

Implementasi Algoritma ECLAT pada Proses *Frequent Itemset Mining* untuk Rekomendasi *Product Bundling*

Ahmad Ainul Fataa¹, Deden Hardan Gutama², Dhina Puspasari Wijaya³, Ahmad Subhan Yazid⁴, Andri Pramutadi⁵

^{1,2,3,4,5}Program Studi Informatika, Fakultas Sains, Rekayasa dan Teknologi, Universitas Alma Ata; Jl. Brawijaya No.99, Tamantirto, Daerah Istimewa Yogyakarta; Telp (0274) 434 2288

Keywords:

Algoritma ECLAT;
Frequent Itemset Mining;
Association Rule Mining;
Product Bundling; Tkinter.

Correspondent Email:

ahmadainulfataa@gmail.com

Abstrak. Al Munawwir Swalayan dalam kegiatan operasionalnya menggunakan sistem *Point of Sale* (POS) dari pihak ketiga yang masih terbatas pada pencatatan transaksi penjualan dan belum menyediakan fitur analisis data untuk mendukung pengambilan keputusan bisnis. Hal ini menyebabkan data transaksi belum dimanfaatkan secara optimal dalam mengidentifikasi pola pembelian konsumen dan penyusunan strategi pemasaran. Penelitian ini bertujuan untuk merancang dan mengimplementasikan aplikasi analisis data transaksi berbasis desktop dengan menerapkan algoritma ECLAT (*Equivalence Class Clustering and Bottom-Up Lattice Traversal*) pada proses *frequent itemset mining* guna menghasilkan rekomendasi *product bundling*. Aplikasi dikembangkan menggunakan bahasa pemrograman Python dengan library Tkinter. Data yang digunakan berupa 22.765 transaksi penjualan pada periode 1–30 September 2025. Hasil pengujian dengan *minimum support* 0,001 dan *minimum confidence* 0,9 menghasilkan 2.385 *frequent itemset* dan 48 aturan asosiasi. Berdasarkan nilai *lift* tertinggi, diperoleh lima aturan terbaik yang direkomendasikan sebagai *product bundling*. Hasil penelitian ini menunjukkan bahwa aplikasi yang dibangun akan membantu mengoptimalkan pemanfaatan data transaksi sebagai dasar pengambilan keputusan bisnis.



Copyright © JPI (Jurnal Profesi Insinyur Universitas Lampung).

Abstract. Al Munawwir Swalayan utilizes a third-party *Point of Sale* (POS) system in its daily operations; however, the system is limited to recording sales transactions and lacks data analysis features to support business decision-making. As a result, transaction data has not been optimally utilized to identify consumer purchasing patterns or to develop effective marketing strategies. This study aims to design and implement a desktop-based transaction data analysis application by applying the ECLAT (*Equivalence Class Clustering and Bottom-Up Lattice Traversal*) algorithm in the *frequent itemset mining* process to generate *product bundling* recommendations based on consumer purchasing patterns. The application was developed using Python programming language with the Tkinter library. The dataset consists of 22,765 sales transaction records from the period of September 1–30, 2025. Experimental results using a minimum support of 0.001 and a minimum confidence of 0.9 produced 2,385 frequent itemsets and 48 association rules. The highest values obtained include a support of 0.0008, a confidence of 1.00, a lift of 355.71, and a leverage of 0.0008. Based on the highest lift values, five best rules were selected as *product bundling* recommendations. The results indicate that the developed application is capable of optimizing the utilization of transaction data as a basis for business decision-making.

1. PENDAHULUAN

Al Munawwir Swalayan merupakan minimarket yang dikelola oleh Yayasan Pondok Pesantren Al Munawwir dengan operasional yang dijalankan oleh santri dan alumni, serta menggunakan sistem *Point of Sale* (POS) berbasis layanan pihak ketiga dengan fitur yang masih terbatas. Permasalahan utama yang dihadapi adalah belum diterapkannya metode yang tepat dalam penyusunan rekomendasi *product bundling*, serta meningkatnya volume data transaksi yang belum diolah dan dimanfaatkan secara optimal. Data transaksi tersebut memiliki potensi untuk dianalisis dalam menemukan pola keterkaitan antar produk. Oleh karena itu, diperlukan penerapan metode analisis data yang tepat guna mendukung strategi penjualan, pemasaran, dan pengambilan keputusan secara lebih efektif.

Salah satu solusi untuk permasalahan ini adalah dengan memanfaatkan Data Mining. Data Mining memiliki beragam pendekatan analisis seperti klasifikasi, klusterisasi, dan asosiasi [1]. Pemilihan teknik tersebut bergantung pada karakteristik dataset dan tujuan analisis. Pada penelitian yang dilakukan oleh [2] menerapkan metode klusterisasi pada data transaksi produk PPOB untuk merumuskan strategi pemasaran melalui penyesuaian harga, segmentasi pasar, dan pengembangan produk. Sementara itu, penelitian [3] menggunakan metode klasifikasi pada data transaksi ritel UD. Mawar Sari untuk mengidentifikasi produk dengan tingkat penjualan tertinggi. Berbeda dengan dua pendekatan tersebut, metode asosiasi (*association rule mining*) lebih tepat digunakan ketika tujuan analisis adalah menemukan hubungan atau keterkaitan antar produk dalam satu transaksi. Dalam konteks *product bundling*, informasi utama yang dibutuhkan bukanlah pengelompokan pelanggan (klusterisasi) atau prediksi jenis produk (klasifikasi), melainkan pola kombinasi produk yang sering muncul secara bersamaan dalam keranjang belanja pelanggan. Karena itu, teknik asosiasi menjadi pilihan yang relevan dan efisien untuk menggali insight dari data transaksi penjualan.

Inti dari teknik asosiasi adalah proses *frequent itemset mining* [4], yakni pencarian kombinasi item yang paling sering muncul secara bersamaan dalam keranjang belanja. Pola tersebut kemudian dimanfaatkan untuk

merekomendasikan strategi *product bundling*, yaitu penggabungan beberapa produk yang sering dibeli bersamaan menjadi satu paket penjualan.

