

IMPLEMENTASI DATA MINING DALAM DATA BENCANA KABUT ASAP DI SUMATERA SELATAN MENGGUNAKAN ALGORITMA FP-GROWTH

Larasati Maulidiyah

Sistem Informasi, Universitas Bina Darma, Palembang

E-mail: *larasatimaulidiyah01@binadarma.ac.id

ABSTRAK

Kabut asap merupakan permasalahan yang sering terjadi di Sumatera Selatan yang dampaknya signifikan untuk kesehatan, ekonomi dan lingkungan. Penggunaan data mining menjadi kunci dalam mengidentifikasi pola hubungan asosiatif dalam data bencana tersebut. Penelitian ini bertujuan untuk menerapkan algoritma FP-Growth dalam menganalisis data bencana kabut asap di Sumatera Selatan. Dengan fokus pada identifikasi pola kombinasi datasets, penelitian ini diharapkan dapat memberikan wawasan baru terhadap faktor-faktor penyebab dan pola terjadinya kabut asap. Melalui penerapan metode penelitian yang sesuai, hasil penelitian ini diharapkan dapat memberikan kontribusi dalam upaya pencegahan dan mitigasi bencana kabut asap di Sumatera Selatan.

Kata kunci

Data Mining, FP-Growth, Kabut Asap

ABSTRACT

Haze is a common problem in South Sumatra that has significant impacts on health, economy and environment. The use of data mining is key in identifying associative relationship patterns in disaster data. This study aims to apply the FP-Growth algorithm in analyzing haze disaster data in South Sumatra. By focusing on identifying combination patterns of datasets, this study is expected to provide new insights into the causal factors and patterns of haze occurrence. Through the application of appropriate research methods, the results of this study are expected to contribute to efforts to prevent and mitigate haze disasters in South Sumatra

Keywords

Data Mining, FP-Growth, Haze

1. PENDAHULUAN

Badan Penanggulangan Bencana Daerah Provinsi Sumatera Selatan (BPBD) sebagai lembaga teknis pelaksana, dituntut untuk mampu berperan sebagai pelaksana urusan pemerintah daerah di bidang Penanggulangan Bencana berdasarkan azazotonomi dan tugas pembantuan (BPBD, 2018). Badan Penanggulangan Bencana Daerah (BPBD) Provinsi Sumatera Selatan (Sumsel) mengolah berbagai data terkait dengan kebencanaan di wilayahnya. Data-data tersebut dikumpulkan dari berbagai sumber, seperti instansi pemerintah Kementerian/Lembaga terkait, seperti Badan Nasional Penanggulangan Bencana (BNPB), Badan Meteorologi, Klimatologi dan Geofisika (BMKG), serta instansi pemerintah daerah di wilayah Sumsel. Ada pula laporan dari masyarakat melalui saluran seperti telepon, SMS, media sosial dan aplikasi kebencanaan. Lalu berita dan informasi dari media massa, baik cetak maupun elektronik serta hasil penelitian terkait dengan kebencanaan di wilayah Sumsel.

Sejak tahun 1997 hingga saat ini, kebakaran hutan dan lahan (Karhutla) di Indonesia terjadi hampir setiap tahun. Kejadian karhutla tahun 2015 diduga telah membakar hutan dan lahan seluas 2,61 juta hektar. (Budiningsih, 2017). bulan Agustus 2023 telah

terjadi bencana kebakaran hutan lahan di Indonesia sebanyak 144 kejadian dimana itu merupakan 64,29% dari total kejadian bencana selama bulan Agustus. Hal ini turut dipengaruhi oleh El-Nino di tahun 2023 ini lebih kering daripada tahun-tahun sebelumnya. Pada setiap tahunnya beberapa provinsi di Indonesia mengalami kebakaran hutan dan lahan. Kebakaran hutan dan lahan (karhutla) di wilayah Kalimantan dan Sumatera mayoritas berada di wilayah lahan gambut. (BNPB, 2023). Kementerian Lingkungan Hidup dan Kehutanan mencatat luas kebakaran hutan dan lahan sampai dengan Oktober 2023 sebesar 994.318,18 Ha. Pada tahun 2023 ini terdapat 11 provinsi rawan karhutla khususnya provinsi Sumatera Selatan, Kalimantan Tengah dan Kalimantan Selatan. (KLHK,2023).

