

ANALISIS POLA PEMBELIAN PELANGGAN MENGGUNAKAN ALGORITMA FP-GROWTH UNTUK Mendukung STRATEGI PEMASARAN PADA DATA TRANSAKSI RETAIL

Rizky Nugraha¹, Nana Suarna², Agus Bahtiar³, Faturrohman⁴.

Program Studi Teknik Informatika¹²
Program Studi Sistem Informasi³
Program Studi Rekayasa Perangkat Lunak⁴

STMIK IKMI Cirebon
<https://ikmi.ac.id/page/18/?lang=de>
rn02501@gmail.com

(*) Corresponding Author : rn02501@gmail.com
Published : 30 Juni 2026

Abstract—With the increasing complexity of transactional data in the modern retail sector, advanced analytical approaches are required to effectively extract hidden patterns, particularly under conditions of high data sparsity. This study aims to identify customer purchasing patterns and generate significant association rules using the Frequent Pattern Growth (FP-Growth) algorithm to support data-driven marketing strategies. Addressing the research gap in conventional methods that struggle with sparse retail data, this study emphasizes the optimization of association rule extraction that is not only statistically valid but also practically valuable. The proposed method implements FP-Growth using RapidMiner on a dataset consisting of 10,000 records, representing 1,991 transactions across 68 product categories. The preprocessing stage includes transforming the dataset into a basket format using pivoting techniques and converting attributes into binominal form. The minimum support (0.04) and minimum confidence (0.12) parameters are determined based on the data distribution characteristics, which exhibit a sparsity level of 94.1%. The results show that the FP-Growth algorithm successfully generates 16 significant association rules with lift ratios greater than 1, indicating meaningful positive correlations between products. Notably, Energy Drink is identified as an association hub with strong connections to several products, including Sugar, Tomato, Potato, and Beef. Furthermore, a strong non-intuitive association pattern is discovered between Detergent → Earphones, with the highest lift value of 1.850, revealing potential cross-category marketing opportunities that were previously unexplored. The main contribution of this study lies in its ability to address the challenges of sparse retail data while producing actionable insights for business decision-making. Practical implications include optimizing product placement strategies, designing effective product bundling schemes, and enhancing cross-selling performance. Therefore, this study provides both methodological and practical contributions within the context of data-driven retail analytics.

Keywords: FP-Growth, Association Rule Mining, Data Sparsity, Retail Analytics, Marketing Strategy.

Abstrak—Meningkatnya kompleksitas data transaksi dalam sektor ritel modern, diperlukan pendekatan analitik yang lebih canggih untuk secara efektif mengekstraksi pola tersembunyi, khususnya dalam kondisi data yang sangat jarang (sparse). Penelitian ini bertujuan untuk mengidentifikasi pola pembelian pelanggan serta menghasilkan aturan asosiasi yang signifikan menggunakan algoritma Frequent Pattern Growth (FP-Growth) guna mendukung strategi pemasaran berbasis data. Dengan mengatasi kesenjangan penelitian pada metode konvensional yang kesulitan menangani data ritel yang sparse, studi ini menekankan optimalisasi ekstraksi aturan asosiasi yang tidak hanya valid secara statistik, tetapi juga bernilai praktis. Metode yang diusulkan mengimplementasikan FP-Growth menggunakan RapidMiner pada dataset yang terdiri dari 10.000 data, yang merepresentasikan 1.991 transaksi dalam 68 kategori produk. Tahap pra-proses mencakup transformasi dataset ke dalam format keranjang (basket) menggunakan teknik pivoting serta konversi atribut menjadi bentuk binominal. Parameter minimum support (0,04) dan minimum confidence (0,12) ditentukan berdasarkan karakteristik distribusi data yang menunjukkan tingkat sparsity sebesar 94,1%. Hasil penelitian menunjukkan bahwa algoritma FP-Growth berhasil menghasilkan 16 aturan asosiasi yang signifikan dengan nilai lift lebih dari 1, yang menunjukkan adanya korelasi positif yang bermakna antar produk. Secara khusus, produk Energy Drink teridentifikasi sebagai

