291, 2022, doi: 10.37600/tekinkom.v5i2.692.
- [17] H. Hery and A. E. Widjaja, "Analysis of Apriori and FP-Growth Algorithms for Market Basket Insights: A Case Study of The Bread Basket Bakery Sales," *J. Digit. Mark. Digit. Curr.*, vol. 1, no. 1, pp. 63–83, 2024, doi: 10.47738/jdmdc.v1i1.2.