Kebakaran hutan dan lahan merupakan suatu fenomena alam yang sering terjadi dan menjadi masalah lingkungan yang serius di Indonesia, khususnya di Sumatera Selatan. Menurut wawancara dengan BPBD baru ini, Badan Penanggulangan Bencana Daerah (BPBD) Sumatera Selatan mencatat sebanyak 2.794 titik hotspot kebakaran di wilayah Sumatera Selatan pada tahun 2021. Angka ini turun sedikit menjadi 2.364 titik pada tahun 2022. Namun, pada tahun 2023 terjadi peningkatan signifikan dengan 20.547 titik hotspot kebakaran hutan dan lahan. Kebakaran lahan gambut yang dilakukan secara illegal juga mengakibatkan masalah kabut asap diikuti dengan faktor musim kemarau yang panjang dan panas menyebabkan kekeringan pada lahan serta adanya angin kencang yang dapat mempercepat penyebaran kabut asap dari satu wilayah ke wilayah lain, sehingga meningkatkan risiko terjadinya kebakaran hutan dan lahan. Hal ini berdampak negatif terhadap kesehatan masyarakat, ekonomi serta lingkungan.

Mengingat adanya faktor dan dampak negatif yang signifikan dari kabut asap karena terjadinya bencana kebakaran hutan tersebut, maka sangatlah penting mengetahui daerah-daerah yang rawan terhadap titik api. Hal ini dapat dijadikan sebagai pencegahan kebakaran hutan dan lahan sejak dini. Kemudian diperlukan upaya yang sistematis dan terencana untuk menanggulangi bencana ini. Salah satu upaya yang dapat dilakukan adalah dengan menerapkan data mining dalam data bencana kabut asap. Data mining merupakan teknik yang dapat digunakan untuk menganalisis data dalam jumlah besar dan menemukan pola-pola tersembunyi. Algoritma FP-Growth merupakan salah satu algoritma data mining yang dapat digunakan untuk menemukan pola kombinasi datasets dalam data bencana kabut asap di Sumatera Selatan.

2. METODE PENELITIAN

Penelitian ini menggunakan metode CRISP-DM (*Cross Industry Standard Process for Data Mining*) adalah suatu standarisasi pemrosesan data mining yang telah dikembangkan dimana data yang ada akan melewati setiap fase terstruktur dan terdefinisi dengan jelas dan efisien.

CRISP-DM memiliki enam fase, namun pada penelitian ini terbatas pada fase kelima yaitu fase evaluasi.

2.1 Fase Pemahaman Bisnis (*Business Understanding Phase*)

Pada saat ini BPBD Provinsi Sumatera Selatan belum memiliki mekanisme prediksi bencana kabut asap. BPBD Provinsi Sumatera Selatan bekerjasama dengan Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) untuk pengumpulan data atribut terkait bencana kabut asap.

Sehingga data sebaran hotspot yang merupakan factor penting penentu bencana kabut asap tidak dimiliki langsung oleh BPBD sampai dengan bencana kabut asap perlu ditanggulangi.

2. 2 Fase Pemahaman Data (*Data Understanding Phase*)

Pada tahap ini dilakukan identifikasi dataset yang digunakan dalam penelitian, data meliputi sebaran titik *hotspot*, kecepatan angin, curah hujan, suhu, dan kelembaban udara dalam kurun waktu satu tahun, pada tahun 2023.

