**JENTIK: Jurnal Elektronika dan Teknik Informatika Terapan**
**Volume. 4 Nomor. 2 Juni 2026**
e-ISSN : 2988-0874 p-ISSN : 2988-0866, Hal 92-104
DOI: https://doi.org/10.59061/jentik.v4i2.1526
Tersedia: https://e-journal.poltek-kampar.ac.id/index.php/JENTIK

# Implementasi Algoritma Fp-Growth Dalam Analisis Penerimaan Mahasiswa Baru

**Baiq Anna Naura Nazifa*[1], Galih Hendro Martono[2]**
[1,2]Program Studi Ilmu Komputer, Fakultas Teknik, Universitas Bumigora, Indonesia
*Email:* baiqannanaura@gmail.com[1], galih.hendro@universitabumgiora.ac.id[2]

***Abstract***. *Competition in higher education encourages universities to use historical admissions data as a basis for more focused recruitment decisions. This study implements the Frequent Pattern Growth (FP-Growth) algorithm to identify frequent itemsets and association rules in new student admissions data at Universitas Bumigora. The analysis used 4,858 applicant records with accepted status from the 2022-2024 admission periods and followed the CRISP-DM framework through the evaluation stage. Four combinations of minimum support and minimum confidence were tested: 5%/50%, 10%/60%, 15%/70%, and 20%/80%. The 5%/50% scenario produced the richest set of patterns, with 1,251 frequent itemsets and 4,763 association rules, while stricter thresholds substantially reduced the number of patterns. The data were strongly concentrated on the Mandiri admission pathway and accepted status. A more informative association linked applicants from vocational high schools (SMK) with the itemset {Mandiri pathway, accepted status, year 2023}, yielding confidence of 1.000 and lift of 1.624. These findings indicate that FP-Growth can support admissions evaluation by revealing segments that are difficult to see from descriptive summaries alone. The results can inform targeted outreach to vocational schools, evaluation of the Mandiri pathway, and enrichment of admissions attributes for future analysis.*

***Keywords:*** *association rules; data mining; FP-Growth; new student admissions; higher education.*

**Abstrak**. Persaingan perguruan tinggi mendorong pemanfaatan data historis penerimaan mahasiswa sebagai dasar penyusunan strategi rekrutmen yang lebih terarah. Penelitian ini mengimplementasikan algoritma Frequent Pattern Growth (FP-Growth) untuk menemukan frequent itemsets dan aturan asosiasi pada data Penerimaan Mahasiswa Baru (PMB) Universitas Bumigora. Analisis menggunakan 4.858 data pendaftar berstatus LULUS pada periode 2022-2024 dengan kerangka CRISP-DM sampai tahap evaluasi. Pengujian dilakukan melalui empat kombinasi minimum support dan minimum confidence, yaitu 5%/50%, 10%/60%, 15%/70%, dan 20%/80%. Skenario 5%/50% menghasilkan pola paling kaya, yaitu 1.251 frequent itemsets dan 4.763 aturan asosiasi, sedangkan peningkatan ambang batas secara konsisten mengurangi jumlah pola yang terbentuk. Dataset menunjukkan konsentrasi yang kuat pada Jalur Mandiri dan status LULUS. Pola yang lebih informatif ditemukan pada pendaftar asal SMK terhadap kelompok item {Jalur Mandiri, Status LULUS, Tahun 2023} dengan confidence 1,000 dan lift 1,624. Hasil tersebut menunjukkan bahwa FP-Growth dapat membantu evaluasi PMB dengan menampilkan segmen pendaftar yang tidak mudah terlihat dari ringkasan deskriptif. Temuan dapat dimanfaatkan untuk promosi yang lebih terarah ke sekolah kejuruan, evaluasi Jalur Mandiri, dan pengayaan atribut data PMB pada analisis berikutnya.

**Kata kunci:** association rule; data mining; FP-Growth; penerimaan mahasiswa baru; perguruan tinggi.

## 1. LATAR BELAKANG

### Pendahuluan

Penerimaan Mahasiswa Baru (PMB) tidak lagi hanya dipandang sebagai rangkaian administrasi untuk mengisi kuota mahasiswa. Dalam persaingan pendidikan tinggi yang semakin ketat, PMB juga menjadi bagian dari perencanaan institusi karena karakteristik pendaftar, jalur masuk, dan pilihan program studi akan memengaruhi strategi promosi serta keberlanjutan layanan akademik. Perkembangan sistem PMB

*Naskah Masuk: 30 April 2025; Revisi: 10 Mei 2026; Diterima: 20 Juni 2026; Terbit: 30 Juni 2026*

berbasis digital membuat perguruan tinggi memiliki catatan historis yang semakin besar, tetapi nilai data tersebut baru terasa ketika diolah menjadi informasi yang dapat digunakan dalam pengambilan keputusan (Nandes et al., 2023; Narizki et al., 2023; Sejati, 2022).

