

BAB 3

ANALISIS DAN PERANCANGAN SISTEM

3.1 Analisis Sistem

Dalam penyusunan skripsi analisis sistem difokuskan pada pengembangan sistem prediksi permintaan obat di gudang farmasi IGD Rumah Sakit Petrokimia Gresik menggunakan metode *Support Vector Regression (SVR)*. Tahapan-tahapan analisa meliputi beberapa hal, seperti pemecahan masalah, melakukan uji model / representasi data dan pengumpulan data.

3.1.1 Pemecahan Masalah

Permasalahan utama yang dihadapi gudang farmasi IGD adalah ketidakakuratan dalam memprediksi permintaan obat yang dapat menyebabkan kelebihan atau kekurangan stok. Penelitian ini menggunakan data historis penjualan untuk memprediksi permintaan obat dengan menggunakan teknik *Support Vector Regression (SVR)* dengan pendekatan regresi.

Untuk mengatasi masalah ini, analisis sistem dilakukan dengan langkah-langkah sebagai berikut :

1. Identifikasi Masalah: Masalah utama adalah ketidakakuratan prediksi permintaan obat yang menyebabkan ketidakseimbangan stok.
2. Pengumpulan data : Mengumpulkan data historis penjualan obat dari Januari 2023 hingga Desember 2024 .
3. Praproses Data: Membersihkan data, menghapus outlier, dan normalisasi data dengan menyeleksi data dari database untuk memastikan bahwa data yang akan digunakan dalam analisis akurat dan relevan. Seperti kode barang, periode, jumlah (data penjualan yang sudah ditotal per periode).

Contoh data penjualan dengan kode barang 10K0124 dapat dilihat pada Tabel 3.1 di bawah ini.

Tabel 3. 1 Data penjualan kode barang 10K0124

Kode Barang	Periode	Total Jumlah
10K0124	Jan-23	6

Kode Barang	Periode	Total Jumlah
10K0124	Feb-23	5
10K0124	Mar-23	7
10K0124	Apr-23	5
10K0124	May-23	13
10K0124	Jun-23	6
10K0124	Jul-23	9
10K0124	Aug-23	14
10K0124	Sep-23	10
10K0124	Oct-23	11
10K0124	Nov-23	12
10K0124	Dec-23	6
10K0124	Jan-24	14
10K0124	Feb-24	11
10K0124	Mar-24	10
10K0124	Apr-24	10
10K0124	May-24	7
10K0124	Jun-24	4
10K0124	Jul-24	10
10K0124	Aug-24	11
10K0124	Sep-24	9
10K0124	Oct-24	10
10K0124	Nov-24	6
10K0124	Dec-24	9

1. Pemodelan : Membangun model prediksi menggunakan metode *SVR* dengan kernel RBF.
2. Optimasi Model : Menggunakan teknik *Grid Search* untuk mengoptimalkan parameter model seperti C, gamma, dan epsilon.

3. Evaluasi Model : Mengukur akurasi model menggunakan matrix *MAE*, *MSE*, *RMSE* dan *MAPE*.
4. Implementasi Sistem : Mengimplementasikan sistem prediksi permintaan obat berbasis *SVR* yang dapat digunakan oleh petugas gudang farmasi IGD.

3.1.2 Uji Model / Representasi Data

Untuk memastikan bahwa model yang dibangun dapat dengan akurat memprediksi permintaan obat, uji model dilakukan. Data yang dipakai dalam penelitian ini adalah data penjualan obat dari mulai Januari 2023 sampai Desember 2024. untuk menampilkan informasi seperti kode barang, jumlah penjualan, dan periode transaksi. Data yang digunakan dalam sistem mencakup :

1. Kode Barang: Identifikasi unik setiap obat.
2. Jumlah Penjualan: Jumlah unit obat yang terjual dalam periode tertentu.
3. Periode Transaksi: Waktu transaksi obat.

Langkah-langkah uji model yang akan dilakukan sebagai berikut:

1. Pembagian Data : Data akan dibagi menjadi dua bagian, yaitu data latih (80%) dan data uji (20%). Data latih digunakan untuk melatih model, sedangkan data uji digunakan untuk menguji akurasi model.
2. Normalisasi Data : Data dinormalisasi dengan menggunakan metode minmax scaling untuk memastikan semua fitur berada dalam rentang yang sama.
3. Pemodelan *SVR* : Model *SVR* dibangun menggunakan kernel *RBF*, parameter model seperti *C*, *gamma* dan *epsilon* dioptimalkan menggunakan *Grid Search*.
4. Evaluasi Model : Model dievaluasi menggunakan matrik evaluasi seperti *MAE*, *MSE*, *RMSE* dan *MAPE*. Hasil digunakan untuk menentukan apakah model sudah cukup akurat untuk digunakan dalam prediksi permintaan obat.

3.1.3 Metode pengumpulan data

Metode pengumpulan data yang digunakan adalah observasi dengan langsung terjun ke lapangan dan melihat secara langsung bagaimana karyawan mengelola

data barang di farmasi RS Petrokimia Gresik kemudian dokumentasi dengan langkah-langkah sebagai berikut :

1. Identifikasi Sumber Daya : Data diperoleh dari sistem manajemen persediaan obat di gudang farmasi IGD.
2. Pengumpulan Data : Data penjualan obat dikumpulkan secara berkala tiap bulan selama bulan Januari 2023 hingga Desember 2024 dari database persediaan gudang farmasi .
3. Penyimpanan Data : Data disimpan dalam format CSV untuk memudahkan proses analisis yang mencakup semua informasi, TRANSNO, KODETRANS, KODEBARANG, STAWAL, JUMLAH, STAKHIR, HRATA, PERIODE.
4. Pembersihan Data : Data yang sudah disimpan pada CSV dan sudah bersih dari outlier dan nilai-nilai tidak valid akan di import pada database sistem prediksi permintaan obat yang dibuat.

3.2 Perancangan Sistem

Adapun alur pemecahan masalah proses sistem yang dirancang untuk prediksi permintaan obat dapat dilihat pada Gambar 3.1 di bawah ini.



Gambar 3. 1 Flowchart Alur Pemecahan Masalah

1. Input Data: Petugas memasukkan kode obat yang ingin diprediksi.

2. Preprocessing Data: Data diambil dari database, dilakukan normalisasi, dan diproses untuk prediksi.
3. Prediksi Permintaan: Model *SVR* dengan kernel RBF dengan optimasi *Grid Search* melakukan prediksi berdasarkan data historis.
4. Evaluasi Hasil: Prediksi dievaluasi dengan *MAPE*, *MAE*, *MSE*, dan *RMSE*

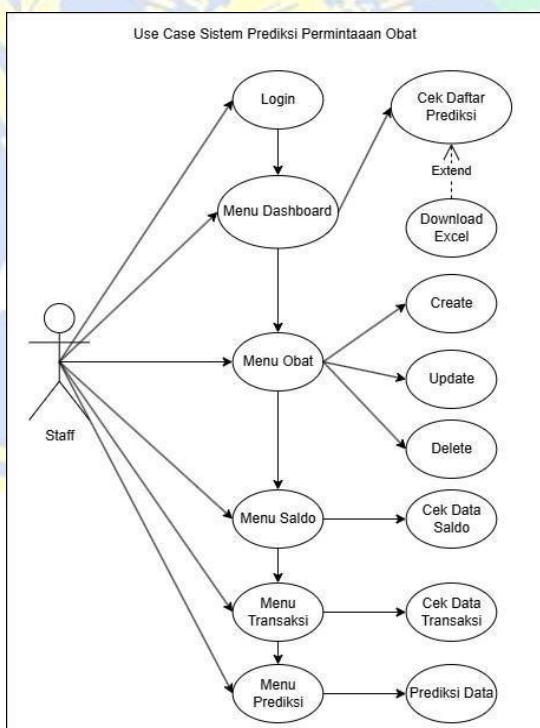
5. Output: Hasil prediksi ditampilkan dalam bentuk grafik dan angka di antarmuka pengguna.

