Optimasi Data Rekam Medis Pasien Rawat Inap BPJS RSUD Tombulilato Dengan Algoritma K-Means Dan FP-Growth

Fatiya Ointu[1*], Alter Lasarudin[2], Wahyudin Hasyim[3]
[1,2,3]Prodi Sistem Informasi, Universitas Muhammadiyah Gorontalo
Jl. Prof. Dr. H. Mansoer Pateda, Desa Pentadio Timur, Kec. Telaga Biru, Kab. Gorontalo, Gorontalo 96181, Indonesia
Email: fatiyaointu@gmail.com[1*]

Abstrak - FATIYA OINTU, Optimasi Data Rekam Medis Pasien Rawat Inap BPJS RSUD Tombulilato Dengan Algoritma K-Means dan FP-Growth. Dibimbing oleh bapak Alter Lasarudin, sebagai pembimbing 1 dan bapak wahyudin Hasyim, sebagai pembimbing 2.
Pengelolaan data rekam medis, terutama dalam meningkatkan kualitas layanan rumah sakit di era digital, menjadi komponen yang semakin penting. Penelitian ini bertujuan untuk mengoptimalkan pengelolaan data rekam medis pasien rawat inap BPJS di Rumah Sakit Umum Daerah Tombulilato dengan menerapkan algoritma K-Means untuk *cluster*ing dan analisis pola asosiasi menggunakan algoritma FP-Growth. Hasil penelitian menunjukkan bahwa *Cluster* 0 terdiri dari pasien perempuan di Kelas Rawat 3, berusia dewasa (18-64 tahun), yang mengalami penyakit infeksi (dukungan 16,4% dengan kepercayaan 100%), penyakit pernapasan (dukungan 7,1% dengan kepercayaan 100%), dan komplikasi kehamilan (dukungan 11,6% dengan kepercayaan 100%). Sementara itu, *Cluster* 1 terdiri dari pasien laki-laki di Kelas Rawat 3, berusia dewasa (18-64 tahun), yang mengalami penyakit infeksi (dukungan 13,6% dengan kepercayaan 100%), penyakit pernapasan (dukungan 16,2% dengan kepercayaan 100%), dan penyakit mental (dukungan 10,3% dengan kepercayaan 100%).
Kata kunci: FP-Growth, K-Means, Rekam Medis

Abstract - *FATIYA OINTU, Utilizing K-Means and FP-Growth Algorithms to Optimize BPJS Inpatient Medical Record Data at Tombulilato Hospital. Under the supervision of Mr. Wahyudin Hasyim, supervisor 2, and Mr. Alter Lasarudin, supervisor 1.*
It is becoming increasingly crucial to manage medical record data in order to enhance the quality of hospital services in the digital era. This study aims to optimize the management of medical record data for BPJS inpatients at Tombulilato Regional General Hospital by applying the K-Means algorithm for clustering and association pattern analysis using the FP-Growth algorithm. The results showed that Cluster 0 consisted of female patients in Class 3, adults (18-64 years), who experienced infectious diseases (16.4% support with 100% confidence), respiratory diseases (7.1% support with 100% confidence), and pregnancy complications (11.6% support with 100% confidence). Cluster 1 was composed of male patients in Class 3, adults aged 18-64 years, who had been diagnosed with infectious diseases (13.6% support with 100% confidence), respiratory diseases (16.2% support with 100% confidence), and mental illness (10.3% support with 100% confidence).
Keywords: FP-Growth, Medical Records, K-Means

1. Pendahuluan

Pengelolaan data rekam medis sangat penting dalam meningkatkan mutu layanan kesehatan, terutama di era digital saat ini. Data yang terorganisir dengan baik dapat memberikan informasi berharga bagi rumah sakit dalam pengambilan keputusan. Di Rumah Sakit Umum Daerah Tombulilato, tantangan dalam mengelola dan menganalisis data rekam medis pasien rawat inap, khususnya bagi peserta BPJS, semakin kompleks. Pengelolaan yang belum optimal berdampak negatif pada kualitas pelayanan yang diberikan.

Jumlah pasien rawat inap BPJS di Rumah Sakit Umum Daerah Tombulilato mengalami peningkatan dari tahun ketahun. Rekam medis mencakup informasi penting seperti identitas pasien, hasil pemeriksaan, pengobatan, tindakan, dan pelayanan kesehatan. Namun, volume data yang terus bertambah dapat meningkatkan risiko kesalahan dalam pengambilan keputusan medis dan menyulitkan pencarian pola yang dapat meningkatkan layanan.

