



Sistem Rekomendasi Distribusi Produk Menggunakan Metode Collaborative Filtering

Yudhistira Rangga Nata¹, Ichsan Ramdhani^{1*}

^{1,2}Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Pamulang, Tangerang Selatan, Indonesia

Email: ¹anggarata24@gmail.com, ^{2*}dosen02110@unpam.ac.id

(* : corresponding author)

Abstrak—Penentuan jumlah distribusi produk ke tiap outlet di PT Zircon Euro Asia masih banyak bergantung pada perkiraan staf, sehingga berisiko menimbulkan overstock dan understock. Penelitian ini mengusulkan model hibrida berbobot yang menggabungkan sinyal tren toko berbasis exponential smoothing dan sinyal item-based Collaborative Filtering (CF) berbasis cosine similarity untuk merekomendasikan kuantitas distribusi per toko dan produk. Bobot hibrida dipilih dari data validasi pada grid 0 sampai 1, bukan ditetapkan berdasarkan perkiraan. Evaluasi memakai pembagian data berurutan menurut waktu dengan pembandingan tren toko saja, moving average, dan CF saja. Kualitas ranking mesin CF diuji dengan leave-out testing pada 21.051 basket uji dari 10 wilayah dengan pembagian berbasis waktu dan menghasilkan Precision@5 sebesar 6,85% serta Recall@15 sebesar 38,63%, sehingga CF lebih tepat berperan sebagai sinyal pelengkap. Pada data uji, hibrida dengan bobot terbaik $w_2 = 0,2$ menghasilkan MAE 1,82, RMSE 4,46, dan WAPE 54,02%, dibanding WAPE 55,36% (tren toko saja), 56,24% (moving average), dan 56,53% (CF saja); terhadap B1 unggul bermakna, terhadap B2 keunggulan tidak terbukti. Model diimplementasikan pada sistem web Laravel dan MySQL.

Kata Kunci: Collaborative Filtering; Sistem Rekomendasi; Distribusi Produk; Peramalan Permintaan; Model Hibrida

Abstract—The quantity of products distributed to each outlet at PT Zircon Euro Asia still depends largely on staff estimates, which risks overstock and understock. This study proposes a weighted hybrid model that combines a store-trend signal based on exponential smoothing with an item-based Collaborative Filtering (CF) signal based on cosine similarity to recommend distribution quantities per store and product. The hybrid weight is selected on validation data over a grid from 0 to 1 rather than assumed. Evaluation uses a time-ordered data split with three baselines: store trend only, moving average, and CF only. The ranking quality of the CF engine was tested by leave-out testing on 21,051 held-out transaction baskets from 10 regions using a time-based split, yielding a Precision@5 of 6.85% and a Recall@15 of 38.63%, so CF is better suited as a complementary signal. On the test data, the hybrid with the best weight $w_2 = 0.2$ yielded a WAPE of 54.02%, versus 55.36% (store trend only), 56.24% (moving average), and 56.53% (CF only); against B1: significant advantage; against B2: advantage not established. The model is implemented in a Laravel and MySQL web system.

Keywords: Collaborative Filtering; Recommender System; Product Distribution; Demand Forecasting; Hybrid Model

1. PENDAHULUAN

Penentuan jumlah produk yang dikirim ke setiap outlet merupakan keputusan rutin dalam rantai distribusi yang memengaruhi ketersediaan barang dan biaya persediaan. PT Zircon Euro Asia, produsen dan distributor minuman kemasan dengan merek Mama Roz yang melayani banyak outlet, masih banyak menentukan jumlah distribusi berdasarkan perkiraan dan pengalaman Staff PPIC (Perencanaan Produksi dan Pengendalian Persediaan), padahal data historis penjualan telah tersedia di dalam sistem. Jumlah kiriman yang melebihi kebutuhan menimbulkan *overstock* dan risiko produk kedaluwarsa, sedangkan jumlah yang kurang membuat outlet kehabisan stok (*understock*).

Masalah ini dapat dipandang sebagai peramalan kuantitas permintaan pada tingkat pasangan toko dan produk. Peramalan ritel pada tingkat yang rinci memiliki tantangan tersendiri (Fildes, Ma, & Kolassa, 2022). Metode sederhana seperti *moving average* dan *exponential smoothing* banyak dipakai sebagai dasar atau pembandingan dalam peramalan (Petroopoulos et al., 2022), tetapi keduanya hanya memakai riwayat satu deret sehingga lemah ketika riwayat suatu pasangan toko dan produk masih pendek.