pusat asosiasi (association hub) dengan hubungan kuat terhadap beberapa produk lain seperti Gula, Tomat, Kentang, dan Daging Sapi. Selain itu, ditemukan pola asosiasi yang kuat dan tidak intuitif antara Deterjen → Earphone, dengan nilai lift tertinggi sebesar 1,850, yang mengungkap peluang pemasaran lintas kategori yang sebelumnya belum teridentifikasi. Kontribusi utama penelitian ini terletak pada kemampuannya dalam mengatasi tantangan data ritel yang sparse sekaligus menghasilkan wawasan yang dapat ditindaklanjuti untuk pengambilan keputusan bisnis. Implikasi praktis meliputi optimalisasi strategi penempatan produk, perancangan skema bundling produk yang efektif, serta peningkatan performa cross-selling. Oleh karena itu, penelitian ini memberikan kontribusi baik secara metodologis maupun praktis dalam konteks analitik ritel berbasis data.

Kata Kunci : FP-Growth, Association Rule Mining, Data Sparsity, Analitik Ritel, Strategi Pemasaran.

INTRODUCTION

Perkembangan teknologi informasi telah mendorong transformasi besar dalam industri ritel modern, di mana data transaksi pelanggan menjadi sumber utama dalam memahami perilaku pembelian dan mendukung strategi pemasaran berbasis data. Seiring meningkatnya jumlah transaksi harian yang tercatat melalui sistem *Point of Sale* (POS), muncul kebutuhan mendesak bagi perusahaan untuk menggali informasi tersembunyi di balik data tersebut. Dalam konteks ini, *data mining* menjadi pendekatan yang esensial untuk mengubah data mentah menjadi wawasan strategis yang dapat meningkatkan efisiensi operasional dan daya saing bisnis.

Salah satu teknik *data mining* yang paling efektif dalam menganalisis perilaku pembelian pelanggan adalah *association-rule mining* (ARM). ARM berperan penting dalam mengidentifikasi keterkaitan antarproduk yang sering dibeli secara bersamaan sehingga memungkinkan peritel untuk menyesuaikan strategi pemasaran, menyusun paket promosi, mengoptimalkan tata letak produk, dan memperbaiki manajemen persediaan [1],[2]. Melalui proses ini, data transaksi yang semula bersifat acak dapat diubah menjadi pola pembelian yang bermakna dan mencerminkan preferensi pelanggan. Dengan demikian, ARM berkontribusi langsung terhadap pengambilan keputusan yang lebih akurat dan adaptif di sektor ritel.

Di antara algoritma ARM, *Frequent Pattern Growth* (*Fp-growth*) menjadi metode yang banyak digunakan karena kemampuannya dalam mengekstraksi *frequent itemsets* tanpa menghasilkan kandidat aturan yang berlebihan seperti pada algoritma Apriori. *Fp-growth* terbukti lebih efisien dalam kecepatan pemrosesan dan mampu mendeteksi pola pembelian dengan jumlah item yang lebih besar, yang pada gilirannya mendukung perencanaan promosi secara dinamis [3]. Penerapan *Fp-growth* juga memfasilitasi identifikasi produk

cross-selling potensial dan memperkaya strategi penjualan berdasarkan perilaku aktual pelanggan.

Penelitian terbaru menegaskan bahwa variasi dari algoritma *Fp-growth* mampu menghasilkan wawasan bisnis yang lebih mendalam dan aplikatif. Lin, Chuang, Chuang, dan Chang, menunjukkan bahwa integrasi antara *big data pipeline* dan *association learning* dapat meningkatkan kinerja sistem rekomendasi produk dan indikator kinerja pemasaran (*marketing KPIs*). Sementara itu, [4] mengembangkan *Region-Aware Fp-growth* yang memperhitungkan dimensi lokasi untuk menemukan asosiasi spesifik wilayah, sedangkan [5] memperkenalkan ARMMatrix untuk membantu analisis menafsirkan himpunan aturan besar menjadi rekomendasi merchandising yang dapat ditindaklanjuti. Temuan tersebut memperkuat peran *Fp-growth* sebagai tulang punggung analisis pola pembelian dalam era *big data retail*.


Lebih lanjut, studi oleh [6] menggabungkan prediksi pola dan preferensi pelanggan untuk menghasilkan sistem rekomendasi *next-basket* yang lebih akurat, sementara [7] mengaplikasikan gabungan *clustering* dan ARM pada lebih dari satu juta transaksi supermarket untuk menghasilkan strategi pemasaran dan pengelolaan stok yang lebih tepat sasaran. Kajian-kajian mutakhir ini menunjukkan bahwa algoritma *Fp-growth* bukan hanya alat analitik, tetapi juga menjadi fondasi strategis dalam penerapan *data-driven marketing* di sektor ritel modern ([8] [4]; [5]; [6]; [7]).