Dalam proses *frequent itemset mining* dibutuhkan algoritma untuk mempercepat pembentukan kombinasi antar produk. Beberapa algoritma yang umum digunakan antara lain Apriori, FP-Growth, dan ECLAT [5]. Penelitian yang dilakukan oleh [4] menjelaskan perbandingan efektivitas antara algoritma Apriori dan ECLAT dalam proses *frequent itemset mining*, di mana ECLAT terbukti empat kali lebih cepat tanpa mengurangi kualitas aturan yang dihasilkan. Penelitian lain oleh [6] menunjukkan bahwa meskipun FP-Growth dan ECLAT menghasilkan pola yang serupa, ECLAT lebih unggul dari sisi efisiensi memori. Sementara itu, penelitian [7] menyimpulkan bahwa tidak ada algoritma yang unggul secara mutlak, karena performa bergantung pada karakteristik data dan faktor evaluasi seperti waktu, memori, serta jumlah transaksi. Namun, ECLAT cenderung lebih unggul dari sisi waktu pemrosesan, menjadikannya pilihan yang efisien untuk dataset berukuran besar.

Meskipun berbagai penelitian sebelumnya telah menerapkan algoritma ECLAT dalam proses *frequent itemset mining*, sebagian besar masih terbatas pada penggunaan metrik evaluasi dasar seperti *support* dan *confidence*, sehingga belum memanfaatkan metrik *leverage* yang mampu memberikan penilaian keterkaitan antar produk secara lebih akurat. Selain itu, implementasi sistem pada penelitian terdahulu umumnya berbasis web, baik menggunakan PHP maupun Python Flask, serta lingkungan analisis seperti RStudio, yang meskipun efektif untuk tujuan akademik, belum sepenuhnya memenuhi kebutuhan yang memerlukan aplikasi mandiri dan tidak bergantung pada koneksi internet. Hingga saat ini, pengembangan aplikasi desktop berbasis Python dengan antarmuka GUI Tkinter untuk memproses *frequent itemset mining* dan menampilkan rekomendasi *product bundling* belum banyak dieksplorasi, sehingga menimbulkan research gap baik dari sisi evaluasi aturan asosiasi maupun implementasi teknologinya.

Dalam penelitian ini, penerapan teknologi dilakukan dengan menggunakan bahasa

pemrograman Python dan pustaka Tkinter untuk membangun aplikasi desktop yang interaktif. Python dipilih karena memiliki ekosistem pustaka (library) yang luas serta kemudahan dalam implementasi algoritma data mining. *Graphical User Interface* (GUI) dibangun menggunakan Tkinter, yang memungkinkan pengguna, khususnya pengelola Al Munawwir Swalayan, untuk melakukan proses pemuatan data transaksi, menjalankan algoritma ECLAT, serta menampilkan hasil rekomendasi product bundling secara visual dan mudah dipahami. Algoritma ECLAT (*Equivalence Class Clustering and bottom-up Lattice Traversal*) sendiri bekerja dengan pendekatan *depth-first search*, menggunakan *intersection-based computation* untuk *frequent itemset mining*. ECLAT mengubah data transaksi menjadi format vertikal di mana setiap item dikaitkan dengan daftar transaksi (TID set) yang mengandung item tersebut. Dengan melakukan operasi irisan antar TID set, algoritma ini secara efisien menemukan kombinasi item yang sering muncul bersama tanpa perlu melakukan pemindaian berulang terhadap seluruh database. Pendekatan ini membuat ECLAT lebih cepat dan hemat memori, terutama pada dataset berukuran besar seperti data transaksi di Al Munawwir Swalayan.

2. TINJAUAN PUSTAKA

2.1. Product Bundling

Product bundling adalah strategi pemasaran dimana dua atau lebih produk digabungkan menjadi satu paket kemudian dijual dengan harga khusus. Tujuannya untuk meningkatkan penjualan, mendorong pembelian yang lebih banyak dan menawarkan nilai yang lebih kepada pelanggan [8].

2.2. Frequent Itemset Mining (FIM)

Frequent itemset mining (FIM) merupakan salah satu teknik utama dalam data mining yang digunakan untuk menemukan sekumpulan item (itemset) yang sering muncul secara bersamaan dalam sekumpulan transaksi. *Frequent itemset mining* merupakan proses pencarian *co-occurrence patterns* dari item yang memiliki tingkat kemunculan (*support*) di atas ambang batas tertentu (*minimum support threshold*) [9].

2.3. Association Rule Mining

Association Rule Mining (ARM) adalah salah satu metode dalam data mining untuk menemukan suatu kombinasi antar item. Fungsi dari *association rule mining* sering juga disebut dengan market basket analysis [10]. Diantara metrik yang dipakai dalam penelitian ini adalah *support*, *confidence*, *lift* dan *leverage*. Evaluasi dilakukan untuk menilai sejauh mana algoritma ECLAT mampu menghasilkan pola asosiasi yang selanjutnya digunakan untuk rekomendasi *product bundling*.

- a. *Support* merupakan proporsi yang menyatakan kemunculan kombinasi item dari total data yang tercatat [11]. Nilai *support* digunakan untuk mengukur seberapa sering kombinasi item tertentu muncul dalam seluruh transaksi. Apabila diketahui item X juga akan membeli barang Y sehingga dibentuk aturan $X \rightarrow Y$. Nilai *support* dijelaskan dengan persamaan berikut:

$$\text{Support}(X \rightarrow Y) = \frac{|X \cup Y|}{|M|} \quad (2.1)$$

- b. *Confidence* merupakan gambaran seberapa kuat aturan asosiasi antar item yang dianggap sebagai nilai akurasi [11]. Nilai *confidence* digunakan untuk menentukan kekuatan hubungan asosiasi antara dua item atau lebih dalam suatu aturan asosiasi. Secara konseptual, *confidence* mengukur seberapa besar kemungkinan item *consequent* (Y) muncul ketika item *antecedent* (X) telah muncul dalam suatu transaksi. Dengan kata lain, *confidence* menunjukkan tingkat keandalan suatu aturan asosiasi $X \rightarrow Y$. Nilai *confidence* dijelaskan dengan rumus persamaan berikut:

$$\text{Confidence}(X \rightarrow Y) = \frac{|X \cup Y|}{|X|} \quad (2.2)$$

- c. *Lift* merupakan ukuran untuk mengetahui tingkat keterkaitan antara item X dan Y dengan membandingkan nilai *confidence* terhadap probabilitas kemunculan item Y secara independen. *Lift* digunakan untuk melihat apakah hubungan X dan Y terjadi

