

Usulan Peramalan Permintaan Produk Parfum Pada Toko *Online* Dengan Metode *Artificial Neural Network* (ANN) (Studi Kasus: Julis)

1st Efin Sahila Putri
Fakultas Teknik Industri
Universitas Telkom
Bandung, Indonesia

efinsahila@student.telkomuniversity.ac.id

2nd Erlangga Bayu Setyawan
Fakultas Teknik Industri
Universitas Telkom
Bandung, Indonesia

erlanggabs@telkomuniversity.ac.id

3rd Gisti Ayu Pratiwi
Fakultas Teknik Industri
Universitas Telkom
Bandung, Indonesia

gistiayupratiwi@telkomuniversity.ac.id

Abstrak— Perkembangan teknologi digital dan tren belanja mendorong industri parfum, termasuk Julis untuk beradaptasi. Julis menghadapi tantangan dalam memprediksi permintaan secara akurat karena masih menggunakan metode peramalan kualitatif yang kurang efektif menghadapi fluktuasi pasar. Produk G1, khususnya Vanilla Cake (30ml, 50ml, 100ml), menunjukkan gap peramalan cukup besar (24%-25,3%). Penelitian ini mengusulkan model peramalan berbasis *Artificial Neural Network* (ANN) yang mempertimbangkan faktor harga, diskon, rating, dan hari besar. Hasil evaluasi menggunakan MAD, MSE, dan MAPE menunjukkan bahwa model ANN mampu menurunkan MAPE menjadi 24,4%, 22,8%, dan 22,8% pada masing-masing ukuran produk. Dengan peningkatan akurasi ini, perusahaan dapat merencanakan produksi dan distribusi lebih efektif, merespons pasar dengan cepat, serta meningkatkan efisiensi dan daya saing di industri parfum daring yang kompetitif.

Kata Kunci— Peramalan, *Artificial Neural Network*, *E-Commerce*, Parfum.

I. PENDAHULUAN

Perkembangan teknologi digital dan tren belanja daring memengaruhi industri parfum, termasuk Julis, yang mengandalkan toko online. Ketidakstabilan permintaan pasar menyulitkan Julis menjaga ketersediaan produk, menyebabkan hilangnya peluang keuntungan. Peramalan yang akurat sangat penting, tetapi Julis masih menggunakan metode kualitatif berbasis intuisi, sehingga prediksi permintaan sering tidak sesuai. Penelitian oleh Pujarani (2024) menunjukkan bahwa pengelompokan produk berdasarkan prioritas (*performance score*) dapat meningkatkan profitabilitas dan efisiensi operasional.

TABEL I. 1
Data Grouping Berdasarkan Performance Score

Group	PS (%)	SKU	SKU (%)	Profit (IDR)	Profit (%)
G1	56%	3	6%	Rp 100.630.918	78%
G2	23%	18	35%	Rp 23.603.722	18%
G3	15%	22	42%	Rp 4.133.273	3%
G4	6%	9	17%	Rp 633.420	0,49%

Tabel I.1 menunjukkan 4 grup produk parfum Julis, dengan fokus penelitian pada Grup 1 (G1) yang menyumbang 78% dari profit perusahaan. Meskipun berkontribusi signifikan,

G1 menghadapi kesulitan dalam memenuhi permintaan tepat waktu, menyebabkan permintaan tidak terpenuhi selama beberapa periode.

TABEL I. 2
Daftar Produk G1

SKU Code	Nama Produk	Group
PP3	100ml Vanilla Cake	G1
PP2	50ml Vanilla Cake	G1
PP1	30ml Vanilla Cake	G1


Pada Tabel I.2 merupakan produk yang ada dalam kategori G1 yaitu, 30ml *Vanilla Cake*, 50ml *Vanilla Cake*, dan 100ml *Vanilla Cake*.

Produk G1 *Vanilla Cake* mengalami gap antara peramalan dan permintaan, dengan rata-rata gap sebesar 25,3% untuk 30ml, 24,0% untuk 50ml, dan 24,8% untuk 100ml. Penelitian ini berfokus pada G1 untuk mengidentifikasi penyebab ketidakakuratan peramalan dan merancang metode peramalan yang lebih tepat guna memenuhi permintaan.

