



Analisis Bibliometrik Tren Penelitian Deep Learning untuk Perilaku Konsumen

Muhammad Yahya Abdullahissalam ^{1*}

¹⁾ muhyahyaas@gmail.com

¹ Universitas Islam Madura, Jl. Pondok Peantren Miftahul Ulum Bettet, Pamekasan Madura, Gladak, Bettet, Kec. Pamekasan, Kabupaten Pamekasan, Jawa Timur 69317, Indonesia

Kata Kunci

Analisis Bibliometrik; Deep Learning; Perilaku Konsumen; Pembelian Impulsif; VosViewer

***) Author Korespondensi**

muhyahyaas@gmail.com

Abstrak

Perkembangan teknologi *deep learning* yang pesat telah mendorong transformasi besar dalam analisis perilaku konsumen, namun arah perkembangan literatur pada bidang ini belum terpetakan secara komprehensif. Penelitian ini bertujuan untuk menganalisis tren perkembangan riset terkait pemanfaatan *deep learning* dalam klasifikasi perilaku konsumen menggunakan pendekatan bibliometrik. Data diambil dari basis data OpenAlex hingga Juni 2026, menghasilkan 411 dokumen relevan yang kemudian dianalisis menggunakan perangkat lunak VOSviewer dengan teknik *co-occurrence*. Temuan penelitian menunjukkan adanya lonjakan publikasi yang signifikan sejak tahun 2020 hingga tahun berjalan 2026, dengan volume dokumen terindeks tertinggi berada pada tahun 2025 (data bersifat parsial dan masih dalam proses agregasi). Analisis kluster menunjukkan dominasi bidang *computer science* (326 kemunculan) dan *artificial intelligence* (238 kemunculan). Hasil pemetaan kata kunci mengidentifikasi keterkaitan kuat antara teknologi kecerdasan buatan dengan strategi bisnis modern, namun menunjukkan adanya kesenjangan pada kajian psikologis yang lebih spesifik seperti perilaku pembelian impulsif (*impulsive buying*). Secara praktis, penelitian ini memberikan landasan bagi pengembang strategi bisnis untuk mengintegrasikan model komputasi yang lebih akurat dengan teori perilaku nyata. Implikasi dari penelitian ini diharapkan dapat mendorong pengembangan riset interdisipliner yang lebih seimbang antara kekuatan teknis algoritma dan pemahaman psikologis konsumen di masa depan.

1. Pendahuluan

Eskalasi teknologi kecerdasan buatan dalam beberapa tahun terakhir telah memicu perubahan fundamental pada domain ilmu komputer dan pemasaran digital. Salah satu arsitektur yang mendominasi perkembangan ini adalah *deep learning*, sebuah model komputasi yang memiliki kapasitas superior dalam mengekstraksi fitur dari dataset yang masif dan kompleks guna menghasilkan prediksi analitik yang lebih akurat. Dalam konteks perilaku konsumen, teknologi ini memungkinkan analisis mendalam terhadap pola pembelian, preferensi, serta mekanika pengambilan keputusan secara lebih presisi. Seiring dengan masifnya ketergantungan masyarakat pada platform digital dan e-commerce, integrasi antara algoritma pembelajaran mendalam dan

kajian perilaku menjadi dasar penting dalam perumusan strategi bisnis berbasis data. Sejumlah literatur terdahulu telah mengeksplorasi utilitas machine learning dan deep learning untuk membedah dinamika konsumen melalui teknik analisis sentimen, segmentasi pelanggan, serta prediksi keputusan pembelian (Jain et al., 2021),(Koehn et al., 2020).Metode bibliometrik pun telah banyak diadopsi untuk memetakan klaster topik yang menghubungkan inovasi teknologi dengan sistem rekomendasi terpersonalisasi. Namun demikian, mayoritas studi saat ini masih terjebak pada dominasi pengembangan model dari perspektif teknis murni tanpa mengkaji secara mendalam aspek psikologis dalam perilaku konsumen. Secara spesifik, investigasi terhadap fenomena pembelian impulsif (impulsive buying) dalam kerangka deep learning masih sangat terbatas, padahal variabel psikologis ini merupakan faktor determinan dalam keputusan pembelian di lingkungan digital. Fragmentasi konseptual antara kemajuan teknis algoritma dan teori perilaku konsumen menciptakan celah riset yang signifikan, sebagaimana diidentifikasi dalam beberapa kajian terbaru (Tan et al., 2025).Berdasarkan problematika tersebut, penelitian ini bertujuan untuk menganalisis tren perkembangan riset pemanfaatan deep learning dalam klasifikasi perilaku konsumen menggunakan pendekatan bibliometrik. Pembatasan ruang lingkup publikasi pada kurun waktu 2020 hingga 2026 dipilih secara sengaja dengan pertimbangan strategis. Meskipun implementasi deep learning dalam riset konsumen telah dimulai sejak periode 2015–2018, fase tersebut didominasi oleh pengujian model teoritis dasar berskala kecil. Memasuki tahun 2020, terjadi transformasi masif yang dipicu oleh lonjakan aktivitas belanja digital global pasca-pandemi COVID-19, dikombinasikan dengan matangnya arsitektur mutakhir seperti Transformers dan Attention Mechanism. Oleh karena itu, periode 2020–2026 merepresentasikan era adopsi praktis berskala besar dan menjadi lini masa paling krusial untuk menangkap tren serta arah kebaruan riset komputasi konsumen yang aktual.Melalui analisis metadata dari database OpenAlex, penelitian ini berusaha mengidentifikasi topik-topik dominan sekaligus mengeksplorasi peluang riset pada dimensi psikologi pembelian yang masih terbuka. Secara akademik, studi ini berkontribusi pada penguatan kajian interdisipliner, sementara secara praktis, hasil yang diperoleh diharapkan dapat menjadi dasar dalam pengembangan model analisis perilaku konsumen yang lebih terintegrasi dan efektif.