Pemanfaatan data penerimaan penting karena pola pendaftar tidak selalu tampak melalui rekapitulasi jumlah semata. Analisis deskriptif dan visualisasi dapat menunjukkan demografi atau kecenderungan umum, sedangkan teknik data mining memungkinkan institusi menggali pola yang lebih tersembunyi. Penelitian pada data PMB telah memanfaatkan Business Intelligence untuk memetakan profil pendaftar, K-Means untuk membentuk segmen promosi, serta berbagai pendekatan Educational Data Mining untuk mendukung keputusan penerimaan dan rekomendasi program studi (Amin, 2024; Indra et al., 2024; Mamaril & Ballera, 2022; Pratama et al., 2022). Pendekatan berbasis data juga relevan dalam upaya memahami keragaman latar belakang calon mahasiswa dan memperluas akses pendidikan secara lebih terarah (Fadhil & Sabic-El-Rayess, 2021).

Kondisi serupa ditemukan pada Universitas Bumigora. Data PMB periode 2022-2024 tersimpan dalam sistem internal dan memuat informasi mengenai tahun pendaftaran, jalur masuk, asal sekolah, program studi, jenis kelamin, nilai rapor, domisili, serta status kelulusan. Selama ini, data tersebut dapat digunakan untuk pelaporan, tetapi masih terdapat ruang untuk menggali hubungan antarkarakteristik pendaftar secara lebih mendalam. Pertanyaan yang menjadi perhatian bukan hanya berapa jumlah pendaftar dari kelompok tertentu, melainkan atribut apa saja yang cenderung muncul secara bersamaan dan pola mana yang cukup bermakna untuk dipertimbangkan dalam strategi PMB (Biro Administrasi Akademik Universitas Bumigora, 2025).

Salah satu teknik yang sesuai untuk kebutuhan tersebut adalah association rule mining. Teknik ini mencari kombinasi item yang sering muncul bersama dan membentuk aturan berbentuk antecedent-consequent. Dalam penelitian pendidikan, FP-Growth telah digunakan untuk menemukan keterkaitan antarhasil belajar dan menunjukkan bahwa pola asosiasi dapat membantu memahami struktur data yang tidak selalu terlihat melalui analisis sederhana (Putri et al., 2021; Sriurai & Nuanmeesri, 2024). Dibandingkan pendekatan berbasis pembangkitan kandidat, FP-Growth memanfaatkan FP-Tree sehingga proses pencarian frequent itemsets dapat dilakukan tanpa menghasilkan

kandidat secara berulang, yang membuatnya relevan untuk dataset dengan banyak kemungkinan kombinasi atribut (Nurasiah, 2021; Shawkat et al., 2022; Hussain et al., 2023).

**Tabel 1. Ringkasan penelitian terdahulu yang relevan**

| No. | Peneliti | Objek/Data | Metode | Temuan/Relevansi |
|---|---|---|---|---|
| 1 | Amin (2024) | Data PMB IAIN Pontianak | Business Intelligence | Memetakan demografi, jalur, dan program studi melalui visualisasi. |
| 2 | Indra et al. (2024) | 1.275 data PMB Universitas Nurul Huda | K-Means | Membentuk tiga klaster untuk mendukung promosi berbasis wilayah dan program studi. |
| 3 | Mamaril & Ballera (2022) | Data penerimaan universitas | Educational data mining | Menggali pola penerimaan untuk mendukung prediksi program. |
| 4 | Putri et al. (2021) | 1.227 data nilai mahasiswa | FP-Growth | Menemukan keterkaitan kelulusan mata kuliah pemrograman dan matematika. |
| 5 | Sriurai & Nuanmeesri (2024) | Data kinerja akademik siswa | FP-Growth | Menghasilkan aturan asosiasi antarnilai untuk mendukung pengembangan pembelajaran. |

