

**ANALISIS ATURAN ASOSIASI UNTUK DETEKSI DINI IDEASI BUNUH DIRI
MEDIA SOSIAL X**Aulia Aisyah Putri ¹, Moenawar ²¹ Teknik Informatika, Universitas Esa Unggul, Jakarta, Indonesia,
auliaaisyahp@gmail.com**Abstrak**

Ideasi bunuh diri merupakan salah satu indikator penting yang perlu diperhatikan dalam upaya pencegahan bunuh diri. Media sosial menjadi ruang ekspresi yang sering digunakan individu untuk mencurahkan perasaan, termasuk tanda-tanda ideasi bunuh diri. Penelitian ini bertujuan untuk menganalisis pola kata-kata yang berkaitan dengan ideasi bunuh diri melalui pendekatan aturan asosiasi menggunakan algoritma Apriori dan FP-Growth. Data dikumpulkan dari media sosial X dan diproses melalui tahapan praproses seperti pembersihan teks, tokenisasi, dan pembentukan transaksi. Hasil penelitian menunjukkan adanya pola kata-kata yang sering muncul bersamaan, seperti "ingin" → "bunuh_diri" dan "dosa" → "bunuh_diri", dengan nilai support dan confidence yang tinggi. Temuan ini diharapkan dapat menjadi acuan awal dalam membangun sistem deteksi dini ideasi bunuh diri berbasis teks media sosial.

Sejarah Artikel*Submitted: 18 April 2026**Accepted: 21 April 2026**Published: 22 April 2026***Kata Kunci**

aturan asosiasi, ideasi bunuh diri, media sosial, apriori, fp-growth

1. PENDAHULUAN

Bunuh diri adalah tindakan mengakhiri hidup sendiri yang sering kali dipengaruhi oleh berbagai faktor kompleks (Ji et al., 2021). Di Indonesia, tren bunuh diri meningkat signifikan sejak tahun 2019. Data dari Pusat Informasi Kriminal Nasional (Pusiknas) Polri mencatat 1.023 kasus bunuh diri antara Januari hingga Oktober 2024. Namun, angka sebenarnya diperkirakan jauh lebih besar karena adanya underreporting yang mencapai 300% akibat stigma sosial. Proses bunuh diri umumnya dimulai dengan ideasi bunuh diri, yaitu pikiran atau keinginan untuk mengakhiri hidup, kemudian bisa berkembang menjadi rencana bunuh diri, sehingga deteksi dini pada tahap ini menjadi krusial dan penting (Chatterjee et al., 2022).

Dalam beberapa tahun terakhir, media sosial menjadi platform yang sering digunakan untuk mengekspresikan perasaan, termasuk ideasi bunuh diri (Macrynika et al., 2021). Menurut survei *We Are Social*, salah satu media sosial yang populer di Indonesia dalam lima tahun terakhir adalah X atau yang sebelumnya dikenal sebagai twitter. Riset Indonesia Indicator (I2) mencatat 175.802.954 postingan netizen Indonesia di X sepanjang 2024. Terdapat beberapa penelitian yang telah membahas deteksi ideasi bunuh diri menggunakan data postingan media sosial, diantaranya penelitian yang dilakukan oleh (Liu et al., 2020) dengan judul "*Suicidal Ideation Cause Extraction From Social Texts*" mengidentifikasi risiko bunuh diri di twitter menggunakan metode Conditional Random Field (CRF) yang fokus pada linguistik dan perilaku pengguna. Penelitian yang dilakukan oleh (Basyouni et al., 2024) yang berjudul "*A Suicidal Ideation Detection Framework on Social Media Using Machine Learning and Genetic Algorithms*" mengusulkan deteksi ideasi bunuh diri menggunakan machine learning dan algoritma genetik untuk seleksi fitur. Namun, sebagian besar penelitian ini terbatas pada analisis linguistik dan belum menggali hubungan antar kata atau frasa dalam data teks secara mendalam.

Dalam hal ini, *Association rules mining (ARM)* dapat menjadi pendekatan yang efektif untuk mengidentifikasi pola atau hubungan tersembunyi dalam data yang merupakan salah satu teknik *unsupervised learning* (Diaz-Garcia et al., 2023). Seiring berkembangnya teknologi, ARM yang sebelumnya digunakan untuk analisis pasar mulai diterapkan pada data media sosial untuk menggali aturan asosiasi, seperti kombinasi kata atau frasa yang sering muncul bersama

dalam data teks (Koukaras et al., 2022). Penelitian ini menggunakan dua algoritma populer dalam *Association rules mining (ARM)*, yaitu Apriori dan FP-Growth. Apriori cocok untuk dataset kecil hingga menengah, sementara FP-Growth lebih efisien untuk dataset besar karena memanfaatkan struktur pohon (Hassan et al., 2023; Shawkat et al., 2022). Kedua algoritma dipilih untuk mengevaluasi kinerja berdasarkan jumlah aturan yang dihasilkan, relevansi aturan terhadap ideasi peringatan, dan efisiensi waktu komputasi.

Berdasarkan penjelasan sebelumnya dan juga masalah yang terjadi, maka penelitian ini berjudul “Analisis Aturan Asosiasi untuk Deteksi Dini Ideasi Bunuh Diri di Media Sosial X”. Hasil yang diharapkan pada penelitian ini adalah pengetahuan baru dari hubungan atau asosiasi pada pola idease bunuh diri berdasarkan data media social X yang digunakan melalui metode *association rules mining* dengan algoritma Apriori, dan FP-Growth

2. METODE PENELITIAN

2.1 Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah unggahan publik dari media sosial X yang mengandung kata kunci terkait ideasi bunuh diri, seperti, "bunuh diri", “lelah hidup”, "ingin mati", dan “apa gunanya hidup”. Penyesuaian kata kunci ini kemudian diterapkan untuk mencari data di X, di mana bahasa yang digunakan cenderung lebih informal dan ekspresif. Oleh karena itu, kata kunci yang ditemukan dari literatur tersebut disesuaikan dengan variasi yang lebih umum digunakan oleh pengguna X, seperti "bunuh diri", "capek hidup", dan "pengen mati", “mending mati aja” dan “hidup ga berguna”. Data dikumpulkan melalui teknik scraping menggunakan pustaka Python, dengan rentang waktu pengambilan data mulai dari Januari hingga Desember 2024.

2.2 Preprocessing Data

2.2.1 Cleaning Text

Cleaning data adalah proses membersihkan data pada kolom teks agar menjadi kalimat yang layak untuk dianalisis dengan menghapus elemen-elemen seperti tautan, retweet, nama pengguna, karakter baris baru, angka, tagar, tanda baca, spasi berlebih, serta mengonversi seluruh huruf pada atribut teks menjadi huruf kecil.

2.2.2 Tokenisasi

Tokenize adalah proses pemecahan suatu teks menjadi token dengan memanfaatkan spasi sebagai pemisah antara token.