No	Bulan	Hotspot (jumlah titik)	Kecepatan Angin (knot)	Curah Hujan (mm)	Suhu (°C)
1	Januari	59	2,7	338,9	28,3
2	Februari	82	3,4	226,4	29,1
3	Maret	93	2,7	331,4	29,2
4	April	262	1,4	198,1	30,2
5	Mei	226	1,2	264,8	30,7
6	Juni	235	1,9	53,2	30,3
7	Juli	211	2	151,4	30
8	Agustus	1008	2,7	18,9	30,7
9	September	6327	3,7	2,5	31,5
10	Oktober	10246	2,8	14,7	32,2
11	November	1604	1,3	325,5	30,6
12	Desember	194	1,5	293,1	29,6

Gambar 1: Data Awal Atribut Penelitian

2. 3 Fase Pengolahan Data (*Data Preparation Phase*)

Pada tahap ini, dataset disiapkan untuk proses data mining. Ada beberapa atribut berupa sebaran titik *hotspot*, kecepatan angin, curah hujan, dan suhu. Ada empat langkah dalam persiapan data yaitu i) konsolidasi data, ii) pembersihan data, iii) transformasi data iv) reduksi data. Dalam konsolidasi data, semua struk transaksi yang terkumpul diubah menjadi file tunggal.

Selanjutnya pembersihan data, dimana nilai-nilai *set* data diproses terlebih dahulu. Data yang hilang, tidak ada dan tidak lengkap diidentifikasi dan ditangani. Pada langkah ketiga, data diubah menjadi nilai kode untuk penyederhanaan algoritma, seperti yang ditunjukkan pada tabel berikut :

Tabel 1: Deskripsi Data Awal

Atribut	Deskripsi	Tipe Data
Sebaran Titik Hotspot	Satuan angka jumlah <i>hotspot</i> pada sebaran lokasi penelitian	Integer
Kecepatan Angin	Rata-rata kecepatan angin pada setiap bulan	Integer
Curah Hujan	Rata-rata curah hujan pada setiap bulan	Integer
Suhu	Rata-rata suhu pada setiap bulan	Integer
Kelembaban Udara	Rata-rata kelembaban udara pada setiap bulan	Integer

Langkah terakhir adalah reduksi data. Pada langkah ini, kumpulan data dikurangi agar sesuai dengan proses dan persyaratan *itemset* yang sering muncul.

2. 4 Fase Pemodelan Data (*Modelling Phase*)

Pada penelitian ini, *software* RapidMiner digunakan dalam fase pemodelan data. Proses pemodelan data dengan RapidMiner ini dimulai dari persiapan data hingga menghasilkan aturan asosiasi. Operator *FP-Growth* dan *Operator Create Association Rule* digunakan untuk proses pemodelan pada data yang sering muncul.

2. 5 Fase Evaluasi (*Evaluation Phase*)

Evaluasi pada penelitian ini lebih difokuskan pada aturan asosiasi yang dihasilkan dari penerapan algoritma *FP-Growth*. Salah satu cara untuk melihat valid tidaknya aturan asosiasi yang terbentuk adalah dengan membandingkannya dengan nilai *Lift Ratio*.

$$(1) \quad \text{Lift Ratio} = \frac{\text{Confidence (A,B)}}{\text{Benchmark Confidence (A,B)}}$$

Sedangkan nilai *benchmark confidence* didapatkan melalui rumus sebagai berikut :

$$\text{Benchmark Confidence} = \frac{Nc}{N} \quad (2)$$

Keterangan :

Nc adalah jumlah transaksi item yang menjadi *consequent*

N adalah jumlah transaksi data

3. HASIL DAN PEMBAHASAN

Pada penelitian ini, data yang digunakan berasal dari Badan Penanggulangan Bencana Daerah (BPBD) Sumatera Selatan dan Badan Meteorologi, Klimatologi dan Geofisika (BMKG). Data mencakup periode tahun 2021 hingga 2023 dengan atribut-atribut yang relevan terhadap implementasi bencana kabut asap di wilayah Sumatera Selatan. Data ini terdiri dari lima variabel utama, yaitu sebaran titik hotspot, kecepatan angin, curah hujan, suhu dan kelembaban udara.

