



Analisis Pola Asosiasi Kompetensi Teknis pada Lowongan Kerja Artificial Intelligence Menggunakan Algoritma Apriori dan Visualisasi Network Graph

Noor Latifah^{1*}, Mahavita Nabila Syahputri²

¹⁻² Program Studi Sistem Informasi, Universitas Muria Kudus, Indonesia

*Penulis Korespondensi: noor.latifah@umk.ac.id

Abstract. The gap between academic curriculum content and modern industrial needs is often an obstacle for fresh graduates in the Information Technology field, particularly in the rapidly evolving Artificial Intelligence (AI) sector. This study aims to identify the relationship patterns among technical competencies (hard skills) most demanded by the global industry. The method employed is Association Rule Mining with the Apriori algorithm to discover association rules between skills, and Network Graph Analysis to visualize the topological map of these competencies. The research dataset covers 15,000 AI job vacancies from the 2024-2025 period, analyzed in depth using Support, Confidence, and Lift Ratio evaluation parameters to validate the strength of relationships between items. The results show that Python is the central competency with the highest frequency of occurrence. Strong association rules were found indicating that proficiency in TensorFlow has a high probability of requiring Python proficiency. The Network Graph visualization reveals three main competency clusters: Data Engineering Ecosystem, Deep Learning, and Infrastructure. These findings offer a strategic foundation for aligning curricula with the job market. Focusing on strengthening the identified competency clusters is expected to directly enhance the relevance and work readiness of graduates.

Keywords: Apriori Algorithm; Artificial Intelligence; Business Intelligence; Network Graph; Technical Competencies.

Abstrak. Kesenjangan antara muatan kurikulum akademik dan kebutuhan industri modern seringkali menjadi kendala bagi lulusan baru di bidang Teknologi Informasi, khususnya pada sektor Artificial Intelligence (AI) yang berkembang pesat. Penelitian ini bertujuan untuk mengidentifikasi pola hubungan antar kompetensi teknis (*hard skills*) yang paling diminati oleh industri global. Metode yang digunakan adalah Association Rule Mining dengan algoritma Apriori untuk menemukan aturan keterkaitan antar skill, serta analisis graf (*Network Graph Analysis*) untuk memvisualisasikan peta topologi kompetensi tersebut. Dataset penelitian mencakup 15.000 data lowongan pekerjaan AI periode 2024-2025 yang dianalisis secara mendalam menggunakan parameter evaluasi *Support*, *Confidence*, dan *Lift Ratio* guna memvalidasi kekuatan hubungan antar item. Hasil penelitian menunjukkan bahwa Python merupakan kompetensi sentral dengan frekuensi kemunculan tertinggi. Ditemukan aturan asosiasi yang kuat bahwa penguasaan TensorFlow memiliki probabilitas tinggi untuk mempersyaratkan penguasaan Python. Visualisasi *Network Graph* memperlihatkan tiga kluster kompetensi utama: Ekosistem Data Engineering, Deep Learning, dan Infrastruktur. Hasil penelitian ini menawarkan pijakan yang strategis untuk menyelaraskan kurikulum dengan pasar kerja. Fokus pada penguatan kluster kompetensi yang teridentifikasi diharapkan dapat langsung meningkatkan relevansi dan kesiapan kerja lulusan.

Kata kunci: Algoritma Apriori; Artificial Intelligence; Kecerdasan Bisnis; Kompetensi Teknis; Network Graph.

1. LATAR BELAKANG

Revolusi Industri 4.0 telah menempatkan Artificial Intelligence (AI) sebagai teknologi inti dalam transformasi bisnis global. Permintaan tenaga kerja di bidang ini melonjak drastis, namun seringkali tidak diimbangi dengan ketersediaan talenta yang memiliki kombinasi skill yang tepat. Pesatnya perkembangan teknologi ini menciptakan kesenjangan (*gap*) yang nyata antara kurikulum akademik dengan kebutuhan praktis di industri. Permasalahan mendasar yang sering muncul adalah kurangnya pemahaman mengenai pola hubungan antar kompetensi teknis. Analisis pasar kerja konvensional umumnya hanya menyajikan statistik deskriptif

berupa daftar *skill* terpopuler, tanpa memberikan wawasan mengenai bagaimana *skill* tersebut saling berkaitan. Padahal, menurut Fauzi et al. (2023), pemanfaatan *Business Intelligence* (BI) sangat vital dalam merumuskan strategi dan pengambilan keputusan bisnis yang akurat. Keputusan yang didasarkan pada data historis yang komprehensif akan jauh lebih efektif dibandingkan keputusan yang hanya didasarkan pada intuisi.