2.2.3 Normalisasi

Normalisasi adalah proses melakukan normalisasi terhadap kata-kata tidak baku atau biasa disebut slang yang umum digunakan dalam percakapan di media social X.

2.2.4 Stopword Removal

Stopwords removal merupakan tahap penghapusan kata-kata umum yang sering muncul dalam teks tetapi tidak memberikan informasi yang signifikan, seperti kata sambung, kata ganti, atau partikel.

2.2.5 Stemming

Stemming merupakan proses untuk mengembalikan kata ke bentuk dasarnya untuk menyederhanakan variasi kata yang memiliki makna serupa.

2.3 Tranformasi Data

Tahap transformasi ini bertujuan untuk mempersiapkan data agar lebih sesuai untuk proses data mining (Rahmata, 2020). Data akan ditransformasi menjadi bentuk yang lebih sesuai untuk analisis dengan menggunakan one-hot encoding. Setiap kata dalam tweet akan dianggap sebagai item, dan kehadiran atau ketidakhadiran kata tersebut akan direpresentasikan dalam matriks biner. Setiap kata yang ada akan diberi label 1, sementara yang tidak ada diberi label 0. Proses ini membuat data lebih cocok untuk algoritma Apriori dan FP-Growth yang mencari pola asosiasi.

2.4 Algoritma dan Proses Analisis

2.4.1 Penentuan Nilai Support dan Confidence

Dalam tahap ini, penulis akan menggunakan metode trial and error untuk menentukan nilai minimum *support* dan minimum *confidence*. Nilai *support* akan diuji mulai dari 0.01 hingga 0.05, sementara nilai *confidence* akan diuji dari 0.4 hingga 0.6. Penentuan ambang batas ini bertujuan untuk menemukan aturan asosiasi yang relevan dan signifikan dalam dataset. Penentuan ambang batas ini bertujuan untuk menemukan aturan asosiasi yang relevan dan signifikan dalam dataset.

2.4.2 Algoritma Apriori

Penelitian ini akan menerapkan algoritma Apriori untuk mengidentifikasi asosiasi di dalam dataset. Algoritma Apriori menghasilkan kandidat itemset pada setiap iterasi, memeriksa frekuensinya terhadap dataset. Itemset yang memenuhi ambang batas dukungan dianggap sebagai itemset yang sering muncul. Berbagai nilai *support* dan *confidence* akan diuji untuk menentukan kombinasi optimal untuk dataset.

2.4.3 Algoritma FP-Growth

FP-Growth diimplementasikan sebagai alternatif yang lebih efisien untuk Apriori, terutama untuk dataset yang besar. Algoritma ini menggunakan *FP-Tree* (*Frequent Pattern Tree*) untuk mengidentifikasi frequent itemsets tanpa perlu berulang kali membuat kandidat itemsets, tidak seperti Apriori. Prosesnya dimulai dengan membangun *FP-Tree* dari dataset, mengatur data untuk menyoroti item yang paling sering muncul. Setelah *FP-Tree* dibangun, algoritma mengidentifikasi itemset yang sering muncul dengan memindai pohon untuk mencari itemset yang memenuhi kriteria dukungan. Aturan asosiasi kemudian diturunkan dari itemset yang teridentifikasi, menggunakan metrik yang sama dengan Apriori: *support*, *confidence*, dan *lift*.

2.5 Interpretasi Hasil

Pada tahap ini, aturan yang dihasilkan menggunakan algoritma FP-Growth dan Apriori akan dievaluasi untuk menghasilkan pengetahuan yang sesuai dengan kebutuhan pengguna. Pada algoritma Apriori, aturan yang dihasilkan dengan menggunakan python didasarkan pada dua parameter utama, yaitu *Support* dan *Confidence*. Sementara itu, pada algoritma FP-Growth, aturan yang dihasilkan dengan menggunakan python melibatkan tiga parameter utama, yaitu *Support*, *Confidence*, dan *Lift*, yang memiliki nilai tertinggi dibandingkan dengan yang lainnya.

2.6 Validasi Pakar

Pada penelitian ini, hasil analisis yang diperoleh akan divalidasi oleh seorang pakar psikologi yang berkompeten dalam bidangnya. Proses validasi pakar dilakukan untuk memastikan keakuratan dan relevansi temuan dalam mendeteksi indikasi ideasi bunuh diri yang tersebar di media sosial X. Pakar psikologi akan memberikan penilaian terhadap metode yang digunakan serta hasil yang diperoleh, berdasarkan pemahaman ilmiah dan pengalaman klinis dalam menangani kasus serupa. Validasi ini penting untuk memastikan bahwa aturan asosiasi yang ditemukan dapat diterapkan dengan tepat dalam konteks kesehatan mental dan tidak hanya didasarkan pada pola data semata. Kriteria pakar yang terlibat dalam validasi ini adalah psikolog yang memiliki latar belakang pendidikan minimal S2 di bidang psikologi klinis, dengan pengalaman lebih dari lima tahun dalam menangani kasus-kasus terkait gangguan mental dan krisis psikologis.

3. Hasil dan pembahasan

3.1 Pengumpulan Data

Data yang digunakan dalam penelitian ini didapatkan melalui proses web scraping postingan pada platform X. Pengumpulan data dilakukan dengan bantuan tool tweet-harvest, yaitu sebuah library berbasis Node.js yang memungkinkan pengambilan cuitan tanpa harus mendaftar ke X API secara langsung. Proses ini dilakukan di lingkungan Google Colab yang sebelumnya telah dikonfigurasi untuk menjalankan skrip yang dibutuhkan. Pada tahap pengumpulan data ini, peneliti menggunakan kata kunci “bunuh diri”, “pengen mati”, “capek hidup”, dan “hidup ga ada gunanya” pada periode postingan dari Desember 2024-Mei 2025. Data yang dikumpulkan difilter berdasarkan bahasa Indonesia (lang:id) kemudian postingan yang berhasil dikumpulkan kemudian disimpan dalam format .csv untuk proses asosiasi.

Data yang didapatkan dari proses scraping berjumlah 12.771 data postingan yang mengandung kata kunci. Namun, tidak semua data tersebut digunakan langsung dalam analisis. Peneliti melakukan proses penyaringan dan penghapusan duplikat untuk memastikan bahwa data yang digunakan relevan dengan penelitian. Data akhir yang akan digunakan untuk proses analisis asosiasi adalah sebanyak 12.374 postingan. Berikut ini merupakan bentuk data yang akan digunakan dalam penelitian:

No	Full-text
1	@oriflake Please tolong capek banget Pengen bunuh diri
2	@ohmydull Pengen mati ajaa capek banget hidup. Tp kalau mati org tua siapa yang ngurus. Berat bgt hidup astagaa
3	@NuBraveIN Gak ada yg dicintai atau yg mencintai. Capek banget hidup ini pengen hilang aja tapi belum siap mati
.	.
11000	@BTS_twt Rasanya aku pengen pergi dari dunia ini aku hanya beban mereka saja. Aku udah gk sanggup lagi. Aku udah capek. Dilihat orang hanya sebelah mata. Andaikan bunuh diri itu gk dosa udah aku lakukan dari dulu.