*Sumber: dirangkum dari penelitian terdahulu dalam skripsi, 2025.*

Penelitian-penelitian terdahulu memperlihatkan bahwa data pendidikan dapat dimanfaatkan untuk segmentasi, visualisasi, maupun penemuan hubungan antarfaktor. Namun, penerapan FP-Growth secara khusus pada data PMB multi-tahun Universitas Bumigora belum menjadi fokus penelitian tersebut. Karena itu, penelitian ini diarahkan untuk mengimplementasikan FP-Growth pada data PMB 2022-2024, mengevaluasi pola yang dihasilkan melalui support, confidence, dan lift, lalu menerjemahkan pola yang relevan menjadi masukan strategis bagi pengelolaan PMB. Kebaruan penelitian terletak pada konteks data institusi, penggunaan data multi-tahun, serta upaya menghubungkan keluaran teknis algoritma dengan kebutuhan strategi penerimaan.

## 2. KAJIAN TEORITIS

### Data Mining dan Educational Data Mining

Data mining merupakan proses untuk mengekstraksi pola, kecenderungan, dan informasi yang bernilai dari kumpulan data sehingga data mentah dapat diubah menjadi pengetahuan yang lebih mudah digunakan. Dalam konteks pendidikan, penerapan teknik tersebut berkembang dalam ranah Educational Data Mining (EDM), yaitu penggunaan metode komputasi untuk memahami pola yang muncul dari data pendidikan dan mendukung keputusan akademik maupun institusional (Begum & Banu, 2024; Papadogiannis et al., 2024). Pada PMB, satu data pendaftar dapat dipandang sebagai sebuah transaksi yang berisi sejumlah atribut, sehingga hubungan antara asal sekolah, jalur pendaftaran, tahun, program studi, atau karakteristik lain dapat dianalisis sebagai pola kemunculan bersama.

### Association Rule Mining

Association rule mining termasuk pendekatan pembelajaran tanpa target kelas yang digunakan untuk menemukan hubungan antarkumpulan item. Aturan umumnya ditulis dalam bentuk A => B, dengan A sebagai antecedent dan B sebagai consequent. Kualitas aturan tidak cukup dinilai hanya dari banyaknya kemunculan, tetapi perlu memperhatikan ukuran yang menggambarkan cakupan, keandalan, dan kekuatan hubungan. Tiga ukuran yang digunakan dalam penelitian ini adalah support, confidence, dan lift (Hamdad & Benatchba, 2021; Amsury et al., 2023; Aktavera et al., 2024).

$$Support(A => B) = count(A \cup B) / N \quad (1)$$

$$Confidence(A => B) = Support(A \cup B) / Support(A) \quad (2)$$

$$Lift(A => B) = Confidence(A => B) / Support(B) \quad (3)$$

Support menunjukkan proporsi transaksi yang memuat A dan B secara bersamaan. Confidence menunjukkan peluang consequent muncul ketika antecedent sudah muncul. Sementara itu, lift membandingkan peluang tersebut dengan peluang kemunculan consequent secara umum. Nilai lift lebih dari 1 menunjukkan asosiasi positif, nilai 1 menunjukkan hubungan yang setara dengan kondisi independen, sedangkan nilai di bawah 1 menunjukkan kecenderungan negatif. Karena confidence dapat tampak tinggi ketika consequent sangat dominan, interpretasi lift menjadi penting agar aturan yang dipilih tidak hanya kuat secara permukaan (Prahartiwi, 2022; Mudumba & Kabir, 2024).

**Algoritma FP-Growth dan Kerangka CRISP-DM**

FP-Growth mencari frequent itemsets dengan mengompresi transaksi ke dalam Frequent Pattern Tree (FP-Tree). Data terlebih dahulu dipindai untuk menentukan item yang memenuhi minimum support, kemudian transaksi yang telah diurutkan dibentuk menjadi jalur-jalur pada FP-Tree. Proses penambangan dilakukan melalui conditional pattern base dan conditional FP-Tree, sehingga pencarian tidak memerlukan pembangkitan kandidat itemset berulang sebagaimana pada Apriori. Karakter ini menjadi alasan utama pemilihan FP-Growth pada penelitian yang memiliki banyak kombinasi atribut (Nurasiah, 2021; Shawkat et al., 2022; Hussain et al., 2023).

Pelaksanaan analisis disusun menggunakan Cross-Industry Standard Process for Data Mining (CRISP-DM). Kerangka ini menempatkan pemahaman masalah, pemahaman data, persiapan data, pemodelan, dan evaluasi sebagai rangkaian yang saling terkait serta dapat diulang apabila ditemukan kebutuhan pada tahap berikutnya. CRISP-DM tetap banyak digunakan karena memberi alur kerja yang cukup fleksibel untuk menghubungkan kebutuhan organisasi dengan proses analitik (Martinez-Plumed et al., 2021; Ruswanti et al., 2024; Singgalen, 2023).