secara kebetulan atau memang memiliki keterkaitan yang kuat [11]. Nilai $lift > 1$ menunjukkan bahwa kemunculan X meningkatkan peluang Y muncul, sedangkan nilai $lift < 1$ menandakan hubungan X dan Y lemah atau terjadi secara kebetulan. Rumus persamaan $lift$ dijelaskan sebagaimana berikut:

$$Lift(X \rightarrow Y) = \frac{Confidence(X \rightarrow Y)}{Support(Y)} \quad (2.3)$$

d. *Leverage* merupakan ukuran yang menunjukkan perbedaan antara kemungkinan kemunculan X dan Y secara bersamaan dengan probabilitas kemunculan X dan Y secara independen. Dalam pengertian lain *leverage* adalah ukuran kuantitatif yang menyatakan selisih absolut antara frekuensi pengamatan bersama (*observed co-occurrence*) dua item dengan frekuensi yang diharapkan apabila kedua item bersifat *independent* [11]. Dengan kata lain, *leverage* mengukur seberapa banyak (dalam proporsi transaksi) pasangan item muncul lebih banyak atau lebih sedikit daripada yang diharapkan secara statistik. Nilai *leverage* dapat dinyatakan dengan persamaan berikut:

$$Leverage(X \rightarrow Y) = Support(X \cup Y) - (Support(X) \times Support(Y)) \quad (2.4)$$

2.4. Algoritma ECLAT

Algoritma ECLAT (*Equivalence Class Clustering and bottom-up Lattice Traversal*) merupakan salah satu metode dalam *frequent itemset mining* yang diperkenalkan oleh [12]. Algoritma ini menggunakan pendekatan *Depth-First Search* (DFS) dan representasi data vertikal untuk menemukan *frequent itemset* secara efisien. ECLAT hanya membutuhkan satu kali pemindaian awal untuk membentuk representasi vertikal berupa *Transaction ID list* (TID-list).

Pada penelitian ini algoritma ECLAT pada proses *frequent itemset mining* yang tahapannya mengacu pada [13] yang dijelaskan sebagaimana berikut:

- Pembentukan TID-list: Setiap item tunggal (1-itemset) direpresentasikan sebagai daftar transaksi (TID) yang memuat item tersebut. Nilai support dihitung berdasarkan panjang daftar transaksi tersebut.
- Proses Kombinasi Itemset: Dua atau lebih item yang memiliki nilai support memenuhi ambang batas (*minimum support*) digabungkan untuk membentuk kandidat itemset yang lebih besar. Gabungan dilakukan melalui operasi *intersection* antar TID-list.
- Perhitungan *Support* dan *Pruning*: Setelah diperoleh hasil *intersection*, setiap itemset dihitung *support*-nya berdasarkan panjang TID-list hasil. Jika nilai *support* < *minimum support*, maka *itemset* tersebut dihapus (*pruning*).
- Pencarian Rekursif (*Depth-First Search*): Langkah kombinasi dan *pruning* dilanjutkan secara rekursif dengan pola *depth-first search*, hingga tidak ada lagi kombinasi yang memenuhi *minimum support*.

2.5. Tkinter

Tkinter merupakan library bawaan Python yang digunakan untuk membangun aplikasi berbasis GUI. Melalui Tkinter, pengembang dapat memanfaatkan beragam komponen antarmuka grafis guna merancang aplikasi desktop secara lebih cepat dan sederhana [14].

3. METODE PENELITIAN

Berdasarkan pendekatannya, penelitian ini menggunakan pendekatan kuantitatif karena berfokus pada pengolahan data transaksi penjualan secara numerik menggunakan algoritma ECLAT pada proses *frequent itemset mining*. Menurut [15] penelitian kuantitatif adalah pendekatan untuk menguji teori-teori objektif dengan cara meneliti hubungan antar variabel yang dapat diukur menggunakan instrumen penelitian dan dianalisis dengan prosedur statistik. Adapun desain penelitian ini terdiri dari beberapa tahapan sebagaimana dijelaskan pada gambar 3.1.



Gambar 3. 1 Desain Penelitian

Langkah-langkah dalam gambar 3.1 dijelaskan sebagaimana berikut:

- a. **Identifikasi Masalah:** Pada tahap ini dilakukan analisis terhadap permasalahan di lapangan, yaitu belum adanya sistem yang mampu memberikan rekomendasi *product bundling* secara otomatis berdasarkan data transaksi.
- b. **Studi Literatur:** Peneliti melakukan kajian pustaka terhadap teori-teori yang berkaitan dengan data mining, *frequent itemset mining*, *association rule mining*, algoritma ECLAT, serta penelitian terdahulu yang relevan sebagai dasar dari penelitian yang akan dilakukan.
- c. **Pengumpulan Data:** Data yang digunakan berasal dari catatan transaksi penjualan pada Al Munawwir Swalayan. Pengumpulan data dilakukan dengan studi literatur, observasi dan dokumentasi.
- d. **Perancangan data:** Pada tahapan ini akan disesuaikan dari data mentah menjadi data yang siap diolah menggunakan algoritma ECLAT.
- e. **Perancangan sistem:** Pada tahapan ini dilakukan perancangan sistem yang akan menggunakan *Iteratif Waterfall Model*.
- f. **Evaluasi:** Pada tahapan ini evaluasi dilakukan untuk menghasilkan rekomendasi *product bundling* yang sesuai menggunakan nilai dari *lift* dan *leverage* sebagai interpretasinya. Pada tahapan ini juga dilakukan pengujian sistem menggunakan *black-box testing* guna menguji fungsionalitas dari sistem yang telah dibuat.
- g. **Pengambilan Kesimpulan:** Pada tahapan ini dilakukan penarikan kesimpulan dari penelitian yang telah dilakukan sebagai acuan penelitian lebih lanjut.

3.1. Sumber Data

Pada penelitian ini subjek yang digunakan adalah Al Munawwir Swalayan dengan populasi yaitu data transaksi pada bulan pada periode 1-30 September 2025 sebanyak 22.765 *record*. Teknik pengumpulan data yang digunakan dalam penelitian ini adalah wawancara tidak terstruktur terhadap pengelola Al Munawwir Swalayan, data primer dan observasi. Adapun contoh data primer yang digunakan pada penelitian ini pada tabel 3.1.


