

COLLABORATIVE FILTERING SEBAGAI PENGGERAK CUSTOMER VALUE DAN LOYALITAS PELANGGAN DALAM MANAJEMEN E-COMMERCE

Marihot Manullang¹, Didik Siswanto²

Universitas Lancang Kuning, Pekanbaru

e-mail: ¹marihot@unilak.ac.id, ²didik@unilak.ac.id

Abstract: *Recommender systems are widely deployed in e-commerce, yet their evaluation is still dominated by prediction-accuracy metrics that say little about the value customers actually perceive. This study examines Collaborative Filtering (CF) as a driver of customer value and loyalty in e-commerce management. Four CF variants (user-based and item-based, with cosine similarity and Pearson correlation) were compared with a popularity baseline using 10-fold cross validation, followed by a six-month A/B experiment and a survey of 400 customers analysed with validity, reliability, classical assumption, difference, multiple regression, and bootstrap mediation tests in Python. Item-based CF with Pearson correlation performed best (MAE 0.687; RMSE 0.856), reducing RMSE by 7.0% relative to the baseline and quadrupling catalogue coverage. CF recommendations increased click-through rate by 29.9% and conversion rate by 41.7%, and shortened product search time by 13.6%. CF significantly raised functional and emotional value but not economic value; the three value dimensions jointly explained loyalty ($\text{adjusted } R^2 = 0.224$), and customer value fully mediated the effect of CF on loyalty. Performance deteriorated for cold-start users and at very high sparsity. CF therefore acts as a strategic management instrument whose business value flows through search efficiency and emotional experience.*

Keyword: *collaborative filtering; Teknologi informasi, customer value; e-commerce; customer loyalty; recommender system.*

Abstrak: Sistem rekomendasi telah banyak diterapkan dalam e-commerce, tetapi evaluasinya masih didominasi metrik akurasi prediksi yang belum menggambarkan nilai yang dirasakan pelanggan. Penelitian ini mengkaji *Collaborative Filtering* (CF) sebagai penggerak *customer value* dan loyalitas pelanggan dalam manajemen e-commerce. Empat varian CF (*user-based* dan *item-based* dengan *cosine similarity* dan *Pearson correlation*) dibandingkan dengan baseline produk populer menggunakan *10-fold cross validation*, dilanjutkan eksperimen A/B selama enam bulan dan survei terhadap 400 pelanggan yang dianalisis dengan uji validitas, reliabilitas, asumsi klasik, uji beda, regresi linier berganda, dan mediasi *bootstrap* menggunakan Python. *Item-based* CF dengan *Pearson correlation* memberikan kinerja terbaik (MAE 0,687; RMSE 0,856), menurunkan RMSE 7,0% dibanding baseline dan memperluas cakupan katalog empat kali lipat. Rekomendasi CF meningkatkan CTR sebesar 29,9% dan *conversion rate* sebesar 41,7%, serta mempersingkat waktu pencarian produk 13,6%. CF meningkatkan nilai fungsional dan emosional secara signifikan, tetapi tidak nilai ekonomi; ketiga dimensi nilai secara simultan menjelaskan loyalitas ($\text{adjusted } R^2 = 0,224$), dan *customer value* memediasi penuh pengaruh CF terhadap loyalitas. Kinerja CF menurun pada pengguna *cold start* dan pada tingkat *sparsity* sangat tinggi. CF merupakan instrumen manajemen strategis yang nilai bisnisnya bekerja melalui efisiensi pencarian dan pengalaman emosional pelanggan.

Kata kunci: *collaborative filtering; customer value; e-commerce; loyalitas pelanggan; sistem rekomendasi.*

PENDAHULUAN

Pertumbuhan perdagangan elektronik menghadirkan ribuan hingga jutaan pilihan produk bagi konsumen. Kelimpahan pilihan tersebut menimbulkan *information overload*, yaitu kondisi ketika pelanggan kesulitan memproses seluruh alternatif sehingga proses pencarian menjadi melelahkan dan peluang transaksi justru menurun. Konsep *bounded rationality* menjelaskan bahwa manusia tidak mengevaluasi seluruh alternatif secara sempurna, melainkan mencari pilihan yang cukup baik dengan biaya kognitif serendah mungkin (Simon, 1955). Dalam kondisi ini, kemampuan platform membantu pelanggan menemukan produk yang relevan menjadi sumber keunggulan bersaing.

