

Model Machine Learning untuk Memprediksi Perilaku Konsumen sebagai Dasar Strategi Penargetan Ulang Iklan

Antoni¹, Mbera Mehuli², Tri Andre Anu³

¹ Informatics Engineering Study Program, Universitas Islam Sumatera Utara, Medan, Indonesia

²History education study program, Universitas Islam Sumatera Utara, Medan, Indonesia

³Information Technology Study Program, Universitas Muhammadiyah Sumatera Utara, Medan, Indonesia

E-mail: ¹antonigtg@ft.uisu.ac.id, ²mberehuli@kip.uisu.ac.id, ³triandre@umsu.ac.id

Korespondensi : antonigtg@ft.uisu.ac.id

Abstrak

Penelitian ini mengkaji bagaimana *machine learning* dapat digunakan untuk memprediksi perilaku konsumen dan menyediakan dasar berbasis data dalam penyusunan strategi *advertising retargeting*. Dalam lingkungan periklanan digital yang semakin kompetitif, praktik *retargeting* generik yang memperlakukan seluruh pengunjung sebagai satu kelompok audiens sering kali menyebabkan pemborosan anggaran, kelelahan iklan (*ad fatigue*), serta rendahnya relevansi pesan, karena niat konsumen bersifat dinamis dan bervariasi menurut waktu, perangkat, sumber trafik, dan tahapan *funnel*. Untuk mengatasi permasalahan tersebut, penelitian ini menerapkan desain pemodelan prediktif kuantitatif dengan memanfaatkan data *clickstream* pengguna dan data peristiwa (*event*) e-commerce pada tingkat individu. Fitur perilaku direkayasa untuk menangkap indikator seperti *recency*, *frequency*, intensitas eksplorasi, durasi sesi, serta sinyal *funnel* (misalnya *add-to-cart*), yang kemudian diikuti dengan proses pembersihan data, pengodean, penskalaan, pembagian data latih–uji berbasis waktu guna mengurangi kebocoran informasi, serta penanganan ketidakseimbangan kelas. Algoritma *Logistic Regression* digunakan sebagai model dasar yang dapat diinterpretasikan untuk mengestimasi probabilitas terjadinya keluaran target (misalnya konversi) dalam rentang waktu tertentu. Kinerja model dievaluasi menggunakan metrik yang sesuai untuk data tidak seimbang, termasuk ROC-AUC dan Precision–Recall (PR-AUC), serta nilai presisi, *recall*, dan *F1-score* pada ambang operasional. Hasil penelitian menunjukkan kemampuan diskriminatif yang sangat kuat (ROC-AUC = 0,961) dan efektivitas tinggi pada kelas positif (PR-AUC = 0,913), yang melampaui garis dasar prevalensi sebesar 0,235. Keluaran probabilitas dari model memungkinkan segmentasi audiens yang terukur ke dalam kelompok niat tinggi, sedang, dan rendah, sehingga mendukung penerapan intensitas *retargeting* dan strategi pesan yang berbeda. Secara keseluruhan, temuan ini menunjukkan bahwa penilaian probabilitas berbasis *machine learning* dapat meningkatkan presisi operasional *retargeting* dibandingkan pendekatan yang hanya berbasis intuisi; namun demikian, dampak bisnis terhadap CPA dan ROAS tetap perlu divalidasi melalui eksperimen lapangan seperti pengujian A/B.

Kata kunci: E-commerce; Regresi logistik; Kinerja; Penargetan ulang; Pembelajaran mesin

Abstract

This study examines how machine learning can be used to predict consumer behavior and provide a data-driven basis for advertising retargeting strategies. In increasingly competitive digital advertising environments, generic retargeting that treats all visitors as a single audience often leads to budget waste, ad fatigue, and low relevance because consumer intent is dynamic and varies across time, device, traffic source, and funnel stage. To address this problem, a quantitative predictive modeling design was applied using user-level clickstream and e-commerce event data. Behavioral features were engineered to capture indicators such as recency, frequency, exploration intensity, session duration, and funnel signals (e.g., add-to-cart), followed by data cleaning, encoding, scaling, time-based train–test splitting to reduce information leakage, and class-imbalance handling. Logistic Regression was employed as an interpretable baseline binary classifier to estimate the probability of a target outcome (e.g., conversion) within a defined time horizon. Model performance was evaluated using metrics appropriate for imbalanced data, including ROC-AUC and Precision–Recall (PR-AUC), as well as precision, recall, and F1-score at operational thresholds. The results indicate strong discriminative capability (ROC-AUC = 0.961) and high effectiveness on the positive class (PR-AUC = 0.913, exceeding the prevalence baseline of 0.235). The probability outputs enable measurable audience segmentation into high-, medium-, and low-intent groups, supporting