3.2 Pre-processing Data

3.2.1 Cleaning Text

Langkah pertama dalam pre-processing data adalah proses membersihkan dan menyelaraskan teks. Tahap ini dimulai dengan dilakukannya proses case folding, yaitu mengubah seluruh huruf dalam teks menjadi huruf kecil (lowercase) agar format penulisan lebih seragam.

Sebelum	Sesudah
@oriflake Please tolong capek banget Pengen bunuh diri	please tolong capek banget pengen bunuh diri
@ohmydull Pengen mati ajaa capek banget hidup. Tp kalau mati org tua siapa yang ngurus. Berat bgt hidup astagaa	pengen mati aja capek banget hidup tp kalau mati org tua siapa yang ngurus. berat bgt hidup astagaa
@NuBraveIN Gak ada yg dicintai atau yg mencintai. Capek banget hidup ini pengen hilang aja tapi belum siap mati	gak ada yg dicintai atau yg mencintai capek banget hidup ini pengen hilang aja tapi belum siap mati

3.2.2 Tokenisasi

Sebelum dilakukan proses tokenisasi, terlebih dahulu dilakukan penyatuan frasa penting yang memiliki makna khusus agar tidak terpisah saat pemecahan kata. Frasa “bunuh diri” yang secara semantik mengandung arti yang berbeda dibandingkan kata “bunuh” dan “diri” secara terpisah. Oleh karena itu, frasa tersebut diubah menjadi satu kesatuan dengan penghubung underscore (“_”) menjadi “bunuh_diri”. Penyatuan frasa dilakukan menggunakan bantuan fungsi re.sub() dari pustaka RegEx (Regular Expression) pada Python. Fungsi ini mencari frasa “bunuh diri” secara utuh menggunakan boundary \b agar hanya mencocokkan kata yang berdiri sendiri, kemudian menggantikannya menjadi “bunuh_diri. Selain itu kalimat “tidak berguna” juga akan diganti menjadi tidak_berguna. Tahap selanjutnya setelah penggabungan frasa penting adalah tokenisasi yaitu proses pemecahan suatu teks menjadi token dengan memanfaatkan spasi sebagai pemisah antara token.

Sebelum	Sesudah
please tolong capek banget pengen bunuh diri	['please', 'tolong', 'capek', 'banget', 'pengen', 'bunuh_diri']
pengen mati aja capek banget hidup tp kalau mati org tua siapa yang ngurus. berat bgt hidup astagaa	['pengen', 'mati', 'aja', 'capek', 'banget', 'hidup', 'tp', 'kalau', 'mati', 'org', 'tua', 'siapa', 'yang', 'ngurus', 'berat', 'bgt', 'hidup', 'astagaa']
gak ada yg dicintai atau yg mencintai capek banget hidup ini pengen hilang aja tapi belum siap mati	['gak', 'ada', 'yg', 'dicintai', 'atau', 'yg', 'mencintai', 'capek', 'banget', 'hidup', 'ini', 'pengen', 'hilang', 'aja', 'tapi', 'belum', 'siap', 'mati']

3.2.1 Normalisasi Slang

Tahapan selanjutnya setelah mengubah teks menjadi token adalah melakukan normalisasi terhadap kata-kata tidak baku atau biasa disebut slang yang umum digunakan dalam percakapan di media social X.

Sebelum	Sesudah
['please', 'tolong', 'capek', 'banget', 'pengen', 'bunuh_diri']	['please', 'tolong', 'capek', 'banget', 'ingin', 'bunuh_diri']
['pengen', 'mati', 'aja', 'capek', 'banget', 'hidup', 'tp', 'kalau', 'mati', 'org', 'tua', 'siapa', 'yang', 'ngurus', 'berat', 'bgt', 'hidup', 'astaga']	['ingin', 'mati', 'saja', 'capek', 'banget', 'hidup', 'tapi', 'kalau', 'mati', 'orang', 'tua', 'siapa', 'yang', 'mengurus', 'berat', 'banget', 'hidup', 'astaga']
['gak', 'ada', 'yg', 'dicintai', 'atau', 'yg', 'mencintai', 'capek', 'banget', 'hidup', 'ini', 'pengen', 'hilang', 'aja', 'tapi', 'belum', 'siap', 'mati']	['tidak', 'ada', 'yang', 'dicintai', 'atau', 'yang', 'mencintai', 'capek', 'banget', 'hidup', 'ini', 'ingin', 'hilang', 'saja', 'tapi', 'belum', 'siap', 'mati']

dan visualisasi wordcloud menunjukkan bahwa kata-kata seperti *bunuh_diri*, *capek*, *ingin*, *hidup*, *mati*, *sakit*, dan *takut* merupakan kata-kata yang paling dominan muncul dalam korpus data. Kemunculan kata *bunuh_diri* dan *mati* secara eksplisit mencerminkan adanya active suicidal ideation, yaitu keinginan sadar dan nyata untuk mengakhiri hidup. Sementara kata-kata seperti *capek*, *sakit*, dan *takut* mencerminkan psychological pain dan hopelessness yang sangat relevan dengan tahap pertama dalam Three-Step Theory (3ST), yaitu bahwa ideasi bunuh diri muncul dari kombinasi rasa sakit psikologis yang mendalam dan keputusan (Klonsky & May, 2015).

Lebih jauh lagi, frekuensi tinggi dari kata *ingin*, *hidup*, dan *pikir* menunjukkan adanya konflik batin dan refleksi eksistensial, yang mencerminkan thwarted belongingness atau ketidakbermaknaan hidup, sebagaimana dijelaskan dalam Interpersonal Psychological Theory of Suicide (IPTS) yang dikembangkan oleh Thomas E. Joiner (Hadzic et al., 2020). Kata *dosa* juga muncul dalam konteks yang mengarah pada konflik moral internal, baik sebagai bentuk rasa bersalah maupun hambatan religius terhadap tindakan bunuh diri. Hal ini menunjukkan bahwa individu dalam dataset tidak hanya mengalami tekanan emosional, tetapi juga merasa menjadi beban (*perceived burdensomeness*) dan *terputus dari keterikatan social* yang mana merupakan dua komponen inti dari IPTS (Hadzic et al., 2020).

