

Analisis Asosiasi Antara Produktivitas Pelajar dan Manajemen Waktu Berdasarkan Algoritma FP-Growth

Muhammad Randy Rabbani¹, Oktavio Theonady², Haniyah Faizah³, Eka Bayu Satria⁴,
Alsella Meiriza⁵, Ken Ditha Tania⁶

Universitas Sriwijaya^{1,2,3,4,5,6}

randyrabbani18@gmail.com¹, oktaviotheonady21@gmail.com², haniyahfzh8@gmail.com³,
ekabayusatria@gmail.com⁴, allsella_meiriza@yahoo.co.id⁵, kenya.tania@gmail.com⁶

Diterima (02-03-2026)	Direvisi (09-04-2026)	Disetujui (20-04-2026)
--------------------------	--------------------------	---------------------------

Abstrak - Penelitian ini bertujuan menganalisis hubungan antara manajemen waktu dan produktivitas pelajar menggunakan algoritma FP-Growth. Data yang digunakan berasal dari *dataset Ultimate Student Productivity* yang terdiri dari 5.000 data dan 21 atribut. Analisis dilakukan melalui tahapan *Knowledge Discovery in Databases (KDD)* yang meliputi seleksi data, pra-pemrosesan, transformasi, serta pembentukan *association rule* berdasarkan nilai *support*, *confidence*, dan *lift ratio*. Hasil penelitian menunjukkan bahwa kategori sedang (*medium*) mendominasi sebagian besar variabel yang dianalisis. Aturan asosiasi memiliki nilai *confidence* tinggi dan *lift ratio* lebih dari satu, yang menunjukkan hubungan signifikan antar variabel. Produktivitas kategori sedang berkaitan dengan durasi belajar dan tingkat fokus yang seimbang, sedangkan kategori rendah berkorelasi dengan hasil akademik yang rendah. Temuan ini menunjukkan bahwa keseimbangan dalam pengelolaan waktu belajar berperan penting dalam membentuk pola produktivitas pelajar. Selain itu, pendekatan berbasis data mampu memberikan gambaran objektif mengenai perilaku belajar siswa. Temuan ini dapat dimanfaatkan untuk mengoptimalkan manajemen waktu belajar guna meningkatkan produktivitas dan capaian akademik pelajar, serta sebagai acuan bagi institusi pendidikan dalam menyusun strategi pembelajaran berbasis data.

Kata Kunci : FP-Growth, Association Rule, Produktivitas Pelajar, Manajemen Waktu, Data Mining

Abstract - This study aims to analyze the relationship between time management and student productivity using the FP-Growth algorithm. The data used in this research were obtained from the *Ultimate Student Productivity dataset*, which consists of 5,000 records and 21 attributes. The analysis was conducted through the *Knowledge Discovery in Databases (KDD)* stages, including data selection, preprocessing, transformation, and the formation of association rules based on support, confidence, and lift ratio values. The results show that the medium category dominates most of the analyzed variables. The association rules have high confidence values and lift ratios greater than one, indicating significant relationships among variables. Medium-level productivity is associated with balanced study duration and focus levels, while low productivity is correlated with low academic performance. These findings indicate that balance in study time management plays an important role in shaping student productivity patterns. In addition, a data-driven approach provides an objective overview of students' learning behavior. These findings can be utilized to optimize study time management in order to improve student productivity and academic achievement, as well as serve as a reference for educational institutions in developing data-driven learning strategies.

Keywords: FP-Growth, Association Rule, Time Management, Student Productivity, Data Mining

I. PENDAHULUAN

Big data adalah sebuah kumpulan data yang sangat besar, beragam jenisnya, dan dihasilkan dengan cepat. Untuk menghasilkan informasi yang relevan, diperlukan teknik manajemen dan analisis tertentu (Safitri & Absharina, 2025). Kemajuan teknologi informasi telah meningkatkan jumlah data yang disimpan di

bidang pendidikan, termasuk data akademik, kebiasaan belajar, manajemen waktu, kehadiran, dan aktivitas siswa lainnya. Tidak mungkin untuk menganalisis data yang sangat besar dan kompleks ini dengan teknik tradisional. Data perilaku siswa seringkali tidak dimanfaatkan secara optimal saat menganalisis korelasinya dengan prestasi akademik (Wang et

al., 2022). Untuk mengungkap pola tersembunyi dalam data pendidikan, metode berbasis penambangan data (*data mining*) diperlukan. Hubungan antara manajemen waktu dan produktivitas siswa merupakan faktor krusial yang harus dianalisis, karena keduanya berperan penting dalam menentukan seberapa baik proses pembelajaran berlangsung.

Penelitian tentang manajemen waktu telah dilakukan secara luas. Namun, sebagian besar penelitian masih mengandalkan tinjauan literatur atau metodologi deskriptif. Saksana (2024) menemukan bahwa prestasi belajar mahasiswa dipengaruhi oleh beberapa faktor yang ada seperti motivasi belajar, keterampilan kognitif, dan manajemen waktu, tetapi penelitian tersebut tidak menggunakan teknik penambangan data untuk memvalidasi pola hubungan langsung. Demikian pula, Rofi et al. (2025) menganalisis manajemen waktu siswa dengan sudut pandang kualitatif, tanpa analisis pola berbasis data. Mengingat kondisi ini, jelas bahwa sedikit penelitian yang mengeksplorasi hubungan antara produktivitas siswa dan manajemen waktu dengan menggunakan *dataset* berskala besar dan teknik penambangan aturan asosiasi. Pada kenyataannya, hubungan antara variabel perilaku belajar cenderung kompleks dan memerlukan pendekatan komputasional untuk pengenalan pola.

