

BAB IV

HASIL DAN PEMBAHASAN

4.1 Statistika Deskriptif

Berdasarkan hasil pengolahan data Produk Domestik Regional Bruto (PDRB) Provinsi Kepulauan Bangka Belitung diperoleh nilai maksimum, nilai minimum, rata-rata (*Mean*) dan simpangan baku. Sebagaimana ditunjukkan pada Tabel 4.1.

Tabel 4.1 Nilai maksimum, minimum, rata-rata dan simpangan baku

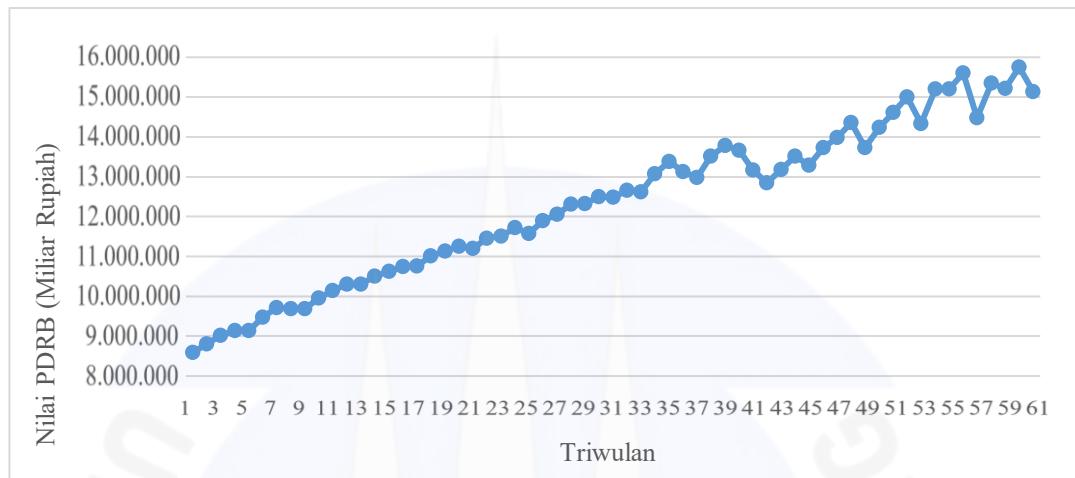
Peubah	N	Maksimum	Minimum	Rata-rata	Simpangan baku
PDRB	61	15.751,49	8.592,66	1.232.549,7	196.962,9
ADHK					

Sumber: Diolah Peneliti 2025

Berdasarkan Tabel 4.1, data yang digunakan sebanyak 61 data diperoleh dari website resmi Badan Pusat Statistik (BPS) Bangka Belitung. Nilai maksimum yaitu 15.751,49 dan nilai minimum sebesar 8.592,66. Dari data tersebut diperoleh nilai rata-rata sebesar 1.232.549,7, sedangkan nilai simpangan bakuinya adalah 196.962,9. Nilai maksimum yang cukup tinggi menunjukkan adanya periode dengan peningkatan PDRB yang signifikan, disebabkan oleh pertumbuhan ekonomi pada sektor-sektor unggulan, peningkatan investasi, atau faktor eksternal yang mendorong produksi. Sementara itu, nilai minimum yang relatif rendah merepresentasikan periode awal atau masa perlambatan ekonomi, yang dapat dipengaruhi oleh kondisi pasar, penurunan permintaan, atau dampak kebijakan tertentu. Nilai simpangan baku sebesar 196.962,9 atau sekitar 15,98% dari nilai rata-rata menunjukkan bahwa data memiliki tingkat variasi yang sedang. Hal ini mengindikasikan bahwa fluktuasi nilai terhadap rata-rata cukup terlihat namun masih dalam batas wajar. Simpangan baku dihitung dari akar kuadrat rata-rata selisih kuadrat antara setiap nilai data dengan nilai rata-ratanya. Semakin besar nilai simpangan baku, semakin besar pula penyebaran data terhadap rata-rata, sedangkan semakin kecil nilai simpangan baku menunjukkan bahwa data lebih homogen atau terpusat di sekitar rata-rata.

4.2 Visualisasi Data

Tahapan visualisasi data digunakan untuk mengetahui apakah data PDRB di Provinsi Kepulauan Bangka Belitung apakah mengandung pola musiman atau tidak. Hasil visualisasi data PDRB di Provinsi Kepulauan Bangka Belitung pada triwulan 1 tahun 2010 sampai dengan triwulan 1 tahun 2025 dapat dilihat pada Gambar 4.1



Sumber : Diolah Peneliti 2025

Gambar 4.1. Visualisasi nilai PDRB Provinsi Kepulauan Bangka Belitung

Pada Gambar 4.1 terlihat bahwa nilai Produk Domestik Regional Bruto (PDRB) Provinsi Kepulauan Bangka Belitung menunjukkan tren peningkatan pada setiap triwulan, yang mencerminkan adanya pertumbuhan ekonomi secara umum. Namun, mulai pada triwulan ke-33, pola pergerakan PDRB mengalami fluktuasi, yang dapat disebabkan oleh dinamika ekonomi seperti perubahan harga komoditas utama, variasi produksi sektor unggulan, serta faktor musiman. Hal ini mengindikasikan bahwa data *time series* PDRB Provinsi Kepulauan Bangka Belitung mengandung unsur tren naik. Nilai PDRB tertinggi tercatat pada triwulan ke-60 sebesar 15.751,49, sedangkan nilai PDRB terendah terjadi pada triwulan 1 sebesar 8.592,66, yang kemungkinan mencerminkan kondisi ekonomi awal periode pengamatan sebelum mengalami pertumbuhan signifikan.

Berdasarkan Gambar 4.1, terlihat adanya pola musiman pada nilai PDRB setiap triwulan dari tahun ke tahun. Pada tahun 2010, nilai PDRB berada pada tingkat yang rendah, mencerminkan kondisi awal perekonomian yang belum mengalami peningkatan signifikan. Memasuki tahun-tahun berikutnya, nilai PDRB triwulanan menunjukkan tren kenaikan yang konsisten, mencerminkan

pertumbuhan ekonomi Provinsi Kepulauan Bangka Belitung yang didorong oleh peningkatan aktivitas produksi dan kontribusi sektor-sektor unggulan. Pada tahun 2020, nilai PDRB mengalami penurunan sebagai dampak dari pandemi Covid-19 yang menyebabkan perlambatan kegiatan ekonomi di berbagai sektor. Selanjutnya, pada tahun 2024 kembali terjadi penurunan yang disebabkan oleh permasalahan tata kelola timah, yang memengaruhi kinerja sektor pertambangan sebagai salah satu kontributor utama PDRB daerah Kepulauan Bangka Belitung.