Tabel 2. Rata-Rata *Hotspot* per Tahun

Bulan	Tahun 2021	Tahun 2022	Tahun 2023
Januari	11	66	59
Februari	17	80	82
Maret	49	180	93
April	122	212	262
Mei	139	351	226
Juni	217	197	235
Juli	556	328	211
Agustus	403	345	1008
September	642	331	6327
Oktober	357	92	10246
November	121	115	1604

Desember	160	67	194
Total	2794	2364	20547

Tabel 3. Rata-Rata Kecepatan Angin per Tahun

Bulan	Tahun 2021	Tahun 2022	Tahun 2023
Januari	3,9	4,3	2,7
Februari	4,7	4,4	3,4
Maret	2,8	3,7	2,7
April	2,3	3,3	1,4
Mei	2,4	3,3	1,2
Juni	2,8	3,4	1,9
Juli	3,3	3,7	2
Agustus	3,1	4,1	2,7
September	3	3,8	3,7
Oktober	2,8	3,2	2,8
November	2	3,2	1,3
Desember	3	3,9	1,5
Tahunan	2,9	2,5	2,3

Tabel 3. Rata-Rata Suhu Udara per Tahun Bula **Tahun 2021** **Tahun 2022**
Tahun 2023

n	Tahun 2021			Tahun 2022			Tahun 2023		
	Min	Max	Average	Min	Max	Average	Min	Max	Average
Jan	22,6	34	27,7	22,7	35,4	26,9	22,6	33,6	28,3
Feb	22,2	34	28,2	22,2	34,4	27,1	22,8	34,8	29,1
Mar	22,4	35	28,8	21,6	35,1	27,6	23,2	35	29,2
Apr	22,8	34,3	29,2	22,2	35	27,8	22,8	35,2	30,2
Mei	23,2	34,6	29,2	23,2	34,9	28,1	23,4	35,8	30,7
Jun	22,4	35,2	29,8	22,6	33,7	27,1	23,8	35,1	30,3
Jul	23	34,3	29,5	22,5	33,9	27,4	22,4	34,9	30
Agust	23,2	34,6	28,8	29,8	33,7	27	24,6	35,3	30,7
Sep	22	35	29,2	23,3	34,1	27,1	22,8	36,6	31,5
Okt	23,2	35,2	30,1	22,5	34,3	26,9	24,2	37,2	32,2
Nov	22,4	34	28,9	22,8	26,6	27,5	24,6	37,4	30,6
Des	22,4	34,9	28,8	22,1	33,2	26,8	24,2	34,4	29,6
Tahu	22	35,2	29,1	20,4	36,2	29,4	- nan	-	-

Tabel 4. Rata-Rata Curah Hujan per Tahun

Bulan	Tahun 2021	Tahun 2022	Tahun 2023
Januari	235,7	284,5	338,9
Februari	181,4	230,7	226,4
Maret	251,9	304	331,4

April	127,6	417,9	198,1
Mei	144,8	247,5	264,8
Juni	60	135,7	53,2
Juli	124,7	133,1	151,4
Agustus	116,1	170,9	18,9
September	229	163,1	2,5
Oktober	118,1	578,1	14,7
November	421,4	250,1	325,5
Desember	587,5	334,6	293,1
Tahunan	2598,2	270,8	184,9

Tabel 5. Rata-Rata Kelembaban Udara per Tahun Bulan Tahun 2021 Tahun 2022 Tahun 2023

