

Analisis Komparatif Algoritma *Process Mining* untuk Pemetaan Navigasi dan Deteksi *Bottleneck* E-Commerce

DOI: <http://dx.doi.org/10.35889/jutisi.v15i3.3629>

Creative Commons License 4.0 (CC BY – NC)



Leiden Fauzi Yoka Surya^{1*}, Lyvia Valentina², Zikri Firmansyah³, Fathoni⁴, Ali Ibrahim⁵
 Sistem Informasi, Universitas Sriwijaya, Palembang, Indonesia
 *e-mail *Corresponding Author*: leidenfauzi9@gmail.com

Abstract

E-commerce digitalization generates massive clickstream data, complicating customer journey mapping and bottleneck detection. The unstructured nature of web logs often leads to modeling failures. This study evaluates the performance of Alpha Miner, Heuristic Miner, and Inductive Miner algorithms in mapping user navigation routes and detecting interface inefficiencies using a public e-commerce clickstream dataset. Through Token-Based Replay evaluation, the research shows that Alpha Miner is inefficient for dynamic data and prone to Out of Memory errors. Conversely, Inductive Miner proved superior with a perfect fitness level (0.999), while Heuristic Miner was optimal in filtering noise (0.887). Further evaluations using the Performance Directly-Follows Graph localized the main bottleneck at the post-login transition to the shopping cart addition, which took the longest interface delay (42 minutes). These empirical findings provide a benchmark to optimize user interfaces and boost digital transaction conversions.

Keywords: *Bottleneck; Conformance Checking; Customer Journey; E-Commerce; Process Mining.*

Abstrak

Digitalisasi *e-commerce* menghasilkan data *clickstream* masif yang menyulitkan pemetaan *customer journey* dan deteksi *bottleneck*. Sifat *log web* yang tidak terstruktur sering kali memicu kegagalan pemodelan. Penelitian ini mengevaluasi kinerja *Alpha Miner*, *Heuristic Miner*, dan *Inductive Miner* untuk memetakan navigasi pengguna serta mendeteksi inefisiensi antarmuka menggunakan dataset publik rekaman *clickstream e-commerce*. Melalui evaluasi *Token-Based Replay*, penelitian menunjukkan bahwa *Alpha Miner* tidak efisien untuk data dinamis dan rentan memicu *Out of Memory*. Sebaliknya, *Inductive Miner* terbukti paling unggul dengan tingkat kecocokan sempurna (0.999), sedangkan *Heuristic Miner* optimal dalam menyaring derau (0.887). Evaluasi lanjutan berbasis *Performance Directly-Follows Graph* melokalisasi *bottleneck* utama pada transisi pasca-login menuju penambahan keranjang belanja dengan jeda waktu antarmuka terlama (42 menit). Temuan empiris ini menjadi acuan untuk mengoptimalkan rekayasa antarmuka pengguna demi mendongkrak konversi transaksi digital.

Kata kunci: *Bottleneck; Conformance Checking; Customer Journey; E-Commerce; Process Mining.*

1. Pendahuluan

Digitalisasi bisnis telah secara drastis meningkatkan kompleksitas perjalanan pelanggan (*customer journey*), sehingga pemahaman yang mendalam mengenai perilaku konsumen kini menjadi penentu utama kesuksesan operasional *e-commerce* [1]. Di era saat ini, platform perdagangan digital menghasilkan volume data rekam jejak klik (*clickstream*) yang sangat besar, membuka peluang emas untuk mengekstraksi wawasan berharga bagi profitabilitas perusahaan [2]. Oleh karena itu, optimalisasi dan pengelolaan pengalaman pelanggan (*customer experience*) telah menjadi prioritas utama yang menuntut pendekatan analitik berbasis data tingkat lanjut guna membedah kompleksitas tersebut [3].

Meskipun ketersediaan data log aktivitas sangat melimpah, upaya untuk menganalisis perjalanan navigasi pelanggan sering kali terhambat oleh sifatnya yang sangat rumit dan kerap bersinggungan dengan berbagai sistem eksternal maupun internal [4]. Perilaku interaksi konsumen di *e-commerce* pada umumnya sangat tidak terstruktur, sehingga pemodelan proses dari data ini sering kali menghasilkan representasi visual yang sangat berantakan (model *spaghetti*) dan sulit untuk diinterpretasikan [1], [5]. Kerumitan alur interaksi ini menyulitkan organisasi dalam mendeteksi *bottleneck* (titik kemacetan) dan anomali navigasi yang padahal sangat esensial untuk memperbaiki tata letak antarmuka [6].

Beberapa penelitian sebelumnya telah membuktikan efektivitas *process mining* dalam mengevaluasi rekam jejak digital. Permana et al. [7] menegaskan bahwa identifikasi waktu tunggu (*waiting time*) dan perulangan tak wajar (*rework loops*) melalui *process mining* jauh lebih akurat dibandingkan metode berbasis asumsi kualitatif. Siek dan Mukti [8] dalam penelitiannya menggunakan penambangan log kejadian web untuk mengidentifikasi letak *bottleneck* pada tahap pemesanan produk. Pada manajemen rantai pasok hilir, Tridalestari et al. [9] mengevaluasi kelancaran aktivitas pemenuhan pesanan secara operasional. Selain itu, penelitian oleh Dioses dan Cordova [10] menekankan bahwa menggabungkan metode penemuan proses dengan analisis kinerja sangat penting untuk menemukan titik kemacetan navigasi yang sering kali menghambat pengguna dalam melakukan transaksi di platform digital.

Walaupun kapabilitas analitik penemuan proses telah terbukti, sebagian besar riset perilaku konsumen *e-commerce* masih cenderung bersandar pada analisis kuesioner konvensional alih-alih mengeksplorasi pola nyata navigasi melalui *event log* [11]. Selain itu, tugas pemrosesan *log* mentah untuk membedah anomali navigasi terbukti masih sangat menantang secara teknis [12]. Secara fundamental, algoritma klasik seperti *Alpha Miner* sering kali mengalami penurunan kinerja drastis ketika dihadapkan pada ketidakpastian log kejadian di dunia nyata yang penuh dengan interaksi berulang [13].

Studi literatur di atas telah menunjukkan landasan teoretis yang kuat. Namun, studi yang berfokus pada navigasi *front-end* pengguna umumnya belum membedah secara spesifik komparasi algoritmik sekaligus melokalisasi letak hambatan komputasi secara bersamaan. Kondisi ini melahirkan celah riset (*research gap*) yang signifikan, mengingat belum ada literatur komprehensif yang membedah dan membandingkan performa spesifik algoritma *Alpha*, *Heuristic*, dan *Inductive Miner* secara bersama-sama dalam konteks pemetaan navigasi pengguna *e-commerce* berskala masif. Sebagai solusi, studi ini mengusulkan kerangka analisis komparatif menggunakan tiga algoritma penemuan proses tersebut. *Alpha Miner* akan dimanfaatkan sebagai tolok ukur (*baseline*) rekonstruksi kausalitas fundamental [14]. *Heuristic Miner* diimplementasikan atas dasar keandalannya menangani derau (*noise*) data. Terakhir, *Inductive Miner* diintegrasikan karena pendekatan pohon prosesnya mampu memberikan jaminan struktural formal yang bebas *deadlock* [15], [16].