Dalam konteks Indonesia, penerapan teknik analisis pola pembelian menggunakan *Fp-growth* memiliki relevansi tinggi bagi pelaku usaha ritel, baik skala besar maupun menengah, yang menghadapi tantangan kompetisi ketat dan perilaku konsumen yang dinamis. Pemanfaatan data transaksi untuk menemukan pola pembelian tidak hanya membantu meningkatkan efektivitas kampanye promosi, tetapi juga dapat memperkuat loyalitas pelanggan dan meningkatkan keuntungan melalui strategi pemasaran yang lebih personal dan terukur. Dengan demikian, penelitian ini memiliki urgensi akademik dan praktis dalam mendorong

transformasi digital sektor ritel menuju pengambilan keputusan berbasis data.

MATERIALS AND METHODS

Desain penelitian ini sepenuhnya bersifat kuantitatif, yang memanfaatkan kekuatan analisis numerik dan algoritma data mining untuk memahami perilaku pelanggan secara objektif. Pendekatan ini memberikan kontribusi dalam menghubungkan antara analisis data transaksi dengan penerapan strategi pemasaran berbasis data di sektor ritel modern.



Gambar 1. Alur Penelitian.

Alur penelitian analisis asosiasi pada data transaksi ritel menggunakan metode FP-Growth. Proses dimulai dari tahap *terminator mulai*, kemudian dilanjutkan dengan identifikasi masalah dan studi literatur untuk memahami konteks penelitian serta menentukan pendekatan yang tepat. Setelah itu, dilakukan pengumpulan data sekunder dari Kaggle yang berupa dataset transaksi ritel. Data yang diperoleh kemudian masuk ke tahap praproses, yang meliputi pembersihan data (menghapus nilai kosong), seleksi atribut yang relevan, serta transformasi data agar sesuai untuk analisis.

Selanjutnya, data yang telah diproses diubah ke dalam format *basket* (data siap olah), yang merepresentasikan setiap transaksi sebagai kumpulan item. Data ini kemudian dianalisis menggunakan algoritma FP-Growth dengan menentukan parameter seperti minimum support, minimum confidence, dan pencarian *frequent itemsets*. Hasil dari proses ini digunakan untuk membentuk *association rules* yang menggambarkan hubungan antar produk dalam transaksi.

Tahap berikutnya adalah evaluasi hasil menggunakan metrik support, confidence, dan lift untuk memastikan bahwa aturan asosiasi yang dihasilkan memiliki kekuatan dan relevansi yang baik. Setelah itu, dilakukan interpretasi serta visualisasi hasil agar lebih mudah dipahami. Proses penelitian diakhiri dengan penarikan kesimpulan serta penyusunan rekomendasi bisnis, yang dapat digunakan

untuk mendukung strategi pemasaran seperti penempatan produk dan cross-selling.

RESULTS AND DISCUSSION

Setelah proses preprocessing data selesai dilakukan, tahap selanjutnya adalah menerapkan algoritma FP-Growth untuk menemukan pola pembelian pelanggan berdasarkan data transaksi yang tersedia. Algoritma ini digunakan untuk mencari frequent itemset, yaitu kombinasi item yang sering muncul dalam transaksi pelanggan.

Pada penelitian ini, proses pencarian frequent itemset dilakukan menggunakan operator FP-Growth pada perangkat lunak RapidMiner dengan parameter minimum support sebesar 0,04. Nilai minimum support tersebut dipilih berdasarkan hasil pengujian parameter sebelumnya yang menunjukkan bahwa nilai tersebut mampu menghasilkan jumlah aturan asosiasi yang cukup representatif untuk dianalisis.

Berdasarkan proses tersebut, sistem menghasilkan sejumlah frequent itemset yang terdiri dari item tunggal (size 1) dan kombinasi dua item (size 2). Itemset dengan ukuran satu menunjukkan produk yang sering muncul secara individual dalam transaksi pelanggan, sedangkan itemset dengan ukuran dua menunjukkan kombinasi produk yang sering dibeli secara bersamaan dalam satu transaksi.

