

Pola Komorbiditas Pasien Diabetes Mellitus Tipe II Di Rumah Sakit Imelda Menggunakan Algoritma FP-Growth dan Apriori

Marulak Lasron Siahaan¹, Bualazatulo Laia², Heru Fredi³, Khoiri Sutan Hasibuan⁴, Adelina⁵, Rika Rosnelly⁶.

^{1,2,3,4,5,6} Program Pascasarjana, Ilmu Komputer, Universitas Potensi Utama, Medan, Indonesia.

E-mail: ¹marulaksiahaan02@gmail.com, ²buallalaia57@gmail.com, ³herufredi85@gmail.com, ⁴khoirisutan@gmail.com, ⁵linaade289@gmail.com, ⁶rikarosnelly@gmail.com.

Abstrak

Diabetes Mellitus Tipe 2 merupakan penyakit kronis yang sering disertai berbagai komorbiditas yang dapat meningkatkan risiko komplikasi, menurunkan kualitas hidup pasien, serta memperberat beban pelayanan kesehatan. Identifikasi pola komorbiditas yang sering muncul menjadi penting sebagai dasar pengambilan keputusan klinis. Penelitian ini bertujuan untuk menganalisis dan membandingkan pola komorbiditas pasien Diabetes Mellitus Tipe II di Rumah Sakit Imelda menggunakan algoritma Apriori dan FP-Growth. Dataset yang digunakan berasal dari data rekam medis sebanyak 758 pasien, yang setelah melalui tahap seleksi dan pembersihan data menghasilkan 664 data transaksi. Proses analisis dilakukan menggunakan teknik Association Rule Mining dengan parameter minimum *support* 20% dan minimum *confidence* 60%. Hasil penelitian menunjukkan bahwa kedua algoritma berhasil menemukan pola komorbiditas yang konsisten, dengan jumlah frequent itemset dan aturan asosiasi yang sama. Algoritma Apriori lebih efisien dari sisi waktu komputasi pada dataset berukuran relatif kecil, sedangkan FP-Growth unggul dalam mengidentifikasi pola penyakit yang bersifat umum dan dominan. Pola utama yang ditemukan meliputi kombinasi Diabetes Mellitus Tipe II dengan hipertensi dan dislipidemia, serta pola spesifik yang melibatkan penyakit kardiovaskular dan muskuloskeletal. Hasil penelitian ini diharapkan dapat menjadi pendukung keputusan klinis dalam pencegahan komplikasi dan perencanaan strategi penanganan pasien diabetes.

Kata kunci: Diabetes Mellitus Tipe 2, Apriori, FP-Growth.

Abstract

Type 2 Diabetes Mellitus is a chronic disease often accompanied by various comorbidities that can increase the risk of complications, reduce the patient's quality of life, and increase the burden of healthcare services. Identifying frequently occurring comorbidity patterns is crucial as a basis for clinical decision-making. This study aims to analyze and compare the comorbidity patterns of Type 2 Diabetes Mellitus patients at Imelda Hospital using the Apriori and FP-Growth algorithms. The dataset used was derived from medical records of 758 patients, which after going through the selection and data cleaning stages resulted in 664 transaction data. The analysis process was carried out using the Association Rule Mining technique with parameters of minimum support of 20% and minimum confidence of 60%. The results showed that both algorithms successfully identified consistent comorbidity patterns, with the same number of frequent itemsets and association rules. The Apriori algorithm was more efficient in terms of computational time on relatively small datasets, while FP-Growth excelled in identifying common and dominant disease patterns. The main patterns identified included the combination of Type II Diabetes Mellitus with hypertension and dyslipidemia, as well as specific patterns involving cardiovascular and musculoskeletal disease. The results of this study are expected to support clinical decision-making in preventing complications and planning treatment strategies for diabetes patients.

Keywords: Type 2 Diabetes Mellitus, Apriori, FP-Growth.

1. PENDAHULUAN

Diabetes Mellitus Tipe II merupakan salah satu penyakit kronis yang prevalensinya terus meningkat di seluruh dunia, dan menjadi masalah kesehatan masyarakat yang cukup serius, termasuk di Indonesia. Pada penelitian Ji, Q., et Al (2024) menemukan 80% pasien memiliki setidaknya satu komorbiditas, dan 52% dari banyak pasien 25.000, memiliki dua atau lebih komorbiditas, Penyakit ini tidak hanya dapat terjadi pada komplikasi jangka panjang, tetapi juga disertai dengan beragam penyakit penyertaan (komorbiditas) seperti

contohnya Hipertensi, Gagal Ginjal, Jantung koroner, dan dislipidemia [1]. Kehadiran komorbiditas pasien diabetes secara cepat mengalami peningkatan resiko kematian, sehingga menurunkan kualitas hidup pasien, serta menjadi beban biaya dalam perawatan.