differentiated retargeting intensity and messaging strategies. Overall, the findings suggest that machine learning-based probability scoring can improve the operational precision of retargeting beyond intuition-driven approaches; however, business impact on CPA and ROAS should be validated through field experiments such as A/B testing

Keywords: Ecommerce; Logistic regression; Performance; Retargeting; Machine Learning

1. PENDAHULUAN

Perkembangan ekosistem digital telah membuat perilaku konsumen terekam dalam jejak data yang sangat kaya, mulai dari klik, durasi kunjungan, produk yang dilihat, hingga pola add-to-cart dan checkout. Di sisi lain, persaingan periklanan digital semakin ketat, biaya akuisisi cenderung meningkat, dan rentang perhatian pengguna semakin pendek [1][2]. Dalam kondisi tersebut, retargeting menjadi strategi yang penting karena menysasar audiens yang telah menunjukkan minat, sehingga peluang konversinya umumnya lebih tinggi dibandingkan dengan audiens baru [3][4]. Namun, dalam konteks retargeting yang efektif, tidak cukup hanya sekadar “mengejar” seluruh pengunjung; diperlukan presisi dalam menentukan siapa yang paling berpotensi membeli, kapan waktu terbaik untuk menampilkan iklan, dan pesan apa yang paling relevan [5][6]. Oleh karena itu, model machine learning menjadi krusial untuk mengolah data perilaku menjadi prediksi yang terukur, sehingga keputusan retargeting dapat bergeser dari pendekatan berbasis intuisi ke strategi berbasis data [7][8].

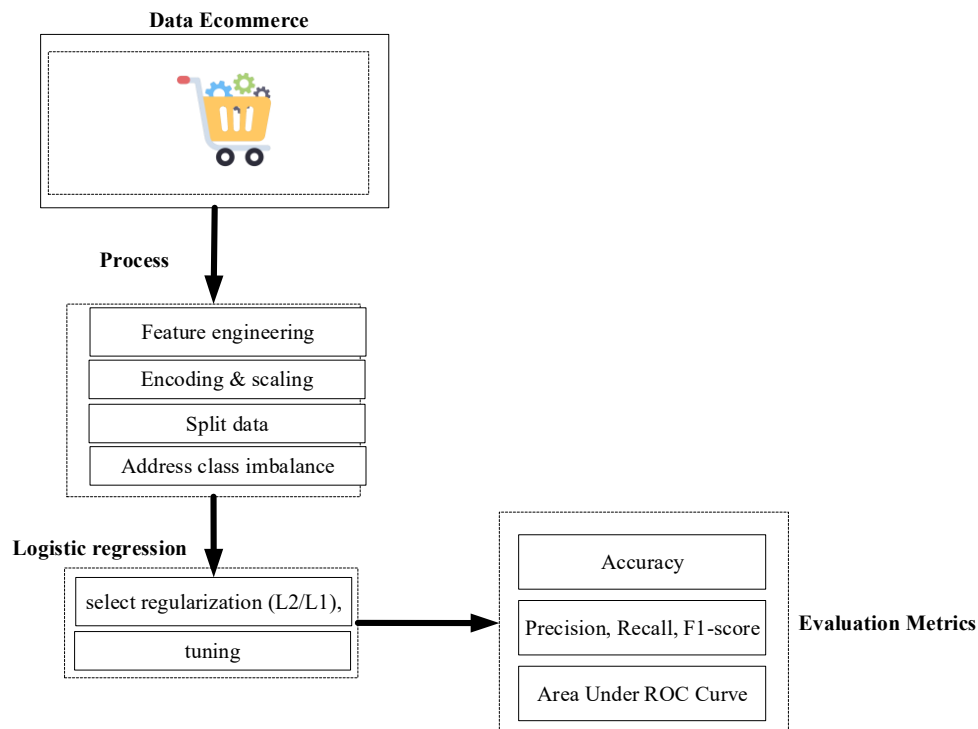
Permasalahan dalam penelitian ini adalah penerapan retargeting pada banyak bisnis masih bersifat generik: seluruh pengunjung atau semua pengguna yang pernah melihat suatu produk dikelompokkan ke dalam audiens yang sama, frekuensi penayangan iklan tidak dibedakan, dan pesan yang ditampilkan cenderung seragam [9][5]. Pendekatan ini menimbulkan berbagai konsekuensi, seperti pemborosan anggaran pada pengguna dengan probabilitas rendah, ad fatigue akibat penayangan iklan yang berulang, serta pengalaman pengguna yang terasa seperti “diikuti” tanpa relevansi [10][11][12][13]. Selain itu, perilaku konsumen bersifat dinamis: minat dapat berubah dengan cepat, keputusan pembelian dipengaruhi oleh waktu, perangkat, sumber trafik, serta tahapan funnel yang berbeda. Tanpa kemampuan memprediksi perilaku secara lebih presisi, strategi retargeting menjadi sulit dioptimalkan dan kinerja kampanye cenderung tidak stabil [14][15]. Solusi yang ditawarkan dalam penelitian ini adalah membangun model machine learning yang mentransformasikan jejak perilaku konsumen digital menjadi skor prediksi, seperti probabilitas klik, add-to-cart, atau pembelian dalam rentang waktu tertentu, sehingga retarget atau pembelian dalam rentang waktu tertentu, sehingga retargeting dapat dilakukan secara selektif dan terarah [16][17]. Model tersebut dapat dilatih menggunakan fitur perilaku seperti recency dan frequency kunjungan, jumlah halaman atau produk yang dilihat, durasi sesi, aktivitas add-to-cart, riwayat interaksi iklan, perangkat yang digunakan, waktu kunjungan, serta sumber trafik.

