

**SISTEM REKOMENDASI PRODUK APLIKASI MARKETPLACE
BERDASARKAN KARAKTERISTIK PEMBELI MENGGUNAKAN METODE
*USER BASED COLLABORATIVE FILTERING***

SKRIPSI

Oleh:
LINGGA WAHYU ROCHIM
NIM. 18650055



**JURUSAN TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2022**

**SISTEM REKOMENDASI PRODUK APLIKASI *MARKETPLACE*
BERDASARKAN KARAKTERISTIK PEMBELI MENGGUNAKAN
METODE *USER BASED COLLABORATIVE FILTERING***

SKRIPSI

**Oleh:
LINGGA WAHYU ROCHIM
NIM. 18650055**

**Diajukan kepada:
Fakultas Sains dan Teknologi Universitas Islam Negeri (UIN) Malang
untuk Memenuhi Salah Satu Persyaratan Dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)**

**JURUSAN TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2022**

LEMBAR PERSETUJUAN

**SISTEM REKOMENDASI PRODUK APLIKASI *MARKETPLACE*
BERDASARKAN KARAKTERISTIK PEMBELI MENGGUNAKAN
METODE *USER BASED COLLABORATIVE FILTERING***

SKRIPSI

Oleh:
LINGGA WAHYU ROCHIM
NIM. 18650055

Telah Diperiksa dan Disetujui untuk Diuji
Tanggal: 6 Juni 2021

Dosen Pembimbing I



Fajar Rohman Hariri, M. Kom
NIP. 19890515 201801 1 001

Dosen Pembimbing II



Prof. Dr. Suhartono
NIP. 19680519 200312 1 001

Mengetahui,
Ketua Jurusan Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Dr. Fachrul Kurniawan, M.MT
NIP. 19771020 200912 1 001

LEMBAR PENGESAHAN

SISTEM REKOMENDASI PRODUK APLIKASI *MARKETPLACE* BERDASARKAN KARAKTERISTIK PEMBELI MENGGUNAKAN METODE *USER BASED COLLABORATIVE FILTERING*

SKRIPSI

Oleh:
LINGGA WAHYU ROCHIM
NIM. 18650055

Telah Dipertahankan di Depan Dewan Penguji
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Pada Tanggal: 15 Juni 2022

Susunan Dewan Penguji

Penguji Utama : Dr. Yunifa Miftachul Arif, M.T
NIP. 19830616 201101 1 004

Ketua Penguji : Dr. Muhammad Faisal, M.T
NIP. 19740510 200501 1 007


Sekretaris Penguji : Fajar Rohman Hariri, M.Kom
NIP. 19890515 201801 1 001

Anggota Penguji : Prof. Dr. Suhartono
NIP. 19680519 200312 1 001

()
()
()
()

Mengetahui,
Ketua Jurusan Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang




Dr. Fachrul Kurniawan, M.MT
NIP. 19771020 200912 1 001

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Lingga Wahyu Rochim
NIM : 18650055
Fakultas / Jurusan : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : Sistem Rekomendasi Produk Aplikasi *Marketplace*
Berdasarkan Karakteristik Pembeli Menggunakan
Metode *User Based Collaborative Filtering*

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 15 Juni 2022

Yang membuat pernyataan,



Lingga Wahyu Rochim

NIM. 18650055

HALAMAN MOTTO

“خير الناس أحسنهم خلقا وأنفعهم للناس”

HALAMAN PERSEMBAHAN

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ الْحَمْدُ لِلَّهِ رَبِّ الْعَالَمِينَ

Puja dan puji syukur atas kehadiran Allah *subhanahu wa ta'ala*, serta shalawat dan salam bagi Rasul-Nya

Penulis mempersembahkan hasil karya ini kepada:

Orang tua penulis yang sangat dicintai dan disayangi, Bapak Suparno dan Ibu Indah Tri Nuryanti, yang tak pernah berhenti memberikan dukungan, do'a, semangat serta kasih sayang yang begitu besar kepada penulis.

Para dosen pembimbing penulis, Bapak Fajar Rohman Hariri, M.Kom dan Bapak Prof. Dr. Suhartono yang senantiasa dengan ketelatenan dan penuh rasa kesabaran dalam memberikan saran, arahan, dan masukan dalam penyusunan karya ini.

Seluruh dosen dan jajaran *civitas akademica* jurusan Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang yang telah memberi ilmu dan memberi kelancaran dalam penyusunan karya ini, tak lupa seluruh guru-guru dan ustadz-ustadz penulis yang telah memberikan banyak ilmu dan pengalaman yang sangat berharga kepada penulis.

Seluruh pihak-pihak yang tak dapat penulis sebutkan satu per satu yang telah selalu memberikan dukungan, do'a, semangat serta bantuan sampai terselesainya karya ini.

KATA PENGANTAR

Assalamu'alaikum warahmatullahi wabarakatuh.

Alhamdulillah rabbil 'aalamiin segala puja puji dan syukur senantiasa penulis panjatkan kehadirat Allah *subhanahu wa ta'ala* yang telah selalu melimpahkan rahmat, taufiq, serta hidayah-Nya, sehingga penulis dapat menyempurnakan skripsi ini dengan tepat waktu, lancer, dan tanpa halangan yang berarti. Sholawat serta salam semoga senantiasa tetap tercurah limpahkan kepada junjungan kita Nabi Muhammad *shalallaahu alaihi wassalaam* yang senantiasa kita nanti-nanti syafaatnya *min yaumil hadza ila yaumil qiyamah*. Aamiin.

Kedua, penulis mengucapkan rasa terima kasih yang begitu besar kepada seluruh pihak-pihak yang telah men-*support* dan membantu rampungnya skripsi ini. Ucapan terima kasih ini penulis disampaikan kepada:

1. Kedua orang tua tercinta yang selalu menjadi semangat utama bagi penulis dalam menyelesaikan penulisan skripsi ini serta telah selalu memberikan dukungan, do'a, semangat serta kasih sayang yang begitu besar kepada penulis.
2. Bapak Dr. Fachrul Kurniawan, M.MT, sebagai Ketua Jurusan Teknik Informatika.
3. Bapak Fajar Rohman Hariri, M.Kom serta Bapak Bapak Prof. Dr. Suhartono selaku dosen Ppmbimbing I dan II yang telah mengorbankan waktunya guna memberikan masukan, arahan, saran dan bimbingannya kepada penulis mulai dari awal penyusunan hingga terselesaikannya skripsi ini.
4. Bapak Dr. Yunifa Miftachul Arif, M.T dan Bapak Dr. Muhammad Faisal, M.T selaku dosen penguji I dan II yang telah memberikan masukan, kritik serta saran kepada penulis mulai dari ujian seminar proposal, ujian seminar hasil, hingga ujian skripsi dengan penuh kesabaran.
5. Seluruh dosen dan jajaran civitas akademika Jurusan Teknik Informatika yang memberikan ilmu yang sangat bermanfaat yang secara tidak langsung ikut terlibat dalam penyusunan skripsi ini.

6. Kawan-kawan Unity of Informatics Force (UFO) Angkatan 2018, khususnya Muhamad Syifa', Ikhwata Andy Pratama, Muhammad Meganata Adam, Abd. Qohar Agus Maulana, Rizki Fitriani, Anisa Rizkiana Putri, Naila Nahdiyah, Inna Fatimatuzzahro, dan Aulia Ananda Salsabila yang senantiasa selalu memberikan semangat dan dukungan dalam berjuang secara bersama-sama menyelesaikan tugas demi tugas dan ujian demi ujian mulai dari hari pertama perkuliahan sampai terselesaikannya pengerjaan skripsi ini dengan tepat waktu.
7. Bapak Steve Stanley selaku pimpinan perusahaan Sindo Lah Pte Ltd Singapore yang selalu memberikan dukungan dan fasilitas kepada penulis sehingga memberikan kesempatan untuk dapat lulus tepat waktu.
8. Seluruh teman-teman pada divisi *programmer* di perusahaan Sindo Lah Pte Ltd Singapore yang juga senantiasa memberikan semangat dan bantuan kepada penulis sehingga skripsi ini dapat selesai dengan lancar.
9. Seluruh pihak-pihak yang tak dapat penulis sebutkan satu per satu yang telah selalu memberikan dukungan, do'a, semangat serta bantuan sampai terselesainya karya ini.

Tidak ada yang sempurna di dunia ini begitu pula hasil karya dari penulis yang masih sangat perlu untuk diberi kritik, saran, dan masukan yang bersifat membangun sehingga dapat menjadi lebih baik lagi kedepannya. Besar harapan penulis, hasil karya penulis ini dapat memberi manfaat bagi yang membaca maupun bagi penulis pribadi.

Wassalamu'alaikum warahmatullahi wabarakatuh.

Malang, 15 Juni 2022

Penulis

DAFTAR ISI

HALAMAN JUDUL	ii
LEMBAR PERSETUJUAN	iii
LEMBAR PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
HALAMAN MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR	viii
DAFTAR ISI	x
DAFTAR GAMBAR	xii
DAFTAR TABEL	xiii
ABSTRAK	xiv
ABSTRACT	xv
الملخص	xvi
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Pernyataan Masalah.....	4
1.3 Tujuan Penelitian.....	5
1.4 Batasan Masalah.....	5
1.5 Manfaat Penelitian.....	5
BAB II STUDI PUSTAKA	6
2.1 Penelitian Terkait	6
2.2 <i>Marketplace</i>	11
2.3 Karakteristik Pembeli	13
2.4 Sistem Rekomendasi	14
2.5 <i>Collaborative Filtering</i>	17
2.5.1 <i>Item Based Collaborative Filtering</i>	18
2.5.2 <i>User Based Collaborative Filtering</i>	19
2.5.3 <i>Improved triangle similarity complemented with user rating preferences</i> (ITR)	20
2.5.4 <i>Weighted Sum</i>	21
2.6 Evaluasi Sistem Rekomendasi	22
BAB III METODOLOGI PENELITIAN	24
3.1 Tahapan Penelitian	24
3.2 Desain Sistem	27

3.3	<i>User Based Collaborative Filtering</i>	28
3.3.1	<i>Data Rating</i>	29
3.3.2	Perhitungan <i>Similarity</i>	29
3.3.3	Perhitungan Prediksi	33
3.3.4	Hasil Rekomendasi	34
3.4	Pengumpulan Data	35
3.5	Rencana Pengujian	37
BAB IV	UJI COBA DAN PEMBAHASAN	40
4.1	Implementasi Program	40
4.1.1	Implementasi <i>Similarity</i> ITR.....	40
4.1.2	Implementasi <i>Weighted Sum</i>	42
4.1.3	RESTful API.....	44
4.2	Implementasi <i>User Interface</i>	46
4.2.1	Implementasi Halaman <i>Login</i>	46
4.2.2	Implementasi Halaman Rekomendasi Produk	47
4.3	Skenario Uji Coba	47
4.1.4	Tahap Pelatihan.....	49
4.1.1.1	Pengambilan <i>Data Rating User</i>	49
4.1.1.2	Perhitungan <i>Similarity</i>	50
4.1.1.3	Perhitungan Nilai Prediksi.....	51
4.4	Hasil Uji Coba.....	52
4.5	Pembahasan	61
4.6	Integrasi Islam	63
BAB V	KESIMPULAN DAN SARAN	66
5.1	Kesimpulan.....	66
5.2	Saran.....	67
DAFTAR PUSTAKA		

DAFTAR GAMBAR

Gambar 3. 1 Tahapan penelitian	25
Gambar 3. 2 Desain sistem	28
Gambar 4. 1 Dokumentasi API “ <i>Get Predicted Value By UserID</i> ”	44
Gambar 4. 2 Dokumentasi API “ <i>Get Product Recommendation By UserID</i> ”	44
Gambar 4. 3 Contoh respon API “ <i>Get Predicted Value By UserID</i> ”	45
Gambar 4. 4 Contoh respon API “ <i>Get Product Recommendation By UserID</i> ” ...	46
Gambar 4. 5 Tampilan halaman <i>login</i>	46
Gambar 4. 6 Tampilan halaman rekomendasi produk	47
Gambar 4. 7 Grafik hasil pengukuran MAE pada tiap model.....	53
Gambar 4. 8 Grafik hasil pengukuran RMSE pada tiap model.....	53
Gambar 4. 9 Pengukuran MAE pada tiap model pelatihan.....	54
Gambar 4. 10 Pengukuran RMSE pada tiap model pelatihan.....	54
Gambar 4. 11 Sampel hasil perbandingan hasil prediksi produk dengan data <i>groundtruth</i> pada <i>user</i> dengan ID 6624	55

DAFTAR TABEL

Tabel 3. 1 Contoh tabel skenario <i>rating</i>	29
Tabel 3. 2 Contoh hasil perhitungan <i>similarity</i> antar <i>user</i>	31
Tabel 3. 3 Contoh hasil perhitungan nilai prediksi <i>user</i>	34
Tabel 3. 4 Data sampel <i>rating</i> pembeli	36
Tabel 3. 5 Data sampel output produk	36
Tabel 4. 1 Data sampel <i>groundtruth</i>	48
Tabel 4. 2 Contoh sampel dari pengambilan data <i>rating user</i>	49
Tabel 4. 3 Contoh sampel hasil perhitungan <i>similarity</i>	50
Tabel 4. 4 Skenario perubahan parameter persentase <i>user</i>	52
Tabel 4. 5 Hasil model yang digunakan pada tahap uji coba.....	55
Tabel 4. 6 Sampel hasil perhitungan nilai prediksi pada <i>user</i> dengan ID 6624....	56
Tabel 4.7 Hasil perhitungan nilai MAE dan RMSE pada data uji	57
Tabel 4. 8 Hasil perhitungan nilai rata-rata MAE dan RMSE pada data uji.....	57
Tabel 4. 9 Sampel hasil analisis output rekomendasi produk pada <i>user</i> dengan ID 6624.....	58
Tabel 4. 10 Hasil perhitungan nilai akurasi, presisi, <i>recall</i> , dan F-score (F1) pada data uji.....	60
Tabel 4. 11 Hasil perhitungan nilai rata-rata akurasi, presisi, <i>recall</i> dan F-score (F1) pada data uji	61

ABSTRAK

Rochim, Lingga Wahyu. 2022. **Sistem Rekomendasi Produk Aplikasi Marketplace Berdasarkan Karakteristik Pembeli Menggunakan Metode User Based Collaborative Filtering**. Skripsi. Jurusan Teknik Informatika, Fakultas Sains dan Teknologi. Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Fajar Rohman Hariri, M.Kom, (II) Prof. Dr. Suhartono

Kata Kunci: *User Based Collaborative Filtering, Sistem Rekomendasi Produk, Marketplace, Karakteristik Pembeli*

Sistem rekomendasi produk merupakan sebuah sistem yang dapat memberikan prediksi produk yang relevan terhadap perilaku atau karakteristik *user*, sehingga dapat mempengaruhi *user* dalam mengambil keputusan untuk membeli suatu produk. Penelitian ini dilakukan untuk dapat memberikan rekomendasi kepada pembeli pada aplikasi *marketplace* Sindomall dengan menggunakan metode *User Based Collaborative Filtering* dikolaborasi dengan algoritma *Improved triangle similarity complemented with user rating preferences* (ITR) untuk menghitung nilai *similarity* antar pembeli dan algoritma *Weighted Sum* untuk menghitung nilai prediksi produk. Karakteristik pembeli diambil dari data perilaku pembeli dalam memberikan *rating* pada produk. Dalam pengujian model yang dilakukan dengan menggunakan data nilai prediksi pada 20 *user* acak pada *database* aplikasi Sindomall pada bulan Desember 2021 didapatkan model optimal dengan nilai parameter presentase *user* sebesar 100%. Hasil dari pengujian *error* sistem menggunakan model terpilih mendapatkan nilai MAE dan RMSE masing-masing sebesar 0.006 dan 0.013, sedangkan pada tahap pengujian akurasi sistem didapatkan nilai akurasi sebesar 0.849, nilai presisi sebesar 0.923, nilai *recall* sebesar 0.869, dan nilai *F-score* (F1) sebesar 0.895.

ABSTRACT

Rochim, Lingga Wahyu. 2022. **Marketplace Application Product Recommendation System Based on Buyer Characteristics Using User Based Collaborative Filtering Method.** Undergraduate Thesis. Department of Informatics Engineering, Faculty of Science and Technology. Maulana Malik Ibrahim State Islamic University Malang. Supervisor: (I) Fajar Rohman Hariri, M.Kom, (II) Prof. Dr. Suhartono

Keywords: User Based Collaborative Filtering, Product Recommendation System, Marketplace, Buyer Characteristics

The product recommendation system is a system that can provide product predictions that are relevant to the behavior or characteristics of the user, so that it can influence the user in making decisions to buy a product. This research was conducted to be able to provide recommendations to buyers on the Sindomall marketplace application using the User Based Collaborative Filtering method in collaboration with the Improved triangle similarity complemented with user rating preferences (ITR) algorithm to calculate the similarity value between buyers and the Weighted Sum algorithm to calculate the predictive value of the product. Buyer characteristics are taken from buyer behavior data in rating the product. In model testing conducted using predictive value data on 20 random users on the Sindomall application database in December 2021, the optimal model was obtained with a user percentage parameter value of 100%. The results of the system error testing using the selected model get the MAE and RMSE values of 0.006 and 0.013 respectively, while at the system accuracy testing stage the accuracy value is 0.849, the precision value is 0.923, the recall value is 0.869, and the F-score (F1) value is 0.895.

الملخص

رحيم، لينغا وحيو. 2022. نظام توصية المنتجات، تطبيق متجر الكتروني مبني على أساس سلوك المشتري بطريقة *User Based Collaborative Filtering*. بحث جامعي. قسم تقنية المعلومات، كلية العلوم والتكنولوجيا، جامعة الإسلامية الحكومية مولانا مالك إبراهيم مالانغ. المشرفين: (I) فجر رحمن حريري الماجستير، (II) البروفيسور الدكتور سوهارتونو.

الكلمات الرئيسية: *User Based Collaborative Filtering*، نظام توصية المنتجات، متجر، سلوك المشتري.