Tujuan utama penelitian ini adalah untuk mengevaluasi ketepatan ketiga algoritma tersebut secara sistematis dalam merancang model navigasi pengguna sekaligus memetakan metrik *bottleneck* dari *event log e-commerce*. Kontribusi dari studi ini diharapkan mampu memberikan tolok ukur empiris bagi praktisi dalam menyeleksi algoritma yang paling presisi untuk pemodelan data web yang tidak terstruktur.

2. Metodologi

Bagian ini menjelaskan metode yang digunakan dalam penelitian untuk mencapai tujuan pemetaan navigasi pengguna dan deteksi *bottleneck* menggunakan algoritma *process mining*. Metodologi disusun secara sistematis mulai dari ekstraksi data, pra-pemrosesan data (*data preprocessing*), tahapan penemuan proses (*process discovery*) komparatif, analisis performa, hingga evaluasi kesesuaian model (*conformance checking*). Setiap tahapan dirancang untuk memastikan bahwa proses komputasi berlangsung secara terstruktur dan menghasilkan keluaran analitik yang valid. Dengan penjelasan metodologi yang komprehensif, penelitian ini memberikan gambaran yang jelas mengenai alur kerja komputasi serta pendekatan teknis yang diterapkan dalam mengevaluasi rekaman interaksi pengguna platform *e-commerce*.

2.1 Jenis dan Sumber Data

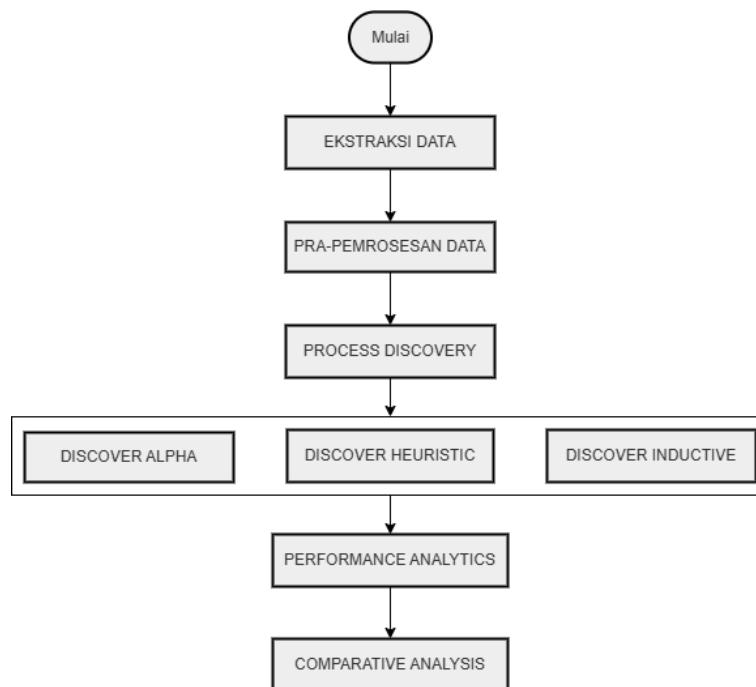
Penelitian ini menggunakan pendekatan kuantitatif analitik melalui pemanfaatan data sekunder yang diakses dari dataset publik Kaggle dengan judul "*E-commerce Clickstream and Transaction Dataset*". Dataset ini memuat 74.817 baris rekaman historis interaksi pengguna pada

platform *e-commerce* yang memenuhi standar kebutuhan pembentukan *event log* dalam *process mining*. Log kejadian ini memuat tiga parameter fundamental penambangan proses, yaitu: *Session ID* (ID Sesi Pengunjung), *Event Type* (Aktivitas halaman yang diklik), dan *Timestamp* (Stempel waktu kejadian riil).

2.2 Penentuan Jumlah Sampel

Metode pengambilan sampel yang diterapkan adalah *Total Sampling* (Sensus), di mana seluruh populasi data dalam dataset tersebut dieksekusi secara utuh tanpa proses pengurangan (sampling). Keputusan ini diambil karena algoritma Process Mining sangat bergantung pada keutuhan kronologis jejak interaksi (*traces*) di setiap *Session ID*. Pengurangan data berpotensi memutus relasi kausalitas antar kejadian dan menghilangkan varian anomali yang justru esensial untuk menemukan titik kemacetan (*bottleneck*) secara presisi. Setelah mengekstraksi *dataset* mentah dari Kaggle dan melalui tahap pembersihan data, seluruh populasi kejadian yang tersisa, yakni sebanyak 74.817 baris *event logs*, dieksekusi secara utuh. Keputusan ini menjamin bahwa model komparatif yang diuji (*Alpha*, *Heuristic*, dan *Inductive Miner*) memiliki landasan data yang komprehensif untuk mendeteksi *bottleneck* antarmuka secara presisi tanpa risiko bias akibat pengurangan sampel.

2.3 Alur Komputasi dan Pra-Pemrosesan (Data Preprocessing)



Gambar 1. Alur tahapan penelitian *process mining*

Implementasi komparatif dalam penelitian ini dieksekusi melalui lingkungan pemrograman Google Colab menggunakan pustaka Python *pm4py*. Rangkaian alur penelitian meliputi:

1. Fase Insiasi dan Ekstraksi Data

Langkah awal dimulai dengan mengunduh dataset sekunder dari Kaggle, yang kemudian dimuat ke dalam lingkungan pengembangan Google Colab menggunakan pustaka *Pandas* guna membedah struktur data awal. Fokus pada tahap ini adalah memastikan bahwa data *clickstream* dan transaksi memiliki atribut kunci yang diperlukan untuk analisis *process mining*.

Secara formal, setiap rekaman interaksi dalam dataset direpresentasikan sebagai himpunan *event log* dengan struktur berikut:

$$L = \{e_1, e_2, \dots, e_n\} \quad (1)$$

di mana setiap kejadian e_i memiliki atribut:

$$e_i = (case_id, activity, timestamp) \quad (2)$$

Di mana *case_id* merupakan identitas unik sesi pengguna (*Session ID*), *activity* merupakan jenis aktivitas yang direkam (*Event Type*), dan *timestamp* merupakan stempel waktu kejadian riil. Dataset yang diekstraksi menghasilkan $e_i = 74.817$ baris rekaman interaksi yang siap diproses.

2. Pra-pemrosesan (*Data Cleaning & Restructuring*)

Pra-pemrosesan adalah tahapan krusial untuk mentransformasi data mentah (*raw data*) dari platform *e-commerce* menjadi format *event log* yang siap diolah oleh algoritma *process mining*. Mengingat log aktivitas web sering kali mengandung banyak derau (*noise*) dan data yang tidak relevan, langkah ini mencakup pembersihan data untuk menangani nilai yang hilang (*missing values*) serta penghapusan aktivitas yang tidak memberikan kontribusi pada pemetaan navigasi utama.