TABEL I. 3
Nilai Kesalahan Peramalan

Produk	30ml Vanilla Cake	50ml Vanilla Cake	100ml Vanilla Cake
MAD	13,12	16,22	4,37
MSE	1310,8	2288,7	671,8
MAPE	25,3%	24,0%	24,8%

Tingkat akurasi peramalan dapat diukur menggunakan MAD, MSE, dan MAPE, dengan error terkecil menunjukkan peramalan paling akurat. Berdasarkan permasalahan yang ada, analisis mendalam diperlukan menggunakan diagram tulang ikan untuk mengidentifikasi penyebab utama masalah yang dihadapi Julis. Berikut merupakan *fishbone diagram* untuk permasalahan yang terjadi.



GAMBAR I. 1
Fishbone Diagram

Berdasarkan Gambar I.4, kepala ikan dari fishbone tersebut adalah nilai MAPE > target perusahaan (<25%). Menurut (Chang, Wang, & Liu, 2007), kriteria MAPE untuk produk fashion adalah sebagai berikut:

TABEL I. 4
Kriteria MAPE

Nilai MAPE	Kriteria
$x < 10\%$	Kemampuan peramalan sangat baik
$10\% \leq x < 20\%$	Kemampuan peramalan baik
$20\% \leq x < 50\%$	Kemampuan peramalan cukup baik
$x \geq 50\%$	Kemampuan peramalan buruk

Menurut Maridakis (1998), MAPE 20-50% masih dianggap cukup baik untuk produk dengan tren permintaan tinggi seperti fashion. Namun, akurasi tersebut belum menjamin pemenuhan permintaan secara tepat waktu, sehingga system peramalan tetap perlu ditingkatkan untuk mencapai target perusahaan, yaitu MAPE < 25%.

Penelitian ini bertujuan untuk mengusulkan model peramalan yang akurat guna meminimasi nilai *gap* antara peramalan dan permintaan pada produk parfum Julis. Beberapa faktor yang menjadi akar masalah dalam peramalan, seperti metode, lingkungan, dan pengetahuan sumber daya manusia, telah diidentifikasi. Solusi yang diusulkan mencakup penggunaan metode *deep learning* untuk analisis data historis, prediksi permintaan pasar yang lebih akurat, serta pelatihan keahlian peramalan bagi tim terkait.

II. LANDASAN TEORI

A. Peramalan

Peramalan adalah metode untuk memperkirakan kemungkinan di masa depan dengan menganalisis data historis [1]. Aktivitas ini berfungsi sebagai dasar dalam perencanaan bisnis, termasuk proyeksi penjualan dan produksi. Meskipun hasil peramalan tidak sepenuhnya akurat karena ketidakpastian, pemilihan faktor penting dan model yang tepat dapat meningkatkan kedekatan hasil dengan kenyataan. Oleh karena itu, peramalan menjadi elemen penting dalam pengambilan keputusan strategis perusahaan [2].

Peramalan dapat dibedakan berdasarkan jangka waktu (pendek, menengah, panjang), sifat penyusunan (objektif dan subjektif), serta pendekatannya (kualitatif dan kuantitatif). Peramalan objektif menggunakan data dan metode analisis sistematis untuk meningkatkan validitas hasil, sedangkan peramalan subjektif lebih mengandalkan intuisi peramal.

Sementara itu, pendekatan kualitatif mengandalkan opini ahli, sedangkan pendekatan kuantitatif menggunakan model matematis yang memerlukan pemilihan metode yang sesuai untuk memastikan akurasi hasil [3].

B. Uji Kesalahan Peramalan

Keakuratan peramalan sangat penting karena kesalahan dapat menyebabkan perencanaan yang tidak efektif. Analisis kesalahan seperti MAD, MSE, dan MAPE digunakan untuk mengukur tingkat akurasi. MAD menunjukkan rata-rata kesalahan absolut, MSE menghitung rata-rata kuadrat kesalahan, dan MAPE memberikan persentase kesalahan terhadap data aktual. Semakin kecil nilai kesalahan yang dihasilkan, semakin baik tingkat akurasi metode peramalan yang digunakan, sehingga membantu perusahaan dalam menyusun perencanaan yang lebih efektif [4]. Berikut merupakan formula untuk menghitung MAD, MSE, dan MAPE.