Tanpa pemahaman mengenai asosiasi ini, proses pengembangan diri mahasiswa maupun pencari kerja menjadi tidak terarah. Hal ini serupa dengan tantangan dalam dunia pendidikan secara umum, dimana Mulyana et al. (2024) menekankan pentingnya rekomendasi berbasis data, seperti penggunaan algoritma *clustering*, untuk menentukan pilihan studi yang tepat bagi mahasiswa. Dalam konteks karir AI, mahasiswa perlu mengetahui paket kompetensi apa yang harus dipelajari secara bersamaan. Hal ini krusial untuk menghindari fenomena *skills mismatch* yang sering terjadi, di mana lulusan memiliki kemampuan teknis namun tidak terintegrasi sesuai ekosistem yang dibutuhkan industri. Oleh karena itu, diperlukan pendekatan berbasis data untuk memberikan rekomendasi yang akurat guna meminimalisir kesalahan dalam pengambilan keputusan studi dan karir. Mahmud Nawawi et al. (2024) menegaskan bahwa model klasifikasi Machine Learning memiliki potensi untuk mengungkap pola tersembunyi dari data historis, termasuk riwayat pendidikan dan minat, yang sangat berguna dalam proses prediksi ketepatan penempatan karir. Oleh karena itu, diperlukan pendekatan Data Mining untuk mengungkap pola tersembunyi (*hidden patterns*) dari data rekrutmen yang masif.

2. KAJIAN TEORITIS

Data Mining dan Association Rule

Data Mining didefinisikan sebagai proses ekstraksi pola menarik dari data dalam jumlah besar yang sebelumnya tidak diketahui. Salah satu teknik utamanya adalah *Association Rule Mining* yang bertujuan menemukan korelasi atau hubungan sebab-akibat antar item dalam suatu dataset transaksi. Penerapan metode ini sudah terbukti efektif di berbagai sektor industri. Sebagai contoh, Handayanna & Irfiani, (2021) menggunakan algoritma ini untuk menganalisis pola penjualan makanan guna meningkatkan strategi pemasaran. Selain itu, Saputra et al. (2023) juga mengimplementasikan metode serupa pada penjualan bahan bangunan untuk mengetahui barang apa saja yang sering dibeli bersamaan oleh konsumen. Hal ini menunjukkan fleksibilitas metode asosiasi untuk diterapkan pada berbagai jenis data, termasuk data kompetensi kerja.

Algoritma Apriori dan Market Basket Analysis

Metode spesifik yang digunakan dalam penelitian ini adalah analisis keranjang pasar (*Market Basket Analysis*) dengan Algoritma Apriori. Menurut Katarina Sianturi et al. (2023), metode ini bertujuan mengetahui pola beli konsumen atau pola asosiasi item yang sering muncul bersamaan dalam suatu transaksi. Informasi ini sangat berharga untuk penataan letak barang atau, dalam konteks penelitian ini, penyusunan kurikulum. Secara teknis, Husain et al. (2023) menjelaskan bahwa Apriori bekerja dengan cara *iterative* (berulang) untuk menemukan *frequent itemset* yang memenuhi standar minimum *support* dan *confidence* yang telah ditentukan. Secara matematis, kekuatan hubungan asosiasi dalam algoritma ini diukur menggunakan tiga parameter utama, yaitu:

- a. *Support* (Nilai Penunjang) Mengukur seberapa sering kombinasi item muncul dalam keseluruhan transaksi.

$$\text{Support}(A) = \frac{\text{Total Transaksi}}{\text{Jumlah Transaksi mengandung } A}$$

- b. *Confidence* (Nilai Kepastian) Mengukur kuatnya hubungan kebenaran antar item (peluang bersyarat).

$$\text{Confidence}(A \rightarrow B) = \frac{\text{Support}(A)}{\text{Support}(A \cup B)}$$

- c. *Lift Ratio* (Nilai Uji) Mengukur validitas aturan. Nilai Lift > 1 menunjukkan korelasi positif yang valid dan bukan kebetulan.