Banyak inisiatif penelitian telah memanfaatkan penambangan aturan asosiasi di sektor pendidikan. Menurut Wang et al. (2022), algoritma Apriori digunakan untuk mengidentifikasi korelasi antara tindakan siswa dan hasil akademik mereka berdasarkan metrik dukungan dan kepercayaan. Selain itu, Sriurai & Nuanmeesri (2024) menggunakan algoritma FP-Growth untuk mengevaluasi hasil belajar siswa, menciptakan aturan yang menunjukkan tingkat kepercayaan yang tinggi. Selain aplikasinya di bidang pendidikan, algoritma FP-Growth sering digunakan dalam berbagai disiplin ilmu lain karena dianggap lebih efisien. Pujiharto et al. (2023) mencatat bahwa metode FP-Growth lebih cepat dan menggunakan memori secara lebih efisien dibandingkan Apriori. Hery & Widjaja (2024) juga menemukan bahwa FP-Growth terbukti lebih mampu menangani *dataset* yang besar. Temuan ini sejalan dengan penelitian Saputra et al. (2023) yang menunjukkan bahwa FP-Growth efisien dalam menghasilkan aturan asosiasi dengan nilai *support* dan *confidence* yang tinggi pada analisis pola transaksi berskala besar. Namun, studi yang ada belum secara khusus membahas hubungan antara manajemen waktu dan

produktivitas siswa melalui analisis yang terintegrasi.

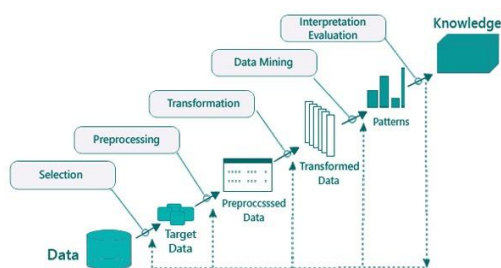
Berdasarkan tinjauan literatur yang telah dilakukan, beberapa celah dalam penelitian telah diidentifikasi. Pertama, studi tentang aturan asosiasi dalam pendidikan sebagian besar menekankan pada nilai akademik daripada fokus pada bagaimana kebiasaan belajar memengaruhi produktivitas siswa. Kedua, penelitian tentang manajemen waktu sebagian besar mengandalkan metode kualitatif, tanpa pendekatan penambangan data untuk analisis pola. Ketiga, meskipun efisiensi FP-Growth telah terbukti, penerapan metode ini dalam menganalisis kecenderungan belajar siswa pada *dataset* besar masih belum memadai. Situasi ini menyoroti kebutuhan akan penelitian yang mengintegrasikan faktor manajemen waktu dan produktivitas siswa ke dalam model analisis terpadu berbasis FP-Growth.

Untuk mengatasi tantangan ini, penelitian saat ini menyarankan penggunaan algoritma FP-Growth untuk mengeksplorasi hubungan antara produktivitas siswa dan manajemen waktu dengan memanfaatkan *dataset* komprehensif siswa. Prosedur analitis dilakukan melalui fase-fase *Knowledge Discovery in Databases* (KDD) yang tahapannya meliputi pemilihan data, pra-pemrosesan, transformasi data, pembuatan pola item set yang sering, dan penetapan aturan asosiasi. Aturan yang dihasilkan akan dievaluasi menggunakan metrik dukungan, kepercayaan, dan rasio *lift* untuk memastikan bahwa hubungan antara variabel-variabel tersebut diukur dengan akurat. Pemilihan FP-Growth didasarkan pada keunggulannya dalam hal efisiensi waktu pemrosesan dan kemampuannya untuk menangani volume data yang besar.

Penelitian ini berfokus pada analisis korelasi antara cara manajemen waktu dan produktivitas mahasiswa melalui metode empiris yang memanfaatkan algoritma FP-Growth. Diharapkan temuan ini dapat menyajikan perspektif yang lebih baik tentang interaksi antara praktik pengelolaan waktu dan tingkat produktivitas mahasiswa. Selain itu, penelitian ini dapat berfungsi sebagai panduan bagi lembaga pendidikan dalam mengembangkan pendekatan berbasis data yang bertujuan untuk meningkatkan produktivitas siswa. Dengan menerapkan metode analisis yang terstruktur dan berfokus pada pola, penelitian ini berupaya memberikan kontribusi ilmiah yang signifikan bagi perkembangan penambangan data di sektor pendidikan.

II. METODOLOGI PENELITIAN

Dalam menganalisis dataset, proses penelitian ini menerapkan kerangka kerja *Knowledge Discovery in Databases* (KDD) yang dilakukan secara bertahap. Prosedur ini dipilih untuk mentransformasi data mentah mengenai kebiasaan belajar menjadi pola asosiasi yang memiliki nilai informasi. Tahapan KDD dalam penelitian ini meliputi pengumpulan data, seleksi, pembersihan (*preprocessing*), transformasi, implementasi *data mining*, serta evaluasi hasil (Wijaya et al., 2023) yang dapat dilihat pada Gambar 1.



Sumber: Penelitian (2026)

Gambar 1. Alur Kerja *Knowledge Discovery in Databases* (KDD)

Data yang diolah dalam penelitian ini bersumber pada repositori Kaggle melalui *dataset ultimate student productivity*. *Dataset* ini merepresentasikan variabel-variabel perilaku akademik yang relevan dengan produktivitas pelajar. Setelah perolehan data, dilakukan serangkaian prosedur persiapan data yang meliputi *data selection*, *data cleaning*, dan *data transformation* untuk menjamin kualitas luaran algoritma.

1. Data Selection

Seleksi data merupakan proses pemilihan sebagian data yang dilakukan sebelum tahap pencarian informasi pada proses *Knowledge Discovery in Database* (KDD) dimulai (Andini & Martanto, 2024). Proses pemilihan data dilakukan dengan mengidentifikasi atribut-atribut yang secara signifikan memengaruhi performa dan manajemen waktu pelajar. Dari *dataset* yang diperoleh, peneliti menetapkan variabel utama yang akan dianalisis. Pemilihan atribut ini bertujuan untuk memfokuskan analisis pada korelasi antara alokasi waktu dan hasil produktivitas yang dicapai.

2. Data Pre-Processing

Tahap *preprocessing* data merupakan langkah awal dalam proses penambahan data,

di mana dilakukan pembersihan data dengan menghapus data yang ganda, memeriksa adanya kesalahan, serta melakukan perbaikan terhadap kesalahan, misalnya kesalahan penulisan (Astri & Martanto, 2024). Pada *dataset* dari Kaggle ini, peneliti melakukan pemeriksaan terhadap nilai-nilai yang hilang (*missing values*) serta data yang tidak konsisten. Selain itu, dilakukan pembersihan terhadap fitur yang tidak relevan dengan tujuan penelitian, seperti data identitas yang tidak berkontribusi pada pembentukan aturan asosiasi. Langkah ini dilakukan agar *dataset* siap masuk ke tahap pemodelan tanpa adanya bias data.