Kurangnya pemanfaatan teknologi dan penerapan algoritma data mining turut memperburuk kondisi ini. Hal ini menyebabkan pasien menerima pelayanan yang kurang memadai, termasuk diagnosis yang tidak tepat. Untuk mengatasi masalah ini, penelitian ini menggunakan teknik data mining yang belum banyak diterapkan di Rumah Sakit Umum Daerah Tombulilato. Dengan memanfaatkan algoritma K-Means, penelitian ini bertujuan untuk mengelompokkan data rekam medis pasien berdasarkan karakteristik serupa, yang akan membantu dalam identifikasi pola kesehatan masyarakat. Selain itu, algoritma FP-Growth akan digunakan

untuk menemukan pola asosiasi antara kondisi kesehatan yang umum dengan demografi pasien, memberikan wawasan yang lebih dalam untuk pengambilan keputusan strategis.

Dengan penggunaan kedua algoritma ini, diharapkan Rumah Sakit Umum Daerah Tombulilato dapat lebih efektif dalam mengelola data rekam medis pasien rawat inap BPJS. Penelitian ini bertujuan untuk mengembangkan model analisis yang dapat meningkatkan efisiensi layanan kesehatan dan, pada akhirnya, memperbaiki kualitas perawatan yang diberikan kepada pasien, tindakan atau pengobatan pasien. Selain itu, berfungsi sebagai informasi yang berguna bagi manajemen rumah sakit untuk menilai dan mengembangkan pelayanan kesehatan.

2. Tinjauan Pustaka

2.1. Data Rekam Medis

Data rekam medis merupakan dokumen penting yang berisi catatan tentang identitas pasien, pemeriksaan, pengobatan, dan tindakan medis. Penelitian sebelumnya menunjukkan bahwa rekam medis elektronik memungkinkan pengumpulan informasi yang lebih efisien. Namun, kelemahan dalam penerapan sistem ini sering kali terkait dengan kurangnya pelatihan bagi tenaga kesehatan[1]. Rumah sakit perlu memiliki rekam medis sebagai suatu standar pelayanan bidang kesehatan yang berguna untuk peningkatan kualitas dalam memberikan pelayanan yang optimal terhadap seluruh pasien[2].

2.2. Data Mining

Data mining digunakan untuk mengumpulkan data melalui pola pengumpulan data antara manusia dan perangkat komputer, baik secara otomatis maupun manual. Data mining sering disebut Knowledge Discovery in Database (KDD), adalah proses mengumpulkan dan menggunakan data historis untuk menemukan pola, keteraturan atau hubungan dalam kumpulan data yang sangat besar[3].

2.3. *Clustering*

Dalam analisis data, clustering adalah teknik penting untuk mengelompokkan berbagai objek ke dalam kelompok – kelompok tertentu berdasarkan karakteristik yang serupa. Objek – objek di dalam satu cluster memiliki kemiripan yang lebih besar dari pada objek – objek di dalam kelompok lain[4]. , clustering adalah teknik pengelompokkan data yang popular[5].

2.4. Algoritma K-Means

Algoritma K-Means didefinisikan sebagai metode mengumpulkan data ke dalam kelompok (K) yang telah ditentukan sebelumnya, dimana (K) adalah jumlah kelompok yang diinginkan. K-Means menghitung jarak antara titik dan pusat kelompok yang mewakili kelompok, kemudian memberikan titik data ke kelompok yang paling dekat. Hasil akhir dari K-Means adalah kelompok yang optimal, di mana titik data dalam setiap kelompok memiliki kesamaan yang tinggi dan perbedaan yang signifikan. Dalam K-Means setiap kelompok memiliki titik pusat yang dikenal sebagai centeroid[6]. Kelemahan algoritma ini terletak pada ketergantungannya pada pemilihan pusat cluster awal, yang dapat memengaruhi hasil akhir[7].

2.5. *Association Rule Mining* (ARM)

Teknik Association Rule Mining (ARM) adalah metode pemebelajaran mesin non-parametik yang paling umum untuk menemukan hubungan tersembunyi antara variabel dalam database. Association Rule Mining merupakan Metode data mining yang dikenal sebagai aturan asosiasi, digunakan untuk mengidentifikasi aturan kombinasi item. Salah satu aspek dalam analisis asosiasi yang paling menarik bagi para peneliti adalah Frequent Pattern Growth[8].

2.6. FP-Growth

FP-Growth adalah bagian dari teknik Association rule dalam data mining yang bertujuan untuk mengungkapkan aturan hubungan antara sekumpulan item dengan mempertimbangkan frekuensi data. Dalam proses pemilihan pola, algoritma FP-Growth membantu dalam pengambilan keputusan tentang proses pemebentukan frequent itemset sebelum menghasilkan aturan sebagai rekomendasi keputusan dimasa akan datang[9]. Algoritma FP-Growth ini mengadopsi prinsip divide-and-conquer dengan cara mengompersi basis data dan mengubah frequent itemset menjadi sebuah struktur pohon yang disebut Frequent Pattern Tree (FP-Tree)[10].