Menurut penelitian Liu, L., et al (2025), dari data sebanyak 5838 pasien Diabetes Mellitus Tipe II terdapat lebih dari 90% pasien diabetes mellitus tipe II memiliki satu penyakit penyerta, dan sebagian besar mengalami dua atau lebih komorbiditas secara bersamaan. Kondisi ini sering disebut sebagai multimorbiditas dan menjadi tantangan serius untuk penatalaksanaan klinis karena setiap penyakit saling mempengaruhi proses pengobatan dan prognosis pada pasien [2]. Hal ini penting untuk mengetahui pola keterkaitan pada pola komorbiditas yang sering muncul pada pasien diabetes mellitus, agar dapat dilakukan langkah penanganan, dan diambil keputusan klinis yang tepat. Perkembangan teknologi informasi saat ini sangat mendorong pemanfaatan data pada rekam medis dalam melakukan analisis penyakit. Data tersimpan di rumah sakit mengandung pola yang tersembunyi, hal ini dapat dilakukan dengan penerapan metode data mining, diantaranya menggunakan algoritma Apriori dan FP-Growth untuk mengetahui pola hubungan antar data (*Association Rule*). Kedua algoritma ini dapat menemukan kombinasi item atau yang sering muncul bersamaan dalam dataset.

Algoritma data mining menjadi sangat penting dalam menganalisis data untuk mengidentifikasi pola-pola kombinasi kode diagnosa dan kode prosedur ini. Pola-pola ini dapat mengungkap hubungan yang tidak dapat terlihat secara langsung antara berbagai variabel dalam data. Algoritma untuk mengenali pola dari data yaitu asosiasi, ada dua algoritma asosiasi yang umum digunakan diantaranya adalah FP-Growth dan Apriori [3]. Perbedaan dasar dari kedua algoritma adalah algoritma FP-Growth menggunakan pendekatan *divide and conquer* yaitu dengan membangun struktur data yang disebut FP-tree dan kemudian mengeksplorasi struktur ini untuk menemukan pola asosiasi. Sedangkan algoritma menggunakan pendekatan *generate and test* dengan cara membuat semua itemset kandidat kemudian menghitung dukungan untuk masing-masing itemset dan membuang yang tidak memenuhi ambang batas dukungan.

Pada penelitian Aglarci et al (2025), membuktikan bahwa *Association Rule* pada data mining mampu mengidentifikasi pola penyakit yang saling memiliki hubungan dengan pasien diabetes secara efektif, baik sebelum maupun sesudah proses diagnosis [4]. Selain itu Algoritma FP-Growth lebih efisien dibandingkan dengan Apriori karena tidak menghasilkan perwakilan setiap iterasi, sehingga lebih cepat dilakukan ketika dataset yang dimiliki berukuran besar. Namun pada penelitian Putri Yani dan Mahdiana (2025) dalam menemukan pola persepsian obat diabetes di rumah sakit. Meskipun dalam fokusnya pada obat, tetapi algoritma apriori masih banyak juga digunakan konsepnya dikarenakan sederhana, dan untuk mudah dilakukan interpretasi dalam mengolah data klinis di lingkungan Rumah Sakit Indonesia [5].