نظام توصية المنتجات هو نظام يمكنه توفير تنبؤات منتجات ذات الصلة بسلوك المشتري، بحيث يمكن أن يؤثر على المشتري في اتخاذ قرارات شراء منتج. تم إجراء هذا البحث ليكون قادرًا على تقديم توصيات للمشتريين على تطبيق متجر Sindomall باستخدام طريقة *User Based Collaborative Filtering* بالتعاون مع خوارزمية *Improved triangle similar* *complemented with user rating preferences* (ITR) لحساب تقييم التشابه بين المشتريين وخوارزمية *Weighted Sum* لحساب تقييم التنبؤ للمنتج. يتم أخذ سلوك المشتري من بيانات سجل المشتري في تقييم المنتج. وفي اختبار النموذج الذي تم إجراؤه باستخدام بيانات تقييم التنبؤ على 20 مستخدمًا عشوائيًا من قاعدة بيانات تطبيق Sindomall بتاريخ ديسمبر 2021، تم الحصول على النموذج الأمثل بنسبة 100٪. وحاصل نتائج تقارير الأخطاء النظام باستخدام النموذج المحدد على قيمتي MAE و RMSE بمعدل 0.006 و 0.013 على التوالي. بينما في مرحلة اختبار دقة النظام، تبلغ قيمة الدقة 0.849، وقيمة الضبط 0.923، وقيمة الاسترجاع 0.869، وقيمة درجة (F1) *F-score* هي 0.895.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Dikarenakannya perkembangan era digital yang semakin modern telah mengakibatkan perubahan perilaku konsumen yang sebelumnya melakukan transaksi melalui toko secara langsung beralih melalui *online shop* atau *e-commerce*. Tidak hanya berupa *traditional e-commerce* melainkan juga mulai bermunculan banyak konsep *e-commerce* yang mulai bermunculan salah satu contohnya adalah *online marketplace*. Perubahan tersebut mampu merubah pemikiran konsumen dalam menentukan keputusan untuk membeli sebuah produk. Keputusan pembeli dalam membeli sebuah produk diakibatkan oleh banyak faktor seperti harga, kualitas produk, promosi bahkan perusahaan tempat mereka membeli sebuah produk (Kotler & Keller, 2012).

Sebagai contoh negara Indonesia memiliki usaha penjualan barang maupun jasa yang menggunakan internet pada tahun 2020 sebesar 90,18 persen, dan 48,42 persen-nya merupakan usaha di sektor perdagangan barang atau *marketplace* (BPS, 2020). Mudahnya berjualan di *online shop* dan antusias pelanggan yang tinggi menjadi salah satu alasan para pedagang beralih ke penjualan secara *online*. Hal itulah yang membuat pertumbuhan *marketplace* di Indonesia adalah yang tertinggi jika disandingkan dengan bangsa lain. Pernyataan tersebut dipengaruhi oleh peran pemerintah yang senantiasa mendukung perkembangan dan pembangunan *marketplace* secara terus-menerus.

Allah *subhanahu wa ta'ala* telah berfirman dalam surah Hud ayat 120:

وَكُلًّا نَقُصُّ عَلَيْكَ مِنْ أَنْبَاءِ الرُّسُلِ مَا نُثَبِّتُ بِهِ فُؤَادَكَ ۖ وَجَاءَكَ فِي هَذِهِ الْحَقُّ وَمَوْعِظَةٌ وَذِكْرَىٰ لِلْمُؤْمِنِينَ

“Semua kisah rasul-rasul Kami ceritakan kepadamu (Nabi Muhammad), yaitu kisah-kisah yang dengannya Kami teguhkan hatimu. Di dalamnya telah di berikan kepadamu (segala) kebenaran, nasihat, dan peringatan bagi orang-orang mukmin.” (Q.S. Hud: 120) (Balitbang Diklat Kementerian Agama RI, 2019).

Pada ayat diatas dapat di jelaskan bahwa dalam hal memberikan sebuah informasi atau berita harus mengandung isi kebenaran didalamnya. Dalam Islam sesungguhnya telah menentukan kaidah-kaidah dalam menyampaikan informasi, seperti bentuk macam informasi yang disampaikan dapat memberikan manfaat dan mengandung teladan yang baik bagi penerima informasi serta tidak mengandung unsur keburukan didalamnya (Kahfi, 2005).

Salah satu hal yang mendukung *marketplace* mengalami pertumbuhan yang pesat adalah fitur-fitur yang disediakan oleh perusahaan sangat inovatif dan dapat menarik minat pelanggan untuk terus membeli produk pada *marketplace* tersebut, baik fitur diskon, *voucher*, *games*, maupun fitur rekomendasi tampilan produk yang disediakan. Diantara banyak fitur yang disediakan *marketplace*, fitur sistem rekomendasi menjadi salah satu fitur yang sangat berpengaruh terhadap pembeli dalam mengambil keputusan untuk membeli suatu produk (Huang *et al.*, 2009). Sistem rekomendasi adalah rekomendasi produk yang digunakan untuk mencocokkan pembeli dengan barang-barang yang relevan dengan minat, kebutuhan serta karakteristik pelanggan (Eide & Zhou, 2018).

Konsep sistem rekomendasi sebenarnya telah diterapkan pada beberapa aplikasi *marketplace* yang sudah ada seperti Amazon, eBay, Tokopedia, Bukalapak, dan lainnya sebagai alat bisnis. Hasilnya beberapa *marketplace* tersebut mengalami peningkatan dalam hal penjualan produk dan membangun loyalitas pembeli (Prasetya, 2017). Sistem rekomendasi diperlukan untuk mempengaruhi *user* dalam membuat keputusan hingga keinginan dalam membeli sebuah produk. Oleh sebab itu perlu mengetahui hal-hal yang mampu mempengaruhi *user* salah satu contohnya yaitu karakteristik *user* dalam memberikan penilaian terhadap suatu produk dalam *marketplace*. Berdasarkan inovasi tersebut, hal menarik untuk dilakukan penelitian yaitu tentang fitur sistem rekomendasi yang dapat menampilkan produk sesuai dengan perilaku pelanggan dalam mengeksplorasi produk.

Terdapat tiga jenis metode dalam sistem rekemendasi produk seperti *Collaborative Filtering*, *Content Based Filtering*, dan *Hybrid* (Badriyah *et al.*, 2017). *Collaborative Filtering* sendiri merupakan sistem rekomendasi yang digunakan untuk penentuan selera *user* berdasarkan kumpulan dari minat, pendapat, serta karakteristik dari *user* yang bisa didapatkan berupa pemberian *rating* yang diberikan oleh *user* dalam suatu produk (Wijaya & Alfian, 2018). Terdapat dua metode pada *Collaborative Filtering* yakni *Item Based* dan *User Based*. *User Based Collaborative Filtering* sendiri merupakan metode yang dihasilkan dari kesamaan karakteristik dan minat antar *user*. Dimana tiap-tiap *user*-nya merupakan bagian dari sekelompok *user* yang mempunyai kecocokan dengan *user* yang lain. Salah satu hal yang

terpenting dari metode ini adalah rekomendasi produk yang dihasilkan akan diperoleh berdasarkan produk yang dinilai oleh *user*. Produk yang direkomendasikan adalah hasil dari produk yang dinilai oleh *user* lainnya ataupun *user* yang memiliki kesamaan produk dinilai.

Penerapan metode *User Based Collaborative Filtering* akan diimplementasikan untuk penentuan rekomendasi produk dalam *marketplace* yang sesuai dengan perilaku pelanggan dalam memberikan penilaian terhadap sebuah produk. Terdapat masalah ketika sistem rekomendasi produk tanpa menerapkan metode yang dapat menyesuaikan dengan karakteristik pembeli, karena hal tersebut tidak akan mempengaruhi pembeli dalam membuat keputusan hingga keinginan dalam membeli sebuah produk.

Berdasarkan masalah-masalah tersebut, penulis menggunakan objek berupa fitur sistem rekomendasi dalam sebuah aplikasi *marketplace* berbasis aplikasi *mobile* sebagai objek untuk penerapan metode *User Based Collaborative Filtering*.

1.2 Pernyataan Masalah

Berdasarkan latar belakang yang telah dipaparkan sebelumnya, pernyataan masalah dari penelitian ini adalah bagaimana mendapatkan rekomendasi produk menggunakan metode *User Based Collaborative Filtering* pada aplikasi *marketplace* berdasarkan karakteristik pembeli dengan nilai akurasi dan *error* yang terukur?

1.3 Tujuan Penelitian

Mendapatkan rekomendasi produk menggunakan metode *User Based Collaborative Filtering* pada aplikasi *marketplace* berdasarkan karakteristik pembeli dengan nilai akurasi dan *error* yang terukur.

1.4 Batasan Masalah

Terdapat beberapa batasan masalah dalam penelitian ini, antara lain adalah:

1. Studi kasus yang digunakan dalam penelitian ini merupakan *marketplace* Sindomall di perusahaan Sindo Lah Pte. Ltd
2. Data yang digunakan berupa data produk dan data *rating* user terhadap suatu produk pada bulan Desember 2021
3. Hasil rekomendasi produk berupa produk yang berstatus belum terjual
4. Hasil rekomendasi produk hanya untuk *user* lama yang telah memberikan *rating* terhadap produk

1.5 Manfaat Penelitian

1. Bagi pengusaha, hasil penelitian diharapkan mampu meningkatkan hasil penjualan produk dan juga dapat meningkatkan loyalitas pembeli.
2. Bagi pembeli, membantu menemukan produk yang berkaitan dengan karakteristik pembeli, sehingga mampu mempengaruhi keputusan pembeli untuk membeli suatu produk.

BAB II

STUDI PUSTAKA

2.1 Penelitian Terkait

Pada tahun 2020, Janan melakukan penelitian untuk mengimplementasikan algoritma *User Based Collaborative Filtering* yang dikolaborasikan melalui algoritma *Cosine Based Similarity* untuk membangun sistem rekomendasi terhadap 6 destinasi wisata terkenal di Kota Batu dalam bentuk aplikasi *game*. Input yang digunakan berupa nilai *rating user* terhasapp masing-masing destinasi wisata dengan kisaran nilai mulai dari 1 sampai 5. Pada pengujian aplikasi berupa kuesioner terhadap total 50 responden untuk menghitung nilai MAE, RMSE, *Precision*, *Recall*, serta *F-measure* di dapatkan masing-masing nilai sebesar 3.25, 3.5, 0.8, 1, dan 0.889 (Janan, 2020).

Penelitian yang dilakukan oleh Fakhri *et al.*, pada tahun 2019 dengan mengimplementasikan metode *User Based Collaborative Filtering* menggunakan 2 aspek penilaian berupa *rating* dan atribut *user* untuk menghitung nilai *similarity* antar *user* untuk sistem rekomendasi restoran di Bandung Raya. *Weighted Coefficient* merupakan algoritma yang digunakan untuk melakukan perhitungan nilai *similarity* berdasarkan 2 aspek penilaian. Metode *K-Nearest Neighbor* digunakan untuk perhitungan nilai prediksi dengan mengambil sejumlah pengguna dengan kemiripan tertinggi sampai yang terendah. Pengujian performa sistem dilakukan dengan menghitung nilai MAE dengan hasil yang didapat sebesar 2.5 (Fakhri *et al.*, 2019).

Pada penelitian serupa yang dilakukan oleh Liu *et al.*, pada tahun 2018, dengan pendekatan metode *User Based Collaborative Filtering* yang digunakan untuk membangun sistem yang memberikan penggunanya rekomendasi pakaian. Perhitungan nilai *similarity* dilakukan dengan menggunakan *Improvement of Similarity Calculation* yang didalamnya terdapat 2 metode perhitungan yakni *Cosine-Based Similarity* untuk mempertimbangkan frekuensi pembelian oleh pengguna yang berbeda dan *Inverse Item Frequency Similarity* untuk membandingkan *popular* dan *unpopular item*. Hasil rekomendasi pakaian didapatkan berdasarkan hasil perhitungan nilai prediksi dengan algoritma *K-Nearest Neighbor*. Akhir dari uji coba sistem yang dilakukan, diperoleh nilai presisi sebesar 22.87% dan nilai *recall* sebesar 27.71% (Liu *et al.*, 2018).

Pada tahun 2015, Jia *et al.* melakukan penelitian terkait pengembangan aplikasi sistem rekomendasi tempat wisata berbasis aplikasi *mobile* dengan tujuan supaya wisatawan dapat mencari destinasi wisatanya dengan mengimplementasikan metode *User Based Collaborative Filtering*. Hasil perhitungan nilai *similarity* dengan menggunakan persamaan *Cosine-Based Similarity* diimplementasikan untuk menghitung nilai prediksi tempat wisata dengan menggunakan metode *K-Nearest Neighbor*. Hasil rekomendasi diperoleh dengan melakukan perankingan nilai prediksi serta mengambil sebanyak 4 tempat wisata yang direkomendasikan, dari hasil rekomendasi tersebut dilakukan kuesioner dari pengguna aplikasi dan kesimpulan *feedback*

dari turis bahwa sistem sebagian besar memberikan rekomendasi serupa dengan yang para turis inginkan (Jia *et al.*, 2015).

Pada analisis yang dilakukan oleh Theodorus dan Budiyanto Setyohadi pada tahun 2016, mereka menerapkan sistem pendukung keputusan dengan mengimplementasikan metode *User Based Collaborative Filtering* pada pemilihan sebuah film. Metodologi yang digunakan untuk membangun sebuah sistem rekomendasi yaitu dengan menggunakan persamaan *Pearson-Correlation Coefficient* agar mendapatkan nilai relasi kedekatan antar *user* serta mengimplementasikan metode *K-Nearest Neighbor* untuk mendapatkan nilai bobot prediksi. Hasil dari beberapa uji coba dari penelitian tersebut dengan menggunakan data sebesar 70 ribu pengguna yang telah memberikan *rating* pada 10 ribu macam film dengan skala nilai *rating* sebesar 1 sampai 5 mendapatkan besaran nilai minimum MAE 0.7, besaran nilai *precision* 0.5882, dan besaran nilai *recall* 0.1067 (Theodorus & Budiyanto Setyohadi, 2016).

Pada tahun 2021, Pangesti *et al.* melakukan penerapan sistem rekomendasi pada aplikasi *e-commerce business – to – business* (B2B) sesuai dengan deskripsi dan penilaian aplikasi oleh setiap *user* dengan memadukan metode *Content Based Filtering* dengan *Collaborative Filtering*. Bahan penilaian yang digunakan berupa penilaian *user* terhadap 4 aplikasi pilihan dari jumlah total 6 aplikasi *e-commerce* yang disajikan peneliti dengan interval nilai 1 sampai 4 dengan 2 kriteria penilaian, yaitu berupa *behaviour marketplace* dan *rating marketplace*. Perhitungan tersebut juga digunakan

untuk mengetahui aplikasi *e-commerce* mana yang banyak dimintai oleh para *user*. Hasil akhir dari penelitian diperoleh Tokopedia dan Shopee menjadi aplikasi dengan nilai prediksi tertinggi dibandingkan dengan Bukalapak, Blibli, Lazada dan JD.ID (Pangesti *et al.*, 2021).

Riset yang telah dilaksanakan oleh Faizin dan Surjandari pada tahun 2020, mereka menentukan rekomendasi produk pada *marketplace* berdasarkan preferensi dan produk yang diminati dari pelanggan. Penelitian dikembangkan dengan menggunakan algoritma *Neural Collaborative Filtering* (NCF). Dalam penerapan algoritma NCF peneliti menggabungkan *Matrix Factorization* dan *Multi-Layer Perceptron* yang mengkolaborasikan non-linearitas *Multi-Layer Perceptron* dan linearitas *Matrix Factorization* dan untuk memodelkan interaksi pengguna dan produk. Metode NCF diuji coba dengan 11.918 data transaksi pada salah satu *marketplave* di Indonesia pada tahun 2019 memperoleh nilai presisi sebesar 90% (Faizin & Surjandari, 2020).

Pada penelitian yang dilakukan oleh Bobadilla *et al.*, pada tahun 2020, mereka mengimplementasikan algoritma *Reliability-based Neural Collaborative Filtering* (RNCF), arsitektur RNCF yang diusulkan untuk mendapatkan hasil rekomendasi yang ditingkatkan dengan melakukan tiga proses pembelajaran berbeda yang menghasilkan tiga level abstraksi berbeda di seluruh sistem, 3 level yang dimaksud yaitu *Matrix Factorization* (MF) pada level 1, prediksi error dengan *Multilayer Neural Networks* (MNN) pada level 2, dan prediksi rating dengan MNN pada level 3. Hasil dari uji coba

pengimplementasian algoritma RNCF pada data aplikasi Netflix dengan jumlah 4.553.208 data *rating* pada 7.000 item oleh 10.000 *user* mendapatkan nilai MAE sebesar 47% (Bobadilla *et al.*, 2020).

Pada tahun 2020, Berat Ujkani *et al.* melakukan penelitian dengan menerapkan sistem rekomendasi dengan mengimplementasikan algoritma *Item Based Collaborative Filtering* untuk pemilihan tema didalam fitur WordPress. Metode tersebut digunakan untuk membuat sebuah sistem rekomendasi yaitu dengan mengimplementasikan algoritma *Similarity Weight* guna mendapatkan nilai *similarity* antar tema serta menggunakan metode *Weighted Sum* untuk mendapatkan nilai bobot prediksi. Hasil dari beberapa uji coba dari penelitian tersebut mendapatkan nilai MAE sebesar 0.945-0.975 dengan jumlah 10-50 item (Berat Ujkani *et al.*, 2020).

Pada tahun 2018, Mardhia dan Normawati menentukan rekomendasi *marketplace* di Indonesia bagi para pelaku usaha dengan mengimplementasikan algoritma *Fuzzy Simple Additive Weighting*. Studi kasus dilakukan pada beberapa toko online paling populer, seperti Tokopedia, Shopee dan Bukalapak. Dimana responden melakukan transaksi online paling banyak. Kriteria yang dicantumkan adalah harga produk, lokasi penjual, reputasi penjual, jumlah produk yang terjual dan dukungan ekspedisi. Hasil akhir dari penelitian ini mendapatkan nilai akurasi sebesar 75% diperoleh dari hasil perbandingan data rekomendasi hasil dari sistem dibandingkan pada data hasil penilaian yang dilakukan responden yang dibagi menjadi data

training untuk mencari bobot yang paling optimal dan pengujian data dalam rasio 4:1 (Mardhia & Normawati, 2018).