$$MAD = \sum \left| \frac{At - Ft}{n} \right| \quad (1)$$

$$MSE = \sum \frac{(At - Ft)^2}{n} \quad (2)$$

$$MAPE = \left(\frac{100}{n} \right) \sum \left| At - \frac{Ft}{At} \right| \quad (3)$$

Keterangan:

At = Permintaan aktual pada periode-t

Ft = Peramalan permintaan pada periode-t


n = Jumlah periode permintaan

C. Machine Learning

Machine Learning adalah model komputasi statistik yang memungkinkan komputer membuat prediksi atau keputusan berdasarkan pola dari data pelatihan tanpa perlu diprogram secara langsung. Proses ini menggunakan algoritma untuk membangun model matematika yang dapat mempelajari data dan mendeteksi pola secara otomatis [5].

D. Artificial Neural Network (ANN)

Artificial Neural Network (ANN) adalah metode machine learning yang meniru cara kerja otak manusia untuk menangkap pola kompleks dalam data. ANN terdiri dari lapisan *input*, lapisan tersembunyi, dan lapisan *output*, dengan *neuron-neuron* yang saling terhubung untuk memodelkan hubungan antara *input* dan *output* [6].




Gambar II. 1
Jaringan ANN

Input layer menerima data awal, *hidden layer* memproses data dan mengidentifikasi pola kompleks, sementara *output layer* menghasilkan prediksi atau klasifikasi. Jumlah *hidden layer* bergantung pada tingkat kompleksitas masalah [7].

III.METODE

A. Kerangka Berpikir


Kerangka berpikir adalah model yang menggambarkan hubungan antara variabel dan langkah-langkah yang akan diambil untuk membantu peneliti menyelesaikan tugas akhir, seperti ditunjukkan pada Gambar III.1.




GAMBAR III. 1
Kerangka Berpikir

Penelitian ini menggunakan variabel hari khusus, diskon, harga, produk favorit, dan rating untuk membandingkan data aktual dengan data historis permintaan parfum. Data diolah melalui *preprocessing* dan dimodelkan menggunakan ANN untuk menghasilkan peramalan permintaan dan nilai *error*.

B. Sistematika Penyelesaian Masalah



GAMBAR III. 2
Sistematika Penyelesaian Masalah




GAMBAR III. 3
Sistematika Penyelesaian Masalah (Lanjutan)

IV.HASIL DAN ANALISIS

A. Pengolahan Data

Pada tahap ini dilakukan proses pengolahan data menggunakan google colab sebagai tools untuk membantu mengerjakan pengolahan data. Berikut merupakan alur pengerjaan yang dilakukan.



GAMBAR IV. 1
Flowchart Diagram

B. *Input Dataset*

Pada tahap ini melakukan *input dataset* yang berfungsi untuk membaca data yang akan diolah pada tahap selanjutnya. Terdapat 3 dataset yang digunakan pada penelitian ini, yaitu ‘dataset_vanillacake30.csv’, ‘dataset_vanillacake50.csv’, dan ‘dataset_vanillacake100.csv’. Berikut *code* dari proses *input dataset*:

```
file_path = 'dataset_vanillacake30.csv'
```

```
dataset = pd.read_csv(file_path)
```

GAMBAR IV. 2
Input Dataset

Mendefinisikan Variabel *Input* (x) dan Variabel *Output* (y)

Pada tahap ini merupakan pendefinisian variabel *input* (x) dan variabel *output* (y). Variabel x merupakan variabel independen yang berfungsi sebagai *input* untuk model prediksi, sedangkan variabel y merupakan variabel dependen yang berfungsi untuk menghasilkan *output* dari prediksi. Berikut *code* dari pendefinisian variabel x dan y:

```
X = dataset[['harga', 'favorite',
'diskon_shopee', 'diskon_tiktok',
'rating_shopee', 'rating_tiktok',
'hari_khusus', 'demand_1_mg_sblm',
'demand_2_mg_sblm',
'demand_sama_bln_sblm']]
y = dataset['demand']
```