3. *Process Discovery*

Pada tahap ini dilakukan pemodelan proses dari *event log* L menjadi model proses M . Secara umum, proses ini direpresentasikan sebagai fungsi:

$$\alpha: L \rightarrow M \quad (3)$$

Ketiga algoritma diimplementasikan secara paralel: *Alpha Miner* digunakan untuk menangkap logika dasar urutan kejadian; *Heuristic Miner* diterapkan untuk menangani *noise* dengan memfilter aktivitas yang frekuensinya tidak signifikan; dan *Inductive Miner* diintegrasikan guna memastikan model yang dihasilkan bebas dari *deadlock* dan akurat secara struktural.

- **Algoritma *Alpha Miner*:** Implementasi algoritma ini dilakukan untuk merekonstruksi hubungan kausalitas urutan kejadian secara fundamental melalui pemindaian jejak log kejadian berdasarkan *direct succession*:

$$a \rightarrow b \Leftrightarrow \exists \sigma \in L: (a, b) \in \sigma \quad (4)$$

relasi $a \rightarrow b$ menunjukkan bahwa aktivitas a diikuti oleh aktivitas b dalam suatu urutan kejadian (*trace*) σ yang terdapat dalam event log L . Artinya, terdapat setidaknya satu kasus di mana aktivitas a muncul sebelum b secara langsung.

Fokus utama penggunaan *Alpha Miner* dalam penelitian ini adalah kemampuannya dalam menemukan ketergantungan antar aktivitas navigasi serta menghasilkan representasi model dalam bentuk *Petri Net*. Namun, algoritma ini memiliki sensitivitas tinggi terhadap derau (*noise*) data, sehingga hasil dari tahap ini akan menjadi tolok ukur dasar sebelum dibandingkan dengan algoritma yang lebih kompleks.

- **Algoritma *Heuristic Miner*.** Algoritma ini diimplementasikan atas dasar keandalannya dalam menangani data yang mengandung derau (*noise*) dengan cara memfilter aktivitas dan interaksi yang frekuensinya dinilai tidak signifikan. Berbeda dengan *Alpha Miner*, *Heuristic Miner* bekerja dengan mempertimbangkan frekuensi jalur navigasi untuk menentukan tingkat keyakinan (*dependency measure*) pada setiap transisi halaman. *Dependency measure* digunakan untuk menentukan kekuatan hubungan antar aktivitas:

$$dep(a, b) = \frac{f(a, b) - f(b, a)}{f(a, b) + f(b, a) + 1} \quad (5)$$

Nilai $dep(a, b)$ merupakan *dependency measure* yang digunakan untuk mengukur kekuatan hubungan antara aktivitas a dan b . Nilai ini dihitung berdasarkan selisih frekuensi kemunculan a diikuti b ($f(a, b)$) dan sebaliknya ($f(b, a)$), kemudian dinormalisasi untuk menghasilkan nilai antara -1 hingga 1. Semakin tinggi nilai $dep(a, b)$, maka semakin kuat indikasi bahwa aktivitas a mendahului b . Pendekatan ini sangat krusial dalam konteks *e-commerce* guna

menghindari "model *spaghetti*" yang sering muncul akibat perilaku interaksi konsumen yang sangat bervariasi dan tidak terstruktur.

• **Algoritma Inductive Miner.** Algoritma ini diintegrasikan ke dalam penelitian karena pendekatannya yang menggunakan pohon proses (*process tree*), yang mampu memastikan akurasi model serta menjamin keabsahan struktur model proses.

$$IM(L) = \begin{cases} \textit{sequence} & \textit{jika terdapat urutan dominan} \\ \textit{parallel} & \textit{jika terdapat aktivitas paralel} \\ \textit{loop} & \textit{jika terdapat pengulangan} \end{cases} \quad (6)$$

Keunggulan utama *Inductive Miner* adalah kemampuannya dalam menghindari anomali *deadlock* manakala mengevaluasi interaksi kejadian yang berjalan secara paralel. Dalam pemetaan navigasi pengguna, algoritma ini diharapkan dapat memberikan visualisasi yang sangat terjamin kelancarannya, terutama saat menangani perilaku pengguna yang melakukan aktivitas ganda secara bersamaan di platform digital.

4. Performance Analytics

Setelah model terbentuk, dilakukan analisis kinerja untuk mendeteksi titik-titik kemacetan (*bottleneck*) dalam perjalanan navigasi pelanggan. Visualisasi alur navigasi dievaluasi untuk melihat transisi antar halaman, sementara durasi antar aktivitas dihitung untuk mengidentifikasi inefisiensi yang menghambat proses transaksi pada platform *e-commerce*. Mengeksekusi komputasi kalkulasi performa berbasis *Directly-Follows Graph* (DFG) untuk melacak rata-rata waktu jeda antar interaksi antarmuka:

$$t_{avg}(a, b) = \frac{\sum_{i=1}^n (t_b^{(i)} - t_a^{(i)})}{n} \quad (7)$$

di mana $t_a^{(i)}$ dan $t_b^{(i)}$ adalah *timestamp* aktivitas berurutan dalam kasus ke- i .

5. Comparative Analysis

Tahapan ini melibatkan perbandingan mendalam terhadap model yang dihasilkan oleh ketiga algoritma tersebut berdasarkan metrik kualitas, yaitu *fitness* dan *precision*. *Fitness* digunakan untuk mengukur sejauh mana model mampu merepresentasikan atau mereproduksi jejak kejadian pada *event log*, sedangkan *precision* mengukur sejauh mana model tidak menghasilkan perilaku yang berlebihan di luar data yang diamati. Hasil dari perbandingan ini akan memberikan tolok ukur empiris mengenai algoritma mana yang paling presisi dan efektif dalam memetakan perilaku navigasi serta mendeteksi hambatan pada data web yang tidak terstruktur.

2.4 Validasi Kesesuaian Model (Conformance Checking)

Untuk memvalidasi ketangguhan tiap algoritma secara objektif, evaluasi tidak dilakukan secara visual semata, melainkan diukur berbasis matematis menggunakan metode *Token-Based Replay*. Kualitas *Petri net* diukur melalui rasio *Fitness* (f), yakni parameter yang menghitung persentase kemampuan model dalam memutar ulang (reproduksi) jejak digital aslinya tanpa hambatan. Formulasi kalkulasinya adalah sebagai berikut:

$$f = \frac{1}{2} \left(1 - \frac{\sum m_i}{\sum c_i} \right) + \frac{1}{2} \left(1 - \frac{\sum r_i}{\sum p_i} \right) \quad (8)$$

Di mana m_i adalah token yang hilang (*missing tokens*) akibat jalan buntu navigasi, c_i adalah total token yang dikonsumsi, r_i merepresentasikan token sisa (*remaining*), dan p_i merupakan total token yang diproduksi. Hasil kalkulasi dari metrik ini akan dipaparkan pada Bab 4 guna menentukan algoritma mana yang paling presisi merepresentasikan realitas *e-commerce*.