Beberapa frequent itemset dengan nilai support tertinggi yang dihasilkan dari proses algoritma FP-Growth ditampilkan pada Tabel 1 berikut

Tabel 1 Hasil Frequentitemset

No	Itemset	Size	Support
1	Dishwashing Liquid	1	0,082
2	Chips	1	0,081
3	Cake	1	0,079
4	Energy Drink	1	0,079
5	Soda	1	0,079
6	Prawns	1	0,079
7	Tissue	1	0,079
8	Phone Cover	1	0,078
9	Milk	1	0,078
10	Face Wash	1	0,077
11	Milk, Butter	2	0,010
12	Earphones, Detergent	2	0,010
13	Dishwashing Liquid, Chicken Breast	2	0,009
14	Chips, Cheese	2	0,009
15	Energy Drink, Tomato	2	0,009

Berdasarkan Tabel 1 dapat dilihat bahwa beberapa produk memiliki nilai support yang cukup tinggi dibandingkan produk lainnya. Produk dengan nilai support tertinggi adalah Dishwashing Liquid dengan nilai support sebesar 0,082, diikuti oleh

Chips dengan nilai support sebesar 0,081, serta beberapa produk lainnya seperti Cake, Energy Drink, dan Soda yang memiliki nilai support sebesar 0,079.

Nilai support tersebut menunjukkan bahwa produk-produk tersebut sering muncul dalam transaksi pelanggan sehingga dapat dikategorikan sebagai produk yang memiliki tingkat penjualan yang cukup tinggi.

Selain item tunggal, algoritma FP-Growth juga menemukan beberapa kombinasi item yang sering muncul secara bersamaan dalam transaksi pelanggan. Contohnya adalah kombinasi Milk dan Butter dengan nilai support sebesar 0,010, serta kombinasi Chips dan Cheese dengan nilai support sebesar 0,009.

Meskipun nilai support dari kombinasi item tersebut relatif kecil, namun pola tersebut tetap dapat memberikan informasi mengenai kecenderungan pelanggan dalam melakukan pembelian produk secara bersamaan. Informasi ini dapat dimanfaatkan oleh perusahaan untuk menentukan strategi pemasaran seperti bundling produk, cross-selling, serta pengaturan tata letak produk di rak toko.

Frequent itemset yang dihasilkan dari proses ini kemudian digunakan sebagai dasar dalam pembentukan association rule pada tahap selanjutnya untuk mengetahui hubungan antarproduk secara lebih spesifik.

Setelah proses pencarian frequent itemset menggunakan algoritma FP-Growth selesai dilakukan, tahap selanjutnya adalah membentuk association rule untuk mengetahui hubungan antarproduk yang sering muncul secara bersamaan dalam transaksi pelanggan.

Pembentukan aturan asosiasi dilakukan menggunakan operator Create Association Rules pada RapidMiner dengan parameter minimum confidence sebesar 0,12. Proses ini menghasilkan sejumlah aturan asosiasi yang menunjukkan keterkaitan antara satu produk dengan produk lainnya dalam transaksi pelanggan.

Dalam penelitian ini, evaluasi aturan asosiasi tidak hanya menggunakan nilai support dan confidence, tetapi juga menggunakan beberapa metrik tambahan seperti lift, leverage, dan conviction untuk mengukur kekuatan hubungan antarproduk secara lebih komprehensif.

Hasil association rule yang diperoleh dari proses tersebut ditampilkan pada Tabel 2 berikut.

Tabel 2 Hasil Association Rules

No	Premis	Conclusi	Confide	Lift
----	--------	----------	---------	------

1	Detergent	Earphones	0,134	1,850
2	Sugar	Energy Drink	0,133	1,680
3	Butter	Milk	0,132	1,695
5	Tomato	Energy Drink	0,127	1,597
6	Spices	Shoes	0,127	1,660
7	Soap	Salt	0,126	1,628
8	Cheese	Chips	0,126	1,557
9	Vitamins	Soda	0,125	1,575
10	Potato	Energy Drink	0,124	1,564
11	Milk	Butter	0,123	1,695
12	Bread	Pastry	0,122	1,658
13	Pastry	Bread	0,122	1,658
14	Chicken Breast	Dishwashing Liquid	0,121	1,59
15	Beef	Energy Drink	0,120	1,56
16	Salt	Soap	0,120	1,62

Berdasarkan Tabel 2 evaluasi aturan asosiasi pada penelitian ini tidak hanya menggunakan metrik support dan confidence, tetapi juga dilengkapi dengan metrik tambahan yaitu lift, leverage, dan conviction. Penggunaan beberapa metrik ini bertujuan untuk memberikan analisis yang lebih komprehensif terhadap kekuatan hubungan antar item dalam dataset transaksi.