3. Data Transformation

Pada tahap transformasi ini dilakukan penyesuaian atau inialisasi data agar sesuai dengan kebutuhan metode yang digunakan (Nurarofah et al., 2023). Pada penelitian ini dilakukan transformasi melalui proses *discretize*, perubahan penamaan kategori menjadi *Low*, *medium*, dan *high*, serta konversi data menggunakan *nominal to numerical* dan *numerical to binomial* untuk mempersiapkan data agar dapat diimplementasikan pada algoritma FP-Growth

4. Data Mining

Data mining merupakan sebuah proses penyelesaian masalah dengan menerapkan model matematika untuk secara otomatis menemukan pola dari data yang telah tersedia, yang juga dikenal sebagai *Knowledge Discovery in Databases* (KDD), yaitu rangkaian proses mengubah kumpulan data mentah menjadi informasi atau pengetahuan yang bermanfaat (Achmad et al., 2023). Peneliti menggunakan algoritma FP-Growth untuk mengidentifikasi pola frekuensi kemunculan *itemset* melalui struktur FP-Tree. Algoritma ini memproses korelasi antara kebiasaan manajemen waktu dengan produktivitas pelajar untuk menemukan *frequent patterns* secara efisien tanpa melakukan pemindaian basis data berulang kali. Dalam proses pencarian pola, digunakan parameter *support* untuk mengukur intensitas suatu *item* atau kombinasi *item* dalam keseluruhan *dataset*. Nilai *support* dihitung menggunakan persamaan (1) sebagai berikut (Wijaya et al., 2023) :

$$Support = \frac{Total\ Transaksi\ X\ dan\ Y}{Total\ Transaksi} \quad (1)$$

Setelah *frequent itemset* diperoleh, tahap selanjutnya adalah pembentukan *Association*

Rule dengan menghitung nilai *confidence*, yaitu tingkat kepercayaan bahwa suatu item B akan muncul apabila *item* A terjadi. Nilai *confidence* dihitung menggunakan persamaan (2) berikut (Wijaya et al., 2023) :

$$Confidence = \frac{Total\ Transaksi\ X\ dan\ Y}{Total\ Transaksi\ X} \times 100 \quad (2)$$

Nilai *support* dan *confidence* digunakan sebagai dasar untuk menentukan kekuatan hubungan antar variabel yang dianalisis. Semakin tinggi nilai *support* dan *confidence*, maka akan semakin kuat pola asosiasi yang terbentuk. *Association Rule* diperlukan untuk menjamin *minimum support* dan *minimum Confidence* secara bersamaan (Ch et al., 2022). Dengan menggunakan pendekatan ini, algoritma FP-Growth mampu mengidentifikasi hubungan antara manajemen waktu dan produktivitas pelajar secara lebih efektif dan akurat

5. Evaluation

Pada *tahap* ini, fokus diberikan pada proses pemodelan yang berkualitas. Tahap ini juga bertujuan untuk mengevaluasi sejauh mana model yang digunakan bekerja secara efektif dan apakah hasilnya sesuai dengan prinsip atau standar yang berlaku untuk algoritma FP-Growth (Rohman & Wibowo, 2024). Evaluasi dilakukan terhadap aturan asosiasi yang ditemukan dengan menggunakan metrik *lift ratio*. Pengujian ini bertujuan untuk mengukur signifikansi hubungan antar variabel, misalnya apakah tingginya intensitas latihan soal berkorelasi kuat dengan durasi belajar yang efektif. Kevalidan aturan ditentukan melalui ambang batas *support* (dukungan data) dan *confidence* (kepastian hubungan). Rumus untuk menghitung nilai *lift ratio* dengan persamaan (3) yang dipaparkan sebagai berikut (Wijaya et al., 2023) :

$$Lift\ Ratio = \frac{support(X \cup Y)}{Support(X) \times Support(Y)} \quad (3)$$

III. HASIL DAN PEMBAHASAN

1. Data

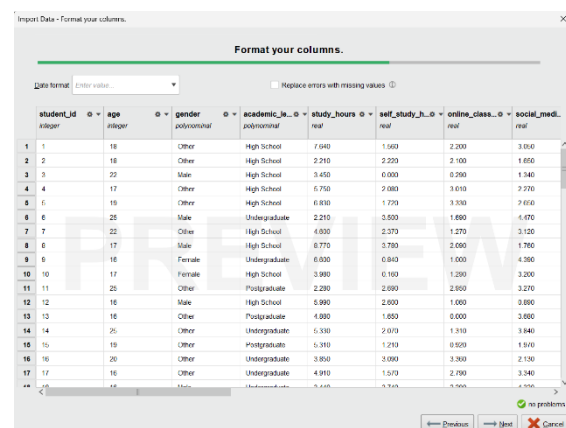
Data yang telah diperoleh berbentuk format CSV (Excel), data ini didapat dari *platform* populer yaitu Kaggle, data berjumlah 5000 baris dengan 21 atribut yang dapat dilihat pada Gambar 2 dibawah ini.

No	Attribute
1	student_id
2	age
3	gender
4	academic_level
5	study_hours
6	self_study_hours
7	online_classes_hours
8	social_media_hours
9	gaming_hours
10	sleep_hours
11	screen_time_hours
12	exercise_minutes
13	caffeine_intake_mg
14	part_time_job
15	upcoming_deadline
16	internet_quality
17	mental_health_score
18	focus_index
19	burnout_level
20	productivity_score
21	exam_score

Sumber: Penelitian (2026)

Gambar 2. Atribut Data

Dataset ini diolah menggunakan *RapidMiner*, sebuah perangkat lunak yang dapat membantu peneliti untuk mengolah data. Untuk mengolah dataset yang diperoleh, perlu dilakukan *import* seperti di Gambar 3 berikut.



Sumber: Penelitian (2026)

Gambar 3. Import Data

2. Data Selection


Setelah data di *import*, dilakukan penyeleksian data yang bertujuan agar data yang diolah sesuai dengan yang dibutuhkan untuk analisis, proses yang dilakukan ialah memilih atribut menggunakan *operator Select Attribute*, hasil pemilihan tersebut dapat dilihat pada Gambar 4 berikut.