3. Metode Penelitian

Penelitian ini menerapkan metode kuantitatif, menggunakan algoritma K-Means untuk mengelompokkan dan FP-Growth untuk mengidentifikasi pola asosiasi dalam data rekam medis. Proses pengujian menggunakan tools RapidMiner, dimana data yang telah diproses diimpor untuk menentukan jumlah *cluster* dan hasil dari *cluster*ing dievaluasi. Selanjutnya, algoritma FP-Growth diterapkan untuk menemukan pola asosiasi dengan mempertimbangkan parameter minimum *support* dan *confidence.*

Dalam penelitian ini data yang digunakan merupakan hasil dari observasi di Rumah Sakit Umum Daerah Tombulilato, setelah melakukan observassi diarahkan untuk ke bagian rekam medik rumah sakit untuk pengambilan data. Data yang didapatkan mencakup diagnosa dan demografi pasien dengan jumlah data 2609 untuk 1 tahun. Penelitian ini menggunakan data 1 tahun yaitu pada tahun 2024. Kemudian, data ini diolah untuk

mendapatkan hasil asosiasi dari hasi *cluster* yang terbentuk, dalam hasil ini akan menunjukkan diagnosa atau penyakit bersamaan dengan demografi pasien apa yang sering muncul dalam 1 tahun pada tahun 2024 dengan *support* dan *confidence.*

Tabel 1. Dataset Rekam Medis Awal

No	Kelas_Rawat	Admission_Date	Discharge_Date	Birth_Date	Birth_Weight	Jenis_Kelamin	Discharge_Status	Icd-10	Tarif_Inacbg	Tarif_Rs	Nama_Pasien	Mrn	Umur	Sep
1	3	28/12/2023	01/01/2024	01/04/1949	0	1	1	E11.4	4077000	1668000	A	121043	74	2110R0021223V000322
2	3	30/12/2023	01/01/2024	01/04/2000	0	2	1	K30	1157000	569000	A	121597	23	2110R0021223V000343
3	3	30/12/2023	01/01/2024	01/04/1970	0	1	1	A09.9	1244300	625000	A	115894	53	2110R0021223V000340
4	3	31/12/2023	01/01/2024	19/04/1996	0	2	1	K30	1157000	564500	A	122046	27	2110R0021223V000349
5	2	30/12/2023	01/01/2024	17/09/2018	0	2	1	A90	1923500	716000	A	121730	5	2110R0021223V000339
6	3	31/12/2023	02/01/2024	14/04/1940	0	1	1	E16.2	3376900	1056500	A	110535	83	2110R0021223V000351
7	3	29/12/2023	02/01/2024	08/07/1976	0	1	1	E11.9	3376900	1360000	A	122047	47	2110R0021223V000332
8	3	30/12/2023	03/01/2024	01/12/1979	0	1	1	H81.1	1221200	1213500	A	111638	44	2110R0021223V000342
9	3	30/12/2023	03/01/2024	07/01/1972	0	2	1	J06.9	1851600	1466000	A	119088	51	2110R0021223V000341
10	2	01/01/2024	03/01/2024	03/09/2021	0	1	1	A49.9	2601500	708500	A	120729	2	2110R0020124V000002
…	…	…	…	…	…	…	…	…	…	…	…	…	…	…
…	…	…	…	…	…	…	…	…	…	…	…	…	…	…
2608	3	27/12/2024	31/12/2024	21/01/1978	0	1	1	B19.9	2906600	1811496	A	1415	46	2110R0021224V000405
2609	3	28/12/2024	25/05/1985	20/03/1974	0	2	1	A01.0	2233000	1171354	A	2397	39	2110R0021224V000417

Selanjutnya, setelah didapatkan data awal akan dilakukan *preprocessing* data pada dataset rekam medis pasien rawat inap BPJS Rumah Sakit Umum Daerah Tombulilato merupakan langkah selanjutnnya, ini dilakukan bertujuan untuk mengolah data awal menjadi data yang sederhana dan menghapus atribut yang tidak relevan atau tidak digunakan dalam penelitian. Untuk atribut yang tidak digunakan terdapat pada tabel yaitu, Admission Date, Discharge Date, Birth Date, Birth Weight, Discharge Status, Tarif Inacbg, Tarif Rs, Nama Pasien, Mrn, Sep.

Tabel 2. Hasil *Preprocessing* Data

No	Kelas Rawat	Jenis_Kelamin	Icd-10	Umur
1	3	1	E11.4	74
2	3	2	K30	23
3	3	1	A09.9	53
4	3	2	K30	27
5	2	2	A90	5
6	3	1	E16.2	83
7	3	1	E11.9	47
8	3	1	H81.1	44
9	3	2	J06.9	51
10	2	1	A49.9	2
…	…	…	…	…
…	…	…	…	…

2608	3	1	B19.9	46
2609	3	2	A01.0	39

Selanjutnnya setelah dilakukan *preprocessing* data, dilakukan *transformasi* data. Pada tahap *transformasi* data ini di lakukan dengan tekhnik Boolean. Setiap data yang terjadi pada sebuah item akan diubah menjadi data dalam sebuah tabel dalam bentuk boolean dimana tanda 1 "TRUE" menunjukkan adanya data, sedangkan tanda 0 "FALSE" menunjukkan tidak adanya data.

