

Sistem Rekomendasi *Collaborative Filtering* Sebagai Upaya Peningkatan Perekonomian di Pasar Tradisional

Herbert A. Tambunan¹, Jimmi Hendrik Pangihutan Sitorus²

^{1,2}AMIK Parbina Nusantara, Pematang Siantar, Indonesia

e-mail: bangtambunan@gmail.com¹, jimmisitorus83@yahoo.com²

Abstrak

Pasar tradisional menghadapi tantangan signifikan dari pertumbuhan pasar modern dan e-commerce, yang dapat menyebabkan penurunan daya tarik, kehilangan daya saing, dan penurunan penjualan. Pasar tradisional memiliki peran kunci dalam keberlanjutan ekonomi, sosial, dan budaya. Oleh karena itu, pelestarian dan transformasi pasar ini menjadi sangat penting untuk mendukung ekonomi, mempromosikan produk lokal, dan menjaga warisan budaya. Penelitian ini bertujuan untuk meningkatkan perekonomian pasar tradisional dengan menerapkan teknologi collaborative filtering, yang memudahkan konsumen dalam mencari produk yang diinginkan. Pasar Horas di Kota Pematang Siantar menjadi objek penelitian. Collaborative filtering adalah teknik rekomendasi yang menggunakan data pengguna untuk merekomendasikan produk berdasarkan kesamaan dengan pengguna lainnya. Dataset yang digunakan mencakup pendapat 2.114 konsumen yang membeli produk dari 10 kios dengan total 97 produk dan 5.948 penilaian produk. Hasil pengujian menggunakan metrik RSME dengan 100 epoch menunjukkan nilai 0.1832 pada data training dan 0.1908 pada data uji. Hasil ini menunjukkan kecocokan metode collaborative filtering berbasis Matrix Factorization sebagai sistem rekomendasi aplikasi di Pasar Horas. Pada konteks pasar tradisional, teknologi ini dapat meningkatkan penjualan dengan merekomendasikan produk relevan kepada pelanggan, mendorong pertumbuhan ekonomi pasar tradisional. Namun, perlu memahami implikasi jangka panjang terhadap komunitas lokal dan ekonomi sebagai langkah selanjutnya dalam penelitian ini.

Kata Kunci: Collaboration Filtering; Sistem Rekomendasi; Tensorflow; Python; Pasar Horas

Abstract

Traditional markets face significant challenges from the growth of modern markets and e-commerce, which can lead to reduced attractiveness, loss of competitiveness and decreased sales. Traditional markets have a key role in economic, social and cultural sustainability. Therefore, the preservation and transformation of this market is very important to support the economy, promote local products and maintain cultural heritage. This research aims to improve the economy of traditional markets by implementing collaborative filtering technology, which makes it easier for consumers to find the desired products. The Horas Market in Pematang Siantar City is the object of research. Collaborative filtering is a technique that uses user data to recommend products based on similarities to other users. The dataset includes the opinions of 2,114 consumers who purchased products from 10 kiosks, totalling 97 products and 5,948 product ratings. Test results using the RSME metric with 100 epochs show a value of 0.1832 on the training data and 0.1908 on the test data. These results show the suitability of the Matrix Factorization-based collaborative filtering method as an application recommendation system at the Horas Market. In the context of traditional markets, this technology can increase sales by recommending relevant products to customers, encouraging the economic growth of traditional markets. However, it is necessary to understand the long-term implications for local communities and the economy as the next step in this research.

Keywords: Collaborative Filtering; Recommendation System; Tensorflow; Python; Horas Market

1. PENDAHULUAN

Pasar tradisional merupakan salah satu bentuk perdagangan yang masih bertahan dan berperan penting dalam perekonomian masyarakat lokal di

Indonesia [1]-[4]. Namun, banyak pasar tradisional yang mengalami penurunan omset dan pengunjung akibat persaingan dengan pasar modern dan toko online yang menawarkan kemudahan dan kenyamanan dalam berbelanja [5]-[9]. Dampak dari persaingan dengan pasar modern adalah berkurangnya minat masyarakat berbelanja di pasar tradisional. Hal tersebut mengakibatkan berkurangnya jumlah pelanggan dan pendapatan pedagang pasar tradisional menurun secara drastis yang akhirnya mengakibatkan kesulitan dalam memenuhi kebutuhan sehari-hari dan dalam mengelola usaha mereka. Pedagang pasar tradisional harus bertahan menghadapi persaingan yang tidak merata dan harus bersaing dengan penawaran yang lebih menarik dari tempat-tempat belanja modern.

Penurunan minat konsumen dapat menyebabkan ketidakpastian dalam usaha pedagang pasar tradisional. Mereka akan kesulitan untuk merencanakan investasi atau pengembangan usaha jika tidak ada jaminan bahwa pasar akan tetap stabil. Jika pendapatan menurun dan persaingan semakin ketat, pedagang pasar tradisional dapat menghadapi tekanan ekonomi yang lebih besar, termasuk risiko bangkrut atau mengurangi skala usaha. Pedagang pasar tradisional juga perlu beradaptasi dengan teknologi baru, strategi pemasaran, dan tuntutan pasar yang berubah. Mereka mungkin memerlukan dukungan dan pelatihan untuk dapat bersaing dalam pasar yang semakin kompleks dengan keterbatasan sumber daya dan pengetahuan dalam menghadapi perubahan-perubahan tersebut.

Teknologi informasi dan komunikasi (TIK) telah membuka peluang baru untuk memperbaiki kondisi pasar tradisional melalui penerapan konsep ekonomi digital. Salah satu teknologi yang dapat digunakan untuk meningkatkan perekonomian di pasar tradisional adalah *collaborative filtering*. *Collaborative filtering* adalah teknologi yang digunakan untuk merekomendasikan produk atau layanan kepada pengguna berdasarkan preferensi dan riwayat pembelian [10]-[13], serta preferensi pengguna lain yang serupa [14]-[16]. Teknologi ini banyak digunakan pada aplikasi *e-commerce* dan sosial media untuk meningkatkan pengalaman pengguna dan memperbaiki kinerja bisnis [17], dalam konteks pasar tradisional, algoritma *collaborative filtering* dapat digunakan untuk membantu pedagang mengidentifikasi produk yang paling diminati oleh konsumen dan memberikan rekomendasi produk yang lebih personal dan relevan kepada konsumen lainnya berdasarkan pengalaman [18]. Namun, penggunaan teknologi ini di pasar tradisional masih terbatas dan belum banyak diteliti.