## 3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif eksploratif dengan teknik association rule mining. Sumber data berupa data sekunder PMB Universitas Bumigora periode 2022-2024 yang diekstraksi dari sistem internal dalam format .xlsx. Setelah proses seleksi, analisis menggunakan 4.858 record pendaftar berstatus LULUS. Variabel yang tersedia mencakup tahun daftar, jalur pendaftaran, asal sekolah, jurusan atau program studi pilihan, program studi diterima, jenis kelamin, rata-rata nilai rapor, domisili, dan status kelulusan (Biro Administrasi Akademik Universitas Bumigora, 2025).

Kerangka CRISP-DM digunakan sampai tahap evaluation. Business understanding diarahkan pada kebutuhan untuk mengenali pola pendaftar yang dapat mendukung strategi PMB. Data understanding dilakukan dengan memeriksa sumber, struktur, dan kualitas data. Pada data preparation, data dibersihkan dari nilai yang tidak lengkap, duplikasi, dan inkonsistensi, kemudian atribut yang digunakan ditransformasikan menjadi item kategorikal. Tahap modeling menerapkan FP-Growth

menggunakan Python pada lingkungan Jupyter Notebook dengan pustaka Pandas dan mlxtend. Hasil model berupa frequent itemsets dan association rules, kemudian dievaluasi menggunakan support, confidence, dan lift. Penelitian tidak mengembangkan sistem atau dasbor sebagai tahap deployment; keluaran akhirnya berupa interpretasi dan rekomendasi strategis.

**Tabel 2. Transformasi atribut utama**

| No. | Atribut | Transformasi | Aturan/Contoh |
|---|---|---|---|
| 1 | Rata-rata nilai rapor | Diskretisasi | >=90 sangat tinggi; 80-<90 tinggi; 75-<80 cukup; <75 standar |
| 2 | Asal sekolah | Generalisasi | SMA Negeri, SMA Swasta, SMK, MAN/Madrasah |
| 3 | Tahun daftar | Pemberian prefix | Contoh: Tahun_2023 |
| 4 | Jalur pendaftaran | Pemberian prefix | Contoh: Jalur_Mandiri, Jalur_Prestasi |
| 5 | Program studi | Cleaning dan prefix | Nama program studi dinormalisasi menjadi item |
| 6 | Jenis kelamin/domisili/status | Cleaning dan prefix | Contoh: JK_L, Domisili_KotaMataram, Status_LULUS |

*Sumber: olahan penelitian, 2025.*

**Tabel 3. Skenario pengujian parameter FP-Growth**

| Skenario | Min. Support | Min. Confidence | Tujuan Pengujian |
|---|---|---|---|
| I | 5% | 50% | Menangkap pola lebih luas dan relatif rinci |
| II | 10% | 60% | Menyaring pola dengan frekuensi lebih tinggi |
| III | 15% | 70% | Memusatkan analisis pada pola dominan |

| | | | |
|---|---|---|---|
| IV | 20% | 80% | Hanya mempertahankan pola mayoritas |

*Sumber: olahan penelitian, 2025.*

Empat skenario digunakan untuk melihat sensitivitas jumlah pola terhadap perubahan ambang batas. Pada setiap skenario, frequent itemsets dibentuk sesuai minimum support, kemudian association rules disaring berdasarkan minimum confidence. Perbandingan jumlah itemset dan aturan, serta nilai lift pada pola-pola yang dipilih, menjadi dasar evaluasi model.

## 4. HASIL DAN PEMBAHASAN

Setelah data dibersihkan dan diubah ke format transaksional, setiap baris merepresentasikan satu pendaftar dengan kumpulan item kategorikal. Hasil penambangan menunjukkan bahwa Jalur_Mandiri dan Status_LULUS masing-masing memiliki support 1,000. Artinya, kedua item tersebut muncul pada seluruh 4.858 transaksi yang dianalisis. Nilai_Tinggi menjadi item dominan berikutnya dengan support 0,657. Kombinasi {Nilai_Tinggi, Jalur_Mandiri, Status_LULUS} juga memiliki support 0,657, sedangkan kombinasi {Tahun_2023, Jalur_Mandiri} mencapai support 0,616.