Tabel 3. *Transformasi* Data

Icd-10	Penyakit Infeksi	Gangguan Kardiovaskular	Penyakit Metabolik	Penyakit Mental	…	Prosedur Medis	Kelas Rawat (1)	Kelas Rawat (2)	Kelas Rawat (3)	Jenkel Laki-Laki (1)	Jenkel Perempuan (2)	Balita (0-5)	Kanak-Kanak (6-12)	Remaja (13-17)	Dewasa (18-64)	Lansia (65 Keatas)
E11.4	0	0	1	0	…	0	0	0	1	1	0	0	0	0	0	1
K30	0	0	0	0	…	0	0	0	1	0	1	0	0	0	1	0
A09.9	1	0	0	0	…	0	0	0	1	1	0	0	0	0	1	0
K30	0	0	0	0	…	0	0	0	1	0	1	0	0	0	1	0
A90	1	0	0	0	…	0	0	1	0	0	1	1	0	0	0	0
E16.2	0	0	1	0	…	0	0	0	1	1	0	0	0	0	0	1
E11.9	0	0	1	0	…	0	0	0	1	1	0	0	0	0	1	0
H81.1	0	0	0	0	…	0	0	0	1	1	0	0	0	0	1	0
J06.9	0	0	0	0	…	0	0	0	1	0	1	0	0	0	1	0
A49.9	1	0	0	0	…	0	0	1	0	1	0	1	0	0	0	0

Pada tabel *transformasi* ini terdapat 20 kategori kondisi kesehatan dan 10 kategori demografi pasien yaitu.
Kondisi kesehatan (penyakit infeksi, gangguan kardiovaskular, Penyakit Metabolik, Penyakit Mental, Penyakit Hati, Neurologis, Reaksi Alergi, Penyakit Pernafasan, Gangguan Pencernaan, Gangguan Kulit, Gangguan Darah, Penyakit Ginjal dan Saluran Kemih, Komplikasi Kehamilan, Komplikasi Pasca Persalinan, Neonatal, Cedera dan Keracunan, Gangguan Jaringan, Tumor, Trauma, Prosedur Medis).
Demografi pasien (Kelas Rawat 1, 2, 3, Jenis Kelamin Laki-Laki, Perempuan, Umur Balita, Kanak-Kanak, Remaja, Dewasa, Lansia).

4. Hasil dan Pembahasan

4.1. Pengujian Algoritma K-Means dan FP-Growth menggunakan RapidMiner

Pengujian ini bertujuan untuk menemukan hasil *cluster*ing menggunakan algoritma K-Means, kemudian hasil clutering yang terbentuk akan dianalisis dengan pola asosiasi menggunakan algoritma FP-Growth. Untuk melihat keterkaitan antara item kategori penyakit dengan demografi pasien yang sering muncul bersamaan.



Gambar 1. Proses Olah Data Algoritma K-Means dan FP-Growth

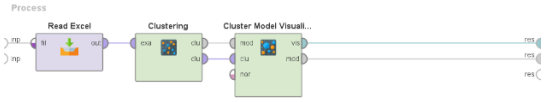
Berdasarkan gambar diatas pengolahan dataset di rapidminer sebagai berikut:

1. Memasukkan operator "*Read Excel*", operator ini digunakan untuk menginput data dari file excel yang akan diolah.
2. Memasukkan operator "K-Means", operator ini sebagai algoritma untuk *cluster*ing yang digunakan dalam penelitian. Pada operator K-Means ini dimasukkan jumlah K yang diinginkan dan jumlah Max Runs.
3. Memasukkan operator "Apply Model" operator ini digunakan untuk mengaplikasikan model *cluster*ing yang telah diperoleh sebelumnya pada dataset yang baru.
4. Memasukkan operator "Filter Examples" operator ini digunakan untuk memfilter data berdasarkan *cluster* tertentu yang akan diolah.
5. Memasukkan operator "Numerical to Binominal" operator ini digunakan untuk mengubah atribut numerik menjadi atribut binominal (dua kategori) dalam analisis asosiasi.
6. Memasukkan operator "FP-Gowth", operator ini sebagai algoritma untuk asosiasi yang digunakan dalam penelitian. Pada operator FP-Gowth ini dimasukkan minimum support.

7. Memasukkan operator “Create Association Rules” operator ini digunakan untuk menghasilkan aturan asosiasi berdasarkan hasil dari FP-Gowth. Pada operator ini dimasukkan minimum confidence.