State of the art dari penelitian ini diantaranya: (Nurhani & Samsudin, 2022) menerapkan algoritma *Collaborative filtering* berbasis aplikasi sistem android untuk melakukan pemesanan makanan dan minuman secara online. Sistem platform ini dibangun untuk meningkatkan pelayanan terhadap pelanggan, serta memudahkan pihak rumah makan dalam mengelola transaksi dan laporan, sehingga sangat membantu meningkatkan bisnis, memantau data maupun manajemen rumah makan. Sistem ini juga memudahkan pelanggan dalam memilih makanan dengan rating terbaik [19]. (Anggoro & Izzatillah, 2022) Menggunakan *collaborative filtering* berbasis android dalam menentukan rekomendasi musik untuk pengguna. Pada penelitian ini sistem rekomendasi lebih personal terhadap penggunanya karena dapat diimplementasi ke dalam aplikasi pemutar musik online dengan menampilkan rekomendasi lagu yang dapat dipilih [20]. (Moon et

al., 2023) memanfaatkan teknik *Collaborative filtering* (CF) untuk mengurangi kelebihan informasi yang masif dalam sistem pemberi rekomendasi modern. Teknik ini dikombinasi dengan Collaborative Mixup (CoMix). Hasil eksperimen ekstensif menunjukkan bahwa berbagai model CF yang dilengkapi dengan CoMix secara konsisten meningkatkan model dasar pada empat kumpulan data yang dijadikan sebagai tolok ukur, CoMix juga dapat meningkatkan akurasi model CF asli, terutama pada pengguna cold-start dan item long-tail [21]. (Kuo & Li, 2023) Menerapkan sistem rekomendasi penyaringan kolaboratif berbasis algoritma Particle Swarm Optimization (PSO) dengan mempertimbangkan peringkat dan ulasan. PSO digunakan untuk menentukan kesamaan penilaian konsumen yang paling sesuai untuk menghindari masalah distorsi data akibat ketersebaran data. Selain itu, Bidirectional Encoder Representations From Transformers (BERT) diterapkan untuk meng-ekstraksi karakteristik umpan balik konsumen. Tujuan dari sistem pemberi rekomendasi adalah untuk menggunakan karakteristik pengguna, seperti informasi pribadi, umpan balik, dan preferensi pengguna, untuk menyediakan produk yang kemungkinan besar diminati pelanggan. Penelitian ini berfokus pada peningkatan *Collaborative filtering*. Berdasarkan penelitian ini dapat diketahui bahwa kombinasi data peringkat dan ulasan dapat meningkatkan kinerja rekomendasi [22]. (Godinot & Tarissan, 2023) Melakukan penelitian untuk mengukur efek pemfilteran kolaboratif (*Collaborative filtering*) pada keragaman perhatian pengguna. Pada penelitian ini, mereka telah menyelidiki dampak sistem pemberi rekomendasi terhadap keragaman perhatian pengguna. Secara khusus, mereka memeriksa kerangka kerja yang diusulkan baru-baru ini yang mengeksplorasi hubungan antara pengguna, item, dan kategori untuk mengukur keragaman perhatian pengguna, dengan menerapkan pendekatan pemfilteran kolaboratif (*Collaborative filtering*) pada kumpulan data yang merekam rekaman musik masa lalu pengguna, mereka dapat melakukan analisis mendetail tentang bagaimana rekomendasi memengaruhi keragaman dalam konteks ini. Hasil dari penelitian ini menunjukkan bahwa rekomendasi cenderung memiliki tingkat keragaman yang relatif tinggi [23]. Masih banyak lagi penelitian-penelitian lain terkait topik penelitian ini ataupun pemanfaatan metode yang sama [24]–[33].

Berdasarkan resume dari penelitian-penelitian terdahulu yang telah dijabarkan, kebaruan yang ditawarkan dari proposal penelitian ini terletak pada penggunaan algoritma *collaborative filtering* sebagai solusi untuk meningkatkan perekonomian di pasar tradisional, dengan studi kasus pasar Horas yang terletak di kota Pematang Siantar. Metode ini diharapkan dapat membantu pedagang di pasar tradisional untuk memperoleh konsumen baru, meningkatkan penjualan, dan mengoptimalkan pengalaman belanja konsumen di pasar tradisional. Penelitian ini juga dapat memberikan wawasan baru dalam pemanfaatan aplikasi Visual Studio Code dengan bahasa pemrograman Python dalam mendukung perkembangan pasar tradisional dan meningkatkan kesejahteraan ekonomi pedagang lokal.

2. METODOLOGI PENELITIAN

2.1. Pengumpulan Data

Penelitian dilakukan di Pasar Horas, salah satu pasar tradisional Kota Pematang Siantar dengan meminta referensi dari para konsumen yang membeli

barang yang dibeli dimulai sejak tanggal 1 Juli 2023 sampai dengan 20 Juli 2023. Data yang telah dikumpulkan mencakup informasi kios/toko, lokasi, produk yang dijual, harga dan penilaian produk yang dibeli oleh konsumen. Terdapat sepuluh toko tempat pengambilan data pada penelitian ini. Setiap toko diberikan ID 1 sampai 10. Untuk membedakan kategori setiap toko yang memiliki kategori berbeda. Diberikan ID dengan rentang A sampai E untuk toko dengan kategori penjualan peralatan dan perlengkapan pertanian, perlengkapan rumah tangga, toko buah, toko peralatan listrik, toko logistik dan bahan dapur. Hasil data yang diperoleh untuk deskripsi toko dapat dilihat pada Tabel 1.