Tabel 3. 1 Data Transaksi Al Munawwir Swalayan

Kode Transaksi	Item Transaksi
NPJG205784420523	DELFI TOP CHOCOLATE 9GR, SOYJOY MOCHACHOCO CASHEW 30GR, SILVER QUEEN VERY BERRY 22GR, SILVER QUEEN CHUNKY JAR CASHEWS 30GR
NPJG209602172046	SILVER QUEEN CASHEWS 55GR, SILVER QUEEN VERY BERRY 22GR
NPJG206549916197	SILVER QUEEN FRUIT & NUTS 58GR
NPJG209170657252	SILVER QUEEN CHUNKY JAR ALMONDS 30GR, SILVER QUEEN FRUIT & NUTS 58GR
NPJG208717704394	DELFI TOP STRAWBERRY 9GR, SILVER QUEEN FRUIT & NUTS 58GR, SILVER QUEEN GREEN TEA MATCHA 55GR, SILVER QUEEN CHUNKY JAR ALMONDS 30GR, SILVER QUEEN CASHEWS 55GR
NPJG203068081894	DELFI TOP CHOCOLATE 9GR, SILVER QUEEN CHUNKY JAR CASHEWS 30GR, SILVER QUEEN MATCHA 22GR, SILVER QUEEN GREEN TEA MATCHA 55GR
NPJG206824555822	DELFI TOP STRAWBERRY 9GR, SILVER QUEEN FRUIT & NUTS 58GR, SILVER QUEEN GREEN TEA MATCHA 55GR, SILVER QUEEN CHUNKY JAR ALMONDS 30GR, SILVER QUEEN CASHEWS 55GR
NPJG207661607073	DELFI TOP CHOCOLATE 9GR, SILVER QUEEN CHUNKY JAR CASHEWS 30GR, SILVER QUEEN MATCHA 22GR, SILVER QUEEN GREEN TEA MATCHA 55GR
NPJG209753117739	DELFI TOP STRAWBERRY 9GR, SILVER QUEEN FRUIT & NUTS 58GR, SILVER QUEEN GREEN TEA MATCHA 55GR, SILVER QUEEN CHUNKY JAR ALMONDS 30GR, SILVER QUEEN CASHEWS 55GR
NPJG209240020727	DELFI TOP CHOCOLATE 9GR, SILVER QUEEN CHUNKY JAR CASHEWS 30GR, SILVER QUEEN MATCHA 22GR, SILVER QUEEN GREEN TEA MATCHA 55GR
NPJG209240020728	DELFI TOP CHOCOLATE 9GR, SILVER QUEEN CHUNKY JAR CASHEWS 30GR, SILVER QUEEN

Kode Transaksi	Item Transaksi
	MATCHA 22GR, SILVER QUEEN GREEN TEA MATCHA 55GR

3.2. Pengembangan Sistem

Metode pengembangan sistem yang digunakan pada penelitian ini menggunakan Iterative Waterfall Model yang merupakan bentuk pengembangan evolusioner dari model klasik yang tetap mempertahankan struktur sistematis Waterfall, tetapi menambahkan fleksibilitas melalui umpan balik antar fase agar kesalahan dapat diperbaiki lebih awal dan proses pengembangan menjadi lebih realistis di dunia nyata. Adapun tahapan dari *Iterative Waterfall Model* dijelaskan pada gambar 3.2.



Gambar 3. 2 Iterative Waterfall Model

Penjelasan dari *Iterative Waterfall Model* dijabarkan sebagaimana berikut [16]:

- Requirements Definition** (Definisi Kebutuhan): Pada tahap ini dilakukan pengumpulan dan analisis kebutuhan dari pengguna (user requirements) serta kebutuhan sistem (system requirements).
- System and Software Design** (Perancangan Sistem dan Perangkat Lunak): Berdasarkan kebutuhan yang telah ditetapkan, dilakukan perancangan arsitektur sistem, desain database, desain antarmuka pengguna, serta struktur modul perangkat lunak. Tujuannya agar proses implementasi lebih terarah.
- Implementation and Unit Testing** (Implementasi dan Pengujian Unit): Desain yang telah dibuat diubah menjadi kode

program (*coding*). Setelah itu, dilakukan unit testing untuk menguji setiap modul secara individual guna memastikan setiap bagian berfungsi sesuai rancangan.

- Integration and System Testing** (Integrasi dan Pengujian Sistem): Modul-modul yang sudah lulus unit testing diintegrasikan menjadi satu kesatuan sistem. Setelah itu dilakukan system testing untuk memastikan seluruh komponen bekerja bersama secara benar sesuai dengan kebutuhan pengguna.
- Operation and Maintenance** (Operasi dan Pemeliharaan): Sistem yang sudah diuji dan disetujui akan diimplementasikan di lingkungan pengguna. Setelah berjalan, dilakukan pemeliharaan (*maintenance*) seperti perbaikan bug, pembaruan fitur, dan penyesuaian terhadap kebutuhan baru.

3.3. Flowchart

Flowchart yang digunakan dalam penelitian ini pada algoritma ECLAT mengacu pada [17] yang dapat diimplementasikan ke dalam kode program. Berikut adalah penjelasan dari flowchart diagram proses algoritma ECLAT pada gambar 3.3:



Gambar 3. 3 Flowchart Algoritma ECLAT

4. HASIL DAN PEMBAHASAN

4.1. Perhitungan Manual

Perhitungan manual akan dijelaskan menggunakan data testing sebelum diproses menggunakan data yang sebenarnya dari data

transaksi Al Munawwir Swalayan. Langkah ini untuk membuktikan kebenaran perhitungan dari hasil manual dan hasil perhitungan program yang sudah diimplementasikan dengan skenario menggunakan minimum support 0.4. Berikut adalah data testing yang akan pakai untuk perhitungan manual pada tabel 4.1:

Tabel 4. 1 Data Testing

Kode Transaksi	Items
NPJG001	DELFI TOP CHOCOLATE 9GR, SOYJOY MOCHACHOCO CASHEW 30GR, SILVER QUEEN VERY BERRY 22GR, SILVER QUEEN CHUNKY JAR CASHEWS 30GR
NPJG002	SILVER QUEEN CASHEWS 55GR, SILVER QUEEN VERY BERRY 22GR
NPJG003	SILVER QUEEN FRUIT & NUTS 58GR
NPJG004	SILVER QUEEN CHUNKY JAR ALMONDS 30GR, SILVER QUEEN FRUIT & NUTS 58GR
NPJG005	DELFI TOP STRAWBERRY 9GR, SILVER QUEEN FRUIT & NUTS 58GR, SILVER QUEEN GREEN TEA MATCHA 55GR, SILVER QUEEN CHUNKY JAR ALMONDS 30GR, SILVER QUEEN CASHEWS 55GR
NPJG006	DELFI TOP CHOCOLATE 9GR, SILVER QUEEN CHUNKY JAR CASHEWS 30GR, SILVER QUEEN MATCHA 22GR, SILVER QUEEN GREEN TEA MATCHA 55GR
NPJG007	DELFI TOP STRAWBERRY 9GR, SILVER QUEEN FRUIT & NUTS 58GR, SILVER QUEEN GREEN TEA MATCHA 55GR, SILVER QUEEN CHUNKY JAR ALMONDS 30GR, SILVER QUEEN CASHEWS 55GR
NPJG008	DELFI TOP CHOCOLATE 9GR, SILVER QUEEN CHUNKY JAR CASHEWS 30GR, SILVER QUEEN MATCHA 22GR, SILVER QUEEN GREEN TEA MATCHA 55GR
NPJG009	DELFI TOP STRAWBERRY 9GR, SILVER QUEEN FRUIT & NUTS 58GR, SILVER QUEEN GREEN TEA MATCHA 55GR, SILVER QUEEN CHUNKY JAR ALMONDS 30GR, SILVER QUEEN CASHEWS 55GR
NPJG010	DELFI TOP CHOCOLATE 9GR, SILVER QUEEN CHUNKY JAR CASHEWS 30GR, SILVER QUEEN MATCHA 22GR, SILVER QUEEN GREEN TEA MATCHA 55GR

Selanjutnya diproses untuk pembentukan TID-list. Berdasarkan data testing yang digunakan sebagai sampel, setiap item tunggal direpresentasikan dalam bentuk TID-list yang berisi daftar ID transaksi tempat item tersebut muncul. Nilai *support* dihitung berdasarkan jumlah transaksi yang memuat item tersebut. Berikut adalah hasil dari pembentukan TID-list dari data testing pada tabel 4.2.

Tabel 4. 2 Hasil Proses Pembentukan TID-list

Item	TID-set	Support Count
SILVER QUEEN GREEN TEA MATCHA 55GR	{5, 6, 7, 8, 9, 10}	6
SILVER QUEEN FRUIT & NUTS 58GR	{3, 4, 5, 7, 9}	5
DELFI TOP CHOCOLATE 9GR	{1, 6, 8, 10}	4

Item	TID-set	Support Count
SILVER QUEEN CHUNKY JAR CASHEWS 30GR	{1, 6, 8, 10}	4
SILVER QUEEN CHUNKY JAR ALMONDS 30GR	{4, 5, 7, 9}	4
SILVER QUEEN CASHEWS 55GR	{2, 5, 7, 9}	4
SILVER QUEEN MATCHA 22GR	{6, 8, 10}	3 (Pruned)
DELFI TOP STRAWBERRY 9GR	{5, 7, 9}	3 (Pruned)

Selanjutnya perhitungan *Frequent Itemset* (*Intersection* dan *DFS*). Proses pencarian kombinasi item dilakukan dengan operasi irisan (*intersection*) antar TID-set secara rekursif menggunakan pendekatan *Depth-First Search* (DFS) pada tabel 4.3.

Tabel 4. 3 perhitungan Frequent Itemset (Intersection dan DFS)

Kombinasi Item	TID-set Item 1	TID-set Item 2	Hasil Intersection TID-set	Support Count	Keputusan
{DELFI TOP CHOCOLATE 9GR, SILVER QUEEN CHUNKY JAR CASHEWS 30GR}	{1, 6, 8, 10}	{1, 6, 8, 10}	{1, 6, 8, 10}	4	Lolos (≥ 4)
{SILVER QUEEN FRUIT & NUTS 58GR, SILVER QUEEN CHUNKY JAR ALMONDS 30GR}	{3, 4, 5, 7, 9}	{4, 5, 7, 9}	{4, 5, 7, 9}	4	Lolos (≥ 4)
{SILVER QUEEN GREEN TEA MATCHA 55GR, DELFI TOP CHOCOLATE 9GR}	{5, 6, 7, 8, 9, 10}	{1, 6, 8, 10}	{6, 8, 10}	3	Dieliminasi (Pruning)

Selanjutnya adalah hasil akhir dari *Frequent Itemset* dari data testing. Berdasarkan pengujian manual, diperoleh 8 *Frequent Itemset* sebagaimana dijelaskan pada tabel 4.4 berikut:

Tabel 4. 4 Hasil Akhir Frequent Itemset

Nama Itemset	Support Count	Support Value
SILVER QUEEN GREEN TEA MATCHA 55GR	6	0.6
SILVER QUEEN FRUIT & NUTS 58GR	5	0.5
DELFI TOP CHOCOLATE 9GR	4	0.4
SILVER QUEEN CHUNKY JAR CASHEWS 30GR	4	0.4
SILVER QUEEN CHUNKY JAR ALMONDS 30GR	4	0.4
SILVER QUEEN CASHEWS 55GR	4	0.4
DELFI TOP CHOCOLATE 9GR, SILVER QUEEN CHUNKY JAR CASHEWS 30GR	4	0.4
SILVER QUEEN FRUIT & NUTS 58GR, SILVER QUEEN CHUNKY JAR ALMONDS 30GR	4	0.4

Selanjutnya mengidentifikasi variabel dasar perhitungan. Sebelum menghitung metrik evaluasi, dilakukan tabulasi terhadap frekuensi kemunculan (TID-set) dari Antecedent (item awal) dan Consequent (item tujuan)

berdasarkan data 10 transaksi. Berikut adalah data dasar *antecedent* dan *consequent* pada tabel 4.5:

Tabel 4. 5 Data Dasar Antecedent dan Consequent

ID Aturan	Aturan Asosiasi (A→B)	TID-set A	TID-set B	TID-set A∩B
Rule 1	{DELFI TOP CHOCOLATE 9GR} → {SILVER QUEEN CHUNKY JAR ALMONDS 30GR}	"{1, 6, 8, 10}"	"{1, 6, 8, 10}"	"{1, 6, 8, 10}"
Rule 2	{SILVER QUEEN FRUIT & NUTS 58GR} → {SILVER QUEEN CHUNKY JAR ALMONDS 30GR}	"{3, 4, 5, 7, 9}"	"{4, 5, 7, 9}"	"{4, 5, 7, 9}"

Selanjutnya dilakukan perhitungan *support* untuk mengukur seberapa sering kombinasi item muncul. Hasil perhitungan *support* dijelaskan pada tabel 4.6.