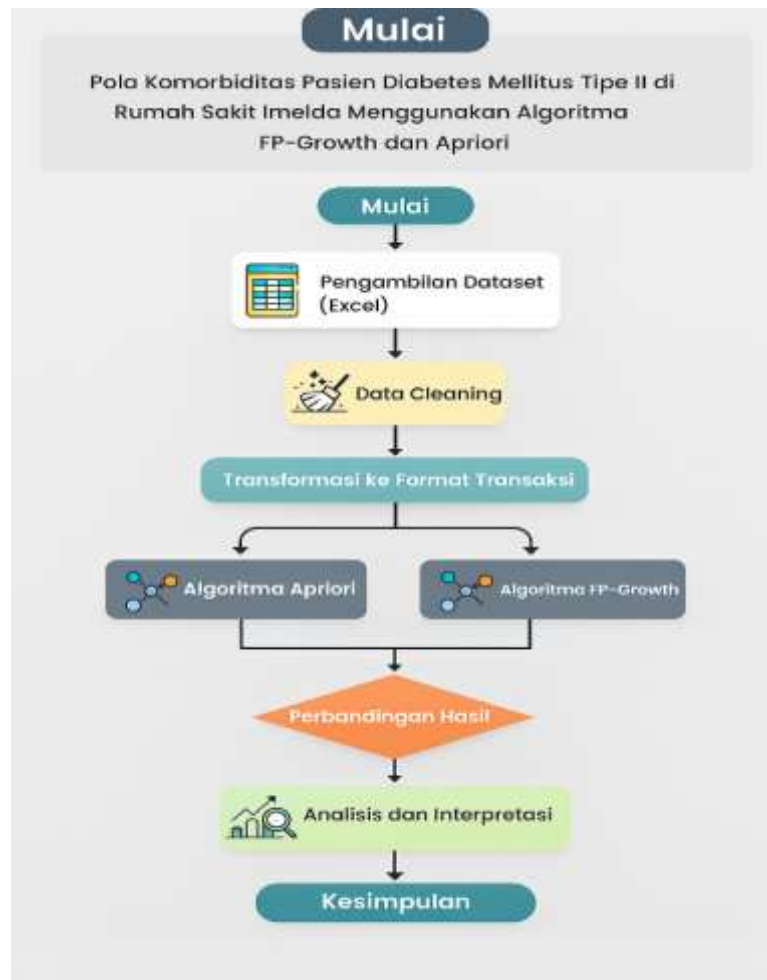
Rumah Sakit Imelda sebagai salah satu penyedia layanan kesehatan yang memiliki pasien Diabetes mellitus Tipe II yang cukup besar, namun dalam data rekam medis tersebut belum dilakukan pemanfaatan secara optimal untuk mengetahui pola komorbiditas yang terjadi. Identifikasi pada penyakit ini penyerta lebih banyak didasarkan pada pengamatan klinis secara individu, oleh karena itu diperlukan suatu penelitian yang mampu untuk mengenali pola komorbiditas pasien Diabetes Mellitus Tipe II yang ada pada Rumah Sakit Imelda dengan teknik pendekatan data mining.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk melakukan analisis pola dan membandingkan pola komorbiditas pada pasien Diabetes Mellitus II yang ada di Rumah Sakit Imelda dengan Algoritma Apriori dan FP-Growth. Hasil keluaran dari penelitian ini akan berupa informasi penting bagi tenaga medis sebagai alat bantu pendukung keputusan dalam melakukan pencegahan komplikasi, serta penyusunan strategi pengobatan klinis, serta dapat meningkatkan kualitas pelayanan kesehatan.

2. METODE PENELITIAN

2.1 Alur Penelitian

Pada penelitian ini, alur penelitian disusun secara sistematis mulai dari awal pengambilan data rekam medis pasien Diabetes Mellitus Tipe II hingga dilakukan penarikan kesimpulan, yaitu berdasarkan pada hasil perbandingan Algoritma Apriori dan FP-Growth. Alur ini bertujuan untuk memastikan bahwa setiap tahapan akan berjalan secara terstruktur dan menghasilkan keluaran yang valid dan dapat dipertanggungjawabkan secara ilmiah. Berikut alur penelitian dapat dilihat pada Gambar 1.



Gambar 1. Alur Penelitian

2.2 Pengambilan Dataset

Pada tahap pertama, peneliti mengumpulkan dataset berupa data sekunder yaitu data rekam medis pasien Diabetes Mellitus Tipe II dari Rumah Sakit Imelda dalam bentuk Format File Microsoft Excel. Dataset ini terdiri dari beberapa atribut utama, yaitu: No. Rekam Medis, JK, Tanggal Masuk, Tanggal Keluar, dan Diagnosa Akhir. Dataset yang akan diolah telah dianonimkan (tanpa mencantumkan identitas pribadi pasien) sehingga tidak melanggar aspek kerahasiaan pasien.

2.3 Seleksi Data (Data Selection)

Setelah data diperoleh dari data medis, maka dilakukan proses seleksi data yang bertujuan untuk memastikan bahwa hanya data yang relevan dan valid yang digunakan dalam proses analisis. Adapun proses seleksi data berdasarkan kriteria sebagai berikut:

Kriteria Inklusi

1. Pasien dengan diagnosis utama Diabetes Mellitus Tipe II
2. Pasien yang memiliki minimal 1 komorbiditas
3. Data pasien dalam kondisi lengkap

Kriteria Eksklusi

1. Pasien tanpa penyakit penyerta
2. Data yang tidak lengkap (missing value)
3. Data yang terduplikasi

2.4 Pembersihan Data (Data Cleaning)

Setelah dilakukan tahapan seleksi data, maka selanjutnya melakukan pembersihan data untuk meningkatkan kualitas dataset yang akan dipakai, adapun tahapan pembersihan data yang akan dilakukan yaitu sebagai berikut [6] :

1. Penghapusan Data Ganda, jika ditemukan adanya nomor rekam medis yang sama, namun memiliki diagnosis penyakit yang berbeda, hal ini karena bahwa pasien tersebut memiliki riwayat kunjungan

yang lebih dari satu kali ke rumah sakit dengan komorbiditas yang berbeda pada setiap periode kunjungan, maka dari peneliti melakukan penggabungan data berdasarkan nomor rekam medis, dimana seluruh diagnosis penyakit pada pasien yang sama dilakukan kombinasikan menjadi satu daftar komorbiditas.