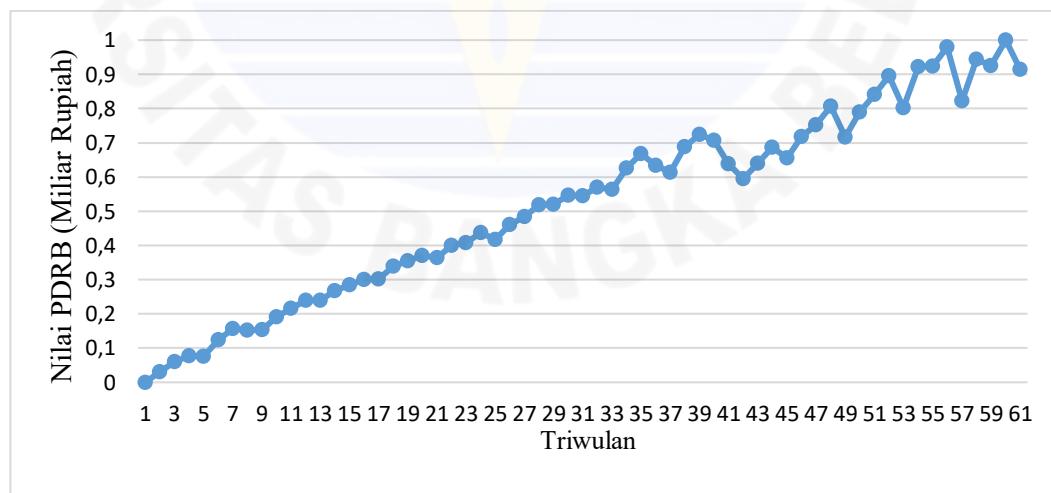
4.3 Penerapan Metode SVR

Pada penerapan metode SVR terdapat beberapa tahap yang harus dilakukan yaitu sebagai berikut:

4.3.1. Normalisasi Data

Proses normalisasi data dilakukan untuk penggunaan fungsi aktivasi pada kernel *sigmoid*, dimana kernel *sigmoid* bekerja pada rentang nilai 0 sampai dengan 1.

Kernel *sigmoid* cenderung sensitif terhadap skala data sehingga penerapan normalisasi membantu dalam mengoptimalkan performa model. Kernel *sigmoid* berbeda dengan ketiga kernel lainnya yaitu kernel *linear*, *polynomial*, dan RBF dimana ketiga kernel ini tidak diperlukan normalisasi data. Ketiga kernel tersebut dapat bekerja menggunakan data asli atau data yang tidak perlu dinormalisasi. Untuk mengubah data nilai PDRB Provinsi Kepulauan Bangka Belitung kedalam rentang nilai 0 sampai dengan 1 maka digunakan Persamaan 2.6.



Sumber : Diolah Peneliti 2025

Gambar 4.2. Nilai PDRB Yang Telah Dilakukan Proses Normalisasi Data

Gambar 4.2 menunjukkan data PDRB Provinsi Kepulauan Bangka Belitung yang telah dinormalisasi. Normalisasi data yang diterapkan dalam penelitian ini tidak mengubah bentuk data asli, melainkan hanya menyesuaikan skala nilai data agar berada dalam rentang tertentu. Proses ini dilakukan untuk meningkatkan efisiensi dan akurasi *machine learning* tanpa mempengaruhi karakteristik data asli dari data tersebut.

4.3.2 Pembagian Data

Pada tahap pembagian data ini, data dibagi menjadi dua kelompok data utama, yaitu data latih dan data uji dengan proporsi 70:30%. Pembagian ini dilakukan untuk memastikan bahwa model *Support Vector Regression* (SVR) dapat dibangun dan dievaluasi secara efektif. Data latih yang digunakan sebanyak 70% dari total data (43 data). Data latih digunakan untuk proses pembelajaran model. Sedangkan data uji yang digunakan sebanyak 30% (18 data) untuk mengukur kinerja model. Pembagian data ini dilakukan untuk menjaga keseimbangan antara ukuran data latih untuk membangun model yang kuat dan data uji yang memadai untuk validasi model, sehingga dapat diperoleh estimasi akurasi yang lebih realistik dan dapat digunakan.

4.3.3 Pengujian Fungsi Kernel dan Parameter

Pengujian fungsi kernel dan parameter dilakukan untuk memperoleh fungsi kernel terbaik yang akan digunakan dalam model SVR. Pada pengujian fungsi kernel dan parameter ini menggunakan 4 kernel yaitu *Linear*, *Radial Basic Function* (RBF), *Polynomial*, dan *Sigmoid*. Penentuan kernel dan parameter dilakukan melalui pengujian satu persatu kernel hingga diperoleh parameter untuk model SVR terbaik dari masing-masing kernel. Pada masing-masing kernel terdapat nilai parameter diantaranya *epsilon* (ϵ), *cost* (C), *gamma* (γ). Pemilihan kernel terbaik dapat dilihat berdasarkan nilai keakurasi *error* terkecil dari rata-rata nilai *mean absolute percentage error* (MAPE). Semakin kecil nilai MAPE yang dihasilkan, maka semakin baik pula tingkat akurasi model SVR dalam melakukan peramalan. Dengan demikian, kernel dengan nilai MAPE paling rendah dianggap sebagai kernel yang paling optimal untuk digunakan dalam model SVR pada penelitian ini. Adapun hasil pengujian dari masing-masing fungsi kernel dalam penelitian ini dapat dilihat pada Tabel 4.2

Tabel 4.2 Fungsi Kernel Linear *Support Vector Regression* (SVR).

Kernel Linear		MAPE	
Parameter	Nilai Parameter Terbaik	Data Latih	Data Uji
ϵ	0,001		
C	10	10,32 %	27,42 %

Sumber: Hasil Pengolahan *R studio*

Tabel 4.2 menyajikan hasil pemilihan fungsi kernel linear beserta nilai parameter terbaik untuk data PDRB Provinsi Kepulauan Bangka Belitung. Proses penentuan parameter dilakukan dengan menguji beberapa kombinasi nilai *Cost* (C) yaitu 1, 10, dan 100, serta nilai *epsilon* (ϵ) yaitu 0,001, 0,01 dan 0,1. Penggunaan beberapa kombinasi pada nilai *Cost* (C) dan *epsilon* (ϵ) memudahkan dalam penentuan nilai parameter terbaik, dimana pemilihan ketiga kombinasi mewakili dari skala rendah, menengah, dan tinggi. Berdasarkan hasil pengujian awal, rentang parameter tersebut kemudian diperluas untuk menemukan titik optimal. Hasil akhirnya menunjukkan bahwa nilai parameter terbaik pada fungsi *kernel* linear adalah $C = 10$ dan $\epsilon = 0,001$. Perbedaan nilai optimal dengan rentang awal pengujian menunjukkan bahwa pencarian parameter yang lebih luas dapat memberikan hasil prediksi yang lebih akurat.

Perolehan nilai MAPE pada data latih sebesar 10,32%. Berdasarkan tingkat signifikansi keakuratan, hasil dari data latih dengan fungsi kernel linear berada pada rentang 10–20%, yang berarti memiliki tingkat akurasi baik untuk data latih. Sementara itu, pada data uji diperoleh nilai MAPE yang lebih besar, yaitu 27,42%. Berdasarkan tingkat signifikansi keakuratan, hasil dari data uji dengan fungsi kernel linear berada pada rentang 20–50%, yang menunjukkan tingkat akurasi cukup untuk data uji. Hal ini sesuai dengan kriteria MAPE yang ditunjukkan pada Tabel 2.1. Perbedaan nilai MAPE yang cukup besar antara data latih dan data uji ini mengindikasikan adanya kemungkinan *underfitting*.

Tabel 4.3 Fungsi Kernel *Polynomial Support Vector Regression* (SVR).

Kernel <i>Polynomial</i>		MAPE	
Parameter	Nilai Parameter Terbaik	Data Latih	Data Uji
γ	0,1		
C	100	37,3%	63,57%

Sumber: Hasil Pengolahan *R Studio*

Tabel 4.3 menyajikan hasil pemilihan fungsi kernel *Polynomial* beserta nilai parameter terbaik untuk data PDRB Provinsi Kepulauan Bangka Belitung. Proses penentuan parameter dilakukan dengan menguji beberapa kombinasi nilai *Cost* (C) yaitu 1, 10, dan 100, serta nilai *Gamma* (γ) yaitu 0,001, 0,01, dan 0,1. Berdasarkan hasil pengujian, nilai parameter terbaik pada fungsi kernel *Polynomial* adalah $C = 100$ dan $\gamma = 0,1$. Kombinasi ini memberikan keseimbangan antara kompleksitas model.