Tabel 1. Tabel Deskripsi Toko

Id Toko	Nama Toko	Jenis Layanan	Gedung	Lantai	Nomor Kios
T1A1	UD. Berkat Tani	Perlengkapan Pertanian	Gedung 1	1	36
T2A1	UD. Subur	Perlengkapan Pertanian	Gedung 1	1	36
T3B1	UD. Hasiholan	Perlengkapan Rumah Tangga	Gedung 1	1	26
T4B1	Toko Sejahtera	Perlengkapan Rumah Tangga	Gedung 2	1	34
T5C1	Siregar	Toko Buah	Gedung 1	1	2
T6C1	Sribuah	Toko Buah	Gedung 2	1	5
T7D1	Modern	Peralatan Elektronik	Gedung 1	1	48
T8D1	Toko Terang	Peralatan Elektronik	Gedung 1	1	53
T9E1	Toko Sedap	Toko Bahan Makanan	Gedung 2	1	10
T10E1	Toko Laris	Toko Bahan Makanan	Gedung 3	1	18

Berdasarkan data yang dikumpulkan juga terdapat informasi harga produk pada setiap toko. Setiap produk diberikan id sesuai nama toko dan kriteria toko. Tabel sampel produk beserta harga dapat dilihat pada Tabel 2.

Tabel 2. Tabel Sampel identitas Produk beserta Harga Barang

No	Id Produk	Nama Barang	Unit	Harga
1	1A1	Pupuk NPK 16:16:16	Kg	9000
2	1A2	Pupuk Urea	Kg	7500
3	1A3	Pupuk POSKA	Kg	8000
4	1A4	Polibag 2 Kg	Kg	20000
5	1A5	Polibag 5 Kg	Kg	22000
6	1A6	Bibit Mentimun sachet Kecil	Bungkus	5000
7	1A7	Bibit Selada	Bungkus	15000
8	1A8	Bibit Cabe	Bungkus	15000
9	1A9	Bibit Terong Ungu	Bungkus	15000
10	2A1	Bibit Cabe Rawit	Bungkus	5000
11	2A2	Root Penumbuh Akar	Botol	35000
12	2A3	Anti Hama Curater	Bungkus	45000
13	2A4	Penyemprot Hama SOLO 15 Liter	Unit	350000
14	2A5	Decis 100ml	Botol	25000
15	2A6	Grow Root 250gr	Botol	35000
16	2A7	Pupuk Mutiara 16	Pcs	15000
17	2A8	Pupuk NPK	Pcs	12000

No	Id Produk	Nama Barang	Unit	Harga
18	2A9	Pupuk Poska	Pcs	11000
19	2A10	Curater Anti Hama	Pcs	50000

Selanjutnya terdapat Tabel rating produk yang diperoleh berdasarkan rating User atau pembeli sebanyak 20.159 record dengan sampel data seperti yang terlihat pada Tabel 3.

Tabel 3. Tabel Rating

Id User	Id Toko	Rating Produk
usr_1A10001	T1A1	5
usr_1A10002	T1A1	
usr_1A10003	T1A1	4
usr_1A10004	T1A1	5
usr_1A10005	T1A1	5
usr_1A10006	T1A1	4
usr_1A10007	T1A1	5
usr_1A10008	T1A1	4
usr_1A10009	T1A1	5
usr_1A10010	T1A1	4
usr_1A10011	T1A1	5
usr_1A10012	T1A1	4
usr_1A10013	T1A1	4
usr_1A10014	T1A1	4
usr_1A10015	T1A1	5
usr_1A10016	T1A1	
usr_1A10017	T1A1	5
usr_1A10018	T1A1	4
usr_1A10019	T1A1	4
usr_1A10020	T1A1	4
usr_1A10021	T1A1	5
usr_1A10022	T1A1	
usr_1A10023	T1A1	5

Pengolahan data dilakukan dengan menggunakan Software *Microsoft Excel* dan *Visual Studio Code* dengan bahasa pemrograman *Python*. Software *Microsoft Excel* digunakan sebagai alat untuk menyimpan dan mengolah data mentah yang diperoleh dari pencatatan yang dilakukan di lapangan sehingga nantinya dijadikan dataset penelitian. Software *Visual Studio code* dengan bahasa *Python* digunakan untuk melakukan perancangan, analisis data, pelatihan dan evaluasi.

2.2. Metode Collaborative Filtering

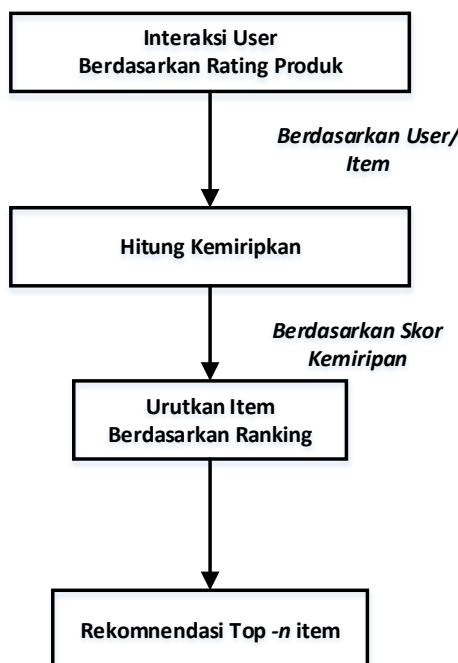
Metode *Collaborative filtering* atau juga dikenal sebagai *User-User Filtering*, menggunakan pengguna informasi dari pengguna lain untuk merekomendasikan item kepada pengguna input. Metode *Collaborative filtering* mencoba menemukan pengguna yang memiliki preferensi dan pendapat yang serupa dengan pengguna

input, lalu merekomendasikan item yang mereka sukai kepada pengguna input. Metode pada penelitian ini memanfaatkan *library keras dan tensor flow*.

Proses *collaborative filtering* sebagai berikut:

1. Kumpulkan data pengguna berdasarkan interaksi dengan produk yang telah dibeli.
2. Hitung skor kemiripan menggunakan rumus.
3. Urutkan berdasarkan kemiripan yang telah dihitung.
4. Berdasarkan urutan terhadap produk yang sudah dibeli, temukan rekomendasi produk tetangga yang paling tinggi, rekomendasikan item dengan skor tertinggi sebanyak n .

Proses untuk membuat sistem rekomendasi berdasarkan pengguna dapat dilihat pada gambar 1.