Berbeda dengan beberapa penelitian sebelumnya, pada penelitian ini menggunakan metode *User Based Collaborative Filtering* untuk menyelesaikan masalah penentuan sistem rekomendasi produk berdasarkan keterkaitan karakteristik antar pembeli dalam hal pemberian *rating* pada suatu produk tertentu. Pengukuran nilai *similarity* antar *user* akan dilakukan dengan menggunakan persamaan *Improved triangle similarity complemented with user rating preferences* (ITR) sedangkan untuk perhitungan nilai prediksi untuk setiap produk akan dilakukan dengan menggunakan persamaan *Weighted Sum*, sedangkan skenario pengujian dilakuakn dengan menghitung nilai *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), Akurasi, Presisi, *Recall* dan *F-Score* (F_1).

2.2 Marketplace

Internet pada masa saat ini sudah banyak dijadikan sebagai sistem perdagangan. Dengan kemajuan sistem perdagangan pada internet yang terus berkembang menjadikan perdagangan elektronik konvensional (*e – commerce*) semakin marak. Seiring berkembangnya *e – commerce* tersebut menciptakan berbagai jenis segi bisnis model seperti *business-to-business* (B2B), *business-to-customer* (B2C), *customer-to-customer* (C2C), atau mungkin *business-to-business-to-customer* (B2B2C). Dengan banyaknya model bisnis yang dapat dipilih oleh pelaku usaha ini, mengakibatkan penjualan yang besar akan dapat diperoleh melalui teknologi yang terintegrasi

sebagai *marketplace* ini. Peran *marketplace* dari pedagang ke konsumen sangat penting karena konsumen akan sangat setia jika mediator dapat memegang prinsip kerja dan menjaga kualitasnya (Purnawati & Setyohadi, 2017). Sehingga dengan memanfaatkan *marketplace* ini, pembeli dapat menemukan jenis barang yang sedang mereka cari dan menemukan penjual yang menjual dengan kriteria tersebut dengan perbandingan harga yang ditawarkan masing – masing penjual.

Penjualan produk akan sukses melalui *marketplace*, tidak hanya berdasarkan produk yang memiliki kualitas saja yang penting, tetapi juga pengetahuan penjual mengenai struktur pasar untuk mengevaluasi posisinya, pesaing, serta mitranya (Edeling & Himme, 2018). Menurut penelitian yang dilakukan oleh Prihastomo *et al.*, pada tahun 2018, terdapat 11 faktor kesuksesan penerapan *marketplace*, yaitu kejujuran, teknik, platform, pemilik platform, produk, layanan operasi, penjual, pemasaran, pembayaran, pembeli, dan lingkungan (Prihastomo *et al.*, 2018).

Marketplace dapat mempengaruhi kebiasaan, sifat, maupun karakter yang dilakukan seorang pembeli mencukupi kebutuhan serta menuntaskan keinginan. Hal-hal tersebut dapat diketahui dengan cara penganalisaan yang dijalankan oleh media yang digunakan (*marketplace*). Penganalisaan ditujukan mengingat perlunya adanya pengarsipan dan identifikasi pada riwayat atas pelaksanaan kegiatan transaksi. Dalam beberapa tahun terakhir, data transaksi ataupun fitur dalam *marketplace* telah umum digunakan sebagai objek penelitian dan analisis bagi para peneliti, karena dirasa masih

perlu adanya bagian dari *marketplace* yang dapat lebih diefisienkan sehingga dapat efektif untuk menarik minat pelanggan (Kurniawan *et al.*, 2017).

Salah satu penelitian dilakukan oleh Subawa dan Mimaki pada tahun 2019, untuk melihat penerimaan budaya *e – marketplace* dalam suatu usaha di provinsi Bali. Mereka melakukan pengujian dengan menggunakan kuisioner dan perangkat lunak dan menghasilkan kesimpulan bahwa kinerja *e – marketplace* berpengaruh positif terhadap niat pengusaha dalam menerima budaya *e – marketplace*. Namun, tidak ada dampak signifikan dari penerapan *e – marketplace* oleh pengusaha Bali (Subawa & Mimaki, 2019). Penelitian lain dilakukan oleh Rachbini *et al.*, pada tahun 2019, mereka menerapkan salah satu jenis model bisnis yaitu C2C *e – marketplace* untuk mengoptimalkan kategori sembako. Peneliti memberikan pemisalan contoh dengan ekuitas pelanggan supaya dapat diketahui dalam sudut pandang parsial pengaruh merek, harga, serta loyalitas pelanggan. Hasil menunjukkan bahwasanya adanya dominasi antara ekuitas merek dan harga pada loyalitas pelanggan serta diperoleh hasil bahwa kepercayaan konsumen mempengaruhi loyalitasnya (Rachbini *et al.*, 2019).

2.3 Karakteristik Pembeli

Maraknya pengguna internet khususnya di Indonesia, membuat internet saat ini tak hanya digunakan sebagai media komunikasi dan bertukar informasi, melainkan digunakan pula sebagai kegiatan ekonomi. Kehadiran *e – commerce* sangat memudahkan kebutuhan masyarakat karena dapat diakses secara lebih cepat dan memiliki cakupan yang luas. Kebutuhan ini mengambil

peran sangat penting pada perkembangan perilaku konsumen. Menurut buku yang ditulis oleh Setiadi pada tahun 2003, perilaku yang ditujukan untuk memperoleh langsung, mengkonsumsi, dan menghabiskan produk atau layanan, dan mencakup proses pengambilan keputusan yang mendahului perilaku itu (Setiadi, 2003).

Dengan berbagai kemudahan yang diberikan oleh *e-commerce*, menjadikan masyarakat Indonesia menjadi lebih konsumtif dibanding masyarakat negara lain. Berdasarkan data akhir peninjauan *We Are Social* yang dilakukan pada tahun 2021, diperoleh bahwa sebesar 88,1% pengakses internet Indonesia menggunakan fasilitas *marketplace* dalam mendapatkan berbagai jenis barang kebutuhan mereka dalam jangka waktu beberapa bulan (Lidwina, 2021). Penelitian yang dilakukan oleh Zhang dan Feng pada tahun 2011, mereka mengatakan bahwa ketika membuat keputusan, seorang konsumen umumnya melalui tujuh tahap utama, yaitu membutuhkan pengakuan, mencari informasi, evaluasi alternative lain sebelum melakukan pembelian, pembelian, konsumsi, evaluasi pasca pembelian, dan divestasi (Zhang & Feng, 2011).

2.4 Sistem Rekomendasi

Sistem rekomendasi adalah galat sistem pengambilan informasi (*Information Retrieval*) dan cabang dari bidang kecerdasan buatan (*Artificial Intelligence*). Sistem rekomendasi dapat dikatakan sebagai sebuah perangkat lunak yang memberikan prediksi berupa pilihan *item* kepada pengguna sesuai dengan karakteristik dan preferensi pengguna dengan tujuan sebagai sistem

pendukung keputusan untuk pengguna dapat menyukai suatu *item*. Kriteria yang digunakan untuk penentuan sistem rekomendasi produk tidak hanya terbatas pada *single* kriteria seperti *rating* yang diberikan oleh pengguna, tetapi dapat menggunakan multi kriteria. Multi kriteria dalam rekomendasi sistem mengambil beberapa karakteristik penting dalam *item*, misal dalam sistem rekomendasi musik dapat mengambil beberapa kriteria seperti lirik, visual, audio, suara, ketukan, genre, dll. Dengan multi kriteria dalam rekomendasi sistem dapat menentukan preferensi subjektif dari pengguna pada beberapa atribut dalam *item* sehingga untuk meningkatkan akurasi prediksi sistem (Arif *et al.*, 2020).

Dengan banyaknya barang yang dijual di *e-commerce* hampir tidak mungkin dan tidak akan praktis jika menelusuri seluruh katalog produk yang ingin dibeli secara manual. Sistem rekomendasi dibangun untuk memberikan daftar item kepada pengguna tanpa harus melakukan penelusuran dengan kueri lain (Chaudhari *et al.*, 2017). Sistem rekomendasi biasanya diklasifikasikan menurut pendekatan terhadap peringkat *item* dan dikategorikan sebagai berikut (Manouselis *et al.*, 2010)

- *Content – based recommendation* : Metode penyaringan berbasis konten biasanya mendasarkan rekomendasi pada informasi pengguna, dan mereka mengabaikan kontribusi dari pengguna lain. Beberapa masalah yang terkait dengan teknik penyaringan konten berbasis konten terbatas analisis dan spesialisasi yang berlebihan- yang menghasilkan *sparsity of data* (Yoshii *et al.*, 2008).

- *Collaborative recommendation* : Metode kolaboratif merekomendasikan produk dengan mempertimbangkan bagaimana pengguna lain dengan selera yang sama dan menggunakan pendapat mereka untuk merekomendasikan item kepada pengguna aktif. Pendekatan kolaboratif menunjukkan masalah seperti *cold – start*, *sparsity*, dan masalah skalabilitas (Yoshii *et al.*, 2008).
- *Hybrid approaches* : Metode hibrida menggabungkan pendekatan berbasis konten dan metode kolaboratif untuk mengurangi masalah yang dihadapi oleh dua teknik *filtering* secara individual. Hibrida sistem rekomendasi juga dapat ditambah dengan berbagai algoritma dan teknik berbasis pengetahuan untuk lebih meningkatkan akurasi sistem rekomendasi (Yoshii *et al.*, 2008).

Pada tahun 2020, Teruya *et al.* melakukan penelitian dalam membahas sistem rekomendasi masalah *cold – start* dimana masalah ini sering dihadapi oleh pengembang web yang harus mengandalkan pihak ketiga agar mendapatkan rekomendasi yang relevan dengan sistem. Penelitian ini dicapai dengan mengimplementasikan usulan API. API yang diusulkan terbukti menjadi pendekatan yang efisien dalam rekomendasi konten yang relevan (Teruya *et al.*, 2020). Penelitian lain dilakukan oleh Guo dan Liu pada tahun 2010, mereka menerapkan teknologi MAS (*Multi Agent System*). Konsep dasarnya adalah mengatur beberapa agen dengan tujuan yang berbeda untuk mencapai tujuan ke masing – masing agen secara maksimal. *Multi Agent System* lebih unggul daripada sistem agen tunggal (Guo & Liu, 2010). Penelitian serupa

yang menggunakan sistem rekomendasi dilakukan oleh Kato dan Yamamoto pada tahun 2020, mereka mengintegrasikan SNS dan Web – GIS untuk merekomendasikan tempat wisata bagi pengguna dengan frekuensi kunjungan yang berbeda. Sistem ini mengurangi beban untuk mengumpulkan informasi tamasya untuk merekomendasikan tempat wisata kepada pengguna dengan frekuensi kunjungan yang berbeda sehingga memungkinkan pertemuan dan akumulasi informasi tempat wisata (Kato & Yamamoto, 2020).

2.5 Collaborative Filtering

Collaborative Filtering atau biasa disingkat CF merupakan metode yang menghasilkan rekomendasi khusus kepada pengguna tentang item berdasarkan pola penilaian atau penggunaan (misalnya, pembelian) tanpa memerlukan informasi eksogen tentang item atau pengguna tersebut. Metode ini menghasilkan prediksi atau rekomendasi untuk pengguna tertentu untuk satu atau banyak item. Item yang dikatakan mungkin terdiri dari item-item yang dapat diberikan *rating* oleh pengguna, nilai *rating* dalam *Collaborative Filtering* dapat mengambil dari berbagai bentuk bisa berupa voting ataupun *binary*. Dalam penelitian yang dilakukan oleh Koren dan Bell pada tahun 2011, mereka menerapkan metode *Collaborative Filtering* terhadap aplikasi *streaming* Netflix. Metode *Collaborative Filtering* dalam penelitian ini digunakan untuk mendapatkan rekomendasi film maupun acara TV berdasarkan dua varian input yaitu *explicit feedback* dan *implicit feedback*. *Explicit feedback* berupa pemberian *rating* bintang yang dilakukan oleh pengguna pada suatu film maupun acara TV, sedangkan *implicit feedback*

berupa *chase history*, riwayat penelusuran, dan pola pencarian. Untuk menghubungkan kedua varian input dan menghasilkan sistem rekomendasi yang lebih akurat mereka menggunakan dua pendekatan metode yaitu *the neighborhood approach* dan *latent factor models*. Metode *neighborhood approach* berfokus pada hubungan antar item atau sebagai alternatif antar pengguna, sedangkan metode *latent factor models* melakukan pendekatan substitusi dengan mengubah produk dan *user* ke dalam *latent* yang sebanding (Koren & Bell, 2011).

2.5.1 Item Based Collaborative Filtering

Item Based Collaborative Filtering bisa dikatakan sebagai salah satu sekumpulan instruksi dalam penyaringan dengan sumber pada *similarity* pemberian *rating* pada item tertentu dengan item lain yang hendak dipilih oleh pengguna. *Similarity level* suatu item akan dihitung berdasarkan parameter keinginan pengguna untuk mendapatkan nilai fungsionalitas item tersebut. Item yang nantinya digunakan sebagai perekomendasi merupakan item dengan nilai prediksi paling tinggi. Pada tahun 2019, Prasetyo *et al.* mengimplementasikan riset dengan algoritma *Item Based Collaborative Filtering* mereka implementasikan dengan tujuan menentukan sistem rekomendasi produk pada *interface* aplikasi *e-commerce smartphone*. Mereka menggunakan metode *Pearson Correlation Based Similarity* untuk menghitung nilai *similarity* antara dua variabel item. Korelasi *pearson* menghitung besaran nilai hubungan linear antara dua variabel, dimana kesalahan harus bersifat *private* dan *probability distribution* memiliki rata-

rata 0 dan varian tampaknya terdistribusi normal (0, 1). Kinerja implementasi *Item Based Collaborative Filtering* dengan *Pearson Correlation Based Similarity* menghasilkan nilai MAE sebesar 0,572 dengan lama eksekusi 6,4 detik (Prasetyo *et al.*, 2019).

2.5.2 User Based Collaborative Filtering

User Based Collaborative Filtering sendiri merupakan penyaringan yang dihasilkan dari ekualitas karakteristik dan minat antar *user*. Dimana setiap entitas merupakan elemen dari sekelompok *user* yang memiliki kesamaan dengan *user* lainnya. Yang harus di garis bawahi dari metode ini yaitu rekomendasi produk yang dihasilkan akan diperoleh berdasarkan item yang dinilai *rating* oleh *user*. Item yang dijadikan sebagai rekomendasi merupakan hasil dari item yang diberi *rating* oleh *user* lainnya ataupun *user* yang memiliki kesamaan produk yang diberi *rating*. Pada tahun 2021, Khusna *et al.* mengadakan riset dengan mengimplementasikan algoritma *User Based Collaborative Filtering* mereka terapkan pada pembangunan sistem rekomendasi produk pada sebuah aplikasi penentuan *gadget shield*. Input parameter yang mereka gunakan berupa pemberian *rating* oleh pelanggan pada produk yang ada pada aplikasi tersebut. Penggunaan algoritma *Euclidean Distance* ditujukan untuk mengukur nilai kemiripan antar produk. Setelah nilai kemiripan didapat dilanjutkan dengan mencari prediksi dengan menerapkan metode *Weight Sum*. Pengujian dengan menggunakan kuesioner *User Acceptance Test* (UAT) oleh sebanyak 20 *user*. Hasil pengujian menunjukkan bahwa dengan perhitungan menggunakan metode *Root Mean*

Square Error mendapatkan nilai akurasi sebesar 0,496 atau sama dengan 90.08% (Khusna *et al.*, 2021).

2.5.3 Improved triangle similarity complemented with user rating preferences (ITR)

Improved triangle similarity complemented with user rating preferences (ITR) merupakan algoritma yang dapat diimplementasikan untuk mendapatkan nilai *similarity* terhadap dua buah titik, didalam algoritma ITR terdapat dua istilah *improved triangle similarity* ($sim^{TRIANGLE}$) dan *user rating preferences* (URP) (Iftikhar *et al.*, 2020). Dalam praktiknya, $sim^{TRIANGLE}$ dianggap sebagai peningkatan dari kesamaan *Triangle Multiplying Jaccard* (TMJ), sehingga *Improved Triangle Similarity* (ITR) tidak hanya berfokus pada peringkat umum, seperti ukuran TMJ, tetapi juga memperhitungkan peringkat pengguna yang tidak umum (Iftikhar *et al.*, 2020).

Terdapat metode lain dalam perhitungan nilai *similarity*, misalnya pada eksperimen yang diimplementasikan oleh Pamungkas dan Hariri pada tahun 2016 mengimplementasikan algoritma *Euclidean Distance* untuk melakukan perhitungan nilai *similarity* untuk pembuatan sistem pengenalan citra tanda tangan. Nilai *similarity* didapatkan dengan melakukan perhitungan akar kuadrat dari 2 buah titik vektor, bobot terkecil dari hasil perhitungan didefinisikan menjadi nilai *fitness* dari sebuah gambar tanda tangan. Dari hasil pengujian sistem didapatkan nilai akurasi sebesar 88% untuk gambar dengan ukuran 50x50 *pixel*, sebesar 71% untuk gambar dengan ukuran

100x100 *pixel*, dan rata-rata nilai akurasi sebesar 81% (Pamungkas & Hariri, 2016).

Dalam penelitian yang dilakukan oleh Sun *et al.*, pada tahun 2017, mereka mengembangkan sebuah sistem rekomendasi dengan penggabungan metode *Improved Triangle Similarity* dengan *Jaccard Similarity*. *Triangle Similarity* mempertimbangkan panjang dan sudut vektor *rating*, sedangkan *Jaccard Similarity* mempertimbangkan pengguna yang tidak memiliki nilai *rating* yang sama. Uji coba dilakukan dengan menggunakan 4 dataset populer yaitu MovieLens 100k, 1M, FilmTrust and EachMovie, hasil uji coba menunjukkan bahwa hasil penggabungan mendapatkan nilai MAE dan RMSE yang lebih kecil sehingga performa dapat meningkat sebesar 0.1%- 6.1% (Sun *et al.*, 2017).