Collaborative Filtering (CF) memanfaatkan pola kesamaan antarentitas untuk membuat prediksi (Papadakis et al., 2022; Roy & Dutta, 2022). Pada metode *item-based*, kemiripan antarproduk dihitung dari pola kemunculannya sehingga informasi dari produk serupa dapat dipakai untuk produk yang riwayatnya kurang (Sarwar et al., 2001). Gagasan ini mulai dipakai pada



peramalan penjualan. Bi et al. (2022) memakai CF berbasis faktorisasi tensor toko, produk, dan waktu agar toko dan produk saling berbagi informasi pada data yang jarang, dan Liang et al. (2024) mengembangkan CF yang disempurnakan untuk peramalan permintaan lintas toko. Di Indonesia, CF telah diterapkan pada sistem rekomendasi produk berbasis web (Frediansa, Mahmudi, & Pranoto, 2025). Di sisi lain, CF menghadapi masalah *cold-start* ketika entitas baru belum memiliki riwayat (Panteli & Boutsinas, 2023). Tren toko dan CF karenanya saling melengkapi: tren toko andal bila riwayat panjang, sedangkan CF dapat meminjam informasi dari produk lain yang serupa ketika riwayat pendek.

Dua hal lain perlu diperhatikan. Pertama, CF umumnya dievaluasi sebagai ranking item, sedangkan kebutuhan distribusi adalah kuantitas. Kedua, evaluasi offline rawan kebocoran data bila pembagian data mengabaikan urutan waktu (Ji et al., 2023), dan evaluasi peramalan memiliki jebakan umum pada pembagian data dan pemilihan metrik (Hewamalage, Ackermann, & Bergmeir, 2023).

Penelitian ini bertujuan merekomendasikan kuantitas distribusi per toko dan produk dengan model hibrida berbobot. Kontribusinya adalah:

- model hibrida yang menggabungkan tren toko berbasis *exponential smoothing* dan sinyal CF berbasis indeks permintaan relatif;
- pemilihan bobot hibrida dari data validasi dan evaluasi berurutan waktu terhadap tiga pembandingan (tren toko saja, *moving average*, CF saja);
- evaluasi kualitas ranking mesin CF pada 21.051 basket uji dari 10 wilayah, serta implementasi model pada sistem web.

2. METODE

2.1 Data Penelitian

Penelitian ini memakai dua kelompok data dari basis data perusahaan (Tabel 1). Kelompok pertama adalah basket transaksi historis yang dipakai membangun matriks kemiripan produk dan menguji ranking CF. Kelompok kedua adalah kuantitas penjualan (terjual) mingguan per toko dan produk dari data transaksi kasir (POS) outlet, yang dipakai sebagai proksi permintaan untuk menghitung tren toko dan mengevaluasi akurasi kuantitas. Pembersihan data meliputi penghapusan duplikat, penanganan nilai negatif atau retur, pengeluaran produk nonaktif, dan pengurutan menurut waktu. Kuantitas terjual diagregasi per minggu (minggu ISO mulai Senin) tanpa mencampur jenis kuantitas lain; dari 699.954 baris item mentah dibuang 48.167 karena kode produk dikecualikan, 10 karena produk tidak ada di master, dan 39.521 karena harga nol atau kosong, sehingga tersisa 612.256 baris. Pada tahap impor tidak ada baris yang ditolak dari 612.256 baris, dan duplikat order (406.765 baris) dibuang pada tahap awal sehingga tersisa 293.189 order unik.

Tabel 1. Ringkasan data penelitian

Data	Keterangan	Jumlah
Basket transaksi	Basket uji sejak 1 November 2025; matriks kemiripan dibangun dari 225.899 basket latih sebelum tanggal itu	21.051 basket
Wilayah	Wilayah asal basket	10
Produk aktif	Produk yang muncul pada basket	149
Kuantitas terjual per toko, produk, minggu	Pengamatan (baris) setelah pembersihan; periode dijelaskan di teks	92.429

2.2 Alur Distribusi

Sistem yang diusulkan terdiri atas aplikasi web Laravel dengan basis data MySQL, yang mengelola akun, peran, dan alur persetujuan, serta layanan perhitungan rekomendasi terpisah berbasis Python FastAPI yang menghitung estimasi kuantitas E per produk (Persamaan 1–5). Aplikasi web menghitung rekomendasi R (Persamaan 6) dengan membandingkan E dan stok toko saat ini, lalu menampilkannya sebagai draft. Bila layanan perhitungan tidak dapat

dihubungi, halaman draft tetap tampil tanpa rekomendasi otomatis disertai pemberitahuan, dan alur persetujuan, pengiriman, serta penerimaan tetap berjalan.