Gambar 1. Alur Proses *Collaborative Filtering*

Collaborative Filtering memanfaatkan interaksi produk atau item berdasarkan perilaku atau kebiasaan pengguna atau user. Tujuannya agar pengguna yang sama dan item yang serupa dapat disukai oleh pengguna sebagai rekomendasi pilihan. Pada pendekatan ini, kemiripan antara dua buah item dihitung menggunakan metrik cosine similarity. Prediksi item 'i' untuk user 'a' dapat diprediksi dengan menggunakan bobot rata-rata yang dapat dituliskan dalam persamaan (1).

$$\rho_{a,i} = \frac{\sum_{j \neq k} r_{aj} W_{ij}}{\sum_{j \neq k} W_{ij}} \quad (1)$$

dimana k adalah item tetangga yang memiliki nilai kemiripan tertinggi terhadap item yang diukur berdasarkan rating pengguna a , dan w_{ij} adalah kemiripan antara item i dan j .

Ada dua pendekatan umum untuk mengimplementasikan *collaborative filtering*: *Memory-Based* (berbasis memori) dan *Model-Based* (berbasis model).

Metode berbasis memori mengandalkan penghitungan kesamaan antara pengguna atau item dalam dataset. Dalam pendekatan ini, pencarian entitas (pengguna atau item) yang mirip dengan entitas yang sedang diberi rekomendasi. Dua jenis metode berbasis *memory-based* yang umum digunakan adalah:

1. *User-Based Collaborative Filtering (UBCF)*

User-Based Collaborative Filtering (UBCF) mencari pengguna lain yang memiliki preferensi serupa dengan pengguna yang sedang diberi rekomendasi. Rekomendasi diberikan berdasarkan preferensi pengguna serupa.

2. *Item-Based Collaborative Filtering (IBCF)*

Item-Based Collaborative Filtering (IBCF) mencari item lain yang mirip dengan item yang sedang diberi rekomendasi. Rekomendasi diberikan berdasarkan item yang mirip dengan item yang disukai oleh pengguna.

Metode *Model-Based Collaborative Filtering* menggunakan model matematis atau statistik untuk memodelkan hubungan antara pengguna dan item. Beberapa metode *model-based Collaborative Filtering* yang umum digunakan diantaranya :

1. *Matrix Factorization (MF)*

Matrix Factorization memfaktorkan matriks interaksi pengguna-item menjadi matriks berperingkat lebih rendah. Ini digunakan untuk memodelkan preferensi pengguna dan item.

2. *Factorization Machines (FM)*

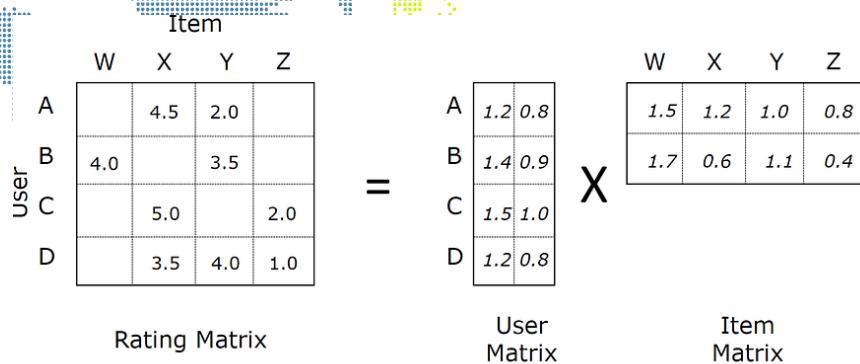
FM adalah model yang memodelkan hubungan antara berbagai fitur pengguna dan item. Ini berguna ketika ada fitur tambahan yang dapat digunakan untuk membuat rekomendasi.

3. *Deep Learning Models*

Metode berbasis model juga dapat memanfaatkan jaringan saraf mendalam, seperti *AutoEncoders*, *Convolutional Neural Networks (CNN)*, atau *Recurrent Neural Networks (RNN)* untuk memodelkan hubungan pengguna dan item secara lebih kompleks.

2.3. *Collaborative Filtering* berbasis *Matrix Factorization (MF)*

Pada penelitian ini, pendekatan yang diadopsi adalah penerapan sistem rekomendasi berbasis teknik MF. Teknik MF adalah salah satu metode populer dalam pembuatan sistem rekomendasi, di mana matriks interaksi antara pengguna dan produk dipecah menjadi dua matriks lebih kecil yang merepresentasikan pengguna dan produk. Matriks pertama dapat dilihat sebagai user matriks dimana baris mewakili pengguna dan kolom adalah *factor laten*. Matriks kedua adalah item matriks di mana baris merupakan *latent factor* dan kolom mewakili item.

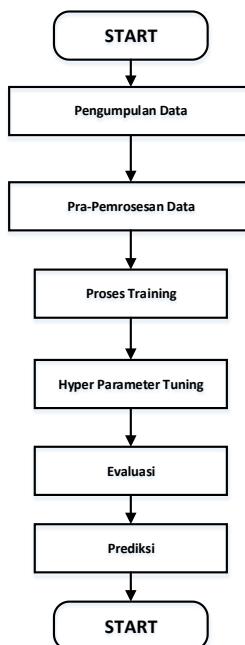


Gambar 2. Algoritma *Matrix Factorization*

Untuk menentukan *latent factor*, algoritma MF bisa menggunakan *Singular Value Decomposition (SVD)*. Pada penelitian ini, menggunakan library *scikit-surprise* yang sudah tersedia pada bahasa pemrograman *python*.

2.4. Flowchart Penelitian

Gambar 3 merupakan flowchart penelitian untuk mengimplementasikan algoritma *collaborative filtering* berbasis MF. Pengumpulan data dilakukan dengan mencatat interaksi antara pengguna dan item. Data yang diperoleh disimpan dalam bentuk file *.csv. Data-data tersebut kemudian di lanjutkan dengan pengolahan menggunakan aplikasi *Visual Studio Code 1.81.1*, menggunakan bahasa pemrograman *python*. Data-data tersebut selanjutnya di import menggunakan library *pandas* dan direpresentasikan dalam bentuk matriks dimana baris merepresentasikan pengguna dan kolom merepresentasikan item. Nilai dalam matriks menunjukkan peringkat atau interaksi lainnya antara pengguna dan item. Contoh sampel data yang diolah dapat dilihat pada Tabel 3.