Tabel 4. 6 Hasil Perhitungan Support

ID Aturan	Formula <i>Support</i> (A∪B)	Hasil <i>Support</i>
Rule 1	4/10	0.4
Rule 2	4/10	0.4

Selanjutnya dilakukan perhitungan nilai *confidence* untuk mengukur tingkat kepastian hubungan dari kombinasi yang sering muncul. Hasil perhitungan *confidence* dijelaskan pada tabel 4.7.

Tabel 4. 7 Hasil Perhitungan Confidence

ID Aturan	Formula <i>Confidence</i> (A→B)	Hasil <i>Confidence</i>
Rule 1	0.4/0.4	1.0 (100%)
Rule 2	0.4/0.5	0.8 (80%)

Selanjutnya dilakukan perhitungan *lift* yang digunakan untuk menentukan kekuatan aturan asosiasi (valid jika > 1). Hasil perhitungan *lift* dijelaskan pada tabel 4.8.

Tabel 4. 8 Hasil Perhitungan Lift

ID Aturan	Formula <i>Lift Ratio</i>	Hasil <i>Lift</i>
Rule 1	1.0/0.4	2.5

ID Aturan	Formula <i>Lift Ratio</i>	Hasil <i>Lift</i>
Rule 2	0.8/0.4	2.0

Kemudian dilanjutkan untuk perhitungan *leverage* untuk mengukur perbedaan antara frekuensi observasi dan frekuensi harapan jika kedua item saling bebas. Hasil perhitungan *leverage* dijelaskan pada tabel 4.10.

Tabel 4. 9 Hasil Perhitungan Leverage

ID Aturan	Formula <i>Leverage</i>	Hasil <i>Leverage</i>
Rule 1	0.4 -(0.4×0.4)	0.24
Rule 2	0.4 -(0.5×0.4)	0.20

Berdasarkan seluruh perhitungan di atas, berikut adalah rangkuman evaluasi aturan asosiasi yang akan diimplementasikan ke dalam sistem.

4.2. Hasil Antarmuka Sistem (Aplikasi Desktop)

- Halaman login adalah tampilan awal yang membatasi akses ke sistem, di mana pengguna harus memasukkan username dan password yang valid sebelum mengakses fitur utama aplikasi pada gambar 4.1.



Gambar 4. 1 Halaman Login

- Halaman register adalah formulir pendaftaran untuk pengguna baru dalam membuat akun, sebagaimana ditunjukkan pada gambar 4.2.



Gambar 4. 2 Halaman Register

- c. Halaman dashboard (beranda) adalah halaman awal setelah login yang menampilkan ringkasan hasil pengolahan data menggunakan algoritma ECLAT, sehingga pengguna dapat memahami kondisi data dan hasil *association rule* pada Gambar 4.3.



Gambar 4. 3 Halaman Dashboard Beranda

- d. Pada halaman ini (gambar 4.4), proses rekomendasi *product bundling* dimulai dengan mengunggah data CSV/XLSX yang sesuai dengan data transaksi AI Munawwir Swalayan, serta tersedia fitur untuk mereset atau menghapus data sebelumnya.



Gambar 4. 4 Halaman Data Transaksi

- e. Halaman Proses Algoritma (gambar 4.5) merupakan inti aplikasi untuk melakukan *frequent itemset mining*. Pengguna dapat menentukan rentang tanggal, *minimum*

support, dan *minimum confidence* sebelum menjalankan proses, dengan hasil berupa waktu eksekusi, jumlah transaksi, serta tabel *frequent itemset*. Halaman ini juga dilengkapi fitur pengelolaan seperti hapus data, refresh, simpan hasil, dan export PDF untuk dokumentasi.



Gambar 4. 5 Halaman Proses ECLAT

- f. Selain menampilkan *frequent itemset*, aplikasi juga menyediakan tab lanjutan seperti *Association Rule* (Gambar 4.6) yang menampilkan aturan asosiasi beserta nilai *support*, *confidence*, *lift*, dan *leverage* sebagai dasar rekomendasi.



Gambar 4. 6 Tab Hasil Frequent Itemset

- g. Tab Rekomendasi *Product Bundling* (Gambar 4.7) menampilkan 5 aturan asosiasi terbaik berdasarkan *confidence* dan *lift* tertinggi sebagai acuan penyusunan paket produk.



Gambar 4. 7 Tab Rekomendasi Product Bundling

- h. Pada Gambar 4.8, tab Visualisasi menampilkan nilai *support*, *confidence*, *lift*, dan *leverage* tertinggi untuk memudahkan pemahaman kualitas aturan asosiasi.



Gambar 4. 8 Tab Visualisasi Hasil Nilai Tertinggi

- i. Fitur Tentang Aplikasi menyediakan panduan penggunaan, informasi fitur, dan konsep dasar algoritma ECLAT untuk membantu pengguna memahami alur dan metode yang digunakan.



Gambar 4. 9 Halaman Tentang Aplikasi

- j. Hasil implementasi berupa laporan PDF yang digunakan untuk pengambilan keputusan, berisi hasil proses algoritma ECLAT seperti ringkasan data, 5 rekomendasi *product bundling* terbaik, dan metrik kunci pada Gambar 4.10.



Gambar 4. 10 Laporan PDF

- k. Pada Gambar 4.11 berisi semua hasil dari *frequent itemset mining* yang disajikan dalam bentuk tabel yang terdiri dari Itemset dan nilai *support*.

Gambar 4. 11 Laporan PDF Frequent Itemset Mining

- l. Pada Gambar 4.12 berisi semua hasil dari *association rule* yang disajikan dalam bentuk tabel dalam bentuk *antecedent*, *consequent*, *support*, *confidence*, *lift* dan *leverage*.

Gambar 4. 12 Laporan PDF Association Rule

- m. Setelah pengembangan selesai, aplikasi berhasil dijalankan secara mandiri melalui file .exe hasil *compile* menggunakan PyInstaller, sehingga lebih praktis tanpa perlu interpreter Python. Aplikasi berukuran 27.015 KB dan telah diuji pada Windows 10 (Build 19045) dengan hasil berjalan baik, seperti ditunjukkan pada Gambar 4.13.