2. Metode Penelitian

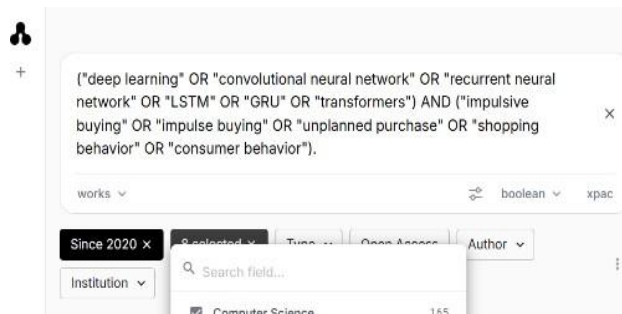
2.1 Sumber data

Dalam riset ini, kami menggunakan pendekatan bibliometrik untuk memetakan bagaimana riset *deep learning* berkembang di ranah perilaku konsumen. Kami memilih metode ini karena sangat efektif untuk menelaah literatur dalam jumlah besar secara objektif dan melihat gambaran besar dari sebuah bidang ilmu. Untuk data utama, kami mengambil metadata dari OpenAlex. Kami memilih OpenAlex karena sifatnya yang terbuka dan kemampuannya menjangkau jutaan karya ilmiah lintas disiplin, termasuk dari jurnal *open-access* atau repositori institusi yang kadang tidak tercatat di pangkalan data komersial seperti Scopus atau *Web of Science*.

Namun, kami juga sangat sadar bahwa karena OpenAlex mengumpulkan data dari berbagai sumber, tingkat konsistensi metadatanya tidak selalu seragam. Oleh karena itu, kami tidak langsung memakai data tersebut mentah-mentah. Kami melakukan proses bersih-bersih data secara teliti agar hasil analisis kami tetap bisa dipertanggungjawabkan. Proses ini kami mulai dengan menyaring 660 dokumen awal untuk memastikan subjeknya benar-benar sesuai dengan ranah *computer science*, *business*, dan *decision sciences*.

Selanjutnya, kami menggunakan automation tools untuk membuang 155 dokumen yang ganda atau jelas tidak lengkap metadatanya, lalu melakukan skrining manual terhadap judul dan abstrak untuk memastikan kesesuaian batas kronologis 2020-2026 dan subject area (Computer Science, Business, Decision Sciences), yang mengeksklusi 36 dokumen tambahan. Kami juga menerapkan standar yang ketat untuk hanya menyertakan artikel dari jurnal yang sudah melewati proses *peer-review*; pada tahap pencarian teks lengkap, 58 dokumen tidak berhasil diakses sehingga turut dieksklusi, sebagaimana dirinci pada diagram PRISMA (Bagian 2.2). Lewat prosedur yang panjang ini, kami akhirnya mengunci 411 dokumen final yang benar-benar siap untuk dianalisis lebih dalam. Dengan cara ini, kami berhasil menggabungkan keunggulan cakupan luas dari OpenAlex dengan standar kualitas data yang tetap terjaga baik. Prosedur pencarian dan seleksi dokumen dilakukan mengikuti pedoman sistematis guna memastikan bahwa pustaka referensi yang dibangun memiliki

relevansi tinggi dengan topik penelitian (Ellegaard & Wallin, 2015). Strategi pencarian disusun dengan mengombinasikan istilah teknis *deep learning* dan perilaku konsumen menggunakan operator Boolean (AND/OR). Adapun *query* pencarian yang digunakan adalah sebagai berikut:




Gambar 1. proses pengambilan data

Berdasarkan *query* tersebut, diperoleh dataset awal sebanyak 660 dokumen (Ellegaard & Wallin, 2015). Tahap berikutnya melibatkan pembersihan data menggunakan perangkat lunak Microsoft Excel untuk menghilangkan duplikasi dan memverifikasi kelengkapan sitasi (Small, 1973). Data yang telah tervalidasi kemudian diproses menggunakan perangkat lunak VOSviewer untuk melakukan analisis keterkaitan (*co-occurrence*) dan pemetaan visual (van Eck & Waltman, 2010). Langkah-langkah ini memastikan bahwa evolusi riset, kluster topik dominan, serta peluang kebaruan dalam domain *deep learning* dapat diidentifikasi secara empiris dan akurat.

2.2 Proses Pengumpulan dan Penyaringan Data

Data mentah yang diekstraksi pada tahapan awal tidak serta-merta langsung diolah secara mentah. Peneliti menerapkan prosedur filtrasi yang sistematis dan terukur guna memitigasi risiko *data noise*—kebisingan informasi yang kerap menjadi batu sandungan dalam kajian bibliometrik karena berpotensi membiaskan peta struktur intelektual yang hendak dibangun (Mongeon & Paul-Hus, 2016). Guna menjamin akuntabilitas dan keterbukaan dalam proses seleksi ini, penelitian ini mengadopsi kerangka diagram alir PRISMA 2020 (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) Seluruh rangkaian seleksi data tersebut dipetakan secara visual melalui diagram alir pada Gambar 2.



Gambar 2. Prisma ekstraksi data mentah

Pada gerbang awal, yakni fase Identifikasi (*Identification*), kueri pencarian yang dirumuskan secara spesifik pada basis data OpenAlex berhasil menjangkit 660 rekaman dokumen. Sebelum memasuki tahap skrining, peralatan otomasi (*automation tools*) digunakan untuk menandai dan menghapus rekaman yang jelas tidak memenuhi kriteria dasar—seperti entri duplikat maupun catatan yang kehilangan elemen metadata esensialnya (Aria & Cuccurullo, 2017). Langkah ini menghapus 155 dokumen sebelum skrining, menyisakan 505 dokumen untuk diproses lebih lanjut.