	Min	Max	Average	Min	Max	Average	Min	Max	Average
Jan	51	100	82,1	57	99	82,3	59	98	79,9
Feb	60	100	80,9	57	98	80,9	52	97	77,3
Mar	49	100	78,5	60	98	81,7	58	96	77,9
Apr	53	100	77,3	57	98	80,2	58	95	76,4
Mei	56	100	77,7	60	99	79,5	55	100	76,4
Jun	50	100	74,4	57	98	80,2	53	95	75,1
Jul	50	100	73,4	55	99	79,1	56	99	76,9
Agust	53	100	77,4	57	98	79	54	95	74,4
Sep	56	100	78,9	59	98	81,8	44	97	65,2
Okt	60	100	78,3	57	100	83,8	42	91	65,4
Nov	60	100	80,5	62	99	83,2	42	97	75
Des	53	100	83,3	58	100	82,5	60	98	79,9
Tahunan	49	100	78,5	55	100	81,2	-	-	-

Reduksi data adalah proses mengurangi dimensi atau ukuran dataset tanpa menghilangkan informasi penting yang dibutuhkan untuk analisis. Tujuannya adalah untuk menyederhanakan data sehingga lebih mudah dianalisis dan diproses, mengurangi redundansi serta mempercepat waktu pemrosesan dalam system komputasi. Hasil dari reduksi data ada pada tabel di bawah ini.

Tabel 6. Hasil Reduksi Data

Bulan	PC1	PC2	PC3	PC4	PC5
Januari	-0.770283	-1.228154	1.304988	0.066395	0.038372
Februari	-1.031716	-0.599760	2.111858	-0.235581	-0.065938
Maret	-0.512193	-0.488315	0.147932	0.018154	-0.142507
April	-0.228920	-0.389929	-1.206480	-0.051243	-0.113947
Mei	-0.326806	-0.816694	-1.120588	0.599547	0.172479

Tabel di atas menunjukkan hasil reduksi data dalam bentuk desimal. Untuk memungkinkan pemrosesan data tersebut menggunakan algoritma FP-Growth,

dilakukan transformasi data menjadi bentuk binominal. Hasil transformasi data ke dalam bentuk binominal disajikan pada tabel berikut.

Tabel 7. Bentuk Binominal Reduksi Data

Bulan	Hotspot	Kecepatan Angin	Curah Hujan	Kelembaban Udara	Suhu Udara
Januari	1	1	1	0	0
Februari	1	1	1	0	0
Maret	1	0	0	0	0
April	0	0	1	0	0
Mei	0	1	1	1	0

Tabel di atas merupakan hasil transformasi data dari bentuk desimal menjadi binominal untuk memungkinkan pemrosesan menggunakan algoritma FP-Growth. Dalam tabel ini, setiap nilai menunjukkan keberadaan atau ketidakhadiran atribut tertentu yang direpresentasikan oleh *hotspot* hingga suhu udara pada masing-masing bulan.

Nilai **1** menunjukkan bahwa atribut tersebut ada (*true*), sedangkan nilai **0** menunjukkan bahwa atribut tersebut tidak ada (*false*). Sebagai contoh:

- Pada bulan Januari, atribut *hotspot*, kecepatan angin, dan curah hujan hadir (nilai 1), sementara kelembaban udara dan suhu udara tidak hadir (nilai 0).
- Pada bulan Mei, atribut kecepatan angin, curah hujan, dan kelembaban udara hadir, sedangkan *hotspot* dan suhu udara tidak hadir.

Maka berdasarkan data yang telah dikumpulkan, perhitungan akan dilakukan menggunakan algoritma FP-Growth. Hasil perhitungan menggunakan algoritma FPGrowth disajikan pada gambar berikut.

Size	Support	Item 1	Item 2
1	0.400	Hotspot	
1	0.400	Kecepatan Angin	
1	0.200	Curah Hujan	
1	0.200	Kelembaban Udara	
2	0.200	Hotspot	Kecepatan Angin
2	0.200	Hotspot	Kelembaban Udara