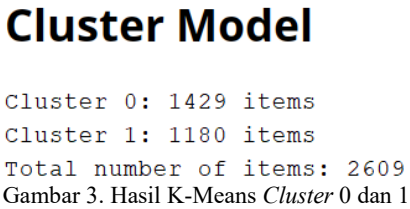
4.2. Pengujian Algoritma K-Means

Pada pengujian algoritma K-means menggunakan rapidminer, operator-operator yang digunakan adalah sebagai berikut:



Gambar 2. Pengujian Algoritma K-Means

Data yang digunakan dalam pengujian ini adalah data rekam medis yang sudah ditransformasi, kemudian dimasukkan ke “*Read Excel*”, setelah itu diolah menggunakan operator “K-Means” dalam operator ini dimasukkan jumlah K yang ingin dihasilkan. Jumlah K yang dimasukkan yaitu 2, artinya akan menghasilkan 2 *cluster*. Selanjutnya, memasukkan jumlah *Max Runs* artinya memasukkan jumlah maksimum percobaan untuk menjalankan algoritma yang berguna untuk memastikan bahwa percobaan beberapa kali dalam menemukan hasil terbaik. Jumlah *Max Runs* yang dimasukkan yaitu 3. Selanjutnya memasukkan operator “*Cluster* Model Visualizer” operator ini akan menghasilkan *cluster* model 2 *cluster* yang telah terbentuk.



Gambar 3. Hasil K-Means *Cluster* 0 dan 1



Gambar 4. Hasil *Cluster Model Visualizer Cluster* 0 dan 1

Berdasarkan kedua gambar diatas dari jumlah data rekam medis 2609 menghasilkan 2 *cluster* yaitu *cluster* 0 sebanyak 1429 item data rekam medis (*cluster* perempuan dengan komplikasi kehamilan tinggi) dan *cluster* 1 sebanyak 1180 item data rekam medis (*cluster* laki-laki dengan komplikasi kehamilan rendah).

4.3. Pengujian Algoritma FP-Growth

Selanjutnya setelah mendapatkan model hasil *cluster*ing pada pengujian algoritma K-means menggunakan rapidminer, hasil *cluster* yang terbentuk akan melanjutkan pengujian pada algoritma FP-Growth. Operator-operator yang digunakan adalah sebagai berikut:



Gambar 5. Pengujian Algoritma FP-Growth

Pada pengujian ini memasukkan operator selanjutnya setelah operator dari pengujian algoritma K-Means. Akan tetapi operator “*Cluster* Model Visualizer” dihapus guna untuk menghasilkan tabel dataset baru dari hasil *cluster*ing tidak dapat terhubung. Operator yang dimasukkan setelah mendapat hasil model *cluster*ing yaitu “*Apply Model*” operator ini digunakan untuk mengaplikasikan model *cluster*ing yang telah diperoleh sebelumnya pada dataset yang baru. Selanjutnya operator yang dimasukkan setelah mendapat hasil *cluster*ing yaitu “*Filter Examples*” operator ini digunakan untuk memfilter hasil *cluster* apa yang akan di lakukan pengujian terlebih dahulu. *cluster* 0 atau *cluster* 1. Selanjutnya dimasukkan operator “*Numerical to Binominal*” operator ini digunakan untuk mengubah atribut numerik menjadi atribut binominal (dua kategori yaitu true dan false) dalam analisis asosiasi. Selanjutnya dimasukkan operator “FP-Growth” dalam operator ini dimasukkan minimum *support* 10%, dan setelah dijalankan hasilnya akan diatur berdasarkan 3 kriteria: Min Size, Max Size dan Contains Item yaitu 4. Ini berarti hanya kombinasi item yang terdiri dari 4 item yang akan ditampilkan. Alasan pengaturan ini untuk menganalisis keterkaitan antara kondisi kesehatan dengan kelas rawat, jenis kelamin dan usia. Selanjutnya dimasukkan operator “*Create Association Rules*” dalam operator ini dimasukkan

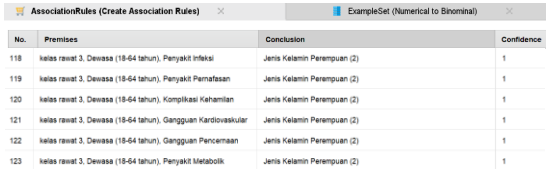
minimum *confidence* 80% dan setelah dirun akan menghasilkan aturan asosiasi berdasarkan hasil dari FP-Gowth.