Gambar 4. 13 Icon Aplikasi Rekomendasi Product Bundling

4.3. Pengujian

Berdasarkan perbandingan perhitungan manual dan sistem, nilai *support*, *confidence*, *lift*, dan *leverage* menunjukkan hasil yang sama. Dua *rule* yang diuji juga menghasilkan nilai identik, sehingga membuktikan implementasi algoritma ECLAT berjalan benar, konsisten, dan valid untuk digunakan pada data transaksi yang di tunjukkan pada gambar .

IV. Tabel Frequent Itemsets

Itemset	Support	Confidence	Lift	Leverage
{CHITATO INDOMIE 68GR}	0.0000	0.0000	0.0000	0.0000
{CUCU BARCAKE VANILLA CAKE 20GR}	0.0000	0.0000	0.0000	0.0000
{TWISTER MINIS CHOC 30GR}	0.0000	0.0000	0.0000	0.0000
{CHITATO INDOMIE 68GR, CUCU BARCAKE VANILLA CAKE 20GR}	0.0000	0.0000	0.0000	0.0000
{CHITATO INDOMIE 68GR, TWISTER MINIS CHOC 30GR}	0.0000	0.0000	0.0000	0.0000
{CUCU BARCAKE VANILLA CAKE 20GR, TWISTER MINIS CHOC 30GR}	0.0000	0.0000	0.0000	0.0000
{CHITATO INDOMIE 68GR, CUCU BARCAKE VANILLA CAKE 20GR, TWISTER MINIS CHOC 30GR}	0.0000	0.0000	0.0000	0.0000

V. Tabel Hasil Asosiasi Rules

Association Rule	Support	Confidence	Lift	Leverage
{CHITATO INDOMIE 68GR} → {CUCU BARCAKE VANILLA CAKE 20GR}	0.0000	0.0000	0.0000	0.0000
{CHITATO INDOMIE 68GR} → {TWISTER MINIS CHOC 30GR}	0.0000	0.0000	0.0000	0.0000
{CUCU BARCAKE VANILLA CAKE 20GR} → {CHITATO INDOMIE 68GR}	0.0000	0.0000	0.0000	0.0000
{CUCU BARCAKE VANILLA CAKE 20GR} → {TWISTER MINIS CHOC 30GR}	0.0000	0.0000	0.0000	0.0000
{TWISTER MINIS CHOC 30GR} → {CHITATO INDOMIE 68GR}	0.0000	0.0000	0.0000	0.0000
{TWISTER MINIS CHOC 30GR} → {CUCU BARCAKE VANILLA CAKE 20GR}	0.0000	0.0000	0.0000	0.0000

Gambar 4. 14 Hasil Pengujian Data Testing dan Kode Program

Berdasarkan hasil aturan asosiasi, sistem menyeleksi lima rekomendasi *product bundling* terbaik berdasarkan nilai *lift* tertinggi karena mencerminkan kekuatan hubungan antar produk. Semakin tinggi *lift*, semakin kuat asosiasinya. Rekomendasi utama adalah kombinasi CHITATO INDOMIE 68GR dan CUCU BARCAKE VANILLA CAKE 20GR yang mengarah ke TWISTER MINIS CHOC 30GR, dengan *lift* 355,7143 dan *confidence* 1,0000, menunjukkan hubungan sangat kuat.

Rekomendasi lain seperti ROMA MARIE GOLD DOUBLE MILK 22GR dan UMKM LARIS CRIPING TELO terhadap PENGGARIS BESI 30CM, serta KOBE BUMBUN AYAM GORENG LENGKUAS 80GR dan RADEN BASTIK PEDAS terhadap CHOCOMANIA CHEESE 69GR juga memiliki *lift* tinggi (276,6667) dan *confidence* sempurna. Selain itu, kombinasi produk lainnya juga menunjukkan *lift* tinggi hingga 249,0000, yang menandakan adanya pola pembelian konsumen yang konsisten dan relevan untuk dijadikan bundling.

Berdasarkan evaluasi metrik, nilai *support* maksimum sebesar 0,00080 menunjukkan aturan muncul pada proporsi kecil namun tetap signifikan karena didukung *confidence* dan *lift* yang tinggi. Aturan terbaik memiliki *confidence* 1,0000, *lift* 355,7143, dan *leverage* 0,00080,

yaitu kombinasi CHITATO INDOMIE 68GR dan CUCU BARCAKE VANILLA CAKE 20GR terhadap TWISTER MINIS CHOC 30GR, yang menjadi asosiasi paling kuat dan konsisten.

Hasil ini menunjukkan aturan yang dihasilkan valid dan dapat digunakan sebagai dasar strategi *product bundling*, penataan produk, serta promosi untuk meningkatkan nilai transaksi dan keputusan bisnis.

Berdasarkan hasil *black-box testing*, seluruh fitur aplikasi berjalan sesuai kebutuhan, mulai dari autentikasi, navigasi, hingga proses ECLAT yang menghasilkan *frequent itemset*, aturan asosiasi, dan rekomendasi secara akurat. Fitur pendukung seperti hapus data, simpan hasil, dan ekspor PDF juga berfungsi dengan baik, sehingga aplikasi siap digunakan.

Tabel 4. 10 Hasil Pengujian Black-box Testing

Fitur yang Diuji	Skenario Pengujian	Input	Output yang Diharapkan	Hasil Pengujian
Login	Login dengan data valid	Username & password benar	Pengguna berhasil masuk ke dashboard	Berhasil
Login	Login dengan data tidak valid	Username/password salah	Sistem menampilkan pesan gagal login	Berhasil
Login	Input kosong	Username/password kosong	Sistem menolak login	Berhasil
Dashboard	Akses menu	Klik menu navigasi	Sistem menampilkan halaman sesuai menu	Berhasil
Data Transaksi	Menampilkan data	Klik menu Data Transaksi	Data transaksi tampil dengan benar	Berhasil
Data Transaksi	Upload data	Klik tombol Upload CSV/XLSX	Data transaksi tampil dengan benar	Berhasil
Proses Algoritma	Input parameter valid	Tanggal, min support, confidence	Sistem menjalankan algoritma	Berhasil
Proses Algoritma	Input parameter tidak valid	Min support kosong	Sistem menampilkan peringatan	Berhasil
Proses Algoritma	Proses ECLAT	Klik tombol Proses Algoritma	Frequent itemset dihasilkan	Berhasil
Delete All Data	Hapus data hasil	Klik Delete All Data	Data hasil analisis terhapus	Berhasil
Refresh Data	Muat ulang data	Klik Refresh Data	Data tampilan diperbarui	Berhasil
Simpan Data	Simpan hasil analisis	Klik Simpan Data	Data tersimpan ke basis data	Berhasil
Export PDF	Eksport laporan	Klik Export PDF	File PDF berhasil dibuat	Berhasil
Association Rules	Tampilkan aturan	Klik tab Association Rule	Aturan asosiasi ditampilkan	Berhasil
Rekomendasi Product Bundling	Tampilkan rekomendasi	Klik Rekomendasi tab	Rekomendasi product bundling muncul	Berhasil
Visualisasi	Tampilkan setiap metrik tertinggi	Klik tab Visualisasi	Menampilkan metrik support, confidence, lift, leverage tertinggi	Berhasil
Tentang Aplikasi	Akses informasi aplikasi	Klik menu Tentang Aplikasi	Informasi aplikasi tampil	Berhasil
Logout	Keluar aplikasi	Klik Logout	Sistem kembali ke halaman login	Berhasil