Konsentrasi ini penting untuk dibaca secara kritis. Confidence 1,000 pada banyak aturan tidak selalu berarti hubungan yang sangat informatif karena consequent seperti Jalur_Mandiri atau Status_LULUS memang muncul hampir atau sepenuhnya pada seluruh transaksi. Pada kondisi seperti ini, lift membantu membedakan aturan yang hanya mencerminkan dominasi atribut dari aturan yang memiliki asosiasi relatif lebih kuat. Pertimbangan semacam ini sejalan dengan prinsip evaluasi association rules yang menempatkan support, confidence, dan lift sebagai ukuran yang perlu dibaca secara bersamaan (Hamdad & Benatchba, 2021; Mudumba & Kabir, 2024).

**Evaluasi Empat Skenario Parameter**

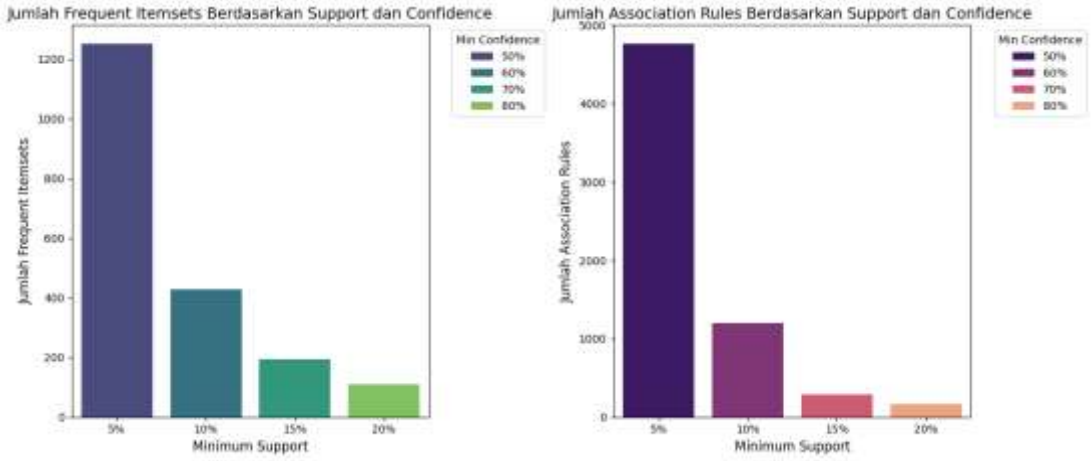
**Tabel 4. Rekapitulasi frequent itemsets dan association rules**

| Skenario | Support / Confidence | Frequent Itemsets | Association Rules |
|---|---|---|---|
| I | 5% / 50% | 1.251 | 4.763 |
| II | 10% / 60% | 427 | 1.199 |
| III | 15% / 70% | 195 | 287 |

| | | | |
|---|---|---|---|
| IV | 20% / 80% | 111 | 164 |

*Sumber: olahan penelitian, 2025.*

Tabel 4 dan Gambar 1 memperlihatkan pola yang konsisten: semakin tinggi minimum support dan minimum confidence, semakin sedikit kombinasi dan aturan yang dapat dipertahankan. Skenario I menghasilkan 1.251 frequent itemsets dan 4.763 aturan, sedangkan Skenario IV hanya menghasilkan 111 itemsets dan 164 aturan. Dalam konteks eksplorasi, Skenario I dipilih sebagai konfigurasi yang paling kaya karena masih menangkap pola yang lebih spesifik tanpa menghilangkan terlalu banyak kombinasi. Skenario dengan ambang yang lebih tinggi tetap berguna sebagai pembanding untuk menunjukkan bahwa pola dominan bertahan ketika penyaringan diperketat.




**Gambar 1. Perbandingan jumlah frequent itemsets dan aturan asosiasi**

*Sumber: olahan penelitian, 2025.*

**Interpretasi Aturan Asosiasi**

**Tabel 5. Contoh pola dominan pada hasil pemodelan**

| No. | Antecedent | Consequent | Support | Confidence | Lift |
|---|---|---|---|---|---|
| 1 | Jalur Mandiri | Status LULUS | 1,000 | 1,000 | 1,000 |
| 2 | Nilai Tinggi | Jalur Mandiri | 0,657 | 1,000 | 1,000 |
| 3 | Nilai Tinggi | Status LULUS | 0,657 | 1,000 | 1,000 |
| 4 | Tahun 2023 | Jalur Mandiri | 0,616 | 1,000 | 1,000 |
| 5 | JK L, Tahun 2023, Nilai Tinggi, Asal SMA Negeri | Jalur Mandiri, Status LULUS | 0,100 | 1,000 | 1,000 |