Sumber: Penelitian (2026)

Gambar 4. Hasil *Select Attribute*

3. Data Pre-Processing

Setelah seleksi data, dilakukan proses *cleaning* atau pembersihan data. Tujuannya untuk membersihkan nilai yang kosong serta duplikasi pada data. Proses yang dilakukan menggunakan *operator Replace Missing Value* dan *Remove Duplicates* yang dapat dilihat pada Gambar 5 berikut.



Sumber: Penelitian (2026)

Gambar 5. Operator *Cleaning Data*

4. Data Transformation

Pada tahapan ini dilakukan proses transformasi data sebelum penerapan algoritma FP-Growth dan *Association Rule*. Transformasi diperlukan karena algoritma asosiasi bekerja lebih optimal pada data berbentuk kategorikal atau biner, sehingga data numerik yang diperoleh dari dataset awal harus diubah ke dalam bentuk yang sesuai.

Proses *discretize* dilakukan untuk mengubah atribut yang memiliki nilai kontinu menjadi beberapa kelompok interval. Pada tahap ini setiap variabel dibagi ke dalam tiga rentang nilai yaitu *range 1*, *range 2*, dan *range 3* berdasarkan distribusi data masing-masing atribut. Pembagian ini bertujuan untuk menyederhanakan variasi nilai sehingga lebih mudah dianalisis pada tahap selanjutnya. Setiap atribut, seperti *study_hours*, *self_study_hours*, *online_classes_hours*, hingga *exam_score*, dibagi berdasarkan rentang nilai tertentu yang merepresentasikan tingkat intensitas atau kondisi masing-masing variabel seperti di

Gambar 6. Tujuan dari proses ini adalah untuk mempermudah identifikasi pola hubungan antar variabel pada tahap analisis asosiasi.

No	Atribut	Kategori
1	study_hours	range1 [-∞ - 3.947], range2 [3.947 - 7.893], range3 [7.893 - ∞]
2	self_study_hours	range1 [-∞ - 2.470], range2 [2.470 - 4.940], range3 [4.940 - ∞]
3	online_classes_hours	range1 [-∞ - 2], range2 [2 - 4], range3 [4 - ∞]
4	social_media_hours	range1 [-∞ - 2.760], range2 [2.760 - 5.520], range3 [5.520 - ∞]
5	gaming_hours	range1 [-∞ - 1.880], range2 [1.880 - 3.760], range3 [3.760 - ∞]
6	sleep_hours	range1 [-∞ - 6], range2 [6 - 8], range3 [8 - ∞]
7	screen_time_hours	range1 [-∞ - 5.767], range2 [5.767 - 10.533], range3 [10.533 - ∞]
8	exercise_minutes	range1 [-∞ - 49.667], range2 [49.667 - 99.333], range3 [99.333 - ∞]
9	focus_index	range1 [-∞ - 21.827], range2 [21.827 - 42.653], range3 [42.653 - ∞]
10	productivity_score	range1 [-∞ - 33.340], range2 [33.340 - 65.680], range3 [65.680 - ∞]
11	exam_score	range1 [-∞ - 22.030], range2 [22.030 - 43.060], range3 [43.060 - ∞]

Sumber: Penelitian (2026)

Gambar 6. Rentang Kategori Atribut

Setelah proses *discretize*, dilakukan perubahan penamaan menggunakan operator *Map* yaitu mengubah penamaan *range 1*, *range 2*, dan *range 3* menjadi kategori yang lebih mudah dipahami, yaitu *Low*, *medium*, dan *high*, yang dapat dilihat pada Gambar 7 Perubahan ini bertujuan untuk meningkatkan keterbacaan data serta mempermudah interpretasi hasil analisis pada tahap pembentukan aturan asosiasi.

Row No.	study_hours = Low	study_hours = Medium	study_hours = High
---------	-------------------	----------------------	--------------------

Sumber: Penelitian (2026)

Gambar 7. Hasil Perubahan Penamaan

Adapun transformasi nilai dari bentuk nominal menjadi Numerik yaitu 1 dan 0. Transformasi ini diperlukan agar data dapat diproses oleh sistem secara komputasional tanpa menghilangkan informasi kategorikal yang telah terbentuk sebelumnya. Seperti pada Gambar 8 berikut.

Row No.	study_hours = Low	study_hours = Medium	study_hours = High
1	0	1	0
2	1	0	0
3	1	0	0
4	0	1	0
5	0	1	0
6	1	0	0
7	0	1	0
8	0	0	1
9	0	1	0
10	0	1	0

Sumber: Penelitian (2026)

Gambar 8. Transformasi *Nominal To Numerical*

Pada tahap akhir, data dipastikan berada dalam format binomial yang merepresentasikan keberadaan atau ketidakhadiran suatu item

dalam setiap transaksi. Format ini merupakan bentuk input yang sesuai untuk algoritma FP-Growth karena memungkinkan proses pencarian *frequent itemset* dan pembentukan *Association Rule* dilakukan secara optimal.

Secara keseluruhan, tahapan transformasi ini berperan penting dalam menyiapkan *dataset* agar sesuai dengan karakteristik metode FP-Growth dan *Association Rule*. Dengan data yang telah berada dalam bentuk kategorikal dan biner, proses identifikasi pola hubungan antar variabel dapat dilakukan dengan lebih efektif serta menghasilkan aturan asosiasi yang lebih mudah diinterpretasikan. Terlihat pada Gambar 9 berikut.

Row No.	study_hours = Low	study_hours = Medium	study_hours = High
1	false	true	false
2	true	false	false
3	true	false	false
4	false	true	false
5	false	true	false
6	true	false	false
7	false	true	false
8	false	false	true
9	false	true	false
10	false	true	false

Sumber: Penelitian (2026)

Gambar 9. Transformasi *Numerical to Binominal*

5. Data Mining

a. Penerapan Algoritma FP-Growth

Pada tahap *data mining* dilakukan menggunakan algoritma FP-Growth untuk menemukan pola hubungan antar variabel berdasarkan nilai minimum *support* yang telah ditentukan. Dalam implementasi menggunakan perangkat lunak *RapidMiner*, proses pencarian *frequent itemset* dilakukan secara otomatis dalam satu tahapan, sehingga *frequent 1-itemset*, *2-itemset*, hingga *3-itemset* dihasilkan secara bersamaan oleh sistem. Pada penelitian ini, hasil tersebut disajikan dalam beberapa tabel terpisah untuk mempermudah proses analisis dan interpretasi pola yang terbentuk.