Memasuki fase Skrining (*Screening*), ke-505 dokumen yang lolos tahap sebelumnya diperiksa judul dan abstraknya untuk menilai kesesuaian batas kronologis (2020-2026) maupun keselarasan ranah keilmuan (*subject area: Computer Science, Business, dan Decision Sciences*). Dari pemeriksaan ini, sebanyak 36 dokumen dieksklusi karena tidak memenuhi salah satu kriteria tersebut, menyisakan 469 dokumen yang selanjutnya dicari versi teks lengkapnya (*reports sought for retrieval*).

Dari 469 dokumen tersebut, sebanyak 58 dokumen tidak berhasil diperoleh teks lengkapnya (*not retrieved*)—baik karena akses jurnal yang terbatas maupun tautan dokumen yang tidak lagi aktif—sehingga tersisa 411 dokumen yang berhasil diakses penuh. Seluruh 411 dokumen ini kemudian dinilai kelayakannya pada fase Kelayakan (*Eligibility*), khususnya terhadap kesesuaian jenis dokumen (hanya artikel jurnal *peer-reviewed* yang dipertimbangkan, dengan (Subramanyam, 1983) menjadi acuan standar kualitas pustaka bibliometrik). Seluruh 411 dokumen yang telah melalui tahap retrieval dinyatakan memenuhi kriteria kelayakan tanpa eksklusi tambahan pada tahap ini. Secara kumulatif, proses penyaringan tiga tahap ini (155 dihapus sebelum skrining, 36 dieksklusi saat skrining, dan 58 tidak berhasil diambil teks lengkapnya) mereduksi 660 dokumen awal menjadi 411 dokumen final (*Included*). Angka inilah yang kemudian dinyatakan memenuhi syarat kelayakan mutlak untuk dianalisis dan dipetakan lebih mendalam menggunakan perangkat lunak VOSviewer.

Sebagai catatan metodologis, adopsi kerangka kerja PRISMA 2020 dalam penelitian ini dilakukan secara khusus hanya untuk memandu transparansi dan akuntabilitas pada proses penyaringan dokumen, mulai dari pelacakan awal hingga diperoleh dataset final. Alur diagram ini kami gunakan murni sebagai instrumen audit untuk menunjukkan bagaimana data mentah disaring secara bertahap hingga menjadi 411 dokumen yang valid. Karena penelitian ini merupakan analisis bibliometrik murni yang berfokus pada pemetaan makro struktur intelektual, kami sengaja tidak mengadopsi tahapan PRISMA yang spesifik untuk tinjauan sistematis (*Systematic Literature Review*). Tahapan seperti penilaian risiko bias studi individual (*risk of bias assessment*) atau evaluasi kualitas metodologis naskah (*quality appraisal*) tidak dilakukan dalam studi ini, sebab analisis kualitas mikro semacam itu berada di luar batas operasional dan domain kajian bibliometrik

2.3 Alur Pelaksanaan Penelitian

Pelaksanaan penelitian ini mengikuti alur kerja standar dalam analisis sains yang mencakup desain pertanyaan riset, pengumpulan data, analisis, visualisasi, hingga tahap interpretasi (Cobos, 2011). Prosedur ini dirancang secara transparan dan kronologis guna mendukung prinsip replikasi metodologis oleh peneliti lain di masa mendatang (Moher et al., 2009). Secara operasional, setiap elemen metadata dari OpenAlex dikonversi ke dalam format yang kompatibel dengan perangkat lunak bibliometrik untuk meminimalkan risiko kehilangan informasi fungsional selama proses migrasi data berlangsung (Moral-Muñoz et al., 2020). Seluruh urutan kerja ini memberikan kerangka yang sistematis dalam membedah fenomena perilaku konsumen di lingkungan digital, yang secara visual dapat diamati pada Gambar 2 mengenai alur pengumpulan data.

2.4 Teknik Analisis dan Pemetaan Bibliometrik

Setelah data tervalidasi, kami mengolahnya menggunakan perangkat lunak VOSviewer untuk membuat visualisasi berbasis jarak yang bisa menunjukkan hubungan antar-topik secara objektif. Teknik utama yang kami gunakan adalah analisis *co-occurrence* atau ko-kejadian kata kunci. Untuk memastikan peta konseptual yang terbentuk benar-benar mencerminkan niat asli para peneliti, kami secara khusus menggunakan kata kunci penulis (*author keywords*), bukan kata kunci indeks yang dibuat otomatis oleh sistem. Kami merasa *author keywords* jauh lebih akurat dalam menggambarkan fokus keilmuan yang sebenarnya.

Dalam proses di VOSviewer, kami tidak memasukkan semua kata kunci mentah karena akan membuat peta visual menjadi terlalu ramai dan sulit dibaca. Oleh karena itu, kami menetapkan ambang batas minimum kemunculan (*minimum occurrence*) sebanyak 5 kali. Melalui batasan ini, dari total 1.423 kata kunci penulis yang berhasil kami ekstrak dari 411 dokumen, ada 84 kata kunci utama yang akhirnya lolos seleksi dan layak divisualisasikan. Untuk merapikan hubungan antarkata kunci tersebut, kami menggunakan metode *association strength* dan menerapkan algoritma *VOS clustering* agar topik-topik yang berdekatan bisa terkumpul dalam klaster yang lebih rapi.