Adapun beberapa alur proses yang digunakan seperti use case diagram dan activity diagram seperti dibawah ini.

1) Use Case Diagram Sistem Prediksi Permintaan Obat

Berikut adalah diagram use case yang menunjukkan interaksi antara sistem dan pengguna. Diagram ini memberikan Gambaran umum tentang fungsi utama yang disediakan oleh sistem serta orang-orang yang terlibat dalam prosesnya.

Diagram use case dapat dilihat pada Gambar 3.2 di bawah ini.



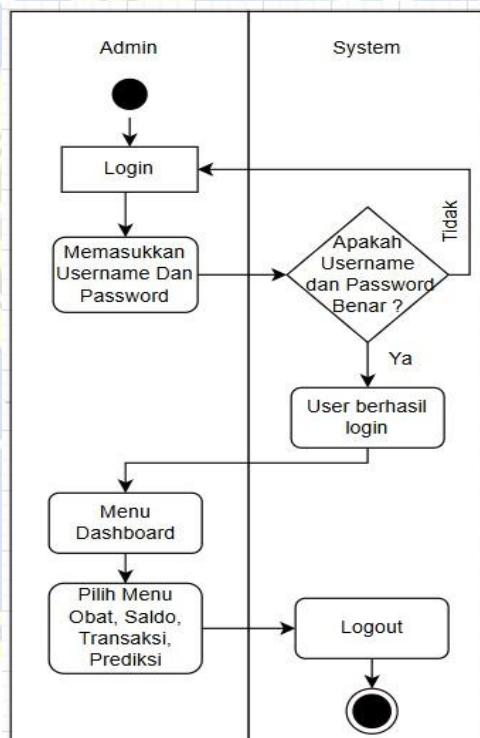
Gambar 3.2 Use Case Diagram Sistem Prediksi Permintaan Obat

2) Activity Diagram Sistem Prediksi Permintaan Obat

Setelah memahami bagaimana use case diagram menunjukkan interaksi pengguna dengan sistem, kita akan melihat activity diagram. Activity diagram menunjukkan langkah-langkah dan alur proses sistem prediksi permintaan obat, serta bagaimana setiap aktivitas berhubungan satu sama lain untuk mencapai tujuan akhir sistem. Beberapa Activity diagram pada sistem prediksi permintaan obat sebagai berikut :

A. Activity Diagram Login

Pada Gambar 3.3 menunjukkan proses diagram login. Diagram tersebut menggambarkan langkah-langkah yang diambil user untuk mengakses sistem, mulai dari memasukkan data username dan password, hingga berhasil masuk sampai keluar lagi aplikasi.

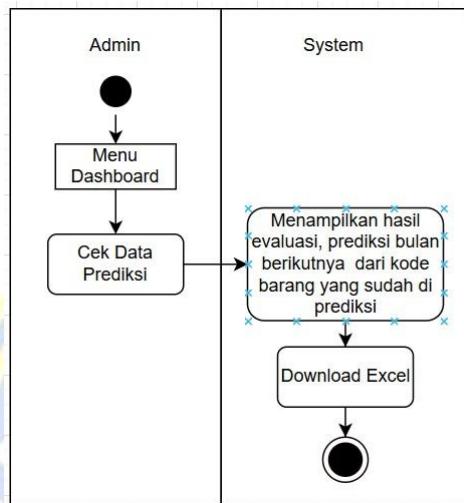


Gambar 3.3 Activity Diagram Login

B. Activity Diagram Dashboard

Pada Gambar 3.4 menunjukkan proses diagram dashboard. Diagram tersebut menggambarkan langkah-langkah setelah user berhasil login, kemudian user dapat

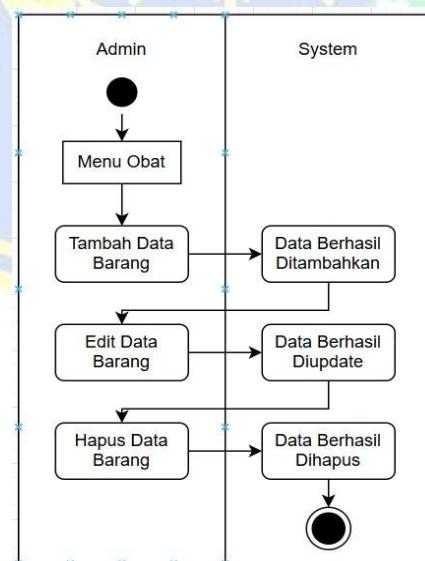
berinteraksi dengan fitur-fitur seperti cek data prediksi dari data-data kode barang yang sudah di prediksi, serta dapat mengunduh data tersebut dalam format excel.



Gambar 3. 4 Activity Diagram Dashboard

C. Activity Diagram Obat

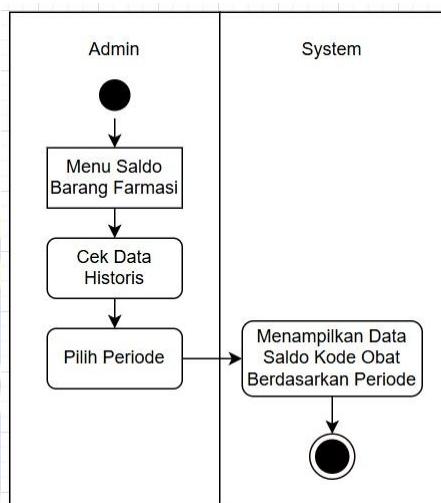
Pada Gambar 3.5 menunjukkan proses diagram obat. Diagram tersebut berkaitan dengan pengelolaan obat, diagram tersebut menggambarkan proses mulai dari pencarian obat hingga pemrosesan obat dalam sistem, seperti tambah, edit dan hapus data.



Gambar 3. 5 Activity Diagram Obat

D. Activity Diagram Saldo Obat

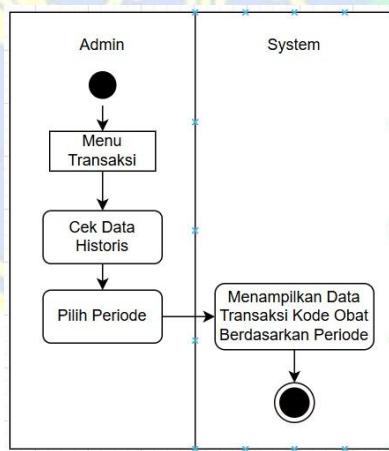
Pada Gambar 3.6 menunjukkan proses diagram saldo, menu ini hanya dapat melihat historis barang tiap periode atau bulan untuk pengecekan stok awal dan akhir dari setiap kode barang.



Gambar 3.6 Activity Diagram Saldo Obat

E. Activity Diagram Transaksi

Pada Gambar 3.7 menunjukkan proses diagram transaksi, menu ini juga hanya dapat melihat historis barang tiap periode dari data yang diambil pada sistem informasi persediaan barang selama Januari 2023 sampai Desember 2024.

