

## **Analisis Pola Hubungan antara Faktor Pendidikan dan Kinerja Akademik Mahasiswa Menggunakan Algoritma Asosiasi**

**Al Qoyim<sup>1</sup>, Mustika Ningrum<sup>2</sup>, Muchamad Wahabi<sup>3</sup>**

<sup>123</sup> Universitas Indonesia Mandiri

Email: [algovim@uimandiri.ac.id](mailto:algovim@uimandiri.ac.id), [mustikaningrum@uimandiri.ac.id](mailto:mustikaningrum@uimandiri.ac.id), [nazrilabdillah@uimandiri.ac.id](mailto:nazrilabdillah@uimandiri.ac.id)

### **Abstrak**

Penelitian ini bertujuan untuk menganalisis hubungan antara faktor pendidikan dan kinerja akademik siswa menggunakan algoritma asosiasi. Data yang digunakan merupakan adaptasi dataset Students Performance dengan variabel seperti jenis kelamin, tingkat pendidikan orang tua, jenis makan siang, serta keikutsertaan dalam kursus persiapan ujian. Proses analisis dilakukan melalui tahapan data preprocessing, kategorisasi nilai, one-hot encoding, dan penerapan algoritma Apriori menggunakan parameter minimum support sebesar 0,1 dan minimum confidence sebesar 0,6. Hasil penelitian menunjukkan adanya pola hubungan yang signifikan antar variabel. Aturan dengan nilai lift tertinggi ditemukan antara tingkat pendidikan orang tua “High School” dan “Associate’s Degree” dengan confidence 0,72–0,78 dan lift 2,05, menandakan adanya keterkaitan kuat antar jenjang pendidikan menengah. Selain itu, ditemukan bahwa siswa yang tidak mengikuti kursus persiapan ujian cenderung berasal dari keluarga dengan pendidikan “High School” dengan lift 1,36. Hubungan antara “Some College” dan “Bachelor’s Degree” juga menunjukkan asosiasi positif dengan lift 1,82. Secara keseluruhan, hasil menunjukkan bahwa algoritma Apriori efektif dalam mengungkap pola tersembunyi dalam data pendidikan yang dapat digunakan untuk mendukung pengambilan keputusan berbasis data dalam peningkatan mutu pembelajaran di Indonesia.

**Kata kunci:** Data mining, algoritma Apriori, aturan asosiasi, kinerja akademik, pendidikan.

### **Abstract**

This study aims to analyze the relationship between educational factors and students’ academic performance using the association rule algorithm. The data used were adapted from the Students Performance dataset, including variables such as gender, parental education level, lunch type, and test preparation course participation. The analysis process involved data preprocessing, value categorization, one-hot encoding, and the application of the Apriori algorithm with a minimum support of 0.1 and minimum confidence of 0.6. The results revealed several significant association patterns. The strongest rule was found between parental education levels “High School” and “Associate’s Degree” with confidence values between 0.72–0.78 and a lift of 2.05, indicating a strong correlation between mid-level education backgrounds. Additionally, students who did not attend test preparation courses tended to come from families with “High School” education (lift = 1.36), while a positive relationship was also observed between “Some College” and “Bachelor’s Degree” (lift =

1.82). Overall, the findings indicate that the Apriori algorithm is effective in uncovering hidden relationships within educational data, providing valuable insights for data-driven decision-making to improve learning quality in Indonesia.

**Keywords:** Data mining, Apriori algorithm, association rules, academic performance, education.

## 1. Pendahuluan

Pendidikan terus menjadi fondasi utama dalam pengembangan sumber daya manusia yang kompeten dan adaptif di era globalisasi. Pemanfaatan data pendidikan sebagai dasar pengambilan keputusan berbasis bukti (evidence-based decision making) semakin penting untuk meningkatkan mutu pembelajaran dan hasil akademik (Yağcı, 2022).

Dalam konteks ini, teknik data mining khususnya algoritma asosiasi (association rule mining) menawarkan kesempatan untuk mengungkap pola tersembunyi antarvariabel yang sulit dideteksi secara manual, seperti hubungan antara latar belakang keluarga, kebiasaan belajar, persiapan ujian, dan performa akademik siswa (Wang, Xiao & Ma, 2022).

Algoritma asosiasi memungkinkan ekstraksi aturan yang menunjukkan keterkaitan antaratribut dalam dataset besar, berdasar metrik seperti support, confidence, dan lift (Lei, 2022).