GAMBAR IV. 3
Mendefinisikan Variabel x dan y

C. Membagi Data *Training* dan Data *Testing*

Tahap ini merupakan pembagian data *training* dan *testing*. Pada penelitian ini pembagian data menggunakan *test_size* sebesar 0.2, dimana 80% data digunakan sebagai data *training* dan 20% data digunakan sebagai data *testing*. Berikut *code* dari pembagian data *training* dan *testing*:

```
X_train, X_test, y_train, y_test =
train_test_split(X, y, test_size=0.2,
random_state=42)
```

GAMBAR IV. 4
Membagi Data Training dan Testing

D. Normalisasi Data

Tahap ini merupakan tahap normalisasi data dengan mengubah nilai-nilai dari *dataset* menjadi skala yang sama dengan tujuan agar membantu mempercepat proses pelatihan model. Berikut *code* dari normalisasi data:

```
scaler_X = MinMaxScaler()
scaler_y = MinMaxScaler()

X_train_scaled =
scaler_X.fit_transform(X_train)
X_test_scaled = scaler_X.transform(X_test)
y_train_scaled =
scaler_y.fit_transform(y_train.values.reshape(-1, 1))
y_test_scaled =
scaler_y.transform(y_test.values.reshape(-1, 1))
```

GAMBAR IV. 5
Normalisasi Data

E. Membangun Model ANN

Pada tahap ini merupakan tahap membangun model ANN dengan menggunakan beberapa parameter yang digunakan dalam menentukan pengerjaan model. Pada penelitian ini menggunakan model aktivasi 'relu' (*Rectified Linear Unit*) untuk membantu model belajar pola *nonlinear*. Lalu menggunakan *optimizer* 'Adam' (*Adaptive Moment Estimation*) karena kemampuannya untuk menyesuaikan kecepatan dalam pembelajaran model. Untuk struktur model yang digunakan yaitu dua hidden layer dengan tiga neuron

yang sama, yaitu 128, dan memiliki satu output layer. Berikut merupakan *code* dari membangun model ANN:

```
def build_model(input_dim):
    model = Sequential()
    model.add(Dense(128,
activation='relu', input_dim=input_dim))
    model.add(Dropout(0.2))
    model.add(Dense(128,
activation='relu'))
    model.add(Dropout(0.2))
    model.add(Dense(1))
    model.compile(optimizer='adam',
loss='mean_squared_error')
    return model

model=build_model(X_train_scaled.shape[1])
```

GAMBAR IV. 6
Membangun Model ANN

F. Melatih Model

Pada tahap ini dilakukan pelatihan model akan *epoch* dan *batch size* yang ditentukan untuk melatih model agar siap untuk melakukan prediksi pada data baru. *Epoch* adalah seberapa banyak model membaca data, sedangkan *batch size* adalah seberapa banyak data yang dipelajari sekaligus dalam satu waktu. Berikut merupakan *code* dari pelatihan model:

```
early_stopping=EarlyStopping(monitor='val_
loss', patience=10,
restore_best_weights=True)

model.fit(
    X_train_scaled, y_train_scaled,
    epochs=300,
    batch_size=32,
    validation_split=0.2,
    callbacks=[early_stopping],
    verbose=0
)
```

GAMBAR IV. 7
Melatih Model

Pada gambar IV.7 menunjukkan nilai *epoch* dan *batch size* yang digunakan. Untuk produk *Vanilla Cake* 30ml menggunakan *epoch* 300 dan *batch size* 32. Untuk produk *Vanilla Cake* 50ml menggunakan *epoch* 500 dan *batch size* 16. Sedangkan untuk produk *Vanilla Cake* 100ml menggunakan *epoch* 500 dan *batch size* 16.

G. Prediksi dan Evaluasi Model

Pada tahap ini dilakukan prediksi model dan evaluasi model yang telah dilakukan. Pada penelitian ini, evaluasi model menggunakan 3 perhitungan, yaitu MAD (*Mean Absolute Deviation*), MSE (*Mean Squared Error*), dan MAPE (*Mean Absolute Percentage Error*). Berikut merupakan *code* dari prediksi dan evaluasi model:

```
def evaluate_model(X_scaled, y_true,
desc=''):
    y_pred_scaled=model.predict(X_scaled)
    y_pred=scaler_y.inverse_transform(y_pred_scaled)
    y_true_=y_true.values.reshape(-1, 1)

    mape=np.mean(np.abs((y_true_ - y_pred)
/ y_true_)) * 100
```



```

mse=mean_squared_error(y_true_,
y_pred)
mad=mean_absolute_error(y_true_,
y_pred)
print(f"{desc} - MAPE: {mape:.2f}%,
MSE: {mse:.2f}, MAD: {mad:.2f}")

return pd.DataFrame({'Aktual':
y_true.values,
'Prediksi':
y_pred.flatten(),
'MAPE':
np.abs((y_true.values - y_pred.flatten()) /
y_true.values)})