Kecerdasan buatan (*artificial intelligence*, AI) telah menggeser praktik pemasaran dari komunikasi massal menuju personalisasi berbasis data (Davenport et al., 2020; Huang & Rust, 2021). Salah satu wujud paling nyata dari pergeseran ini adalah sistem rekomendasi, yang memungkinkan keterlibatan pelanggan secara personal pada skala besar (Kumar et al., 2019). Teknik yang paling luas digunakan adalah *Collaborative Filtering* (CF), yang memprediksi preferensi seorang pengguna berdasarkan pola perilaku pengguna lain yang serupa. Pendekatan *user-based* CF dirintis melalui sistem GroupLens (Resnick et al., 1994), sedangkan pendekatan *item-based* CF yang menghitung kemiripan antarproduk dikembangkan oleh Sarwar et al. (2001) dan diterapkan dalam skala industri oleh Amazon (Linden et al., 2003). Perkembangan terbaru juga memanfaatkan *deep learning* untuk sistem rekomendasi (Zhang et al., 2019).

Meskipun demikian, evaluasi sistem rekomendasi masih didominasi ukuran akurasi prediksi seperti *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE), padahal akurasi bukan satu-satunya dimensi keberhasilan (Herlocker et al., 2004). Jannach dan


Jugovac (2019) menunjukkan bahwa ukuran nilai bisnis sistem rekomendasi sangat beragam dan jarang dikaitkan secara langsung dengan persepsi pelanggan. Penelitian empiris yang ada umumnya menilai dampak rekomendasi terhadap penjualan (Pathak et al., 2010) atau keragaman penjualan (Fleder & Hosanagar, 2009), sementara isu bias dan pemerataan paparan produk juga semakin mendapat perhatian (Chen et al., 2023).

Dari sisi manajemen, keberhasilan diukur melalui *customer value*, yaitu penilaian menyeluruh pelanggan atas manfaat yang diterima dibandingkan pengorbanan yang dikeluarkan (Zeithaml, 1988). *Customer value* bersifat multidimensi, mencakup nilai fungsional, emosional, dan nilai terkait harga (Sweeney & Soutar, 2001). Transformasi digital menuntut perusahaan menghubungkan investasi teknologi dengan penciptaan nilai bagi pelanggan (Verhoef et al., 2021). Namun, kajian yang menghubungkan keluaran algoritma CF secara langsung dengan dimensi *customer value*, loyalitas, dan *customer lifetime value* (CLV) masih terbatas.

Penelitian ini bertujuan untuk (1) membandingkan kinerja varian CF dalam memprediksi preferensi pelanggan; (2) menguji dampak rekomendasi CF terhadap kinerja bisnis, yaitu CTR, *conversion rate*, *average order value* (AOV), waktu pencarian, retensi, dan CLV; (3) menguji pengaruh rekomendasi CF terhadap nilai fungsional, emosional, dan ekonomi; (4) menguji pengaruh ketiga dimensi nilai tersebut terhadap loyalitas serta peran mediasinya; dan (5) mengidentifikasi batas kinerja CF pada kondisi *cold start* dan *sparsity*. Hipotesis yang diuji adalah H1–H3: rekomendasi CF berpengaruh positif terhadap nilai fungsional, emosional, dan ekonomi; H4: ketiga dimensi nilai berpengaruh terhadap loyalitas; dan H5: *customer value* memediasi pengaruh CF terhadap loyalitas.

METODE

Penelitian ini menggunakan pendekatan kuantitatif yang menggabungkan eksperimen algoritmik, eksperimen lapangan A/B, dan survei. Tahapan penelitian disajikan pada Gambar 1.