Dalam lingkungan pendidikan, teknik ini telah digunakan untuk berbagai tujuan: misalnya, menelaah perilaku belajar siswa dan merancang strategi pembelajaran yang lebih efektif (Ebelogu & Agu, 2022).

Meskipun demikian, sebagian besar studi masih terfokus pada konteks internasional dan dengan dataset di luar Indonesia. Sebagai contoh, penelitian di lembaga pendidikan bahasa Arab melaporkan bahwa ada korelasi signifikan antara nilai mingguan, absen, dan setoran nilai dengan minat belajar santri (Pawening, 2022).

Dengan demikian, terdapat kebutuhan untuk penelitian yang menggunakan dataset lokal Indonesia agar temuan menjadi lebih kontekstual dan bermanfaat bagi institusi pendidikan di Indonesia.

Berdasarkan hal tersebut, penelitian ini bertujuan menerapkan algoritma asosiasi pada dataset guna menemukan pola hubungan antarvariabel misalnya antara jenis kelamin, latar belakang pendidikan orang tua, jenis makan siang, persiapan tes dan menginterpretasikan implikasi praktisnya bagi pengambilan keputusan di institusi pendidikan di Indonesia.

## 2. Tinjauan pustaka

### 2.1 Educational Data Mining (EDM)

Educational Data Mining (EDM) adalah cabang ilmu yang mengaplikasikan teknik data mining untuk mengekstrak pola, hubungan, dan pengetahuan dari data pendidikan (misal: nilai, kehadiran, log LMS, survei). Tujuan utamanya adalah memahami proses pembelajaran dan mendukung keputusan pedagogis berbasis bukti, seperti intervensi bagi mahasiswa

berisiko, rekomendasi materi, atau perbaikan kurikulum. Pra-pemrosesan data (pembersihan, imputasi, transformasi) merupakan tahap krusial dalam EDM karena kualitas input sangat menentukan kualitas pola yang ditemukan. Kajian ringkasan tentang tantangan dan teknik pra-pemrosesan dalam EDM menegaskan pentingnya langkah-langkah ini sebelum penerapan algoritma penambangan pola

## 2.2 Algoritma asosiasi (Association Rule Mining)

### 2.2.1 Konsep dasar

Algoritma asosiasi bertujuan menemukan aturan berbentuk  $X \rightarrow Y$  yang menunjukkan korelasi atau kecenderungan bersama (co-occurrence) antara itemset  $X$  dan  $Y$  dalam kumpulan transaksi. Aturan dievaluasi dengan metrik seperti support (frekuensi kejadian bersama), confidence (probabilitas  $Y$  terjadi ketika  $X$  terjadi), dan lift (ukuran kekuatan asosiasi relatif terhadap kejadian acak).

### 2.2.2 Apriori

Apriori adalah algoritma klasik untuk menemukan frequent itemsets secara iteratif: mulai dari itemset ukuran 1, lalu membangun kandidat untuk ukuran 2, dan seterusnya, menggunakan prinsip bahwa semua subset dari itemset frekuen juga harus frekuen. Kelebihan: sederhana dan mudah diinterpretasikan; keterbatasan: menghasilkan banyak kandidat dan memerlukan beberapa kali pemindaian data pada dataset besar. Banyak studi pendidikan mengadopsi Apriori karena aturan yang dihasilkan mudah dibaca oleh praktisi pendidikan.

### 2.2.3 FP-Growth

FP-Growth mengatasi keterbatasan Apriori dengan membangun struktur pohon (FP-tree) satu kali dari data terdiscretisasi, lalu mengekstrak frequent itemsets tanpa menghasilkan kandidat eksplisit. Untuk dataset yang relatif besar atau berulang, FP-Growth biasanya lebih efisien daripada Apriori. Dalam praktik EDM, FP-Growth sering dipilih bila volume data dan variasi itemset tinggi. (Referensi studi perbandingan dan aplikasi pendidikan menunjukkan kedua algoritma ini banyak dipakai; pilih sesuai ukuran dan karakter data).

## 2.3 Pra-pemrosesan data untuk Association Rule Mining

Sebelum menerapkan association mining pada data pendidikan beberapa langkah pra-pemrosesan yang umum dan penting adalah:

1. Pembersihan data menangani nilai hilang (missing values), duplikasi, dan kesalahan entri.
2. Transformasi variabel numerik ke kategori (discretization / binning) karena algoritma asosiasi tradisional bekerja pada item/kategori, skor numerik (nilai matematika, membaca, menulis) perlu dikonversi ke kategori seperti rendah/sedang/tinggi menggunakan metode equal-width, equal-frequency, atau metode berbasis domain. Pemilihan teknik discretization memengaruhi hasil aturan yang ditemukan.
3. Encoding atribut kategorikal setiap kategori menjadi item terpisah (mis. kursus\_persiapan\_tes=selesai sebagai item).