Gambar 3. Flowchart Penelitian

Tabel 4. Sampel Data Produk dan Rating User

Id User	2A1	2A2	2A3	2A4	2A5	2A6	2A7	2A8	2A9	2A1
usr_a13	5	5	5	5		5	5			
usr_a131			5			5				
usr_a132										5
usr_a133				5			5		5	5
usr_a134		4	5	5		5			1	5
usr_a135		5							5	
usr_a136		5	5			5		5		5
usr_a137	5			5						

Kemudian, untuk mengurangi bias langkah berikutnya adalah melakukan pra-pemrosesan data dengan mengurangi data yang tidak memiliki rating dari dataset. Setelah proses pra preprocessing data selesai, langkah berikutnya adalah membagi dataset menjadi set pelatihan dan set pengujian untuk evaluasi pada model. Rasio split data pada penelitian ini 80% untuk data training, dan 20% untuk data testing. Tahap selanjutnya adalah melakukan proses inisialisasi matriks. satu untuk pengguna (U) dan satu lagi untuk item (I). Dimensi matriks ini biasanya lebih kecil daripada matriks asli dan disebut sebagai faktor laten. Setelah proses inisialisasi matriks selesai, optimasi gradient descent dilakukan untuk meminimalkan kesalahan antara perkalian matriks U dan I dengan matriks asli. Selama proses ini, menambahkan regularisasi mungkin diperlukan untuk mencegah *overfitting*.

Percobaan prediksi dilakukan setelah matriks U dan I dioptimalkan, perkalian akan memberikan matriks prediksi yang mendekati matriks asli. Untuk mendapatkan rekomendasi terhadap pengguna tertentu, dapat dilakukan dengan melihat baris matriks prediksi yang sesuai dengan pengguna tersebut dan mengurutkan item berdasarkan nilai prediksi. Untuk melakukan evaluasi, set pengujian kinerja model menggunakan metrik RMSE (*Root Mean Square Error*). Model yang terbaik adalah model yang memperoleh nilai RMSE terkecil. Eksperimen pada saat training juga dilakukan dengan berbagai nilai untuk *hyperparameter* seperti *learning rate*, jumlah faktor laten, dan koefisien regularisasi untuk mendapatkan model terbaik. Dari seluruh proses ujicoba, model yang memperoleh nilai RMSE akan digunakan sebagai model untuk melakukan prediksi rekomendasi terbaik untuk user.

3. HASIL DAN PEMBAHASAN

Pada bagian ini akan dijelaskan mengenai serangkaian eksplorasi data, pengujian dan evaluasi terhadap metode yang digunakan.

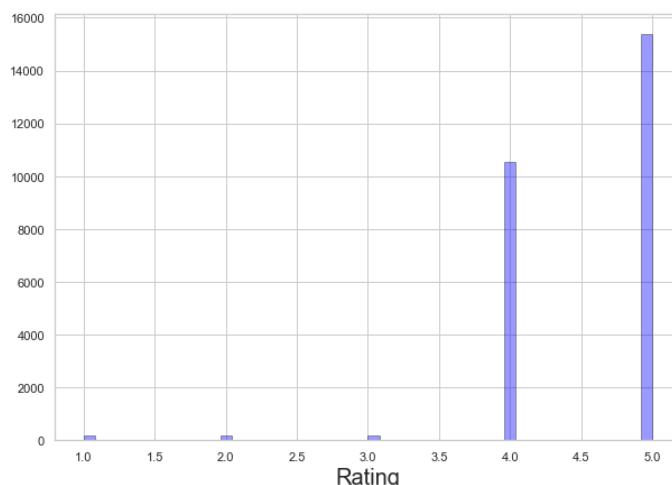
3.1. Hasil Pra-pemrosesan Dat

Pengujian ini dilakukan untuk mengetahui informasi lebih dalam dari data yang telah dikumpulkan dan melakukan seleksi data yang layak digunakan pada tahap training data. Dari hasil data yang diperoleh, ditemukan bahwa jumlah rating yang diperoleh dari penilaian user sebanyak 2.159 terhadap 97 produk. Setelah data yang tidak memiliki rating dikurangi, diperoleh jumlah data sebanyak 5.948 rating. Hasil pra-processing data dapat dilihat pada Tabel 5.

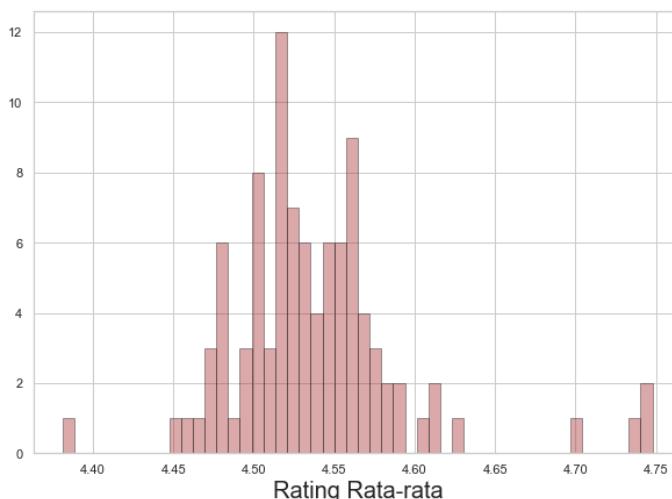
Tabel 5. Data hasil *Pra Processing*

	Id User	Id Produk	Rating
0	usr_1A11	P1A1	5.0
6	usr_1A17	P1A1	5.0
8	usr_1A19	P1A1	5.0
20138	usr_1E1418	P1E9	4.0
20141	usr_1E1421	P1E9	5.0
20150	usr_1E143	P1E9	5.0
20152	usr_1E1432	P1E9	5.0
20157	usr_1E1437	P1E9	5.0

Keseimbangan distribusi data diperlukan untuk menghindari bias. Pengamatan pada distribusi data berdasarkan rating, dapat dilihat pada gambar 4 dan gambar 5.