```

GAMBAR IV. 8
Prediksi dan Evaluasi Model

H. Hasil Evaluasi Model

Pada tahap ini merupakan tampilan dari hasil evaluasi model yang telah dilakukan sebelumnya.

```

print("\nEvaluasi pada Data Tahun
Berikutnya:")
results_next_year=evaluate_model(X_next_year_scaled, y_next_year, desc="Next Year")

```

GAMBAR IV. 9
Hasil Evaluasi Model

Berikut merupakan hasil *code* diatas, yaitu evaluasi model pada setiap produknya:

```

MAD: 29.87
MSE: 1358.08
MAPE: 24.41%

```

GAMBAR IV. 10
Hasil Evaluasi Error Vanilla Cake 30ml

Pada gambar IV.10 menunjukkan hasil evaluasi model untuk produk *Vanilla Cake* 30ml dengan MAD sebesar 29,87, MSE sebesar 1358,08, dan MAPE sebesar 24,41%.

```

MAD: 36.48
MSE: 2020.62
MAPE: 22.80%

```

GAMBAR IV. 11
Hasil Evaluasi Error Vanilla Cake 30ml

Pada gambar IV.11 menunjukkan hasil evaluasi model untuk produk *Vanilla Cake* 50ml dengan MAD sebesar 36,48, MSE sebesar 2020,62, dan MAPE sebesar 22,80%.

```

MAD: 22.58
MSE: 762.24
MAPE: 22.80%

```

GAMBAR IV. 12
Hasil Evaluasi Error Vanilla Cake 30ml

Pada gambar IV.12 menunjukkan hasil evaluasi model untuk produk *Vanilla Cake* 100ml dengan MAD sebesar 22,58, MSE sebesar 762,24, dan MAPE sebesar 22,80%.

I. Hasil Prediksi

Pada tahap ini merupakan tampilan dari hasil prediksi masa depan menggunakan ANN.

```

print("\nHasil Prediksi Tahun
Berikutnya:")
print(results_next_year)

```

GAMBAR IV. 13
Hasil Prediksi

Berikut merupakan hasil *code* diatas, yaitu hasil prediksi pada setiap produknya:

Aktual	Prediksi
0	78 52.512070
1	73 53.358257
2	71 67.141335
3	87 63.240841
4	87 63.537899
5	101 77.636101
6	85 77.489471
7	115 85.179543
8	98 80.859634
9	141 81.480202
10	117 85.635323
11	89 91.379005
12	138 85.553566
13	136 78.844002
14	94 98.960785
15	120 94.653183
16	94 77.986534
17	137 94.135170
18	131 91.194344
19	96 92.425858
20	110 91.489685
21	110 80.397545
22	163 89.964241
23	101 84.654991
24	98 92.916794
25	90 82.468269
26	127 79.860619
27	165 92.013420
28	125 96.566994
29	145 93.510788
30	91 87.078964
31	142 95.100967
32	65 86.139587
33	72 94.588211
34	165 80.907478
35	82 83.655769
36	170 109.650154
37	90 79.941399
38	135 93.069557
39	135 92.507812

GAMBAR IV. 14
Hasil Prediksi Vanilla Cake 30ml

Aktual	Prediksi
0	87 147.182144
1	94 145.441788
2	185 149.614441
3	180 170.469833
4	213 181.337021
5	210 192.826355
6	169 188.026733
7	171 188.831680
8	244 202.156860
9	271 199.835220
10	239 203.138260
11	214 192.435532
12	186 204.434006
13	272 211.287125
14	224 225.823837