Pada penelitian-penelitian sebelumnya, umumnya evaluasi association rule hanya berfokus pada support dan confidence, sehingga hubungan antar item belum sepenuhnya mencerminkan tingkat ketergantungan yang sebenarnya. Oleh karena itu, penelitian ini mengatasi keterbatasan tersebut dengan menambahkan metrik lift untuk mengukur kekuatan hubungan relatif, leverage untuk melihat selisih probabilitas aktual terhadap independensi, serta conviction untuk mengukur tingkat kepercayaan terhadap aturan yang dihasilkan.

Dengan demikian, penambahan metrik evaluasi ini mampu menjawab research gap terkait keterbatasan analisis pada penelitian sebelumnya, serta menghasilkan aturan asosiasi yang lebih akurat dan relevan dalam mendukung pengambilan keputusan strategi pemasaran pada data transaksi retail.

Berdasarkan Tabel 2 diperoleh sebanyak 16 aturan asosiasi yang memenuhi nilai minimum support dan confidence yang telah ditentukan. Aturan asosiasi dengan nilai confidence tertinggi adalah Detergent → Earphones dengan nilai confidence sebesar 0,134 serta nilai lift sebesar

1,850. Hal ini menunjukkan bahwa pelanggan yang membeli Detergent memiliki kecenderungan lebih tinggi untuk membeli Earphones dalam transaksi yang sama.

Selain itu terdapat hubungan antara Butter dan Milk yang memiliki nilai confidence sebesar 0,132 dengan nilai lift sebesar 1,695, yang menunjukkan bahwa kedua produk tersebut cukup sering dibeli secara bersamaan oleh pelanggan.

Beberapa aturan lainnya seperti Cheese → Chips, Vitamins → Soda, serta Potato → Energy Drink juga menunjukkan adanya kecenderungan pelanggan untuk membeli produk-produk tertentu secara bersamaan dalam satu transaksi.

Selain itu, terdapat pula hubungan antarproduk lintas kategori seperti Soap → Salt dan Spices → Shoes yang menunjukkan bahwa dalam satu transaksi pelanggan tidak hanya membeli produk dalam satu kategori tertentu, tetapi juga mengkombinasikan berbagai jenis produk sesuai dengan kebutuhan mereka.

Jika dilihat dari nilai lift yang dihasilkan pada aturan asosiasi, sebagian besar aturan memiliki nilai lift lebih besar dari satu. Hal ini menunjukkan bahwa hubungan antarproduk yang ditemukan memiliki korelasi positif, sehingga kombinasi produk tersebut tidak terjadi secara kebetulan dalam transaksi pelanggan.

Secara keseluruhan, hasil analisis ini menunjukkan bahwa pola pembelian pelanggan dalam dataset transaksi memiliki kecenderungan terhadap kombinasi produk tertentu yang muncul secara berulang. Pola-pola tersebut mencerminkan perilaku konsumen dalam melakukan pembelian produk yang dapat dimanfaatkan oleh perusahaan untuk memahami preferensi pelanggan serta mendukung penyusunan strategi pemasaran yang lebih efektif.

CONCLUSION

Berdasarkan hasil penelitian yang telah dilakukan terhadap data transaksi ritel menggunakan algoritma FP-Growth, dapat disimpulkan bahwa pola pembelian pelanggan berhasil diidentifikasi secara efektif meskipun dataset memiliki tingkat sparsity yang tinggi (94,1%). Algoritma FP-Growth terbukti mampu mengekstraksi hubungan antarproduk secara efisien melalui pembentukan struktur FP-Tree tanpa perlu proses pembangkitan kandidat, sehingga menunjukkan kinerja yang adaptif terhadap karakteristik data ritel modern yang kompleks. Aturan asosiasi yang dihasilkan juga memiliki nilai signifikan dan relevansi bisnis,

dengan ditemukannya 16 aturan yang memiliki nilai lift lebih dari 1, yang mengindikasikan adanya korelasi positif antarproduk. Penggunaan parameter minimum support (0,04) dan minimum confidence (0,12) dinilai tepat karena mampu menyeimbangkan antara jumlah aturan dan kualitas hubungan yang dihasilkan.