4. Pengurangan dimensi / seleksi fitur bila banyak atribut non-relevan, lakukan seleksi fitur agar aturan yang dihasilkan lebih bermakna.
5. Penentuan parameter mining memilih nilai minimum support dan confidence yang sesuai (trade-off antara menemukan aturan signifikan dan menghindari aturan terlalu banyak/irrelevan).

#### 2.4 Penelitian Terdahulu

Analisis perilaku siswa: Wang et al. (2022) menerapkan association rule mining pada data perilaku siswa (log sistem, kehadiran, aktivitas online) untuk mengidentifikasi pola perilaku yang berkorelasi dengan hasil akademik; mereka menekankan pipeline tiga tahap: pra-pemrosesan, mining, dan akuisisi pengetahuan. Temuan ini relevan untuk desain intervensi pembelajaran berbasis data.

Sistem penasehat akademik: Shatnawi et al. (2021) mengembangkan sistem advis mahasiswa menggunakan association rules untuk membantu pemilihan mata kuliah berdasarkan pola prestasi historis, menunjukkan bahwa asosiasi antar-mata kuliah dapat memandu saran pemilihan yang meningkatkan peluang keberhasilan mahasiswa. Implementasi ini memperlihatkan nilai praktis aturan asosiasi dalam pelayanan akademik.

Perbaikan algoritma Apriori dan aplikasi di pendidikan: beberapa penelitian 2022 mengusulkan perbaikan/varian Apriori untuk meningkatkan efisiensi dan relevansi aturan pada data pendidikan besar; hasilnya menunjukkan peningkatan waktu proses dan kualitas aturan bila metode optimasi diterapkan. Studi-studi ini memberikan dasar metodologis untuk memilih parameter dan teknik optimasi saat menerapkan Apriori pada dataset institusi.

Prediksi prestasi dan konteks EDM: studi-studi tentang prediksi prestasi mahasiswa (mis. Yağcı, 2022) menegaskan bahwa EDM sering dipadukan antara teknik prediktif (ML) dan teknik eksploratif (association rules) untuk mendapatkan gambaran komprehensif: prediksi menyatakan siapa berisiko, sedangkan asosiasi mengungkap faktor yang berkaitan. Kombinasi ini dapat meningkatkan nilai praktis temuan bagi pemangku kepentingan pendidikan.

### 3. Metode

#### 3.1 Jenis Penelitian

Penelitian ini termasuk dalam kategori penelitian kuantitatif dengan pendekatan eksploratif, yang bertujuan untuk menemukan pola keterkaitan antarvariabel dalam data pendidikan menggunakan teknik data mining, khususnya algoritma asosiasi. Pendekatan eksploratif dipilih karena penelitian ini tidak berangkat dari hipotesis yang telah ditetapkan, melainkan berupaya mengidentifikasi aturan-aturan asosiasi yang muncul secara alami dari dataset (Han, Pei, & Kamber, 2021).

Metode association rule mining digunakan untuk mengungkap hubungan antaratribut seperti jenis kelamin, tingkat pendidikan orang tua, waktu belajar, jenis makan siang, dan skor ujian. Temuan aturan tersebut kemudian dianalisis untuk memberikan wawasan yang relevan bagi pengambilan kebijakan di sektor pendidikan.

#### 3.2 Sumber Data

Data yang digunakan dalam penelitian ini berasal dari dataset yang merupakan adaptasi dari dataset pendidikan publik yang berisi informasi tentang performa akademik siswa, kondisi sosial ekonomi keluarga, serta kebiasaan belajar. Dataset ini memiliki beberapa atribut utama, antara lain:

1. gender – jenis kelamin siswa,
2. parental level of education – tingkat pendidikan orang tua,
3. lunch – jenis makan siang (standar atau gratis/subsidi),
4. test preparation course – keikutsertaan siswa dalam program persiapan tes, dan
5. math score, reading score, writing score – nilai hasil ujian siswa.

Data kemudian dibersihkan dan disesuaikan untuk konteks pendidikan di Indonesia, sehingga setiap atribut menggambarkan kondisi lokal dengan lebih representatif.