Alur distribusi terdiri atas empat tahap yang dijalankan empat peran secara berurutan (Gambar 1 dan Tabel 2). Staff PPIC memilih toko dan tanggal, lalu memeriksa dan dapat mengubah draft rekomendasi sebelum mengajukannya. Manager PPIC, yang bukan pengaju draft, menyetujui draft dengan kemungkinan menyesuaikan jumlah kirim final, atau menolaknya dengan alasan sehingga draft kembali ke Staff PPIC untuk diperbaiki dan diajukan ulang. Divisi Logistik melaksanakan pengiriman dan mencatat jumlah yang benar-benar dikirim, yang dapat berbeda dari jumlah yang disetujui karena mengikuti ketersediaan stok gudang. Crew Outlet menghitung fisik barang dan mencatat jumlah yang diterima, dan stok toko diperbarui pada saat konfirmasi penerimaan. Transisi status di luar urutan ini ditolak oleh sistem.



Gambar 1. Alur distribusi produk dari rekomendasi hingga penanganan selisih

Tabel 2. Peran, aksi, dan status draft pada setiap tahap

Tahap	Peran	Aksi	Status draft sesudahnya
1	Staff PPIC	Memilih toko dan tanggal, memeriksa atau mengubah draft rekomendasi, lalu mengajukan	diajukan
2	Manager PPIC	Menyetujui (jumlah final dapat disesuaikan) atau menolak dengan alasan	disetujui_manager; ditolak (kembali ke Staff PPIC)
3	Divisi Logistik	Mengirim barang dan mencatat jumlah yang dikirim	dikirim_logistik
4	Crew Outlet	Menghitung fisik barang dan mencatat jumlah yang diterima; stok toko diperbarui	diterima_outlet

Selisih dihitung per produk sebagai jumlah dikirim dikurangi jumlah diterima. Selisih positif berarti kekurangan di outlet; selisih itu dicatat apa adanya tanpa menghambat penyelesaian draft, ditampilkan sebagai pengingat kepada Staff PPIC, dan ditambahkan ke draft berikutnya untuk toko yang sama sebagai item susulan yang dipisahkan dari kuantitas reguler. Status selisih tidak disimpan, tetapi dihitung saat dibaca: tidak ada bila jumlah dikirim sama dengan jumlah diterima, terbuka bila ada kekurangan yang belum ditutup, dan lunas bila jumlah yang diterima pada item susulan yang menaunginya telah mencapai besar kekurangan. Susulan yang sendiri berselisih menimbulkan selisih baru sehingga rantai berlanjut. Selisih negatif, yaitu jumlah diterima lebih besar daripada jumlah dikirim, dicatat dan ditandai untuk ditinjau, tetapi tidak memicu susulan.


2.3 Model Hibrida Tren Toko dan Collaborative Filtering

Notasi yang dipakai adalah sebagai berikut. Indeks s menyatakan toko, i dan j menyatakan produk, dan t menyatakan periode (minggu). $q_{s,i,t}$ adalah kuantitas terjual produk i di toko s pada periode t . Parameter α ($0 < \alpha \leq 1$) mengatur pemulusan, $m_{\min}$ adalah panjang riwayat minimum agar

tren toko terdefinisi, k adalah jumlah produk tetangga pada CF, dan w_1 serta w_2 adalah bobot kedua sinyal. Seluruh nilai pada periode t dihitung hanya dari data sampai periode $t - 1$ agar tidak ada informasi masa depan yang terpakai.