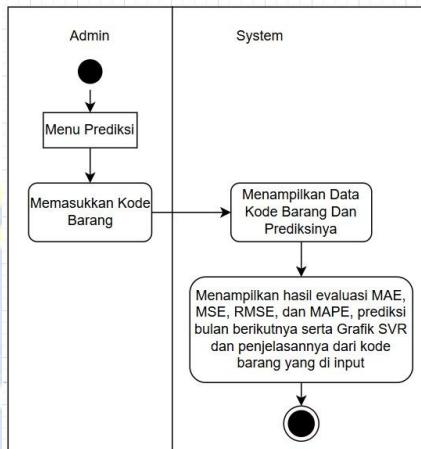


Gambar 3.7 Activity Diagram Transaksi

F. Activity Diagram Prediksi

Pada Gambar 3.8 menunjukkan proses diagram prediksi, menu ini menjelaskan proses prediksi permintaan obat mulai dari menginputkan kode barang, kemudian

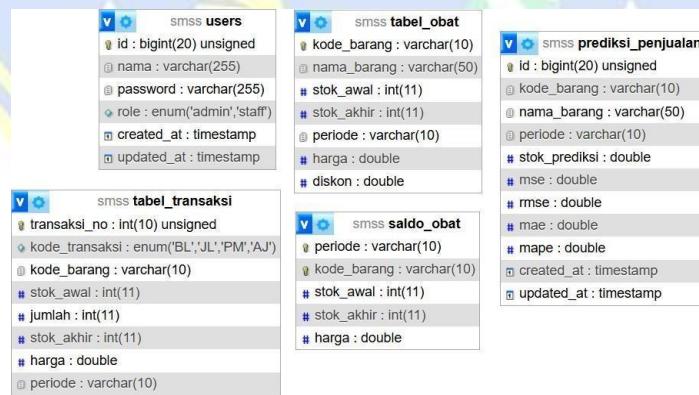
sistem akan melakukan prediksi dari kode barang tersebut. Sistem akan menampilkan semua data penjualan kode barang yang diinput dan hasil prediksi, menampilkan matrik evaluasi *MAE*, *MSE*, *RMSE*, dan *MAPE*, prediksi untuk periode bulan berikutnya, serta menampilkan grafik *SVR* dan penjelasannya.



Gambar 3. 8 Activity Diagram Prediksi

3.3 Perancangan Basis Data

Pada studi kasus gudang farmasi IGD RS Petrokimia Gresik, database sistem prediksi penjualan barang yang menggunakan metode *Support Vector Regression* (*SVR*) terdiri dari lima tabel, pada Gambar 3.9 menunjukkan tabel-tabel yang digunakan, diantaranya :



Gambar 3. 9 Class Diagram Sistem Prediksi Obat

1 Tabel users

Tabel 3. 2 Tabel Users

Column	Data type	Constraints
id	bigint(20)	PRIMARY KEY
nama	varchar(255)	
password	varchar(255)	
role	enum("admin","staff")	
created_at	timestamp	
update_at	timestamp	

2 Tabel tabel_obat

Tabel 3. 3 Tabel Obat

Column	Data type	Constraints
kode_barang	varchar(255)	PRIMARY KEY
nama_barang	varchar(255)	
stok_awal	int(10)	
stok_akhir	int(10)	
periode	varchar(255)	
harga	double	
diskon	double	

3 Tabel tabel_transaksi

Tabel 3. 4 Tabel Transaksi

Column	Data type	Constraints
transaksi_no	int(10) unsigned	PRIMARY KEY
kode_transaksi	enum("BL","JL")	
kode_barang	varchar(255)	FOREIGN KEY
stok_awal	int(10)	
Column	Data type	Constraints
jumlah	int(10)	

stok_akhir	int(10)	
harga	double	
periode	varchar(255)	

4 Tabel saldo_obat

Tabel 3. 5 Tabel Saldo

Column	Data type	Constraints
periode	varchar(255)	PRIMARY KEY
kode_barang	varchar(255)	FOREIGN KEY
stok_awal	int(10)	
stok_akhir	int(10)	
harga	double	

5 Tabel prediksi_penjualan

Tabel 3. 6 Tabel Prediksi Penjualan

Column	Data type	Constraints
id	bigint(20)	PRIMARY KEY
kode_barang	varchar(255)	FOREIGN KEY
nama_barang	varchar(255)	
periode	varchar(255)	
stok_prediksi	double	
MAE	double	
MSE	double	
RMSE	double	
Column	Data type	Constraints
MAPE	double	
created_at	timestamp	

update_at	timestamp	
-----------	-----------	--

Pada kasus ini struktur ERD adalah sebagai berikut :

- a) Tabel tabel_obat adalah tabel utama yang terhubung ke tabel_transaksi, saldo_obat, dan prediksi_penjualan melalui kode_barang. Namun kunci utama dan kunci asing yang dipakai hanya pada tabel_obat ke prediksi_penjualan. **prediksi_penjualan** memiliki hubungan **manyto-one** dengan **tabel_obat** melalui **kode_barang**.
- b) Untuk kunci utama dan kunci asing yang lain tidak dipakai.
- c) Tabel users adalah tabel terpisah yang tidak terhubung langsung dengan tabel lain.

3.4 Perancangan Antarmuka Sistem

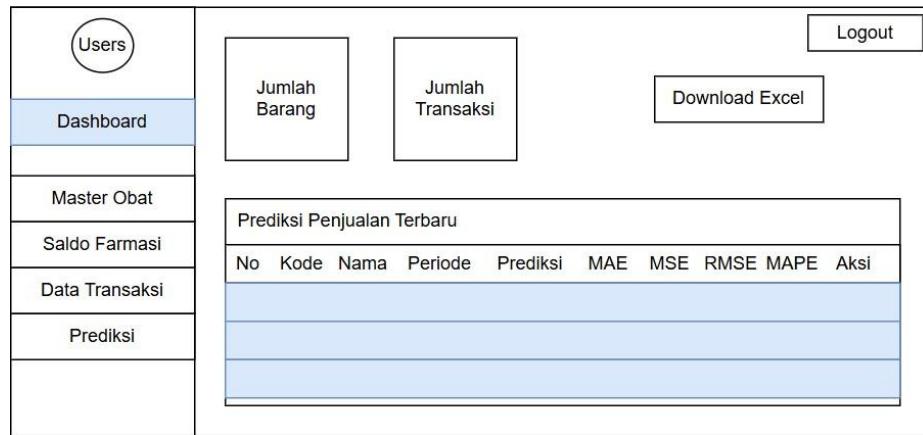
A. Interface Menu Login

Pada Gambar 3.10 menunjukkan interface menu login, dengan desain sederhana yang dapat beralih ke menu register dan form-form untuk memasukkan nama dan password sebagai syarat mengakses sistem.