3. Hasil dan Pembahasan

3.1 Analisis Tren Publikasi Tahunan



Gambar 3. Grafik perkembangan jumlah publikasi tahunan

Berdasarkan hasil penelusuran dokumen pada indeks OpenAlex yang dilakukan secara spesifik pada Juni 2026, dinamika riset mengenai pemanfaatan *deep learning* dalam membedah perilaku konsumen menunjukkan pergerakan yang sangat dinamis dan terus tumbuh positif. Jika melihat data riil dari total 411 dokumen yang berhasil dikumpulkan, terlihat jelas adanya peningkatan volume publikasi yang konsisten dari tahun ke tahun. Pada awal periode pemetaan tahun 2020, riset di bidang ini diawali dengan kontribusi minor sebesar 4% atau sebanyak 16 dokumen. Angka ini kemudian merangkak naik secara bertahap pada tahun 2021 dengan 6% (25 dokumen), tahun 2022 dengan 7% (29 dokumen), dan tahun 2023 dengan 9% (37 dokumen). Akselerasi yang cukup signifikan mulai terlihat pada tahun 2024, di mana volume publikasi melonjak hingga menyumbang 20% atau setara dengan 82 dokumen dari keseluruhan dataset.

Merujuk pada visualisasi data yang tertuang pada gambar diatas, akumulasi volume dokumen tertinggi yang berhasil terekam berada pada tahun 2025, yakni mencapai 43% atau sebanyak 177 dokumen. Namun, penting untuk ditegaskan di sini, guna memitigasi bias interpretasi terhadap data transisi, bahwa tingginya angka di tahun 2025 tersebut tidak serta-merta diklaim sebagai titik puncak absolut dari tren riset ini. Adanya penurunan angka kontribusi yang tampak pada tahun 2026, yaitu sebesar 11% atau sebanyak 45 dokumen, sama sekali bukan mengindikasikan bahwa minat akademisi dan industri terhadap topik ini sedang merosot.


Penurunan visual tersebut murni terjadi karena batasan waktu penarikan metadata yang dilakukan di tengah-tengah tahun berjalan 2026. Selain itu, terdapat faktor jeda waktu transisi (*indexing lag*) yang dibutuhkan oleh database OpenAlex untuk mengagregasi dan merekam secara komprehensif seluruh karya ilmiah yang baru saja diterbitkan di penghujung tahun 2025 serta awal tahun 2026. Dengan demikian, data pada rentang waktu akhir tersebut masih bersifat parsial dan akan terus berkembang.

Secara keseluruhan, arah pergerakan literatur dari tahun 2020 hingga akhir tahun penerbitan yang telah stabil menunjukkan akselerasi yang kuat. Lompatan kuantitas ini menjadi bukti nyata di lapangan bahwa integrasi antara kecerdasan buatan dan ruang lingkup perilaku manusia di pasar digital kini telah menjadi kebutuhan krusial. Masifnya aktivitas masyarakat di platform *e-commerce*, media sosial, dan ekosistem digital lainnya

telah memicu ledakan data konsumen dalam skala raksasa. Fenomena inilah yang menuntut para peneliti untuk bergeser dari metode statistik konvensional yang kaku menuju pemanfaatan algoritma *deep learning* yang jauh lebih peka, fleksibel, dan akurat dalam mengenali pola-pola tersembunyi dari keputusan pembelian konsumen di lingkungan digital.

(Balakrishnan et al., 2022) menjelaskan bahwa model berbasis CNN dan Bi-LSTM memiliki performa yang baik dalam menganalisis sentimen konsumen pada data digital berskala besar. Selain itu, perkembangan publikasi juga memperlihatkan adanya perubahan pendekatan penelitian. Kajian perilaku konsumen yang sebelumnya lebih banyak menggunakan metode statistik konvensional mulai berkembang menuju pendekatan berbasis *machine learning* dan *deep learning* yang lebih adaptif terhadap dinamika perilaku pengguna di lingkungan digital (Liu et al., 2020). Pergeseran tersebut menunjukkan bahwa teknologi komputasi kini tidak hanya digunakan untuk mengolah data, tetapi juga mulai dimanfaatkan untuk memahami pola interaksi dan keputusan pembelian konsumen secara lebih mendalam.

3.2 Tren Publikasi per Kategori



Gambar 4. Visualisasi kategori bidang penelitian.

Hasil klasifikasi bidang penelitian menunjukkan bahwa *computer science* menjadi kategori dengan jumlah publikasi tertinggi dibandingkan kategori lainnya. Dominasi bidang ini menunjukkan bahwa perkembangan penelitian masih banyak berfokus pada pengembangan model komputasi, algoritma kecerdasan buatan, dan teknik analisis data berbasis *deep learning*.

Selain *computer science*, kategori *business and management* juga memiliki kontribusi publikasi yang cukup besar. Temuan tersebut memperlihatkan bahwa teknologi *deep learning* mulai banyak diterapkan untuk mendukung strategi bisnis, khususnya dalam memahami preferensi pelanggan, analisis ulasan konsumen, dan pengembangan pemasaran berbasis data. Alzahrani et al. (2022) menjelaskan bahwa analisis sentimen berbasis *deep learning* mampu membantu perusahaan memahami tingkat kepuasan pelanggan melalui data ulasan digital secara lebih mendalam. Penelitian Jain et al. (2021) juga menunjukkan bahwa kombinasi CNN-LSTM dapat meningkatkan efektivitas klasifikasi opini konsumen pada platform digital.