Hasil pemodelan pada data latih menghasilkan nilai MAPE sebesar 37,3%, sedangkan ketika diimplementasikan pada data latih, nilai MAPE meningkat menjadi 63,57%. Perbedaan nilai MAPE yang cukup besar antara data latih dan data uji ini mengindikasikan adanya kemungkinan *underfitting*, yaitu model mampu memberikan hasil yang relatif baik pada data latih, namun kemampuannya untuk melakukan generalisasi terhadap data yang belum pernah dilihat menjadi berkurang.

Tabel 4.4 Fungsi Kernel *Sigmoid Support Vector Regression* (SVR).

Kernel <i>Sigmoid</i>		MAPE	
Parameter	Nilai Parameter Terbaik	Data Latih	Data Uji
γ	0,1		
C	10	10.74%	44.59%

Sumber: Hasil Pengolahan *R Studio*

Tabel 4.4 merupakan hasil fungsi kernel *sigmoid* dan nilai parameter terbaik untuk data PDRB Provinsi Kepulauan Bangka Belitung. Proses penentuan parameter dilakukan dengan menguji beberapa kombinasi nilai *Cost* (C) 1, 10, 100, dan nilai *Gamma* (γ) 0,001, 0,01, 0,1 didapatkan nilai parameter terbaik. Nilai

parameter terbaik pada fungsi kernel sigmoid adalah $C = 10$ dan $\gamma = 0,1$. Hasil pemodelan pada data latih memperoleh nilai MAPE sebesar 10,74%, sedangkan jika diimplementasikan pada data uji memperoleh nilai MAPE yang lebih besar yaitu 44,59%. Perbedaan nilai MAPE yang cukup besar antara data latih dan data uji ini mengindikasikan adanya kemungkinan *underfitting*.

Tabel 4.5 Fungsi Kernel *Radial Basic Function* (RBF) Support Vector Regression (SVR).

Kernel RBF		MAPE	
Parameter	Nilai Parameter Terbaik	Data Latih	Data Uji
γ	0,25		
C	10	2,08%	3,55%

Sumber: Hasil Pengolahan *R Studio*.

Tabel 4.5 merupakan hasil fungsi kernel *Radial Basic Function* (RBF) dan nilai parameter terbaik untuk data PDRB Provinsi Kepulauan Bangka Belitung. Percobaan pemilihan nilai parameter yang dilakukan pada kernel RBF dilakukan dengan menguji beberapa nilai *Cost* (C) 1, 10, 100, dan beberapa nilai *Gamma* (γ) 0,001, 0,01, 0,1, 0,25 dengan Rstudio. Nilai parameter terbaik pada fungsi kernel RBF adalah $C = 10$ dan $\gamma = 0,25$.

Hasil pemodelan pada data latih menghasilkan nilai MAPE sebesar 2,61%, sedangkan pada data uji diperoleh nilai MAPE sebesar 3,55%. Nilai MAPE yang rendah pada kedua data tersebut menunjukkan kemampuan model dalam mengenali pola data secara akurat dan mempertahankan kinerjanya pada data baru. Model dengan kernel RBF ini memberikan prediksi yang akurat dan stabil, bahkan menunjukkan nilai MAPE paling kecil dibandingkan dengan ketiga kernel lainnya yang diuji.

4.3.4 Model SVR Terbaik

Berdasarkan hasil dari pengujian fungsi kernel dan parameternya maka dapat dipilih model SVR terbaik berdasarkan nilai rata-rata Mean *Absolute Percentage Error* (MAPE) terendah dari data latih dan data uji. Berikut model SVR terbaik pada data PDRB Provinsi Kepulauan Bangka Belitung.

Tabel 4.6 Kriteria Nilai *Mean Absolute Percentage Error* (MAPE) Pada *Support Vector Regression* (SVR).

Kernel	MAPE			Kriteria nilai
	Data Latih	Data Uji	Rata-rata	
Linear	10,32%	27,42%	24,03%	Cukup
Polynimial	37,3%	63,57%	69,085%	Buruk
<i>Sigmoid</i>	10,74%	44,59%	33,035%	Cukup
RBF	2,08%	3,55%	3,08%	Sangat Baik

Sumber: Diolah Peneliti 2025

Tabel 4.6 menunjukkan bahwa kernel linear dengan nilai MAPE rata-rata sebesar 24,03%. Perbedaan antara nilai MAPE pada data latih dan data uji tidak terlalu signifikan, meskipun nilai MAPE pada data latih sedikit lebih besar. Kenaikan nilai MAPE dari data latih ke data uji mengindikasikan bahwa ada sedikit *underfitting*.

Kernel *polynomial* memiliki nilai MAPE rata-rata sebesar 69,085%. Kenaikan nilai MAPE pada data uji yang cukup tinggi menunjukkan kernel *polynomial* mengalami *underfitting*. Model dengan kernel *polynomial* mampu mempelajari pola pada data latih, namun kesulitan dalam generalisasi ketika diterapkan pada data uji.

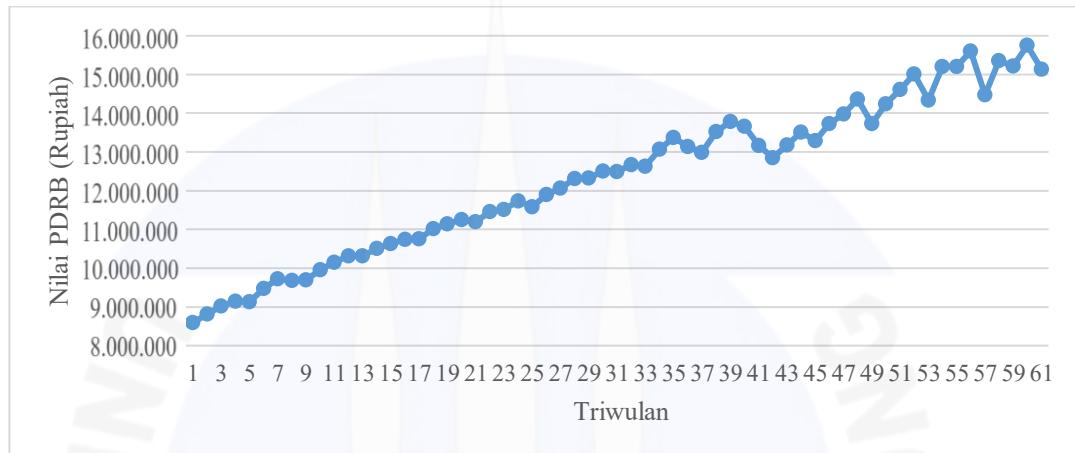
Kernel *Sigmoid* menghasilkan nilai MAPE pada data latih yang relatif tinggi, sehingga mengindikasikan bahwa model dengan kernel ini kurang mampu mempelajari pola data secara optimal pada tahap pelatihan. Nilai MAPE pada data uji terlihat lebih tinggi dibandingkan dengan data latih, kondisi tersebut menunjukkan bahwa kinerja model semakin menurun ketika diterapkan pada data yang belum pernah dilatihkan. Hal ini menandakan kernel sigmoid tidak dapat diandalkan untuk menghasilkan prediksi yang akurat dan konsisten.