Gambar 3. 10 Interface Menu Login

B. Interface Menu Dashboard

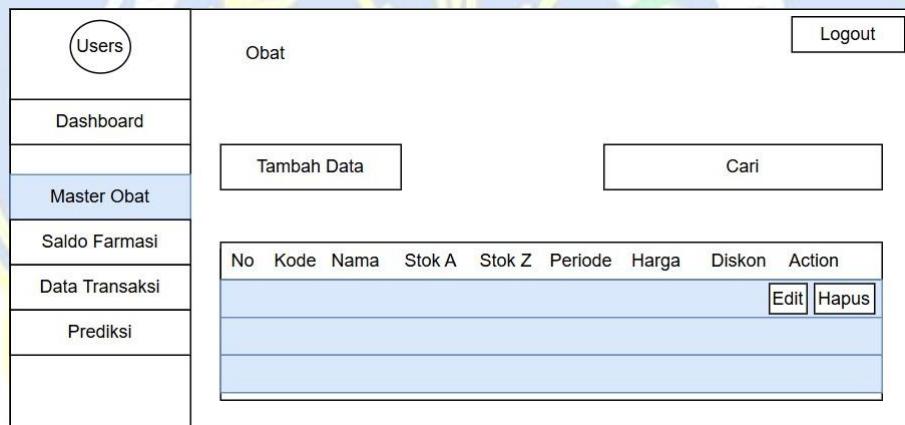
Selanjutnya, pada Gambar 3.11 menunjukkan menu dashboard sebagai pusat informasi bagi user dengan menampilkan berbagai fitur dan data penting secara ringkas, seperti jumlah barang, jumlah transaksi, download excel dan data kode barang yang sudah di prediksi.



Gambar 3. 11 Interface Menu Dashboard

C. Interface Menu Obat

Selanjutnya, pada Gambar 3.12 menunjukkan menu obat, interface ini memungkinkan user untuk mencari, menambah, mengedit, dan menghapus, serta mengelola informasi terkait obat.



Gambar 3. 12 Interface Menu Obat

D. Interface Menu Saldo

Selanjutnya, pada Gambar 3.13 menunjukkan menu saldo, interface ini memungkinkan user untuk melihat saldo stok obat per periodenya. Menu ini tidak ada interaksi CRUD (Create, Read, Update, Delete), karena hanya mengambil data per periode saja dari database persediaan gudang untuk melihat stok awal dan akhir obat tersebut setiap bulannya.

Gambar 3. 13 Interface Menu Saldo Obat

E. Interface Menu Transaksi

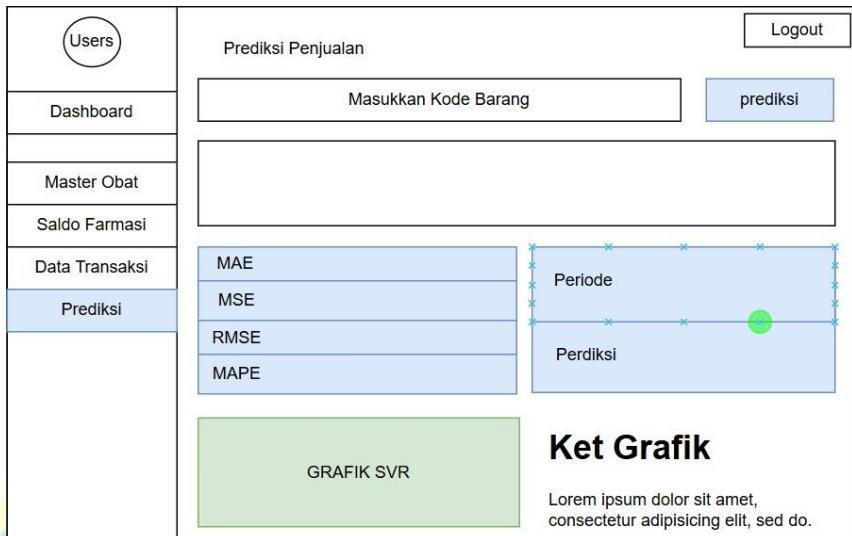
Selanjutnya, pada Gambar 3.14 menunjukkan menu transaksi, interface ini memungkinkan user untuk melihat transaksi obat per periodenya. Menu ini sama dengan menu saldo, tidak ada interaksi CRUD (Create, Read, Update, Delete), karena hanya mengambil data per periode saja dari database persediaan gudang untuk melihat jumlah transaksi penjualan obat setiap bulannya.

Gambar 3. 14 Interface Menu Transaksi

F. Interface Menu Prediksi

Selanjutnya, pada Gambar 3.15 menunjukkan menu prediksi, interface ini memungkinkan user untuk melakukan prediksi dari kode barang obat yang diinput, sistem akan menampilkan semua data asli dari kode barang yang diinput dan prediksinya, dengan 80% data latih dan 20% data uji yang sudah di coding, kemudian di kolom bawahnya sistem akan menampilkan metrik evaluasinya *MAE*, *MSE*, *RMSE* dan *MAPE* serta periode bulan berikutnya dengan hasil prediksinya.

Lalu dibawahnya lagi sistem akan menampilkan grafik plot *SVR* serta penjelasan terkait grafik tersebut.



Gambar 3. 15 Interface Menu Prediksi

3.5 Perancangan Pengujian

Pengujian ini bertujuan untuk memastikan bahwa sistem yang dibangun dapat memberikan prediksi yang cukup akurat dan sesuai dengan kebutuhan gudang farmasi IGD RS Petrokimia Gresik. Berikut adalah penjelasan detail mengenai perancangan pengujian: 1. Jumlah dan pembagian data latih dan uji

Data yang dipakai di dalam penelitian ini adalah data histori penjualan obat dari mulai bulan Januari 2023 hingga Desember 2024. Data yang digunakan mencakup kode barang, jumlah penjualan, dan periode transaksi.

Untuk pembagian datanya dibagi menjadi dua bagian, yaitu :

- 1) Data Latih (Training Data): 80% dari total data digunakan untuk melatih model *SVR*. Data latih ini akan digunakan untuk membangun model prediksi dengan mempelajari pola dari data historis.
- 2) Data Uji (Testing Data): 20% dari total data digunakan untuk menguji akurasi model. Data uji ini akan digunakan untuk mengevaluasi seberapa baik model yang telah dibangun dapat memprediksi permintaan obat.

Jika total data adalah 24 bulan (Januari 2023 hingga Desember 2024), maka:

- a) Data latih: 19 bulan (80% dari 24 bulan).

- b) Data uji: 5 bulan (20% dari 24 bulan).
2. Langkah-langkah pengujian yang akan dilakukan
- Pengumpulan Data

Mengumpulkan data histori penjualan obat dari database persediaan gudang farmasi IGD dari periode Januari 2023 sampai Desember 2024. Data yang digunakan untuk prediksi permintaan ini mencakup kode barang, jumlah penjualan dan periode penjualan.
 - Praproses Data

Membersihkan data dari nilai-nilai yang tidak valid dan menghapus outlier, kemudian melakukan normalisasi data menggunakan *min-max scaling* untuk memastikan bahwa fitur berada dalam rentang yang sama.
 - Pembagian Data

Setelah data dinormalisasi data dibagi menjadi 80% data latih dan 20% data uji.
 - Pemodelan dengan *SVR*

Kemudian membangun model dengan metode *Support Vector Regression (SVR)* dengan kernel *Radial Basis Function (RBF)*, dan dioptimalkan dengan teknik *Grid Search* untuk mencari parameter model *C*, *gamma* dan *epsilon* terbaik.
 - Evaluasi Model

Menguji model dengan data uji, serta menghitung akurasi model menggunakan metrik evaluasi *MAE*, *MSE*, *RMSE*, dan *MAPE*.
 - Interpretasi Hasil