$$\text{Lift}(A \rightarrow B) = \frac{\text{Support}(B)}{\text{Confidence}(A \rightarrow B)}$$

Keandalan algoritma ini juga didukung oleh penelitian Dongga et al. (2023) yang berhasil memanfaatkan Apriori untuk menentukan persediaan barang secara efisien berdasarkan pola data historis. Visualisasi Data dan Dashboard Selain penggalian data, aspek visualisasi memegang peranan penting dalam sistem Kecerdasan Bisnis. Data hasil tambang (*mining*) seringkali berbentuk angka yang sulit dipahami secara langsung. Afikah et al. (2022) menyatakan bahwa implementasi BI melalui platform visualisasi (seperti *Tableau* atau *Dashboard* kustom) sangat efektif untuk menganalisis data kompleks menjadi informasi yang mudah dipahami oleh pengambil keputusan. Dalam penelitian ini, visualisasi *Network Graph* digunakan untuk memetakan hubungan antar kompetensi agar lebih intuitif.

3. METODE PENELITIAN

Pengumpulan Data

Penelitian ini menggunakan dataset sekunder "AI Job Market Dataset" yang mencakup data lowongan pekerjaan global di bidang *Artificial Intelligence* untuk periode tahun 2024 hingga 2025. Dataset terdiri dari 15.000 baris data dengan berbagai atribut seperti *Job Title*, *Company Location*, dan *Salary*. Fokus utama analisis dalam penelitian ini adalah pada atribut *required_skills* yang berisi daftar kompetensi teknis yang dipersyaratkan oleh perusahaan. Sampel data yang digunakan dapat dilihat pada Tabel 1.

Tabel 1. Sampel Data Mentah Lowongan Pekerjaan AI.

Job Title	Company Location	Salary (USD)	Required Skills
AI Research Scientist	China	90,376	Tableau, PyTorch, Kubernetes, Linux, NLP
AI Software Engineer	Canada	61,895	Deep Learning, AWS, Mathematics, Python, Docker
AI Specialist	Switzerland	152,626	Kubernetes, Deep Learning, Java, Hadoop, NLP
NLP Engineer	India	80,215	Scala, SQL, Linux, Python
AI Consultant	France	54,624	MLOps, Java, Tableau, Python

Sumber: AI Job Market Dataset (2025).

Pra-pemrosesan Data (*Data Preprocessing*)

Tahapan pra-pemrosesan data memegang peranan krusial dalam keberhasilan implementasi *Data Mining*. Sebagaimana diterapkan dalam penelitian (Fitriani et al., 2022) yang menggunakan metodologi standar CRISP-DM (*Cross-Industry Standard Process for Data Mining*), kualitas data input sangat menentukan akurasi model yang dihasilkan. Data mentah seringkali mengandung *noise*, nilai yang hilang (*missing values*), atau format yang tidak konsisten yang dapat menyebabkan bias pada hasil analisis asosiasi. Oleh karena itu, penelitian ini melakukan serangkaian tahapan pembersihan yang sistematis.

Langkah pertama adalah Seleksi Fitur (*Feature Selection*). Dataset awal memiliki dimensi yang cukup lebar dengan total 19 atribut, mencakup data administratif seperti tanggal posting (*posting_date*), rasio kerja jarak jauh (*remote_ratio*), hingga skor benefit (*benefits_score*). Mengingat tujuan utama penelitian ini adalah mengungkap pola hubungan antar kompetensi teknis, maka atribut-atribut administratif tersebut dieliminasi karena dianggap tidak relevan dan berpotensi menambah beban komputasi. Penulis melakukan reduksi dimensi dengan hanya mempertahankan atribut kunci, yaitu *Job Title* sebagai identitas posisi dan *Required Skills* sebagai variabel transaksional utama.

Langkah kedua adalah transformasi data menggunakan teknik *Text Mining*. Data pada kolom *Required Skills* tersimpan dalam format teks tunggal (*string*) yang dipisahkan oleh tanda koma (contoh: "Python, SQL, Git"). Format ini tidak dapat diolah langsung oleh algoritma Apriori yang membutuhkan struktur data transaksional. Merujuk pada Cindy Astuti et al.