Gambar 6. Hasil FP-Growth Tabel *Cluster* 0

Berdasarkan gambar hasil analisis operator "FP-Growth" *cluster* 0 maka terdapat beberapa hasil frequent itemset data rekam medis pasien rawat inap BPJS Rumah Sakit Umum Daerah Tombulilato yaitu sebagai berikut:

1. Jika pasien adalah Jenis Kelamin Perempuan di kelas rawat 3 dan berusia Dewasa (18-64 tahun), maka ada kemungkinan mereka mengalami Penyakit Infeksi dengan tingkat dukungan sebesar 0,164 atau 16,4%.
2. Jika pasien adalah Jenis Kelamin Perempuan di kelas rawat 3 dan berusia Dewasa (18-64 tahun), maka ada kemungkinan mereka mengalami Penyakit Pernafasan dengan tingkat dukungan sebesar 0,071 atau 7,1%.
3. Jika pasien adalah Jenis Kelamin Perempuan di kelas rawat 3 dan berusia Dewasa (18-64 tahun), maka ada kemungkinan mereka mengalami Komplikasi Kehamilan dengan tingkat dukungan sebesar 0,116 atau 11,6%.
4. Jika pasien adalah Jenis Kelamin Perempuan di kelas rawat 3 dan berusia Dewasa (18-64 tahun), maka ada kemungkinan mereka mengalami Gangguan Kardiovaskular dengan tingkat dukungan sebesar 0,054 atau 5,4%.
5. Jika pasien adalah Jenis Kelamin Perempuan di kelas rawat 3 dan berusia Dewasa (18-64 tahun), maka ada kemungkinan mereka mengalami Gangguan Pencernaan dengan tingkat dukungan sebesar 0,043 atau 4,3%.
6. Jika pasien adalah Jenis Kelamin Perempuan di kelas rawat 3 dan berusia Dewasa (18-64 tahun), maka ada kemungkinan mereka mengalami Penyakit Metabolik dengan tingkat dukungan sebesar 0,055 atau 5,5%.



AssociationRules (Create Association Rules) | ExampleSet (Numerical to Binominal)

No.	Premises	Conclusion	Confidence
118	kelas rawat 3, Dewasa (18-64 tahun), Penyakit Infeksi	Jenis Kelamin Perempuan (2)	1
119	kelas rawat 3, Dewasa (18-64 tahun), Penyakit Pernafasan	Jenis Kelamin Perempuan (2)	1
120	kelas rawat 3, Dewasa (18-64 tahun), Komplikasi Kehamilan	Jenis Kelamin Perempuan (2)	1
121	kelas rawat 3, Dewasa (18-64 tahun), Gangguan Kardiovaskular	Jenis Kelamin Perempuan (2)	1
122	kelas rawat 3, Dewasa (18-64 tahun), Gangguan Pencernaan	Jenis Kelamin Perempuan (2)	1
123	kelas rawat 3, Dewasa (18-64 tahun), Penyakit Metabolik	Jenis Kelamin Perempuan (2)	1

Gambar 7. Hasil *Create Association Rules* Tabel *Cluster* 0

Berdasarkan gambar hasil analisis operator "*Create Association Rules*" *cluster* 0 maka terdapat beberapa hasil pola data rekam medis pasien rawat inap BPJS Rumah Sakit Umum Daerah Tombulilato yaitu sebagai berikut:

1. Jika pasien berada di kelas rawat 3, berusia dewasa (18-64 tahun) dan mengalami penyakit infeksi maka akan berjenis kelamin perempuan (2) dengan tingkat kepercayaan 1,000 atau 100%.
2. Jika pasien berada di kelas rawat 3, berusia dewasa (18-64 tahun) dan mengalami penyakit pernafasan maka akan berjenis kelamin perempuan (2) dengan tingkat kepercayaan 1,000 atau 100%.
3. Jika pasien berada di kelas rawat 3, berusia dewasa (18-64 tahun) dan mengalami komplikasi kehamilan maka akan berjenis kelamin perempuan (2) dengan tingkat kepercayaan 1,000 atau 100%.
4. Jika pasien berada di kelas rawat 3, berusia dewasa (18-64 tahun) dan mengalami gangguan kardiovaskular maka akan berjenis kelamin perempuan (2) dengan tingkat kepercayaan 1,000 atau 100%.
5. Jika pasien berada di kelas rawat 3, berusia dewasa (18-64 tahun) dan mengalami gangguan pencernaan maka akan berjenis kelamin perempuan (2) dengan tingkat kepercayaan 1,000 atau 100%.
6. Jika pasien berada di kelas rawat 3, berusia dewasa (18-64 tahun) dan mengalami penyakit metabolik maka akan berjenis kelamin perempuan (2) dengan tingkat kepercayaan 1,000 atau 100%.