Di sisi lain, kategori seperti *psychology* dan *behavioral science* masih memiliki jumlah publikasi yang relatif lebih sedikit. Kondisi ini memperlihatkan bahwa sebagian besar penelitian masih lebih menitikberatkan pada pengembangan teknologi dibandingkan pembahasan perilaku konsumen dari sisi psikologis. Padahal, aspek emosional dan faktor impulsif memiliki pengaruh yang cukup besar terhadap keputusan pembelian konsumen di lingkungan digital.

biochemical and molecular biology of VOCs in plants and animals

Hasil pemetaan *co-occurrence* menggunakan perangkat lunak VOSviewer bernilai membentuk sebuah jaringan kata kunci yang secara komprehensif memvisualisasikan konstelasi riset antara *deep learning* dan perilaku konsumen. Berdasarkan algoritma klasterisasi otomatis, terbentuk 6 klaster utama yang merepresentasikan kedekatan intelektual antar-topik. Jika ditelaah lebih dalam melalui visualisasi jarak dan ketebalan garis penghubungnya, terlihat jelas bahwa beberapa kata kunci mendominasi literatur dengan frekuensi kemunculan dan nilai *Total Link Strength* (TLS) yang sangat masif.

Berdasarkan peta jaringan yang terbentuk, fokus riset di lapangan sebenarnya didominasi oleh kata kunci teknis yang granular, seperti *machine learning* (kemunculan: 136; TLS: 518) dan *deep learning* (130; TLS: 485). Sebelumnya, pangkalan data memang mencatat angka frekuensi yang sangat tinggi pada istilah *computer science* (326) dan *artificial intelligence* (238). Namun, hasil penelusuran lebih lanjut menunjukkan bahwa kedua istilah makro tersebut merupakan label konsep (*concept tags*) yang tergenerasi otomatis oleh sistem indeks metadata OpenAlex, bukan kata kunci murni dari penulis naskah (*author keywords*). Oleh karena itu, agar tidak membiaskan peta struktur intelektual dan tren riset yang riil, kedua kata kunci makro tersebut sengaja dikeluarkan dari analisis substantif naskah ini. Meskipun demikian, tingginya frekuensi pada istilah komputasi granular lainnya tetap mengonfirmasi bahwa lanskap riset saat ini masih didominasi oleh pengujian kekuatan teknis algoritma dalam memproses data konsumen berskala besar

Menariknya, di luar dominasi teknis tersebut, jaringan visualisasi juga memperlihatkan pergerakan riset yang mulai merambah ranah terapan bisnis. Hal ini dibuktikan dengan kemunculan kata kunci *consumer behaviour* (80; TLS: 295), *marketing* (76; TLS: 270), dan *sentiment analysis* (45; TLS: 162). Integrasi kecerdasan buatan dalam pemasaran kini memang secara intensif difokuskan untuk membedah jejak digital konsumen, seperti ulasan produk dan interaksi di media sosial. Sejalan dengan hal tersebut, arsitektur komputasi tingkat lanjut seperti *deep learning* terbukti memiliki superioritas mutlak dalam mengklasifikasikan teks dan mengekstraksi sentimen yang tersembunyi di balik data konsumen yang tidak terstruktur.

Kendati teknologi ini terbukti ampuh secara analitik, visualisasi VOSviewer mengungkap sebuah celah riset (*research gap*) yang cukup ironis. Topik-topik krusial yang bersentuhan langsung dengan dimensi psikologis konsumen, seperti emosi dan *impulsive buying* (pembelian impulsif), justru berada di area periferal dengan

nilai keterhubungan (TLS) yang sangat rendah. Fenomena ini memperkuat pandangan bahwa inovasi kecerdasan buatan sering kali terlalu fokus pada metrik komputasi dan gagal menyentuh sisi pengalaman psikologis konsumen secara mendalam. Kondisi inilah yang menjadi bukti empiris bahwa kajian mengenai impulsivitas pembelian dalam kerangka model *deep learning* masih sangat marginal dan perlu segera dieksplorasi secara serius di masa depan.

3.4 Analisis Klaster Penelitian

Hasil visualisasi bibliometrik menggunakan VOSviewer menunjukkan bahwa penelitian mengenai *deep learning* dalam perilaku konsumen membentuk beberapa kelompok topik yang saling berkaitan. Setiap klaster menggambarkan fokus kajian yang berkembang dalam literatur, mulai dari penguatan teknologi komputasi, penerapan dalam strategi bisnis, pembahasan aspek psikologis konsumen, hingga pemanfaatan data digital dalam skala besar. Pembagian klaster ini memperlihatkan bahwa perkembangan riset pada bidang ini bersifat interdisipliner dan terus mengalami perluasan ruang lingkup penelitian.

3.4.1 Klaster Teknologi dan Sistem

Klaster pertama ini memetakan perkembangan aspek teknis dan arsitektur komputasi yang digunakan untuk membedah data perilaku konsumen. Setelah memisahkan kata kunci umum seperti *computer science* dan *artificial intelligence* yang muncul akibat otomatisasi metadata OpenAlex, fokus kajian pada klaster ini terlihat lebih jelas pada ranah yang spesifik. Tren riset sesungguhnya di lapangan didominasi oleh penggunaan *machine learning* (136 kemunculan) dan *deep learning* (130 kemunculan). Hal ini diperkuat dengan munculnya istilah arsitektur yang lebih granular seperti *artificial neural network* (91 kemunculan), *convolutional neural network* atau CNN (42 kemunculan), serta *neural networks* (38 kemunculan). Pola ini menegaskan bahwa fokus utama para peneliti adalah memanfaatkan keunggulan jaringan saraf tiruan untuk mengenali pola belanja digital, klasifikasi data, dan ekstraksi fitur perilaku konsumen secara otomatis.