No	Itemsets	Support
1	focus_index = Medium	0.685
2	gaming_hours = Low	0.620
3	screen_time_hours = Medium	0.612
4	exam_score = Low	0.610
5	sleep_hours = Medium	0.607
6	study_hours = Medium	0.593
7	productivity_score = Medium	0.533
8	social_media_hours = Medium	0.513
9	online_classes_hours = Low	0.498
10	self_study_hours = Low	0.496
11	self_study_hours = Medium	0.485
12	online_classes_hours = Medium	0.478
13	social_media_hours = Low	0.444
14	productivity_score = Low	0.420
15	study_hours = Low	0.374
16	exam_score = Medium	0.359
17	gaming_hours = Medium	0.348
18	exercise_minutes = Medium	0.336
19	exercise_minutes = Low	0.334
20	exercise_minutes = High	0.330
21	screen_time_hours = Low	0.313

Sumber: Penelitian (2026)

Gambar 10. *Frequent 1-Itemsets*

Gambar 10 menunjukkan *frequent 1-itemset*, yaitu *item* tunggal yang memiliki tingkat kemunculan tinggi dalam dataset. Berdasarkan hasil perhitungan *support*, *item* dengan nilai tertinggi adalah *focus_index = Medium* sebesar 0,685, yang membuktikan bahwa sebagian besar responden memiliki tingkat fokus pada kategori sedang. Selanjutnya diikuti oleh *gaming_hours = Low* sebesar 0,620 dan *screen_time_hours = Medium* sebesar 0,612. Selain itu, beberapa variabel lain seperti *exam_score = Low*, *sleep_hours = Medium*, dan *study_hours = Medium* juga memiliki nilai *support* yang relatif tinggi, yang menunjukkan bahwa karakteristik data didominasi oleh kategori sedang pada beberapa aktivitas utama pelajar.

No	Support	Itemsets
1	0.433	focus_index = Medium gaming_hours = Low
2	0.419	focus_index = Medium screen_time_hours = Medium
3	0.378	gaming_hours = Low screen_time_hours = Medium
4	0.363	gaming_hours = Low exam_score = Low
5	0.387	screen_time_hours = Medium exam_score = Low
6	0.375	screen_time_hours = Medium sleep_hours = Medium
7	0.377	exam_score = Low sleep_hours = Medium
8	0.301	exam_score = Low study_hours = Medium
9	0.357	sleep_hours = Medium study_hours = Medium
10	0.321	sleep_hours = Medium productivity_score = Medium
11	0.265	productivity_score = Medium social_media_hours = Medium
12	0.269	productivity_score = Medium online_classes_hours = Low
13	0.253	social_media_hours = Medium online_classes_hours = Low
14	0.262	social_media_hours = Medium self_study_hours = Low
15	0.248	online_classes_hours = Low self_study_hours = Low
16	0.242	online_classes_hours = Low self_study_hours = Medium
17	0.251	productivity_score = Low study_hours = Low

Sumber: Penelitian (2026)

Gambar 11. *Frequent 2-Itemsets*

Gambar 11 menunjukkan bahwa *Frequent 2-Itemsets*, yaitu kombinasi dua item yang sering muncul secara bersamaan dalam

dataset. Kombinasi dengan nilai *support* tertinggi adalah *focus_index = Medium* dan *gaming_hours = Low* sebesar 0,433, yang mengindikasikan bahwa tingkat fokus sedang sering muncul bersamaan dengan durasi bermain game yang rendah. Kombinasi lain yang juga cukup dominan adalah *focus_index = Medium* dan *screen_time_hours = Medium*, serta *gaming_hours = Low* dengan *screen_time_hours = Medium*. Pola ini menunjukkan adanya keterkaitan antara tingkat fokus, aktivitas penggunaan teknologi, dan kebiasaan harian responden.

No	Support	Itemsets		
1	0.266	focus_index = Medium	gaming_hours = Low	screen_time_hours = Medium
2	0.245	focus_index = Medium	gaming_hours = Low	exam_score = Low
3	0.266	focus_index = Medium	gaming_hours = Low	sleep_hours = Medium
4	0.269	focus_index = Medium	gaming_hours = Low	study_hours = Medium
5	0.277	focus_index = Medium	gaming_hours = Low	productivity_score = Medium
6	0.248	focus_index = Medium	screen_time_hours = Medium	exam_score = Low
7	0.260	focus_index = Medium	screen_time_hours = Medium	sleep_hours = Medium
8	0.267	focus_index = Medium	screen_time_hours = Medium	study_hours = Medium
9	0.270	focus_index = Medium	screen_time_hours = Medium	productivity_score = Medium
10	0.242	focus_index = Medium	exam_score = Low	sleep_hours = Medium
11	0.266	focus_index = Medium	sleep_hours = Medium	study_hours = Medium
12	0.272	focus_index = Medium	sleep_hours = Medium	productivity_score = Medium
13	0.324	focus_index = Medium	study_hours = Medium	productivity_score = Medium
14	0.262	focus_index = Medium	productivity_score = Medium	exam_score = Medium
15	0.244	gaming_hours = Low	exam_score = Low	productivity_score = Low
16	0.244	gaming_hours = Low	study_hours = Medium	productivity_score = Medium
17	0.242	screen_time_hours = Medium	exam_score = Low	sleep_hours = Medium
18	0.254	screen_time_hours = Medium	exam_score = Low	productivity_score = Low
19	0.252	exam_score = Low	sleep_hours = Medium	productivity_score = Low
20	0.244	exam_score = Low	productivity_score = Low	study_hours = Low
21	0.243	study_hours = Medium	productivity_score = Medium	exam_score = Medium

Sumber: Penelitian (2026)

Gambar 12. Frequent 3-Itemsets

Selanjutnya pada Gambar 12, diperoleh kombinasi tiga variabel yang muncul secara bersamaan dan memenuhi nilai minimum *support*. Salah satu kombinasi dengan nilai *support* tertinggi adalah *focus_index = Medium*, *study_hours = Medium*, dan *productivity_score = Medium* sebesar 0,324. Hal ini menunjukkan bahwa tingkat fokus dan durasi belajar pada kategori sedang cenderung berkaitan dengan tingkat produktivitas yang juga berada pada kategori sedang. Selain itu, kombinasi yang melibatkan variabel fokus, penggunaan teknologi, serta hasil akademik juga cukup sering muncul, seperti *focus_index = Medium*, *gaming_hours = Low*, dan *screen_time_hours = Medium*.