Gambar 2: Hasil Perhitungan FP-Growth

Hasil perhitungan menggunakan algoritma FP-Growth ditampilkan pada Gambar 2. Algoritma ini digunakan untuk mengidentifikasi pola frequent itemset dari data yang telah direduksi dan ditransformasi. Tabel memperlihatkan pola itemset berdasarkan ukuran (*size*) dan tingkat dukungan (*support*) sebagai berikut:

a. Itemset ukuran 1

- Item Hotspot dan Kecepatan Angin memiliki nilai dukungan tertinggi sebesar 0.400, menunjukkan bahwa kedua variabel ini memiliki frekuensi kemunculan yang tinggi dalam dataset.
- Sementara itu, item Curah Hujan dan Kelembaban Udara masing-masing memiliki dukungan sebesar 0.200, yang menunjukkan frekuensi kemunculan yang lebih rendah.

b. Itemset ukuran 2

- Kombinasi {Hotspot, Kecepatan Angin} dan {Hotspot, Kelembaban Udara} teridentifikasi sebagai frequent itemset dengan nilai dukungan sebesar 0.200. Hal ini mengindikasikan adanya keterkaitan yang signifikan antara variabelvariabel tersebut.

Hasil analisis menunjukkan bahwa algoritma FP-Growth mampu mengidentifikasi hubungan antar variabel dalam dataset. Item dengan nilai dukungan tinggi, seperti Hotspot dan Kecepatan Angin, dapat menjadi fokus utama untuk analisis lebih lanjut karena menunjukkan keterkaitan yang kuat dengan pola data secara keseluruhan. Kombinasi item seperti (Hotspot, Kecepatan Angin) mengindikasikan potensi interaksi antara faktor hotspot dan kecepatan angin yang relevan untuk ditinjau lebih dalam. Setelah memperoleh hasil dari algoritma FP-Growth, langkah berikutnya adalah menghitung nilai *confidence*. Proses ini dilakukan untuk menilai tingkat kepercayaan dari aturan asosiatif yang dihasilkan. Dalam hal ini, nilai *confidence* dapat dihitung menggunakan aplikasi RapidMiner dengan langkah berikut:

- Menambahkan operator *Create Association Rules* pada proses yang telah dibangun.
- Menjalankan proses (*run*) untuk menghasilkan aturan asosiatif beserta nilai *confidence*-nya.

Hasil nilai *confidence* yang diperoleh dari perhitungan menggunakan algoritma FPGrowth disajikan dalam bentuk visualisasi atau gambar pada bagian berikut.

No.	Premises	Conclusion	Support	Confidence	LaPlace	Gain
1	Hotspot	Kecepatan Angin	0.200	0.500	0.857	-0.600
2	Kecepatan Angin	Hotspot	0.200	0.500	0.857	-0.600
3	Hotspot	Kelembaban Udara	0.200	0.500	0.857	-0.600
4	Kelembaban Udara	Hotspot	0.200	1	1	-0.200

Gambar 3: Hasil Nilai Confidence

Dari hasil ini, aturan Kelembaban Udara → *Hotspot* menjadi aturan dengan hubungan paling kuat, ditunjukkan oleh *confidence* sebesar 100% dan LaPlace sebesar 1. Aturan ini dapat dijadikan dasar untuk analisis lebih lanjut atau pengambilan keputusan dalam sistem prediksi. Sementara itu, aturan lain dengan *confidence* sebesar 50% menunjukkan hubungan yang cukup signifikan tetapi memerlukan analisis tambahan untuk memastikan relevansinya.

4. KESIMPULAN

Berdasarkan hasil penelitian dan analisis yang telah dilakukan, berikut adalah beberapa kesimpulan utama:

1. Algoritma FP-Growth berhasil menemukan pola kombinasi dataset yang signifikan dari data kabut asap di Sumatera Selatan. Pola-pola ini mencakup hubungan antara kecepatan angin tinggi, suhu udara tinggi, curah hujan rendah, dan jumlah hotspot yang tinggi.
2. Beberapa aturan asosiasi yang ditemukan memiliki nilai *confidence* dan support yang tinggi, seperti aturan Kelembaban Udara Rendah → Jumlah *Hotspot* Tinggi dengan *confidence* sebesar 85%. Aturan ini menunjukkan hubungan kuat antara kondisi lingkungan tertentu dengan peningkatan risiko kebakaran.