Menampilkan hasil prediksi periode bulan berikutnya dan menampilkan grafik hasil prediksi *SVR* beserta keterangannya berdasarkan kode barang yang diinputkan.
3. Instrumen pengujian dari sistem yang akan dibangun
- Untuk menguji sistem yang dibangun, beberapa instrumen pengujian yang akan digunakan, antara lain :
- Matrik Evaluasi

1. *Mean Absolute Error (MAE)* : Mengukur rata-rata kesalahan absolut antara nilai prediksi dan nilai aktual.
2. *Mean Squared Error (MSE)* : Mengukur rata-rata kesalahan kuadrat antara nilai prediksi dan nilai aktual.
3. *Root Mean Squared Error (RMSE)* : Mengukur akar kuadrat dari rata-rata kesalahan kuadrat.
4. *Mean Absolute Percentage Error (MAPE)* : Mengukur rata-rata kesalahan dalam bentuk persentase dari nilai aktual.

b) Grafik Hasil Prediksi

Sistem akan menampilkan hasil prediksi *SVR* berdasarkan kode barang yang diinputkan oleh user. Grafik ini membandingkan antara data asli (nilai aktual) dan prediksi model. Jika garis prediksi model mendekati atau sesuai dengan garis data asli, berarti model *SVR* bekerja dengan baik dan mampu memprediksi permintaan obat dengan akurat. Titik-titik yang ditandai sebagai support vectors menunjukkan data yang paling berpengaruh dalam membentuk model. Titik-titik ini biasanya berada di dekat atau di luar margin toleransi (ϵ) yang ditentukan oleh model. Jika ada jarak antara garis prediksi model dan data asli, itu menunjukkan error atau kesalahan prediksi. Semakin kecil jaraknya, semakin akurat model tersebut.

c) Laporan Hasil Pengujian

Hasil pengujian mencakup nilai *MAE*, *MSE*, *RMS*, dan *MAPE*, prediksi permintaan kode barang yang diinput untuk periode bulan berikutnya, serta grafik support vector.

3.6 Data Dan Perhitungan

1) Menyiapkan Data

Data yang digunakan adalah data dengan kode barang 10K0124 (SC BRITENING 50) dari Januari 2023 sampai Desember 2024.

Tabel 3. 7 Data Penjualan SC BRITENING 50

Periode	Jumlah Total
---------	--------------

Jan-23	6
Feb-23	5
Mar-23	7
Apr-23	5
May-23	13
Jun-23	6
Jul-23	9
Aug-23	14
Sep-23	10
Oct-23	11
Nov-23	12
Dec-23	6
Jan-24	14
Feb-24	11
Mar-24	10
Apr-24	10
May-24	7
Jun-24	4
Jul-24	10
Aug-24	11
Sep-24	9
Oct-24	10
Nov-24	6
Dec-24	9

2) Normalisasi Data

Karena *SVR* sensitif terhadap skala data, maka dilakukan normalisasi pada indeks waktu. X = indeks waktu

X_{min} = 0 (Januari 2023)

X_{max} = 23 (Desember 2024)

Contoh perhitungan (Agustus 2024 – X = 19)

$$X_{scaled} = \frac{19 - 0}{23 - 0} = \frac{19}{23} = 0,826$$

Tabel 3. 8 Hasil Normalisasi Indeks Waktu

Periode	Indeks Waktu	X (Normalisasi)
Jan-23	0	0.000
Feb-23	1	0.043

Mar-23	2	0.087
Apr-23	3	0.130
May-23	4	0.174
Jun-23	5	0.217
Jul-23	6	0.261
Aug-23	7	0.304
Sep-23	8	0.348
Oct-23	9	0.391
Nov-23	10	0.435
Dec-23	11	0.478
Jan-24	12	0.522
Feb-24	13	0.565
Mar-24	14	0.609
Apr-24	15	0.652
May-24	16	0.696
Jun-24	17	0.739
Jul-24	18	0.783
Aug-24	19	0.826
Sep-24	20	0.870
Oct-24	21	0.913
Nov-24	22	0.957
Dec-24	23	1000

3) Menentukan Parameter Terbaik dengan *Grid Search*

Grid Search digunakan untuk menemukan kombinasi C , γ , dan ϵ terbaik.

Misalkan *Grid Search* dilakukan dengan kombinasi berikut:

- a) $C = [0.1, 1, 10, 100]$ = Mengontrol seberapa keras margin SVM.
- b) $\gamma = [0.01, 0.1, 1]$ = Mengontrol jarak pengaruh dari sebuah support vector dalam *RBF* kernel.
- c) $\epsilon = [0.01, 0.1, 1]$ = Menentukan margin error dalam *SVR*.

Berikut adalah penjelasan dari setiap kombinasi

- a) Parameter $C = [0.1, 1, 10, 100]$

Mempunyai 4 nilai dengan 3 kenaikan, nilai-nilai tersebut naik dengan skala

logaritmik (basis 10) :

Dari $0.1 \rightarrow 1 \rightarrow 10 \rightarrow 100 \rightarrow$ kenaikan $10x$ setiap langkah.

C kecil → model lebih toleran terhadap error, lebih smooth.

C besar → model akan berusaha keras mengurangi error, tapi bisa overfit.

b) Gamma (γ) = [0.01, 0.1, 1]

Mempunyai 3 nilai dengan 2 kenaikan, nilai-nilai tersebut naik dengan skala logaritmik (basis 10) :

Dari 0.01 → 0.1 → 1 → kenaikan juga 10x setiap langkah.

Gamma kecil = pengaruh data point tersebar luas (lebih smooth).

Gamma besar = pengaruhnya tajam (berfokus lokal), bisa overfit.

c) Epsilon (ϵ) = [0.01, 0.1, 1]

Mempunyai 3 nilai dengan 2 kenaikan, nilai-nilai tersebut naik dengan skala logaritmik (basis 10) :

Dari 0.01 → 0.1 → 1 kenaikan juga 10x setiap langkah.

Epsilon kecil = model lebih ketat (lebih akurat, tapi mungkin overfit).

Epsilon besar = model mengabaikan error kecil (lebih generalisasi).

Semua parameter menggunakan skala logaritmik basis 10 (faktor 10x antar nilai), namun dengan jumlah kenaikan yang bereda, dimana C mempunyai 4 kenaikan, sedangkan gamma dan epsilon mempunyai 3 kenaikan.

Dilakukan uji untuk setiap kombinasi dengan cross-validation 3 dan memilih parameter yang memberikan error terkecil. Perhitungan ini menggunakan bantuan pemrograman python dan mendapatkan hasil parameter terbaik $C = 10$, $\gamma = 0.1$, $\epsilon = 0.1$. Namun untuk perhitungan manual akan seperti ini dengan Cross Validation = 3 contoh perhitungannya.