Untuk menangkap pola nonlinier yang umum ditemukan dalam data perilaku konsumen, algoritma yang relevan antara lain Logistic Regression sebagai model dasar yang mudah diinterpretasikan [18][19]. Keluaran model dalam bentuk skor memungkinkan pembentukan segmen retargeting berdasarkan prioritas (niat tinggi, sedang, dan rendah), penentuan frekuensi penayangan iklan yang lebih rasional, serta pemilihan pesan iklan yang lebih sesuai dengan tahapan funnel pengguna. Dengan pendekatan ini, strategi retargeting tidak lagi sekadar “menembak ulang” audiens yang sama, melainkan menjadi proses yang terukur: siapa yang ditargetkan, kapan, dan dengan intensitas seperti apa [20][21]. Dampak yang diharapkan tidak hanya berupa peningkatan metrik prediksi, tetapi juga perbaikan kinerja bisnis seperti conversion rate, cost per acquisition (CPA), dan return on ad spend (ROAS), sekaligus mengurangi pemborosan akibat ad fatigue. Pada akhirnya, penelitian ini menempatkan machine learning sebagai fondasi bagi pengambilan keputusan pemasaran digital yang lebih efisien, adaptif, dan relevan, sejalan dengan perilaku konsumen yang terus berubah.

2. METODE PENELITIAN

Penelitian ini menerapkan pendekatan kuantitatif dengan desain predictive modeling untuk membangun model machine learning yang memprediksi perilaku konsumen sebagai dasar perumusan strategi ad retargeting. Unit analisis ditetapkan pada tingkat pengguna (user level), dengan kerangka supervised learning untuk klasifikasi biner, di mana variabel dependen didefinisikan sebagai terjadinya perilaku target (seperti pembelian atau add-to-cart) dalam rentang waktu tertentu setelah interaksi terakhir (misalnya 7 hari). Data penelitian bersumber dari jejak perilaku digital yang terekam dalam sistem (clickstream dan peristiwa e-commerce), yang mencakup aktivitas kunjungan, interaksi produk, serta aksi dalam funnel (melihat produk, add-to-cart, checkout, dan pembelian). Setiap observasi dibangun sebagai representasi perilaku pengguna dalam jendela waktu yang konsisten, sehingga label dapat ditetapkan secara objektif berdasarkan ada atau tidaknya kejadian target dalam horizon waktu yang ditentukan.