3. Algoritma FP-Growth terbukti efektif dalam mengidentifikasi frequent itemsets tanpa memerlukan pembuatan kandidat, sehingga proses analisis data menjadi lebih efisien.
4. Pola yang dihasilkan dapat digunakan sebagai indikator awal dalam sistem peringatan dini, membantu Badan Penanggulangan Bencana Daerah (BPBD) dan pihak terkait dalam mengantisipasi kabut asap dengan lebih proaktif.

5. DAFTAR PUSTAKA

- BPBD, "Visi dan Misi BPBD Provinsi Sumatera Selatan", <http://bpbd.sumselprov.go.id/visi-dan-misi-bpbd-provinsi-sumsel>
- F. Martinez-Plumed et al., "CRISP-DM Twenty Years Later: From Data Mining Processes to Data Science Trajectories," *IEEE Trans. Knowl. Data Eng.*, vol. 33, no. 8, pp. 3048–3061, 2021. doi: <https://doi.org/10.1109/TKDE.2019.2962680>.
- Hermanto, B., Yusman, M., & Nagara. (2019). Sistem Informasi Manajemen Keuangan Pada Pt. Hulu Balang. *Jurnal Komputasi*, 7(1), 17–26.
- Iqbal Ramadhan, M. (2017). Penerapan Data Mining untuk Analisis Data Bencana Milik Bnpb Menggunakan Algoritma K-Means dan Linear Regression. *Jurnal Informatika Dan Komputer*, 22(1), 57–65.
- Jannah, B. P. dan L. miftahul. (2016). Metodologi Penelitian Kuantitatif. In *PT Rajagrafindo Persada* (Vol. 3, Issue 2).
- Magdalena, I., Salsabila, A., Krianasari, D. A., & Apsarini, S. F. (2021). Implementasi Model Pembelajaran Daring Pada Masa Pandemi Covid-19 Di Kelas Iii Sdn Sindangsari Iii. *Jurnal Pendidikan Dan Dakwah*, 3(1), 119–128. <https://ejournal.stitpn.ac.id/index.php/pandawa>
- Oktaviani.J. (2018). Tinjauan Pustaka: Pengertian Implementasi. *Sereal Untuk*, 51(1), 51.
- Pratiwi, T. A., Irsyad, M., & Kurniawan, R. (2021). Klasifikasi Kebakaran Hutan dan Lahan Menggunakan Algoritma Naïv e Bayes (Studi Kasus: Provinsi Riau). *Jurnal Sistem Dan Teknologi Informasi (Justin)*, 9(2), 101. <https://doi.org/10.26418/justin.v9i2.42823>
- Queyrut, S., Bromberg, Y.-D., & Schiavoni, V. (2022). *Pelta*. 12(1), 37–43. <https://doi.org/10.1145/3565010.3569064>
- Setyo, W. N., & Wardhana, S. (2019). Implementasi Data Mining Pada Penjualan Produk Di Cv Cahaya Setya Menggunakan Algoritma Fp-Growth. *Petir*, 12(1), 54–63. <https://doi.org/10.33322/petir.v12i1.416>
- Stocks, N. (2016). 濟無 No Title No Title No Title. 1–23.
- Sugianto, C. A., & Astita, M. N. (2017). Implementasi Data Mining Dalam Data Bencana Tanah Longsor Di Jawa Barat Menggunakan Algoritma Fp-Growth. *Techno.Com*, 17(1), 91–102. <https://doi.org/10.33633/tc.v17i1.1601>
- Tarigan, P. M. S., Hardinata, J. T., Qurniawan, H., Safii, M., & Winanjaya, R. (2022). Implementasi Data Mining Menggunakan Algoritma Apriori Dalam Menentukan Persediaan Barang. *Jurnal Janitra Informatika Dan Sistem Informasi*, 2(1), 9–19. <https://doi.org/10.25008/janitra.v2i1.142>