2.5.4 Weighted Sum

Untuk mendapatkan perhitungan (bobot) prediksi untuk setiap item yang direkomendasikan kepada *user*, dapat diuji dengan menggunakan persamaan *Weighted Sum*. *Weighted Sum* sendiri merupakan metode untuk pengambilan keputusan dengan multi-kriteria sederhana guna mengevaluasi sejumlah alternatif yang kaitannya dengan sebanyak jumlah kriteria keputusan (Handoko *et al.*, 2017). Pada tahun 2017, Nasution *et al.* melakukan penelitian dengan mengimplementasikan metode *Weighted Sum* mereka gunakan untuk membangun sebuah sistem pengambilan keputusan penentuan peserta jaminan kesehatan masyarakat, dimana sistem ini mampu memberikan daftar *ranking* pada masing-masing atribut serta alternatif

peserta yang berhak menerima Jamkesmas dengan menerapkan metode *Fuzzy* sederhana. Mereka menggunakan sepuluh kriteria dalam *Weighted Sum* dengan memberikan nilai bobot pada setiap kriterianya, dimana penentuan nilai bobot didasarkan pada lima variabel linguistik *fuzzy* (Nasution *et al.*, 2017).

2.6 Evaluasi Sistem Rekomendasi

Evaluasi bertujuan untuk mengetahui seberapa tinggi tingkat akurasi ataupun tingkat *error* dari hasil sistem rekomendasi pada setiap *user*. Terdapat berbagai persamaan dan algoritma yang dapat digunakan untuk mendapatkan tingkat akurasi dan tingkat *error* pada hasil sistem rekomendasi dapat menggunakan persamaan *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), Akurasi, Presisi, *Recall*, serta *F-Score* (F_1).

Beberapa metode di atas sangat umum digunakan untuk pengukuran tingkat keakuratan dari model-model perkiraan. Sama halnya dengan penelitian yang diselesaikan oleh Arif *et al.* pada tahun 2021, perhitungan akurasi pada sistem rekomendasi destinasi wisata pada turis dengan mengimplementasikan *confusion matrix* guna mengukur besaran akurasi, presisi, *recall*, dan *F-score* (F_1) dari performa sistem. Dari hasil pengukuran penerapan *Automatic Scenario Control* pada *Tourism Serious Game* pada 1500 kemungkinan kombinasi bobot kriteria yang mewakili ekspektasi pelaku destinasi pariwisata diperoleh nilai akurasi sebesar 0.78, presisi pada nilai 0.80, *recall* pada nilai 0.96, dan nilai *F-score* (F_1) pada besaran 0.87. Sedangkan pada penilaian calon turis sebagai pemain dalam pengujian, sistem

mendapatkan nilai rata-rata sebesar 7.8 untuk aspek media dan sebesar 7.9 untuk aspek material (Arif *et al.*, 2021).

Pada penelitian yang dilakukan oleh Suryanto pada tahun 2019, rumus *Mean Absolute Error* (MAE) diusulkan pada penerapan implementasi algoritma *Regresi Linear* pada peramalan hasil panen padi. Pengujian tersebut diterapkan pada prediksi produksi padi sebesar 5.347,763 ton dengan memperoleh besaran *Mean Absolute Error* (MAE) pada besaran 1,49. Terdapat juga penelitian yang dilakukan oleh Koochi & Kiani pada tahun 2016, dimana perhitungan nilai Presisi dan *Recall* diimplementasikan dengan tujuan mendapatkan tingkat akurasi pada sistem rekomendasi dengan mengimplementasikan algoritma *User Based Collaborative Filtering* menggunakan algoritma *Fuzzy C-Means* dengan diterapkan pada dataset MovieLens, hasil penelitian mendapatkan nilai *mean* presisi pada persentase 54% dan *mean* nilai *recall* pada presentase 13% (Suryanto, 2019).

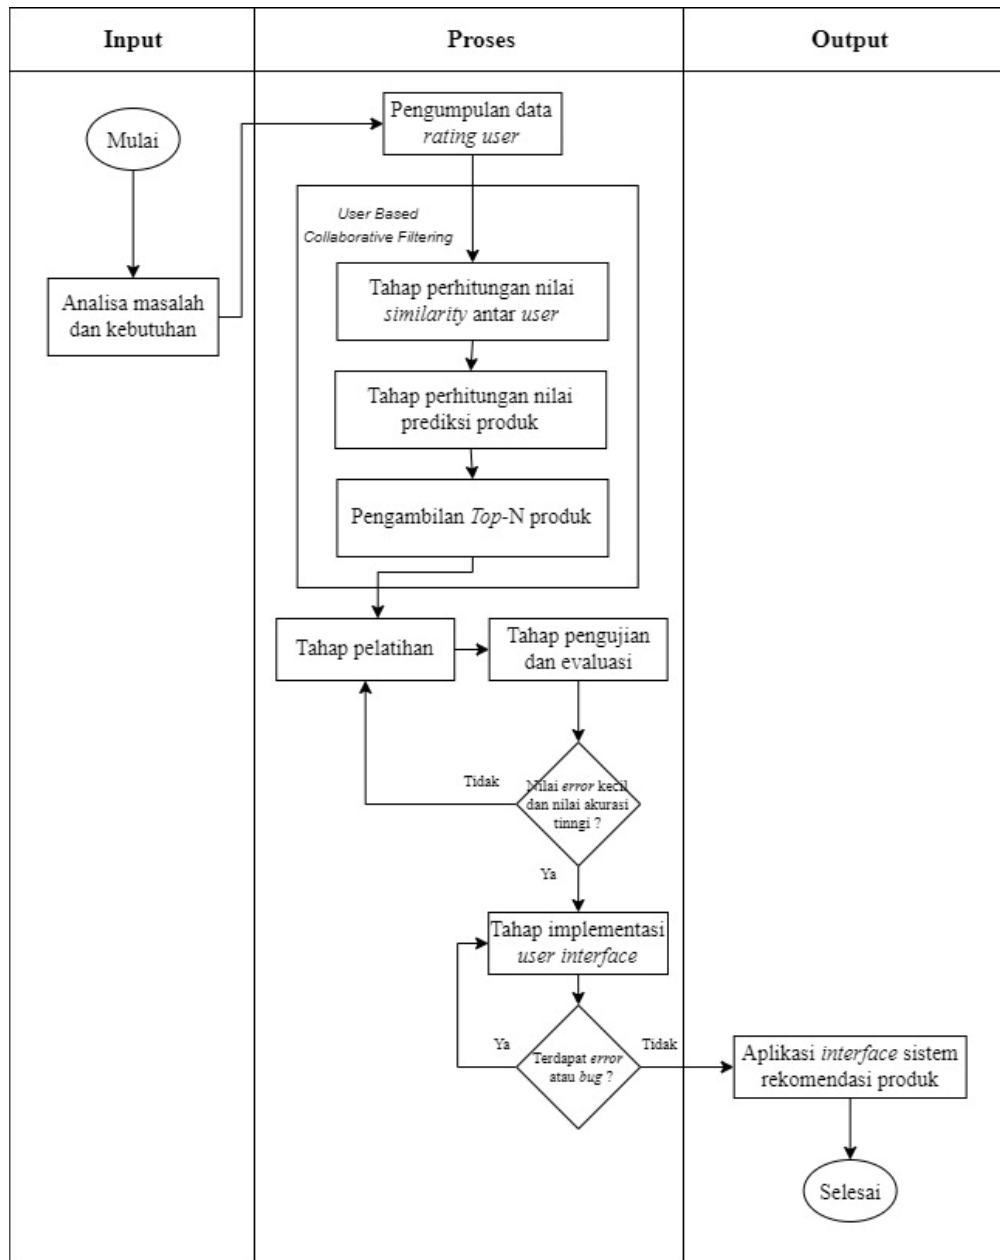
BAB III

METODOLOGI PENELITIAN

3.1 Tahapan Penelitian

Sistem rekomendasi yang nantinya akan dibuat merupakan media bagi pembeli untuk mendapatkan produk-produk yang sesuai dengan karakteristik pembeli dalam memberikan *rating* pada sebuah produk. Hasil dari rekomendasi produk didapat dengan menerapkan metode *User Collaborative Filtering* ditujukan sekaligus untuk dapat meningkatkan loyalitas pembeli. Nantinya hasil rekomendasi produk nantinya akan ditampilkan pada halaman awal aplikasi *mobile*. Produk tersebut selanjutnya dapat diberi aksi oleh pembeli seperti *like*, *unlike* ataupun melakukan pembelian. Tahap awal penelitian yaitu dengan pembuatan aplikasi *mobile* mulai dari REST API hingga diterapkan pada pembuatan *mobile platform*, aplikasi *mobile* tersebut nantinya digunakan sebagai media untuk pengumpulan data *rating* produk dari pembeli dan pemrosesan hasil sistem rekomendasi produk.

Data proses yang digunakan adalah berupa data *rating* produk yang diberikan oleh pembeli. Sedangkan hasil sistem rekomendasi produk pada aplikasi adalah hasil pengimplementasian metode *User Collaborative Filtering* dari data *rating* produk dari pembeli. Dari hasil tersebut akan dilakukan evaluasi dengan menghitung tingkat akurasi dan *error* dengan menggunakan metode *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), Akurasi, Presisi, *Recall* dan *F-Score* (F_1).



Gambar 3. 1 Tahapan penelitian

Berikut penjelasan dari Gambar 3.1 yaitu tahapan-tahapan dalam penelitian ini, yaitu:

- 1) Tahapan input merupakan tahapan didalamnya terdapat penganalisaan permasalahan baik dari segi metode, proses dan tujuan penelitian serta dilakukannya analisa kebutuhan *output* dari penelitian.

2) Tahapan proses

a. Pengumpulan data *rating user*

Pengambilan semua data *rating* yang dilakukan oleh pembeli terhadap sebuah produk pada *database* aplikasi Sindomall pada bulan Desember tahun 2021.

b. Implementasi metode *User Based Collaborative Filtering*

- Tahap perhitungan nilai *similarity* antar *user*

Melakukan perhitungan nilai *similarity* antar *user* dengan menggunakan data *rating* setiap produk yang telah diambil menggunakan algoritma ITR.

- Tahap perhitungan nilai prediksi produk

Melakukan perhitungan nilai prediksi produk untuk *user* yang *login* ke sistem menggunakan nilai *similarity* yang didapatkan dengan menggunakan algoritma *Weighted Sum*.

- Pengambilan *Top-N* produk

Hasil daftar produk yang direkomendasikan diambil dari *Top-N* nilai prediksi produk yang diurutkan dari nilai tertinggi ke terendah.

c. Tahap pelatihan

Dilakukan pengukuran dengan merubah nilai parameter persentase *user* yang berbeda-beda, dimana tingkat *error* dari setiap parameter akan dilakukan pemantauan pada perubahan nilai *error*-nya untuk mendapatkan nilai presentase *user* dengan *error* paling rendah.

d. Tahap pengujian dan evaluasi

Melakukan pengukuran nilai akurasi dan *error* pada sistem sesuai dengan nilai parameter presentase *user* yang telah ditentukan untuk dilakukan evaluasi apakah nilai akurasi sudah dapat dikatakan tinggi dan nilai *error* dapat ditoleransi.

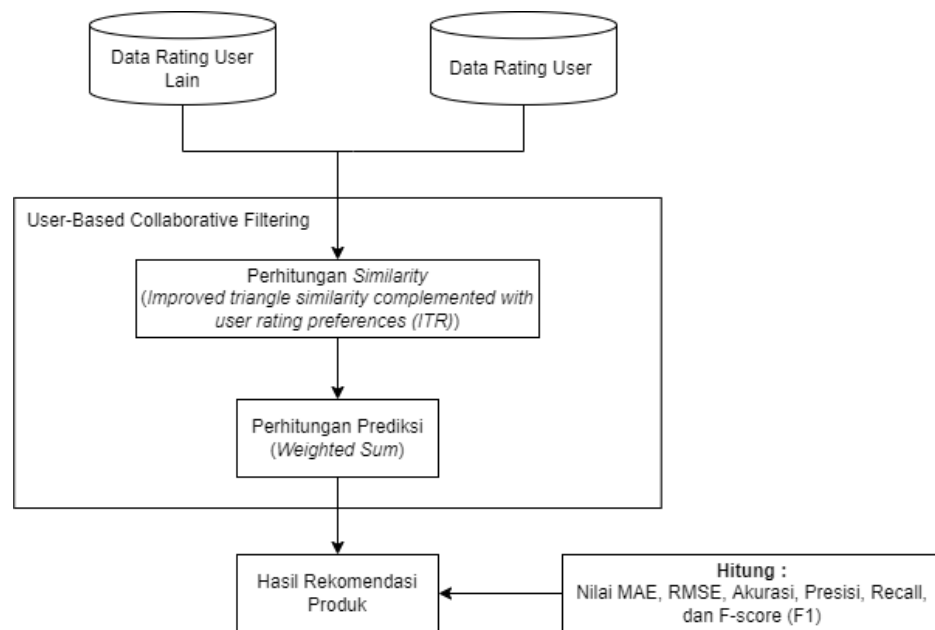
e. Tahap implementasi *user interface*

Pengembangan aplikasi menggunakan *mobile* app yang akan di *develop* sesuai kebutuhan pengguna untuk mendapatkan rekomendasi produk. Apabila hasil dari implementasi *user interface* tidak ditemukannya *error* atau *bug*, maka dianggap berhasil.

3) Pada tahapan output, akhir penelitian merupakan hasil dari pengembangan aplikasi *interface* yang memberikan rekomendasi produk kepada pengguna.

3.2 Desain Sistem

Desain sistem dalam penelitian ini ditampilkan pada Gambar 3.2 dimulai dengan tahapan pengambilan data *rating* dari *user* dilanjutkan pada tahapan dalam metode *User-Based Collaborative Filtering* yaitu perhitungan nilai *similarity* dengan menggunakan metode *Improved triangle similarity complemented with user rating preferences* (ITR) dan perhitungan nilai prediksi dengan menggunakan metode *Weighted Sum*. Tahapan terakhir hasil rekomendasi produk akan dihitung nilai MAE, RMSE, Akurasi, Presisi, *Recall*, dan *F-Score* (F_1).



Gambar 3. 2 Desain sistem

3.3 User Based Collaborative Filtering

Metode *User Based Collaborative Filtering* digunakan karena sesuai dengan visi yang digunakan pada aplikasi *marketplace* Sindomall, dimana lebih mengedepankan terbentuknya suatu kelompok komunitas pada *user*-nya terhadap beberapa produk tertentu. Dengan menggunakan metode *User Based Collaborative Filtering* yang mendefinisikan setiap *user*-nya merupakan bagian dari sekelompok user yang memiliki kecocokan dengan *user* lainnya, akan dapat membentuk suatu kelompok *user* dengan minat yang sama pada beberapa produk. Berikut ini akan dijelaskan bagaimana proses untuk mendapatkan sebuah rekomendasi produk dengan mengimplementasikan metode *User Based Collaborative Filtering*:

3.3.1 Data Rating

Tahapan pertama dalam pengimplementasian *User Based Collaborative Filtering* yaitu dengan pemberian *rating* yang dilakukan oleh pembeli terhadap sebuah produk pada aplikasi Sindomall, adapun format data yang akan disajikan adalah seperti pada Tabel 3.1.

Tabel 3. 1 Contoh tabel skenario *rating*

Produk <i>User</i>	(a) <i>Philodendron Gloriosum</i>	(b) <i>Alocasia Macrorrhiza</i>	(c) <i>Labisia sp.</i>	(d) <i>Aglaonema Pictum</i>	(e) <i>Begonia sp.</i>
(1) Cedric	5	4	3	3	4
(2) Daniel	4	3	5	5	4
(3) Yuni	2	3	3	5	5
(4) Hebe	5	5	5	4	4
(5) Giva	-	-	4	-	-

3.3.2 Perhitungan *Similarity*

Persamaan yang digunakan untuk mengukur nilai kemiripan antar dua *user* yaitu dengan menggunakan persamaan *Improved triangle similarity complemented with user rating preferences (ITR)*. Dimana menurut penelitian yang dilakukan Fkih pada tahun 2021, peneliti *review* dan membandingkan 13 algoritma perhitungan *similarity measure* pada skenario uji coba menggunakan tiga *dataset* standar (MovieLens100k, MovieLens1M dan Jester), dimana ITR merupakan algoritma yang paling cocok dan efisien untuk metode *User Based*

Collaborative Filtering (Fkih, 2021). Adapun rumus algoritma ITR adalah pada persamaan 3.1

$$sim^{ITR}(u, v) = sim^{TRIANGLE}(u, v) * sim^{URP}(u, v) \quad (3.1)$$

Keterangan:

- $sim^{ITR}(u, v)$ = Nilai *similarity* ITR antar *user* u dengan *user* v
- $sim^{TRIANGLE}(u, v)$ = Nilai *similarity triangle* antar *user* u dengan *user* v
- $sim^{URP}(u, v)$ = Nilai *similarity* URP antar *user* u dengan *user* v

Adapun untuk rumus persamaan $sim^{TRIANGLE}(u, v)$ dan $sim^{URP}(u, v)$ adalah pada persamaan 3.2 dan 3.3

$$sim^{TRIANGLE}(u, v) = 1 - \frac{\sqrt{\sum_{i \in I_{uv}} (r_{ui} - r_{vi})^2}}{\sqrt{\sum_{i \in I_{uv}} r_{ui}^2} + \sqrt{\sum_{i \in I_{uv}} r_{vi}^2}} \quad (3.2)$$

Keterangan:

- I_{uv} = Himpunan nilai *rating* oleh *user* u atau *user* v
- r_{ui} = Nilai *user* u pada item ke-i
- r_{vi} = Nilai *user* v pada item ke-i

$$sim^{URP}(u, v) = 1 - \frac{1}{1 + \exp(-|\bar{r}_u - \bar{r}_v| * |\sigma_u - \sigma_v|)} \quad (3.3)$$

Keterangan:

- \bar{r}_u = Rata-rata nilai *rating* *user* u
- \bar{r}_v = Rata-rata nilai *rating* *user* v
- σ_u = Simpangan baku nilai *rating* *user* u

- σ_v = Simpangan baku nilai *rating user* v

Dengan rumus simpangan baku pada persamaan 3.4

$$\sigma_u = \sqrt{\frac{\sum_{i \in I_u} (r_{ui} - \bar{r}_u)^2}{|I_u|}} \quad (3.4)$$

Keterangan:

- r_{ui} = Nilai *user* u pada item ke-i
- \bar{r}_u = Rata-rata nilai *rating user* u
- I_u = Panjang himpunan nilai *rating user* u

Perhitungan nilai *similarity* dilakukan kepada *user* satu dengan *user* lainnya, sehingga masing-masing *user* memiliki nilai *similarity* dengan semua *user*. Pada Tabel 3.2 merupakan hasil dari perhitungan nilai *similarity* pada masing-masing *user*.