Selain itu, penelitian ini berhasil mengungkap pola pembelian yang bersifat intuitif maupun non-intuitif. Pola intuitif menggambarkan hubungan produk yang secara logis sering dibeli bersama, sedangkan pola non-intuitif seperti hubungan antara detergent dan earphones dengan nilai lift tertinggi (1,850) membuka peluang strategi pemasaran lintas kategori yang sebelumnya tidak teridentifikasi. Produk Energy Drink juga teridentifikasi sebagai “association hub” karena memiliki keterkaitan dengan berbagai produk lain seperti sugar, tomato, potato, dan beef, sehingga berpotensi dijadikan sebagai anchor product dalam strategi pemasaran. Temuan ini menunjukkan bahwa perilaku konsumen tidak selalu linear dan dapat dipengaruhi oleh berbagai faktor seperti impulsivitas dan kenyamanan dalam berbelanja.

Lebih lanjut, hasil aturan asosiasi yang diperoleh dapat diimplementasikan secara praktis dalam berbagai strategi pemasaran, seperti penyusunan product bundling, penerapan cross-selling lintas kategori, serta optimasi penataan produk (product placement) untuk meningkatkan peluang pembelian simultan. Penelitian ini juga memberikan kontribusi akademik dan praktis, di mana secara akademik memperkuat bukti bahwa FP-Growth tetap efektif pada data dengan tingkat sparsity tinggi serta pentingnya metrik lift dalam mengevaluasi kekuatan hubungan antarproduk. Secara praktis, penelitian ini menyediakan insight berbasis data yang dapat membantu pelaku ritel dalam merancang strategi pemasaran yang lebih efektif, efisien, dan sesuai dengan perilaku aktual pelanggan. Dengan demikian, penelitian ini berhasil menjawab seluruh rumusan masalah dan menunjukkan bahwa pendekatan data mining berbasis FP-Growth dapat menjadi fondasi yang kuat dalam mendukung pengambilan keputusan strategis di sektor ritel.

REFERENCE

- [1] S. Hashad, T. Y. Wah, A. Alnoor, and J. Chew, “Comparative study of Apriori and FP-Growth algorithms for large-scale retail POS data analysis,” *International Journal of Advanced Computer Science and Applications*, vol. 15, no. 2, pp. 210–222, 2024.

- [2] D. Yanti, F. Maradjabessy, A. Qurtubi, and R. Rachmadewi, "Association rule mining for customer behavior analysis in retail data using FP-Growth algorithm," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, vol. 11, no. 2, pp. 178–189, 2024.
- [3] R. S. Hashad, T. Y. Wah, A. S. Alnoor, and B. K. Chew, "A comparative study of Apriori and FP-Growth algorithms for retail market basket analysis," *Computers*, vol. 13, no. 5, pp. 95–109, 2024, doi: 10.3390/computers13050095.
- [4] H. Jang, "Region-aware FP-Growth for spatial retail transaction analysis," *Information Sciences*, vol. 577, pp. 353–370, 2021, doi: 10.1016/j.ins.2021.07.029.
- [5] A. Varu, J. Christino, and F. Paulovich, "ARMatrix: Interactive visualization and interpretation of large association rule sets for merchandising decisions," *Information Visualization*, vol. 21, no. 1, pp. 52–70, 2022, doi: 10.1177/14738716211057123.
- [6] C. Chen and H. Li, "Next-basket recommendation via hybrid pattern prediction and association learning," *Expert Systems with Applications*, vol. 186, p. 115763, 2021, doi: 10.1016/j.eswa.2021.115763.
- [7] A. Alawadh and A. Barnawi, "Integrating clustering and association rule mining for large-scale retail transaction analysis," *Journal of Big Data*, vol. 11, no. 2, pp. 77–95, 2024, doi: 10.1186/s40537-024-00987-1.
- [8] S. C. Lin, Y. Y. Chuang, C. L. Chuang, and Y. C. Chang, "Integrating big data pipelines and association learning for product recommendation systems," *Applied Sciences*, vol. 11, no. 19, p. 9092, 2021, doi: 10.3390/app1119092.