Gambar 8. Hasil FP-Growth Tabel *Cluster* 1

Berdasarkan gambar hasil analisis operator "FP-Growth" *cluster* 1 maka terdapat beberapa hasil frequent itemset data rekam medis pasien rawat inap BPJS Rumah Sakit Umum Daerah Tombulilato yaitu sebagai berikut:

1. Jika pasien adalah Jenis Kelamin Laki-Laki di kelas rawat 3 dan berusia Dewasa (18-64 tahun), maka ada kemungkinan mereka mengalami Penyakit Infeksi dengan tingkat dukungan sebesar 0,136 atau 13,6%.
2. Jika pasien adalah Jenis Kelamin Laki-Laki di kelas rawat 3 dan berusia Dewasa (18-64 tahun), maka ada kemungkinan mereka mengalami Penyakit Pernafasan dengan tingkat dukungan sebesar 0,162 atau 16,2%.

3. Jika pasien adalah Jenis Kelamin Laki-Laki di kelas rawat 3 dan berusia Dewasa (18-64 tahun), maka ada kemungkinan mereka mengalami Penyakit Mental dengan tingkat dukungan sebesar 0,103 atau 10,3%.
4. Jika pasien adalah Jenis Kelamin Laki-Laki di kelas rawat 3 dan berusia Dewasa (18-64 tahun), maka ada kemungkinan mereka mengalami Gangguan Pencernaan dengan tingkat dukungan sebesar 0,034 atau 3,4%.
5. Jika pasien adalah Jenis Kelamin Laki-Laki di kelas rawat 3 dan berusia Dewasa (18-64 tahun), maka ada kemungkinan mereka mengalami Neurologis dengan tingkat dukungan sebesar 0,021 atau 2,1%.
6. Jika pasien adalah Jenis Kelamin Laki-Laki di kelas rawat 3 dan berusia Dewasa (18-64 tahun), maka ada kemungkinan mereka mengalami Gangguan Kardiovaskular dengan tingkat dukungan sebesar 0,022 atau 2,2%.

AssociationRules (Create Association Rules)

No.	Premises	Conclusion	Confidence
109	kelas rawat 3, Dewasa (18-64 tahun), Penyakit Infeksi	Jenis Kelamin Laki-Laki (1)	1
110	kelas rawat 3, Dewasa (18-64 tahun), Penyakit Pernafasan	Jenis Kelamin Laki-Laki (1)	1
111	kelas rawat 3, Dewasa (18-64 tahun), Penyakit Mental	Jenis Kelamin Laki-Laki (1)	1
112	kelas rawat 3, Dewasa (18-64 tahun), Gangguan Pencernaan	Jenis Kelamin Laki-Laki (1)	1
113	kelas rawat 3, Dewasa (18-64 tahun), Neurologis	Jenis Kelamin Laki-Laki (1)	1
114	kelas rawat 3, Dewasa (18-64 tahun), Gangguan Kardiovaskular	Jenis Kelamin Laki-Laki (1)	1

Gambar 9. Hasil *Create Association Rules* Tabel *Cluster* 1

Berdasarkan gambar hasil analisis operator "*Create Association Rules*" *cluster* 1 maka terdapat beberapa hasil pola data rekam medis pasien rawat inap BPJS Rumah Sakit Umum Daerah Tombulilato yaitu sebagai berikut:
1. Jika pasien berada di kelas rawat 3 berusia dewasa (18-64 tahun) dan mengalami penyakit infeksi maka akan berjenis kelamin laki-laki (1) dengan tingkat kepercayaan 1,000 atau 100%.
2. Jika pasien berada di kelas rawat 3 berusia dewasa (18-64 tahun) dan mengalami penyakit pernafasan maka akan berjenis kelamin laki-laki (1) dengan tingkat kepercayaan 1,000 atau 100%.
3. Jika pasien berada di kelas rawat 3 berusia dewasa (18-64 tahun) dan mengalami penyakit mental maka akan berjenis kelamin laki-laki (1) dengan tingkat kepercayaan 1,000 atau 100%.
4. Jika pasien berada di kelas rawat 3 berusia dewasa (18-64 tahun) dan mengalami gangguan pencernaan maka akan berjenis kelamin laki-laki (1) dengan tingkat kepercayaan 1,000 atau 100%.
5. Jika pasien berada di kelas rawat 3 berusia dewasa (18-64 tahun) dan mengalami neurologis maka akan berjenis kelamin laki-laki (1) dengan tingkat kepercayaan 1,000 atau 100%.
6. Jika pasien berada di kelas rawat 3 berusia dewasa (18-64 tahun) dan mengalami gangguan kardiovaskular maka akan berjenis kelamin laki-laki (1) dengan tingkat kepercayaan 1,000 atau 100%.