Gambar 1 Tahapan Penelitian

Data penelitian terdiri dari tiga kelompok. Pertama, log interaksi dan rating produk (skala 1–5) dari 600 pengguna terhadap 250 produk dalam delapan kategori, berjumlah 14.291 baris. Kedua, data 8.153 sesi eksperimen A/B selama Juli–Desember 2025. Ketiga, survei terhadap 400 pelanggan. Sumber data: nama platform e-commerce mitra dan prosedur izin penggunaan data. Seluruh identitas pelanggan diganti dengan kode acak sesuai prinsip pseudonimisasi dan minimisasi data dalam Undang-Undang Pelindungan Data Pribadi (Republik Indonesia, 2022).

Pra-pemrosesan meliputi penghapusan duplikat, rating kosong, dan rating di luar skala 1–5, sehingga tersisa 14.069 pasangan pengguna-produk dengan tingkat *sparsity* matriks User-Item sebesar 90,62%. Kemiripan antarpengguna u dan v dihitung dengan *cosine similarity* (1) dan *Pearson correlation* (2), dengan r_{ui} adalah rating pengguna u terhadap produk i dan $\bar{r}_u$

adalah rata-rata rating pengguna u .

$$\cos(u, v) = \frac{\sum_i r_{ui} r_{vi}}{\sqrt{\sum_i r_{ui}^2} \sqrt{\sum_i r_{vi}^2}} \quad (1)$$

$$\text{pearson}(u, v) = \frac{\sum_i (r_{ui} - \bar{r}_u)(r_{vi} - \bar{r}_v)}{\sqrt{\sum_i (r_{ui} - \bar{r}_u)^2} \sqrt{\sum_i (r_{vi} - \bar{r}_v)^2}} \quad (2)$$

Prediksi rating pada *user-based* CF menggunakan k tetangga terdekat $N_k(u)$ yang telah menilai produk i sebagaimana persamaan (3). *Item-based* CF menggunakan rumus analog dengan tetangga berupa produk yang paling mirip (Sarwar et al., 2001). Sebagai pembandingan digunakan baseline rata-rata rating produk yang setara dengan strategi rekomendasi produk terpopuler.

$$\hat{r}_{ui} = \bar{r}_u + \frac{\sum_{v \in N_k(u)} \text{sim}(u, v)(r_{vi} - \bar{r}_v)}{\sum_{v \in N_k(u)} |\text{sim}(u, v)|} \quad (3)$$

Akurasi diukur dengan MAE (4) dan RMSE (5) menggunakan *10-fold cross validation*, sedangkan kualitas daftar rekomendasi diukur dengan Precision@10, Recall@10, dan *catalog coverage* dengan produk relevan didefinisikan sebagai produk berating ≥ 4 (Herlocker et al., 2004). Jumlah tetangga k ditentukan melalui pengujian *hold-out* 80:20 pada $k = 5$ sampai 80.

$$\text{MAE} = \frac{1}{n} \sum |r_{ui} - \hat{r}_{ui}| \quad (4)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum (r_{ui} - \hat{r}_{ui})^2} \quad (5)$$

Pada eksperimen A/B, pengguna dibagi secara acak ke kelompok Kontrol (rekomendasi produk terpopuler) dan Treatment (rekomendasi CF). Perbedaan CTR dan *conversion rate* diuji dengan Z-test dua proporsi, AOV dengan uji Mann-Whitney U, dan waktu pencarian dengan Welch t-test. CLV dihitung sebagai pendapatan pelanggan selama enam bulan dikalikan margin kontribusi yang diasumsikan 20%.