Kernel RBF dengan nilai MAPE rata-rata sebesar 3,08% mengindikasikan bahwa model dengan kernel RBF adalah kernel yang paling akurat di antara semua kernel yang diuji, dengan kesalahan prediksi yang sangat kecil. Nilai MAPE yang rendah pada kedua dataset menunjukkan bahwa model mampu menangkap pola non-linear secara efektif melalui fungsi basis radial yang memproyeksikan data ke ruang berdimensi lebih tinggi. Kemampuan ini memungkinkan model untuk

merepresentasikan tren dan fluktuasi PDRB secara konsisten, sekaligus meminimalkan error pada data uji, sehingga menghasilkan prediksi yang stabil dan memiliki tingkat generalisasi yang tinggi terhadap data baru.

4.3.5 Denormalisasi Data

Denormalisasi data dilakukan setelah proses pengujian selesai dan model terbaik telah diperoleh. Proses ini bertujuan untuk mengembalikan data yang sebelumnya telah melalui tahap normalisasi ke dalam bentuk aslinya, sehingga nilainya kembali sama seperti sebelum dilakukan normalisasi.



Sumber: Diolah Peneliti 2025

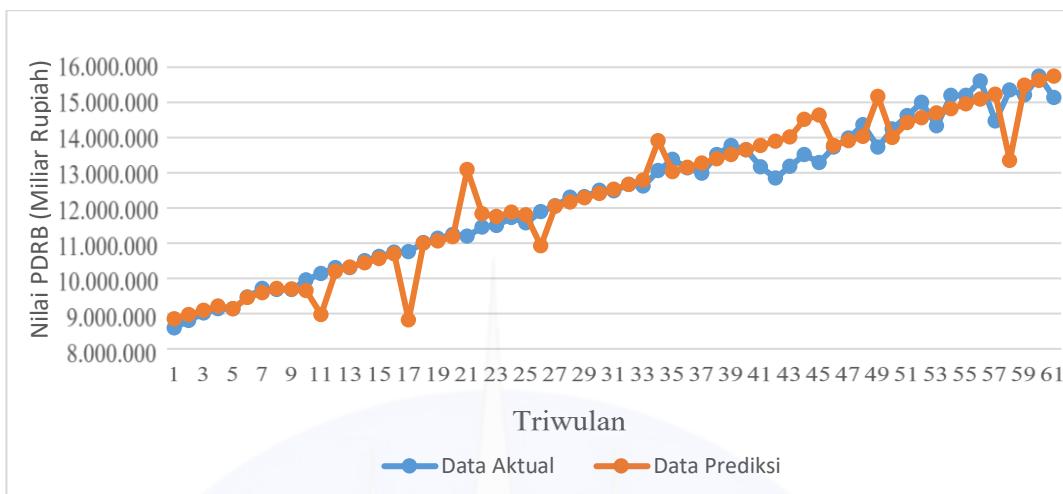
Gambar 4.3. Nilai PDRB Yang Telah Dilakukan Denormalisasi Data

Gambar 4.3 menyajikan data PDRB Provinsi Kepulauan Bangka Belitung yang telah dikembalikan ke skala aslinya melalui proses denormalisasi. Proses ini bertujuan untuk mengonversi kembali nilai hasil prediksi yang sebelumnya telah diubah skalanya pada tahap praproses menjadi nilai dengan satuan dan rentang yang sama seperti data asli. Dengan demikian, hasil prediksi dapat dibandingkan secara langsung dengan data aktual yang ada. Denormalisasi tidak memengaruhi pola, tren, maupun bentuk data, karena yang diubah hanya skala nilainya. Proses denormalisasi data menggunakan Persamaan 2.7.

4.4. Hasil Prediksi

Pada tahap terakhir yaitu hasil prediksi, setelah dilakukan penentuan kernel dan parameter terbaik pada data PDRB Provinsi Kepulauan Bangka Belitung diperoleh bahan kernel RBF dengan nilai MAPE paling kecil adalah kernel terbaik. Oleh karena itu data PDRB akan diprediksi menggunakan kernel RBF. Berikut hasil

prediksi data PDRB Provinsi Kepulauan Bangka Belitung menggunakan kernel RBF terlihat pada Gambar 4.4.

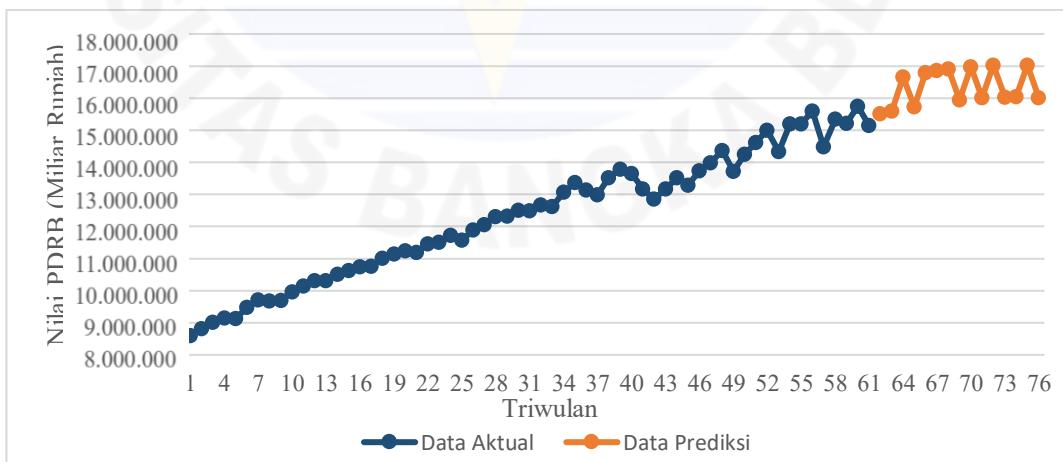


Sumber: Diolah Peneliti 2025

Gambar 4.4. Grafik Data Aktual dan Data Prediksi Kernel RBF Dengan Metode SVR

Gambar 4.4 menampilkan perbandingan antara data aktual dan data hasil prediksi menggunakan kernel *Radial Basis Function* (RBF). Secara keseluruhan, model prediksi mampu mengikuti tren kenaikan PDRB dari periode awal hingga akhir pengamatan.

Namun, pada beberapa titik seperti triwulan ke-17, triwulan ke-21, dan triwulan ke-58, terlihat adanya deviasi antara data aktual dan prediksi. Perbedaan ini menunjukkan adanya fluktuasi yang tidak sepenuhnya terakomodasi oleh model.



Sumber: Hasil Pengolahan R Studio

Gambar 4.5. Grafik Data Aktual dan Data Hasil Peramalan Metode SVR.

Terlihat bahwa model prediksi yang digunakan mampu mengikuti pola tren data aktual dengan cukup baik. Data aktual ditampilkan hingga periode ke-61, sedangkan data prediksi dimulai dari periode ke-62 sampai dengan periode ke-76 atau sebanyak 3 periode (jangka menengah). Secara umum, hasil prediksi menunjukkan kecenderungan yang serupa dengan data aktual. Hal ini mengindikasikan bahwa model yang dibangun memiliki kemampuan dalam menangkap pola historis data. Meskipun terdapat sedikit deviasi antara nilai aktual dan nilai prediksi, namun fluktuasi tersebut masih berada dalam rentang dan tidak menyimpang secara signifikan dari pola data sebelumnya.