Estimasi kuantitas dihitung dari dua sinyal (Gambar 2). Sinyal pertama adalah tren toko T , yaitu *exponential smoothing* sederhana atas riwayat kuantitas q pasangan toko s dan produk i pada periode t , dengan α sebagai parameter pemulusan (Persamaan 1). T hanya didefinisikan bila pasangan memiliki riwayat paling sedikit $m_{\min}$ periode. Pasangan di bawah batas itu dikategorikan *cold-start*. Nilai T pertama pada suatu pasangan diinisialisasi dengan kuantitas pertama yang teramati pada pasangan itu, dan pembaruan berikutnya memakai Persamaan 1.

$$T_{s,i,t} = \alpha q_{s,i,t-1} + (1 - \alpha) T_{s,i,t-1} \quad (1)$$



Gambar 2. Alur model hibrida untuk rekomendasi kuantitas distribusi

Sinyal kedua berasal dari *item-based* CF. Kemiripan dua produk i dan j dihitung dengan *cosine similarity* pada matriks basket biner, dengan $x_{b,i}$ bernilai 1 bila produk i ada pada basket b (Persamaan 2; Sarwar et al., 2001). Matriks ini dibangun hanya dari basket segmen latih.

$$\text{sim}(i, j) = \frac{\sum_b x_{b,i} x_{b,j}}{\sqrt{\sum_b x_{b,i}^2} \sqrt{\sum_b x_{b,j}^2}} \quad (2)$$

Karena volume antarproduk berbeda jauh, kuantitas produk lain tidak dapat dipakai langsung. Sinyal CF memakai indeks permintaan relatif $r_{s,j}$, yaitu perbandingan tren toko s untuk produk j dengan rata-rata tren μ_j pada himpunan toko S_j yang memiliki produk tersebut (Persamaan 3). Dengan $N_k(i)$ sebagai k produk paling mirip dengan i yang memiliki $r_{s,j}$, sinyal CF untuk produk i di toko s adalah jumlah terbobot indeks tersebut yang dikembalikan ke skala produk i dengan μ_i (Persamaan 4). Karena matriks basket bersifat biner, nilai $\text{sim}(i, j)$ berada pada selang 0 sampai 1. $N_k(i)$ hanya memuat produk j yang memiliki $r_{s,j}$ pada toko s , dan μ_j hanya dihitung dari tren yang tersedia sebelum periode t .

$$r_{s,j} = \frac{T_{s,j}}{\mu_j}, \quad \mu_j = \frac{1}{|S_j|} \sum_{s \in S_j} T_{s,j} \quad (3)$$

$$C_{s,i} = \mu_i \frac{\sum_{j \in N_k(i)} \text{sim}(i, j) r_{s,j}}{\sum_{j \in N_k(i)} \text{sim}(i, j)} \quad (4)$$

Estimasi akhir adalah kombinasi linear berbobot kedua sinyal (Persamaan 5), dengan aturan cadangan menurut ketersediaan sinyal:



- bila T dan C sama-sama tersedia, E mengikuti Persamaan 5;
- bila T tidak terdefinisi (*cold-start*), $E = C$;
- bila C tidak dapat dihitung, $E = T$;
- bila keduanya tidak tersedia, $E = 0$ dengan keterangan “tanpa dasar data” agar Staff PPIC mengisinya secara manual.

Kuantitas yang direkomendasikan kepada Staff PPIC diperoleh dengan membandingkan estimasi dengan stok toko saat ini (Persamaan 6).

$$E_{s,i} = w_1 T_{s,i} + w_2 C_{s,i}, \quad w_1 + w_2 = 1 \quad (5)$$

$$R_{s,i} = \max\left(0, \text{round}(E_{s,i} - \text{stok}_{s,i})\right) \quad (6)$$

Pada Persamaan 6, $\text{stok}_{s,i}$ adalah stok produk i di toko s saat ini, round membulatkan ke bilangan bulat terdekat, dan $\max(0, \cdot)$ mencegah rekomendasi bernilai negatif bila stok melebihi estimasi. Dengan demikian R adalah jumlah yang perlu dikirim agar stok toko mencapai estimasi kebutuhan E .

2.4 Pemilihan Bobot dan Pembanding

Bobot tidak ditetapkan berdasarkan perkiraan. Nilai w_2 diuji pada grid $0; 0,1; \dots; 1,0$ dengan $w_1 = 1 - w_2$. Bobot terbaik adalah yang menghasilkan WAPE terkecil pada data validasi (bila selisihnya tidak bermakna dipilih yang MAE-nya lebih kecil), kemudian dikunci dan dilaporkan pada data uji. Bobot awal rancangan, $w_1 = 0,7$ dan $w_2 = 0,3$, hanyalah satu titik grid yang diuji bersama nilai lain. Kedua ujung grid sekaligus menjadi pembanding, yaitu $w_2 = 0$ sebagai tren toko saja (B1) dan $w_2 = 1$ sebagai CF saja (B3). Pembanding ketiga adalah *moving average* dengan jendela n periode (B2). Parameter α , $m_{\min}$, k , dan n dipilih pada data validasi $\alpha = 0,5$; $m_{\min} = 2$; $k = 10$; $n = 4$.