Gambar 4. Jumlah Distribusi Data Berdasarkan Rating User



Gambar 5. Rating Rata-rata

3.2. Analisis Model

Salah satu komponen kunci dari pendekatan ini adalah penggunaan "embedding". Embedding adalah teknik yang mengubah entitas kategorikal, seperti ID pengguna atau ID produk, menjadi vektor kontinu dalam ruang berdimensi lebih rendah. Dengan demikian, model yang dikembangkan dalam penelitian ini dapat mempelajari dan memahami representasi vektorial dari setiap pengguna dan produk berdasarkan data historis interaksi mereka. Representasi vektorial mengacu pada operasi matematika di mana vektor pengguna dan vektor produk dikalikan untuk menghasilkan skor prediksi. Skor ini menunjukkan seberapa cocok suatu produk dengan preferensi pengguna. Namun, untuk meningkatkan akurasi prediksi, bias ditambahkan ke skor ini. Bias adalah konstanta yang menyesuaikan skor berdasarkan karakteristik unik dari setiap pengguna atau produk. Inisialisasi fungsi pada tahap ini dapat dilihat pada perintah berikut :

```
# inisialisasi fungsi
def __init__(self, num_user, num_produk, embedding_size, **kwargs):
    super(RecommenderNet, self).__init__(**kwargs)
    self.num_user = num_user
    self.num_produk = num_produk
    self.embedding_size = embedding_size
    self.user_embedding = layers.Embedding( # layer embedding user
        num_user,
        embedding_size,
        embeddings_initializer = 'he_normal',
        embeddings_regularizer = keras.regularizers.l2(1e-6)
    )
    self.user_bias = layers.Embedding(num_user, 1) # layer embedding user bias
    self.produk_embedding = layers.Embedding( # layer embedding produk
        num_produk,
        embedding_size,
        embeddings_initializer = 'he_normal',
        embeddings_regularizer = keras.regularizers.l2(1e-6)
    )
    self.produk_bias= layers.Embedding(num_produk, 1) # layer embedding produk bias
```

Untuk memastikan bahwa skor prediksi yang dihasilkan berada dalam rentang yang dapat diinterpretasikan (dalam hal ini antara 0 dan 1), digunakan fungsi aktivasi sigmoid. Fungsi sigmoid adalah fungsi matematika yang mengubah setiap angka input dalam rentang [0,1] agar dapat merepresentasikan probabilitas. Fungsi sigmoid di terapkan pada perintah berikut :

```
def call(self, inputs):
    user_vector = self.user_embedding(inputs[:,0]) # memanggil layer embedding 1
    user_bias = self.user_bias(inputs[:,0]) # memanggil layer embedding 2
    produk_vector = self.produk_embedding(inputs[:, 1]) # layer embedding 3
```

```
produk_bias = self.produk_bias(inputs[:, 1]) # memanggil layer embedding 4
dot_user_produk = tf.tensordot(user_vector, produk_vector, 2)
x = dot_user_produk + user_bias + produk_bias
return tf.nn.sigmoid(x) # activation sigmoid
```

Pada konteks sistem rekomendasi, output yang mendekati 1 menunjukkan kemungkinan tinggi bahwa pengguna akan menyukai produk, sedangkan output yang mendekati 0 menunjukkan kemungkinan rendah. Seperti yang dijelaskan sebelumnya, model ini menggunakan *Binary Crossentropy* untuk menghitung *loss function*, Adam (*Adaptive Moment Estimation*) sebagai optimizer dengan nilai learning rate = 0.001 dan *root mean squared error* (RMSE) sebagai metrics evaluation.

```
model.compile(
    loss = tf.keras.losses.BinaryCrossentropy(),
    optimizer = keras.optimizers.Adam(learning_rate=0.001),
    metrics=[tf.keras.metrics.RootMeanSquaredError()]
)
```

Proses training model dilakukan dengan nilai epoch sebanyak 100, dan batch size = 4.

```
History = model.fit(x = x_train, y = y_train, batch_size = 8, epochs = 100,
                     validation_data = (x_valid, y_valid))
```

dari hasil pengujian dan setting *hyper parameter* yang telah dijelaskan diatas, model diperoleh nilai RMSE sebesar 0.1833 pada data training, dan 0.1908 pada data validasi.

3.3. Prediksi Rekomendasi Produk

Untuk mendapatkan rekomendasi produk, sampel user diambil secara dan definisikan pada variabel yang belum diberi rating oleh user. Dalam hal ini merupakan daftar produk yang belum pernah dibeli oleh pengguna. Pada produk lainnya, pengguna telah memberi rating pada beberapa produk yang telah mereka beli. Rating yang telah diberikan pada produk tersebut akan digunakan sebagai referensi untuk membuat rekomendasi produk baru yang mungkin cocok untuk pengguna. Sampel user secara acak adalah user dengan ID usr_8D18. Dengan prediksi rekomendasi produk seperti yang terlihat pada gambar 6.

```
Tampilkan Produk Rekomendasi Kepada userID : usr_8D18

Produk yang mungkin sedang Anda Cari :
-----
Lampu Emergency Surya          >> Toko TOKO TERANG |: Peralatan Elektronik
Lampu LED Hannoch 25 Watt       >> Toko TOKO TERANG |: Peralatan Elektronik
Lampu LED Hanoch 10 Watt        >> Toko TOKO TERANG |: Peralatan Elektronik
Lampu LED Phillips 23 Watt     >> Toko TOKO TERANG |: Peralatan Elektronik
Lampu LED Strip 5 Meter         >> Toko TOKO TERANG |: Peralatan Elektronik
Obeng Plus Minus Besar         >> Toko TOKO TERANG |: Peralatan Elektronik
Senter Rechargeable            >> Toko TOKO TERANG |: Peralatan Elektronik
```

Gambar 6. Hasil Prediksi Rekomendasi kepada User Secara Acak

Untuk produk lain yang mungkin belum pernah dilihat atau dibeli user, berdasarkan popularitas dapat dilihat pada gambar 7.

Produk yang rekomendasikan untuk Anda :	
Bibit Terong Ungu	>> Toko UD. BERKAT TANI : Perlengkapan Pertanian
Mixer Philips	>> Toko Toko SEJAHTERA : Perlengkapan Rumah Tangga
Botol Minum Kaca	>> Toko Toko SEJAHTERA : Perlengkapan Rumah Tangga
Apel Red Import	>> Toko SIREGAR : Toko Buah
Apel Malang	>> Toko SIREGAR : Toko Buah
Semangka Merah	>> Toko SRIBUAH : Toko Buah
Jeruk Manis	>> Toko SRIBUAH : Toko Buah
Salak Pondoh	>> Toko SRIBUAH : Toko Buah
Jambu Biji Kristal Merah	>> Toko SRIBUAH : Toko Buah
Melon Kuning	>> Toko SRIBUAH : Toko Buah

Gambar 7. Hasil Prediksi Rekomendasi kepada Anda

Implementasi *collaborative filtering* bisa menjadi tugas yang rumit dan memerlukan pemahaman yang baik tentang matematika, statistik, dan pemrograman. Selain itu, perlu diingat bahwa masalah *cold start* (ketika tidak ada data tentang pengguna atau item) dan skalabilitas adalah tantangan yang perlu diatasi dalam implementasi yang lebih besar.