*Sumber: olahan penelitian, 2025.*

Pola pada Tabel 5 terutama menggambarkan struktur data yang sangat terkonsentrasi. Karena Jalur Mandiri dan Status LULUS hadir pada seluruh transaksi, aturan yang mengarah pada kedua item tersebut menghasilkan confidence 1,000 tetapi lift 1,000. Dengan kata lain, antecedent tidak menaikkan peluang consequent dibandingkan baseline karena consequent memang sudah dominan. Walaupun demikian, pola tersebut tetap bermanfaat sebagai temuan deskriptif yang menunjukkan karakter data PMB yang dianalisis dan sekaligus menjelaskan mengapa sebagian besar aturan memiliki ukuran keberarikan yang terbatas.

Temuan yang lebih informatif muncul pada asosiasi pendaftar asal SMK terhadap kelompok item {Jalur_Mandiri, Status_LULUS, Tahun_2023}. Aturan ini memiliki confidence 1,000 dan lift 1,624. Nilai lift di atas 1 menunjukkan bahwa kemunculan kelompok consequent tersebut relatif lebih besar ketika antecedent Asal_SMK muncul dibandingkan dengan peluang consequent pada data secara umum. Secara praktis, nilai 1,624 dapat dibaca sebagai kecenderungan sekitar 1,6 kali terhadap pola tersebut. Temuan ini lebih bernilai dibandingkan aturan-aturan dengan lift 1,000 karena menunjukkan asosiasi yang melampaui dominasi baseline.

Hasil tersebut memperluas penggunaan analisis data PMB yang sebelumnya banyak berfokus pada visualisasi atau pengelompokan. Amin (2024) menunjukkan manfaat visualisasi untuk membaca profil pendaftar, sedangkan Indra et al. (2024) menggunakan K-Means untuk membentuk segmen promosi. Dalam penelitian ini, FP-Growth memberikan sudut pandang berbeda dengan menunjukkan kombinasi atribut yang sering muncul bersamaan. Hasil ini juga sejalan dengan Putri et al. (2021) dan Sriurai dan Nuanmeesri (2024), yang memperlihatkan bahwa FP-Growth mampu mengungkap keterkaitan pada data pendidikan. Perbedaannya terletak pada objek yang dianalisis, yaitu data PMB multi-tahun dan orientasi interpretasi ke strategi penerimaan mahasiswa.

**Implikasi Strategis dan Keterbatasan**

Asosiasi yang melibatkan pendaftar dari SMK memberi dasar untuk mempertimbangkan promosi yang lebih tersegmentasi ke sekolah kejuruan, terutama sekolah yang selama ini menjadi sumber pendaftar potensial di Nusa Tenggara Barat. Di sisi lain, dominasi Jalur Mandiri menunjukkan bahwa kanal tersebut perlu dijaga dari sisi akses informasi, proses administrasi, dan pengalaman pendaftar. Institusi juga dapat

meninjau daya tarik jalur lain agar variasi kanal penerimaan tidak terlalu bergantung pada satu jalur. Temuan Nilai_Tinggi dengan support 0,657 dapat menjadi bahan untuk merancang komunikasi atau program yang lebih relevan bagi calon mahasiswa berprestasi.

Keterbatasan utama penelitian berada pada struktur dataset. Ketika Jalur_Mandiri dan Status_LULUS menjadi atribut yang konstan, banyak aturan secara otomatis memiliki confidence tinggi dan lift 1,000. Karena itu, hasil tidak seharusnya dibaca sebagai prediksi individual, melainkan sebagai pemetaan pola pada data historis yang tersedia. Pengayaan atribut seperti jurusan asal SMK, sumber informasi pertama mengenai kampus, motivasi memilih program studi, serta domisili yang lebih granular akan memberi variasi yang lebih baik pada analisis berikutnya. Pengembangan ini juga sejalan dengan arah Educational Data Mining yang menekankan kualitas dan konteks data sebagai dasar interpretasi institusional (Papadogiannis et al., 2024; Mamaril & Ballera, 2022).