Perhitungan kombinasi pertama $C = 0.1$, $gamma = 0.01$, $epsilon = 0.01$

1. Pembagian Data (3 Folds Berdasarkan Indeks Waktu):

a) Fold 1 (Data Training 1 & 2, Data Uji 3): Periode Jan-23 s/d Sep-23

(Indeks 0-8)

b) Fold 2 (Data Training 1 & 3, Data Uji 2): Periode Jan-23 s/d Mar-23

(Indeks 0-2) dan Okt-23 s/d Des-24 (Indeks 9-23)

- c) Fold 3 (Data Training 2 & 3, Data Uji 1): Periode Apr-23 s/d Sep-24
(Indeks 3-20) dan Jan-24 s/d Des-24 (Indeks 12-23)
2. Simulasi Pelatihan dan Prediksi
- a) Iterasi 1 (Fold 3 sebagai Data Uji):
- Data Training: (Jan-23 s/d Sep-23) - Jumlah Total: [6, 5, 7, 5, 13, 6, 9, 14, 10]
Jumlah data training = 9
Rata-rata "Jumlah Total" data training = $(6 + 5 + 7 + 5 + 13 + 6 + 9 + 14 + 10) / 9 = 75 / 9 = 8.33$
Data Uji: (Okt-23 s/d Des-24) - Jumlah Total: [11, 12, 6, 14, 11, 10, 10, 7, 4, 10, 11, 9, 10, 6, 9]
Simulasi Prediksi: Kita asumsikan prediksi untuk data uji adalah rata-rata data training ditambah sedikit variasi: [8.5, 8.2, 8.7, 8.1, 8.6, 8.3, 8.4, 8.8, 8.0, 8.5, 8.2, 8.7, 8.1, 8.6, 8.3].
Perhitungan MAE Iterasi 1:
Nilai Aktual (Data Uji): [11, 12, 6, 14, 11, 10, 10, 7, 4, 10, 11, 9, 10, 6, 9]
Nilai Prediksi (Simulasi): [8.5, 8.2, 8.7, 8.1, 8.6, 8.3, 8.4, 8.8, 8.0, 8.5, 8.2, 8.7, 8.1, 8.6, 8.3]
Nilai Absolut Error: $|11 - 8.5|, |12 - 8.2|, |6 - 8.7|, |14 - 8.1|, |11 - 8.6|, |10 - 8.3|, |10 - 8.4|, |7 - 8.8|, |4 - 8.0|, |10 - 8.5|, |11 - 8.2|, |9 - 8.7|, |10 - 8.1|, |6 - 8.6|, |9 - 8.3|$
Nilai Absolut Error: [2.5, 3.8, 2.7, 5.9, 2.4, 1.7, 1.6, 1.8, 4.0, 1.5, 2.8, 0.7, 1.9, 2.6, 0.7]
 $MAE \text{ Iterasi } 1 = (2.5 + 3.8 + 2.7 + 5.9 + 2.4 + 1.7 + 1.6 + 1.8 + 4.0 + 1.5 + 2.8 + 0.7 + 1.9 + 2.6 + 0.7) / 15 = 36.6 / 15 = 2.44$
- b) Iterasi 2 (Fold 2 sebagai Data Uji):
- Data Training: (Jan-23 s/d Mar-23) & Baris 11-25 (Okt-23 s/d Des-24)
Jumlah Total: [6, 5, 7, 11, 12, 6, 14, 11, 10, 10, 7, 4, 10, 11, 9, 10, 6, 9]
Jumlah data training = $3 + 15 = 18$
Rata-rata "Jumlah Total" data training = $(6 + 5 + 7 + 11 + 12 + 6 + 14 + 11 + 10 + 10 + 7 + 4 + 10 + 11 + 9 + 10 + 6 + 9) / 18 = 168 / 18 = 9.33$

Data Uji: (Apr-23 s/d Sep-23) - Jumlah Total: [5, 13, 6, 9, 14, 10] Simulasi Prediksi: Kita asumsikan prediksi untuk data uji adalah rata-rata data training ditambah sedikit variasi: [9.5, 9.0, 9.8, 9.2, 9.7, 9.1] Perhitungan *MAE* Iterasi 2:

Nilai Aktual (Data Uji): [5, 13, 6, 9, 14, 10]

Nilai Prediksi (Simulasi): [9.5, 9.0, 9.8, 9.2, 9.7, 9.1]

Nilai Absolut Error: |5-9.5|, |13-9.0|, |6-9.8|, |9-9.2|, |14-9.7|, |10-9.1|

Nilai Absolut Error: [4.5, 4.0, 3.8, 0.2, 4.3, 0.9]

$$MAE \text{ Iterasi } 2 = (4.5 + 4.0 + 3.8 + 0.2 + 4.3 + 0.9) / 6 = 17.7 / 6 = 2.95$$

c) Iterasi 3 (Fold 1 sebagai Data Uji):

Data Training: (Apr-23 s/d Des-24) - Jumlah Total: [5, 13, 6, 9, 14, 10, 11, 12, 6, 14, 11, 10, 10, 7, 4, 10, 11, 9, 10, 6, 9]

Jumlah data training = 21

$$\text{Rata-rata "Jumlah Total" data training} = (5 + 13 + 6 + 9 + 14 + 10 + 11 + 12 + 6 + 14 + 11 + 10 + 10 + 7 + 4 + 10 + 11 + 9 + 10 + 6 + 9) / 21 = 197 / 21 = 9.38$$

Data Uji: (Jan-23 s/d Mar-23) - Jumlah Total: [6, 5, 7]

Simulasi Prediksi: Kita asumsikan prediksi untuk data uji adalah rata-rata data training ditambah sedikit variasi: [9.5, 9.0, 9.8].

Perhitungan *MAE* Iterasi 3:

Nilai Aktual (Data Uji): [6, 5, 7]

Nilai Prediksi (Simulasi): [9.5, 9.0, 9.8]

Nilai Absolut Error: |6-9.5|, |5-9.0|, |7-9.8|

Nilai Absolut Error: [3.5, 4.0, 2.8]

$$MAE \text{ Iterasi } 3 = (3.5 + 4.0 + 2.8) / 3 = 10.3 / 3 = 3.43$$

3. Perhitungan *MAE* untuk Setiap Iterasi

$$\text{Rata-rata } MAE = (MAE \text{ Iterasi } 1 + MAE \text{ Iterasi } 2 + MAE \text{ Iterasi } 3) / 3$$
$$\text{Rata-rata } MAE = (2.44 + 2.95 + 3.43) / 3 = 8.82 / 3 = 2.94$$

Untuk perhitungan kombinasi kedua C = 0.1, gamma = 0.01, epsilon = 0.1

a) Fold 1 (Fold 3 sebagai data uji)

Data Training: [6, 5, 7, 5, 13, 6, 9, 14, 10]

Rata-rata: 8.33

Data Uji: [11, 12, 6, 14, 11, 10, 10, 7, 4, 10, 11, 9, 10, 6, 9]

Simulasi Prediksi: [8.8, 8.3, 8.1, 8.5, 8.2, 8.6, 8.0, 8.6, 8.4, 8.7, 8.9, 9.3, 9.1, 9.0, 9.2]

Perhitungan *MAE* Iterasi 1:

Nilai Absolut Error: [2.2, 3.7, 2.1, 5.5, 2.8, 1.4, 2, 1.6, 4.4, 1.3, 2.1, 0.3, 0.9, 3, 0.2]

MAE Iterasi 1: 2.23

b) Fold 2 (Fold 2 sebagai data uji)

Data Training: [6, 5, 7, 11, 12, 6, 14, 11, 10, 10, 7, 4, 10, 11, 9, 10, 6, 9]

Rata-rata: 9.33

Data Uji: [5, 13, 6, 9, 14, 10]

Simulasi Prediksi: [8.9, 9.4, 9.0, 9.3, 9.1, 9.2] Perhitungan

MAE Iterasi 2:

Nilai Absolut Error: [3.9, 3.6, 3, 0.3, 4.9, 0.8]

MAE Iterasi 2: 2.75

c) Fold 3 (Fold 1 sebagai data uji)