4. SIMPULAN

Pada konteks pertumbuhan pasar modern dan e-commerce, pasar tradisional seperti Pasar Horas di Kota Pematangsiantar menghadapi tantangan serius. Penerapan teknologi *collaborative filtering* dalam rangka meningkatkan perekonomian di pasar tradisional menunjukkan potensi untuk diterapkan pada aplikasi sistem rekomendasi produk yang relevan kepada pelanggan. Metode collaborative filtering berbasis *Matrix Factorization* telah diuji dan menghasilkan hasil yang menjanjikan, dengan nilai *Root Mean Squared Error* (RSME) sekitar 0.1832 pada data training dan 0.1908 pada data uji, metode ini terbukti cocok diterapkan sebagai sistem rekomendasi aplikasi dalam konteks pasar tradisional. Implementasi sistem rekomendasi *collaborative filtering* dalam skala kecil sebagai pilot di Pasar Horas memungkinkan pemahaman lebih mendalam tentang cara kerja sistem dan tanggapan konsumen, dengan pendekatan yang intensif, penerapan teknologi *collaborative filtering* dapat menjadi alat yang efektif untuk mendukung keberlanjutan dan pertumbuhan pasar tradisional di tengah persaingan dari pasar modern dan *e-commerce*.

DAFTAR PUSTAKA

- [1] T. M. Mokalu, H. Nayoan, and S. Sampe, "Peran Pemerintah Dalam Pemberdayaan Pasar Tradisional Guna Meningkatkan Kesejahteraan Masyarakat (Studi Kasus Di Pasar Langowan Timur Kecamatan Langowan Timur)," *Jurnal Governance*, vol. 1, no. 2, pp. 1–12, 2021, [Online]. Available: <https://ejurnal.unsrat.ac.id/index.php/governance/article/view/34847>
- [2] Ariyanti Luhur Tri Setyarini, V. D. Purnomo, Syukron Abdul Kadir, and Benedictus Hestu Cipto Handoyo, "Analysis of Bantul Regency Regional Regulation Number 9 of 2021 Concerning People's Market Management," *Formosa Journal of Multidisciplinary Research*, vol. 2, no. 1, pp. 241–258, 2023, doi: 10.5592/fjmr.v2i1.2433.
- [3] G. Arifin, Y. H. Trinugraha, and N. Nurhadi, "Solidaritas dan Modal Sosial Pedagang

- Pasar Legi Surakarta Menghadapi Tantangan Pasar Modern," *Jurnal Sosiologi Andalas* vol. 7, no. 2, pp. 112–126, 2021, doi: 10.25077/jsa.7.2.112-126.2021.
- [4] M. N. Muzakki and K. HusnaAsri, "Strategi UMKM Bertahan Di Masa Pandemi," *ALIF* vol. 1, no. 2, pp. 63–71, 2022, doi: 10.37010/alif.v1i2.1021.
- [5] D. R. Effendi, R. Fermayani, A. S. Egim, and R. R. Harahap, "Pengaruh Persepsi Konsumen Mengenai Harga, Lokasi, Dan Kualitas Pasar Modern Terhadap Minat Beli Konsumen," *Jurnal Ecogen*, vol. 4, no. 2, pp. 188–197, 2021, doi: 10.24036/jmpe.v4i2.11169.
- [6] A. Shomad, "Memproteksi Warung Kelontong Dari Ekspansi Minimarket Dan Revolusi Industri 4.0 (Analisis Peraturan Presiden No. 112 Tahun 2007 Tentang Penataan dan Pembinaan Pasar Tradisional, Pusat Perbelanjaan dan Toko Modern)," *Jurnal Administrasi dan Kebijakan Publik*, vol. 6, no. 1, pp. 113–132, 2021, doi: 10.25077/jakp.6.1.113-132.2021.
- [7] F. Wibowo, A. U. Khasanah, and F. I. F. S. Putra, "Analisis Dampak Kehadiran Pasar Modern terhadap Kinerja Pemasaran Pasar Tradisional Berbasis Perspektif Pedagang dan Konsumen di Kabupaten Wonogiri," *Benefit: Jurnal Manajemen dan Bisnis*, vol. 7, no. 1, pp. 53–65, 2022, doi: 10.23917/benefit.v7i1.16057.
- [8] A. A. Wakhid, A. Qohar, and L. Faizal, "Model Kebijakan Pemerintah Daerah dalam Pengembangan Pasar Tradisional untuk Meningkatkan Daya Saing Terhadap Pasar Modern," *Jurnal Tapis: Teropong Aspirasi Politik Islam*, vol. 18, no. 2, pp. 81–99, 2022, doi: 10.24042/tps.v18i2.14356.
- [9] V. A. Qurrrata, R. G. Supratman, and R. B. Khuzaimah, "Strategi ketahanan pasar rakyat di masa pandemi covid-19," *Inovasi*, vol. 18, no. 1, pp. 105–111, 2022, doi: 10.30872/jinv.v18i1.10365.
- [10] X. Xiao, J. Wen, W. Zhou, F. Luo, M. Gao, and J. Zeng, "Multi-interaction fusion collaborative filtering for social recommendation," *Expert Systems with Applications*, vol. 205, p. 117610, 2022, doi: 10.1016/j.eswa.2022.117610.
- [11] O. Azeroual and T. Koltay, "RecSys Pertaining to Research Information with Collaborative Filtering Methods: Characteristics and Challenges," *Publications*, vol. 10, no. 2, pp. 1–14, 2022, doi: 10.3390/publications10020017.
- [12] R. Wang, Z. Wu, J. Lou, and Y. Jiang, "Attention-based dynamic user modeling and Deep Collaborative filtering recommendation," *Expert Systems with Applications*, vol. 188, p. 116036, 2022, doi: 10.1016/j.eswa.2021.116036.
- [13] Z. Cai, G. Yuan, S. Qiao, S. Qu, Y. Zhang, and R. Bing, "FG-CF: Friends-aware graph collaborative filtering for POI recommendation," *Neurocomputing*, vol. 488, pp. 107–119, 2022, doi: 10.1016/j.neucom.2022.02.070.
- [14] N. Nassar, A. Jafar, and Y. Rahhal, "A novel deep multi-criteria collaborative filtering model for recommendation system," *Knowledge-Based Systems*, vol. 187, p. 104811, 2020, doi: 10.1016/j.knosys.2019.06.019.
- [15] Y. Lv, Y. Zheng, F. Wei, C. Wang, and C. Wang, "AICF: Attention-based item collaborative filtering," *Advanced Engineering Informatics*, vol. 44, no. February, p. 101090, 2020, doi: 10.1016/j.aei.2020.101090.
- [16] M. F. Aljunid and M. D. Huchaiah, "IntegrateCF: Integrating explicit and implicit feedback based on deep learning collaborative filtering algorithm," *Expert Systems with Applications*, vol. 207, no. June, p. 117933, 2022, doi: 10.1016/j.eswa.2022.117933.
- [17] L. C. Jiang, R. R. Liu, and C. X. Jia, "User-location distribution serves as a useful feature in item-based collaborative filtering," *Physica A: Statistical Mechanics and its Applications*, vol. 586, p. 126491, 2022, doi: 10.1016/j.physa.2021.126491.
- [18] N. Ghasemi and S. Momtazi, "Neural text similarity of user reviews for improving collaborative filtering recommender systems," *Electronic Commerce Research and*