Secara keseluruhan, hasil *frequent itemset* yang diperoleh dari algoritma FP-Growth menunjukkan adanya keterkaitan antar variabel perilaku belajar, aktivitas harian, dan produktivitas pelajar. *Itemset* dengan nilai *support* tinggi menunjukkan pola kemunculan yang dominan dalam *dataset* dan akan digunakan pada tahap selanjutnya untuk menghasilkan aturan asosiasi (*Association*

Rule) berdasarkan nilai *confidence*. Oleh karena itu, pola hubungan yang dihasilkan tidak hanya menggambarkan frekuensi kemunculan, tetapi juga kekuatan hubungan antar variabel yang dapat diinterpretasikan secara lebih komprehensif.

b. Pembentukan *Association Rule*
Setelah diperoleh *frequent itemset* menggunakan algoritma FP-Growth, tahap selanjutnya adalah pembentukan *Association Rule* untuk mengetahui keterkaitan antar variabel secara lebih spesifik. *Association Rule* dibentuk berdasarkan nilai *support* dan *confidence* yang telah memenuhi ambang batas minimum yang ditentukan. Nilai *support* menunjukkan intensitas kombinasi item dalam *dataset*, sedangkan *confidence* menunjukkan tingkat kepercayaan terhadap aturan yang terbentuk, yaitu seberapa besar kemungkinan suatu kondisi terjadi apabila kondisi lain terpenuhi.

No	Premises	Conclusions	Support	Confidence
1	productivity_score = Medium, exam_score = Medium	focus_index = Medium	0.262	0.822
2	study_hours = Medium, productivity_score = Medium	focus_index = Medium	0.323	0.827
3	gaming_hours = Low, productivity_score = Medium	focus_index = Medium	0.277	0.828
4	screen_time_hours = Medium, productivity_score = Medium	focus_index = Medium	0.269	0.833
5	productivity_score = Medium	focus_index = Medium	0.446	0.838
6	sleep_hours = Medium, productivity_score = Medium	focus_index = Medium	0.272	0.849
7	exam_score = Medium	productivity_score = Medium	0.319	0.889
8	study_hours = Medium, exam_score = Medium	productivity_score = Medium	0.243	0.902
9	focus_index = Medium, exam_score = Medium	productivity_score = Medium	0.262	0.910
10	gaming_hours = Low, productivity_score = Low	exam_score = Low	0.244	0.964
11	productivity_score = Low	exam_score = Low	0.405	0.965
12	screen_time_hours = Medium, productivity_score = Low	exam_score = Low	0.254	0.967
13	sleep_hours = Medium, productivity_score = Low	exam_score = Low	0.251	0.969
14	productivity_score = Low, study_hours = Low	exam_score = Low	0.244	0.973

Sumber: Penelitian (2026)

Gambar 13. Confidence

Berdasarkan hasil pada Gambar 13, diperoleh beberapa aturan yang menunjukkan hubungan antar variabel produktivitas pelajar. Salah satu aturan yang memiliki nilai *confidence* tinggi adalah hubungan antara *study_hours = Medium* dan *productivity_score = Medium* terhadap *focus_index = Medium* dengan nilai *confidence* sebesar 0,827. Hal ini menunjukkan bahwa pelajar yang memiliki durasi belajar dan tingkat produktivitas pada kategori sedang cenderung memiliki tingkat fokus yang juga berada pada kategori sedang.

Selain itu, terdapat juga aturan lain seperti *screen_time_hours = Medium* dan *productivity_score = Medium* yang menghasilkan *focus_index = Medium* dengan *confidence* sebesar 0,833, serta *sleep_hours = Medium* dan *productivity_score = Medium* terhadap *focus_index = Medium* dengan *confidence* sebesar 0,849.

Pola ini menunjukkan bahwa tingkat produktivitas memiliki hubungan yang cukup erat dengan tingkat fokus pelajar, terutama ketika aktivitas harian berada pada kategori sedang.

Hubungan antara hasil akademik dan produktivitas juga terlihat pada aturan *focus_index = Medium* dan *exam_score = Medium* yang menghasilkan *productivity_score = Medium* dengan *confidence* sebesar 0,910. Hal ini menunjukkan bahwa tingkat fokus dan hasil akademik yang baik cenderung berkaitan dengan produktivitas pelajar yang lebih optimal.

Sementara itu, beberapa aturan dengan *confidence* tertinggi berkaitan dengan kategori nilai rendah, seperti *gaming_hours = Low* dan *productivity_score = Low* yang menghasilkan *exam_score = Low* dengan *confidence* sebesar 0,964, serta *productivity_score = Low* dan *study_hours = Low* yang menghasilkan *exam_score = Low* dengan *confidence* sebesar 0,973. Pola ini menunjukkan bahwa produktivitas dan durasi belajar yang rendah memiliki kecenderungan kuat terhadap hasil akademik yang rendah.

Secara keseluruhan, aturan asosiasi yang diperoleh menunjukkan bahwa variabel fokus, durasi belajar, produktivitas, dan hasil akademik memiliki hubungan yang saling berkaitan. Tingkat aktivitas yang berada pada kategori sedang cenderung menghasilkan kondisi yang seimbang antara fokus dan produktivitas, sedangkan kategori rendah pada beberapa variabel utama berpotensi menghasilkan hasil akademik yang kurang optimal. Temuan ini menunjukkan bahwa pengelolaan waktu belajar, aktivitas harian, dan tingkat fokus merupakan faktor penting dalam meningkatkan produktivitas serta pencapaian akademik pelajar.

c. Analisis Pola Hubungan Antara Produktivitas dan Manajemen Waktu

Berdasarkan hasil *Association Rule* yang telah diperoleh, dapat dianalisis pola hubungan antara produktivitas pelajar dengan aspek manajemen waktu yang meliputi durasi belajar, penggunaan waktu layar, aktivitas bermain game, waktu tidur, serta aktivitas pembelajaran daring. Analisis ini bertujuan untuk mengidentifikasi kecenderungan perilaku yang berkontribusi terhadap tingkat produktivitas maupun hasil akademik pelajar.