Kesesuaian antara kata-kata yang dominan di hasil wordcloud dan komponen teoritis dari IPTS dan 3ST menunjukkan bahwa ideasi bunuh diri yang diekspresikan dalam platform X (Twitter) tidak bersifat acak atau ringan, melainkan mengikuti pola psikologis yang telah dijelaskan oleh teori ilmiah. Temuan ini memperkuat asumsi bahwa media sosial dapat menjadi tempat yang merepresentasikan kondisi psikologis serius, termasuk tahapan ideasi bunuh diri yang sebenarnya, mulai dari rasa lelah mental, kehilangan makna hidup, hingga keinginan eksplisit untuk mati.

3.4 Penerapan Algoritma

3.4.1 Penentuan Support dan Confidence

Pada tahap awal analisis asosiasi digunakan algoritma Apriori untuk mengekstraksi frequent itemsets dari data teks yang telah ditransformasikan menjadi matriks biner. Sebelum menjalankan algoritma secara penuh, dilakukan eksperimen terhadap berbagai nilai minimum *support* untuk menentukan ambang batas yang optimal dalam konteks data. Pada tahap eksperimen, dilakukan pengujian terhadap kombinasi nilai minimum *support* dan minimum *confidence* untuk mengetahui pengaruhnya terhadap jumlah aturan asosiasi yang dihasilkan oleh algoritma Apriori. Nilai *confidence* yang digunakan bervariasi pada awal dimulai dari 0.3 sampai 0.8 untuk mendapatkan aturan yang bagus.

Minimum Support	Minimum Confidence					
	0,3	0,4	0,5	0,6	0,7	0,8
0,01	391	286	196	129	75	33
0,02	131	90	64	39	21	11
0,03	62	48	35	19	10	7
0,04	46	35	25	16	9	6
0,05	37	27	19	13	6	4
0,06	35	24	17	11	5	3
0,07	31	21	14	9	3	1
0,08	24	18	12	7	2	1
0,09	24	18	12	7	2	1
0,1	20	16	11	6	2	1

Hasil pengujian pada Tabel 4-9 menunjukkan bahwa semakin tinggi nilai minimum *support* maka jumlah aturan yang terbentuk semakin sedikit. Ketika *min_support* ditetapkan rendah, terbentuk association rules sebanyak 391 namun cenderung bersifat umum dan mengandung banyak noise. Sebaliknya, ketika *min_support* dinaikkan secara bertahap dan *min_confidence* distabilkan pada 0.6, jumlah aturan semakin menyempit, dari 17 aturan pada *support* 0.04 hingga hanya 4 aturan pada *support* 0.12. Berdasarkan pertimbangan tersebut, dipilih kombinasi *min_support* = 0.04 dan *min_confidence* = 0.6 sebagai parameter optimal karena menghasilkan jumlah aturan yang cukup dengan kualitas pola yang lebih spesifik, relevan, dan minim duplikasi. Kombinasi ini dianggap seimbang antara kuantitas dan kualitas aturan, sesuai dengan tujuan analisis ideasi bunuh diri yang membutuhkan pola yang bermakna secara semantik maupun psikologis.

3.4.2 Algoritma Apriori

Algoritma apriori digunakan untuk menemukan pola asosiasi antara kata-kata yang sering muncul secara bersamaan dalam tweet yang berkaitan dengan ideasi bunuh diri. Gambar 4- 12 menjelaskan proses pembentukan aturan dari hasil kombinasi kata-kata yang sering muncul bersama dalam tweet yang berkaitan dengan ideasi bunuh diri. Tahap pertama dalam membangun algoritma apriori adalah dengan mencari kombinasi untuk 1-itemset yang kemudian dihitung masing-masing nilai *support*-nya. Kombinasi 1-itemset yang dipilih adalah yang memenuhi nilai *support* 0.04. Hasil kombinasi 1-itemset yang memenuhi nilai *support* minimum dapat dilihat dalam Tabel 4- 10 di bawah ini:

Tabel 4- 1 Kombinasi 1-itemset Algoritma Apriori

Nama Itemset	Banyak Transaksi	Support
bunuh_diri	7675	0.620252
capek	4723	0.381687
ingin	4542	0.36706
hidup	4312	0.348473
mati	3841	0.310409
banget	2960	0.239211
dosa	871	0.07047
tidak_berguna	809	0.065460
pikir	766	0.061904
takut	737	0.05956
sakit	717	0.057944
sendiri	671	0.054227
dunia	575	0.046468
diri	532	0.042993
allah	515	0.04162
menang	500	0.040407

Selanjutnya merupakan pencarian kombinasi untuk 2-itemset berdasarkan data kombinasi 1-itemset yang telah didapatkan sebelumnya kemudian dihitung masing masing nilai *support*-nya. Hasil kombinasi 2-itemset yang memenuhi nilai *support* minimum dapat dilihat dalam Tabel 4- 11 di bawah ini:

Tabel 4- 2 Kombinasi 2-itemset Algoritma Apriori

Nama Itemset	Banyak Transaksi	Support
bunuh_diri, banget	1512	0.122192
banget, capek	2073	0.167529

hidup, banget	1539	0.124374
ingin, banget	952	0.077016
mati, banget	638	0.05156
bunuh_diri, capek	2613	0.211169
dosa, bunuh_diri	818	0.066187
hidup, bunuh_diri	1399	0.11306
ingin, bunuh_diri	3126	0.252626
bunuh_diri, mati	1878	0.151851
bunuh_diri, pikir	636	0.051398
sakit, bunuh_diri	618	0.049943
takut, bunuh_diri	604	0.048812
hidup, capek	2622	0.211896
ingin, capek	1155	0.093341
mati, capek	719	0.058106
ingin, hidup	913	0.073784
hidup, mati	878	0.070955
hidup, tidak_berguna	766	0.061904
ingin, mati	2418	0.19541

Tahap selanjutnya yaitu mencari kombinasi untuk 3-itemset berdasarkan data kombinasi 2-itemset yang telah didapatkan. Hasil kombinasi 3-itemset yang memenuhi nilai *support* minimum dapat dilihat dalam Tabel 4- 12 di bawah ini:

Tabel 4- 3 Kombinasi 3-itemset Algoritma Apriori

Nama Itemset	Banyak Transaksi	<i>Support</i>
bunuh_diri, banget, capek	922	0.074511
ingin, bunuh_diri, banget	661	0.053418
hidup, banget, capek	1300	0.105059
ingin, banget, capek	500	0.040407
hidup, bunuh_diri, capek	766	0.061904
ingin, bunuh_diri, capek	889	0.071925
bunuh_diri, mati, capek	506	0.040892
hidup, bunuh_diri, ingin	617	0.049863
hidup, bunuh_diri, mati	507	0.041054
ingin, bunuh_diri, mati	1198	0.096816

Setelah mendapatkan kombinasi 3-itemset, apriori tidak dapat lagi melakukan iterasi pencarian sehingga kombinasi 4-itemset tidak ditemukan. Oleh karena lanjut ke proses selanjutnya yaitu proses pembentukan rule dari masing-masing kombinasi yang sudah didapatkan menggunakan fungsi *association_rules()*.