2. Penghapusan data kosong (*missing value*)
3. Penyeragaman Istilahh Diagnosis Penyakit

Misalnya :

DM Thype 2, DM Tipe 2, DM Tipe II, DM Type 2 menjadi “Diabetes Mellitus Tipe II”

4. Penghapusan Kesalahan penulisan

Tujuan dari tahap ini adalah untuk memastikan bahwa data siap digunakan untuk dilakukan proses data mining tanpa menimbulkan kesalahan pada hasil analisis.

2.5 Transformasi Data (Data Transformation)

Setelah melakukan pembersihan data, maka tahap selanjutnya melakukan transformasi data ke dalam bentuk format yang sesuai dengan kebutuhan Association Rule Mining, yaitu format Transaksi (*transactional data*), contoh Hasil tahapan transformasi data yaitu sebagai berikut [7] :

Table 1 Contoh Hasil Transformasi Data

No. Rekam Medis	Daftar Penyakit
24822	Hipetensi, Diabetes Mellitus Tipe II, Dislipidemia
44570	Varises esofagus, Pan gastropati, Diabetes Mellitus Tipe II

Format transaksi inilah yang akan kemudian akan digunakan sebagai input pada Algoritma Apriori dan FP-Growth.

2.6 Proses Mining dengan Algoritma Apriori

Berikut langkah proses algoritma apriori, diantaranya [8]:

1. Analisa pola frekuensi tertinggi

Pada tahap in akan mencari kombinasi pada masing-masing item, yang memenuhi nilai support suatu item, yang dapat diperoleh dengan menggunakan rumus sebagai berikut :

$$\text{Support A} = \frac{\text{Jumlah Transaksi mengandung A}}{\text{Total Transaksi}} \times 100\% \quad (1)$$

Sementara, jika menggunakan nilai support dari 2 item diperoleh menggunakan rumus sebagai berikut:

$$\text{Support (A, B)} = \frac{\text{Jumlah Transaksi mengandung A dan B}}{\text{Total Transaksi}} \times 100\% \quad (2)$$

2. Pembentuk aturan asosiasi

Jika semua pola frekuensi tinggi telah dilakukan dan diperoleh, lalu selanjutnya mencari aturan asosiasi yang menemukan syarat minimum confidence dari aturan $A \rightarrow B$, hal ini akan diperoleh melalui rumus sebagai berikut:

$$\text{Confidence} = P(B, A) = \frac{\text{Jumlah Transaksi mengandung A dan B}}{\text{Total Transaksi}} \times 100\% \quad (3)$$

2.7 Proses Mining dengan Algoritma FP-Growth

Algoritma FP-Growth merupakan salah satu metode dalam data minining asositif rules mining (ARM), algoritma ini merupakan perkembangan dari metode Apriori, algoritma ini biasakannya digunakan untuk mengidentifikasi item yang paling sering muncul didalam suatu kumpulan data sebelum dimodifikasi emelen struktur datanya [9]. Algoritma ini tidak melakukan pembangkitan calon (*candidate generation*), melainkan menerapkan konsep FP-Tree untuk mencari Frekuensi Item Set, artinya algoritma ini mengaplikasikan untuk mengidentifikasi relasi item dari yang sering muncul [10].

2.8 Perbandingan Hasil

Pada tahap ini yaitu melakukan perbandingan hasil dari Algoritma yang digunakan, dengan tujuan untuk menemukan pola hubungan ataupun relasi antar komorbiditas yang ada pada pasien Diabetes Mellitus tipe II di Rumah Sakit Imelda, kedua algoritma ini memiliki tujuan yang sama, tetapi memiliki pendekatan komputasi yang berbeda. Maka dari itu dilakukan perbandingan, untuk mengetahui algoritma mana yang lebih efektif dan efisien dalam menganalisa data komorbiditas yang ada pada pasien [11]. Perbandingan akan dilakukan berdasarkan parameter utama sebagai berikut :

- 1) Waktu Proses
- 2) Jumlah Aturan asosiasi yang dihasilkan

- 3) Nilai Rata-rata confidence
- 4) Nilai Lift

Hasil perbandingan akan ditampilkan dalam bentuk tabel ataupun grafik agar memudahkan analisis.