Kuesioner terdiri dari 15 butir skala Likert 1–5 yang diadaptasi dari Sweeney dan Soutar (2001), mencakup nilai fungsional (FV, 4 butir), nilai emosional

(EV, 4 butir), nilai ekonomi (KV, 4 butir), dan loyalitas (LOY, 3 butir). Validitas diuji dengan korelasi butir-total, reliabilitas dengan *Cronbach's alpha* (Cronbach, 1951), dan asumsi klasik dengan uji Kolmogorov-Smirnov, VIF, serta uji Glejser. H1–H3 diuji dengan Welch t-test dan ukuran efek Cohen's d, H4 dengan regresi linier berganda pada persamaan (6), dan H5 dengan interval kepercayaan *bootstrap* 2.000 resample untuk efek tidak langsung (Preacher & Hayes, 2008). Seluruh analisis dijalankan dengan Python (NumPy, pandas, SciPy, scikit-learn) di Google Colab.

$$Y = a + b_1FV + b_2EV + b_3KV + e$$

HASIL DAN PEMBAHASAN

Pengujian jumlah tetangga menunjukkan bahwa error menurun tajam dari $k = 5$ hingga $k = 20$ lalu mendatar, dengan nilai optimum pada $k = 30$. Hasil *10-fold cross validation* pada Tabel 1 menunjukkan bahwa keempat varian CF lebih akurat daripada baseline, dengan *item-based* CF berbasis *Pearson correlation* sebagai model terbaik.

Tabel 1 Hasil 10-Fold Cross Validation (k = 30)

Model	MAE	RMSE
Item-Based CF Pearson	0,687 ± 0,016	0,856 ± 0,019
User-Based CF Pearson	0,692 ± 0,015	0,861 ± 0,017
Item-Based CF Cosine	0,703 ± 0,018	0,869 ± 0,022
User-Based CF Cosine	0,704 ± 0,017	0,874 ± 0,020
Baseline populer	0,747 ± 0,019	0,921 ± 0,019

Nilai merupakan rata-rata ± simpangan baku dari 10 fold.

Model terbaik menurunkan RMSE sebesar 7,0% dibanding baseline, dan perbedaannya signifikan (*paired t-test*, $t = -19,95$; $p < 0,001$). Keunggulan *item-based* CF sejalan dengan temuan Sarwar et al. (2001) dan Linden et al. (2003): hubungan antarproduk lebih stabil

daripada selera individu, dan setiap produk dinilai oleh lebih banyak pengguna. Keunggulan *Pearson correlation* atas *cosine similarity* disebabkan oleh koreksi terhadap perbedaan kebiasaan pengguna dalam memberi nilai.

Tabel 2 Kualitas Rekomendasi Top-10

Model	Precision @10	Recall @10	Coverage
Baseline populer	0,065	0,183	10,4%
User-Based CF	0,064	0,169	43,2%
Item-Based CF	0,059	0,142	42,4%


Tabel 2 memperlihatkan temuan yang penting bagi manajemen. Precision@10 dan Recall@10 CF tidak lebih tinggi daripada baseline populer, karena produk laris memang disukai banyak orang. Namun, *catalog coverage* meningkat dari 10,4% menjadi 43,2%, sehingga CF memperkenalkan sekitar empat kali lebih banyak produk kepada pelanggan. Hal ini mendukung pandangan bahwa akurasi saja tidak cukup untuk menilai sistem rekomendasi (Herlocker et al., 2004) dan bahwa desain algoritma menentukan luas paparan katalog (Chen et al., 2023; Fleder & Hosanagar, 2009).

Tabel 3 Akurasi Berdasarkan Panjang Histori Pengguna

Histori (interaksi)	n uji	MAE	RMSE
≤4 (cold start)	78	0,767	0,939
5–10	280	0,753	0,929
11–25	1.016	0,704	0,870
26–50	737	0,703	0,874
>50	703	0,678	0,840

Tabel 3 dan Gambar 2 mengonfirmasi dua hambatan utama CF. RMSE pengguna *cold start* (≤ 4 interaksi) mencapai 0,939, lebih tinggi daripada pengguna dengan histori lebih dari 50 interaksi (0,840). Ketika data latih dikurangi, keunggulan CF hilang pada

sparsity sekitar 96%, dan pada *sparsity* 98% kedua varian CF justru kalah dari baseline. Implikasinya, pengelola platform perlu menerapkan strategi khusus bagi pelanggan baru, misalnya rekomendasi populer per segmen dan pengumpulan preferensi awal, serta mempertimbangkan model *hybrid* atau *deep learning* yang lebih tahan terhadap data jarang (Zhang et al., 2019).