4.5. Penerapan Metode SARIMA

Pada penerapan metode SARIMA terdapat beberapa tahap yang harus dilakukan yaitu:

4.5.1 Identifikasi Pola Data

Langkah awal dalam analisis deret waktu melakukan identifikasi pola yang terdapat pada data. Identifikasi ini bertujuan untuk mengetahui karakteristik data yang dapat memengaruhi pemilihan dan pembentukan model peramalan yang sesuai. Plot deret waktu triwulanan Produk Domestik Regional Bruto (PDRB) dapat dilihat pada Gambar 4.1.

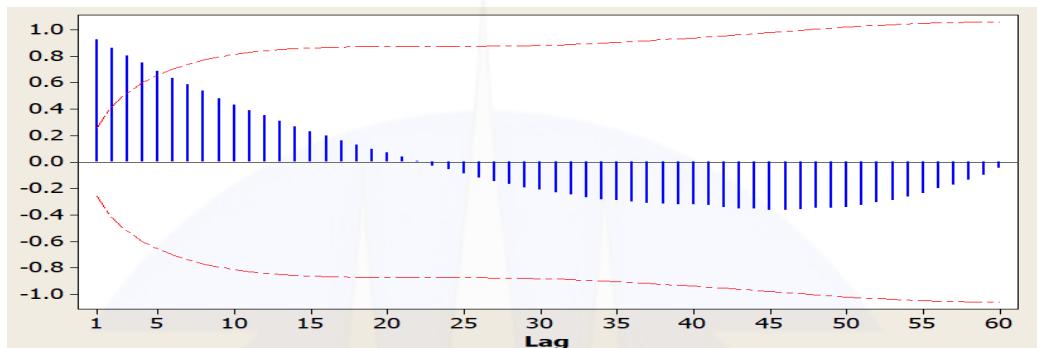
Terlihat bahwa nilai PDRB mengalami tren peningkatan dari waktu ke waktu, yang menunjukkan adanya kecenderungan pertumbuhan ekonomi secara umum. Selain tren yang meningkat, terdapat pula fluktuasi musiman yang berulang setiap tahunnya, ditunjukkan oleh pola naik-turun yang konsisten di setiap triwulan. Pola ini mengindikasikan bahwa data PDRB mengandung unsur tren dan musiman, pendekatan model deret waktu mempertimbangkan kedua komponen ini, sehingga metode SARIMA menjadi relevan untuk digunakan.

4.5.2 Identifikasi Kestasioneran Data

Identifikasi kestasioneran merupakan tahap penting dalam analisis deret waktu, karena kestasioneran merupakan syarat utama agar model peramalan dapat dibangun secara tepat dan menghasilkan estimasi parameter yang konsisten. Suatu deret waktu dikatakan stasioner apabila rata-rata, varians, serta kovariansnya bersifat konstan.

4.5.2.1 Uji Augmented Dickey-Fuller (ADF)

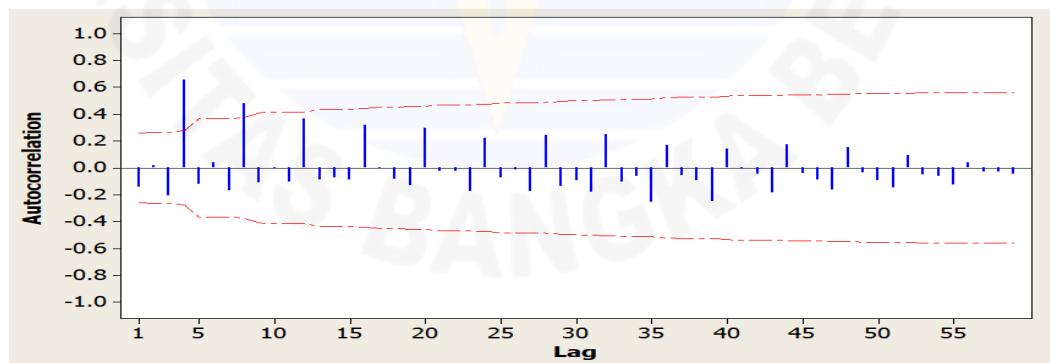
Uji *Augmented Dickey-Fuller* (ADF) digunakan untuk mengecek stasioneritas rata-rata pada data deret waktu. Stasioneritas diperlukan agar model peramalan, seperti SARIMA, dapat memberikan prediksi yang akurat. Jika data belum stasioner dalam rata-rata, diperlukan diferensiasi (*differencing*) untuk mencapai kestasioneran data agar pemodelan dapat dilakukan dengan akurat. Berikut merupakan plot data stasioner dalam rata-rata.



Sumber: Hasil Pengolahan *Software*

Gambar 4.6 Plot Data Produk Domestik Regional Bruto (PDRB) Tidak Stasioner Dalam Rata-rata

Gambar 4.6 merupakan grafik data PDRB di Provinsi Kepulauan Bangka Belitung tidak stasioner dalam rata-rata. Terlihat pola penurunan autokorelasi yang terjadi secara perlahan merupakan karakteristik utama deret waktu yang mengandung unit *root*. Kondisi ini sejalan dengan hipotesis $H_0 : \gamma = 0$.



Sumber: Hasil Pengolahan *Software*

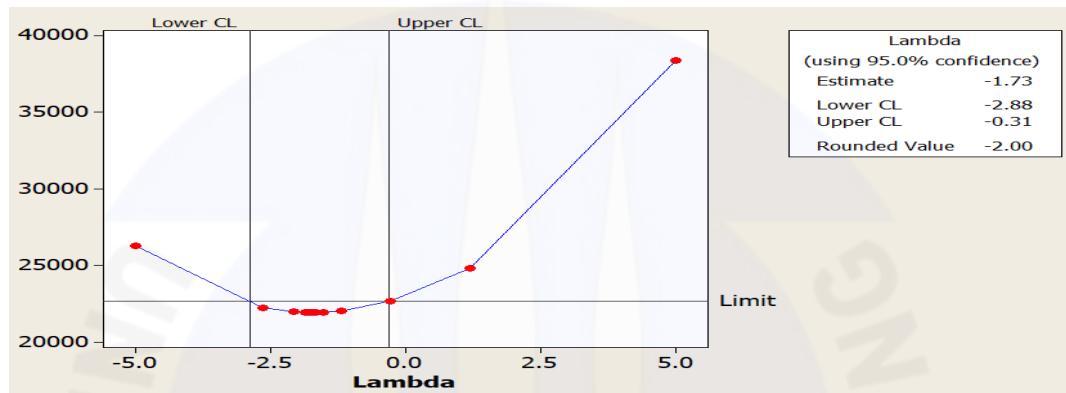
Gambar 4.7 Plot Data Produk Domestik Regional Bruto (PDRB) Stasioner Dalam Rata-rata

Setelah dilakukan proses diferensiasi (*differencing*) satu kali, grafik data PDRB menunjukkan pola yang berbeda dibandingkan dengan kondisi sebelumnya.

Hasil *plotting* memperlihatkan bahwa sebagian lag telah berada dalam batas signifikansi, sedangkan komponen musiman hanya tampak keluar pada lag ke-4. Kondisi ini menunjukkan bahwa data telah memenuhi asumsi kestasioneran dalam rata-rata. Setelah terpenuhinya asumsi tersebut, data dapat digunakan untuk tahap identifikasi model deret waktu.