Data Training: [5, 13, 6, 9, 14, 10, 11, 12, 6, 14, 11, 10, 10, 7, 4, 10, 11, 9, 10, 6, 9]

Rata-rata: 9.38

Data Uji: [6, 5, 7]

Simulasi Prediksi: [9.0, 9.5, 10.0] Perhitungan

MAE Iterasi 3:

Nilai Absolut Error: [3, 4.5, 3]

MAE Iterasi 3: 3.5

d) Rata-rata *MAE* = $(2.23 + 2.75 + 3.5) / 3 = 2.82$

Untuk perhitungan kombinasi ketiga C = 0.1, gamma = 0.01, epsilon = 1

a) Fold 1 (Fold 3 sebagai data uji)

Data Training: [6, 5, 7, 5, 13, 6, 9, 14, 10]

Rata-rata: 8.33

Data Uji: [11, 12, 6, 14, 11, 10, 10, 7, 4, 10, 11, 9, 10, 6, 9]

Simulasi Prediksi: [9.5, 9.2, 9.7, 9.1, 9.6, 9.3, 9.4, 9.8, 9.0, 9.5, 9.2, 9.7, 9.1, 9.6, 9.3]

Perhitungan *MAE* Iterasi 1:

Nilai Absolut Error: [1.5, 2.8, 3.7, 4.9, 1.4, 0.7, 0.6, 2.8, 5.0, 0.5, 1.8, 0.3, 0.9, 3.6, 0.3]

MAE Iterasi 1: 2.14

- b) Fold 2 (Fold 2 sebagai data uji)

Data Training: [6, 5, 7, 11, 12, 6, 14, 11, 10, 10, 7, 4, 10, 11, 9, 10, 6, 9]

Rata-rata: 9.33

Data Uji: [5, 13, 6, 9, 14, 10]

Simulasi Prediksi: [10.5, 10.0, 10.8, 10.2, 10.7, 10.1] Perhitungan *MAE* Iterasi 2:

Nilai Absolut Error: [5.5, 3.0, 4.8, 1.2, 3.3, 0.1]

MAE Iterasi 2: 2.88

- c) Fold 3 (Fold 1 sebagai data uji)

Data Training: [5, 13, 6, 9, 14, 10, 11, 12, 6, 14, 11, 10, 10, 7, 4, 10, 11, 9, 10, 6, 9]

Rata-rata: 9.38

Data Uji: [6, 5, 7]

Simulasi Prediksi: [10.5, 10.0, 10.8] Perhitungan *MAE* Iterasi 3:

Nilai Absolut Error: [4.5, 5.0, 3.8]

MAE Iterasi 3: 4.43

- d) Rata-Rata *MAE* = Rata-rata *MAE* = $(2.14 + 2.88 + 4.43) / 3 = 3.15$

Tabel 3. 9 Hasil Pencarian Parameter Terbaik Menggunakan *Grid Search*

C	Gamma (γ)	Epsilon (ϵ)	MAE
0.1	0.01	0.01	2.94
0.1	0.01	0.1	2.82
0.1	0.01	1	3.15

0.1	0.1	0.01	2.98
0.1	0.1	0.1	2.75
0.1	0.1	1	3.92
0.1	1	0.01	2.67
0.1	1	0.1	2.51
0.1	1	1	3.65
1	0.01	0.01	2.45
1	0.01	0.1	2.33
1	0.01	1	3.72
1	0.1	0.01	2.22
1	0.1	0.1	2.05
1	0.1	1	3.15
1	1	0.01	2.03
1	1	0.1	1.92
1	1	1	2.98
10	0.01	0.01	1.98
10	0.01	0.1	1.81
10	0.01	1	2.85
10	0.1	0.01	1.76
10	0.1	0.1	1.44
10	0.1	1	2.75
10	1	0.01	1.72
10	1	0.1	1.58
10	1	1	2.64
100	0.01	0.01	2.15
100	0.01	0.1	1.92
100	0.01	1	2.88
100	0.1	0.01	1.81
100	0.1	0.1	1.62
100	0.1	1	2.77
100	1	0.01	1.76
100	1	0.1	1.65
100	1	1	2.71

4) Perhitungan Kernel RBF

Setelah dilakukan normalisasi dan mendapatkan nilai gamma dari kombinasi terbaik *Grid Search*, nilai gamma yang digunakan adalah ($\gamma = 0.1$) untuk menghitung kernel antara setiap pasangan data. Contoh perhitungan kernel RBF akan seperti ini (Agustus 2024).

Untuk menghitung bulan Agustus maka mengambil titik referensi sebelumnya, July mendapat hasil ($X = 0.783$).

$$K(0.826, 0.783) = \exp(-0.1 \times (0.826 - 0.783)^2)$$

$$= \exp(-0.1 \times 0.00186) = \exp(-0.000186) = 0.9998$$

Tabel 3. 10 Perhitungan Kernel RBF untuk Data Latih

Periode	X (Normalisasi)	Kernel RBF terhadap X sebelumnya
Jan-23	0.000	-
Feb-23	0.043	0,999815
Mar-23	0.087	0,999806
Apr-23	0.130	0,999815
Mei-23	0.174	0,999806
Jun-23	0.217	0,999815
Jul-23	0.261	0,999806
Aug-23	0.304	0,999815
Sep-23	0.348	0,999806
Oct-24	0.391	0,999815
Nov-23	0.435	0,999806
Dec-23	0.478	0,999815
Jan-24	0.522	0,999806
Feb-24	0.565	0,999815
Mar-24	0.609	0,999806
Apr-24	0.652	0,999815
Mei-24	0.696	0,999806
Jun-24	0.739	0,999815
Jul-24	0.783	0,999806

Tabel 3. 11 Perhitungan Kernel RBF untuk Data Uji

Periode	X (Normalisasi)	Kernel RBF terhadap X sebelumnya
Aug-24	0.826	0.9998

Sep-24	0.870	0.9995
Oct-24	0.913	0.9991
Nov-24	0.957	0.9986
Dec-24	1000	0.9982

5) Menghitung Prediksi

Setelah itu dilakukan proses perhitungan prediksi, karena nilai α_i , α_i^* (Lagrange multipliers) dan b (bias) dihitung melalui proses optimasi numerik (yang dilakukan oleh *SVR*), dan perhitungan prediksi juga akan dilakukan dengan bantuan pemrograman python.

```
# Mendapatkan nilai Bias (b) bias = best_SVR.intercept_[0]
# Mendapatkan nilai α (Lagrange Multipliers) alphas = best_SVR.dual_coef_[0]
# ( $\alpha_i - \alpha_i^*$ ) support_vectors =
best_SVR.support_vectors_ support_indices
= best_SVR.support_
a) Nilai α (Lagrange Multipliers): [-1,-1, -1, -1, 1, -1, -0.9827004, 1, 1, 1,
1,-1, 1, 1, 1, 1, -1, -1, -0.0172996]
b) Nilai Bias (b): 8.896311709880829
# Predicting the training and testing data y_train_pred =
best_SVR.predict(X_train) y_test_pred = best_SVR.predict(X_test)
```