Pada tahap prapemrosesan, dilakukan pembersihan data untuk menangani nilai hilang, duplikasi, dan outlier, serta transformasi variabel agar sesuai dengan kebutuhan model. Feature engineering dilakukan untuk mengekstraksi indikator perilaku yang relevan, seperti recency, frequency, intensitas eksplorasi produk, durasi sesi, serta konteks akses (misalnya perangkat atau waktu kunjungan) apabila tersedia. Variabel kategorikal dikonversi menggunakan teknik pengodean (misalnya one-hot encoding), sedangkan variabel numerik dinormalisasi atau distandarisasi untuk menjaga stabilitas estimasi parameter. Mengingat data konversi umumnya tidak seimbang, penelitian ini menerapkan penyesuaian bobot kelas dan/atau strategi sampling proporsional guna mencegah bias terhadap kelas mayoritas, sekaligus tetap menjaga interpretabilitas hasil. Pemodelan dilakukan menggunakan Logistic Regression sebagai model dasar yang robust dan mudah diinterpretasikan untuk klasifikasi biner, yang dapat diperluas dengan regularisasi (L1/L2) guna mengendalikan overfitting dan meningkatkan kemampuan generalisasi. Pembagian data dilakukan berbasis waktu (time-based split) untuk meminimalkan kebocoran informasi dan mensimulasikan kondisi operasional ketika model diterapkan pada periode berikutnya. Kinerja model dievaluasi menggunakan metrik yang relevan untuk data tidak seimbang, seperti ROC-AUC dan PR-AUC, serta nilai presisi, recall, dan F1-score pada ambang keputusan yang dipilih secara rasional. Keluaran model berupa probabilitas digunakan untuk membentuk segmentasi audiens retargeting (misalnya niat tinggi, sedang, dan rendah), sehingga strategi penayangan iklan dapat difokuskan pada pengguna dengan peluang konversi lebih tinggi, sekaligus meningkatkan efisiensi biaya iklan dan kualitas pengalaman pengguna. Tahapan penelitian tersebut ditunjukkan pada Gambar 1.



Gambar 1. Arsitektur sistem

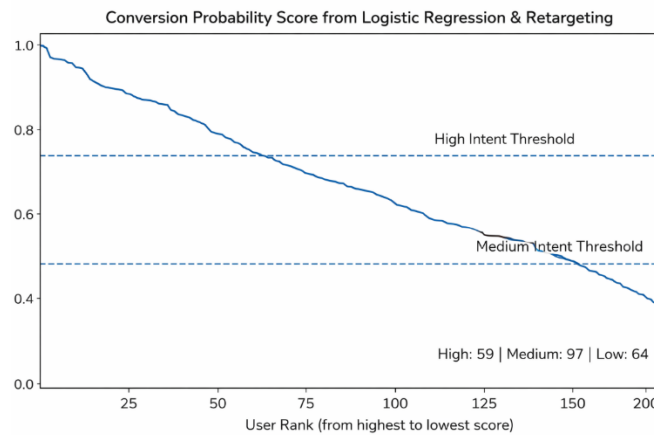
3. HASIL DAN PEMBAHASAN

Pada bagian hasil, model Regresi Logistik, yang dikembangkan melalui rekayasa fitur, pengkodean dan penskalaan, pemisahan data latih-uji, dan penanganan ketidakseimbangan kelas, menunjukkan kemampuan yang memadai dalam memprediksi perilaku konsumen untuk tujuan penargetan ulang. Kinerja model dinilai menggunakan metrik yang sesuai untuk data yang tidak seimbang, yaitu ROC-AUC dan presisi, recall, dan skor F1 pada ambang probabilitas yang dipilih. Pendekatan ini memastikan bahwa output probabilistik dapat digunakan secara praktis untuk membangun segmentasi audiens yang lebih terukur (niat tinggi/sedang/rendah). Pada bagian diskusi, temuan ini memperkuat bahwa Regresi Logistik dapat menangkap pola perilaku yang terkait dengan kemungkinan konversi ketika fitur perilaku ditentukan dengan baik (misalnya, kekinian, frekuensi, intensitas eksplorasi, dan sinyal saluran seperti peristiwa tambah ke keranjang). Pertukaran presisi-recall menjadi dasar untuk menetapkan ambang batas yang selaras dengan tujuan kampanye, baik tujuannya untuk memaksimalkan konversi atau untuk mengendalikan biaya, membuat model bermakna secara operasional daripada hanya mengandalkan akurasi saja. Interpretasi koefisien model juga membantu menjelaskan faktor mana yang paling berkontribusi terhadap niat pembelian, meskipun efektivitas bisnis idealnya harus divalidasi melalui eksperimen dunia nyata seperti pengujian A/B untuk mengkonfirmasi dampaknya pada ROAS dan CPA.