4.5.2.2 Uji Box-Cox

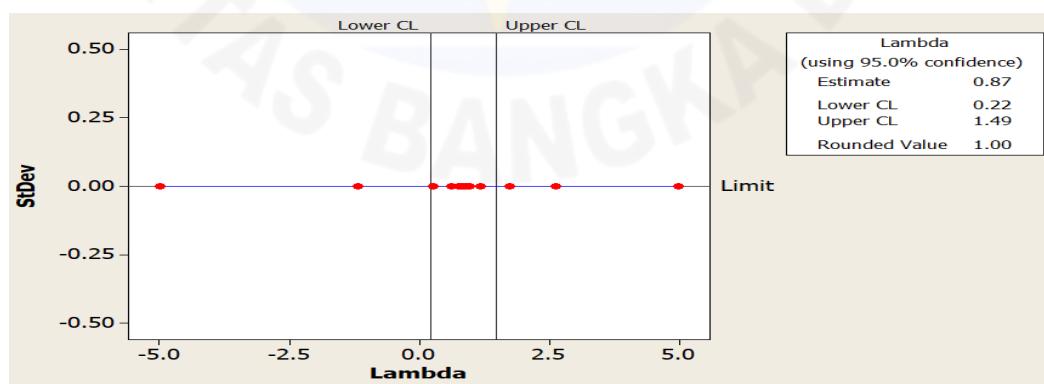
Uji *Box-Cox* digunakan untuk melihat data stasioner dalam varians pada data deret waktu. Data yang tidak stasioners dalam varians perlu dilakukan transformasi. Sebagaimana dijelaskan pada sub bab 2.1.13.2.



Sumber: Hasil Pengolahan *Software*

Gambar 4.8 Plot Data Produk Domestik Regional Bruto (PDRB) Tidak Stasioner Dalam Varians

Gambar 4.8 menunjukkan data deret waktu yang masih memiliki varians tidak konstan (belum stasioner dalam varians). Hal ini ditunjukkan oleh nilai $\gamma \neq 1$, oleh karena ini perlu dilakukan transformasi.



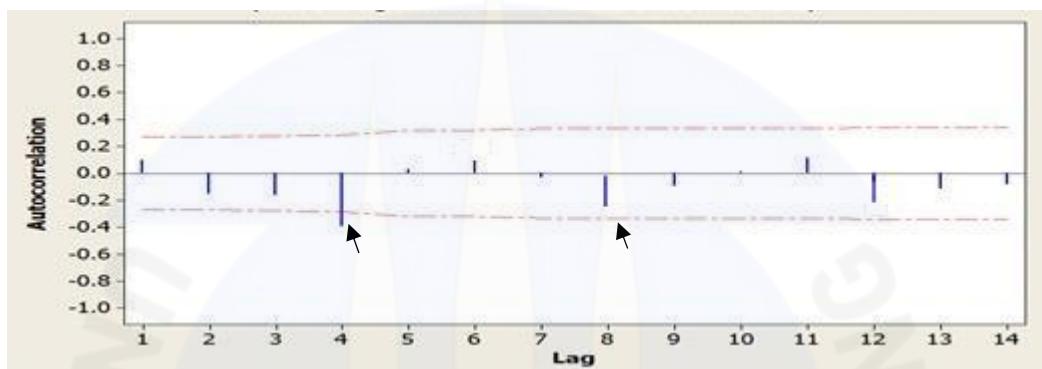
Sumber: Hasil Pengolahan *Software*

Gambar 4.9. Transformasi Data Produk Domestik Regional Bruto (PDRB) Stasioner Dalam Varians

Gambar 4.10 ditampilkan grafik data yang telah distasionerkan terhadap varians, yang ditunjukkan dengan nilai *rounded value* bernilai 1.00. Hal ini menunjukkan bahwa fluktuasi varians data telah berhasil distabilkan melalui proses transformasi yang dilakukan. Data sudah memenuhi salah satu syarat utama dalam analisis deret waktu, yaitu kestasioneran dalam varians.

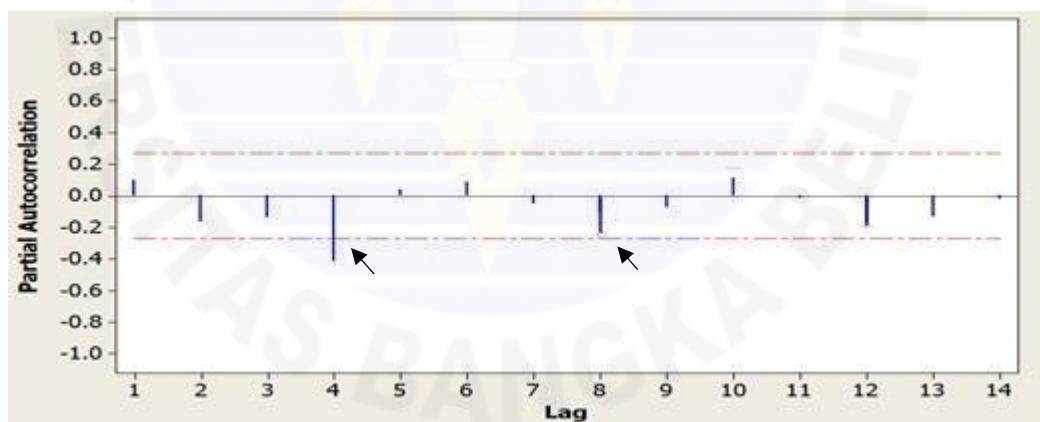
4.5.3 Identifikasi ACF dan PACF

Identifikasi plot data ACF dan PACF. Kedua plot ini menjadi dasar dalam menentukan ordo dari komponen *autoregressive* (AR) dan *moving average* (MA), baik pada pola non-musiman maupun musiman.