Tabel 3. 2 Contoh hasil perhitungan *similarity* antar *user*

<i>User</i>	<i>User</i>	Nilai <i>Similarity</i>
Cedric	Daniel	0,3280
Cedric	Yuni	0,2751
Cedric	Hebe	0,3296
Cedric	Giva	0,0057
Daniel	Yuni	0,3025
Daniel	Hebe	0,3588
Daniel	Giva	0,0084
Yuni	Hebe	0,1713
Yuni	Giva	0,0203
Hebe	Giva	0,0020

Nilai *similarity* 0,3280 pada baris pertama Tabel 3.2 diperoleh dengan penerapan persamaan 3.1

$$sim^{TRIANGLE}(1,2)$$

$$\begin{aligned}
&= 1 - \frac{\sqrt{(5-4)^2 + (4-3)^2 + (3-5)^2 + (3-5)^2 + (4-4)^2}}{\sqrt{(5^2 + 4^2 + 3^2 + 3^2 + 4^2) + \sqrt{(4^2 + 3^2 + 5^2 + 5^2 + 4^2)}}} \\
&= 1 - \frac{\sqrt{10}}{\sqrt{75 + \sqrt{91}}} \\
&= 1 - \frac{\sqrt{10}}{\sqrt{75 + 9,53939201}} \\
&= 1 - \frac{\sqrt{10}}{\sqrt{84,539392}} \\
&= 1 - \frac{3,16227766}{9,19453055} \\
&= 1 - 0,3439 \\
&= 0,6560
\end{aligned}$$

$$sim^{URP}(1,2)$$

$$\begin{aligned}
&= 1 - \frac{1}{1 + \exp(-|3,8 - 4,2| * |0,7483 - 0,7483|)} \\
&= 1 - \frac{1}{1 + \exp(-0,4 * 0)} \\
&= 1 - \frac{1}{1 + \exp(0)} \\
&= 1 - \frac{1}{1 + 1} \\
&= 1 - \frac{1}{2} \\
&= 0,5
\end{aligned}$$

$$sim^{ITR}(1,2) = sim^{TRIANGLE}(1,2) * sim^{URP}(1,2)$$

$$= 0,6560 * 0,5$$

$$= 0,3280$$

Nilai *similarity* memiliki nilai antara 0 dan 1. Jika bernilai 0 maka antar dua *user* tersebut tidak memiliki kemiripan, sedangkan bernilai 1 maka antar dua *user* tersebut dapat dikatakan identik (Firmansyah, 2018).

3.3.3 Perhitungan Prediksi

Perhitungan nilai prediksi produk dilakukan setelah berhasil mendapatkan nilai *similarity* antar *user*. Persamaan yang digunakan untuk menghitung nilai prediksi produk adalah dengan menggunakan *Weighted Sum*. Dimana menurut penelitian yang dilakukan oleh Fkih pada tahun 2021, peneliti membandingkan 3 metode perhitungan nilai prediksi *rating* pada 13 algoritma perhitungan *similarity measure*, metode *Weighted Sum* menghasilkan nilai akurasi terbesar dibandingkan 2 metode lainnya yaitu *Z-Score* dan *Mean-Centered Aggregation* (Fkih, 2021). Adapun rumus persamaan *Weighted Sum* adalah pada persamaan 3.5.

$$P(a, i) = \frac{\sum_{i \in 1} (R_{a,i} * S_{i,j})}{\sum_{i \in 1} |S_{i,j}|} \quad (3.5)$$

Keterangan:

- $P(a,i)$ = Nilai prediksi antar item a terhadap objek i
- $R(a,i)$ = Penilaian untuk item a oleh objek i
- $S(i,j)$ = Nilai *similarity* antar objek i dengan objek j

Contoh perhitungan dilakukan pada *user* Giva terhadap 4 *user* teratas lainnya (memiliki nilai kemiripan tertinggi) dimana *user* ini baru

memberikan *rating* pada salah satu produk yaitu produk c dengan nilai 4 seperti pada Tabel 3.1, dan akan mencari sebuah rekomendasi produk. Dengan persamaan 3.5 maka akan dapat menentukan nilai prediksi *rating user* Giva terhadap produk yang belum diberi *rating* oleh *user* Giva. Sebagai contoh berikut adalah perhitungan nilai prediksi *rating user* Giva terhadap produk a:

$$\begin{aligned}
 P(a, 5) &= \frac{(5 * 0,0057) + (4 * 0,0084) + (2 * 0,0203) + (5 * 0,0020)}{|0,0057| + |0,0084| + |0,0203| + |0,0020|} \\
 P(a, 5) &= \frac{0,1127}{0,0364} \\
 P(a, 5) &= 3,0962
 \end{aligned}$$

Tabel 3. 3 Contoh hasil perhitungan nilai prediksi *user*

<i>User</i>	Produk	Nilai Prediksi
Giva	<i>Philodendron Gloriosum</i>	3,0962
Giva	<i>Alocasia Macrorrhiza</i>	3,2665
Giva	<i>Aglaonema Pictum</i>	4,6319
Giva	<i>Begonia sp.</i>	4,5577

3.3.4 Hasil Rekomendasi

Dari hasil perhitungan nilai prediksi *user* terhadap suatu produk, semua data prediksi tersebut khususnya pada suatu *user* akan diurutkan dari nilai prediksi tertinggi hingga ke yang terendah. Tentunya nilai prediksi *rating* tertinggi akan berada pada peringkat pertama. Penampilan hasil rekomendasi *Top-N* produk pada sistem akan diambil dari urutan *top ranking* 10 dari total keseluruhan produk. Hal tersebut didasarkan pada hasil penelitian yang dilakukan oleh Faizin dan

Surjandari pada tahun 2020, menyimpulkan bahwa nilai *Top-N* rekomendasi produk dengan faktor *learning rate*, *batch size*, dan jumlah faktor prediktif pada marketplace di Indonesia sebesar 10 produk (Faizin & Surjandari, 2020).

Pada Tabel 3.3 merupakan hasil dari skenario kasus perhitungan nilai prediksi dimana *user* Giva memiliki nilai prediksi pada setiap produk yang belum pernah diberikan *rating*. Data tersebut masih belum diurutkan dari nilai yang tertinggi ke terendah, adapun jika diurutkan maka hasil rekomendasi produk pada *user* Giva adalah dengan urutan sebagai berikut

1. *Aglaonema Pictum* (Produk d)
2. *Begonia sp.* (Produk e)
3. *Alocasia Macrorrhiza* (Produk b)
4. *Philodendron Gloriosum* (Produk a)

3.4 Pengumpulan Data

Data yang digunakan peneliti sebagai objek dalam melakukan penelitian merupakan data sekunder yang diperoleh dari data *rating* pembeli dan data produk yang belum laku terjual pada aplikasi Sindomall di perusahaan Sindo Lah Pte Ltd pada bulan Desember 2021.

Data *rating* pembeli yang didapat memiliki sebanyak 264 baris terhadap 420 produk (terdapat nilai atribut yang kosong untuk setiap pembeli) dengan kisaran nilai *rating* 1 sampai 5 (untuk pembeli yang sudah melakukan pembelian pada suatu produk) yang disusun secara berurutan berdasarkan

nama pembeli dan nama produk. Tabel 3.4 merupakan contoh beberapa sampel data *rating* pembeli yang akan digunakan dalam penelitian ini

Tabel 3. 4 Data sampel *rating* pembeli

Produk	<i>Abelmoschus sp. Papua</i>	<i>Acrotrema sp</i>	<i>Aglaonema Army Suroso</i>	<i>Aglaonema Commutatum VARIEGATED</i>	<i>Aglaonema Pictum Tricolor</i>	<i>Aglaonema Pride of Columbia</i>	...	<i>Syngonium Yellow VARIEGATED</i>	<i>Syzygium Jiewhoei</i>	<i>Thaumatococcus Africa Fantasy</i>	<i>Thaumatococcus Selloum VARIEGATED</i>	<i>Trevesia Sundaica</i>	<i>Zamioculcas VARIEGATED</i>
User													
4uonly	1	1	1	1	1	1	1	1	1	1	1	1	1
A.L Lim	1	1	1	1	1	1	1	1	1	1	1	1	1
Abdul Latiff	1	1	1	1	1	1	1	1	1	1	1	1	1
Abdul Rahman Fadali	1	1	1	1	1	1	1	1	1	1	1	1	1
Adelene	1	1	1	1	1	1	1	1	1	1	1	1	1
Adliah Anuar	1	1	1	1	1	1	1	1	1	1	1	1	1
Adrian	1	1	1	1	5	1	1	1	1	1	1	1	1
Agnes Lim	1	1	1	1	1	1	1	1	1	1	1	1	1
Ai Hong Tan	1	1	1	1	1	1	1	1	1	1	1	1	1
Ai Leen Fung	1	1	1	1	1	1	1	1	1	1	1	1	1
...
Yunni Susilo	1	1	1	1	1	1	1	1	1	1	1	1	1
Zach Lee	1	1	1	1	1	1	1	1	1	1	1	1	1
Zachary Liang	1	1	1	1	1	1	1	1	1	1	1	1	1
Zack Tan	1	1	1	1	1	1	1	1	1	1	1	1	1
Zan Plant	1	1	1	1	1	1	1	1	1	1	1	1	1
Zee Mung Wu	1	1	1	1	1	1	1	1	1	1	1	1	1
Zhenyuan Lin	1	1	1	1	1	1	1	1	1	1	1	1	1
Zul Marquez	1	1	1	1	1	1	1	5	1	1	1	1	1
Zura Md Kassim	1	1	1	1	1	1	1	1	1	1	1	1	1
Zz	1	1	1	1	1	1	1	1	1	1	1	1	1

Data produk yang belum laku terjual nantinya akan digunakan sebagai output dari hasil rekomendasi produk. Data yang didapat sebanyak 8137 baris produk. Tabel 3.5 merupakan contoh beberapa sampel data produk yang belum laku terjual yang akan digunakan dalam penelitian ini

Tabel 3. 5 Data sampel output produk

ID	Nama Produk	Harga	Nama Penjual
81942	Anthurium Crystallinum HYBRID	40	Dedi -
81941	Philodendron Melanochrysum	35	Usma .
81940	Sansevieria sp.	40	Zim Flora
81938	Philodendron Verrucosum	62	Dedi -

81937	Sansevieria Parva Stick VARIEGATED	30	Nelwan Vico
81936	Philodendron Caramel Marble	75	Bahtiar Andalas
81934	Anthurium Radicans HYBRID	70	Bahtiar Andalas
81933	Philodendron Verrucosum	100	Bahtiar Andalas
81932	Philodendron Gloriosum	32	Dee Dee
...
65836	Anthurium Crystallinum X Forgetii	50	Rizky Putri
65835	Anthurium King of Spades	200	Rizky Putri
65834	Anthurium King of Spades	85	Rizky Putri
65833	Philodendron Billietiae x Atabapoense	100	Dee Dee
65832	Syngonium Maria Allusion	35	Rendi Toreh
65831	Anthurium Vittarifolium VARIEGATED	150	Dee Dee
65830	Philodendron Burlemarx VARIEGATED	90	Dee Dee
65818	Aglaonema Pictum Tricolor	33	Gayatri Florist
65807	Philodendron Billietiae x Atabapoense	45	Deni Setiawan
65804	Aglaonema Pictum Tricolor	40	Eddi Okta

3.5 Rencana Pengujian

Data yang akan diuji pada tahap pengujian merupakan data *real* hasil dari perhitungan manual nilai prediksi dengan menggunakan MATLAB dibandingkan dengan data *real* hasil perhitungan sistem dengan menggunakan *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE) untuk menghitung perbedaan besaran *error* dalam perhitungan nilai prediksi. Terdapat 2 matrik evaluasi yang terkenal untuk melakukan penilaian pada kinerja sistem rekomendasi yaitu MAE dan RMSE (Silveira *et al.*, 2019). Adapun nilai MAE dan RMSE akan dihitung dengan persamaan 3.6 dan persamaan 3.7.

$$MAE = \frac{\sum_{i=1}^N |p_{i,j} - q_{i,j}|}{N} \quad (3.6)$$

Keterangan:

- MAE = Nilai rata-rata *error*

- N = Total *user*
- $p_{i,j}$ = Nilai prediksi *rating* user i terhadap produk j
- $q_{i,j}$ = Nilai real *rating* user i terhadap produk j

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\tilde{r}_i - r_i)^2}{n}} \quad (3.7)$$

Keterangan:

- n = Jumlah *user*
- \tilde{r}_i = Nilai prediksi *rating* user i terhadap produk j
- r_i = Nilai real *rating* user i terhadap produk j

Karena sistem rekomendasi dianggap sebagai jenis sistem pengambilan informasi (*information retrieval*) tertentu, presisi dan *recall* matrik telah digunakan oleh banyak peneliti untuk evaluasi sistem rekomendasi, presisi diartikan sebagai rasio rekomendasi yang relevan dengan jumlah total item yang direkomendasikan. *Recall* diartikan sebagai rasio rekomendasi yang relevan dengan jumlah produk yang relevan (Polatidis & Georgiadis, 2017).

$$Presisi = \frac{\text{Produk yang direkomendasikan dengan benar}}{\text{Jumlah produk yang direkomendasikan}} \quad (3.8)$$

$$Recall = \frac{\text{Produk yang relevan}}{\text{Jumlah produk yang direkomendasikan}} \quad (3.9)$$

Hasil nilai presisi dan *recall* dapat digabungkan menjadi satu metrik, yang disebut *F-score* (F_1), seperti yang didefinisikan dalam persamaan 3.10.

$$F_1 = \frac{2 * Presisi * Recall}{Presisi + Recall} \quad (3.10)$$

Untuk perhitungan nilai akurasi akan dihitung menggunakan persamaan

3.11.

$$Akurasi = \frac{TP}{(TP + TN + FP + FN)} \quad (3.11)$$

Dimana,

1. *True Positive* (TP) adalah produk yang direkomendasikan benar dan produk tersebut relevan.
2. *True Negative* (TN) adalah produk yang direkomendasikan benar tetapi produk tersebut tidak relevan.
3. *False Positive* (FP) adalah produk yang direkomendasikan salah tetapi produk tersebut relevan.
4. *False Negative* (FN) adalah produk yang direkomendasikan salah dan produk tersebut tidak relevan.

Untuk setiap skenario pengujian, perhitungan nilai prediksi akan dimulai dengan nilai persentase *user* sebesar 10% dengan nilai kemiripan terdekat. Kemudian, akan diperluas setiap kali pengujian sebesar 10% hingga 100% (keseluruhan *user*), dari total *user* dengan nilai kemiripan tersebut akan dicari pada nilai persentase ke berapa sistem memiliki nilai akurasi yang paling tinggi.

BAB IV

UJI COBA DAN PEMBAHASAN

Pada BAB IV ini, dijelaskan hasil uji coba dan pembahasan mengenai sistem rekomendasi produk sesuai dengan tujuan penelitian yang sudah dipaparkan pada BAB I. Hasil pengujian dan pembahasan yang telah dilakukan akan dipaparkan dengan integrasi dalam Islam pada bab ini.

4.1 Implementasi Program

Tahap pengimplementasian program dilakukan untuk mengonversikan rumus metode *User Based Collaborative Filtering* yang masih bersifat matematis menjadi sebuah kode program. Bahasa pemrograman yang digunakan adalah bahasa *python* dengan versi 3.10.1.