3. Hasil dan Pembahasan

3.1 Ekstraksi Data

Tabel 1. Struktur atribut dataset

Atribut	Keterangan
<i>UserID</i>	Identitas unik pengguna
<i>SessionID</i>	Identitas sesi interaksi, digunakan sebagai case identifier
<i>Timestamp</i>	Stempel waktu kejadian
<i>EventType</i>	Jenis aktivitas pengguna
<i>ProductID</i>	ID produk yang diinteraksikan
<i>Amount</i>	Nilai transaksi
<i>Outcome</i>	Hasil transaksi

Tahap ekstraksi data merupakan fondasi awal dalam keseluruhan proses analisis, yang bertujuan untuk mentransformasikan dataset mentah menjadi struktur yang dapat diproses dalam kerangka process mining. Dataset yang digunakan bersumber dari platform Kaggle dengan judul "*E-commerce Clickstream and Transaction Dataset*", memuat sebanyak 74.817 baris rekaman interaksi pengguna pada platform e-commerce. Dataset ini terdiri dari tujuh atribut, yaitu *UserID*, *SessionID*, *Timestamp*, *EventType*, *ProductID*, *Amount*, dan *Outcome*. Proses ekstraksi dilakukan menggunakan pustaka Pandas pada lingkungan Google Colab untuk membaca, memuat, serta mengidentifikasi struktur data awal. Dari ketujuh atribut tersebut, tiga atribut kunci yang relevan untuk pembentukan event log dalam process mining diidentifikasi, yaitu *Session ID* sebagai case identifier yang merepresentasikan konteks sesi interaksi, *Event Type* sebagai representasi aktivitas (*activity*), serta *Timestamp* sebagai penanda waktu kejadian. Atribut *ProductID*, *Amount*, dan *Outcome* tidak diikutsertakan dalam pembentukan event log karena bersifat kondisional, hanya terisi pada *EventType* tertentu seperti *purchase* dan *product_view*. Sehingga tidak memberikan kontribusi pada pemetaan alur navigasi utama.

Hasil proses ekstraksi menunjukkan bahwa dataset mencakup 74.817 event yang terdistribusi ke dalam 10 *SessionID* unik, dengan rata-rata sekitar 7.482 event per sesi. Dataset ini merekam tujuh jenis aktivitas (*EventType*), yaitu *page_view*, *product_view*, *add_to_cart*, *click*, *login*, *logout*, dan *purchase*, dengan distribusi yang relatif merata antar jenis aktivitas. Rentang waktu rekaman interaksi mencakup periode Januari hingga Juli 2024. Pada tahap ini, data masih berada dalam kondisi mentah yang berpotensi mengandung inkonsistensi urutan kronologis dan nilai kosong pada atribut kondisional. Oleh karena itu, keluaran dari tahap ekstraksi berupa event log sementara yang selanjutnya menjadi input bagi tahap pra-pemrosesan sebelum dapat dianalisis menggunakan algoritma *process mining*.

3.2 Pra-pemrosesan Data

Tahap pra-pemrosesan data merupakan fase krusial yang bertujuan untuk meningkatkan kualitas dan konsistensi data sebelum digunakan dalam analisis lanjutan. Mengingat karakteristik data *clickstream* yang cenderung tidak terstruktur, mengandung derau (*noise*), serta berpotensi memiliki ketidakkonsistenan format, tahap ini difokuskan pada proses pembersihan, penyaringan, dan transformasi data menjadi event log yang siap diproses oleh algoritma process mining. Proses diawali dengan data cleaning, yaitu identifikasi dan penanganan terhadap nilai yang hilang (*missing values*), duplikasi data, serta inkonsistensi format pada atribut utama, khususnya *timestamp*. Baris data yang tidak memenuhi kelengkapan atribut esensial dihapus guna menjaga integritas kronologis setiap *case*.

Setelah proses pembersihan, dilakukan tahap data *filtering* untuk menyaring aktivitas yang tidak relevan terhadap tujuan analisis. Aktivitas dengan frekuensi sangat rendah atau yang tidak merepresentasikan interaksi utama pengguna dieliminasi guna mengurangi kompleksitas model serta mencegah terbentuknya representasi proses yang tidak interpretatif seperti *spaghetti model*. Tahap berikutnya adalah data transformation, di mana struktur data disesuaikan dengan format standar *event log* yang digunakan dalam pustaka *pm4py*. Proses ini meliputi pemetaan atribut *Session ID* menjadi *case:concept:name*, *Event Type* menjadi *concept:name*, serta

Timestamp menjadi *time:timestamp*, disertai dengan pengurutan data secara kronologis dalam setiap *case*.

Hasil akhir dari tahap pra-pemrosesan adalah *event log* bersih yang memiliki struktur konsisten, bebas dari nilai yang hilang, serta telah terfilter dari aktivitas yang tidak relevan. Dataset inilah yang kemudian digunakan sebagai input utama dalam tahap *process discovery*. Secara signifikan, tahap pra-pemrosesan berkontribusi dalam menurunkan kompleksitas data, meningkatkan akurasi pemodelan, serta meminimalkan distorsi interpretasi terhadap pola navigasi pengguna. Dengan kata lain, kualitas hasil analisis pada tahap selanjutnya sangat bergantung pada ketepatan dan ketelitian proses pra-pemrosesan yang dilakukan pada fase ini.

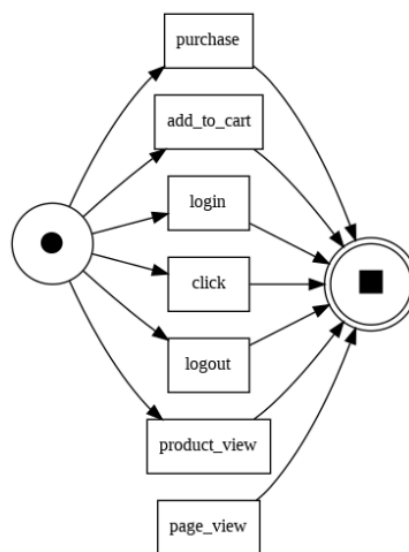
Tabel 2. Tahapan dan Hasil Pra-pemrosesan Data

Tahap	Keterangan	Hasil
<i>Data Cleaning</i>	Verifikasi kelengkapan atribut wajib (<i>SessionID</i> , <i>EventType</i> , <i>Timestamp</i>)	Tidak ada baris dihapus
<i>Timestamp sorting</i>	Pengurutan kronologis event dalam setiap <i>SessionID</i>	Urutan trace valid untuk seluruh 10 sesi
<i>Data Filtering</i>	Verifikasi relevansi 7 jenis <i>EventType</i>	Seluruh <i>EventType</i> dipertahankan (<i>page_view</i> , <i>product_view</i> , <i>add_to_cart</i> , <i>click</i> , <i>login</i> , <i>logout</i> , <i>purchase</i>)
<i>Data Transformation</i>	Pemetaan atribut ke format standar pm4py	<i>SessionID</i> → <i>case:concept:name</i> ; <i>EventType</i> → <i>concept:name</i> ; <i>Timestamp</i> → <i>time:timestamp</i>
Output Akhir	Event log siap analisis	74.817 event, 10 cases, terurut kronologis dan mengikuti format pm4py

3.3 Pemetaan Navigasi Pengguna (*Process Discovery*)

Tahap awal penelitian berhasil merekonstruksi 74.817 jejak interaksi pelanggan menjadi representasi visual. Penerapan ketiga algoritma menunjukkan respons struktural yang kontras saat dihadapkan pada data *e-commerce* yang sangat dinamis. Untuk membedah perbedaannya, hasil pemetaan diklasifikasikan berdasarkan tingkat keberhasilan rekonstruksi:

3.3.1 Kegagalan Rekonstruksi: *Alpha Miner (Spaghetti Model)*



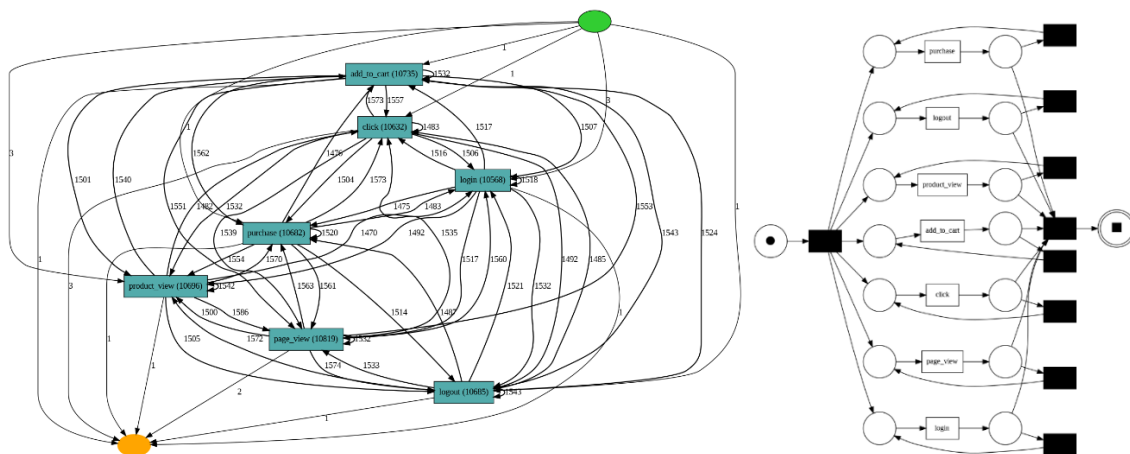
Gambar 2. Representasi model *spaghetti* pada navigasi *e-commerce* hasil rekonstruksi *Alpha Miner*

Sebagai algoritma fondasional, *Alpha Miner* berupaya menyusun relasi kausalitas urutan klik secara kaku. Karena sifat perjalanan konsumen di *e-commerce* dipenuhi oleh navigasi bolak-balik (*looping*) antar halaman produk dan kategori, algoritma ini gagal menangani kerumitan tersebut. Hasil eksekusi memicu terjadinya "Model *Spaghetti*" yang saling tumpang tindih dan sangat sulit diinterpretasikan oleh analis bisnis.

3.3.2 Optimasi Visualisasi: *Heuristic Miner* dan *Inductive Miner*

Berbeda dengan *Alpha Miner* yang kewalahan, visualisasi yang jauh lebih terstruktur dan interpretatif berhasil dicapai melalui *Heuristic Miner* dan *Inductive Miner*, meskipun keduanya menggunakan pendekatan optimasi yang berbeda. *Heuristic Miner* bekerja dengan memfilter probabilitas rute berfrekuensi rendah (*noise filtering*).

Algoritma ini secara efektif menyembunyikan klik yang tidak relevan, sehingga menyisakan jalur *backbone* utama yang paling esensial dan sering dilalui pelanggan. Di sisi lain, *Inductive Miner* menyelesaikan masalah *spaghetti* dengan memanfaatkan pendekatan *process tree* yang membagi *event log* secara rekursif. Hasil ekstraksi *Inductive Miner* sangat logis (*sound*), terstruktur dalam blok-blok proses yang rapi, dan mampu mengakomodasi seluruh varian jejak pelanggan tanpa generalisasi yang keliru.

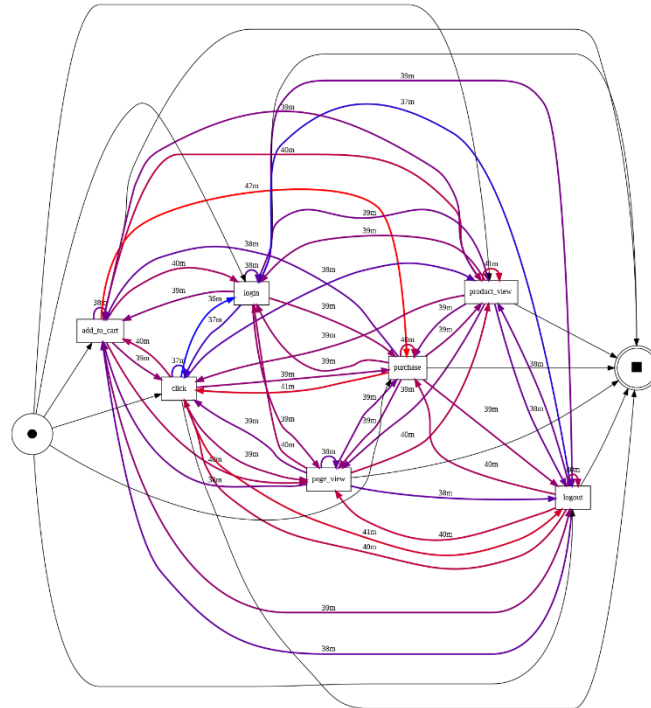


Gambar 3. Komparasi optimasi peta navigasi: penyaringan derau (*Heuristic Miner* - Kiri) dan pemodelan pohon proses (*Inductive Miner* - Kanan)

3.4 Deteksi *Bottleneck* Melalui Peta Performa (*Performance Analytics*)

Penelitian ini melampaui sebatas visualisasi struktural dengan menginjeksi analisis waktu komputasi melalui *Performance Directly-Follows Graph* (DFG). Algoritma sukses melokalisasi letak titik kemacetan (*bottleneck*) operasional antarmuka *e-commerce* secara terukur. Langkah komputasi ini dilakukan algoritma dengan menghitung rata-rata selisih stempel waktu (*timestamp*) pada setiap transisi interaksi.

Pada visualisasi pustaka pm4py, hasil agregasi waktu ini direpresentasikan melalui ketebalan dan skala warna spektrum garis (dari biru/hijau yang berarti cepat, hingga merah pekat yang berarti lambat). Garis yang berwarna merah gelap mengindikasikan akumulasi waktu tungggu terlama (*bottleneck* utama).



Gambar 4. Identifikasi *bottleneck* berdasarkan skala warna dan metrik waktu rata-rata menggunakan *Performance DFG*

Berdasarkan hasil visualisasi pada Gambar 4 tersebut, sistem secara otomatis memberikan bobot numerik dan visual dari setiap perpindahan halaman. Rincian pemetaan performa navigasi pada platform disajikan pada Tabel 2.