2.9 Analisis dan Interpretasi

Langkah terakhir tahapan analisis dan Interpretasi hasil, tahap ini bertujuan untuk memberikan makna terhadap pola yang ditemukan dan mengaitkannya dengan konteks medis dan klinis pada pasien diabetes mellitus tipe II, pada analisis hanya dilakukan secara kualitatif dan kuantitatif, yang meliputi interpretasi nilai statistik (*support*), *confidence*, *lift*) serta relevansi klinis terhadap pola komorbiditas yang terbentuk.

3. HASIL DAN PEMBAHASAN

3.1 Pengambilan Dataset

Dataset diperoleh dari rekam medis pasien Diabetes mellitus tipe II di Rumah Sakit Imelda selama periode penelitian. Data terdiri dari atribut diagnosa penyerta (komorbid), seperti hipertensi, penyakit jantung, nefropati diabetik, retinopati, obesitas, dan lain-lain. Jumlah data: 758 pasien DM Tipe II. Dimana Dataset tersebut akan digunakan untuk mencari suatu pola ketertiban (*association rules*) antar penyakit penyerta pada pasien diabetes mellitus tipe II.

3.2 Data Cleaning

Pada tahapan data cleaning yang dilakukan adalah berupa menghapus data diagnosa akhir yang kosong, sehingga menghasilkan jumlah data sebanyak 757 data. Lalu pada tahap ini melakukan seleksi atau filter Diagnosa yang terjangkau Diabetes Mellitus dan Seleksi Komorbiditas penyakit penyerta dengan minimal 1 komorbiditas, selanjutnya melakukan perubahan diagnosa akhir atau penyeragaman menjadi huruf kecil, selanjutnya melakukan standart Penulisan DM Tipe 2 menjadi diabetes mellitus tipe 2, selanjutnya melakukan penggabungan diagnosa akhir yang memiliki Nomor Rekam Medis sama. Sehingga hasil dari tahapan ini menjadi sebanyak 664 data, seperti yang terdapat pada table 1 dibawah ini. Hal ini dilakukan agar memastikan pola yang ditemukan lebih akurat dari tidak bias.

Tabel 1. Hasil Data Cleaning

No	RM	Diagnosa Akhir
1	24822	"hypertensi, diabetes mellitus tipe 2, dislipidemia"
2	44570	"hypertensi, diabetes mellitus tipe 2, dislipidemia,hypertensi, diabetes mellitus tipe 2 , dislipidemia"
3	47024	"hypertensi, diabetes mellitus tipe 2, dislipidemia"
4	51158	"hypertensi, diabetes mellitus tipe 2, dislipidemia"
5	64648	"hnp lumbal, spondylosis lumbal, chf ec hhd, diabetes mellitus tipe 2, dislipidemia, tb paru, diabetes mellitus tipe 2"

3.3. Transformasi ke Format Transaksi

Data diagnosis penyerta dikonversi menjadi dalam suatu format transaksi untuk pembelajaran dengan menggunakan algoritma Apriori dan FP0-Growth, dimana hasil total transaksi sebanyak 664 pasien dengan total item unik sebanyak 20, hal ini yang akan menjadi data utama untuk input proses teknik association rule mining, seperti pada gambar 2 dibawah ini.

	Keterangan	Jumlah
0	Jumlah Transaksi (Pasien)	664
1	Jumlah Unit Item (Diagnosis Unik)	20

Gambar 2. Hasil Format Transaksi.

Selanjutnya merubah data Transaksi setelah dilakukan encoding, sehingga menghasilkan luaran seperti gambar 3 dibawah ini.

DATA TRANSAKSI SETELAH ENCODING
 Ukuran data: (654, 20)

```

chf ec hhd ckd on hd desan tyoid diabetes mellitus tipe 2 dislipidemia dyspepsia gastropaty ge akut hhd hipertensi hnp lumbal hipertensi hypostromia ispa pan gastropati pneumonia ppok spondylitis lumbal tb paru varises esofagus
    
```

0	False	False	False	True	True	False	False	False	False	False	True	False	False	False	False	False	False	False	False
1	False	False	False	True	True	False	False	False	False	False	True	False	False	False	False	False	False	False	False
2	False	False	False	True	True	False	False	False	False	False	True	False	False	False	False	False	False	False	False
3	False	False	False	True	True	False	False	False	False	False	True	False	False	False	False	False	False	False	False
4	True	False	False	True	True	False	False	False	False	True	False	False	False	False	False	False	True	True	False

Gambar 3. Hasil Format Transaksi.