Sumber: Hasil Pengolahan Software

Gambar 4.10. Diagram *autocorellation function* (ACF) non musiman

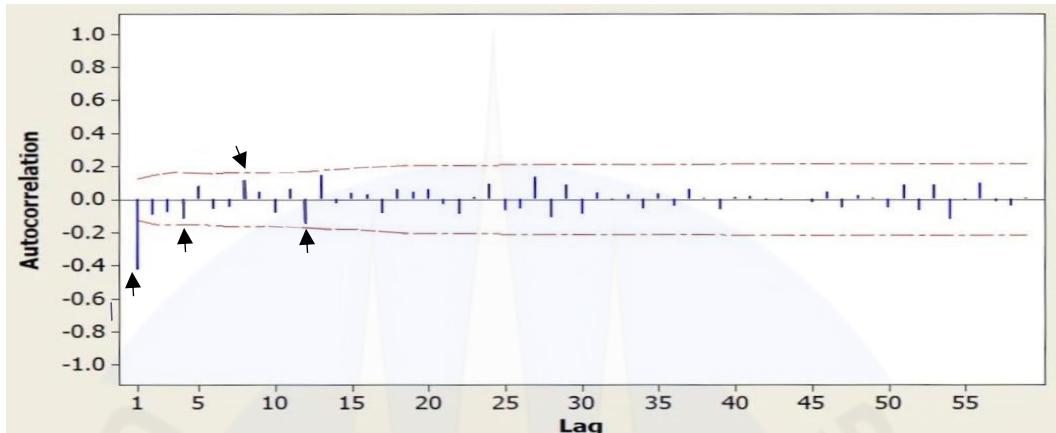


Sumber: Hasil Pengolahan Software

Gambar 4.11. Diagram *partial autocorellation function* (PACF) non musiman

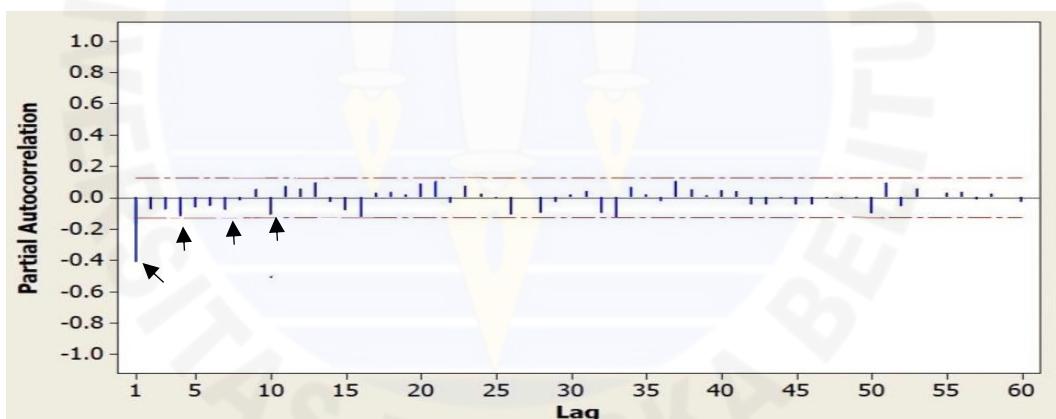
Berdasarkan Gambar 4.10 dapat dikatakan ACF (*Autocorrelation Function*) signifikan pada lag 4 dan lag 8, sementara pada lag-lag lainnya mendekati nol dan berada dalam batas signifikan. Hal ini menunjukkan adanya pola berulang yang searah pada lag-lag tersebut, yang mengindikasikan bahwa adanya pola musiman pada data dengan periode musiman ($S = 4$).

PACF (*Partial Autocorrelation Function*) juga menunjukkan signifikan pada lag 4 dan lag 8, sedangkan lag-lag lainnya mendekati nol dan berada di dalam batas signifikan. Signifikan pada lag 4 dan lag 8 memperkuat dugaan adanya komponen musiman. Terlihat plot *autocorrelation* dan *partial autocorrelation* menunjukkan bahwa dominan korelasi berada dalam interval kepercayaan, yang menunjukkan stasioneritas.



Sumber: Hasil Pengolahan Software

Gambar 4.12. Diagram *autocorellation function* (ACF) musiman



Sumber: Hasil Pengolahan Software

Gambar 4.13. Diagram *partial autocorellation function* (PACF) musiman

Berdasarkan Gambar 4.13, pada plot ACF musiman terlihat adanya pola *cut-off* pada lag ke-1, hal yang sama juga tampak pada plot PACF. Selain itu, pada grafik ACF terlihat adanya peningkatan nilai autokorelasi pada lag ke-4, lag ke-8, dan lag ke-12. Pola tersebut mencerminkan adanya kecenderungan musiman yang berulang secara konsisten pada periode-periode selanjutnya, yang menunjukkan bahwa data masih mengandung pengaruh musiman yang signifikan.

4.5.4 Penentuan Parameter Model ARIMA

Pada penentuan parameter model karena proses diferensiasi (*differencing*) dilakukan terhadap data pertama, maka orde diferensiasi $d = 1$. Identifikasi model sementara ini digunakan untuk model yang optimal dengan melihat pada plot ACF dan plot PACF yang digunakan sebagai petunjuk awal untuk orde p, d, q awal model. Parameter model ARIMA dan pada Tabel 4.7.

Tabel 4.7 Parameter model ARIMA

Model ARIMA	Model (p, d, q)
Model 1	(4, 1, 4)
Model 2	(4, 1, 0)
Model 3	(0, 1, 4)

Sumber: Diolah Peneliti, 2025

Berdasarkan Tabel 4.7 parameter (p, d, q) mempresentasikan urutan model *autoregressive* (AR), *differencing*, dan *moving average* (MA) pada komponen non musiman (p, d, q). Namun, karena data yang digunakan menunjukkan pola musiman triwulanan, maka pemodelan ARIMA perlu dikembangkan menjadi *Seasonal Autoregressive Integrated Moving Average* (SARIMA) dengan menambahkan komponen musiman (P, D, Q) dan periode musiman $s = 4$.

4.5.5 Penentuan Parameter Model SARIMA

Dalam penentuan parameter model, dilakukan proses diferensiasi satu kali terhadap data sehingga orde diferensiasi ditetapkan sebesar $d = 1$. Tahap identifikasi model ini bertujuan untuk menentukan model sementara yang selanjutnya digunakan dalam pemilihan model yang optimal, dengan mengacu pada pola yang ditunjukkan oleh plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) sebagai pedoman awal dalam menentukan nilai orde p, d, q serta P, D, Q pada model. Untuk mendapatkan model terbaik dipilih model dengan nilai MAPE terkecil. Parameter model SARIMA dan nilai MAPE pada Tabel 4.8.

Tabel 4.8 Perbandingan Model SARIMA Berdasarkan Nilai MAPE

Model SARIMA	Model	MAPE
	$(p, d, q)(P, D, Q)^s$	
Model 1	$(4,1,4)(1,1,1)^4$	8,47%
Model 2	$(4,1,0)(1,1,0)^4$	6%
Model 3	$(0,1,4)(0,1,1)^4$	2%

Sumber: Diolah Peneliti, 2025

Berdasarkan Tabel 4.8 parameter (p, d, q) mempresentasikan urutan model *autoregressive* (AR), *differencing*, dan *moving average* (MA) pada komponen non musiman (p, d, q) , sedangkan (P, D, Q) menggambarkan urutan AR, *differencing* musiman dan MA pada komponen musiman. Nilai MAPE yang paling kecil terdapat pada model-3 yaitu model SARIMA $(0,1,4)(0,1,1)^4$ dengan nilai MAPE terkecil yaitu sebesar 2% lebih kecil dari nilai MAPE model 1 dan model 2. Nilai MAPE yang sangat kecil ini menunjukkan bahwa Model 3 memiliki tingkat kesalahan peramalan yang sangat rendah serta tingkat akurasi yang sangat tinggi dibandingkan kandidat model lainnya. Model 3 dapat dikatakan sebagai model terbaik yang mampu merepresentasikan pola data PDRB di Provinsi Kepulauan Bangka Belitung. Model ini kemudian dipilih untuk digunakan pada tahap peramalan periode berikutnya. Adapun persamaan SARIMA $(0,1,4)(0,1,1)^2$ sebagai berikut:

$$(1 - B)(1 - B^4) Y_t = (1 + \theta_1 B + \theta_2 B^2 + \theta_3 B^3 + \theta_4 B^4)(1 + \theta_1 B^4) \varepsilon_t \quad [4.1]$$

4.5.6 Uji White Noise

Uji *white noise* dilakukan untuk memastikan bahwa residual dari model SARIMA bersifat acak atau tidak menunjukkan adanya autokorelasi yang signifikan. Uji ini dilakukan dengan menggunakan uji *Ljung-Box* pada beberapa nilai lag.