3.1. Regresi Logistik

Dalam studi ini, Regresi Logistik berfungsi sebagai model klasifikasi biner yang memprediksi perilaku konsumen menggunakan fitur perilaku e-commerce yang berasal dari pipeline pra-pemodelan. Output utama model ini bukan hanya label pasti, tetapi juga skor probabilitas (0–1) untuk setiap pengguna. Skor ini kemudian digunakan sebagai dasar untuk strategi penargetan ulang: pengguna dengan ppp tinggi diprioritaskan untuk penargetan ulang (niat tinggi), pengguna dengan ppp moderat disertakan dengan pengaturan frekuensi/anggaran yang lebih konservatif (niat menengah), dan pengguna dengan ppp rendah dibatasi untuk

menghindari pemborosan pengeluaran dan mengurangi risiko kelelahan iklan. Dari sudut pandang evaluasi, kinerja model harus dilaporkan menggunakan metrik yang sesuai untuk data yang tidak seimbang (presisi, recall, skor F1, dan ROC-AUC), dan ambang batas probabilitas harus dipilih agar sesuai dengan tujuan kampanye. Gambar 2 menyajikan keluaran Regresi Logistik dalam bentuk skor probabilitas dan contoh segmentasi audiens penargetan ulang berdasarkan skor tersebut.



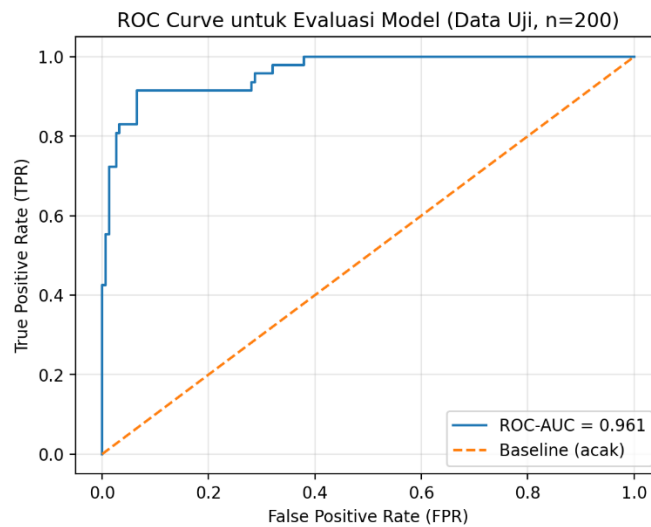
Gambar 2. Hasil Regresi Logistik

Grafik menunjukkan skor probabilitas konversi (sumbu Y, 0–1) yang dihasilkan oleh model regresi logistik untuk 200 pengguna yang diurutkan dari skor tertinggi hingga terendah (sumbu X: Peringkat Pengguna). Garis biru menurun hampir secara monoton, dimulai mendekati 1,0 untuk pengguna peringkat teratas dan turun hingga sekitar 0,38 untuk pengguna peringkat terendah, menunjukkan bahwa model menetapkan kemungkinan konversi yang lebih rendah seiring peringkat bergerak ke kanan. Dua garis horizontal putus-putus menandai ambang batas segmentasi: ambang batas Niat Tinggi yang lebih tinggi (sekitar 0,74) dan ambang batas Niat Sedang yang lebih rendah (sekitar 0,49). Teks ringkasan di kanan bawah melaporkan segmen yang dihasilkan: Tinggi = 59 pengguna, Sedang = 97 pengguna, dan Rendah = 64 pengguna. Pengguna di atas ambang batas Tinggi diperlakukan sebagai prioritas penargetan ulang teratas karena mereka memiliki kemungkinan konversi yang diprediksi paling tinggi; pengguna antara ambang batas Tinggi dan Sedang termasuk dalam kelompok niat menengah, biasanya cocok untuk penargetan ulang dengan pesan "pemanasan" atau penawaran moderat; dan pengguna di bawah ambang batas Sedang diklasifikasikan sebagai pengguna dengan niat rendah, sehingga penargetan ulang biasanya dibatasi atau dialihkan ke strategi berbiaya lebih rendah karena probabilitas konversi yang diprediksi relatif rendah.