15	143	199.575958
16	164	202.445541
17	172	199.462524
18	187	195.930084
19	209	193.987915
20	206	200.832138
21	186	203.784958
22	251	188.786423
23	172	193.114700
24	189	189.165802
25	165	203.749268
26	187	203.122971
27	230	193.101944
28	95	190.946518
29	275	198.527817
30	185	201.257889
31	142	188.741104
32	143	206.915207
33	172	169.824966
34	165	207.785934
35	158	199.915344
36	270	176.841537
37	154	188.307724
38	101	201.168060
39	170	177.130524

GAMBAR IV. 15
Hasil Prediksi Vanilla Cake 50ml


	Aktual	Prediksi
0	97	64.055664
1	62	68.316025
2	48	70.206802
3	82	69.499992
4	97	69.258133
5	110	74.602592
6	72	79.848785
7	111	76.579308
8	120	77.702454
9	121	79.908615
10	76	82.293617
11	94	80.036659
12	101	84.561882
13	135	78.862007
14	89	88.032951
15	75	79.260811
16	113	75.980637
17	115	76.134201
18	103	89.403511
19	96	78.513557
20	111	79.544884
21	117	81.754288
22	133	86.194199
23	107	85.482849
24	89	85.973381
25	117	78.404533
26	86	84.982292
27	130	85.649948
28	75	86.042709
29	125	78.977188
30	85	78.621216
31	92	82.133896
32	78	79.852020
33	72	74.843445
34	65	75.919777
35	57	73.742401
36	125	74.339935
37	64	81.705215
38	51	78.666252

39 63 74.606224

GAMBAR IV. 16
Hasil Prediksi Vanilla Cake 100ml

J. Analisis Hasil

Penelitian ini membandingkan antara peramalan *eksisting* dan usulan dan berikut merupakan grafik yang menggambarkan hasil peramalan *eksisting* dan usulan.



GAMBAR IV. 17
Perbandingan Presentase Gap Kondisi Eksisting dan Kondisi Usulan

Pada gambar IV.17 memperlihatkan perbandingan *gap* antara hasil peramalan dengan data aktual untuk tiga varian ukuran produk parfum *Vanilla Cake*, yaitu 30ml, 50ml, dan 100ml. Pada varian 30ml, nilai *gap* menurun dari 25,3% menjadi 24,4%. Untuk varian 50ml, *gap* mengalami penurunan dari 24% menjadi 22,8%. Sementara itu, penurunan paling signifikan terjadi pada varian 100ml, dari 24,8% menjadi 22,8%, dengan selisih sebesar 2%. Penurunan *gap* ini mengindikasikan bahwa metode peramalan usulan mampu memberikan hasil prediksi yang lebih akurat dan lebih mendekati kondisi aktual permintaan di pasar dibandingkan metode *eksisting*. Dalam kondisi *eksisting*, model yang digunakan oleh perusahaan cenderung hanya mengandalkan data historis permintaan tanpa mempertimbangkan faktor-faktor eksternal dan variabel lain yang memiliki pengaruh besar terhadap fluktuasi permintaan, seperti hari khusus, diskon, harga, *rating* produk, dan favorit produk.

Berikut merupakan tabel yang menunjukkan perbandingan nilai MAD, MSE, dan MAPE dari kondisi *eksisting* dan kondisi usulan:

TABEL IV. 1
Nilai MAD, MSE, dan MAPE Kondisi Eksisting

Kondisi Eksisting			
Produk	30ml Vanilla Cake	50ml Vanilla Cake	100ml Vanilla Cake
MAD	13,12	16,22	4,37
MSE	1310,83	2288,66	671,83
MAPE	25,3%	24,0%	24,8%

TABEL IV. 2
Nilai MAD, MSE, dan MAPE Kondisi Usulan

Kondisi Usulan			
Produk	30ml Vanilla Cake	50ml Vanilla Cake	100ml Vanilla Cake
MAD	29,87	36,48	22,58
MSE	1358,08	2020,62	762,24
MAPE	24,4%	22,8%	22,8%

Menurut Makridakis (1998), toleransi terhadap kesalahan peramalan seperti MAPE sangat bergantung pada stabilitas permintaan dan karakteristik produk. Untuk produk-produk dengan volatilitas tinggi atau yang dipengaruhi oleh tren dan momen musiman, MAPE di atas 20% masih dapat diterima. Produk parfum termasuk ke dalam kategori ini karena permintaannya sangat dipengaruhi oleh faktor musiman, seperti hari raya, tren media sosial, dan perilaku konsumen yang cenderung berubah-ubah. Maka dari itu, nilai MAPE pada kondisi usulan yang berada di kisaran 22,8% hingga 24,4% sebenarnya masih dalam batas toleransi yang wajar dan dapat diterima.