Tabel 4- 4 Hasil Rules Algoritma Apriori

No	Antecedents	Consequents	<i>Support</i>	<i>Confidence</i>
1	(banget)	(capek)	0.1675	0.7003
2	(dosa)	(bunuh_diri)	0.0661	0.9392
3	(ingin)	(bunuh_diri)	0.2526	0.6882
4	(pikir)	(bunuh_diri)	0.0513	0.8302

5	(sakit)	(bunuh_diri)	0.0499	0.8619
6	(takut)	(bunuh_diri)	0.0488	0.8195
7	(hidup)	(capek)	0.2119	0.6081
8	(tidak_berguna)	(hidup)	0.0619	0.9457
9	(mati)	(ingin)	0.1954	0.6295
10	(bunuh_diri, banget)	(capek)	0.0745	0.6098
11	(ingin, banget)	(bunuh_diri)	0.0534	0.6936
12	(hidup, banget)	(capek)	0.1051	0.8447
13	(banget, capek)	(hidup)	0.1051	0.6271
14	(ingin, capek)	(bunuh_diri)	0.0719	0.7706
15	(mati, capek)	(bunuh_diri)	0.0409	0.7038
16	(ingin, hidup)	(bunuh_diri)	0.0499	0.6758
17	(bunuh_diri, mati)	(ingin)	0.0968	0.6376

Aturan-aturan yang dihasilkan oleh apriori berisi pasangan kata (antecedents dan consequents), serta nilai *support*, *confidence*, dan *lift* sebagai metrik evaluasi kekuatan asosiasi antar kata.

3.4.3 Algoritma FP-Growth

Selain menggunakan algoritma Apriori, penelitian ini juga menggunakan algoritma FP-Growth sebagai metode pembandingan untuk menemukan pola asosiasi antar kata. FP-Growth dipilih karena keunggulannya dalam efisiensi komputasi, terutama pada data dengan ukuran besar. Berbeda dengan Apriori yang membangkitkan kandidat itemset secara eksplisit, FP-Growth membangun struktur pohon yang disebut FP-Tree untuk mengekstraksi pola langsung dari data, sehingga dapat mengurangi waktu proses secara signifikan.

Data masukan yang digunakan untuk FP-Growth sama dengan yang digunakan pada Apriori. Algoritma ini juga dijalankan dengan parameter minimum *support* sebesar 0,04 dan minimum *confidence* sebesar 0,6, agar hasilnya dapat dibandingkan secara adil dengan Apriori.

```
import pandas as pd
from mlxtend.preprocessing import TransactionEncoder
from mlxtend.frequent_patterns import fpgrowth, association_rules

# Jalankan FP-Growth
frequent_itemsets_fpgrowth = fpgrowth(df_encoded, min_support=0.05, use_colnames=True)

rules_fpgrowth = association_rules(frequent_itemsets_fpgrowth, metric="confidence", min_threshold=0.6)

print(rules_fpgrowth[['antecedents', 'consequents', 'support', 'confidence', 'lift']])
```

Gambar 4- 1 Proses Association rules mining FP-Growth

Gambar 4-14 menjelaskan proses penerapan algoritma FP-Growth menggunakan library Machine Learning Extensions (mlxtend). Dalam penelitian ini, fungsi `fpgrowth()` digunakan untuk secara otomatis mencari frequent itemset yang memenuhi ambang minimum *support* sebesar 0,04. Fungsi ini bekerja dengan menerima data dalam bentuk one-hot encoded, lalu secara internal menerapkan langkah-langkah utama FP-Growth, seperti pembentukan struktur FP-Tree, Conditional Pattern Base (CPB), dan Conditional FP-Tree sesuai dengan algoritma asli yang dikembangkan oleh Han et al. (2000). Meskipun proses internalnya tidak terlihat secara eksplisit oleh pengguna, seluruh mekanisme tersebut tetap dijalankan di latar belakang. Dengan demikian, penerapan FP-Growth melalui mlxtend tetap sesuai dengan kaidah algoritmiknya namun jauh lebih praktis secara implementasi.

Dari hasil pemrosesan dengan fungsi fpgrowth() diperoleh sejumlah kata yang sering muncul bersamaan dalam cuitan, sebagaimana ditampilkan pada Tabel 4-15 berikut:

Tabel 4- 5 Pengurutan item berdasarkan frekuensi dan min support 0.04

Nama Itemset	Banyak Transaksi	Support
bunuh_diri	7675	0.620252
capek	4723	0.381687
ingin	4542	0.36706
hidup	4312	0.348473
mati	3841	0.310409
banget	2960	0.239211
dosa	871	0.07047
tidak_berguna	809	0.065460
pikir	766	0.061904
takut	737	0.05956
sakit	717	0.057944
sendiri	671	0.054227
dunia	575	0.046468
diri	532	0.042993
allah	515	0.04162
menang	500	0.040407

Selanjutnya pada dataset awal di kolom produk, item nya diurutkan berdasarkan frekuensi priority atau frekuensi tertinggi yang sudah didapatkan. Hasil dari dataset yang sudah diurutkan dapat dilihat pada Tabel 4-15 berikut ini.

Tabel 4- 6 Contoh Hasil pengurutan transaksi berdasarkan frekuensi

Id Transaksi	Tweet
T000001	['bunuh_diri', 'ingin', 'sendiri', 'makan', 'marah', 'marah', 'emosi', 'alias', 'perlahan', 'dibiarin', 'ego', 'bendung', 'inisiatif']
T000002	['hidup', 'tidak_berguna', 'bilang', 'hati', 'otak', 'denial', 'kontribusi', 'bil']
T000003	['bunuh_diri', 'capek', 'hidup', 'mati', 'mati', 'mati', 'mati', 'kerja', 'gitu', 'keluarga', 'susah', 'isi', 'otak', 'mana', 'ayo', 'ayo', 'ayo', 'jaga', 'jaga', 'utuh', 'perfect', 'imbang', 'partner', 'sosialisasi']
⋮	⋮
T12327	['bunuh_diri', 'capek', 'ingin', 'hidup', 'dunia', 'allah', 'enak', 'pergi', 'kota', 'dahh']

Setelah himpunan frequent itemset diperoleh, tahap selanjutnya adalah menghasilkan aturan asosiasi dengan menetapkan nilai minimum *confidence* dengan menggunakan *association_rules()*. Dalam penelitian ini, digunakan nilai minimum *confidence* sebesar 0.6 untuk memastikan kekuatan hubungan antar item. Berdasarkan hasil tersebut, diperoleh sejumlah aturan asosiasi yang ditunjukkan pada Tabel 4-16 berikut ini:

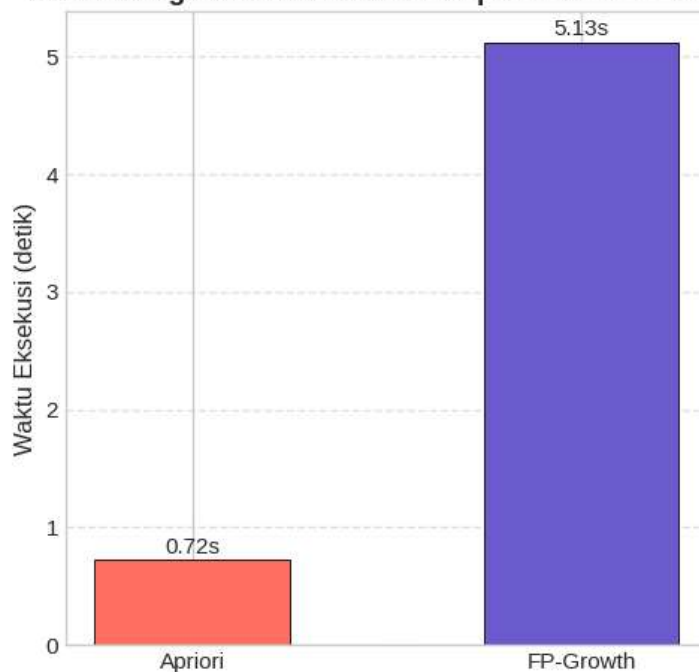
Tabel 4- 7 Hasil Analisis Asosiasi Algoritma Fp-Growth

No	Antecedents	Consequents	Support	Confidence
1	(banget)	(capek)	0.1675	0.7003
2	(dosa)	(bunuh_diri)	0.0661	0.9392
3	(ingin)	(bunuh_diri)	0.2526	0.6882
4	(pikir)	(bunuh_diri)	0.0513	0.8302
5	(sakit)	(bunuh_diri)	0.0499	0.8619
6	(takut)	(bunuh_diri)	0.0488	0.8195
7	(hidup)	(capek)	0.2119	0.6081
8	(tidak_berguna)	(hidup)	0.0619	0.9457
9	(mati)	(ingin)	0.1954	0.6295
10	(bunuh_diri, banget)	(capek)	0.0745	0.6098
11	(ingin, banget)	(bunuh_diri)	0.0534	0.6936
12	(hidup, banget)	(capek)	0.1051	0.8447
13	(banget, capek)	(hidup)	0.1051	0.6271
14	(ingin, capek)	(bunuh_diri)	0.0719	0.7706
15	(mati, capek)	(bunuh_diri)	0.0409	0.7038
16	(ingin, hidup)	(bunuh_diri)	0.0499	0.6758
17	(bunuh_diri, mati)	(ingin)	0.0968	0.6376

3.4.4 Evaluasi Model

Evaluasi performa dilakukan untuk membandingkan efisiensi waktu eksekusi antara algoritma Apriori dan FP-Growth. Meskipun dalam berbagai literatur FP-Growth sering dianggap lebih efisien karena menggunakan struktur pohon (FP-Tree) dalam membentuk frequent itemsets tanpa membangkitkan semua kandidat, hasil penelitian ini justru menunjukkan sebaliknya. Gambar 4.14 berikut menampilkan hasil perbandingan waktu eksekusi kedua algoritma saat diterapkan pada dataset yang sama dengan parameter minimum *support* 0.04 dan minimum *confidence* 0.6.

Perbandingan Waktu Eksekusi Apriori vs FP-Growth



Gambar 4- 2 Perbandingan Waktu Eksekusi Apriori vs FP-Growth

Seperti terlihat pada Gambar 4.14, Apriori menyelesaikan prosesnya dalam waktu sekitar 0.72 detik, sementara FP-Growth membutuhkan waktu sekitar 5.13 detik. Perbedaan signifikan ini diduga terjadi karena ukuran dataset yang digunakan tidak terlalu besar, serta jumlah item dalam tiap transaksi tidak banyak, sehingga proses pembangunan struktur FP-Tree justru memerlukan waktu lebih lama daripada pendekatan enumerasi sederhana milik Apriori. Dengan demikian, hasil ini menunjukkan bahwa pemilihan algoritma tidak hanya berdasarkan teori, tetapi juga harus disesuaikan dengan karakteristik dataset yang digunakan. Dalam kasus ini, Apriori lebih efisien dan memberikan hasil yang identik dengan FP-Growth dari segi aturan asosiasi, sehingga lebih disarankan untuk data dengan ukuran kecil hingga menengah.

3.5 Interpretasi Hasil

Dalam penelitian ini menggunakan dua algoritma *association rules mining* untuk menemukan pola hubungan antar kata dalam tweet yang mengandung ideasi bunuh diri. Dengan menggunakan parameter minimum *support* sebesar 0.04 dan minimum *confidence* sebesar 0.6, kedua algoritma menghasilkan aturan asosiasi yang identik mulai dari jumlah aturan yang

Tabel 4.10 menampilkan cuplikan dari aturan asosiasi terpilih berdasarkan nilai *lift* tertinggi. Aturan-aturan ini menunjukkan relasi kuat antar kata seperti “bunuh diri” → “capek” dan “banget, hidup” → “capek”, yang muncul secara konsisten baik pada hasil Apriori maupun FP-Growth.

Tabel 4- 8 Hasil Asosiasi Ideasi Bunuh Diri (*support, confidence, dan lift*)

No	Antecedents	Consequents	Support	Confidence	Lift
1	(banget)	(capek)	0.1675	0.7003	1.8348
2	(dosa)	(bunuh_diri)	0.0661	0.9392	1.5143
3	(ingin)	(bunuh_diri)	0.2526	0.6882	1.1096
4	(pikir)	(bunuh_diri)	0.0513	0.8302	1.3386
5	(sakit)	(bunuh_diri)	0.0499	0.8619	1.3896
6	(takut)	(bunuh_diri)	0.0488	0.8195	1.3213
7	(hidup)	(capek)	0.2119	0.6081	1.5931
8	(tidak_berguna)	(hidup)	0.0619	0.9457	2.7138
9	(mati)	(ingin)	0.1954	0.6295	1.715
10	(bunuh_diri, banget)	(capek)	0.0745	0.6098	1.5976
11	(ingin, banget)	(bunuh_diri)	0.0534	0.6936	1.1182
12	(hidup, banget)	(capek)	0.1051	0.8447	2.2131
13	(banget, capek)	(hidup)	0.1051	0.6271	1.7996
14	(ingin, capek)	(bunuh_diri)	0.0719	0.7706	1.2423
15	(mati, capek)	(bunuh_diri)	0.0409	0.7038	1.1346
16	(ingin, hidup)	(bunuh_diri)	0.0499	0.6758	1.0895
17	(bunuh_diri, mati)	(ingin)	0.0968	0.6376	1.737

Berdasarkan hasil penerapan algoritma Apriori dan FP-Growth terhadap data yang telah melalui proses pre-processing, ditemukan sejumlah asosiasi kata atau frasa yang menunjukkan hubungan kuat antar konsep dalam percakapan atau ungkapan ideasi bunuh diri. Aturan-aturan asosiasi yang terbentuk menggambarkan kecenderungan kata-kata tertentu untuk muncul bersama dalam satu konteks yang sama, yang dapat diinterpretasikan sebagai pola pikir atau emosi tertentu yang sering dialami oleh individu.