2.5 Skema Evaluasi

Evaluasi kuantitas. Data kuantitas diurutkan menurut waktu dan dibagi menjadi segmen latih, validasi, dan uji secara berurutan proporsi 70/15/15 menurut urutan periode. Pada setiap periode di segmen validasi dan uji, estimasi dihitung hanya dari data sampai periode sebelumnya (*rolling origin*) agar tidak ada informasi masa depan yang terpakai (Hewamalage, Ackermann, & Bergmeir, 2023; Ji et al., 2023). Galat diukur dengan MAE, RMSE, dan WAPE (Persamaan 7); MAPE tidak dipakai karena banyak pengamatan bernilai nol. Pengamatan mencakup pasangan toko dan produk yang pernah terjual sebelum periode t , dengan kuantitas aktual nol bila tidak ada penjualan pada periode t ; pasangan yang belum pernah terjual dikeluarkan. Hasil dilaporkan secara keseluruhan dan per lapisan *cold-start* dan *non-cold-start*. Selisih galat mutlak per pasangan antara model hibrida terbaik terhadap B1 dan terhadap B2 diuji dengan uji peringkat bertanda Wilcoxon pada taraf signifikansi 5%.

$$\text{WAPE} = \frac{\sum_n |y_n - \hat{y}_n|}{\sum_n |y_n|} \times 100\% \quad (7)$$

Evaluasi ranking. Kualitas ranking CF diuji dengan *leave-out testing* pada 21.051 basket uji, yaitu basket sejak 1 November 2025, sedangkan matriks kemiripan dibangun hanya dari basket sebelum tanggal itu: separuh item pada tiap basket uji disembunyikan secara acak (seed 42), lalu diperiksa apakah mesin merekomendasikan kembali item tersebut dari item yang tersisa. Metrik yang dipakai adalah Precision@K dan Recall@K untuk $K = 5, 10$, dan 15 (Herlocker, Konstan, Terveen, & Riedl, 2004). Pengujian ini memakai pembagian berdasarkan waktu.

2.6 Implementasi Sistem

Antarmuka sistem dibangun dengan Blade dan Tailwind CSS pada Laravel. Setiap peran pada Gambar 1 memakai akun terpisah dengan pemisahan tugas, sehingga draft hanya dapat diajukan, disetujui, dikirim, dan diterima oleh peran yang berwenang pada tahapnya.


3. HASIL DAN PEMBAHASAN

3.1 Kualitas Ranking Collaborative Filtering

Tabel 3 dan Gambar 3 menyajikan hasil *leave-out testing* pada 21.051 basket uji. Precision@K turun dari 6,85% pada K = 5 menjadi 5,35% pada K = 15, sedangkan Recall@K naik dari 16,97% menjadi 38,63%. Pola ini sesuai dengan *trade-off* yang diharapkan: semakin besar K, daftar rekomendasi memuat lebih banyak item relevan sehingga Recall naik, tetapi proporsi item relevan di dalam daftar menurun sehingga Precision turun (Herlocker et al., 2004).

Tabel 3. Hasil pengujian Precision@K dan Recall@K

K (jumlah rekomendasi)	Precision@K	Recall@K
5	6,85%	16,97%
10	5,49%	27,09%
15	5,35%	38,63%



Gambar 3. Trade-off Precision@K dan Recall@K pada 21.051 basket uji

Per wilayah, Precision@5 berkisar dari 3,6% (Jawa Tengah) hingga 8,3% (Jakarta Barat), dan Recall@15 dari 34,0% (Jakarta Timur) hingga 48,0% (Jawa Timur). Tanpa wilayah yang hanya diuji dengan 33 basket, Precision@5 berkisar dari 6,4% (Jakarta Timur) hingga 8,3% (Jakarta Barat). Wilayah Jawa Tengah hanya diuji dengan 33 basket sehingga hasilnya kurang representatif. Precision@K yang tergolong rendah menunjukkan bahwa CF lebih tepat dipakai sebagai sinyal pelengkap bagi tren toko daripada sebagai prediktor tunggal, yang menjadi dasar rancangan hibrida pada penelitian ini.