## 5. KESIMPULAN DAN SARAN

Implementasi FP-Growth pada 4.858 data PMB Universitas Bumigora periode 2022-2024 mampu menghasilkan frequent itemsets dan association rules melalui empat skenario pengujian. Skenario minimum support 5% dan minimum confidence 50% memberikan keluaran paling kaya, yaitu 1.251 frequent itemsets dan 4.763 aturan. Pola dominan memperlihatkan konsentrasi data pada Jalur Mandiri, Status LULUS, serta kelompok pendaftar dengan nilai rapor tinggi. Di antara aturan yang dianalisis, hubungan pendaftar asal SMK terhadap {Jalur Mandiri, Status LULUS, Tahun 2023} menjadi temuan yang lebih informatif karena memiliki confidence 1,000 dan lift 1,624. Dengan demikian, FP-Growth dapat digunakan sebagai alat eksplorasi untuk membantu institusi memahami pola historis PMB, dengan catatan bahwa nilai metrik harus ditafsirkan sesuai distribusi data.

Bagi Universitas Bumigora, hasil penelitian dapat digunakan sebagai bahan awal untuk menyusun promosi yang lebih terarah ke sekolah kejuruan, mengevaluasi dan memperkuat pengelolaan Jalur Mandiri, serta memperkaya variabel pada sistem PMB. Untuk pengembangan selanjutnya, hasil analisis dapat ditampilkan melalui dasbor Business Intelligence atau diintegrasikan secara berkala ke sistem PMB. Penelitian

lanjutan juga dapat menambahkan pendekatan kualitatif untuk menjelaskan alasan di balik pola yang ditemukan, menerapkan model klasifikasi untuk tujuan prediktif, atau menghubungkan data penerimaan dengan kinerja akademik mahasiswa setelah diterima.

## DAFTAR REFERENSI

Aktavera, B., Oktafia, H., Wijaya, L., Studi, P., Komputer, I., Petulai, U. P., Lebong, R., Studi, P., Informasi, S., Insan, U. B., Apriori, A., & Apriori, A. (2024). Analisis Association Rule Menggunakan Algoritma Apriori dan Algoritma FP Growth. Jurnal Teknologi Informasi Mura, 16(1), 54-61.

Amin, M. (2024). Pemetaan Demografi Data Penerimaan Mahasiswa Baru Menggunakan Business Intelligence. Jurnal Tika, 9(1), 11-16. https://doi.org/10.51179/tika.v9i1.2471

Amsury, F., Kurniawati, I., & Rizki Fahdia, M. (2023). Implementasi Association Rules Menentukan Pola Pemilihan Menu Di the Gade Coffee & Gold Menggunakan Algoritma Apriori. INFOTECH Journal, 9(1), 279-286. https://doi.org/10.31949/infotech.v9i1.5357

Begum, D. I. P., & Banu, D. N. (2024). Data Mining Techniques. Futuristic Trends in Information Technology Volume 3 Book 2, 3, 188-206. https://doi.org/10.58532/v3bfit2p6ch2

Biro Administrasi Akademik Universitas Bumigora. (2025). Data Penerimaan Mahasiswa Baru Universitas Bumigora Periode 2022-2024.

Fadhil, I., & Sabic-El-Rayess, A. (2021). Providing Equity of Access to Higher Education in Indonesia: A Policy Evaluation. Indonesian Journal on Learning and Advanced Education (IJOLAE), 3(1), 57-75. https://doi.org/10.23917/ijolae.v3i1.10376

Hamdad, L., & Benatchba, K. (2021). Association Rules Mining. SN Computer Science, 2(6), 449. https://doi.org/10.1007/s42979-021-00819-x

Hussain, H., Pahlevi, R. R., Wardana, A. A., & Mugitama, S. A. (2023). Smart Camping Management Asset using Frequent Pattern-Growth Algorithm. 2023 11th International Conference on Information and Communication Technology (ICoICT), 475-480. https://doi.org/10.1109/ICoICT58202.2023.10262776

Indra, I. I., Rizki, U., Jakak, P. M., Prayogi, M. B., & Rahman, M. (2024). Penerapan Metode K-Means Clustering Dalam Pengembangan Strategi Promosi Berbasis Data Penerimaan Mahasiswa Baru (Studi Kasus: Universitas Nurul Huda). Jurnal Nasional Ilmu Komputer, 5(1), 25-43. https://doi.org/10.47747/jurnalnik.v5i1.1656

Mamaril, J. C. O., & Ballera, M. A. (2022). Multiple educational data mining approaches to discover patterns in university admissions for program prediction. International Journal of Informatics and Communication Technology (IJ-ICT), 11(1), 45. https://doi.org/10.11591/ijict.v11i1.pp45-56