Gambar 2 RMSE pada Berbagai Tingkat Sparsity


Tabel 4 Hasil Eksperimen A/B

Metrik	Kontrol	CF	Δ	Sig.
CTR	7,51%	9,75%	+29,9 %	< 0,001
Conversion rate	9,93%	14,06 %	+41,7 %	< 0,001
AOV (ribu Rp)	238,2	262,3	+10,1 %	0,036
Waktu cari (menit)	9,61	8,30	-13,6 %	< 0,001
CLV 6 bulan (ribu Rp)	59,8	107,2	+79%	< 0,001

CTR dan conversion rate diuji dengan Z-test dua proporsi; AOV dan CLV dengan Mann-Whitney U; waktu pencarian dengan Welch t-test.

Hasil eksperimen A/B pada Tabel 4 menunjukkan bahwa seluruh metrik bisnis bergerak ke arah yang diharapkan dan signifikan. Kenaikan terbesar terjadi pada *conversion rate* (41,7%), sedangkan kenaikan AOV relatif kecil (10,1%). Artinya, CF terutama mendorong terjadinya transaksi, bukan memperbesar nilai keranjang. Penurunan waktu

pencarian sebesar 13,6% menjadi bukti langsung berkurangnya biaya pencarian pelanggan. Temuan ini konsisten dengan Pathak et al. (2010) yang menemukan pengaruh positif kekuatan rekomendasi terhadap penjualan, serta dengan Kumar et al. (2019) mengenai peran AI dalam keterlibatan pelanggan yang personal. Gambar 3 memperlihatkan bahwa kurva retensi kedua kelompok mulai terpisah pada bulan ketiga; pada bulan keenam, 30,1% pengguna kelompok CF masih aktif dibandingkan 20,3% pada kelompok Kontrol.



Gambar 3 Retensi Pengguna per Bulan


Seluruh butir kuesioner dinyatakan valid karena r hitung (0,756–0,815) melebihi r tabel (0,098; $n = 400$). Nilai *Cronbach's alpha* untuk nilai fungsional, emosional, dan ekonomi berturut-turut 0,769, 0,798, dan 0,780, sedangkan loyalitas 0,669, sedikit di bawah batas 0,70 karena hanya terdiri dari tiga butir. Uji asumsi klasik terpenuhi: residual berdistribusi normal (Kolmogorov-Smirnov, $p = 0,736$), tidak terjadi multikolinieritas (VIF maksimum 1,005), dan tidak terjadi heteroskedastisitas (seluruh nilai signifikansi uji Glejser $> 0,05$).

Tabel 5 Perbandingan Customer Value antar Kelompok

Variabel	Kontrol	CF	t	Sig.	d
Fungsional	3,55	3,78	3,72	< 0,001	0,37
Emosional	3,46	3,67	3,07	0,002	0,31
Ekonomi	3,56	3,63	1,06	0,289	0,11
Loyalitas	3,61	3,69	1,38	0,169	0,14

d = ukuran efek Cohen's d ; uji Welch t-test.

Tabel 5 dan Gambar 4 menunjukkan bahwa rekomendasi CF meningkatkan nilai fungsional ($d = 0,37$) dan nilai emosional ($d = 0,31$) secara signifikan, sehingga H1 dan H2 diterima. Perbedaan nilai ekonomi tidak signifikan ($p = 0,289$), sehingga H3 ditolak. Hasil ini masuk akal secara teoretis: CF mengurangi beban kognitif dan biaya pencarian (Simon, 1955) sekaligus menghadirkan rasa dipahami serta kejutan menemukan produk baru, tetapi persepsi nilai ekonomi terutama dibentuk oleh harga dan promosi (Zeithaml, 1988; Sweeney & Soutar, 2001) yang tidak diubah oleh algoritma CF.