3.2 Akurasi Estimasi Kuantitas

Tabel 4 membandingkan galat model hibrida dan pembanding pada segmen uji. Segmen latih mencakup periode 1 Jan 2025–14 Sep 2025 (37 minggu), segmen validasi 15 Sep 2025–9 Nov 2025 (8 minggu), dan segmen uji 10 Nov 2025–31 Des 2025 (8 minggu) dengan 29.659 pengamatan, 1.123 (3,79%) di antaranya *cold-start*. Bobot terbaik yang dipilih dari data validasi adalah $w_2 = 0,2$. Kurva WAPE validasi terhadap w_2 menurun lalu naik, dengan WAPE terendah 41,33% pada $w_2 = 0,2$; bobot awal 0,3 mendekati optimum, dengan selisih WAPE validasi 0,01 poin persentase terhadap bobot terbaik terpilih ($w_2 = 0,2$).



Tabel 4. Perbandingan galat pada data uji

Model	MAE	RMSE	WAPE (%)	N
B1: tren toko saja ($w_2 = 0$)	1,87	4,60	55,36	29.659
B2: <i>moving average</i> ($n = 4$)	1,90	4,67	56,24	29.659
B3: CF saja ($w_2 = 1$)	1,91	4,61	56,53	29.659
Hibrida bobot awal ($w_1 = 0,7$; $w_2 = 0,3$)	1,82	4,42	53,88	29.659
Hibrida bobot terbaik ($w_2 = 0,2$)	1,82	4,46	54,02	29.659

WAPE hibrida terbaik lebih rendah 1,34 poin persentase (2,42% secara relatif) dibanding B1 dan lebih rendah 2,22 poin persentase (3,95%) dibanding B2; selisih MAE masing-masing 0,05 dan 0,07 satuan kuantitas (positif berarti hibrida lebih kecil). Terhadap B1, hibrida terbaik mengungguli secara bermakna (Wilcoxon: $p < 0,001$, $n = 4.020$ pasangan). Terhadap B2, WAPE total hibrida lebih rendah, tetapi uji Wilcoxon per pasangan berpihak pada pembanding (median selisih galat per pasangan tidak positif), sehingga keunggulan bergantung pada pasangan bervolume besar dan tidak dapat dikatakan bermakna (Wilcoxon: $p < 0,001$, $n = 4.020$ pasangan). Pada lapisan *non-cold-start*, WAPE B1 53,98% dan hibrida 53,27%; pada lapisan *cold-start*, WAPE B1 100,00% (B1 mengeluarkan 0 menurut aturan cadangan karena tren tidak terdefinisi) dan hibrida 78,26%.

3.3 Pembahasan dan Keterbatasan

Hasil di atas perlu dibaca dengan beberapa keterbatasan:

- Pengujian ranking memakai satu pembagian waktu dan satu pengacakan item yang disembunyikan. Banyak kandidat berskor sama sehingga hasilnya bergantung pada urutan item; pada lima seed, Precision@5 berkisar 6,84–7,15% dan Recall@15 38,08–39,82%. Matriks kemiripan dibangun hanya dari basket latih (sebelum 1 Nov 2025) dan tidak memuat item yang disembunyikan, yang diambil dari basket uji (mulai 1 Nov 2025).
- Kuantitas yang dievaluasi adalah kuantitas terjual, bukan kuantitas yang dikirim, dan dapat dibatasi stok pada saat itu, sehingga belum tentu kebutuhan sebenarnya. Akurasi diukur pada estimasi E terhadap penjualan, bukan pada rekomendasi R, karena riwayat stok tidak tersedia. Evaluasi bersifat offline pada satu perusahaan dan tidak mengukur dampak operasional seperti penurunan *overstock* dan *understock*.
- Precision@K tergolong rendah dan wilayah Jawa Tengah hanya diuji dengan 33 basket.