3.2. Evaluasi

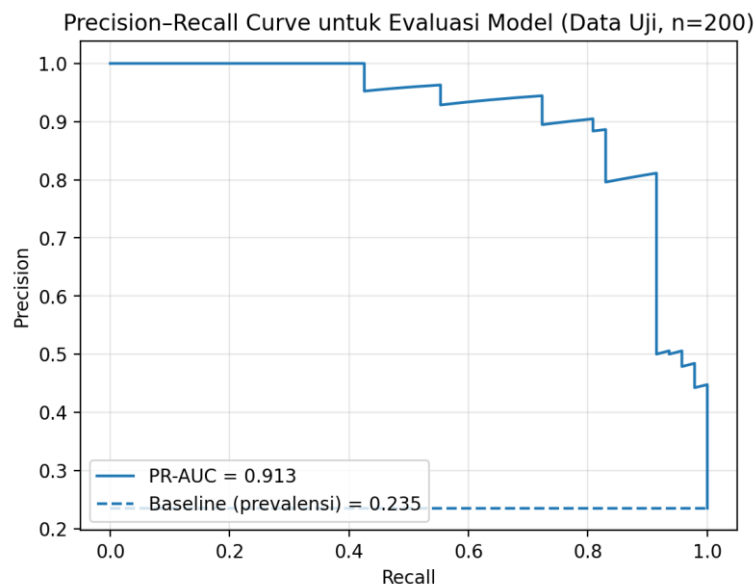
Evaluasi harus menekankan kemampuan model untuk menghasilkan skor probabilitas yang dapat digunakan untuk pemeringkatan dan segmentasi audiens penargetan ulang, daripada hanya mengandalkan keputusan kelas biner. Dalam konteks pemasaran digital, peristiwa konversi biasanya terjadi dengan tingkat rendah (kelas positif adalah minoritas), sehingga metrik yang terutama mencerminkan kinerja pada kelas mayoritas (misalnya, akurasi) dapat menyebabkan kesimpulan yang bias. Oleh karena itu, evaluasi yang lebih tepat mencakup Kurva ROC/ROC-AUC untuk mengukur kemampuan diskriminatif model dalam memisahkan calon konverter dari non-konverter di berbagai ambang batas keputusan, serta Kurva Presisi-Recall/PR-AUC untuk menilai kinerja pada kelas positif yang merupakan inti dari tujuan penargetan ulang. Pemilihan ambang batas bersifat operasional dan harus diturunkan dari trade-off presisi-recall berdasarkan tujuan kampanye, misalnya memprioritaskan presisi untuk meningkatkan efisiensi biaya (mengurangi pengeluaran yang terbuang) atau memprioritaskan recall untuk memperluas cakupan

calon konverter (mengurangi peluang yang terlewatkan). Hasil evaluasi menggunakan Kurva ROC dan Kurva Presisi-Recall disajikan pada Gambar 3 dan 4.



Gambar 3. ROC CURVE

Gambar 3 menunjukkan Kurva ROC yang digunakan untuk mengevaluasi kemampuan model dalam membedakan antara pengguna yang melakukan konversi dan yang tidak (set pengujian, $n=200$). Sumbu X mewakili Tingkat Positif Palsu (penargetan yang salah terhadap pengguna yang tidak melakukan konversi), sedangkan sumbu Y mewakili Tingkat Positif Sejati (proporsi pengguna yang melakukan konversi yang berhasil ditangkap). Garis putus-putus oranye adalah garis dasar acak; kurva biru terletak jauh di atasnya, menunjukkan bahwa model berkinerja jauh lebih baik daripada peluang acak. ROC-AUC sebesar 0,961 mencerminkan daya diskriminatif yang sangat kuat, sehingga model ini cocok untuk memberi peringkat pengguna dan membentuk segmen penargetan ulang berdasarkan prioritas. Kurva Presisi-Recall disajikan pada Gambar 4.