5. Kesimpulan

Berdasarkan penelitian yang telah dilakukan maka, dapat diambil kesimpulannya yaitu:
1. Hasil yang didapatkan dari penelitian algoritma K-Means yaitu terbentuk 2 *cluster* dari hasil *cluster*ing. *Cluster* 0 (*cluster* perempuan dengan komplikasi kehamilan tinggi) sebanyak 1429 item dataset dan *cluster* 1 (*cluster* laki-laki dengan komplikasi kehamilan rendah) sebanyak 1180 item dataset.
2. Hasil yang didapatkan dari penelitian hasil *cluster*ing menggunakan algoritma FP-Growth untuk menemukan pola asosiasi antara kondisi kesehatan yang umum diderita dengan demografi pasien yaitu:
   1) *Cluster* 0 (jenis kelamin perempuan, berada di kelas rawat 3 dan berusia dewasa 18-64 tahun): Kemungkinan mengalami Penyakit Infeksi (dukungan 16,4% dengan kepercayaan 100%), Penyakit Pernafasan (7,1% dengan kepercayaan 100%) Komplikasi Kehamilan (dukungan 11,6% dengan kepercayaan 100%).
   2) *Cluster* 1 (jenis kelamin laki-laki, berada di kelas rawat 3 dan berusia dewasa 18-64 tahun): Kemungkinan mengalami Penyakit Infeksi (dukungan 13,6% dengan kepercayaan 100%), Penyakit Pernafasan (dukungan 16,2% dengan kepercayaan 100%), Penyakit Mental (dukungan 10,3% dengan kepercayaan 100%).

Daftar Pustaka

[1] F. Yunisca, E. Chalimah, and L. O. A. Sitanggang, "Implementasi Peraturan Menteri Kesehatan Republik Indonesia Nomor 24 Tahun 2022 Tentang Rekam Medis Terhadap Hasil Pemantauan Kesehatan Pekerja Radiasi di Kawasan Nuklir Serpong," *Reakt. Bul. Pengelolaan Reakt. Nukl.*, vol. 19, no. 2, p. 34, 2022, doi: 10.17146/bprn.2022.19.2.6700.

[2] D. Chintia and A. E. Kusumaningrum, "Peran Rekam Medis Sebagai Alat Bukti Dalam Penyelesaian Sengketa Medis Antara Dokter Dan Pasien," *J. JURISTIC*, vol. 1, no. 01, p. 8, 2020, doi: 10.35973/jrs.v1i01.1448.

[3] V. Jessfry and M. Siddik, "Penerapan Data Mining Menggunakan Algortima Apriori Dalam Membangun Sistem Persediaan Barang," *J. Inf. Syst. Informatics Eng.*, vol. 8, no. 1, pp. 187–199, 2024.

[4] M. B. Uddin and Z. Fatah, "Gudang Jurnal Multidisiplin Ilmu Penerapan Data Mining Clustering K-Means Dalam Mengelompokkan Data Penduduk Penyandang Disabilitas," vol. 2, no. November, pp. 86–94, 2024.

[5] R. Ranjawali, A. C. Talakua, and R. T. Abineno, "Clustering Stunting Pada Balita Dengan Metode K-Means Di Puskesmas Kanatang," *SATI Sustain. Agric. Technol. Innov.*, pp. 80–92, 2023, [Online]. Available: https://ojs.unkriswina.ac.id/index.php/semnas-FST/article/view/587/324

[6] R. N. Pratistha and B. Kristianto, "Implementasi Algoritma K-Means dalam Klasterisasi Kasus Stunting pada Balita di Desa Randudongkal," *J. Indones. Manaj. Inform. dan Komun.*, vol. 5, no. 2, pp. 1193–1205, 2024, doi: 10.35870/jimik.v5i2.634.

[7] Sekar Setyaningtyas, B. Indarmawan Nugroho, and Z. Arif, "Tinjauan Pustaka Sistematis: Penerapan Data Mining Teknik Clustering Algoritma K-Means," *J. Teknoif Tek. Inform. Inst. Teknol. Padang*, vol. 10, no. 2, pp. 52–61, 2022, doi: 10.21063/jtif.2022.v10.2.52-61.

[8] Nola Ritha, E. Suswaini, and W. Pebriadi, "Penerapan Association Rule Menggunakan Algoritma Apriori Pada Poliklinik Penyakit Dalam (Studi Kasus: Rumah Sakit Umum Daerah Bintan)," *J. Sains dan Inform.*, vol. 7, no. 2, pp. 222–230, 2021, doi: 10.34128/jsi.v7i2.329.

[9] A. Anggrawan, M. Mayadi, and C. Satria, "Menentukan Akurasi Tata Letak Barang dengan Menggunakan Algoritma Apriori dan Algoritma FP-Growth," *MATRIK J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 21, no. 1, pp. 125–138, 2021, doi: 10.30812/matrik.v21i1.1260.

[10] A. Nur, A. Wahid, and D. Avianto, "Penerapan Association Rule Terhadap Diagnosa Penyakit Menggunakan Algoritma Frequent Pattern Growth Application of Association Rule To Disease Diagnosis Using Frequent Pattern Growth Algorithm," *J. Ilm. NERO*, vol. 8, no. 2, pp. 123–132, 2023.