3.4. Algoritma Apriori

Apriori mencari *frequent itemset* melalui iterasi berulang dimana parameter yang akan digunakan, Minimum support: 20%, dan Minimum confidence: 60%, berikut Hasil *frequent itemset* apriori sebagai berikut pada gambar 4 dibawah ini.

```

FREQUENT ITEMSET APRIORI
Jumlah itemset: 35
waktu eksekusi (detik): 0.0203
/usr/local/lib/python3.12/dist-packages/jupyter_client
return datetime.utcnow().replace(tzinfo=utc)
/usr/local/lib/python3.12/dist-packages/jupyter_client
return datetime.utcnow().replace(tzinfo=utc)
    
```

	support	itemsets
1	1.000000	(diabetes mellitus tipe 2)
2	0.707831	(dislipidemia)
10	0.707831	(dislipidemia, diabetes mellitus tipe 2)
25	0.524096	(diabetes mellitus tipe 2, dislipidemia, hyper...
4	0.524096	(hipertensi)

Gambar 4. *Frequent itemset* apriori.

Sehingga *Association Rules* Apriori dapat menghasilkan sebagai berikut dibawah ini,

	antecedents	consequents	support	confidence	lift
0	(chf ec hhd)	(diabetes mellitus tipe 2)	0.201807	1.0	1.000000
1	(chf ec hhd)	(dislipidemia)	0.201807	1.0	1.412766
2	(chf ec hhd)	(hnp lumbal)	0.201807	1.0	4.955224
3	(hnp lumbal)	(chf ec hhd)	0.201807	1.0	4.955224
4	(chf ec hhd)	(spondylosis lumbal)	0.201807	1.0	4.955224

Gambar 5. *Association Rules* Apriori.

3.5. Algoritma FP-Growth

Pada algoritma FP-Growth menggunakan *FP-tree* sehingga lebih cepat dibanding dengan menggunakan Apriori karena tidak menghasilkan kandidat secara eksplisit. Parameter sama digunakan dengan Minimum support: 20%, sehingga hasil *Frequent Itemset FP-Growth* yang ditemukan seperti pada table 4 dibawah ini.

	support	itemsets
0	1.000000	(diabetes mellitus tipe 2)
1	0.707831	(dislipidemia)
6	0.707831	(diabetes mellitus tipe 2, dislipidemia)
2	0.524096	(hipertensi)
9	0.524096	(hipertensi, diabetes mellitus tipe 2, dislipi...

Gambar 6. *Frequent Itemset* FP-Growth

Sehingga *Association Rules* FP-Growth menghasilkan sebagai berikut dibawah ini,

	antecedents	consequents	support	confidence	lift
1	(dislipidemia)	(diabetes mellitus tipe 2)	0.707831	1.0	1.000000
8	(hipertensi)	(diabetes mellitus tipe 2, dislipidemia)	0.524096	1.0	1.412766
2	(hipertensi)	(dislipidemia)	0.524096	1.0	1.412766
4	(hipertensi)	(diabetes mellitus tipe 2)	0.524096	1.0	1.000000
5	(hipertensi, diabetes mellitus tipe 2)	(dislipidemia)	0.524096	1.0	1.412766

Gambar 7. Association Rules FP-Growth

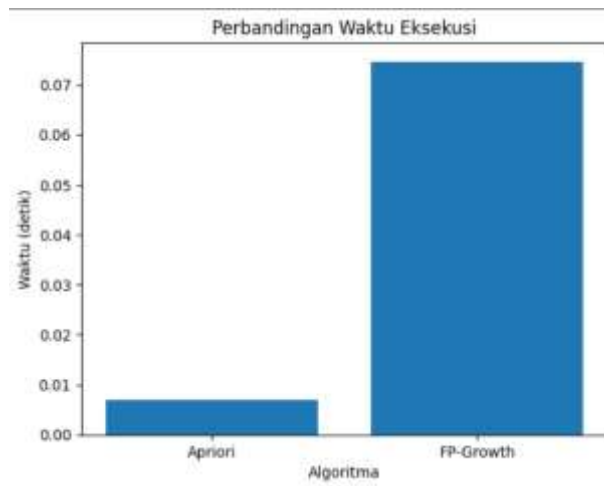
3.6. Perbandingan Hasil Apriori dan FP-Growth