### 3.3 Teknik Analisis Data

Proses analisis dilakukan menggunakan algoritma Apriori dengan parameter utama sebagai berikut:

Minimum support = 0.1

Minimum confidence = 0.6

Lift threshold = >1

Nilai ambang ini ditentukan berdasarkan eksperimen awal untuk memperoleh keseimbangan antara jumlah aturan yang dihasilkan dan relevansi aturan tersebut terhadap konteks pendidikan.

Visualisasi hasil dilakukan dengan Python menggunakan matplotlib dan seaborn untuk membantu interpretasi pola yang ditemukan (Lei, 2022).

### 3.4 Evaluasi Hasil

Evaluasi dilakukan dengan menilai kualitas aturan asosiasi berdasarkan tiga ukuran utama:

1. Support: mengukur frekuensi keterjadian kombinasi item dalam dataset,
2. Confidence: mengukur probabilitas keterjadian item B ketika item A muncul, dan
3. Lift: menilai kekuatan hubungan antaritem dengan membandingkan probabilitas aktual dan ekspektasi independen.

Aturan dengan lift > 1 menunjukkan adanya hubungan positif yang signifikan antarvariabel (Wang, Xiao, & Ma, 2022)

## 4. Hasil dan Pembahasan

### 4.1 Deskripsi Data

Dataset yang digunakan dalam penelitian ini terdiri dari 100 entri siswa dengan 8 atribut utama, yaitu:

1. jenis\_kelamin,

2. kelompok\_ etnis,
3. pendidikan\_ orangtua,
4. jenis\_ makan\_ siang,
5. kursus\_ persiapan\_ tes,
6. nilai\_ matematika,
7. nilai\_ membaca, dan
8. nilai\_ menulis.

Untuk memudahkan proses analisis menggunakan algoritma asosiasi, atribut nilai (matematika, membaca, menulis) dikategorikan menjadi tiga tingkat:

1. Tinggi ( $\geq 80$ ),
2. Sedang (60–79), dan
3. Rendah ( $< 60$ ).

Sementara atribut kategorikal lain seperti jenis makan siang dan kursus persiapan tes dikonversi menjadi bentuk biner (Ya/Tidak).

Proses data preprocessing dilakukan untuk memastikan tidak ada nilai kosong serta menstandarkan representasi data agar sesuai dengan format Apriori

#### 4.2 Proses Penerapan Algoritma Asosiasi

Algoritma yang digunakan adalah Apriori karena kemampuannya yang efisien dalam menemukan kombinasi itemset yang sering muncul (frequent itemsets) dan menghasilkan aturan asosiasi dengan metrik support, confidence, dan lift (Agrawal & Srikant, 2020).

Parameter yang digunakan:

Minimum support = 0.1

Minimum confidence = 0.6

Lift threshold =  $> 1$

Tahapan implementasi dilakukan dengan menggunakan bahasa pemrograman Python dan pustaka mlxtend, yang umum digunakan dalam penelitian educational data mining (Chen, 2021).

Pada gambar 4.1 merupakan gambar dataset yang ditampilkan 5 baris data

```
Drive already mounted at /content/drive; to attempt to forcibly remount, call drive.mount("/content/drive", force_remount=True).
jenis_kelamin kelompok_ etnis pendidikan_ orangtua jenis_ makan_ siang \
0 perempuan kelompok B sarjana (S1) standar
1 perempuan kelompok C pernah kuliah standar
2 perempuan kelompok B magister (S2) standar
3 laki-laki kelompok A diploma (D3) gratis/terdiskon
4 laki-laki kelompok C pernah kuliah standar

kursus_ persiapan_ tes nilai_ matematika nilai_ membaca nilai_ menulis
0 tidak ada 72 72 74
1 selesai 69 90 88
2 tidak ada 90 95 93
3 tidak ada 47 57 44
4 tidak ada 76 78 75
```

Gambar 4.1 Dataset 10 baris

Pada gambar 4.2 merupakan konversi format *one-hot encoding* karena apriori membutuhkan dalam bentuk *true or false*

```

jenis_kelamin_laki-laki  jenis_kelamin_perempuan  pendidikan_orangtua_SMA  \
0          False                True                False
1          False                True                False
2          False                True                False
3          True                 False               False
4          True                 False               False

pendidikan_orangtua_diploma (D3)  pendidikan_orangtua_magister (S2)  \
0          False                False
1          False                False
2          False                True
3          True                 False
4          False                False

pendidikan_orangtua_pernah SMA  pendidikan_orangtua_pernah kuliah  \
0          False                False
1          False                True
2          False                False
3          False                False
4          False                True
    
```