- [19] F. Nurhani and Samsudin, "Implementasi Algoritma Collaborative Filtering pada Sistem Pemesanan Makanan dan Minuman dengan Platform Android," *Jurnal Ilmiah Komputasi*, vol. 21, no. 3, pp. 317–332, 2022, doi: 10.32409/jikstik.21.3.3110.
- [20] M. V. Anggoro and M. Izzatillah, "Sistem Rekomendasi Musik dengan Metode Collaborative Filtering Berbasis Android," *STRING (Satuan Tulisan Riset dan Inovasi Teknologi)*, vol. 7, no. 1, pp. 1–8, 2022, doi: 10.30998/string.v7i1.10300.
- [21] J. Moon, Y. Jeong, D. K. Chae, J. Choi, H. Shim, and J. Lee, "CoMix: Collaborative filtering with mixup for implicit datasets," *Information Sciences*, vol. 628, pp. 254–268, 2023, doi: 10.1016/j.ins.2023.01.110.
- [22] R. J. Kuo and S. S. Li, "Applying particle swarm optimization algorithm-based collaborative filtering recommender system considering rating and review," *Applied Soft Computing*, vol. 135, p. 110038, 2023, doi: 10.1016/j.asoc.2023.110038.
- [23] A. Godinot and F. Tarissan, "Measuring the effect of collaborative filtering on the diversity of users' attention," *Applied Network Science*, vol. 8, no. 1, pp. 1–18, 2023, doi: 10.1007/s41109-022-00530-7.
- [24] F. Fkih, "Enhancing item-based collaborative filtering by users' similarities injection and low-quality data handling," *Data and Knowledge Engineering*, vol. 144, p. 102126, 2023, doi: 10.1016/j.datak.2022.102126.
- [25] S. Poudel and M. Bikdash, "Closed-Form Models of Accuracy Loss due to Subsampling in SVD Collaborative Filtering," *Big Data Mining and Analytics*, vol. 6, no. 1, pp. 72–84, 2023, doi: 10.26599/BDMA.2022.9020024.
- [26] J. Zhu, K. Li, J. Peng, and J. Qi, "Self-Supervised Graph Attention Collaborative Filtering for Recommendation," *Electronics (Switzerland)*, vol. 12, no. 4, pp. 1–17, 2023, doi: 10.3390/electronics12040793.
- [27] J. Wang, H. Mei, K. Li, X. Zhang, and X. Chen, "Collaborative Filtering Model of Graph Neural Network Based on Random Walk," *Applied Sciences (Switzerland)*, vol. 13, no. 3, pp. 1–17, 2023, doi: 10.3390/app13031786.
- [28] A. A. Patoulia, A. Kiourtis, A. Mavrogiorgou, and D. Kyriazis, "A Comparative Study of Collaborative Filtering in Product Recommendation," *Emerging Science Journal*, vol. 7, no. 1, pp. 1–15, 2023, doi: 10.28991/ESJ-2023-07-01-01.
- [29] K. Liu, F. Xue, X. He, D. Guo, and R. Hong, "Joint Multi-Grained Popularity-Aware Graph Convolution Collaborative Filtering for Recommendation," *IEEE Transactions on Computational Social Systems*, vol. 10, no. 1, pp. 72–83, 2023, doi: 10.1109/TCSS.2022.3151822.
- [30] J. Wang, Z. Chen, Y. Qin, D. He, and F. Lin, "Multi-Aspect co-Attentional Collaborative Filtering for extreme multi-label text classification," *Knowledge-Based Systems*, vol. 260, p. 110110, 2023, doi: 10.1016/j.knosys.2022.110110.
- [31] E. Ahmed and A. Letta, "Book Recommendation Using Collaborative Filtering Algorithm," *Applied Computational Intelligence and Soft Computing*, vol. 2023, no. Article ID 1514801, pp. 1–12, 2023, doi: 10.1155/2023/1514801.
- [32] X. Zhou, "Design of a Hybrid Recommendation Algorithm based on Multi-objective Collaborative Filtering for Massive Cloud Data," *International Journal of Advanced Computer Science and Applications*, vol. 14, no. 2, pp. 472–481, 2023, doi: 10.14569/IJACSA.2023.0140256.
- [33] H. Liu, L. Guo, P. Li, P. Zhao, and X. Wu, "Collaborative filtering with a deep adversarial and attention network for cross-domain recommendation," *Information Sciences*, vol. 565, pp. 370–389, 2021, doi: 10.1016/j.ins.2021.02.009.