Albawi menjelaskan bahwa CNN memiliki kemampuan yang baik dalam mengenali pola pada data kompleks melalui proses ekstraksi fitur secara otomatis (Albawi et al., 2017). Temuan tersebut menjadikan model *deep learning* banyak digunakan dalam pengolahan data konsumen yang bersifat dinamis dan tidak terstruktur. Sejalan dengan itu, (Kim, 2014) juga menunjukkan bahwa CNN mampu meningkatkan performa klasifikasi teks pada analisis sentimen konsumen dibandingkan metode tradisional. Dominasi penelitian pada klaster ini menunjukkan bahwa perkembangan riset masih sangat dipengaruhi oleh kebutuhan peningkatan performa model dan efisiensi sistem komputasi. Hal tersebut menyebabkan sebagian besar penelitian masih lebih menitikberatkan pada aspek teknis dibandingkan pemahaman perilaku konsumen secara mendalam.

3.4.2 Klaster Bisnis dan Analitik

Klaster kedua terdiri atas kata kunci seperti *business* (109), *marketing* (76), *decision making* (35), dan *consumer analytics* yang saling terhubung dalam jaringan visualisasi. Klaster ini menunjukkan bahwa teknologi *deep learning* mulai banyak dimanfaatkan untuk mendukung kebutuhan bisnis berbasis data, khususnya dalam memahami preferensi pelanggan dan pola keputusan pembelian. Perkembangan e-commerce dan platform digital mendorong perusahaan untuk memanfaatkan analisis data konsumen secara lebih intensif. Dalam konteks ini, teknologi *deep learning* digunakan untuk membantu perusahaan mengolah data pelanggan dalam jumlah besar agar strategi pemasaran dapat disusun secara lebih tepat sasaran. Koehn et al. (2020) menjelaskan bahwa penerapan *deep learning* dalam analisis perilaku pelanggan mampu membantu perusahaan memahami pola konsumsi secara lebih akurat melalui pemrosesan data digital.

Selain itu, (Alzahrani et al., 2022) menyebutkan bahwa analisis sentimen berbasis *deep learning* dapat membantu perusahaan mengevaluasi persepsi konsumen terhadap produk maupun layanan secara lebih efektif. Kemunculan kata kunci *decision making* pada klaster ini menunjukkan bahwa penelitian tidak lagi hanya berfokus pada identifikasi perilaku konsumen, tetapi juga mulai diarahkan pada pemanfaatan hasil analisis untuk mendukung pengambilan keputusan bisnis secara strategis. Hal tersebut memperlihatkan

bahwa perkembangan teknologi kecerdasan buatan mulai memiliki peran yang semakin penting dalam proses bisnis modern.

3.4.3 *Klaster Perilaku Konsumen dan Psikologi*

Klaster ketiga memperlihatkan keterkaitan antara teknologi *deep learning* dengan kajian perilaku konsumen dan aspek psikologis pengguna. Kata kunci seperti *consumer behaviour* (80), *human behavior*, *emotion*, dan *impulsive buying* mulai muncul dalam jaringan visualisasi meskipun frekuensinya masih lebih rendah dibandingkan klaster teknologi.

Kemunculan kata kunci tersebut menunjukkan bahwa penelitian mulai bergerak ke arah pemahaman perilaku konsumen secara lebih mendalam, tidak hanya berfokus pada pengolahan data dan performa algoritma. Dalam lingkungan digital, keputusan pembelian konsumen sering kali dipengaruhi oleh faktor emosional, dorongan impulsif, serta pengalaman pengguna saat berinteraksi dengan platform digital. Liu et al. (2020) menjelaskan bahwa penggunaan *deep learning* dalam analisis perilaku konsumen memiliki potensi besar untuk memahami pola keputusan pembelian secara lebih adaptif.

Namun demikian, sebagian besar penelitian masih berorientasi pada aspek teknis sehingga pembahasan mengenai faktor psikologis konsumen belum banyak dieksplorasi secara mendalam. Kondisi tersebut menunjukkan adanya celah penelitian yang cukup jelas antara perkembangan teknologi komputasi dan kajian psikologi konsumen. Padahal, integrasi kedua aspek tersebut dapat memberikan pemahaman yang lebih komprehensif mengenai perilaku pembelian di era digital.

3.4.4 *Klaster Data dan Analisis Digital*

Klaster keempat didominasi oleh kata kunci seperti *data science* (78), *data mining* (62), *big data* (46), *sentiment analysis* (45), dan *social media* (33). Klaster ini menunjukkan bahwa perkembangan penelitian perilaku konsumen semakin bergantung pada pemanfaatan data digital dalam jumlah besar. Media sosial, platform e-commerce, dan aplikasi digital menghasilkan data konsumen yang sangat kompleks dan terus berkembang secara real-time.

Kondisi tersebut membuat pendekatan *deep learning* menjadi relevan karena mampu mengolah data tidak terstruktur secara lebih efektif dibandingkan metode konvensional. Jain et al. (2021) menjelaskan bahwa kombinasi CNN-LSTM mampu meningkatkan akurasi klasifikasi opini konsumen pada data ulasan digital. Sementara itu, (Geethanjali & Valarmathi, 2024) menunjukkan bahwa model *hybrid deep learning* dapat membantu proses analisis emosi konsumen pada media sosial secara lebih adaptif terhadap data multibahasa dan tidak terstruktur. Meskipun perkembangan analisis data digital berlangsung sangat cepat, sebagian besar penelitian pada klaster ini masih berfokus pada peningkatan akurasi sistem dan pengolahan data. Pembahasan mengenai interpretasi perilaku konsumen secara kontekstual masih relatif terbatas, sehingga peluang pengembangan penelitian pada aspek tersebut masih terbuka cukup luas di masa mendatang.

3.5 **Pembahasan Tren Penelitian**

Secara umum, hasil analisis menunjukkan bahwa penelitian mengenai *deep learning* dalam perilaku konsumen mengalami perkembangan yang cukup pesat dalam beberapa tahun terakhir. Dominasi kata kunci seperti *machine learning*, *deep learning*, dan *artificial intelligence* menunjukkan bahwa sebagian besar penelitian masih berfokus pada pengembangan metode komputasi dan pengolahan data digital.