(2024), teknik pemrosesan teks yang diterapkan meliputi: (1) *Case Folding* untuk menyeragamkan seluruh teks menjadi huruf kecil guna menghindari duplikasi entitas (misalnya "PYTHON" dan "python"); (2) *Tokenization* untuk memecah *string* panjang menjadi daftar *item* terpisah; dan (3) *Trimming* untuk menghapus spasi berlebih di awal dan akhir kata.

Terakhir, dilakukan penyaringan frekuensi (*Frequency Filtering*). Mengingat terdapat ribuan variasi *skill* unik dalam dataset, analisis yang melibatkan seluruh item akan menghasilkan graf yang terlalu padat dan sulit diinterpretasikan. Oleh karena itu, penelitian ini membatasi ruang lingkup analisis pada 15 kompetensi dengan frekuensi kemunculan tertinggi (*top frequent items*). Pembatasan ini bertujuan untuk mereduksi *noise* dari kompetensi yang sangat jarang muncul (*outliers*) agar pola asosiasi utama yang terbentuk benar-benar merepresentasikan tren pasar secara umum.

Implementasi Algoritma

Implementasi teknis penelitian ini dilaksanakan menggunakan bahasa pemrograman Python, dengan memanfaatkan pustaka Pandas untuk manipulasi struktur data dan NetworkX untuk pemodelan graf. Proses analisis dimulai dengan tahap transformasi data transaksi, di mana daftar kompetensi yang sebelumnya berupa teks tidak terstruktur dikonversi menjadi matriks insiden biner (*binary incidence matrix*). Dalam representasi matriks ini, setiap baris mewakili satu dokumen lowongan pekerjaan, sedangkan setiap kolom mewakili satu varian kompetensi unik, dengan nilai 1 menandakan keberadaan *skill* tersebut dan nilai 0 menandakan ketidakberadaan.


Selanjutnya, menurut Agatha et al. (2025), algoritma perhitungan dijalankan secara otomatis untuk mengkalkulasi parameter kinerja kritis jaringan. Sistem melakukan perhitungan iteratif untuk menentukan *power budget*, *rise time budget*, *link margin*, *total loss*, dan *Optical Signal-to-Noise Ratio* (OSNR) dengan mengacu pada standar teknis seperti ITU-T G.652D. Berdasarkan nilai *loss* dan jarak yang dihasilkan, algoritma secara cerdas menentukan kebutuhan dan lokasi penempatan perangkat repeater atau amplifier, memastikan jarak antar perangkat tetap berada dalam ambang batas (*threshold*) yang direkomendasikan, yaitu 80 hingga 100 km.

Tahap akhir implementasi adalah pemetaan hasil asosiasi ke dalam visualisasi *Network Graph* menggunakan algoritma tata letak *Force-Directed* (seperti Fruchterman-Reingold), di mana simpul (*nodes*) merepresentasikan kompetensi teknis dan ketebalan sisi (*edges*) merepresentasikan bobot kekuatan hubungan antar kompetensi tersebut.

4. HASIL DAN PEMBAHASAN

Analisis Deskriptif Kompetensi

Berdasarkan hasil ekstraksi data dari 15.000 lowongan pekerjaan, teridentifikasi kompetensi teknis yang paling mendominasi pasar kerja AI global. Python menempati urutan pertama sebagai *skill* yang paling banyak diminta, diikuti oleh SQL dan TensorFlow. Hal ini mengonfirmasi posisi Python sebagai bahasa standar dalam pengembangan AI. Visualisasi distribusi kompetensi dapat dilihat pada Gambar 1.



Gambar 1. Distribusi 10 Kompetensi Teknis Paling Sering Muncul pada Lowongan AI.

Dominasi keterampilan teknis seperti Python dan SQL dalam data lowongan kerja mengkonfirmasi pentingnya transformasi digital dalam manajemen sumber daya manusia. Hal ini selaras dengan studi Arya Satya Pratama et al. (2023) yang menekankan bahwa penggunaan *Big Data* dan *Artificial Intelligence* saat ini telah menjadi strategi utama bagi departemen HRD dalam meningkatkan efektivitas rekrutmen dan memperkirakan kebutuhan talenta di masa depan dengan akurasi tinggi. Dengan memahami distribusi kompetensi yang paling banyak dicari (*top frequent skills*), organisasi dapat merancang program pelatihan dan strategi perekrutan yang lebih tepat sasaran, sehingga mengurangi potensi kesenjangan kompetensi (*skills gap*) di tengah percepatan era digital.