4.1.1 Implementasi *Similarity* ITR

Implementasi algoritma *similarity* ITR dimulai dengan mengambil data *rating* produk pada semua *user* dari *database* Sindomall dan dilanjutkan dengan menghitung nilai *similarity* antar *user*-nya.

```
conn = mysql.connect()
cursor = conn.cursor(pymysql.cursors.DictCursor)

cursor.execute("SELECT productid, producttitle FROM
sindo_invoice WHERE current_status = '6' AND
reviewcomplete_value > 0 AND NOT productid = 0 AND NOT
producttitle LIKE 'LIVE%' AND MONTH(invoicedate) = '12'
GROUP BY producttitle ORDER BY producttitle ASC")
products_reviewed = cursor.fetchall()

cursor.execute("SELECT buyerid, buyername FROM
sindo_invoice WHERE current_status = '6' AND
reviewcomplete_value > 0 AND NOT productid = 0 AND NOT
producttitle LIKE 'LIVE%' AND MONTH(invoicedate) = '12'
AND NOT buyerid = " + str(user_id) + " GROUP BY buyerid
ORDER BY buyername ASC")
users_reviewed = cursor.fetchall()
```



```

check_user_type = cursor.fetchone()

cursor.execute("SELECT productid, reviewcomplete_value FROM
sindo_invoice WHERE current_status = '6' AND
MONTH(invoicedate) = '12' AND buyerid = " + str(user_id) + "
AND productid IN (SELECT productid FROM sindo_invoice WHERE
current_status = '6' AND reviewcomplete_value > 0 AND NOT
productid = 0 AND NOT producttitle LIKE 'LIVE%' AND
MONTH(invoicedate) = '12' GROUP BY producttitle ORDER BY
producttitle ASC) GROUP BY productid")
rating_value_data = cursor.fetchall()

if(check_user_type is None):
    response = jsonify([])
    response.status_code = 200
    return response
else:
    user_logged_in_rating_array = []
    for product_reviewed in products_reviewed:
        product_id = product_reviewed["productid"]

        rating_value = 0

        for rating_value_product in rating_value_data:
            if rating_value_product["productid"] ==
product_id:
                rating_value =
int(rating_value_product["reviewcomplete_value"])

                user_logged_in_rating_array += [rating_value]

                similarity_result_array = []
                for user_reviewed in users_reviewed:
                    user_reviewed_id = user_reviewed["buyerid"]

                    cursor.execute("SELECT productid,
reviewcomplete_value FROM sindo_invoice WHERE current_status
= '6' AND MONTH(invoicedate) = '12' AND buyerid = " +
str(user_reviewed_id) + " AND productid IN (SELECT productid
FROM sindo_invoice WHERE current_status = '6' AND
reviewcomplete_value > 0 AND NOT productid = 0 AND NOT
producttitle LIKE 'LIVE%' AND MONTH(invoicedate) = '12'
GROUP BY producttitle ORDER BY producttitle ASC) GROUP BY
productid")

                    rating_value_data = cursor.fetchall()

                    user_rating_array = []
                    for product_reviewed in products_reviewed:
                        product_id =
product_reviewed["productid"]
                        rating_value = 0

                        for rating_value_product in
rating_value_data:
                            if rating_value_product["productid"]
== product_id:
                                rating_value =
int(rating_value_product["reviewcomplete_value"])

```

```

        user_rating_array += [rating_value]

    u = user_logged_in_rating_array;
    v = user_rating_array;

    mean_u = Average(u)
    mean_v = Average(v)

    a = 0
    b = 0
    c = 0
    d = 0
    e = 0
    sim_triangle = 0
    simpangan_baku_u = 0
    simpangan_baku_v = 0

    for i in range(len(u)):
        a += pow((u[i] - v[i]), 2)
        b += pow(u[i], 2)
        c += pow(v[i], 2)
        d += pow((u[i] - mean_u), 2)
        e += pow((v[i] - mean_v), 2)

    f = try_div(math.sqrt(a), (math.sqrt(b +
math.sqrt(c))))
    sim_triangle = 1 - f

    simpangan_baku_u = math.sqrt(d / len(u))
    simpangan_baku_v = math.sqrt(e / len(v))

    sim_urp = 1 - (1 / (1 + math.exp(-abs(mean_u
- mean_v) * abs(simpangan_baku_u - simpangan_baku_v))))

    sim_itr = abs(sim_triangle * sim_urp)
    similarity_result = {
        "UserLoggedInID": user_id,
        "UserReviewedID": user_reviewed_id,
        "Similarity": sim_itr
    }
    similarity_result_array +=
[similarity_result]

    similarity_result_array_sorted =
sorted(similarity_result_array, key=lambda dct:
dct['Similarity'], reverse=True)

```

4.1.2 Implementasi *Weighted Sum*

Pada tahapan ini program telah mendapatkan nilai *similarity* antar *user* yang selanjutnya akan di hitung nilai prediksi produknya dengan algoritma *Weighted Sum*.

```

top_n_user = round((100 / 100) *
len(similarity_result_array_sorted))

        weighted_sum_result_array = []
        for product_reviewed in products_reviewed:
            product_id = product_reviewed["productid"]

            cursor.execute("SELECT buyerid,
reviewcomplete_value FROM sindo_invoice WHERE current_status
= '6' AND MONTH(invoicedate) = '12' AND buyerid IN (SELECT
buyerid FROM sindo_invoice WHERE current_status = '6' AND
reviewcomplete_value > 0 AND NOT productid = 0 AND NOT
producttitle LIKE 'LIVE%' AND MONTH(invoicedate) = '12' AND
NOT buyerid = " + str(user_id) + " GROUP BY buyerid ORDER BY
buyername ASC) AND productid =" + str(product_id) + " GROUP
BY buyerid")

            rating_value_data = cursor.fetchall()

            ws_pembilang = 0
            ws_penyebut = 0
            for i in range(top_n_user):
                similarity_value =
similarity_result_array_sorted[i]["Similarity"]
                user_reviewed_id =
similarity_result_array_sorted[i]["UserReviewedID"]

                rating_value = 0

                for rating_value_user in
rating_value_data:
                    if rating_value_user["buyerid"] ==
user_reviewed_id:
                        rating_value =
int(rating_value_user["reviewcomplete_value"])

                        ws_pembilang = ws_pembilang +
(rating_value * similarity_value)
                        ws_penyebut = ws_penyebut +
abs(similarity_value);

                weighted_sum_value = ws_pembilang /
ws_penyebut

                weighted_sum_result = {
                    "UserLoggedInID": user_id,
                    "ProductID": product_id,
                    "WeightedSum": weighted_sum_value
                }
                weighted_sum_result_array +=
[weighted_sum_result]

```

Setelah nilai prediksi pada setiap produk dengan *Weighted Sum* telah didapatkan, selanjutnya dilakukan pengurutan nilai dari tertinggi ke terendah sehingga di dapatkan produk yang direkomendasikan.

```

weighted_sum_result_array_sorted =
sorted(weighted_sum_result_array, key=lambda dct:
WeightedSum'], reverse=True)

        top_n_product = int((10 / 100) *
products_reviewed)

        recommendation_product_result_array = []
        for i in range(top_n_product):
            recommendation_product_result_array +=
weighted_sum_result_array_sorted[i]]

```

4.1.3 RESTful API

Model *User Based Collaborative Filtering* yang telah dibangun pada *pseudocode* program, selanjutnya *output* dari hasil tersebut disajikan dalam RESTful API sehingga nantinya para *developer* khususnya *developer* dari Sindomall dapat menggunakan model sistem rekomendasi produk sesuai dengan API yang telah dibangun.

Name	Description
user_id * required string (path)	user_id

Gambar 4. 1 Dokumentasi API “Get Predicted Value By UserID”

Name	Description
access_token * required string (query)	access_token
server_key * required string (formData)	server_key
user_id * required integer(\$int32) (formData)	user_id

Gambar 4. 2 Dokumentasi API “Get Product Recommendation By UserID”

Gambar 4.1 dan Gambar 4.2 adalah halaman dokumentasi API yang dibangun sesuai dengan konsep model yang telah dipaparkan pada penelitian ini. Terdapat 2 *endpoint* API, yang pertama “*Get Predicted Value By UserID*” merupakan API untuk mendapatkan nilai prediksi produk pada *user* sesuai dengan “*UserID*” yang diinputkan, adapun respon kembalian dari *endpoint* tersebut terdapat pada Gambar 4.3. Untuk *endpoint* yang kedua “*Get Product Recommendation By UserID*” merupakan API untuk mendapatkan hasil dari rekomendasi produk yaitu berupa postingan produk yang belum terjual, *endpoint* ini oleh peneliti sudah diintegrasikan pada sistem aplikasi Sindomall adapun respon kembalian dari *endpoint* kedua ini terdapat pada Gambar 4.4. Format kembalian dari kedua *endpoint* berupa *JavaScript Object Notation* (JSON), sehingga API ini fleksibel dapat diterapkan pada bahasa pemrograman apapun.

```
{
  "ProductID": 395,
  "UserLoggedInID": 881,
  "WeightedSum": 1.7749271255546915
},
{
  "ProductID": 536,
  "UserLoggedInID": 881,
  "WeightedSum": 1.580521465299293
},
{
  "ProductID": 1726,
  "UserLoggedInID": 881,
  "WeightedSum": 1.452769313969964
},
```

Gambar 4. 3 Contoh respon API “*Get Predicted Value By UserID*”

```

{
  "api_status": 200,
  "message": "Success Get Recommendation Product !",
  "data": [
    [
      {
        "post_id": "143726",
        "price": "60",
        "name": "Scindapsus sp.",
        "image": "https://sindomall.test/upload/photos/2022/04/04ye0R0PHWkYU3tTeHyH_11_204307f845a1a6838d55fb318bae90c_image_small.jpg"
      },
      {
        "post_id": "143672",
        "price": "70",
        "name": "Scindapsus sp.",
        "image": "https://sindomall.test/upload/photos/2022/04/LiKkgmuSn3mkF0d1ESoP_11_d514d52f773b1d1e1fe70493a88cad99_image_small.jpg"
      }
    ]
  ]
}

```

Gambar 4. 4 Contoh respon API “Get Product Recommendation By UserID”

4.2 Implementasi User Interface

Pembangunan *user interface* agar pengguna dapat memahami sistem rekomendasi produk dengan lebih mudah.

4.2.1 Implementasi Halaman Login

Halaman *login* merupakan halaman awal ketika *user* membuka aplikasi, pada halaman *login* ini *user* harus menginputkan *email* dan *password* yang sudah terdaftar di dalam *database* sistem seperti Gambar 4.5.



Gambar 4. 5 Tampilan halaman *login*

4.2.2 Implementasi Halaman Rekomendasi Produk

Dari hasil response API pada Gambar 4.4 selanjutnya diimplementasikan *interface*-nya pada halaman “*Recommendation*” untuk *user*. Gambar 4.6 merupakan tampilan hasil rekomendasi produk pada *user* yang telah melakukan *login* pada sistem. Pada halaman rekomendasi produk ditampilkan mengenai gambar dari produk dan harga dari setiap produk.



Gambar 4. 6 Tampilan halaman rekomendasi produk

4.3 Skenario Uji Coba

Skenario uji coba merupakan alur yang diimplementasikan untuk mengevaluasi pada sistem yang telah dibuat. Pengujian yang dilakukan pada

penelitian ini adalah menghitung nilai akurasi dan *error* dari hasil nilai prediksi produk.

Tahapan pertama dalam melakukan pengujian adalah memperoleh data *groundtruth* dengan tujuan sebagai pembanding dari hasil perhitungan nilai prediksi yang diambil dalam sistem yang sudah diimplementasikan. Adapun data *groundtruth* pada riset ini adalah berupa nilai prediksi pada 20 *user* secara acak dari total 264 *user* yang telah memberikan *rating* pada produk, data *rating user* tersebut diambil dari *database* aplikasi Sindomall pada bulan Desember 2021, dari data *rating* yang didapat akan di-generate dengan aplikasi Matlab untuk mendapatkan *groundtruth* nilai prediksi produk. *Groundtruth* yang diperoleh berupa tabel dengan data atribut “UserLoggedInID” dengan tipe data *integer*, atribut “ProductID” dengan tipe berupa *integer* serta *index* “WeightedSum” yang merupakan nilai prediksi dengan tipe data *float*. Tabel 4.1 merupakan salah satu sampel dari *user* yang diimplementasikan untuk data *groundtruth*.

Tabel 4. 1 Data sampel *groundtruth*

UserLoggedInID	ProductID	Nilai Prediksi
6624	2815	0.0845069849469635
6624	387	0.107536762168715
6624	1844	0.165158582296050
6624	2157	0.282859712238740
6624	872	0.0422399885213950
...
6624	836	0.0351995093802755
6624	231	0.354197832863011
6624	507	0.0360600121009402
6624	679	0.0634751132445122
6624	1499	0.156593303058968

4.1.1.3 Perhitungan Nilai Prediksi

Dalam perhitungan nilai prediksi dengan algoritma Weighted Sum juga sekaligus dilakukan perhitungan nilai *error*, adapun perhitungan nilai *error* pada penelitian ini penulis menggunakan *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE). Nilai MAE dapat diperoleh dengan melakukan perhitungan menggunakan persamaan 3.6 dan nilai RMSE dapat diperoleh dengan melakukan perhitungan menggunakan persamaan 3.7.

Pada proses pelatihan ini, diadakan pengukuran dengan merubah nilai parameter persentase *user* dengan nilai *similarity* antar *user* yang paling besar, dimana tingkat *error* dari setiap parameter akan dilakukan pemantauan pada perubahan nilai *error*-nya. Hal tersebut dilakukan untuk dapat mengetahui berapa jumlah persentase *user* yang memiliki nilai kemiripan terbesar dalam menghitung nilai prediksi yang memiliki nilai *error* paling minimal. Skenario perubahan parameter persentase *user* pada proses pelatihan dimulai pada persentase 10% dari total *user*, dan meningkat sebesar 10% dalam setiap pengujian sampai mencapai nilai 100% atau keseluruhan *user*. Berdasarkan scenario tersebut, maka model pelatihan yang diperoleh terdapat pada Tabel 4.4.

Tabel 4. 4 Skenario perubahan parameter persentase *user*

Model	Persentase <i>user</i> (%)
1	10
2	20
3	30
4	40
5	50
6	60
7	70
8	80
9	90
10	100

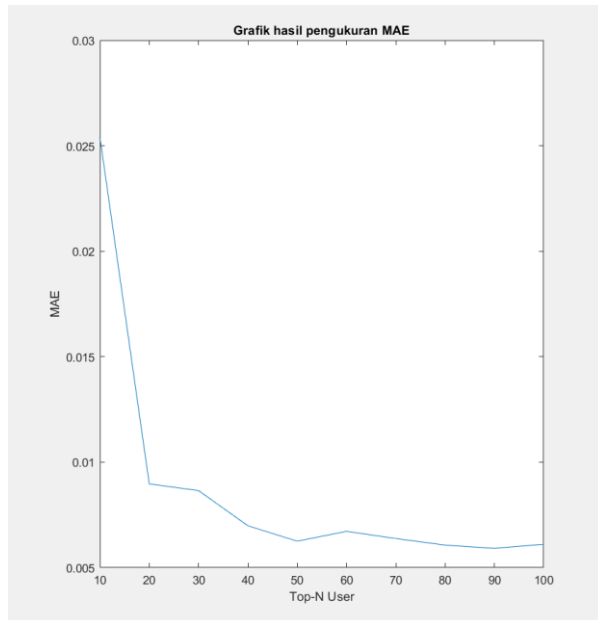
Setelah model skenario pengujian telah terbentuk, tahapan berikutnya adalah melakukan pengujian untuk dapat memilih model mana yang memiliki nilai *error* paling minimal dengan membandingkan hasil nilai prediksi dari sistem dengan data uji.

Setelah melakukan pengujian dengan skenario yang telah ditentukan, maka akan diperoleh tingkat *error* dari metode *User Based Collaborative Filtering* berdasarkan pengukuran *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE) sesuai dengan persamaan 3.6 dan 3.7.

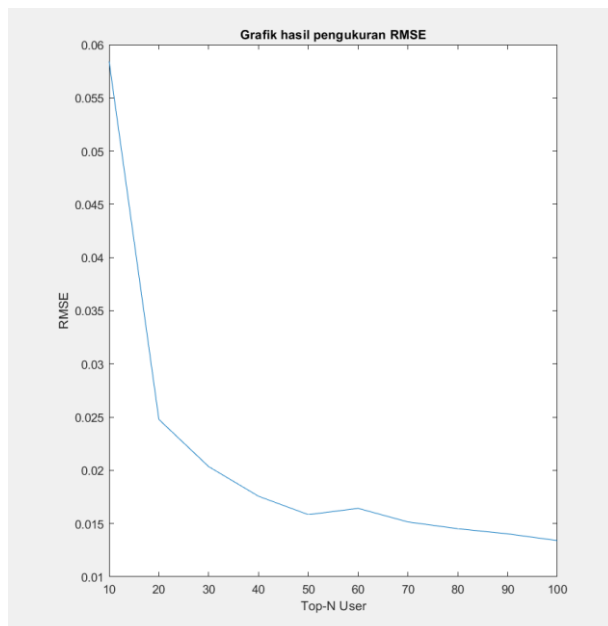
4.4 Hasil Uji Coba

Pada subbab hasil uji coba, akan dipaparkna hasil uji coba yang telah dilakukan sesuai dengan skenario uji coba yang dipaparkan pada subbab sebelumnya. Pengujian dilalukan pada model-model yang telah dibentuk pada Tabel 4.4. Pada tahap proses pelatihan terdapat 10 model yang telah ditentukan dengan mengkombinasi perubahan pada parameter persentase *user*, yang selanjutnya dilakukan proses pelatihan sehingga setiap model didapatkan nilai *error* terhadap nilai prediksi produk. Adapun hasil

pengukuran MAE dan RMSE pada masing-masing model adalah pada Gambar 4.6 dan Gambar 4.7.

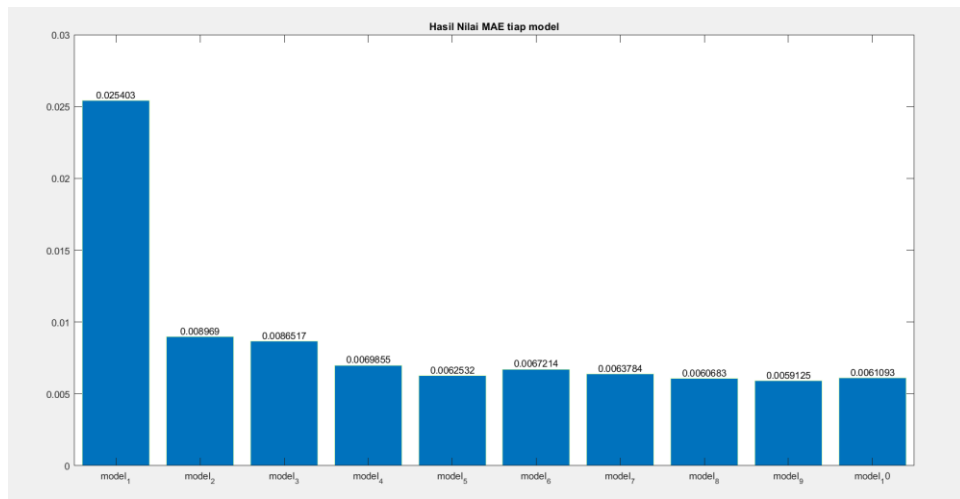


Gambar 4. 7 Grafik hasil pengukuran MAE pada tiap model




Gambar 4. 8 Grafik hasil pengukuran RMSE pada tiap model

Berdasarkan uji coba dalam memilih model dengan nilai *error* yang paling minimal pada tabel 4.1, maka dapat ditarik kesimpulan pada Gambar 4.8 dan Gambar 4.9.