Martinez-Plumed, F., Contreras-Ochando, L., Ferri, C., Hernandez-Orallo, J., Kull, M., Lachiche, N., Ramirez-Quintana, M. J., & Flach, P. (2021). CRISP-DM Twenty

Years Later: From Data Mining Processes to Data Science Trajectories. IEEE Transactions on Knowledge and Data Engineering, 33(8), 3048-3061. https://doi.org/10.1109/TKDE.2019.2962680

Mudumba, B., & Kabir, M. F. (2024). Mine-first association rule mining: An integration of independent frequent patterns in distributed environments. Decision Analytics Journal, 10, 100434. https://doi.org/10.1016/j.dajour.2024.100434

Nandes, Y. T., Zamzami, Z., D, S., Zamsuri, A., & Vebby, V. (2023). Rancang Bangun Sistem Informasi Manajemen Seleksi Penerimaan Mahasiswa Baru Universitas Lancang Kuning. Jurnal Karya Ilmiah Multidisiplin (JURKIM), 3(1), 78-89. https://doi.org/10.31849/jurkim.v3i1.12011

Narizki, M., Widyanto, R. A., & Prabowo, N. (2023). Perancangan UI/UX Sistem Penerimaan Mahasiswa Baru Berbasis Perangkat Mobile dengan Metode Design Thinking. Journal of Information System Research (JOSH), 4(4). https://doi.org/10.47065/josh.v4i4.3652

Nurasiah. (2021). Implementasi Algoritma FP-Growth Pada Pengenalan Pola Penjualan. TIN: Terapan Informatika Nusantara, 1(9), 438-444.

Papadogiannis, I., Wallace, M., & Karountzou, G. (2024). Educational Data Mining: A Foundational Overview. Encyclopedia, 4(4), 1644-1664. https://doi.org/10.3390/encyclopedia4040108

Prahartiwi, L. I. (2022). Implementasi Algoritma FP-Growth Untuk Menemukan Pola Pembelian Konsumen Pada Analisis Keranjang Pasar. IJIS - Indonesian Journal On Information System, 7(1), 71-78. https://doi.org/10.36549/ijis.v7i1.208

Pratama, A. R., Aryanto, R. R., & Pratama, A. T. M. (2022). Model Klasifikasi Calon Mahasiswa Baru Untuk Sistem Rekomendasi Program Studi Sarjana Berbasis Machine Learning. Jurnal Teknologi Informasi dan Ilmu Komputer, 9(4), 725-734. https://doi.org/10.25126/jtiik.2022934311

Putri, Z. K., Iskandar, I., & Nazir, A. (2021). Implementasi Algoritma FP-Growth untuk Menemukan Pola Keterkaitan Antara Matakuliah Pemrograman dan Matakuliah Matematika. Jurnal CoreIT: Jurnal Hasil Penelitian Ilmu Komputer dan Teknologi Informasi, 7(2), 51. https://doi.org/10.24014/coreit.v7i2.15351

Ruswanti, D., Susilo, D., & Riani, R. (2024). Implementasi CRISP-DM pada Data Mining untuk Melakukan Prediksi Pendapatan dengan Algoritma C.45. Go Infotech: Jurnal Ilmiah STMIK AUB, 30(1), 111-121. https://doi.org/10.36309/goi.v30i1.266

Sejati, P. (2022). Design and Build PMB System with Prediction of Prospective Students Accepted or Withdrawal Using Random Forest Algorithm. Journal of Computer Science and Technology Studies, 4(2), 58-70. https://doi.org/10.32996/jcsts.2022.4.2.8

Shawkat, M., Badawi, M., El-ghamrawy, S., Arnous, R., & El-desoky, A. (2022). An optimized FP-growth algorithm for discovery of association rules. The Journal of Supercomputing, 78(4), 5479-5506. https://doi.org/10.1007/s11227-021-04066-y

Singgalen, Y. A. (2023). Penerapan Metode CRISP-DM dalam Klasifikasi Data Ulasan Pengunjung Destinasi Danau Toba Menggunakan Algoritma Naive Bayes

Classifier (NBC) dan Decision Tree (DT). JURNAL MEDIA INFORMATIKA BUDIDARMA, 7(3), 1551. https://doi.org/10.30865/mib.v7i3.6461

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), 1-6. https://doi.org/10.60101/jarst.2023.253807