Di sisi lain, munculnya kata kunci seperti *consumer behaviour*, *marketing*, dan *sentiment analysis* memperlihatkan bahwa penelitian mulai bergerak ke arah pemahaman perilaku konsumen secara lebih aplikatif. Perkembangan tersebut menunjukkan bahwa teknologi tidak lagi hanya digunakan untuk meningkatkan performa sistem, tetapi juga mulai dimanfaatkan untuk memahami pola interaksi dan keputusan pembelian konsumen. (Bhuvaneshwari et al., 2022) menjelaskan bahwa penggunaan CNN dalam analisis ulasan produk e-commerce mampu membantu perusahaan memahami opini pelanggan secara lebih efektif. Temuan tersebut memperlihatkan bahwa perkembangan teknologi *deep learning* telah memberikan kontribusi

nyata terhadap pengembangan strategi bisnis berbasis data. Namun demikian, hasil pemetaan bibliometrik menunjukkan bahwa penelitian terkait perilaku impulsif dan aspek psikologis konsumen masih relatif terbatas dibandingkan penelitian berbasis teknis. Kondisi ini menunjukkan bahwa penelitian saat ini masih lebih banyak menitikberatkan pada peningkatan performa algoritma dibandingkan pemahaman perilaku konsumen secara mendalam.

Apabila ditelaah lebih lanjut, dominasi orientasi teknis dalam literatur saat ini juga memengaruhi karakteristik kanal publikasi dan kepengarangan di lapangan. Pola publikasi yang berkembang menunjukkan bahwa riset interdisipliner ini masih digerakkan oleh kelompok peneliti (*research group*) dari rumpun ilmu sains komputasi yang mencoba mengaplikasikan algoritma prediktif ke dalam studi ekosistem digital modern. Akibatnya, wadah diseminasi ilmiah yang mendominasi tren ini sebagian besar masih berupa jurnal-jurnal teknologi, kecerdasan buatan, dan sistem informasi, sementara porsi jurnal rumpun psikologi murni terpantau masih sangat marginal. Kondisi ini semakin mempertegas pentingnya pergeseran fokus riset masa depan agar tidak hanya bertumpu pada optimasi metrik akurasi model, melainkan juga harus membuka ruang kolaborasi yang lebih luas dengan pakar perilaku untuk memetakan aspek emosional konsumen di pasar digital.

3.6 Implikasi dan Celah Penelitian

Hasil penelitian ini menunjukkan bahwa integrasi antara *deep learning* dan perilaku konsumen memiliki potensi yang besar untuk terus dikembangkan, terutama dalam mendukung pengambilan keputusan bisnis berbasis data. Pemanfaatan teknologi kecerdasan buatan memungkinkan perusahaan memahami preferensi pelanggan secara lebih cepat, akurat, dan adaptif terhadap perubahan perilaku konsumen di lingkungan digital. Koehn et al. (2020) menjelaskan bahwa pendekatan *deep learning* mampu meningkatkan kemampuan analisis perilaku pelanggan melalui pemrosesan data dalam jumlah besar secara lebih efisien dibandingkan metode konvensional.

Di sisi lain, perkembangan penelitian saat ini masih didominasi oleh pendekatan teknis yang berorientasi pada peningkatan performa model dan akurasi sistem. Kondisi tersebut terlihat dari dominasi kata kunci seperti *machine learning*, *deep learning*, dan *artificial intelligence* pada hasil visualisasi bibliometrik. Sementara itu, pembahasan mengenai faktor psikologis konsumen seperti emosi, motivasi pembelian, dan *impulsive buying* masih relatif terbatas. Temuan ini sejalan dengan penelitian (Liu et al., 2020) yang menyebutkan bahwa sebagian besar penelitian perilaku konsumen berbasis kecerdasan buatan masih berfokus pada aspek komputasi dibandingkan eksplorasi perilaku manusia secara mendalam. Padahal, dalam konteks pemasaran digital, keputusan pembelian konsumen sering kali dipengaruhi oleh faktor emosional dan impulsif yang tidak selalu dapat dijelaskan hanya melalui pendekatan teknis.

Selain itu, wang dan rekan-rekannya menjelaskan bahwa analisis sentimen berbasis *deep learning* masih menghadapi tantangan dalam memahami konteks psikologis dan dinamika emosi konsumen secara lebih kompleks (Alzahrani et al., 2022). Oleh karena itu, penelitian selanjutnya perlu mengembangkan pendekatan yang lebih interdisipliner dengan menggabungkan teknologi *deep learning*, teori perilaku konsumen, dan pendekatan psikologi digital agar hasil analisis tidak hanya memiliki performa teknis yang tinggi, tetapi juga mampu memberikan interpretasi yang lebih realistis terhadap perilaku konsumen di lingkungan digital modern.

4. Kesimpulan

Meskipun memberikan pemetaan yang komprehensif, penelitian bibliometrik ini memiliki beberapa keterbatasan metodologis yang perlu dicatat. Pertama, ekstraksi metadata sepenuhnya bertumpu pada basis data tunggal (OpenAlex) sehingga dokumen yang mungkin eksklusif berada pada pangkalan data komersial lain berpotensi belum terekam. Kedua, penarikan data di tengah tahun berjalan menyebabkan tren periode akhir masih bersifat parsial akibat adanya jeda waktu indeksasi sistem (*indexing lag*). Terakhir, penelitian ini secara sadar membatasi ruang lingkup pengujian hanya pada analisis ko-kejadian kata kunci (*co-occurrence*) untuk membedah struktur konseptual topik. Ketiadaan pemetaan demografis sektoral—seperti analisis

penulis paling produktif, jurnal terkemuka, maupun analisis jaringan relasional seperti ko-sitasi (*co-citation*) dan ko-kepengarangan (*co-authorship*)—merupakan sebuah pilihan sadar metodologis (*conscious choice*) karena keterbatasan lini masa pengerjaan revisi naskah serta fokus utama studi ini yang memang dikunci pada penemuan celah riset (*research gap*) konseptual. Oleh karena itu, perluasan teknik analisis ke arah pemetaan kepengarangan struktural dan sitasi tersebut sangat disarankan untuk dijadikan agenda utama bagi penelitian lanjutan guna memperluas konstelasi intelektual bidang ini.