Gambar 4. Precision recall

Gambar 4 menyajikan Kurva Presisi-Recall (set pengujian, $n=200$), yang mengevaluasi kinerja model pada kelas positif (konversi), yang biasanya merupakan kelas minoritas. Sumbu X

mewakili recall (berapa banyak konversi aktual yang berhasil ditangkap), sedangkan sumbu Y mewakili presisi (di antara pengguna yang diprediksi akan melakukan konversi, berapa banyak yang benar-benar melakukan konversi). Garis putus-putus biru menunjukkan garis dasar prevalensi 0,235, yang berarti bahwa jika pengguna dipilih secara acak, presisi yang diharapkan akan sekitar 0,235. Kurva utama terletak jauh di atas garis dasar ini, dan PR-AUC adalah 0,913, menunjukkan kesesuaian yang kuat untuk penargetan ulang karena model mempertahankan presisi tinggi di berbagai tingkat recall. Tren menurun saat recall mendekati 1,0 adalah hal yang diharapkan: karena model menjadi lebih agresif dalam menangkap hampir semua konversi (recall yang lebih tinggi), presisi biasanya menurun karena peningkatan false positive. Pertukaran ini mendukung pemilihan ambang batas berdasarkan tujuan kampanye, baik untuk meningkatkan efisiensi biaya (memprioritaskan presisi) atau untuk menangkap lebih banyak konversi (memprioritaskan recall).

4. KESIMPULAN DAN SARAN

Studi ini menyimpulkan bahwa jejak perilaku konsumen dalam ekosistem digital dapat dimanfaatkan secara efektif untuk meningkatkan ketepatan strategi penargetan ulang melalui pendekatan pembelajaran mesin. Praktik penargetan ulang generik (menargetkan semua pengunjung dengan frekuensi dan pesan yang seragam) berisiko menyebabkan pemborosan anggaran, kelelahan iklan, dan pengalaman pengguna yang kurang relevan, terutama karena perilaku dan minat konsumen bersifat dinamis dan dipengaruhi oleh waktu, perangkat, sumber lalu lintas, dan tahapan saluran penjualan. Untuk mengatasi masalah ini, studi ini mengembangkan model prediktif menggunakan data perilaku e-commerce (misalnya, kekinian, frekuensi, intensitas eksplorasi, durasi sesi, dan sinyal saluran penjualan seperti peristiwa tambah ke keranjang), dengan Regresi Logistik sebagai dasar interpretasi. Hasilnya menunjukkan bahwa Regresi Logistik menghasilkan skor probabilitas yang memadai (ppp) untuk memprediksi kecenderungan konversi dan untuk membangun segmen audiens penargetan ulang yang terukur (niat tinggi/sedang/rendah). Hal ini memungkinkan keputusan penargetan untuk fokus pada pengguna dengan kemungkinan konversi yang lebih tinggi dan memungkinkan intensitas iklan disesuaikan secara lebih rasional. Evaluasi model menggunakan metrik yang sesuai untuk data yang tidak seimbang mengkonfirmasi kinerja diskriminatif yang kuat (ROC-AUC = 0,961) dan efektivitas yang solid pada kelas positif (PR-AUC = 0,913, jauh di atas garis dasar prevalensi 0,235). Secara operasional, trade-off presisi-recall memberikan dasar untuk memilih ambang batas keputusan yang selaras dengan tujuan kampanye, membuat pendekatan ini lebih bermakna daripada hanya mengandalkan akurasi saja. Meskipun demikian, untuk memastikan bahwa peningkatan metrik prediktif diterjemahkan menjadi keuntungan bisnis yang sebenarnya (misalnya, CPA yang lebih rendah dan ROAS yang lebih tinggi), studi ini menekankan perlunya validasi lebih lanjut melalui eksperimen dunia nyata seperti pengujian A/B.

DAFTAR PUSTAKA

- [1] S. Barde, A. Jain, N. Singh, S. Patel, and A. Barde, "Artificial Intelligence and Machine Learning in Marketing," in *AI Marketing and Ethical Considerations in Consumer Engagement*, IGI Global Scientific Publishing, 2025, pp. 1–32.
- [2] H. Yoganarasimhan, "Search personalization using machine learning," *Manage. Sci.*, vol. 66, no. 3, pp. 1045–1070, 2020.
- [3] W. Xiong, Z. Xiong, and T. Tian, "Who to show the ad to? Behavioral targeting in Internet advertising," *J. Internet Digit. Econ.*, vol. 2, no. 1, pp. 15–26, 2022.
- [4] E. A. Dorgbefe, "Enhancing customer retention using predictive analytics and personalization in digital marketing campaigns," *Int J Sci Res Arch*, vol. 4, no. 1, pp. 403–423, 2021.
- [5] A. R. Lubis, S. Prayudani, O. Nugroho, Y. Y. Lase, and M. Lubis, "Comparison of Model