Aturan Asosiasi (Association Rules)

Setelah tahap perhitungan frekuensi itemset (*frequent itemsets mining*), analisis dilanjutkan ke tahap pembentukan aturan asosiasi menggunakan algoritma Apriori. Dari ribuan kemungkinan kombinasi, sistem melakukan penyaringan (*pruning*) untuk hanya mempertahankan aturan yang memiliki nilai *Lift Ratio* di atas 1.0. Nilai *Lift* ini krusial karena menunjukkan seberapa kuat pengaruh satu kompetensi terhadap kompetensi lainnya dibandingkan jika keduanya muncul secara acak.

Hasil perhitungan terbaik dapat dilihat pada Tabel 2. Data menunjukkan bahwa aturan "TensorFlow → Python" memiliki nilai *Confidence* sebesar 43% dan *Lift Ratio* sebesar 1.36. Secara statistik, ini berarti seorang kandidat yang menguasai TensorFlow memiliki kemungkinan 43% juga menguasai Python, dan keberadaan *skill* TensorFlow meningkatkan probabilitas penguasaan Python sebanyak 1.36 kali lipat dibandingkan rata-rata populasi. Temuan ini sejalan dengan penelitian (Wijaya et al., 2023) yang membuktikan bahwa nilai *Lift* yang tinggi mengindikasikan pola hubungan yang signifikan dan bukan sekadar kebetulan.

Selain itu, ditemukan aturan dengan nilai *Lift* tertinggi (1.80) pada pasangan "Scala → Spark". Angka 1.80 ini sangat tinggi, mengindikasikan hubungan yang hampir eksklusif; artinya, di pasar kerja, sangat jarang ditemukan lowongan yang meminta *Spark* tanpa meminta *Scala*. Pola ketergantungan prasyarat ini memiliki kemiripan karakteristik dengan studi (Anas & Zebua, 2022) dalam domain pendidikan, di mana keberhasilan pada satu variabel prasyarat (seperti mata kuliah dasar) sangat mempengaruhi hasil akhirnya. Dalam konteks penelitian ini, pola semacam itu menjadi dasar yang kuat untuk pengembangan model rekomendasi pelatihan atau pengembangan kurikulum yang berbasis keterampilan yang saling terkait (Anggrawan et al., 2021).

Tabel 2. Aturan Asosiasi Kompetensi Teknis dengan Nilai Lift Tertinggi.

Aturan (Rule)	Confidence	Lift Ratio	Interpretasi Hubungan
TensorFlow → Python	43%	1.36	Penguasaan TensorFlow memiliki ketergantungan positif terhadap bahasa Python.
PyTorch → Python	41%	1.35	Ekosistem riset AI berbasis PyTorch hampir selalu mensyaratkan Python.
Scala → Spark	38%	1.80	Hubungan sangat kuat di bidang <i>Big Data</i> ; Scala adalah bahasa <i>native</i> untuk Spark.
Kubernetes → Docker	35%	1.55	<i>Skill</i> orkestrasi (Kubernetes) selalu beriringan dengan kontainer (Docker).
Java → SQL	32%	1.12	Pengembangan <i>backend</i> Java memiliki korelasi standar dengan SQL.

Sumber: Hasil Pengolahan Data (2025).

Analisis Visualisasi Jaringan (*Network Graph*)


Untuk mengatasi keterbatasan tabel dalam menampilkan hubungan yang kompleks, hasil asosiasi dipetakan ke dalam bentuk graf jaringan (*Network Graph*). Dalam visualisasi ini, setiap kompetensi direpresentasikan sebagai simpul (*node*), dan hubungan asosiasi direpresentasikan sebagai garis penghubung (*edge*). Ukuran simpul merefleksikan frekuensi kemunculan, sedangkan ketebalan garis merefleksikan kekuatan bobot asosiasi (*weight*) antar kompetensi.

Visualisasi pada Gambar 2 memperlihatkan struktur topologi yang menarik. Terlihat jelas bahwa Python memiliki *degree centrality* (jumlah koneksi) tertinggi, menjadikannya "hub" atau pusat gravitasi dari seluruh ekosistem kompetensi AI. Hal ini memvisualisasikan data kuantitatif sebelumnya bahwa Python adalah bahasa penghubung utama.