Selanjutnya yaitu tahap melakukan Analisa perbandingan dari hasil perbandingan yang ada pada algoritma Apriori dan FP-Growth, dan hasil perbandingan seperti pada tabel 2 dibawah ini,

Tabel 2 Perbandingan Hasil Apriori dan FP-Growth

Aspek	Apriori	FP-Growth
Waktu komputasi	0,032974	0,082752
Jumlah frequent itemset	35	35
Aturan yang ditemukan	153 aturan	153 aturan
Pola utama	Chf ec hdd ↔ Hnp Lumbal ↔ Spondylosis Lumbal	dislipidemia-hypertensi

Berdasarkan pada tabel diatas, maka hasil pengujian yang lebih efisien yaitu menggunakan algoritma apriori dibandingkan FP-Growth, dengan waktu yang eksekusi yang lebih singkat, hal ini dapat terlihat pada Grafik dibawah ini.

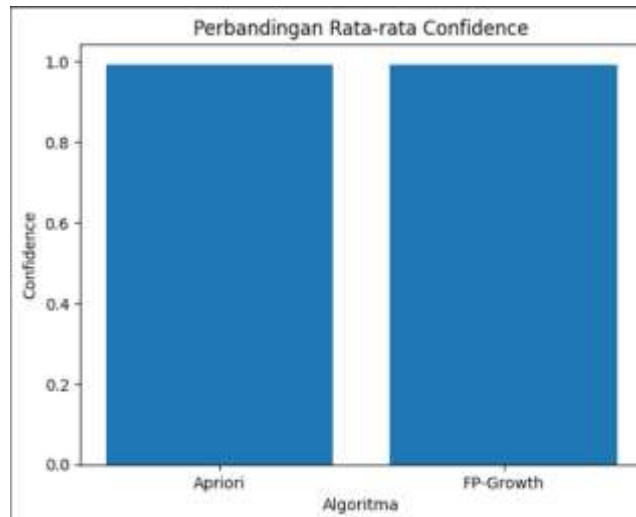


Gambar 7. Visualisasi Perbandingan Waktu.

Dengan hasil jumlah *frequent* pada itemset dan *association rule* sama, sesuai pada Gambar 8, dan Gambar 9.



Gambar 8. Visualisasi Perbandingan Jumlah Aturan Asosiasi.



Gambar 9. Visualisasi Perbandingan Rata-rata Confidence.

Hal ini menunjukkan bahwa dataset yang dimiliki berukuran relatif kecil, sehingga lebih optimal algoritma apriori, dibandingkan FP-Growth yang memiliki *overhead* pembangunan struktur FP-Tree.

3.7. Interpretasi

Berdasarkan hasil dari analisis data komorbiditas pada pasien diabetes mellitus pada penggunaan algoritma apriori dan FP-Growth, keduanya berhasil melakukan proses indentifikasi pola penyakit secara konsisten, meskipun dengan karakteristik pola yang berbeda. Hal ini menunjukkan masing-masing algoritma memiliki keunggulan dalam mengekstraksi informasi.

Hasil algoritma apriori menunjukkan pola yang bersifat spesifik dan kuat hal ini dibuktikan dengan nilai confidence sebesar 1,0 dan lift yang sangat tinggi, sehingga pola yang muncul pada kombinasi penyakit yaitu CHF EC HDD, HNP Lumbal, dan Spondylosis Lumbal. Meskipun pada pola ini memiliki nilai support yang relatif rendah, tinggi nilai lift mengindikasikan bahwasannya memiliki keterkaitan antar penyakit tersebut tidak terjadi secara acak, dan memiliki hubungan klinis yang erat. Hal ini terjadi karena adanya kelompok pasien dengan kondisi klinis yang lebih kompleks, seperti gangguan kardiovaskular dan musculoskeletal cenderung lebih muncul secara bersamaan.

Sedangkan pada hasil algoritma FP-Growth menghasilkan pola komorbiditas yang bersifat dominan dan sangat umum, hal ini dapat dibuktikan memiliki nilai support yang tinggi dan confidence yang mencapai 1,0. Pola utama yang dihasilkan yaitu Diabetes Mellitus Tipe 2, Dislipidemia, dan Hipertensi, yang merupakan kombinasi penyakit metabolic yang sering dan umum dijumpai pada populasi pasien diabetes. Dengan nilai lift yang berada dalam kategori sedang dapat menunjukkan bahwa meskipun asosiasinya tidak sekuat pola apriori, pola ini muncul secara konsisten pada Sebagian besar data dan mencerminkan kondisi klinis yang umum terjadi.