Gambar 4 Skor Customer Value per Dimensi (IK 95%)

Tabel 6 Hasil Regresi Linier Berganda terhadap Loyalitas

Variabel	B	t	Sig.
Konstanta	1,148	4,805	< 0,001
Fungsional (X1)	0,186	4,569	< 0,001
Emosional (X2)	0,284	7,497	< 0,001
Ekonomi (X3)	0,225	5,606	< 0,001

$F = 39,358$ (Sig. < 0,001); $R^2 = 0,230$; $adjusted\ R^2 = 0,224$; $t\ tabel = 1,966$; $F\ tabel = 2,627$.

Hasil regresi pada Tabel 6 menunjukkan bahwa ketiga dimensi nilai berpengaruh positif dan signifikan terhadap loyalitas secara parsial (t hitung > 1,966) maupun simultan (F hitung $39,358 > F$ tabel 2,627), sehingga H4 diterima. Nilai emosional merupakan prediktor terkuat ($B = 0,284$). Nilai $adjusted\ R^2$ sebesar 0,224 menunjukkan bahwa 22,4% variasi loyalitas dijelaskan oleh *customer value*, sementara sisanya

dipengaruhi faktor lain seperti kepercayaan, harga, dan kualitas layanan.

Uji mediasi menghasilkan efek tidak langsung CF terhadap loyalitas melalui *customer value* sebesar 0,122 dengan interval kepercayaan *bootstrap* 95% [0,065; 0,182] yang tidak memuat nol, sedangkan efek langsung CF terhadap loyalitas tidak signifikan. Dengan demikian, H5 diterima dan *customer value* berperan sebagai mediator penuh (Preacher & Hayes, 2008). Rantai pengaruh yang terbentuk adalah rekomendasi CF → efisiensi pencarian dan pengalaman emosional → *customer value* → loyalitas → retensi dan CLV. Temuan ini memperluas kajian nilai bisnis sistem rekomendasi (Jannach & Jugovac, 2019) dengan menunjukkan bahwa dampak finansial CF bekerja melalui persepsi nilai pelanggan, bukan secara langsung.

Secara manajerial, hasil ini mengandung empat implikasi. Pertama, rekomendasi CF paling efektif ditempatkan pada titik keputusan pembelian, seperti halaman produk dan keranjang, karena dampak terbesarnya ada pada konversi. Kedua, keberhasilan sistem rekomendasi perlu diukur secara berlapis: metrik teknis, metrik perilaku, metrik persepsi, dan metrik hasil. Ketiga, peningkatan nilai ekonomi membutuhkan perpaduan CF dengan strategi harga dan promosi personal. Keempat, strategi *cold start* perlu diperlakukan sebagai kebijakan operasional, disertai kepatuhan terhadap regulasi perlindungan data pribadi (Republik Indonesia, 2022) dan prinsip AI yang bertanggung jawab (Huang & Rust, 2021).

SIMPULAN

Penelitian ini menunjukkan bahwa *Collaborative Filtering* tidak hanya berfungsi sebagai alat teknis untuk memprediksi rating, tetapi juga sebagai instrumen manajemen strategis yang menggerakkan *customer value* dan loyalitas pelanggan. Konfigurasi *item-*

based CF dengan *Pearson correlation* memberikan akurasi terbaik dan memperluas paparan katalog secara substansial, meskipun ketepatan daftar rekomendasi tidak melampaui strategi produk populer. Nilai bisnis CF bekerja melalui dua jalur, yaitu efisiensi pencarian yang meningkatkan nilai fungsional dan pengalaman personal yang meningkatkan nilai emosional, sedangkan nilai ekonomi tidak tersentuh oleh personalisasi berbasis perilaku.

Kontribusi utama penelitian ini adalah kerangka evaluasi terpadu yang menghubungkan metrik algoritmik, metrik perilaku, dan persepsi nilai pelanggan dalam satu rangkaian analisis, sehingga investasi sistem rekomendasi dapat dinilai dari sudut pandang ilmu komputer dan ilmu manajemen sekaligus. Temuan mengenai batas kinerja CF pada kondisi *cold start* dan *sparsity* tinggi menegaskan bahwa efektivitas personalisasi sangat bergantung pada kepadatan data perilaku, sehingga kerangka ini dapat diperluas pada model *hybrid* dan pendekatan pembelajaran mendalam.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Lembaga Penelitian dan Pengabdian kepada Masyarakat (LPPM) Universitas Lancang Kuning atas dukungan pendanaan melalui skema Penelitian Fundamental Guru Besar serta kepada platform e-commerce mitra yang telah memfasilitasi pengumpulan data.