Salah satu asosiasi terkuat ditunjukkan oleh aturan (tidak_berguna) → (hidup) dengan nilai *confidence* sebesar 0.9457 dan *lift* sebesar 2.7138. Aturan ini menunjukkan bahwa dalam banyak kasus ketika seseorang menyebut dirinya merasa “tidak berguna”, hampir dapat dipastikan bahwa kata “hidup” juga ikut muncul dalam konteks yang sama. *Lift* yang tinggi

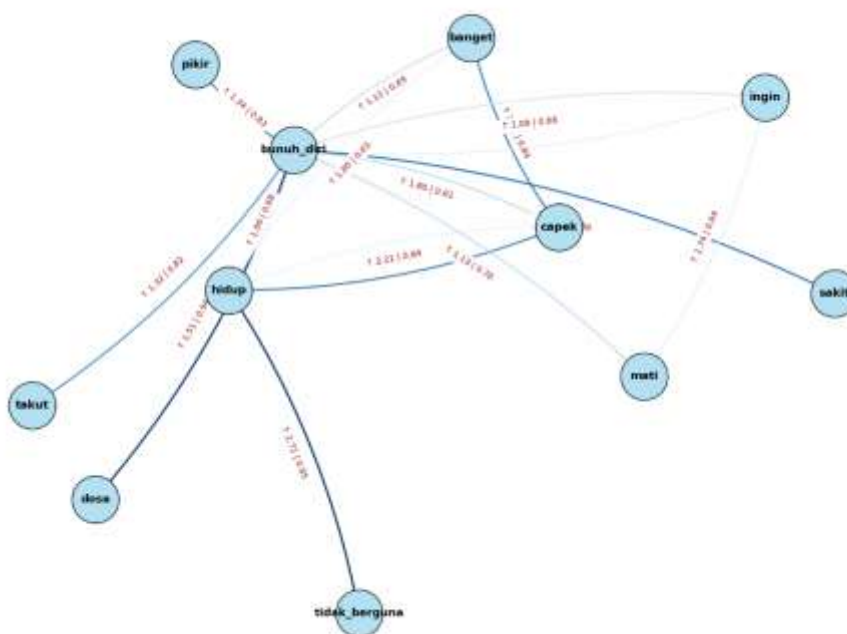
menunjukkan bahwa hubungan ini jauh lebih kuat dibandingkan dengan kemunculan kata “hidup” secara acak. Hubungan ini juga memperkuat indikasi adanya beban eksistensial dan krisis nilai diri yang dialami individu.

Selanjutnya, frasa (dosa) → (bunuh_diri) memiliki *confidence* yang sangat tinggi sebesar 0.9392 dengan *lift* sebesar 1.5143, yang menunjukkan adanya kaitan kuat antara persepsi “dosa” dan konsep “bunuh diri”. Hal ini merepresentasikan konflik batin atau nilai-nilai keagamaan yang muncul saat seseorang memiliki ideasi untuk mengakhiri hidup. Asosiasi yang serupa juga muncul pada aturan (sakit) → (bunuh_diri) dan (takut) → (bunuh_diri) yang masing-masing memiliki *confidence* sebesar 0.8619 dan 0.8195. Keduanya menunjukkan bahwa perasaan sakit, baik secara fisik maupun emosional, serta rasa takut, cenderung menyertai keinginan untuk mengakhiri hidup.

Selain itu, terdapat asosiasi (banget) → (capek) dengan *confidence* 0.7003 dan *lift* 1.8348 yang mengindikasikan bahwa kata “banget” sering digunakan untuk menekankan intensitas kelelahan atau keputusasaan yang dirasakan. Ini diperkuat lagi oleh asosiasi (hidup) → (capek) dengan *confidence* 0.6081 dan *lift* 1.5931, serta (hidup, banget) → (capek) dengan *confidence* 0.8447 dan *lift* 2.2131. Kombinasi tersebut menunjukkan bahwa kehidupan yang sangat berat atau melelahkan menjadi tema utama dalam percakapan.

Aturan lain seperti (ingin) → (bunuh_diri), (pikir) → (bunuh_diri), dan kombinasi tiga kata seperti (ingin, capek) → (bunuh_diri) juga memperlihatkan bagaimana perasaan ingin menyerah atau lelah sering kali disertai dengan pemikiran tentang bunuh diri. Meski nilai *confidence*-nya bervariasi, asosiasi tersebut menunjukkan konsistensi dalam pola emosi yang mendasari ekspresi ideasi bunuh diri.

Aturan Asosiasi Ideasi Bunuh Diri Media Sosial X



Gambar 4- 3 Graph Hasil Association rules mining

Gambar 4-15 di atas menyajikan visualisasi aturan asosiasi yang diperoleh dari penerapan algoritma *association rules mining* terhadap kumpulan tweet yang berkaitan dengan ideasi bunuh diri. Graph tersebut merepresentasikan hubungan antar kata yang sering muncul bersamaan dalam satu tweet, khususnya yang berkaitan dengan topik bunuh diri. Setiap node atau simpul mewakili kata-kata penting yang sering muncul, sedangkan garis penghubung menunjukkan adanya aturan asosiasi antara dua kata, dengan arah panah mengindikasikan arah

asosiasi dari antecedent menuju consequent. Nilai *lift* dan *confidence* ditampilkan di sepanjang garis, memberikan informasi kuantitatif tentang kekuatan dan kepercayaan dari setiap aturan yang terbentuk. Warna dan ketebalan garis merepresentasikan kekuatan asosiasi berdasarkan nilai *lift* dan *confidence*. Semakin tebal dan gelap garis, maka semakin kuat pula asosiasinya.

Dari graph tersebut, terlihat bahwa kata "bunuh_diri" menjadi pusat dari sebagian besar asosiasi yang terbentuk, menandakan bahwa kata ini sering kali muncul bersamaan dengan kata-kata lain yang bermuatan emosional negatif. Misalnya, kata "dosa" memiliki asosiasi yang sangat kuat dengan "bunuh_diri", dengan *confidence* sebesar 0.94 dan *lift* sebesar 1.51, menunjukkan bahwa ketika seseorang menyebutkan kata "dosa", besar kemungkinan tweet tersebut juga mengandung kata "bunuh_diri". Hal serupa juga terlihat pada kata "pikir", "takut", dan "mati" yang memiliki nilai *confidence* yang tinggi dalam mengarah ke kata "bunuh_diri", menunjukkan adanya muatan reflektif atau emosional mendalam yang cenderung berujung pada ekspresi keinginan bunuh diri.