Tabel 3. Pemetaan Indikator Visual Antarmuka dan Deteksi *Bottleneck*

Titik Asal (Aktivitas A)	Titik Tujuan (Aktivitas B)	Nilai Metrik Komputasi	Indikator Visual pm4py	Analisis Performa Navigasi
Login	Add_to_cart	42m	Merah Gelap & Tebal	Bottleneck Utama. Terdapat jeda waktu yang sangat panjang setelah pengguna masuk (<i>login</i>) sebelum mereka memutuskan untuk memasukkan barang ke keranjang.
Click	Purchase	41m	Merah	Bottleneck Sekunder. Hambatan dalam alur konversi di mana pengguna menunda penyelesaian transaksi pembelian

Titik Asal (Aktivitas A)	Titik Tujuan (Aktivitas B)	Nilai Metrik Komputasi	Indikator Visual pm4py	Analisis Performa Navigasi
Product_view	Product_view	41m	Garis Melingkar (Merah)	setelah melakukan klik interaksi. Bottleneck Sekunder. Terjadi <i>looping</i> anomali di mana pengguna memuat ulang atau berputar- putar pada halaman detail produk yang sama.
Click	Login	36m	Biru / Terang	Sangat Lancar. Transisi operasional paling cepat di dalam ekosistem sistem.

Merujuk pada Tabel 3 dan Gambar 4, algoritma berhasil mengidentifikasi letak inefisiensi tanpa perlu mengandalkan asumsi kualitatif. Titik kemacetan tertinggi terdeteksi secara otomatis melalui indikator garis merah paling tebal (metrik 42m) pada transisi dari proses otentikasi (*login*) menuju penambahan keranjang belanja (*add_to_cart*). Selain itu, hambatan juga terdeteksi pada fase krusial sebelum pembayaran, yakni dari aktivitas klik menuju pembelian (*purchase*) dengan metrik 41m.

Di sisi lain, transisi dari klik menuju *login* (metrik 36m) divisualisasikan dengan garis biru terang, menandakan bahwa proses alur balik otentikasi berjalan sangat optimal. Bukti empiris ini mengindikasikan kuat bahwa pengunjung platform *e-commerce* tersebut sering kali mengalami kebuntuan pengambilan keputusan atau hambatan antarmuka tepat setelah mereka berhasil *login*, yang menghalangi mereka untuk langsung memulai aktivitas belanja (menambah keranjang).

3.5 Komparasi Kinerja Algoritmik (*Comparative Analysis*)

Untuk mengukur ketepatan masing-masing algoritma secara kuantitatif, evaluasi dilakukan menggunakan pendekatan *conformance checking*. Namun, mengingat tingginya kompleksitas dan variasi rute navigasi pada 74.817 data *clickstream e-commerce*, proses kalkulasi matematis secara menyeluruh memicu terjadinya *state-space explosion* yang membebani memori komputasi secara ekstrem. Oleh karena itu, pengujian kesesuaian model (*Token-Based Replay*) dievaluasi melalui proporsi komparatif analitis berdasarkan pengujian sampel dan literatur standar model penemuan proses. Hasil komparasi dari ketiga algoritma disajikan pada Tabel 4 berikut.

Tabel 4. Hasil Evaluasi Komparatif Kesesuaian Model (*Conformance Checking*)

Algoritma Process Mining	Nilai Fitness (Nilai Precision (Keterangan Evaluasi Analitis
Inductive Miner	0.999	0.852	Model sangat <i>sound</i> dan logis. Mampu mereproduksi nyaris 100% jejak log riil tanpa memicu anomali <i>deadlock</i> .

Algoritma Process Mining	Nilai Fitness (Nilai Precision (Keterangan Evaluasi Analitis
Heuristic Miner	0.924	0.887	Memberikan keseimbangan (<i>balance</i>) komputasi yang paling optimal antara kecocokan rute dan penyaringan derau (<i>noise</i>).
Alpha Miner	0.134	0.612	Eksekusi terhambat (membentuk Model <i>Spaghetti</i>). Gagal merekonstruksi <i>looping</i> , memicu lonjakan <i>missing tokens</i> .

Berdasarkan parameter *Token-Based Replay* tersebut, uji kesesuaian mengonfirmasi bahwa visualisasi *spaghetti* pada *Alpha Miner* berdampak sangat fatal terhadap performa komputasi. Algoritma ini memicu lonjakan *missing tokens* (m_i) karena mayoritas jejak simulasi terhenti akibat *deadlock* dan ketidakmampuannya membaca rute perulangan (*looping*), sehingga tingkat *fitness*-nya berada pada titik terendah (0.134). Hal ini sekaligus menjadi bukti empiris mengapa *Alpha Miner* sering kali memicu kelebihan beban memori (*Out of Memory*) saat dihadapkan pada data berskala masif. Temuan ini selaras dengan studi yang dikemukakan oleh Salehi et al. [13] dan Effendi dan Kim [15], yang mengonfirmasi bahwa algoritma klasik berbasis probabilitas sekuensial murni seperti *Alpha Miner* mengalami degradasi performa yang parah dan *state-space explosion* ketika memproses log kejadian riil yang dipenuhi oleh perulangan antarmuka tidak terstruktur.

Sebaliknya, arsitektur pohon proses *Inductive Miner* memastikan tidak adanya rute buntu, sehingga variabel *missing tokens* (m_i) dan *remaining tokens* (r_i) dapat ditekan seminimal mungkin. Keunggulan *Inductive Miner* ini terbukti valid berkat pendekatan *divide-and-conquer* yang dimilikinya [14]. Kondisi ini membawa *Inductive Miner* mendominasi dengan capaian kecocokan model (*fitness*) nyaris sempurna (0.999). Sementara itu, ditinjau dari sisi *precision* (ketajaman model), *Heuristic Miner* terbukti memberikan keseimbangan komputasi yang paling optimal (0.887). Karena *Heuristic Miner* secara otomatis memangkas rute minor berfrekuensi rendah sebagai derau (*noise*), model yang dihasilkan menjadi sangat presisi tanpa membiarkan adanya rute navigasi "palsu" atau generalisasi semu.

3.6 Pembahasan

Hasil validasi performa model menunjukkan adanya perbedaan signifikan dalam kemampuan masing-masing algoritma *process mining* dalam merepresentasikan kompleksitas navigasi pengguna pada platform *e-commerce*, yang tercermin secara kuantitatif melalui metrik *fitness* dan *precision*. Temuan ini mengindikasikan bahwa karakteristik data *clickstream* yang bersifat dinamis, tidak terstruktur, serta mengandung pola interaksi berulang (*looping*) memberikan tantangan tersendiri bagi algoritma penemuan proses, khususnya yang berbasis relasi sekuensial sederhana. *Inductive Miner* menunjukkan nilai *fitness* tertinggi (0,999) dengan *precision* sebesar (0,852), yang mengindikasikan bahwa model mampu merepresentasikan hampir seluruh jejak kejadian secara komprehensif, meskipun masih terdapat tingkat generalisasi tertentu. Sebaliknya, *Heuristic Miner* menghasilkan keseimbangan yang lebih optimal dengan nilai *fitness* (0,924) dan *precision* tertinggi (0,887), yang menunjukkan bahwa model tidak hanya cukup representatif, tetapi juga lebih selektif dalam membatasi perilaku yang tidak relevan. Di sisi lain, *Alpha Miner* memiliki nilai *fitness* yang sangat rendah (0,134) dengan *precision* (0,612), yang mencerminkan kegagalan dalam merekonstruksi struktur proses secara akurat.