Lebih lanjut, algoritma tata letak graf berhasil mengelompokkan kompetensi menjadi tiga komunitas (*community structure*) yang terpisah secara natural:

1. **Klaster Data Science:** Terdiri dari Python yang terhubung erat dengan *library* analitik seperti TensorFlow, PyTorch, dan Scikit-Learn.
2. **Klaster Data Engineering:** Terbentuk dari simpul Scala, Java, Spark, dan Hadoop yang saling terhubung tebal, terpisah dari klaster Python.
3. **Klaster MLOps & Infrastructure:** Membentuk segitiga kompetensi antara Kubernetes, Docker, dan Linux di sisi luar graf.

Polarisasi visual ini memberikan wawasan yang tidak terlihat pada tabel biasa: bahwa kompetensi teknis membentuk "paket keahlian" (*skill bundles*). Implikasi praktisnya, seorang *Data Engineer* (Klaster 2) tidak perlu memprioritaskan belajar TensorFlow (Klaster 1) sebelum menguasai Spark, karena jarak graf-nya terlalu jauh. Visualisasi ini mendukung teori Afikah et al. (2022) mengenai efektivitas *dashboard* visual dalam menyederhanakan kompleksitas data untuk pengambilan keputusan strategis.



Gambar 2. Peta Jaringan Asosiasi Kompetensi AI (Top 15 Skills).

Visualisasi pada Gambar 2 memperlihatkan terbentuknya tiga ekosistem utama: (1) *Data Science* (Python-TensorFlow), (2) *Data Engineering* (Scala-Spark), dan (3) *MLOps* (Kubernetes-Docker). Ini menunjukkan bahwa kompetensi teknis membentuk paket keahlian

(*skill bundles*), di mana satu kompetensi seringkali tidak berdiri sendiri melainkan membutuhkan kompetensi pendukung lainnya.

Pentingnya visualisasi dalam analisis asosiasi ini juga didukung oleh temuan Husain et al. (2023). Dalam penelitian mereka mengenai pola pembelian, dijelaskan bahwa pemetaan hasil asosiasi ke dalam bentuk graf jaringan sangat efektif untuk mengidentifikasi centrality atau item pusat. Item dengan derajat (*degree*) koneksi yang tinggi mengindikasikan perannya sebagai produk 'hub' yang memicu interaksi dengan elemen lain. Hal ini selaras dengan struktur jaringan kompetensi AI yang terbentuk pada penelitian ini, di mana Python terlihat memiliki derajat sentralitas tertinggi, menegaskan sebagai kompetensi inti yang menjembatani berbagai kluster spesialisasi.

5. KESIMPULAN DAN SARAN

Berdasarkan implementasi metode hibrida *Association Rule Mining* dan visualisasi *Network Graph* terhadap data lowongan pekerjaan global, penelitian ini menyimpulkan bahwa lanskap kompetensi teknis di bidang *Artificial Intelligence* membentuk pola struktur yang saling ketergantungan. Temuan empiris menunjukkan Python memegang peran sentral, dan terdapat polarisasi spesialisasi yang jelas antara *Data Science*, *Data Engineering*, dan *MLOps*. Implikasi strategis dari temuan ini menyarankan agar institusi pendidikan dan pencari kerja mengubah strategi pembelajaran dari pendekatan isolasi menjadi pendekatan berbasis paket kompetensi yang memiliki korelasi *Lift Ratio* tinggi. Untuk penelitian masa depan, disarankan memperluas variabel analisis dengan melibatkan atribut *soft skills* dan melakukan analisis komparatif antar benua untuk mendapatkan wawasan yang lebih spesifik secara geografis.