- in Predicting Customer Churn Based on Users' habits on E-Commerce," in *2022 5th International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*, IEEE, 2022, pp. 300–305.
- [6] A. R. Lubis, S. Prayudani, M. Lubis, and O. Nugroho, "Latent Semantic Indexing (LSI) and Hierarchical Dirichlet Process (HDP) Models on News Data," in *2022 5th International Conference of Computer and Informatics Engineering (IC2IE)*, IEEE, 2022, pp. 314–319.
- [7] I. B. Ridwan, "Transforming customer segmentation with unsupervised learning models and behavioral data in digital commerce," *Int. J. Res. Publ. Rev.*, vol. 6, no. 5, pp. 2232–2249, 2025.
- [8] S. Habil, S. El-Deeb, and N. El-Bassiouny, "AI-based recommendation systems: the ultimate solution for market prediction and targeting," in *The Palgrave handbook of interactive marketing*, Springer, 2023, pp. 683–704.
- [9] F. Fachrizal, "Data Transmission Performance on the Internet of Thing (IoT) Network Using Long Range Communication (LoRA)," in *2021 International Conference on Computer Science and Engineering (IC2SE)*, IEEE, 2021, pp. 1–4.
- [10] J. Lee, O. Jung, Y. Lee, O. Kim, and C. Park, "A comparison and interpretation of machine learning algorithm for the prediction of online purchase conversion," *J. Theor. Appl. Electron. Commer. Res.*, vol. 16, no. 5, pp. 1472–1491, 2021.
- [11] J. Yeo, S. Kim, E. Koh, S. Hwang, and N. Lipka, "Predicting online purchase conversion for retargeting," in *Proceedings of the Tenth ACM international conference on web search and data mining*, 2017, pp. 591–600.
- [12] O. Nugroho, "Identifikasi Asal Daerah Berdasarkan Dialek Menggunakan Metode Evolving Multilayer Perceptron," 2021, *Universitas Sumatera Utara*.
- [13] A. R. Lubis, H. R. Safitri, M. Lubis, M. L. Hamzah, A.-K. Al-Khowarizmi, and O. Nugroho, "Enhancing Text Summarization with a T5 Model and Bayesian Optimization.," *Rev. d'Intelligence Artif.*, vol. 37, no. 5, 2023.
- [14] R. B. Sarvesetty and N. Yeri, "Target looping using machine learning: an analytical approach using hyper-data in banking," *J. Bank. Financ. Technol.*, vol. 8, no. 2, pp. 65–76, 2024.
- [15] A. Mirzaee, M. Zeynali, A. Ghorbanzadeh, and P. Ghorbanzadeh, "Personal Recommender Model and Predicting Consumer Behavior in Digital Marketing Based on Deep Learning," *Trans. Mach. Intell.*, vol. 7, no. 3, pp. 179–193, 2024.
- [16] C. Ziakis and D. Kydros, "Using machine learning models to investigate consumer attitudes toward online behavioral advertising," *Intellect. Econ.*, vol. 16, no. 2, 2022.
- [17] H. Ekelik and Ş. Emir, "A comparison of machine learning classifiers for evaluation of remarketing audiences in e-commerce," *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilim. Derg.*, vol. 16, no. 2, pp. 341–359, 2021.
- [18] S. Malik and A. Rana, "Transforming Digital Marketing with Machine Learning Algorithms," *J. Graph. Era Univ.*, pp. 271–300, 2025.
- [19] J. Lin, "Application of machine learning in predicting consumer behavior and precision marketing," *PLoS One*, vol. 20, no. 5, p. e0321854, 2025.
- [20] O. Nugroho and G. A. Hutagalung, "Design and Implementation of Android-Based Public Transport Trayek using Cloud Computing Infrastructure," *Al'adzkiya Int. Comput. Sci. Inf. Technol. J.*, vol. 1, no. 1, 2020.
- [21] M. Arfah, F. Fachrizal, and O. Nugroho, "Developing A Model Of Association Rules With Machine Learning In Determining User Habits On Social Media.," *Eastern-European J. Enterp. Technol.*, no. 2, 2024.