Gambar 4. 9 Pengukuran MAE pada tiap model pelatihan



Gambar 4. 10 Pengukuran RMSE pada tiap model pelatihan

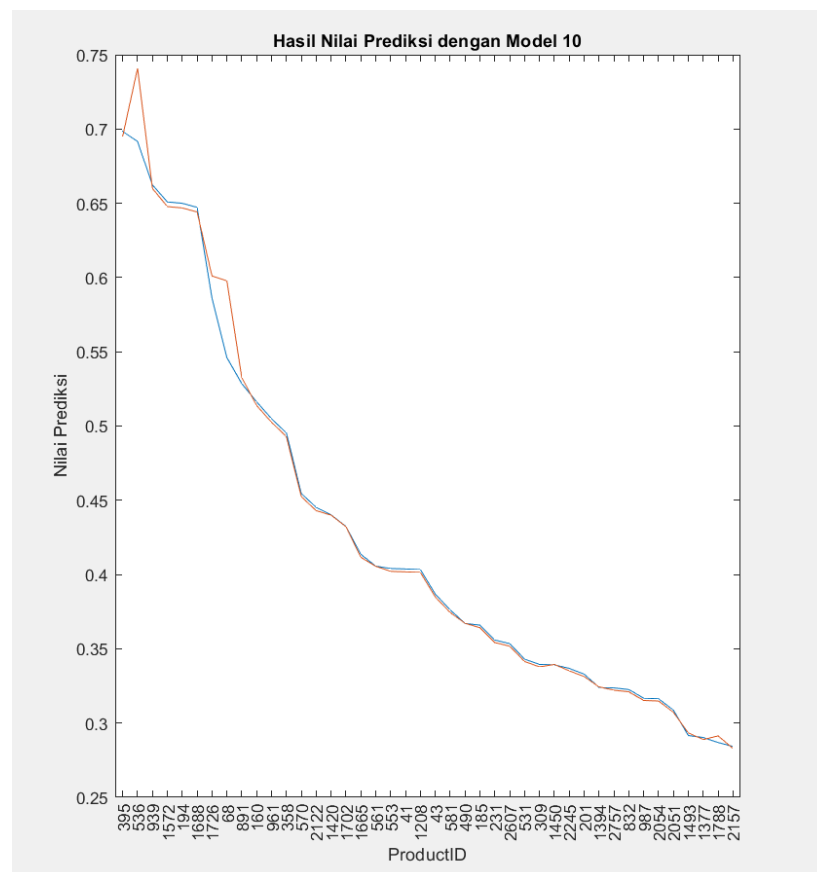
Berdasarkan grafik pada Gambar 4.8 dan Gambar 4.9 perbandingan hasil nilai *error* pada setiap model pelatihan dengan variasi perubahan nilai parameter persentase *user*, model 10 memiliki nilai RMSE yang paling

minimal dengan nilai 0.013399 dibandingkan dengan nilai model lainnya. Oleh karena itu, parameter yang akan digunakan pada tahap uji coba adalah sesuai dengan model 10 sesuai pada Tabel 4.5.

Tabel 4. 5 Hasil model yang digunakan pada tahap uji coba

Model	Persentase <i>user</i> (%)
10	100

Data yang akan digunakan pada tahap uji coba merupakan sama dengan data yang digunakan pada tahap pelatihan. Adapun hasil dari uji coba pengukuran nilai prediksi menggunakan model 10 terhadap data uji salah satu *user* dengan ID 6624 ada pada Gambar 4.10.



Gambar 4. 11 Sampel hasil perbandingan hasil prediksi produk dengan data *groundtruth* pada *user* dengan ID 6624

Tabel 4. 6 Sampel hasil perhitungan nilai prediksi pada *user* dengan ID 6624

User ID	Product ID	Nilai Prediksi	Nilai Aktual
6624	395	0.698378618061853	0.695020703282443
6624	536	0.691609239954889	0.740901720318779
6624	939	0.662347837842095	0.659941575988402
6624	1572	0.650917320832368	0.647787607471637
6624	194	0.649987387519991	0.646862145425609
6624	1688	0.647253344019953	0.644141247638854
6624	1726	0.586157133227591	0.600997000908553
6624	68	0.546105868753410	0.597808602271507
6624	891	0.528583617369766	0.532655616707886
6624	160	0.516288957802623	0.513806558890321
6624	961	0.504922873013092	0.502495124032950
6624	358	0.495273396601240	0.492892043828855
6624	570	0.454633900779681	0.452447949126571
6624	2122	0.445166463615163	0.443026032896337
6624	1420	0.440215404392039	0.439990257781758
6624	1702	0.432388758442872	0.432201243583373
6624	1665	0.413596047870877	0.411607412700880
6624	561	0.405618914281552	0.405560113063947
6624	553	0.404059232857387	0.402116452201337
6624	41	0.403768673720325	0.401827290118532
6624	1208	0.403394133172160	0.401454550420521
6624	43	0.386782707656397	0.384922995264193
6624	581	0.376212453964920	0.374403565023170
6624	490	0.367082811637095	0.367209298091913
6624	185	0.365902158385215	0.364142842974228
6624	231	0.355909100070144	0.354197832863011
6624	2607	0.353478404923001	0.351778824882324
6624	531	0.343051052825519	0.341401609141845
6624	309	0.339473842601996	0.337841598710481
6624	1450	0.339178209668113	0.339438865859722
6624	2245	0.336808447481514	0.335189019231022
6624	201	0.332903534704676	0.331302881892015
6624	1394	0.324033440210626	0.324366914847526
6624	2757	0.323674210936016	0.322117934170796
6624	832	0.322579733516727	0.321028719171930
6624	987	0.316753342725811	0.315230342588839
6624	2054	0.316342434813483	0.314821410386700
6624	2051	0.308685543186407	0.307201334304794
6624	1493	0.291560100900166	0.293335573763094
6624	1377	0.290280098230495	0.288884385637343
6624	1788	0.286871889316137	0.291369091989498
6624	2157	0.284226317296316	0.282859712238740

Dari hasil tabel pengukuran nilai prediksi pada Tabel 4.6, selanjutnya data-data tersebut dihitung nilai MAE dan RMSE pada seluruh data uji yang ditampilkan pada Tabel 4.7.

Tabel 4.7 Hasil perhitungan nilai MAE dan RMSE pada data uji

User ID	MAE	RMSE
481	0.005491635088760	0.012411641149291
644	0.006237039453667	0.014122151817566
703	0.015334498182913	0.023582001972058
1001	0.005871580756359	0.013233925891327
1011	0.005471407229314	0.012371107929966
1224	0.006048661127732	0.012696901956723
2669	0.005879764269807	0.013248615900930
3721	0.006018842716870	0.013438112554318
3876	0.005245937176106	0.011846455485858
3973	0.003618292769555	0.009913514777409
4517	0.005978100232473	0.013502852095531
4811	0.006571222684326	0.014789041877031
5035	0.005681433461807	0.014828236666735
5127	0.005262750417987	0.011880887938167
5344	0.005861303726034	0.013217358258767
5451	0.006194328025977	0.014026922473032
6037	0.007427294663996	0.015358599741547
6561	0.004175673769774	0.010530450148534
6624	0.004468373926925	0.011436925646037
6905	0.005348047212621	0.011550455281337

Dari perhitungan nilai MAE dan RMSE diatas selanjutnya akan dihitung nilai rata-ratanya. Adapun perhitungan rata-rata nilai MAE dan RMSE adalah sebagai berikut.

$$MAE = \frac{0.122186186893004}{20} = 0.006109309344650$$

$$RMSE = \frac{0.267986159562163}{20} = 0.013399307978108$$

Tabel 4. 8 Hasil perhitungan nilai rata-rata MAE dan RMSE pada data uji

MAE	RMSE
0.006109309344650	0.013399307978108

Setelah nilai prediksi dari produk yang direkomendasikan sesuai dengan “ProductID” yang telah didapatkan, selanjutnya akan diimplementasikan tahapan selanjutnya dengan menghitung nilai akurasi, presisi, *recall*, dan *F-score* (F_1) berdasarkan output produk yang didapatkan. Output produk dikatakan benar apabila memiliki “ProductID” yang sama dengan hasil perhitungan nilai prediksi, dan output produk dikatakan relevan apabila memiliki “ProductID” yang sama dengan hasil perhitungan nilai prediksi dan berstatus belum terjual. Adapun contoh dari output produk yang direkomendasikan pada salah satu user ada pada Tabel 4.9.

Tabel 4. 9 Sampel hasil analisis output rekomendasi produk pada *user* dengan ID 6624

User ID	Product ID	Produk yang benar	Produk yang relevan
6624	395	v	v
6624	536	v	v
6624	939	v	v
6624	1572	v	v
6624	194	v	v
6624	1688	v	v
6624	1726	v	v
6624	68	v	v
6624	891	v	v
6624	160	v	v
6624	961	v	v
6624	358	v	v
6624	570	v	-
6624	2122	v	-
6624	1420	v	v
6624	1702	v	-
6624	1665	-	-
6624	561	-	-
6624	553	v	v
6624	41	v	v
6624	1208	v	v
6624	43	v	v
6624	581	v	v
6624	490	v	v

6624	185	v	v
6624	231	v	v
6624	2607	v	v
6624	531	v	v
6624	309	-	-
6624	1450	v	v
6624	2245	v	v
6624	201	v	v
6624	1394	v	v
6624	2757	v	v
6624	832	v	v
6624	987	v	v
6624	2054	v	v
6624	2051	v	v
6624	1493	v	v
6624	1377	v	v
6624	1788	v	v
6624	2157	v	v

Berdasarkan Tabel 4.9 diatas, maka selanjutnya akan dihitung nilai presisi dan *recall*-nya berdasarkan persamaan 3.8 dan 3.9. Berikut merupakan sampel nilai presisi dan *recall* dari salah satu data user dengan ID 6624.

$$Presisi = \frac{39}{42} = 0.928$$

$$Recall = \frac{36}{42} = 0.857$$

Dari nilai Presisi dan Recall yang telah didapatkan, maka selanjutnya akan dihitung nilai F-score (F_1), seperti yang didefinisikan dalam persamaan 3.10. Berikut merupakan nilai F-score (F_1) dari salah satu data user dengan ID 6624.

$$F_1 = \frac{2 * 0.928 * 0.857}{0.928 + 0.857} = 0.891$$

Berikut merupakan hasil perhitungan nilai akurasi dari salah satu data user dengan ID 6624 dengan menggunakan persamaan 3.11.

$$Akurasi = \frac{36}{36 + 3 + 0 + 3} = 0.857$$

Tabel 4. 10 Hasil perhitungan nilai akurasi, presisi, *recall*, dan *F-score* (F₁) pada data uji

User ID	Akurasi	Presisi	<i>Recall</i>	F-score (F ₁)
481	0.857	0.928	0.857	0.891
644	0.857	0.928	0.857	0.891
703	0.833	0.904	0.857	0.879
1001	0.857	0.928	0.857	0.891
1011	0.880	0.928	0.904	0.915
1224	0.833	0.857	0.857	0.857
2669	0.928	0.952	0.952	0.952
3721	0.857	0.928	0.857	0.891
3876	0.809	0.904	0.904	0.904
3973	0.857	0.928	0.857	0.891
4517	0.857	0.928	0.857	0.891
4811	0.809	0.952	0.880	0.914
5035	0.857	0.928	0.857	0.891
5127	0.857	0.928	0.857	0.891
5344	0.809	0.952	0.880	0.914
5451	0.857	0.928	0.857	0.891
6037	0.857	0.928	0.857	0.891
6561	0.809	0.880	0.880	0.880
6624	0.857	0.928	0.857	0.891
6905	0.857	0.928	0.857	0.891

Berdasarkan *output* hasil nilai akurasi, presisi, *recall*, dan *F-score* (F₁)

diatas selanjutnya akan dihitung nilai rata-ratanya. Adapun perhitungan nilai rata-rata akurasi, presisi, *recall*, dan *F-score* (F₁) adalah sebagai berikut.

$$Akurasi = \frac{16,994}{20} = 0,849$$

$$Presisi = \frac{18,465}{20} = 0,923$$

$$Recall = \frac{17,398}{20} = 0,869$$

$$F_1 = \frac{17,907}{20} = 0,895$$

Tabel 4. 11 Hasil perhitungan nilai rata-rata akurasi, presisi, *recall* dan *F-score* (F1) pada data uji

Akurasi	Presisi	<i>Recall</i>	<i>F-score</i> (F1)
0,849	0,923	0,869	0,895

4.5 Pembahasan

Mengacu pada proses uji coba yang selesai dilakukan, maka diperoleh nilai akurasi dan *error* dari perhitungan nilai prediksi pada model yang memiliki nilai *error* paling minimal pada data rating 20 *user* yang dipilih secara acak sebelumnya. Pada proses pelatihan parameter persentase *user* yaitu untuk mendapatkan nilai *similarity* pada *user* yang memiliki nilai terdekat, parameter tersebut memiliki pengaruh yang berbeda pada hasil akhir. Jika nilai persentase terlalu kecil maka nilai prediksi yang didapatkan tidak terlalu optimal sehingga mendapatkan nilai *error* yang tinggi. Sedangkan jika nilai presentase tinggi maka data yang digunakan untuk menghitung nilai prediksi akan semakin lengkap sehingga akan mendapatkan nilai *error* yang rendah.

Pada perhitungan nilai *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE) mendapatkan kesimpulan bahwa metode *User Based Collaborative Filtering* dengan menggunakan algoritma ITR dalam perhitungan nilai *similarity* dan metode *Weighted Sum* dalam perhitungan nilai prediksi dengan menggunakan parameter persentase *user* sebesar 100% pada data uji memperoleh hasil akurasi RMSE sebesar 0.013 dan *error* MAE sebesar 0.006. Pada pengevaluasian hasil rekomendasi produk yang diberikan

oleh sistem hasil dari menghitung besaran akurasi, presisi, *recall*, dan *F-Score* (F_1), output produk dikatakan benar apabila memiliki “ProductID” yang sama dengan hasil perhitungan *top 10* nilai prediksi produk, dan output produk dikatakan relevan apabila memiliki “ProductID” yang sama dengan hasil perhitungan *top 10* nilai prediksi dan berstatus belum terjual. Adapun hasil dari perhitungan diperoleh nilai Akurasi sebesar 0,849, nilai Presisi sebesar 0.923, nilai *Recall* sebesar 0.869, dan nilai *F-Score* (F_1) sebesar 0.895.

Walaupun nilai MAE dan RMSE yang didapatkan kecil sedangkan apabila dilakukan perhitungan berdasarkan persentase absolut *error* rata-ratanya didapatkan hasil yang tidaklah kecil. Hal ini disebabkan karena dalam perhitungan RMSE tidak dapat terlepas dari konsep variansi, sehingga nilainya akan sangat rentan terhadap selisih antar rata-rata data yang digunakan. Oleh karena itu, nilai MAE dan RMSE yang kecil dikarenakan data nilai prediksi yang digunakan merupakan nilai satuan sehingga selisih nilai prediksi dengan data nilai pada data *groundtruth* akan rentan menjadi nilai yang lebih kecil.

Berdasarkan grafik yang ditunjukkan pada Gambar 4.9, masih dapat memungkinkan untuk menghasilkan rekomendasi produk pada *user* tertentu dengan melakukan perankingan dari produk yang memiliki nilai prediksi tertinggi ke terendah. Masih terdapatnya nilai *error* yang dapat ditoleransi dikarenakan masih dominannya produk yang belum diberi oleh para *user*,

sehingga perhitungan nilai *similarity* antar *user* tidak dapat dilakukan secara maksimal.

4.6 Integrasi Islam

Menurut Kahfi pada tahun 2005, dalam ajaran agama Islam sistem pendukung keputusan tidaklah dilarang asalkan informasi didalamnya tidak terdapat informasi yang salah atau batil dan tidak mendorong munculnya kemungkaran dan dosa, sehingga dapat dikatakan sistem rekomendasi yang juga merupakan sistem pendukung keputusan haruslah memberi informasi yang baik dan benar. Sebagaimana Allah *subhanahu wa ta'ala* telah berfirman dalam surah Hud ayat 120:

وَكُلًّا نَقُصُّ عَلَيْكَ مِنْ أَنْبَاءِ الرُّسُلِ مَا نُثَبِّتُ بِهِ فُؤَادَكَ ۖ وَجَاءَكَ فِي هَذِهِ الْحَقُّ وَمَوْعِظَةٌ وَذِكْرَىٰ لِلْمُؤْمِنِينَ

“Semua kisah rasul-rasul Kami ceritakan kepadamu (Nabi Muhammad), yaitu kisah-kisah yang dengannya Kami teguhkan hatimu. Di dalamnya telah di berikan kepadamu (segala) kebenaran, nasihat, dan peringatan bagi orang-orang mukmin.” (Q.S. Hud: 120) (Balitbang Diklat Kementerian Agama RI, 2019).

Tafsir Jalalain karangan Jalaluddin As-Suyuthi dan Jalaluddin Muhammad Ibnu Ahmad Al-Mahally menafsirkan lafal وَكُلًّا ini di-*nashab*-kan pada alamat *naqsh* meskipun *tanwin*-nya adalah pergantian dari *mudhaf ilaih*, sehingga dapat diartikan semua kisah rasul-rasul yang diperlukan (informasi), sedangkan lafal مَا di sini menjadi *badal* daripada lafal وَكُلًّا dimaksudkan kisah-kisah para rasul (informasi) dapat dimanfaatkan untuk memberikan sebuah kebenaran serta dapat mempertebal keimanan (Al-Mahalli & Al-Imam Jalaluddin Abdurrahman bin Abu Bakar As-Sayuthi, Najib Junaidi, 2010).

Pada ayat di atas, terdapat potongan kalimat *وَجَاءَكَ فِي هَذِهِ الْحَقُّ* yang dalam bahasa Arab mempunyai arti “*dan dalam surat ini telah datang kepadamu kebenaran*”. Jika dikaitkan dengan informasi memiliki maksud tentang berita yang benar. Menurut hasil penelitian Kahfi pada tahun 2005 istilah “surat” dapat diartikan sebagai “berita yang benar”, sedangkan pada konteks ayat diatas berita yang benar tersebut ditujukan sebagai pelajaran untuk membuat jera orang-orang kafir (Kahfi, 2005).

Jika dikaitkan dengan sistem rekomendasi produk dimana didalamnya memberikan informasi berupa daftar produk bagi pembeli berupa gambar dan harga dari produk, sistem rekomendasi produk sah dilakukan dan tidak melanggar ajaran Islam karena didalamnya tidak mengandung hal salah atau batil dan tidak mendorong munculnya kemungkaran dan dosa.

Di masa sekarang ini, sistem rekomendasi produk pada *marketplace* akan sangat berpengaruh dalam *e-commerce* karena dapat mempermudah dan mempengaruhi keputusan pembeli untuk membeli sebuah produk. Jika *marketplace* dapat diimbangi dengan teknik pemasaran yang baik maka akan lebih memberi keuntungan bagi para pengusaha salah satunya dengan sistem rekomendasi produk, yang dapat membantu pembeli dalam menemukan produk yang berkaitan dengan karakteristiknya, sehingga dapat mempengaruhi keputusan konsumen untuk membeli suatu produk.