5. KESIMPULAN

- a. Sistem rekomendasi *product bundling* berhasil dikembangkan berbasis desktop menggunakan Python (Tkinter) untuk membantu analisis pola pembelian di Al Munawwir Swalayan. Hasil perhitungan manual dan aplikasi terbukti konsisten. Sistem mampu mengolah data transaksi, menghasilkan *frequent itemset*, dan membentuk *association rules* berdasarkan parameter *support*, *confidence*, *lift*, dan *leverage*.
- b. Dari 22.765 data transaksi (1–30 September 2025) dengan *minimum support* 0.0001 dan *minimum confidence* 0.9, diperoleh 2.385 *frequent itemset* dan 48 aturan asosiasi. Nilai tertinggi yang dihasilkan adalah *support* 0.0008, *confidence* 1.00, *lift* 355,71, dan *leverage* 0.0008. Dari hasil tersebut, dipilih 5 aturan terbaik untuk ditampilkan (berdasarkan *lift* tertinggi) sebagai rekomendasi *product bundling*.

DAFTAR PUSTAKA

- [1] Amna, W. S., I. G. I. S. T. A. E. Putra, A. J. W. W. A. Syukrilla, A. K. W. N. H. T. Indriyani, and L. W. Santoso, *Data Mining*. Padang: PT Global Eksekutif Teknologi, 2023.
- [2] M. R. Dzikrillah, D. H. Gutama, D. P. Wijaya, D. Danianti, P. S. Informatika, and U. A. Ata, "IMPLEMENTASI ALGORITMA K-MEANS DALAM PENGELOMPOKAN TINGKAT TRANSAKSI PRODUK PPOB NUSANTARA," *JIP (Jurnal Inform. Polinema)*, vol. 10, pp. 341–350, 2024.
- [3] N. W. Wardani, P. G. S. C. Nugraha, and G. S. Mahendra, "Implementasi Naïve Bayes Pada Data Mining Untuk Mengklasifikasikan Penjualan Barang Terlaris Pada Perusahaan Ritel," *JST (Jurnal Sains dan Teknol.)*, vol. 12, no. 3, pp. 656–668, 2024, doi: 10.23887/jstundiksha.v12i3.38605.
- [4] D. P. Wijaya, P. F. Dewi, and N. M. Saraswati, "Analyzing the Effectiveness of Apriori and ECLAT Algorithms in Frequent Itemset Mining," vol. 1, no. 1, pp. 16–20, 2025.
- [5] R. K. Hapsari *et al.*, *Data Mining*. Bandung: Indie Press, 2024.
- [6] F. Ardian Nugroho, B. Pramono, and J. Teknik Informatika, "Komparasi Algoritma Equivalence Class Transformation (ECLAT) dan FP-Growth pada Analisis Data Penjualan," *Animator*, vol. 2, no. 1, pp. 1–5, 2024.
- [7] D. Erlina, D. Irfansyah, and I. Pratama, "Literatur Sistematis Perbandingan Kinerja Algoritma Apriori, ECLAT, dan FP-Growth dalam Analisis Pola Asosiasi," *Indones. J. Comput. Sci. Eng.*, vol. 02, no. 1, pp. 58–63, 2025.
- [8] M. Zenia Rabbil, R. Permana, F. Agharid Zahra, and D. Fitri Sugiyanti, "Strategi Pemasaran Product Bundling Dalam Meningkatkan Penjualan Produk Hijab Sattka," *Manaj. Pemasar. Int.*, vol. 2, no. 3, pp. 315–325, 2025.
- [9] J. Han, J. Pei, and H. Tong, *Data Mining: Concepts and Techniques*, 4th ed., vol. 17. Cambridge: Morgan Kaufmann, 2023. [Online]. Available: <https://datamineaz.org/textbooks/hanDataMiningConceptual.pdf>
- [10] D. Winarti, M. Kom, E. Revita, and M. Kom, "Penerapan Data Mining untuk Analisa Tingkat Kriminalitas Dengan Algoritma Association Rule Metode FP-Growth," *J. SIMTIKA*, vol. 4, no. 3, pp. 8–22, 2021.
- [11] Muttaqin *et al.*, *Pengenalan Data Mining*, no. July. Yayasan Kita Menulis, 2023.
- [12] M. J. Zaki, "Scalable algorithms for association mining," *IEEE Trans. Knowl. Data Eng.*, vol. 12, no. 3, pp. 372–390, 2000, doi: 10.1109/69.846291.
- [13] P. Fournier-Viger, "Eclat Algorithm for Frequent Itemset Mining." [Online]. Available: <https://www.philippe-fournier-viger.com/spmf/Eclat.php>
- [14] D. Manalu, R. S. Saragih, and P. S. P. Sitorus, *Pemrograman Python Dengan Gui Tkinter*. Balikpapan: Borneo Novelty Publishing, 2024.
- [15] J. W. Creswell and J. D. Creswell, *Research Design: Qualitative, Quantitative, and Mixed Methods Approaches*, Fifth Edit. California: SAGE Publications, 2018.
- [16] I. Sommerville, *Software Engineering*. 2016.
- [17] H. Lan, X. Ma, L. Ma, and W. Qiao, "Pattern Investigation of Total Loss Maritime Accidents Based on Association Rule Mining," *Reliab. Eng. Syst. Saf.*, 2022, doi: <https://doi.org/10.1016/j.res.2022.108893>.