DAFTAR PUSTAKA

- Chen, J., Dong, H., Wang, X., Feng, F., Wang, M., & He, X. (2023). Bias and debias in recommender system: A survey and future directions. *ACM Transactions on Information Systems*, 41(3), 1–39.
- Cronbach, L. J. (1951). Coefficient alpha and the internal structure of tests. *Psychometrika*, 16(3), 297–334.
- Davenport, T., Guha, A., Grewal, D., & Bressgott, T. (2020). How artificial intelligence will change the future of marketing. *Journal of the Academy of Marketing Science*, 48(1), 24–42.
- Fleder, D., & Hosanagar, K. (2009). Blockbuster culture's next rise or fall: The impact of recommender systems on sales diversity. *Management Science*, 55(5), 697–712.
- Herlocker, J. L., Konstan, J. A., Terveen, L. G., & Riedl, J. T. (2004). Evaluating collaborative filtering recommender systems. *ACM Transactions on Information Systems*, 22(1), 5–53.
- Huang, M.-H., & Rust, R. T. (2021). A strategic framework for artificial intelligence in marketing. *Journal of the Academy of Marketing Science*, 49(1), 30–50.
- Jannach, D., & Jugovac, M. (2019). Measuring the business value of recommender systems. *ACM Transactions on Management Information Systems*, 10(4), 1–23.
- Kumar, V., Rajan, B., Venkatesan, R., & Lecinski, J. (2019). Understanding the role of artificial intelligence in personalized engagement marketing. *California Management Review*, 61(4), 135–155.
- Linden, G., Smith, B., & York, J. (2003). Amazon.com recommendations: Item-to-item collaborative filtering. *IEEE Internet Computing*, 7(1), 76–80.
- Pathak, B., Garfinkel, R., Gopal, R. D., Venkatesan, R., & Yin, F. (2010). Empirical analysis of the impact of recommender systems on sales. *Journal of Management Information Systems*, 27(2), 159–188.
- Preacher, K. J., & Hayes, A. F. (2008). Asymptotic and resampling strategies for assessing and comparing indirect effects in multiple mediator models. *Behavior Research Methods*, 40(3), 879–891.
- Republik Indonesia. (2022). *Undang-Undang Nomor 27 Tahun 2022*

- tentang Pelindungan Data Pribadi.*
- Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P., & Riedl, J. (1994). GroupLens: An open architecture for collaborative filtering of netnews. *Proceedings of the 1994 ACM Conference on Computer Supported Cooperative Work* (pp. 175–186).
- Sarwar, B., Karypis, G., Konstan, J., & Riedl, J. (2001). Item-based collaborative filtering recommendation algorithms. *Proceedings of the 10th International Conference on World Wide Web* (pp. 285–295).
- Simon, H. A. (1955). A behavioral model of rational choice. *The Quarterly Journal of Economics*, 69(1), 99–118.
- Sweeney, J. C., & Soutar, G. N. (2001). Consumer perceived value: The development of a multiple item scale. *Journal of Retailing*, 77(2), 203–220.
- Verhoef, P. C., Broekhuizen, T., Bart, Y., Bhattacharya, A., Dong, J. Q., Fabian, N., & Haenlein, M. (2021). Digital transformation: A multidisciplinary reflection and research agenda. *Journal of Business Research*, 122, 889–901.
- Zeithaml, V. A. (1988). Consumer perceptions of price, quality, and value: A means-end model and synthesis of evidence. *Journal of Marketing*, 52(3), 2–22.
- Zhang, S., Yao, L., Sun, A., & Tay, Y. (2019). Deep learning based recommender system: A survey and new perspectives. *ACM Computing Surveys*, 52(1), 1–38.