Hasil penelitian menunjukkan bahwa

produktivitas pelajar cenderung berada pada kategori sedang ketika beberapa aspek manajemen waktu juga berada pada tingkat yang seimbang. Hal ini terlihat pada aturan asosiasi yang menunjukkan bahwa kombinasi *study_hours = Medium* dan *exam_score = Medium* menghasilkan *productivity_score = Medium* dengan tingkat *confidence* yang tinggi. Pola ini menunjukkan bahwa pengelolaan waktu belajar yang cukup, tanpa berlebihan maupun kekurangan, berkontribusi terhadap tingkat produktivitas yang optimal.

Selain itu, tingkat fokus juga memiliki hubungan yang erat dengan produktivitas. Aturan yang menunjukkan bahwa *productivity_score = Medium* berkaitan dengan *focus_index = Medium* mengindikasikan bahwa kemampuan pelajar dalam mempertahankan fokus menjadi salah satu faktor utama dalam mencapai produktivitas yang baik. Faktor manajemen waktu seperti *sleep_hours = Medium* juga berkontribusi terhadap kondisi tersebut, yang menunjukkan bahwa keseimbangan antara waktu istirahat dan aktivitas belajar memiliki peran penting.

Sebaliknya, pola hubungan juga menunjukkan bahwa produktivitas yang rendah cenderung berkaitan dengan manajemen waktu yang kurang optimal. Kombinasi *study_hours = Low* dan *productivity_score = Low* yang menghasilkan *exam_score = Low* dengan nilai *confidence* tinggi menunjukkan bahwa kurangnya alokasi waktu belajar berdampak langsung terhadap pencapaian akademik. Selain itu, hubungan antara *gaming_hours = Low* dan *productivity_score = Low* terhadap *exam_score = Low* menunjukkan bahwa meskipun aktivitas bermain game rendah, produktivitas yang rendah tetap dapat berkontribusi terhadap hasil akademik yang kurang baik apabila tidak diimbangi dengan aktivitas belajar yang cukup.

Secara keseluruhan, pola hubungan yang ditemukan menunjukkan bahwa produktivitas pelajar tidak hanya dipengaruhi oleh satu faktor tunggal, tetapi merupakan hasil interaksi dari berbagai aspek manajemen waktu. Keseimbangan antara waktu belajar, istirahat, penggunaan teknologi, serta tingkat fokus menjadi faktor utama dalam mencapai produktivitas yang optimal. Temuan ini mengindikasikan bahwa penerapan manajemen waktu yang baik dapat

membantu meningkatkan produktivitas sekaligus mendukung pencapaian akademik pelajar secara lebih efektif.

6. Evaluation

Tahap evaluasi ini dilakukan untuk menilai kualitas pada aturan asosiasi yang dihasilkan dari penerapan algoritma FP- Growth. Evaluasi dilakukan dengan menggunakan tiga parameter utama yaitu *support*, *confidence*, dan *lift ratio*. Nilai *support* membuktikan tingkat kemunculan aturan dalam dataset, *confidence* menunjukkan tingkat kepercayaan terhadap aturan yang terbentuk, sedangkan *lift ratio* digunakan untuk mengidentifikasi kekuatan hubungan antar variabel. Nilai *lift* yang lebih dari 1 menunjukkan bahwa hubungan antar variabel memiliki korelasi positif dan aturan yang dihasilkan dianggap memiliki keterkaitan yang kuat.

No	Premises	Conclusions	Support	Confidence	Lift
1	productivity_score = Medium, exam_score = Medium	focus_index = Medium	0.262	0.822	1.200
2	study_hours = Medium, productivity_score = Medium	focus_index = Medium	0.323	0.827	1.206
3	gaming_hours = Low, productivity_score = Medium	focus_index = Medium	0.277	0.828	1.209
4	screen_time_hours = Medium, productivity_score = Medium	focus_index = Medium	0.269	0.833	1.217
5	productivity_score = Medium	focus_index = Medium	0.446	0.838	1.224
6	sleep_hours = Medium, productivity_score = Medium	focus_index = Medium	0.272	0.849	1.239
7	exam_score = Medium	productivity_score = Medium	0.319	0.889	1.669
8	study_hours = Medium, exam_score = Medium	productivity_score = Medium	0.243	0.902	1.693
9	focus_index = Medium, exam_score = Medium	productivity_score = Medium	0.262	0.910	1.708
10	gaming_hours = Low, productivity_score = Low	exam_score = Low	0.244	0.964	1.579
11	productivity_score = Low	exam_score = Low	0.405	0.965	1.581
12	screen_time_hours = Medium, productivity_score = Low	exam_score = Low	0.254	0.967	1.585
13	sleep_hours = Medium, productivity_score = Low	exam_score = Low	0.251	0.969	1.585
14	productivity_score = Low, study_hours = Low	exam_score = Low	0.244	0.973	1.594

Sumber: Penelitian (2026)

Gambar 14. Lift Ratio

Berdasarkan hasil evaluasi pada Gambar 14 di atas, seluruh aturan asosiasi memiliki nilai lift lebih besar dari 1, yang menunjukkan bahwa aturan yang terbentuk mempunyai hubungan yang bermakna dan tidak terjadi secara kebetulan. Salah satu aturan dengan nilai lift tertinggi adalah hubungan antara *focus_index = Medium* dan *exam_score = Medium* terhadap *productivity_score = Medium* dengan nilai lift sebesar 1,708 dan *confidence* sebesar 0,910. Hal ini menunjukkan bahwa pelajar yang memiliki tingkat fokus dan hasil akademik pada kategori sedang memiliki kemungkinan yang lebih besar untuk memiliki produktivitas pada kategori sedang dibandingkan kondisi lainnya.

Selain itu, aturan dengan nilai lift tinggi juga terlihat pada hubungan *study_hours = Medium* dan *exam_score = Medium* terhadap *productivity_score = Medium* dengan *lift* sebesar 1,693. Pola ini menunjukkan bahwa keseimbangan waktu belajar memiliki kontribusi penting terhadap produktivitas pelajar. Sementara itu, aturan yang berkaitan dengan kategori rendah juga menunjukkan hubungan yang kuat, seperti *productivity_score = Low* dan *study_hours = Low* terhadap *exam_score = Low* dengan

confidence sebesar 0,973 dan *lift* sebesar 1,594. Hal ini mengindikasikan bahwa rendahnya produktivitas dan waktu belajar memiliki kecenderungan kuat terhadap rendahnya hasil akademik.