Dengan mempertimbangkan aspek teknis tersebut, dapat disimpulkan bahwa model peramalan usulan berbasis ANN memberikan peningkatan yang signifikan dalam hal akurasi dan relevansi prediksi. Pendekatan ini tidak hanya mampu mengurangi nilai error, tetapi juga menyediakan dasar yang lebih kuat bagi perusahaan untuk merespons perubahan permintaan pasar secara adaptif dan strategis. Oleh karena itu, penerapan metode peramalan yang lebih canggih seperti ANN sangat dianjurkan untuk mendukung pengambilan keputusan bisnis yang lebih tepat sasaran, efisien, dan berorientasi pada kebutuhan pasar yang dinamis.

V. KESIMPULAN

Berdasarkan hasil penelitian ini, peramalan menggunakan *Artificial Neural Network* (ANN) berhasil meningkatkan akurasi prediksi permintaan parfum dibandingkan metode peramalan sebelumnya. Hasil evaluasi menunjukkan bahwa model usulan dengan mempertimbangkan variabel-variabel tambahan, seperti hari khusus, diskon, *rating*, favorit, dan harga produk, mampu menurunkan nilai kesalahan peramalan (MAD, MSE, dan MAPE). Model usulan ini berhasil meminimasi nilai *gap* antara permintaan aktual dan

peramalan sebesar 0,9% pada produk *Vanilla Cake* 30ml, 1,2% pada produk *Vanilla Cake* 50ml, dan 2% pada produk *Vanilla Cake* 100ml. Di sisi lain, usulan ini telah mencapai target perusahaan untuk nilai MAPE < 25%. Penurunan *gap* antara prediksi dan permintaan aktual menunjukkan bahwa pendekatan ini lebih efektif dalam memahami pola permintaan pasar.

REFERENSI

- [1] F. Ahmad, "PENENTUAN METODE PERAMALAN PADA PRODUKSI PART NEW GRANADA BOWL ST Di PT.X," *JISI: JURNAL INTEGRASI*, pp. 31-39, 2020.
- [2] M. H. Hamirsa and R. Rumita, "USULAN PERENCANAAN PERAMALAN (FORECASTING) DAN SAFETY STOCK PERSEDIAAN SPARE PART BUSI CHAMPION TYPE RA7YC-2 (EV01/EW-01/2) MENGGUNAKAN METODE TIME SERIES PADA PT TRIANGLE MOTORINDO SEMARANG," *Industrial Engineering Online*, pp. 1-10, 2022.
- [3] C. Iswahyudi, Pengantar Forecasting (Teknik Peramalan), 2015.
- [4] N. Chaaerunnisa and A. Momon, "PERBANDINGAN METODE SINGLE EXPONENTIAL SMOOTHING DAN MOVING AVERAGE PADA PERAMALAN PENJUALAN PRODUK MINYAK GORENG DI PT TUNAS BARU LAMPUNG," *Jurnal Rekayasa Sistem Industri*, pp. 101-106, 2021.
- [5] R. R. Santoso, R. Megasari and Y. A. Hambali, "Implementasi Metode Machine Learning Menggunakan Algoritma Evolving Artificial Neural Network Pada Kasus Prediksi Diagnosis Diabetes," *JATIKOM: Jurnal Aplikasi dan Teori Ilmu Komputer*, pp. 85-97, 2020.
- [6] M. Y. Habibi and E. Riksakomara, "Peramalan Harga Garam Konsumsi Menggunakan Artificial Neural Network Feedforward-Backpropagation (Studi Kasus : PT. Garam Mas, Rembang, Jawa Tengah)," *JURNAL TEKNIK*, pp. 306-310, 2017.
- [7] M. Uzair and N. Jamil, Effects of Hidden Layers on the Efficiency of Neural Network, 2020.