Allah *subhanahu wa ta'ala* berfirman dalam Al-Qur'an Surah Nuh ayat 8:

تُمْ إِلَيَّ دَعْوُهُمْ جَهَارًا

“Kemudian, sesungguhnya aku menyeru mereka dengan cara terang-terangan.” (Q.S. Nuh: 8) (Balitbang Diklat Kementerian Agama RI, 2019).

Menurut TafsirAl-Qurtubi karangan Ahmad Mustofa Al-Maraghi berdasarkan ayat di atas Allah menganjurkan untuk mengajak secara terang-terangan, lafal *جَهْرًا* inilah yang mengandung arti untuk menyeru dengan suara keras. Jika dikaitkan pada sistem rekomendasi produk dalam *marketplace* hal tersebut dapat diartikan sebagai mengajurkan atau mempromosikan pada pembeli untuk dapat membeli produk yang tentunya tanpa ada unsur paksaan di dalamnya (Abu Abdullah Muhammad, 2021).

Adanya penelitian ditujukan bagi para pengusaha dalam bidang *marketplace* serta khususnya bagi para konsumen *marketplace* itu sendiri. Bagi pengusaha sistem rekomendasi produk dapat dijadikan sebagai strategi pemasaran produk sehingga nantinya dapat meningkatkan penghasilan perusahaan, serta dengan mengimplementasikan metode *User Based Collaborative Filtering* dapat meningkatkan loyalitas pembeli. Bagi konsumen tentunya dapat memudahkan menemukan produk yang sesuai dengan perilakunya dalam memberikan *rating* pada suatu produk tertentu, sehingga mampu mempengaruhi keputusan konsumen dalam membeli sebuah produk.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Dari penelitian yang telah selesai dilakukan untuk membangun sistem rekomendasi produk pada aplikasi *marketplace* dengan menggunakan metode *User Based Collaborative Filtering* dikolaborasikan dengan algoritma ITR untuk menghitung nilai *similarity* dan algoritma *Weighted Sum* untuk menghitung nilai prediksi serta dilakukan pengujian dengan data uji yang didapatkan dari *database* aplikasi *marketplace* Sindomall pada bulan Desember tahun 2021 yang disajikan dalam bentuk nilai prediksi pada setiap *user* yang telah memberikan *rating* pada suatu produk. Pembuatan beberapa model yang ditujukan untuk mencari nilai parameter persentase *user* dengan nilai *error* paling minimal, yang selanjutnya diperoleh model terpilih dengan nilai parameter persentase *user* sebesar 100% yang akan digunakan sebagai parameter dalam pengujian untuk mengukur nilai *error* dan akurasi dengan data uji berupa data *rating* 20 *user* yang diambil secara acak. Pada tahap pengujian *error* sistem didapatkan nilai MAE sebesar 0.006 dan nilai RMSE sebesar 0.013, sedangkan pada tahap pengujian akurasi sistem didapatkan nilai akurasi sebesar 0.849, nilai presisi sebesar 0.923, nilai *recall* sebesar 0.869, dan nilai *F-score* (F_1) sebesar 0.895. Dengan nilai *error* dan akurasi sistem yang telah diperoleh dapat disimpulkan bahwa sistem dapat memberikan rekomendasi produk pada *user* dengan baik, hal tersebut

dikarenakan nilai *error* yang didapat terbilang rendah karena mendekati nilai 0 dan nilai akurasi sistem yang dapat dikatakan tinggi.

5.2 Saran

Berdasarkan hasil penilaian dan pengujian sistem yang telah dilakukan pada penelitian ini, peneliti menyadari bahwa penelitian yang dilakukan masih memiliki banyak sekali kekurangan sehingga peneliti mengharapkan adanya perbaikan untuk dapat meningkatkan performa sistem. Berikut merupakan *point-point* yang perlu dipertimbangkan pada penelitian selanjutnya:

1. Penambahan kriteria lain dalam pengambilan data karakteristik pembeli tidak hanya terbatas pada perilaku pembeli dalam memberi *rating* pada produk sehingga akurasi sistem menjadi lebih baik.
2. Menggunakan algoritma perhitungan nilai *similarity* yang dapat mengatasi *sparsity problem*, yaitu permasalahan terkait nilai *rating* produk yang kosong sehingga dapat meningkatkan akurasi sistem.

DAFTAR PUSTAKA

- Abu Abdullah Muhammad. (2021). Konsep Dakwah Nabi Nuh Dalam Kitab TafsirAl-Qurtubi. *Dakwatuna*, 7.
- Al-Mahalli, A.-I. J. M., & Al-Imam Jalaluddin Abdurrahman bin Abu Bakar As-Sayuthi, Najib Junaidi, L. (2010). *Terjemah Tafsir Jalalain*. 1–402.
- Arif, Y. M., Harini, S., Nugroho, S. M. S., & Hariadi, M. (2021). An Automatic Scenario Control in Serious Game to Visualize Tourism Destinations Recommendation. *IEEE Access*, 9, 89941–89957. <https://doi.org/10.1109/ACCESS.2021.3091425>
- Arif, Y. M., Nurhayati, H., Kurniawan, F., Nugroho, S. M. S., & Hariadi, M. (2020). Blockchain-Based Data Sharing for Decentralized Tourism Destinations Recommendation System. *International Journal of Intelligent Engineering and Systems*, 13(6), 472–486. <https://doi.org/10.22266/ijies2020.1231.42>
- Badriyah, T., Restuningtyas, I., & Setyorini, F. (2017). Sistem Rekomendasi Collaborative Filtering Berbasis User Algoritma Adjusted Cosine Similarity. *Prosiding Seminar Nasional Sisfotek*, 10(1), 38–45.
- Balitbang Diklat Kementerian Agama RI, L. P. M. A.-Q. (2019). *Al-Qur'an dan Terjemahannya Edisi Penyempurnaan* (p. 650). Lajnah Pentashihan Mushaf Al-Qur'an.
- Berat Ujkani, Daniela Minkovska, & Lyudmila Stoyanova. (2020). *A recommender system for WordPress themes using item-based collaborative filtering technique*. 2020–2022.
- Bobadilla, J., Alonso, S., & Hernando, A. (2020). Deep learning architecture for collaborative filtering recommender systems. *Applied Sciences (Switzerland)*, 10(7). <https://doi.org/10.3390/app10072441>
- BPS. (2020). *Statistik E-Commerce 2020* (L. Anggraini, S. Utoyo, & E. Sari (eds.)). Badan Pusat Statistik Indonesia. <https://www.bps.go.id/>
- Chaudhari, S., Sawant, A., & Patil, R. (2017). Self-tuning approach for implementing a multidimensional recommendation system using PID. *2017 Innovations in Power and Advanced Computing Technologies, i-PACT 2017, 2017-Janua*, 1–4. <https://doi.org/10.1109/IPACT.2017.8244895>
- Edeling, A., & Himme, A. (2018). When does market share matter? New empirical generalizations from a meta-analysis of the market share-performance relationship. *Journal of Marketing*, 82(3), 1–24.

<https://doi.org/10.1509/jm.16.0250>

- Eide, S., & Zhou, N. (2018). Deep neural network marketplace recommenders in online experiments. *RecSys 2018 - 12th ACM Conference on Recommender Systems*, 387–391. <https://doi.org/10.1145/3240323.3240387>
- Faizin, A., & Surjandari, I. (2020). Product recommender system using neural collaborative filtering for marketplace in indonesia. *IOP Conference Series: Materials Science and Engineering*, 909(1). <https://doi.org/10.1088/1757-899X/909/1/012072>
- Fakhri, A. A., Baizal, Z. K. A., & Setiawan, E. B. (2019). Restaurant Recommender System Using User-Based Collaborative Filtering Approach: A Case Study at Bandung Raya Region. *Journal of Physics: Conference Series*, 1192(1). <https://doi.org/10.1088/1742-6596/1192/1/012023>
- Firmansyah, A. A. (2018). *Pengembangan Pencarian Produk Terkait Menggunakan Euclidean Distance Dan Cosine Simi- Larity Pada Aplikasi Halal Nutrition Food*.
- Fkih, F. (2021). Similarity measures for Collaborative Filtering-based Recommender Systems: Review and experimental comparison. *Journal of King Saud University - Computer and Information Sciences*, xxxx. <https://doi.org/10.1016/j.jksuci.2021.09.014>
- Guo, Y. Y., & Liu, Q. C. (2010). E-commerce personalized recommendation system based on multi-agent. *Proceedings - 2010 7th International Conference on Fuzzy Systems and Knowledge Discovery, FSKD 2010*, 4(Fskd), 1999–2003. <https://doi.org/10.1109/FSKD.2010.5569483>
- Handoko, D., Mesran, M., Nasution, S. D., Yuhandri, Y., & Nurdianto, H. (2017). Application Of Weight Sum Model (WSM) In Determining Special Allocation Funds Recipients. *The IJICS (International Journal of Informatics and Computer Science)*, 1(2), 31–35. <http://ejurnal.stmik-budidarma.ac.id/index.php/ijics/article/view/528>
- Huang, P., Lurie, N. H., & Mitra, S. (2009). Searching for experience on the web: An empirical examination of consumer behavior for search and experience goods. *Journal of Marketing*, 73(2), 55–69. <https://doi.org/10.1509/jmkg.73.2.55>
- Iftikhar, A., Ghazanfar, M. A., Ayub, M., Mehmood, Z., & Maqsood, M. (2020). An Improved Product Recommendation Method for Collaborative Filtering. *IEEE Access*, 8, 123841–123857. <https://doi.org/10.1109/ACCESS.2020.3005953>
- Janan, A. (2020). Sistem Rekomendasi Pada Game Wisata Di Kota Batu

Menggunakan Metode User Based Collaborative Filtering. *Skripsi. Sains Dan Teknologi. Teknik Informatika. Universitas Islam Negeri Maulana Malik Ibrahim. Malang.*

Jia, Z., Yang, Y., Gao, W., & Chen, X. (2015). User-based collaborative filtering for tourist attraction recommendations. *Proceedings - 2015 IEEE International Conference on Computational Intelligence and Communication Technology, CICT 2015, May 2016, 22–25.* <https://doi.org/10.1109/CICT.2015.20>

Kahfi, A. S. (2005). *Informasi dalam Perspektif Islam.*

Kato, Y., & Yamamoto, K. (2020). Development of sightseeing spot recommendation system considering users' visit frequency. *2020 Joint 11th International Conference on Soft Computing and Intelligent Systems and 21st International Symposium on Advanced Intelligent Systems, SCIS-ISIS 2020.* <https://doi.org/10.1109/SCISISIS50064.2020.9322776>

Khusna, A. N., Delasano, K. P., & Saputra, D. C. E. (2021). Penerapan User-Based Collaborative Filtering Algorithm. *MATRIK: Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer, 20(2), 293–304.* <https://doi.org/10.30812/matrik.v20i2.1124>

Koohi, H., & Kiani, K. (2016). User based Collaborative Filtering using fuzzy C-means. *Measurement: Journal of the International Measurement Confederation, 91, 134–139.* <https://doi.org/10.1016/j.measurement.2016.05.058>

Koren, Y., & Bell, R. (2011). Advances in Collaborative Filtering - Recommender Systems Handbook. *Recommender Systems Handbook, 145–186.* <http://www.springerlink.com/index/10.1007/978-0-387-85820-3>

Kotler, & Keller. (2012). Marketing management. In *Soldering & Surface Mount Technology* (Vol. 13, Issue 3). N.J: Pearson Prentice Hall. <https://doi.org/10.1108/ssmt.2001.21913cab.040>

Kurniawan, F., Umayah, B., Hammad, J., Nugroho, S. M. S., & Hariadi, M. (2017). Market Basket Analysis to Identify Customer Behaviours by Way of Transaction Data. *Knowledge Engineering and Data Science, 1(1), 20.* <https://doi.org/10.17977/um018v1i12018p20-25>

Lidwina, A. (2021). Penggunaan E-Commerce Indonesia Tertinggi di Dunia. *2KataData, April, 2021.* <https://databoks.katadata.co.id/datapublish/2021/06/04/penggunaan-e-commerce-indonesia-tertinggi-di-dunia>

Liu, Y., Nie, J., Xu, L., Chen, Y., & Xu, B. (2018). Clothing Recommendation

System Based on Advanced User-Based Collaborative Filtering Algorithm. *Lecture Notes in Electrical Engineering*, 473, 436–443. https://doi.org/10.1007/978-981-10-7521-6_53

Manouselis, N., Verbert, K., Drachsler, H., & Santos, O. C. (2010). Workshop on recommender systems for Technology Enhanced Learning. *RecSys'10 - Proceedings of the 4th ACM Conference on Recommender Systems*, 17(6), 377. <https://doi.org/10.1145/1864708.1864797>

Mardhia, M. M., & Normawati, D. (2018). Marketplace seller recommender with user-based multi criteria decision making. *Proceeding of 2018 12th International Conference on Telecommunication Systems, Services, and Applications, TSSA 2018*, 1–5. <https://doi.org/10.1109/TSSA.2018.8708794>

Nasution, S. D., Utama, A. P., & Tetap. (2017). Penerapan Weighted Sum Model (Wsm) Dalam Penentuan Peserta Jaminan. *Jurnal Riset Sistem Informasi Dan Teknik Informatika*, 2(1), 40–47.

Pamungkas, D. P., & Hariri, F. R. (2016). Pengenalan Citra Tanda Tangan Menggunakan Metode 2D-LDA dan Euclidean Distance. *Creative Information Technology Journal*, 3(4), 269. <https://doi.org/10.24076/citec.2016v3i4.83>

Pangesti, W. E., Suryadithia, R., Faisal, M., & ... (2021). Collaborative Filtering Based Recommender Systems For Marketplace Applications. *International Journal of ...*, 1201–1209. <https://ijersc.org/index.php/go/article/view/184>

Polatidis, N., & Georgiadis, C. K. (2017). A dynamic multi-level collaborative filtering method for improved recommendations. *Computer Standards and Interfaces*, 51, 14–21. <https://doi.org/10.1016/j.csi.2016.10.014>

Prasetya, C. S. D. (2017). Sistem Rekomendasi Pada E-Commerce Menggunakan K-Nearest Neighbor. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 4(3), 194. <https://doi.org/10.25126/jtiik.201743392>

Prasetyo, B., Haryanto, H., Astuti, S., Astuti, E. Z., & Rahayu, Y. (2019). Implementasi Metode Item-Based Collaborative Filtering dalam Pemberian Rekomendasi Calon Pembeli Aksesoris Smartphone. *Eksplora Informatika*, 9(1), 17–27. <https://doi.org/10.30864/eksplora.v9i1.244>

Prihastomo, Y., Meyliana, Hidayanto, A. N., & Prabowo, H. (2018). The Key Success Factors in E-Marketplace Implementation: A Systematic Literature Review. *Proceedings of 2018 International Conference on Information Management and Technology, ICIMTech 2018, September*, 443–448. <https://doi.org/10.1109/ICIMTech.2018.8528189>

Purnawati, N. W., & Setyohadi, D. B. (2017). The Analysis of Implementation

- Business Model Canvas At The E-Marketplace Dipeta Company. *Scientific Journal of Informatics*, 4(2), 125–133. <https://doi.org/10.15294/sji.v4i2.9945>
- Rachbini, W., Hatta, I. H., & Evi, T. (2019). Determinants of trust and customer loyalty on C2C e-marketplace in Indonesia. *International Journal of Management*, 10(3), 119–129. <https://doi.org/10.34218/IJM.10.3.2019.012>
- Setiadi, J. N. (2003). *Perilaku Konsumen Konsep dan Implikasi untuk Strategi dan Penelitian Pemasaran* (Kencana Prenada Media Group (ed.); 1st ed.).
- Silveira, T., Zhang, M., Lin, X., Liu, Y., & Ma, S. (2019). How good your recommender system is? A survey on evaluations in recommendation. *International Journal of Machine Learning and Cybernetics*, 10(5), 813–831. <https://doi.org/10.1007/s13042-017-0762-9>
- Subawa, N. S., & Mimaki, C. A. (2019). E-Marketplace Acceptance of MSMEs in bali based on performance expectancy and task technology fit. *PervasiveHealth: Pervasive Computing Technologies for Healthcare*, 157–160. <https://doi.org/10.1145/3377817.3377838>
- Sun, S. B., Zhang, Z. H., Dong, X. L., Zhang, H. R., Li, T. J., Zhang, L., & Min, F. (2017). Integrating triangle and jaccard similarities for recommendation. *PLoS ONE*, 12(8), 1–16. <https://doi.org/10.1371/journal.pone.0183570>
- Suryanto, A. A. (2019). Penerapan Metode Mean Absolute Error (Mea) Dalam Algoritma Regresi Linear Untuk Prediksi Produksi Padi. *Saintekbu*, 11(1), 78–83. <https://doi.org/10.32764/saintekbu.v11i1.298>
- Teruya, H. S., Marcal, I., Correia, R. C. M., Garcia, R. E., Eler, D. M., & Nunes, J. O. R. (2020). URecommender: An API for Recommendation Systems | URecommender: Uma API para Sistemas de Recomendação de Conteúdo. *Iberian Conference on Information Systems and Technologies, CISTI, 2020-June*(June), 24–27.
- Theodorus, A., & Budiyanto Setyohadi, D. (2016). User-Based Collaborative Filtering Dengan Memanfaatkan Pearson- Correlation Untuk Mencari Neighbors Terdekat Dalam Sistem Rekomendasi. *Thesis Magister Teknologi Informasi Universitas Atma Jaya Yogyakarta*, 1–6. <http://e-journal.uajy.ac.id/8924/>
- Wijaya, A. E., & Alfian, D. (2018). Sistem Rekomendasi Laptop Menggunakan Collaborative Filtering Dan Content-Based Filtering. *Jurnal Computech & Bisnis*, 12, 14–16.
- Yoshii, K., Goto, M., Komatani, K., Ogata, T., & Okuno, H. G. (2008). An efficient hybrid music recommender system using an incrementally trainable probabilistic generative model. *IEEE Transactions on Audio, Speech and*

Language Processing, 16(2), 435–447.
<https://doi.org/10.1109/TASL.2007.911503>

Zhang, Y., & Feng, Y. Q. (2011). Factors that influence a buyer's decision process of shopping online: The effects of tradition and virtual community. *Proceedings - 2011 International Conference of Information Technology, Computer Engineering and Management Sciences, ICM 2011*, 3(1), 294–297. <https://doi.org/10.1109/ICM.2011.316>