Contoh perhitungan manual untuk bulan Agustus 2024 dengan nilai kernel RBF sebelumnya 0.9998

$$F(X \text{ Agustus } 2024) = \sum(\alpha_i - \alpha_i^*)K(X_i, X \text{ Agustus } 2024) + b$$

$$F(\text{Agustus}2024) = (-1*0.9998) + (-1*0.9998) + (-1*0.9998) + (-1*0.9998) + (1*0.9998) + (-0.9827004*0.9998) + (1*0.9998) + (1*0.9998) + (1*0.9998) + (-1*0.9998) + (1*0.9998) + (1*0.9998) + (1*0.9998) + (1*0.9998) + (-1*0.9998) + (-1*0.9998) + 8.896311709880829$$

$$F(\text{Agustus}2024) = (-0.9998 \times 6) + (0.9998 \times 10) + (0.9998 \times -0.9827004) + (0.9998 \times -0.0172996)$$

$$F(\text{Agustus2024}) = (-5.9988) + (9.988) + (-0.98250286) + (-0.01729692)$$

$$+8.896311709880829$$

$$F(\text{Agustus2024}) = 10.036578825519$$

Tabel 3. 12 Prediksi Data Latih

Periode	Penjualan Aktual	Prediksi Latih (Train)	Error Latih (Train)
Jan-23	6	8.34	2.34
Feb-23	5	8.44	3.44
Mar-23	7	8.55	1.55
Apr-23	5	8.66	3.66
May-23	13	8.78	-4.22
Jun-23	6	8.89	2.89
Jul-23	9	9.01	0.01
Aug-23	14	9.13	-4.87
Sep-23	10	9.24	-0.76
Oct-23	11	9.35	-1.65
Nov-23	12	9.45	-2.55
Dec-23	6	9.55	3.55
Jan-24	14	9.64	-4.36
Feb-24	11	9.73	-1.27
Mar-24	10	9.8	-0.2
Apr-24	10	9.87	-0.13
May-24	7	9.93	2.93
Jun-24	4	9.97	5.97

Tabel 3. 13 Prediksi Data Uji

Periode	Penjualan Aktual	Prediksi Uji (Test)	Error Uji (Test)
Jul-24	10	10.01	0.01
Aug-24	11	10.04	-0.96
Sep-24	9	10.05	1.05
Oct-24	10	10.06	0.06
Nov-24	6	10.06	4.06

6) Menghitung Matrik Evaluasi

Setelah mendapat nilai error dari prediksi data ujinya, maka dilakukan perhitungan metrik evaluasinya sebagai berikut :

a) Mean Absolute Error (MAE)

$$MAE = \frac{1}{5}(|-0,96| + |1,05| + |0,06| + |4,06| + |1,05|)$$

$$MAE = \frac{1}{5}(-0,96 + 1,05 + 0,06 + 4,06 + 1,05) = \frac{7,18}{5} = 1,44$$

MAE melakukan proses perhitungan kesalahan dari rata-rata absolut antar nilai asli dengan nilai prediksi. Ini menunjukkan seberapa jauh prediksi dari nilai sebenarnya tanpa mempertimbangkan arah kesalahan (positif atau negatif). Semakin kecil nilai MAE, semakin baik akurasi model. Hasil menunjukkan nilai MAE sebesar 1,44 yang artinya rata-rata prediksi meleset sebesar 1,44 unit dari nilai aktual.

b) Mean Squared Error (MSE)

$$MSE = \frac{1}{5}(0,96^2 + 1,05^2 + 0,06^2 + 4,06^2 + 1,05^2)$$

$$MSE = \frac{1}{5}(0,9216 + 1,1025 + 0,0036 + 16,4836 + 1,1025)$$

$$= \frac{19,6138}{5} = 3,92$$

MSE menghitung melakukan proses perhitungan kuadrat selisih

rata-rata antara nilai asli dengan nilai prediksi. Dengan menguadratkan selisih, *MSE* memberikan bobot lebih besar pada kesalahan yang lebih besar. Semakin kecil nilai *MSE*, semakin baik kualitas model. Hasil menunjukkan nilai *MSE* sebesar 3,92 yang artinya rata-rata kuadrat kesalahan sebesar 3,92.

c) Root Mean Squared Error (RMSE)

$$RMSE = \sqrt{3,92} = 1,98$$

RMSE adalah akar kuadrat dari *MSE*. Ini memberikan ukuran dalam satuan yang sama dengan variabel target sehingga lebih mudah diinterpretasikan. dengan nilai *RMSE* yang lebih rendah. Hasil menunjukkan bahwa nilai *RMSE* adalah 1,98, yang berarti kesalahan prediksi rata-rata adalah 1,98 unit.

d) Mean Absolute Percentage Error (MAPE)

$$MAPE = \frac{1}{5} \left(\frac{|-0,96|}{11} + \frac{|1,05|}{9} + \frac{|0,06|}{10} + \frac{|4,06|}{6} + \frac{|1,05|}{9} \right) \times 100\%$$

$$MAPE = \frac{1}{5} (8,73 + 11,67 + 0,6 + 67,67 + 11,67) = 20,07\%$$

$$\text{Akurasi} = 100\% - MAPE$$

$$\text{Akurasi} = 100\% - 20,07 = 79,93\%$$

Nilai *MAPE* yang lebih rendah menunjukkan bahwa akurasi model lebih tinggi. Hasil menunjukkan nilai *MAPE* sebesar 20,07% yang artinya rata-rata kesalahan prediksi adalah 20,07% dari nilai asli. Dan jika dijadikan akurasi, model memiliki akurasi sebesar 79,93%

7) Menghitung Prediksi Periode Bulan Berikutnya

a) Normalisasi data sebelumnya Desember 2024 (X) = 1000 X (H-24) = 1000

$$X_{scaled}(\text{January 2025}) = \frac{24 - 0}{23 - 0} = \frac{24}{23} = 1.043$$

b) Menghitung kernel *RBF*

Untuk X (Jan-25) = 1,043 dan untuk X (Des-24) = 1000

$$K(1,043, 1000) = \exp(-0.1 \times (1,043 - 1000)^2)$$

$$= \exp(-0.1 \times 0.0018) = \exp(-0.00018) = 0.9998$$

c) Setelah memasukkan kernel ini ke dalam model *SVR* yang telah dilatih, maka mendapatkan hasil prediksi:

$$F(\text{January}2025) = (-1*0.9998) + (-1*0.9998) + (-1*0.9998) + (-1*0.9998) + (1*0.9998) + (-0.9827004*0.9998) + (1*0.9998) + (1*0.9998) + (1*0.9998) + (1*0.9998) + (-1*0.9998) + (1*0.9998) + (1*0.9998) + (1*0.9998) + (1*0.9998) + (-0.0172996*0.9998) + 8.896311709880829$$

$$F(\text{January}2025) = (-0.9998 \times 6) + (0.9998 \times 10) + (0.9998 \times -0.9827004) + (0.9998 \times -0.0172996)$$

$$F(\text{January}2025) = (-5.9988) + (9.988) + (-0.98250286) + (-0.01729692) + 8.896311709880829$$

$$F(\text{January}2025) = 10.036578825519$$

$$F(\text{January}2025) = 10.03$$

Jadi dengan menggunakan metode *Support Vector Regression (SVR)* pada kode barang 10K0124 (SC BRITENING 50) didapatkan hasil evaluasi matrik *MAE* sebesar 1,44, *MSE* sebesar 3,92, *RMSE* sebesar 1,98, dan *MAPE* sebesar 20,07%, Akurasi yang didapat sebesar 79,93% yang menunjukkan kemampuan model peramalan baik. Lalu untuk perhitungan prediksi periode bulan berikutnya yaitu Januari 2025 adalah 10.03 unit terjual.