DAFTAR REFERENSI

- Afikah, P., Avorizano, A., Afandi, I. R., & Hasan, F. N. (2022). Implementasi business intelligence untuk menganalisis data kasus virus corona di Indonesia menggunakan platform Tableau. *Jurnal Pseudocode*, 9(1), 25–32. <https://doi.org/10.33369/pseudocode.9.1.25-32>
- Agatha, S., & Wulandari, A. (2025). Perancangan sistem perhitungan kinerja jaringan untuk mendukung visualisasi topologi jaringan backbone DWDM. *Prosiding Seminar Nasional Teknik Elektro*, 11.
- Anas, A., & Zebua, A. J. (2022). Implementasi algoritma Apriori untuk mendapatkan pola kelulusan mahasiswa. *Jurnal Ilmiah Media Sisfo*, 16(1), 54–61. <https://doi.org/10.33998/mediasisfo.2022.16.1.1173>
- Anggrawan, A., Mayadi, M., & Satria, C. (2021). Menentukan akurasi tata letak barang menggunakan algoritma Apriori dan FP-Growth. *MATRIK: Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, 21(1), 125–138. <https://doi.org/10.30812/matrik.v21i1.1260>

- Pratama, A. S., Sari, S. M., Faiza, M., Badwi, M., & Anshori, M. I. (2023). Pengaruh artificial intelligence, big data, dan otomatisasi terhadap kinerja SDM di era digital. *Jurnal Publikasi Ilmu Manajemen*, 2(4), 108–123. <https://doi.org/10.55606/jupiman.v2i4.2739>
- Astuti, K. C., Firmansyah, A., & Riyadi, A. (2024). Implementasi text mining untuk analisis sentimen masyarakat terhadap ulasan aplikasi digital Korlantas Polri pada Google Play Store. *REMIK: Riset dan E-Jurnal Manajemen Informatika Komputer*, 8(1). <https://doi.org/10.33395/remik.v8i1.13421>
- Fauzi, A., Nugroho, A. A., Monte, K. A., Ignesia, A. A., Makruf, M. N., Andreas, R., & Hasanah, S. R. (2023). Pemanfaatan business intelligence dalam pembuatan strategi dan pengambilan keputusan bisnis. *Jurnal Portofolio: Jurnal Manajemen dan Bisnis*, 2(3). <https://doi.org/10.70704/jpmb.v2i3.172>
- Fitriani, M., Nama, G. F., & Mardiana, M. (2022). Implementasi association rule dengan algoritma Apriori pada data peminjaman buku menggunakan metodologi CRISP-DM. *Jurnal Informatika dan Teknik Elektro Terapan*, 10(1). <https://doi.org/10.23960/jitet.v10i1.2263>
- Handayanna, F., & Irfiani, E. (2021). Analysis of food sales patterns using the Apriori algorithm. *Journal of Information Systems*, 20(4).
- Husain, Y., Oktaviyani, E. D., & Christina, S. (2023). Analisis perbandingan algoritma Apriori, FP-Growth, dan Eclat dalam menemukan pola pembelian konsumen. *Jurnal Konstelasi*, 3(2). <https://doi.org/10.24002/konstelasi.v3i2.7007>
- Sianturi, S. K., Fansuri, D. S., & Aini, W. N. (2023). Algoritma Apriori untuk mengetahui pola beli konsumen pada sistem informasi market basket analysis berbasis Android. *Jurnal Insan Unggul*, 11(1), 35–58. <https://doi.org/10.47926/jiu.2023.11.1.35-58>
- Nawawi, H. M., Hikmah, A. B., Mustopa, A., & Wijaya, G. (2024). Model klasifikasi machine learning untuk prediksi ketepatan penempatan karir. *Jurnal SAINTEKOM*, 14(1), 13–25. <https://doi.org/10.33020/saintekom.v14i1.512>
- Mulyana, A., Hermawan, Y., & Saputri, N. J. (2024). Penerapan data mining menggunakan algoritma K-means clustering untuk rekomendasi pilihan program studi. *KERNEL: Jurnal Riset Inovasi Bidang Informatika dan Pendidikan Informatika*, 5(1), 60–72. <https://doi.org/10.31284/j.kernel.2024.v5i1.7624>
- Saputra, A., Herlina, H., Sari, L., & Sartika, D. (2023). Implementasi association rule mining pada penjualan barang menggunakan algoritma Apriori. *Jurnal Multidisiplin Dehasen*, 2(4), 709–718. <https://doi.org/10.37676/mude.v2i4.4805>
- Wijaya, A., Faqih, A., Solihudin, D., Rohmat, C. L., & Permana, S. E. (2023). Penerapan association rules menggunakan algoritma Apriori untuk identifikasi pola pembelian. *Jurnal Mahasiswa Teknik Informatika*, 7(6). <https://doi.org/10.36040/jati.v7i6.8270>