5. Referensi

- Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017). Understanding of a Convolutional Neural Network. *2017 International Conference on Engineering and Technology (ICET)*, 1–6. <https://doi.org/10.1109/ICEngTechnol.2017.8308186>
- Alzaharani, M. E., Aldhyani, T. H. H., Alsubari, S. N., Althobaiti, M. M., & Fahad, A. (2022). Developing an Intelligent System with Deep Learning Algorithms for Sentiment Analysis of E-Commerce Product Reviews. *Computational Intelligence and Neuroscience*, 2022, 3840071. <https://doi.org/10.1155/2022/3840071>
- Aria, M., & Cuccurullo, C. (2017). bibliometrix: An R-tool for Comprehensive Science Mapping Analysis. *Journal of Informetrics*, 11(4), 959–975. <https://doi.org/10.1016/j.joi.2017.08.007>
- Balakrishnan, V., Khan, S., & Arabnia, H. (2022). Deep Learning Approaches for Consumer Sentiment Analysis in Social Media. *Expert Systems with Applications*, 198, 116785. <https://doi.org/10.1016/j.eswa.2022.116785>
- Bhuvaneshwari, P., Rao, A. N., Robinson, Y. H., & Thippeswamy, M. N. (2022). Sentiment Analysis for User Reviews Using Bi-LSTM Self-Attention Based CNN Model. *Multimedia Tools and Applications*, 81, 12405–12419. <https://doi.org/10.1007/s11042-022-12410-4>
- Cobos, C. (2011). A Hybrid Software Tool for the Bibliometric Analysis of Scientific Domains. *4th International Conference on Soft Computing*, 345–352.
- Ellegaard, O., & Wallin, J. A. (2015). The Bibliometric Analysis of Scholarly Production: How to Build a Reference Library in a Specific Topic. *Scientometrics*, 105(3), 1809–1831. <https://doi.org/10.1007/s11192-015-1645-z>
- Geethanjali, N., & Valarmathi, M. (2024). Hybrid Deep Learning Model for Multilingual Social Media Sentiment Analysis. *Journal of Big Data*, 11(1), 55. <https://doi.org/10.1186/s40537-024-00812-5>
- Jain, P. K., Saravanan, V., & Pamula, R. (2021). A Hybrid CNN-LSTM: A Deep Learning Approach for Consumer Sentiment Analysis Using Qualitative User-Generated Contents. *ACM Transactions on Asian and Low-Resource Language Information Processing*, 20(5), 1–15. <https://doi.org/10.1145/3457206>
- Kim, Y. (2014). Convolutional Neural Networks for Sentence Classification. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 1746–1751. <https://doi.org/10.3115/v1/D14-1181>
- Koehn, D., Lessmann, S., & Schaal, M. (2020). Predicting Online Shopping Behaviour from Clickstream Data Using Deep Learning. *Expert Systems with Applications*, 150, 113342. <https://doi.org/10.1016/j.eswa.2020.113342>
- Liu, Y., Lu, J., Yang, J., & Mao, F. (2020). Sentiment Analysis for E-Commerce Product Reviews by Deep Learning Model of Bert-BiGRU-Softmax. *Mathematical Biosciences and Engineering*, 17(6), 7819–7837. <https://doi.org/10.3934/mbe.2020398>
- Moher, D., Liberati, A., Tetzlaff, J., & Altman, D. G. (2009). Preferred Reporting Items for Systematic Reviews and Meta-Analyses: The PRISMA Statement. *PLoS Medicine*, 6(7), e1000097. <https://doi.org/10.1371/journal.pmed.1000097>
- Mongeon, P., & Paul-Hus, A. (2016). The Journal Coverage of Web of Science and Scopus: A Comparative

- Analysis. *Scientometrics*, 106(1), 213–228. <https://doi.org/10.1007/s11192-015-1765-5>
- Moral-Muñoz, J. A., Herrera-Viedma, E., Santisteban-Espejo, A., & Cobo, M. J. (2020). Software Tools for Conducting Bibliometric Analysis in Science: An Up-to-Date Review. *El Profesional de La Información*, 29(1). <https://doi.org/10.3145/epi.2020.ene.03>
- Small, H. (1973). Co-citation in the Scientific Literature: A New Measure of the Relationship Between Two Documents. *Journal of the American Society for Information Science*, 24(4), 265–269. <https://doi.org/10.1002/asi.4630240406>
- Subramanyam, K. (1983). Bibliometric Studies of Scientific Literature. *Journal of Information Science*, 6(1), 33–37. <https://doi.org/10.1177/016555158300600105>
- Tan, Q. L., Hashim, S., & Abdullah, N. L. (2025). Mapping the Knowledge-Consumer Behavior Nexus: A Bibliometric Analysis and Systematic Review. *Humanities and Social Sciences Communications*, 12, 1243. <https://doi.org/10.1057/s41599-025-05613-1>
- van Eck, N. J., & Waltman, L. (2010). Software Survey: VOSviewer, a Computer Program for Bibliometric Mapping. *Scientometrics*, 84(2), 523–538. <https://doi.org/10.1007/s11192-009-0146-3>