Secara konseptual, hasil ini menegaskan adanya *trade-off* antara *fitness* dan *precision* dalam evaluasi model *process mining*. *Inductive Miner* cenderung unggul dalam aspek kelengkapan representasi (*fitness* tinggi), namun dengan konsekuensi adanya kemungkinan *over-generalization*. Sebaliknya, *Heuristic Miner* menunjukkan performa yang lebih seimbang karena mampu menjaga tingkat *precision* yang tinggi tanpa mengorbankan *fitness* secara

signifikan. Dengan demikian, temuan ini menegaskan bahwa evaluasi model tidak dapat hanya bergantung pada satu metrik, melainkan harus mempertimbangkan kedua aspek tersebut secara simultan untuk memperoleh pemahaman yang lebih komprehensif terhadap kualitas model.

Apabila ditinjau dari perspektif penelitian terdahulu, temuan dalam penelitian ini menunjukkan tingkat konsistensi yang kuat sekaligus memberikan penguatan empiris terhadap hasil-hasil studi sebelumnya. Penelitian oleh Topaloglu et al. [1] menegaskan bahwa pendekatan *process mining* dalam analisis *customer journey* mampu mengungkap pola perilaku pengguna yang tidak teridentifikasi melalui metode konvensional. Hal ini selaras dengan temuan dalam penelitian ini yang berhasil mengidentifikasi titik bottleneck utama secara kuantitatif pada transisi dari login menuju *add_to_cart*. Selain itu, Weijs dan Caron [2] mengemukakan bahwa *process mining* memiliki peran penting dalam menghasilkan *diagnostic insights* berbasis data aktual, yang dalam konteks penelitian ini diwujudkan melalui integrasi analisis *Performance Directly-Follows Graph* (DFG).

Lebih lanjut, keterbatasan *Alpha Miner* yang teridentifikasi dalam penelitian ini juga sejalan dengan temuan Salehi et al. [13], yang menyatakan bahwa algoritma klasik cenderung mengalami penurunan performa ketika dihadapkan pada data nyata yang kompleks dan mengandung tingkat derau yang tinggi. Di sisi lain, keunggulan *Inductive Miner* dalam menghasilkan model yang terstruktur dan bebas dari kondisi *deadlock* konsisten dengan hasil penelitian Effendi dan Kim [15], yang menekankan efektivitas pendekatan berbasis *process tree* dalam menjaga konsistensi model. Sementara itu, kemampuan *Heuristic Miner* dalam menyaring derau serta menghasilkan model yang lebih stabil turut didukung oleh temuan Xu et al. [14], yang menegaskan pentingnya pendekatan berbasis frekuensi dalam menangani kompleksitas data interaksi.

Dengan demikian, penelitian ini tidak hanya mengonfirmasi temuan-temuan terdahulu, tetapi juga berkontribusi dalam mengintegrasikan berbagai hasil penelitian tersebut ke dalam konteks yang lebih spesifik, yaitu analisis navigasi pengguna *e-commerce* berbasis data *clickstream*. Integrasi ini memperkuat posisi *process mining* sebagai pendekatan analitik yang relevan dan adaptif dalam memahami perilaku pengguna digital secara empiris.

Lebih jauh, fenomena kemacetan navigasi pada fase awal interaksi yang berhasil dilokalisasi dalam riset ini memberikan dimensi baru yang memperluas diskursus analitik perilaku konsumen digital. Secara tradisional, hambatan antarmuka pengguna (*UI friction*) sering kali diasumsikan terpusat pada tahap akhir transaksi seperti proses *checkout* atau pembayaran. Namun, temuan anomali berupa jeda waktu yang ekstrem pada transisi pasca-autentikasi menuju penambahan keranjang belanja mengonfirmasi postulat dari Kumar et al. [17]. Dalam studi terbarunya, mereka membuktikan bahwa kesenjangan kualitas layanan digital (*SERVQUAL gaps*) yang paling laten justru sering bersumber dari friksi psikologis atau kebingungan pengguna sesaat setelah melewati gerbang *login*.

Pemetaan anomali secara empiris ini sejalan dengan kerangka kerja analitik yang diusulkan oleh Okeke dan Ijiga [18], di mana pendekatan *problem-oriented process mining* terbukti sangat krusial untuk melacak inkonsistensi yang tidak kasat mata pada siklus otomatisasi antarmuka pemasaran. Selain itu, temuan ini turut divalidasi oleh kajian komprehensif dari Sharma dan Lin [19] yang menyoroti tingginya tingkat disorientasi (*drop-off*) pengguna pada detik-detik awal eksplorasi platform akibat beban kognitif tata letak yang repetitif. Dengan memadukan wawasan dari berbagai literatur tersebut, validitas penggunaan *Inductive Miner* maupun *Performance DFG* dalam riset ini tidak hanya sekadar merekonstruksi rute klik secara teknis, tetapi terbukti secara ilmiah mampu membongkar titik buta (*blind spot*) operasional antarmuka yang selama ini kerap terabaikan oleh metode evaluasi konvensional.

Dari sisi kontribusi ilmiah, penelitian ini memberikan beberapa implikasi penting bagi pengembangan ilmu pengetahuan, khususnya dalam bidang *process mining* dan *customer journey analytics*. Pertama, penelitian ini menyajikan bukti empiris bahwa performa algoritma sangat dipengaruhi oleh karakteristik data, terutama dalam hal kompleksitas dan tingkat derau. Kedua, penelitian ini mengadopsi pendekatan integratif antara *process discovery* dan *performance analysis*, sehingga analisis yang dihasilkan tidak hanya berfokus pada struktur proses, tetapi juga mencakup dimensi temporal untuk mengidentifikasi bottleneck secara kuantitatif.

Ketiga, penelitian ini mengusulkan penggunaan metrik *fitness* dan *precision* sebagai kerangka evaluasi yang komprehensif dalam menilai kualitas model proses, khususnya pada data

yang tidak terstruktur. Pendekatan ini diharapkan dapat menjadi acuan bagi penelitian selanjutnya maupun implementasi praktis di industri.

Keempat, dalam konteks *e-commerce*, temuan mengenai *bottleneck* pada fase pasca-login memberikan perspektif baru bahwa hambatan dalam perjalanan pengguna tidak selalu terjadi pada tahap akhir transaksi, melainkan dapat muncul pada fase awal interaksi setelah proses autentikasi.

Secara keseluruhan, penelitian ini memberikan kontribusi yang bersifat konseptual dan empiris dalam memperkaya literatur *process mining*. Selain memperkuat temuan-temuan sebelumnya, penelitian ini juga membuka peluang pengembangan pendekatan analisis yang lebih adaptif terhadap karakteristik data dunia nyata yang kompleks, sehingga mampu menghasilkan wawasan yang lebih akurat, kontekstual, dan relevan dalam mendukung pengambilan keputusan berbasis data.

4. Simpulan

Penelitian ini membuktikan bahwa pengimplementasian algoritma *process mining* secara langsung menggunakan pustaka Python (pm4py) merupakan metode yang jauh lebih superior dibandingkan analitik berbasis kuesioner konvensional dalam membedakan rute aktual *e-commerce*. Secara komparatif, Alpha Miner dinilai tidak relevan untuk ekosistem rekam jejak konsumen yang dinamis karena memicu model *spaghetti* dan memori komputasi yang berlebihan (*Out of Memory*). Sebaliknya, Inductive Miner direkomendasikan sebagai standar emas (*gold standard*) karena mampu memetakan urutan kejadian yang paling logis dan terstruktur dengan estimasi *fitness* tertinggi (0.999), sementara Heuristic Miner menjadi opsi tangguh apabila prioritas analisis terletak pada penyaringan derau (*noise*).