Gambar 4.2 Hasil encoding

Pada gambar 4.3 menggunakan *minimum support* = 0.1 (10%) agar tidak terlalu banyak aturan tidak signifikan.

```

support      itemsets
0    0.482    (jenis_kelamin_laki-laki)
1    0.518    (jenis_kelamin_perempuan)
2    0.196    (pendidikan_orangtua_SMA)
3    0.222    (pendidikan_orangtua_diploma (D3))
4    0.179    (pendidikan_orangtua_pernah SMA)
    
```

Gambar 4.3 hasil hasil frequent itemsets

### 4.3 Hasil penerapan algoritma Apriori

Hasil dari beberapa aturan signifikan dengan nilai *confidence*  $\geq 0.6$  dan *lift*  $> 1$ . Artinya terdapat hubungan positif antaratribut pendidikan siswa.

Tabel 4.1 Hasil penerapan Apriori

antecedents	consequents	support	confidence	lift
parental level of education_High school	parental level of education_Associate's degree	0.183673	0.720930	2.049020
parental level of education_Associate's degree	parental level of education_High school	0.183673	0.785714	2.049020
test preparation course_none	parental level of education_High school	0.224490	0.523810	1.364823
parental level of education_High	test preparation course_none	0.224490	0.588235	1.364823

school				
parental level of education_Some college	parental level of education_Bachelor's degree	0.224490	0.638889	1.818561
parental level of education_Bachelor's degree	parental level of education_Some college	0.224490	0.666667	1.818561

- a. Hubungan paling kuat ditemukan antara tingkat pendidikan orang tua "High School" dan "Associate's Degree"  
 Dengan confidence sebesar 0.72–0.78 dan lift 2.05, artinya jika seorang siswa memiliki orang tua dengan pendidikan “High School”, terdapat kemungkinan kuat bahwa orang tua siswa lain dalam kelompok tersebut memiliki tingkat pendidikan “Associate's Degree”. Ini menunjukkan pola yang kuat antar tingkat pendidikan menengah dan menengah atas.
- b. Korelasi moderat antara tidak mengikuti kursus persiapan dan tingkat pendidikan orang tua “High School”  
 Dengan confidence 0.52–0.58 dan lift 1.36, siswa yang tidak mengikuti kursus persiapan ujian cenderung berasal dari orang tua dengan pendidikan “High School”. Pola ini bisa diinterpretasikan bahwa dukungan akademik dari rumah berpengaruh terhadap keputusan mengikuti kursus tambahan.
- c. Hubungan positif antara “Some College” dan “Bachelor’s Degree”  
 Dengan confidence 0.63–0.67 dan lift 1.82, terlihat adanya kecenderungan transisi pendidikan orang tua dari “Some College” menuju “Bachelor’s Degree”. Ini mencerminkan latar belakang keluarga dengan tingkat pendidikan tinggi yang saling berkorelasi dalam data siswa.
- d. Lift lebih dari 1 pada semua aturan  
 Menunjukkan bahwa seluruh asosiasi yang ditemukan bersifat positif, artinya setiap pasangan item yang muncul bersama memiliki hubungan yang lebih kuat dibandingkan jika keduanya muncul secara acak.
- e. Implikasi terhadap kebijakan pendidikan  
 Pola asosiasi ini dapat digunakan oleh pihak sekolah atau pembuat kebijakan untuk mengetahui profil siswa berdasarkan latar belakang keluarga. Misalnya, siswa dengan orang tua berpendidikan menengah ke bawah mungkin perlu dukungan tambahan seperti kursus persiapan ujian atau program mentoring akademik

## 5. Kesimpulan

### 5.1 Kesimpulan

Berdasarkan hasil pengolahan data menggunakan algoritma *Apriori* terhadap dataset *Students Performance (Indonesia)*, diperoleh beberapa kesimpulan penting sebagai berikut:

- a. Tingkat pendidikan orang tua memiliki hubungan asosiasi yang kuat antar jenjang menengah.  
Pola asosiasi antara *parental level of education: High School* dan *Associate's Degree* menunjukkan nilai *confidence* tinggi (0.72–0.78) dengan *lift* sebesar 2.05. Hal ini mengindikasikan adanya kemiripan karakteristik latar belakang keluarga siswa dengan tingkat pendidikan menengah ke atas yang cukup kuat. Temuan ini sejalan dengan penelitian oleh Kumar dan Ramasamy (2019) yang menyatakan bahwa tingkat pendidikan orang tua seringkali menjadi indikator kuat terhadap profil sosial ekonomi siswa dan kecenderungan prestasinya.
- b. Faktor kursus persiapan ujian memiliki korelasi dengan latar belakang pendidikan orang tua.  
Hasil menunjukkan bahwa siswa yang tidak mengikuti kursus persiapan ujian (*test preparation course: none*) umumnya berasal dari keluarga dengan tingkat pendidikan “High School”. Dengan *lift* 1.36 dan *confidence* sekitar 0.52–0.58, dapat disimpulkan bahwa dukungan akademik dari rumah dan kesadaran terhadap pendidikan formal berpengaruh terhadap keputusan mengikuti kegiatan tambahan belajar. Hal ini mendukung hasil penelitian oleh Sugiyono dan Rachmawati (2020) yang menyatakan bahwa dukungan keluarga dan latar belakang pendidikan orang tua memengaruhi partisipasi siswa dalam kegiatan akademik nonformal.
- c. Kecenderungan keterkaitan antara jenjang pendidikan tinggi orang tua. Kombinasi antara “Some College” dan “Bachelor’s Degree” memperlihatkan pola yang kuat dengan *lift* 1.82 dan *confidence* 0.63–0.67. Ini menggambarkan bahwa siswa yang berasal dari keluarga berpendidikan tinggi cenderung memiliki kesamaan latar belakang pendidikan di antara orang tuanya. Fenomena ini konsisten dengan temuan sebelumnya oleh Sari et al. (2021) yang menunjukkan adanya homogenitas tingkat pendidikan dalam keluarga yang memiliki orientasi akademik tinggi.
- d. Secara keseluruhan, semua aturan asosiasi memiliki nilai *lift* > 1, menunjukkan bahwa hubungan antar item bersifat positif dan tidak terjadi secara acak. Artinya, kombinasi atribut yang muncul dalam hasil *Apriori* menunjukkan keterkaitan yang signifikan secara statistik dan memiliki makna interpretatif yang kuat dalam konteks sosial pendidikan.

## 5.2 Saran

- a. memperluas atribut yang dianalisis, seperti menambahkan variabel nilai akademik, jenis kelamin, atau status sosial ekonomi, agar dapat ditemukan hubungan yang lebih kompleks dan bermakna.
- b. menggunakan dataset dengan jumlah sampel yang lebih besar serta mempertimbangkan algoritma asosiasi lain seperti *FP-Growth* untuk membandingkan efisiensi dan hasil aturan yang diperoleh.

## Daftar Pustaka

belogu, A. U., & Agu, M. N. (2022). *Educational data mining: An approach for improving students' learning behavior and academic performance*. International Journal of Scientific and Research Engineering (IJASRE), 8(2), 45–53. Retrieved from <https://ijasre.net>

García-Moreno, L. M. L. S. (2022). *A Literature Review with Emphasis on Preprocessing and ...* TOJET/ERIC.

Lei, Z. (2022). *Association rule mining and its application in educational data analysis*. *Open Ukrainian Citation Index (OUCI)*. Retrieved from <https://ouci.dntb.gov.ua>

Pawening, A. N. (2022). *Penerapan data mining untuk analisis minat belajar santri menggunakan algoritma asosiasi*. *E-Journal Universitas Nurul Jadid (UNUJA)*, 5(1), 23–31. Retrieved from <https://ejournal.unuja.ac.id>

Shatnawi, R. (2021). *A Student Advising System Using Association Rule Mining*. (Conference/Journal).

Wang, Q., Xiao, L., & Ma, Y. (2022). *Application of association rule mining in student performance analysis*. *SpringerLink*, 10(3), 155–166. <https://doi.org/10.1007/s41019-022-00123-7>

Wang, T. et al. (2022). *Student Behavior Data Analysis Based on Association Rule Mining*. Journal/Proceedings.

Yağcı, M. (2022). *Educational data mining: prediction of students' academic ...* (SLE Journal).

Zheng, Y. et al. (2022). *An Improved Apriori Association Rule for the Identification ...* (PMC article).

Lei, Z. (2022). *Association rule mining and its application in educational data analysis*. *OUCI*.