4. KESIMPULAN

Penelitian ini mengusulkan model hibrida berbobot yang menggabungkan tren toko berbasis *exponential smoothing* dan sinyal *item-based* CF untuk merekomendasikan kuantitas distribusi, dengan bobot dipilih dari data validasi dan evaluasi berurutan waktu terhadap tiga pembanding. Mesin CF menunjukkan *trade-off* Precision dan Recall yang sesuai teori, dengan Precision@K antara 5,35% dan 6,85% serta Recall@K meningkat dari 16,97% pada $K = 5$ menjadi 38,63% pada $K = 15$ pada 21.051 basket uji dari 10 wilayah, sehingga CF lebih tepat berperan sebagai sinyal pelengkap. Pada data uji, hibrida dengan bobot terbaik $w_2 = 0,2$ mengungguli tren toko saja (B1) dan tidak terbukti mengungguli *moving average* (B2), dengan WAPE 54,02% berbanding 55,36% dan 56,24%. Manfaat CF terbesar tampak pada lapisan *cold-start* (WAPE B1 100,00% menjadi 78,26% pada hibrida), dengan catatan B1 mengeluarkan 0 pada lapisan ini menurut aturan cadangan. Model telah diimplementasikan pada sistem web Laravel dan MySQL. Penelitian lanjutan dapat melakukan uji coba terbatas (*pilot*) di perusahaan dengan mengukur *overstock* dan *understock*, menambahkan faktor musiman dan promosi, serta membandingkan model dengan metode peramalan lain seperti ARIMA atau pembelajaran mesin pada data historis yang lebih panjang.



REFERENCES

- Bi, X., Adomavicius, G., Li, W., & Qu, A. (2022). Improving sales forecasting accuracy: A tensor factorization approach with demand awareness. *INFORMS Journal on Computing*, 34(3), 1644–1660. <https://doi.org/10.1287/ijoc.2021.1147>
- Fildes, R., Ma, S., & Kolassa, S. (2022). Retail forecasting: Research and practice. *International Journal of Forecasting*, 38(4), 1283–1318. <https://doi.org/10.1016/j.ijforecast.2019.06.004>
- Frediansa, D., Mahmudi, A., & Pranoto, Y. A. (2025). Sistem rekomendasi produk berdasarkan kesamaan preferensi antar pembeli dengan menggunakan collaborative filtering berbasis web. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(6), 10587–10595. <https://doi.org/10.36040/jati.v9i6.15413>
- 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. <https://doi.org/10.1145/963770.963772>
- Hewamalage, H., Ackermann, K., & Bergmeir, C. (2023). Forecast evaluation for data scientists: Common pitfalls and best practices. *Data Mining and Knowledge Discovery*, 37(2), 788–832. <https://doi.org/10.1007/s10618-022-00894-5>
- Ji, Y., Sun, A., Zhang, J., & Li, C. (2023). A critical study on data leakage in recommender system offline evaluation. *ACM Transactions on Information Systems*, 41(3), 1–27. <https://doi.org/10.1145/3569930>
- Liang, M., Yang, L., Li, K., & Zhai, H. (2024). Improved collaborative filtering for cross-store demand forecasting. *Computers & Industrial Engineering*, 190, 110067. <https://doi.org/10.1016/j.cie.2024.110067>
- Panteli, A., & Boutsinas, B. (2023). Addressing the cold-start problem in recommender systems based on frequent patterns. *Algorithms*, 16(4), 182. <https://doi.org/10.3390/a16040182>
- Papadakis, H., Papagrigoriou, A., Panagiotakis, C., Kosmas, E., & Fragopoulou, P. (2022). Collaborative filtering recommender systems taxonomy. *Knowledge and Information Systems*, 64(1), 35–74. <https://doi.org/10.1007/s10115-021-01628-7>
- Petropoulos, F., Apiletti, D., Assimakopoulos, V., Babai, M. Z., Barrow, D. K., Ben Taieb, S., Bergmeir, C., Bessa, R. J., Bijak, J., Boylan, J. E., Browell, J., Carnevale, C., Castle, J. L., Cirillo, P., Clements, M. P., Cordeiro, C., Cyrino Oliveira, F. L., De Baets, S., Dokumentov, A., ... Ziel, F. (2022). Forecasting: Theory and practice. *International Journal of Forecasting*, 38(3), 705–871. <https://doi.org/10.1016/j.ijforecast.2021.11.001>
- Roy, D., & Dutta, M. (2022). A systematic review and research perspective on recommender systems. *Journal of Big Data*, 9(1), 59. <https://doi.org/10.1186/s40537-022-00592-5>
- Sarwar, B., Karypis, G., Konstan, J. A., & Riedl, J. (2001). Item-based collaborative filtering recommendation algorithms. In *Proceedings of the 10th International Conference on World Wide Web* (pp. 285–295). ACM. <https://doi.org/10.1145/371920.372071>