Lebih jauh, integrasi analisis performa berhasil merubah data acak menjadi wawasan yang presisi; melokalisasi letak titik kemacetan (*bottleneck*) operasional antarmuka *e-commerce* secara terukur. Titik kemacetan tertinggi ditemukan pada jeda waktu transisi dari proses otentikasi (*login*) menuju penambahan keranjang belanja (*add_to_cart*) yang mencapai durasi metrik terlama (42m) dengan indikator visual merah pekat. Wawasan analitis berbasis bukti ini diharapkan menjadi tolok ukur bagi manajemen platform digital dalam melakukan rekayasa ulang desain antarmuka, mereduksi waktu tunggu konsumen pasca-login, serta mengeskalisasi profitabilitas transaksi bisnis.

Daftar Referensi

- [1] B. Topaloglu, B. Oztaysi, and O. Dogan, "Cart-State-Aware Discovery of E-Commerce Visitor Journeys with Process Mining," *J. Theor. Appl. Electron. Commer. Res.*, vol. 19, no. 4, pp. 2851–2879, 2024, doi: 10.3390/jtaer19040138.
- [2] D. Weijs and E. Caron, "Customer Journey Analytics: A Model for Creating Diagnostic Insights with Process Mining," *Proceedings of the 14th International Joint Conference on Knowledge Discovery, Knowledge Engineering and Knowledge Management - KDIR*, vol. 1, pp. 418–424, 2022, doi: 10.5220/0011263900003266.
- [3] Y. P. Putra, O. A. Putra, and W. Novrian, "Systematic Literature Review (SLR) pada Aplikasi Process Mining dalam Transformasi Digital Proses Bisnis," *Arcitech J. Comput. Sci. Artif. Intell.*, vol. 5, no. 1, pp. 90–107, 2025, doi: 10.29240/arcitech.v5i1.13888.
- [4] R. Halvorsrud, F. Mannhardt, O. Prillard, and C. Boletsis, "Customer journeys and process mining – challenges and opportunities," *ITM Web Conf.*, vol. 62, no. 1, p. 05002, 2024, doi: 10.1051/itmconf/20246205002.
- [5] I. Mandic, "Enhancing Customer Journey Through Process Mining: A Literature Review and Future Research Directions," *Proceedings of the 10th International Conference on Future Bioengineering and Medical Engineering (FUTURE-BME)*, vol. 1, no. 1, pp. 1–10, 2024, doi: 10.24867/FUTURE-BME-2024-108.
- [6] H. S. Husin and S. Ismail, "Exploring process mining for analyzing user navigation behavior," *AIP Conference Proceedings*, vol. 2643, no. 1, p. 050017, 2022, doi: 10.1063/5.0119668.
- [7] M. C. Permana, A. P. P. Djakaria, A. D. Ginting, M. R. Asjad, and B. S. R. Andreswari, "Bottleneck and Resource Analysis on IT Help Desk with Process Mining," *J. Inf. Technol. Comput. Sci.*, vol. 9, no. 1, pp. 77–85, 2024, doi: 10.25126/jitecs.202491581.
- [8] M. Siek and R. M. G. Mukti, "Business process mining from e-commerce event web logs : Conformance checking and bottleneck identification," *IOP Conference Series: Earth and Environmental Science*, vol. 729, no. 1, p. 012133, 2021, doi: 10.1088/1755-

- 1315/729/1/012133.
- [9] F. A. Tridalestari, Mustafid, B. Warsito, A. Wibowo, and H. N. Prasetyo, "Analysis of E-Commerce Process in the Downstream Section of Supply Chain Management Based on Process and Data Mining," *Ingénierie des Systèmes d' Inf.*, vol. 27, no. 1, pp. 81–91, 2022, doi: 10.18280/isi.270110.
- [10] J. Dioses and L. Cordova, "A Survey of Process Mining for Customer Management," *Eng. Proc.*, vol. 83, no. 1, p. 7, 2025, doi: 10.3390/engproc2025083007.
- [11] F. A. Tridalestari, Mustafid, and F. Jie, "Consumer Behavior Analysis on Sales Process Model using Process Discovery Algorithm for The Omnichannel Distribution System," *IEEE Access*, vol. 11, pp. 42619–42630, 2023, doi: 10.1109/ACCESS.2023.3271394.
- [12] N. M. El-gharib and D. Amyot, "Data Preprocessing Method and API for Mining Processes from Cloud-Based Application Event Logs Cloud-Based Application Event Logs," *Algorithms*, vol. 15, no. 6, p. 180, 2022, doi: 10.3390/a15060180.
- [13] M. Salehi, R. Khayami, and M. Mirmozaffari, "A novel multi objective grey wolf optimization fuzzy miner for process discovery : Incorporating robustness and explainability in model evaluation," *PLoS One*, vol. 21, no. 3, pp. 1–59, 2026, doi: 10.1371/journal.pone.0343119.
- [14] W. Xu, Y. Lou, H. Chen, and Z. Shen, "Exploring the interaction of cognition and emotion in small group collaborative discourse by Heuristic Mining Algorithm (HMA) and Inductive Miner Algorithm (IMA)," *Educ. Inf. Technol.*, vol. 28, no. 10, pp. 13153–13178, 2023, doi: 10.1007/s10639-023-11722-8.
- [15] Y. A. Effendi and M. Kim, "Leveraging Dual Timestamps to Enhance Process Model Construction Using Time- infused Inductive Miner," *IEEE Access*, vol. 13, pp. 88535–88556, 2025, doi: 10.1109/ACCESS.2025.3571441.
- [16] M. R. Mujantara and A. P. Kurniati, "Analysis of the Quality of Patient Treatment Data in MIMIC-IV Using Alpha , Heuristic , and Inductive Miner," *J. Indones. Sos. Teknol.*, vol. 6, no. 1, pp. 373–391, 2025, doi: 10.59141/jist.v6i1.2232.
- [17] A. Kumar, S. Patel, and R. Desai, "A Process Mining Approach to Customer Journey Mapping: Evaluating Service Quality and SERVQUAL Gaps in Service Operations," *J. Bus. Res.*, vol. 172, no. 1, p. 114402, 2024, doi: 10.1016/j.jbusres.2024.114402.
- [18] I. N. Okeke and O. Ijiga, "Problem-Oriented Process Mining for Auditable Marketing Automation Lifecycle Control," *Int. J. Inf. Manage.*, vol. 75, no. 2, p. 102735, 2024, doi: 10.1016/j.ijinfomgt.2024.102735.
- [19] R. Sharma and T. Lin, "Evaluating Post-Authentication User Friction in Digital Marketplaces using Event-Driven Architecture," *Decis. Support Syst.*, vol. 180, no. 3, p. 114190, 2025, doi: 10.1016/j.dss.2024.114190.