Beberapa aturan lain menunjukkan bahwa produktivitas yang berada pada kategori sedang memiliki hubungan yang erat dengan tingkat fokus sedang, terutama ketika dikombinasikan dengan faktor manajemen waktu seperti durasi tidur dan penggunaan waktu layar. Kondisi ini menunjukkan bahwa keseimbangan aktivitas harian berperan penting dalam membentuk tingkat fokus dan produktivitas pelajar.

Secara keseluruhan, hasil evaluasi menunjukkan bahwa aturan asosiasi yang dihasilkan memiliki tingkat kepercayaan dan kekuatan korelasi yang baik. Nilai *confidence* yang tinggi serta *lift ratio* yang lebih dari 1 membuktikan bahwa pola yang ditemukan dapat digunakan untuk menjelaskan hubungan antara manajemen waktu dan produktivitas pelajar secara valid. Dengan demikian, pada hasil penelitian ini dapat memberikan gambaran mengenai faktor-faktor yang berkontribusi terhadap produktivitas dan pencapaian akademik, sehingga dapat menjadi dasar dalam upaya peningkatan manajemen waktu yang lebih efektif.

IV. KESIMPULAN

Penelitian ini menganalisis hubungan antara manajemen waktu dan produktivitas pelajar menggunakan algoritma FP-Growth melalui tahapan *Knowledge Discovery in Databases* (KDD). Hasil analisis menunjukkan bahwa variabel seperti *study_hours*, *focus_index*, *sleep_hours*, *screen_time_hours*, *gaming_hours*, *exam_score*, dan *productivity_score* memiliki pola keterkaitan tertentu.

Frequent itemset dan *Association Rule* yang terbentuk menunjukkan bahwa kategori sedang (*medium*) mendominasi sebagian besar variabel utama. Aturan dengan nilai *confidence* tinggi dan *lift ratio* lebih dari satu membuktikan bahwa hubungan antar variabel memiliki keterkaitan yang bermakna. Produktivitas pada kategori sedang cenderung berkaitan dengan durasi belajar dan tingkat fokus pada kategori yang sama, sedangkan kategori rendah pada durasi belajar dan produktivitas berkaitan dengan hasil akademik yang rendah.

Untuk penelitian selanjutnya, analisis dapat dikembangkan pada dataset dengan cakupan yang lebih luas atau melalui pengaturan parameter *support* dan *confidence* yang berbeda untuk melihat variasi pola yang

terbentuk.

V. REFERENSI

- Achmad, F., Nurdiawan, O., & Wijaya, Y. A. (2023). Analisa Pola Transaksi Pembelian Konsumen Pada Toko Ritel Kesehatan Menggunakan Algoritma Fp-Growth. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(1), 168–175.
- Andini, E., & Martanto, M. (2024). Analisis Asosiasi Fp-Growth Untuk Meningkatkan Efisiensi Pemilihan Produk Frozen Food Di Toko Aneka Frozen Food Josef Family. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(2), 1985–1991.
- Astri, D. F., & Martanto, M. (2024). Clustering Penduduk Miskin Menggunakan Algoritma K-Means Pada Wilayah Jawa Barat. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(2), 1548–1554.
- Ch, S., Prasad, S. L. V, Rambabu, M., & Kumar, N. (2022). Association Rule Generation for Student Performance Analysis using Apriori Algorithm. *Journal of Science and Technology*, 7(03), 107–112.
- Hery & Widjaja, A. E. (2024). Analysis of apriori and fp-growth algorithms for market basket insights: A case study of the bread basket bakery sales. *Journal of Digital Market and Digital Currency*, 1(1), 63–83.
- Nurarofah, E., Herdiana, R., & Nuris, N. D. (2023). Penerapan asosiasi menggunakan algoritma FP-Growth pada pola transaksi penjualan di Toko Roti. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(1), 353–359.
- Pujiharto, E. W., Kusri, K., & Nasiri, A. (2023). Analisis Perbandingan Kinerja Algoritma Apriori, FP-Growth dan Eclat dalam menemukan Pola Frekuensi pada Dataset INA-CBG'S. *CogITo Smart Journal*, 9(2), 340–354.
- Rofi, M. F., Nisa, T. S., Widyastuti, A. H., & Zulfahmi, M. N. (2025). Analisis manajemen waktu siswa sekolah dasar melalui jurnal harian. *PPIMAN Pusat Publikasi Ilmu Manajemen*, 3(1), 283–290.
- Rohman, N., & Wibowo, A. (2024). Clustering of popular Spotify songs in 2023 using K-Means method and silhouette coefficient. *Jurnal Pilar Nusa Mandiri*, 20(1), 18–24.
- Safitri, D. W., & Absharina, E. D. (2025). Dalam Pendidikan Untuk Meningkatkan Literasi Digital Melalui Pembelajaran E-Learning Pada Siswa Dengan Pemanfaatan Big Data. *Simtek: Jurnal Sistem Informasi Dan Teknik Komputer*, 10(1), 23–28.
- Saksana, J. C. (2024). Analisis pengaruh motivasi belajar, kemampuan kognitif dan manajemen waktu terhadap prestasi belajar mahasiswa. *Jurnal Pendidikan Dan Kebudayaan Nusantara*, 2(4), 172–181.
- Saputra, J. P. B., Rahayu, S. A., & Hariguna, T. (2023). Market basket analysis using FP-growth algorithm to design marketing strategy by determining consumer purchasing patterns. *Journal of Applied Data Sciences*, 4(1), 38–49.
- Sriurai, W., & Nuanmeesri, S. (2024). The development of *Association Rules* for student performance analysis using FP-Growth algorithm as a guideline for multidisciplinary learning. *Journal of Applied Research on Science and Technology (JARST)*, 23(1), 253807.
- Wang, T., Xiao, B., & Ma, W. (2022). Student Behavior Data Analysis Based on Association Rule Mining. *International Journal of Computational Intelligence Systems*, 15(1).
- Wijaya, A., Faqih, A., Solihudin, D., Rohmat, C. L., & Permana, S. E. (2023). Penerapan *Association Rules* menggunakan algoritma apriori untuk identifikasi pola pembelian. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(6), 3871–3878.