Secara menyeluruh, hasil ini mengindikasikan penyakit Diabetes Mellitus Tipe 2 merupakan penyakit inti, dimana sering disertai dengan komorbiditas lainnya, yaitu Dislipidemia, dan Hipertensi, serta komorbiditas penyakit kardiovaskular dan musculoskeletal. Temuan ini dapat menjadi dasar acuan pengambilan keputusan klinis dalam melakukan proses skrining, dan pencegahan komplikasi yang terjadi, serta perencanaan penanganan pasien lebih terarah.

4. KESIMPULAN

Algoritma apriori cenderung menampilkan pola komorbiditas yang bersifat spesifik dengan kekuatan asosiasi yang sangat tinggi meskipun frekuensi kemunculan rendah, sedangkan FP-Growth lebih menonjolkan pola penyakit yang bersifat umum dan dominan pada Sebagian besar pasien diabetes mellitus tipe. Pola yang muncul pada penyakit diabetes mellitus tipe 2 yaitu penyakit inti yang disertai dengan Dislipidemia dan Hipertensi, secara keilmuan Kesehatan mencerminkan kondisi sindrom metabolik dan dapat meningkatkan resiko komplikasi kardiovaskular. Selain itu ditemukan juga pola pola komorbiditas khusus yang mengakibatkan penyakit jantung kronis, dan gangguan musculoskeletal, yang menggambarkan suatu kelompok pasien dengan komputasi yang lebih tinggi. Dari sisi kerja dua algoritma, apriori menunjukkan lebih baik pada penelitian ini, sementara FP-Growth menghasilkan pola dan aturan yang setara, sehingga

penggunaan kedua algoritma secara bersamaan memberikan gambaran yang lebih komprehensif terhadap pola penyakit dan mendukung pengambilan keputusan klinis yang lebih terintegrasi.

DAFTAR PUSTAKA

- [1] Q. Ji, S. Chai, R. Zhang, J. Li, and Y. Zheng, "Prevalence and co-prevalence of comorbidities among Chinese adult patients with type 2 diabetes mellitus : a cross- sectional , multicenter , retrospective , observational study based on 3B study database," no. June, 2024, doi: 10.3389/fendo.2024.1362433.
- [2] L. Liu, X. Wang, M. Gui, F. Ju, L. Cao, and B. Bi, "Investigation of multimorbidity patterns and association rules in patients with type 2 diabetes mellitus using association rules mining algorithm," pp. 1-14, 2025.
- [3] J. Nas, "Penerapan Data Mining Dalam Mencari Pola Asosiasi Data Tracer Study Menggunakan Equivalence Class Transformation (ECLAT)," no. Tek. Inform. UIN Sultan Syarif Kasim Riau, 2022., 2023.
- [4] A. V. Aglarci and F. Karakurt, "Symptoms affecting the development of diabetes : analysis of risk factors with data mining," vol. 5, 2025.
- [5] P. Yani *et al.*, "Discovering Prescription Patterns in Type 2 Diabetes Based on Demographic Attributes Using Association Rules," vol. 8, no. 3, pp. 536-544, 2025.
- [6] S. Wijanarko and S. A. Santoso, "Penerapan Fungsi Mid Dan Find pada Pembersihan Data Alamat," vol. X, no. 1, pp. 14-18, 2024.
- [7] A. R. Aziz, B. Warsito, A. Prahutama, and U. Diponegoro, "Pengaruh transformasi data pada metode learning vector quantization terhadap akurasi klasifikasi diagnosis penyakit jantung 1,2,3," vol. 10, no. 2012, pp. 21-30, 2021.
- [8] I. Musdalifah and A. Jananto, "Analisis Perbandingan Algoritma Apriori Dan FP-Growth Dalam Pembentukan Pola Asosiasi Keranjang Belanja Pelanggan," 2022.
- [9] N. D. N. Eva Nurarofah, Ruli Herdiana, "PENERAPAN ASOSIASI MENGGUNAKAN ALGORITMA FP-GROWTH PADA POLA TRANSAKSI PENJUALAN DI TOKO ROTI," vol. 7, no. 1, 2023.
- [10] R. Kurniawan, Y. A. Wijaya, T. Informatika, P. Lunak, and S. Informasi, "IMPLEMENTASI ALGORITMA FP-GROWTH PADA DATA TRANSAKSI PENJUALAN SEBLAK JONTOR," vol. 8, no. 1, pp. 112-122, 2024.
- [11] I. B. M. Spss, "Analisis Data Penelitian Kesehatan : Perbandingan Hasil antara SmartPLS , R dan IBM SPSS Health Research Data Analysis : Comparison of Results between," vol. 1, no. 1, pp. 17-22, 2023.