Selain itu, terdapat hubungan erat antara kata "tidak_berguna" dan "hidup", dengan nilai *lift* mencapai 2.21 dan *confidence* sebesar 0.95. Hal ini mengindikasikan bahwa perasaan tidak berguna sangat erat dikaitkan dengan makna hidup, atau bahkan mempertanyakan arti hidup itu sendiri, yang sering kali muncul dalam konteks ideasi bunuh diri. Kata-kata seperti "capek", "banget", dan "ingin" juga membentuk jaringan asosiasi yang signifikan dengan kata "hidup" maupun "bunuh_diri". Misalnya, asosiasi dari "capek" ke "hidup" menunjukkan bahwa rasa lelah secara emosional sering diekspresikan melalui ungkapan kelelahan terhadap hidup itu sendiri.

Secara keseluruhan, grafik ini menggambarkan bahwa dalam percakapan publik di media sosial, ideasi bunuh diri tidak muncul secara terpisah, tetapi sering kali disertai dengan ekspresi emosional seperti kelelahan, ketakutan, rasa bersalah, hingga kehilangan makna hidup. Hubungan asosiasi antar kata ini memberikan wawasan bahwa ada pola linguistik yang dapat diidentifikasi sebagai indikasi potensi ideasi bunuh diri, yang pada gilirannya dapat dimanfaatkan untuk mendeteksi dini risiko atau tanda-tanda peringatan dalam komunikasi digital. Visualisasi ini tidak hanya memperkuat hasil perhitungan metrik asosiasi secara kuantitatif, tetapi juga memberikan gambaran kontekstual yang lebih mendalam terhadap makna di balik kata-kata yang digunakan oleh pengguna media sosial.

4. KESIMPULAN

Penelitian ini menggunakan pendekatan data mining dengan menerapkan dua algoritma association rules mining apriori dan fp-growth untuk mengidentifikasi pola asosiasi kata yang berkaitan dengan ideasi bunuh diri dalam data media sosial X. Hasil analisis asosiasi menunjukkan bahwa terdapat sejumlah pola asosiasi dengan nilai support, confidence, dan lift yang tinggi. Kata-kata seperti "tidak berguna", "capek", "bunuh diri", dan "mati" sering muncul dalam asosiasi dengan kata-kata yang berhubungan dengan kehidupan atau pikiran tentang kematian. Temuan ini menunjukkan bahwa media sosial dapat menjadi cerminan dari beban psikologis yang sedang dialami oleh seseorang, dan bahwa pola bahasa yang digunakan dapat memberikan sinyal awal adanya potensi ideasi bunuh diri.

Untuk memastikan akurasi interpretasi dari hasil analisis peneliti juga melakukan proses validasi hasil oleh pakar yang memiliki latar belakang di bidang psikologi. Validasi ini menunjukkan bahwa aturan-aturan asosiasi yang ditemukan memang merepresentasikan kondisi psikologis yang rentan, seperti rasa putus asa, kelelahan emosional, dan perasaan tidak berharga. Dengan demikian, penelitian ini memberikan kontribusi dalam pemanfaatan analisis asosiasi berbasis teks sebagai pendekatan awal untuk mendeteksi indikasi risiko bunuh diri melalui ekspresi yang tertuang di media sosial.

DAFTAR PUSTAKA

- Basyouni, A., Abdelkader, H., Elkilani, W. S., Alharbi, A., Xiao, Y., & Ali, A. H. (2024). A Suicidal Ideation Detection Framework on Social Media using Machine Learning and Genetic Algorithms. *IEEE Access*, 12(August), 124816–124833. <https://doi.org/10.1109/ACCESS.2024.3454796>
- Chatterjee, M., Kumar, P., Samanta, P., & Sarkar, D. (2022). Suicide ideation detection from online social media: A multi-modal feature based technique. *International Journal of Information Management Data Insights*, 2(2), 100103. <https://doi.org/10.1016/j.jjime.2022.100103>
- Diaz-Garcia, J. A., Ruiz, M. D., & Martin-Bautista, M. J. (2023). A survey on the use of association rules mining techniques in textual social media. *Artificial Intelligence Review*, 56(2), 1175–1200. <https://doi.org/10.1007/s10462-022-10196-3>
- Hadzic, A., Spangenberg, L., Hallensleben, N., Forkmann, T., Rath, D., Strauß, M., Kersting, A., & Glaesmer, H. (2020). The association of trait impulsivity and suicidal ideation and its fluctuation in the context of the Interpersonal Theory of Suicide. *Comprehensive Psychiatry*, 98. <https://doi.org/10.1016/j.comppsy.2019.152158>
- Hassan, M. M., Karim, A., Mollick, S., Azam, S., Ignatious, E., & Farhan Al Haque, A. S. M. (2023). An Apriori Algorithm-Based Association Rule Analysis to detect Human Suicidal Behaviour. *Procedia Computer Science*, 219, 1279–1288. <https://doi.org/10.1016/j.procs.2023.01.412>
- Ji, S., Pan, S., Li, X., Cambria, E., Long, G., & Huang, Z. (2021). Suicidal Ideation Detection: A Review of Machine Learning Methods and Applications. *IEEE Transactions on Computational Social Systems*, 8(1), 214–226. <https://doi.org/10.1109/TCSS.2020.3021467>
- Klonsky, E. D., & May, A. (2015). The Three-Step Theory (3ST): A New Theory of Suicide Rooted in the " Ideation-to-Action " Framework. *International Journal of Cognitive Therapy*, 8, 114–129. <https://doi.org/10.1521/ijct.2015.8.2.114>
- Koukaras, P., Tjortjis, C., & Rousidis, D. (2022). Mining association rules from COVID-19 related twitter data to discover word patterns, topics and inferences. *Information Systems*, 109, 102054. <https://doi.org/10.1016/j.is.2022.102054>
- Liu, D., Fu, Q., Wan, C., Liu, X., Jiang, T., Liao, G., Qiu, X., & Liu, R. (2020). Suicidal ideation cause extraction from social texts. *IEEE Access*, 8, 169333–169351. <https://doi.org/10.1109/ACCESS.2020.3019491>
- Macrynika, N., Auad, E., Menjivar, J., & Miranda, R. (2021). Does social media use confer suicide risk? A systematic review of the evidence. *Computers in Human Behavior Reports*, 3(April), 100094. <https://doi.org/10.1016/j.chbr.2021.100094>
- Shawkat, M., Badawi, M., El-ghamrawy, S., Arnous, R., & El-desoky, A. (2022). An optimized FP-growth algorithm for discovery of association rules. *Journal of Supercomputing*, 78(4), 5479–5506. <https://doi.org/10.1007/s11227-021-04066-y>