Tabel 4.9 Hasil Pengujian *White Noise* Terhadap Residual

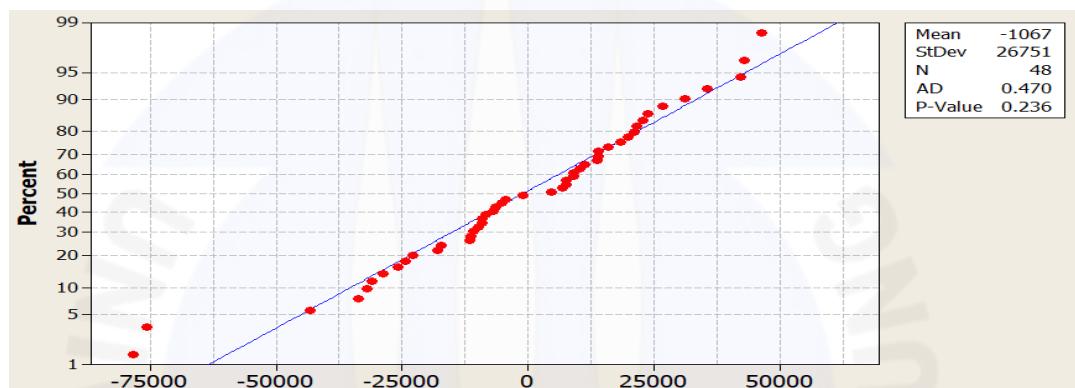
Lag	Nilai <i>p</i>-value
4	0,77
8	0,385
12	0,679

Sumber: Diolah Peneliti, 2025

Hasil uji menunjukkan Seluruh nilai *P-value* lebih besar dari tingkat sifnifikasi 0,05. Hasil ini menunjukkan bahwa residual model SARIMA tidak mengandung autokorelasi yang berarti, sehingga bersifat *white noise*. Berdasarkan hasil tersebut, model dinyatakan layak digunakan untuk proses peramalan.

4.5.7 Uji Normalitas

Setelah model SARIMA dibentuk, langkah selanjutnya adalah melakukan uji diagnostik terhadap residual model, salah satunya adalah uji normalitas. Uji normalitas bertujuan untuk mengetahui apakah residual yang dihasilkan oleh model terdistribusi normal atau tidak. Hasil uji normalitas dapat dilihat pada Gambar 4.13 dibawah ini.



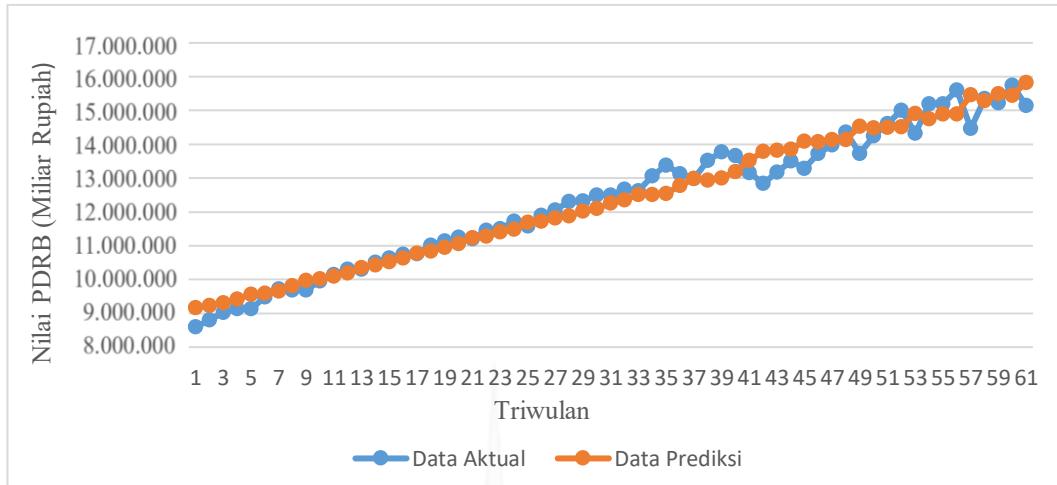
Sumber: Hasil Pengolahan *Software*

Gambar 4.14. Pengujian Normalitas Produk Domestik Regional Bruto (PDRB)

Hasil uji menunjukkan bahwa nilai *p-value* sebesar 0,236 (lebih besar dari nilai $\alpha = 0,05$), sehingga dapat disimpulkan bahwa residual terdistribusi normal. Hal ini menunjukkan bahwa model SARIMA yang dibangun telah memenuhi asumsi normalitas residual, yang merupakan salah satu syarat penting dalam analisis deret waktu. Selain itu, Gambar 4.15 yang menampilkan Q-Q plot residual menunjukkan bahwa sebagian besar titik berada di sekitar garis diagonal. Hal ini mengindikasikan bahwa distribusi residual mendekati distribusi normal, dan memperkuat hasil uji statistik.

4.5.8 Forecasting

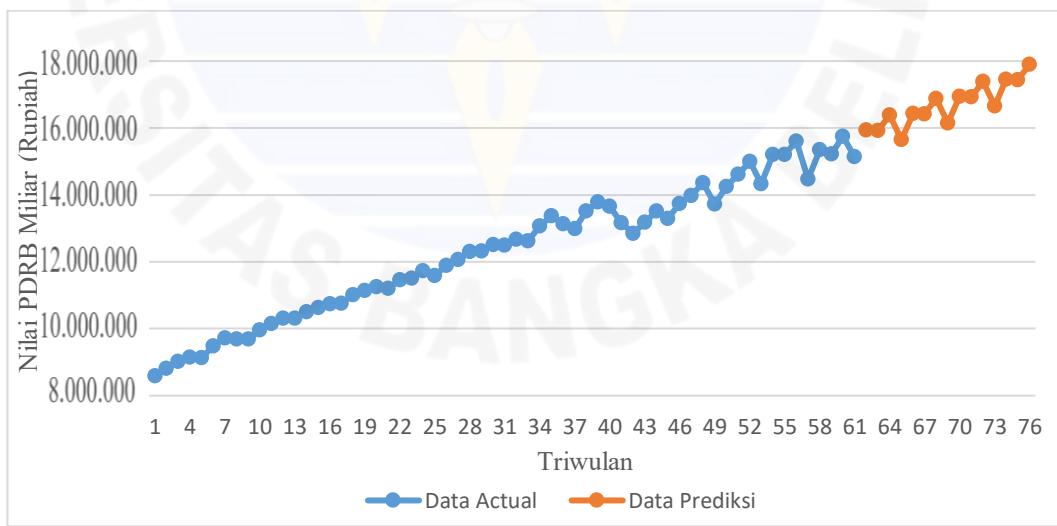
Setelah model SARIMA terbaik diperoleh, model tersebut yang akan digunakan untuk melakukan peramalan. Berikut hasil prediksi data PDRB periode triwulan II 2025 sampai dengan triwulan IV 2028 pada Gambar 4.14 sebagai berikut:



Sumber: Diolah Peneliti, 2025

Gambar 4.15. Grafik Data Aktual dan Data Prediksi Produk Domestik Regional Bruto (PDRB) dengan Metode SARIMA

Gambar 4.16 memperlihatkan perbandingan antara data aktual dan hasil prediksi PDRB Provinsi Kepulauan Bangka Belitung. Berdasarkan grafik, terlihat bahwa model peramalan yang digunakan mampu merepresentasikan pola pergerakan PDRB dengan baik, serta memiliki tingkat error yang rendah. Kesesuaian antara kedua garis ini mengindikasikan bahwa model memiliki performa yang baik dalam memprediksi nilai PDRB, yang dapat dilihat dari minimnya deviasi pada titik-titik data tertentu.



Sumber: Diolah Peneliti, 2025

Gambar 4.16. Grafik Data Aktual dan Hasil Prediksi Produk Domestik Regional Bruto (PDRB) Peramalan Metode SARIMA

Gambar 4.17 menyajikan grafik perbandingan antara data aktual dan data prediksi PDRB menggunakan metode SARIMA. Dalam grafik tersebut, data aktual diperlihatkan dari periode ke-1 sampai dengan periode ke-61, sedangkan data prediksi dimulai dari periode ke-62 sampai dengan periode ke-76. Terlihat dari grafik model mampu mempresentasikan pola musiman serta tren yang terdapat dalam data historis PDRB dengan cukup baik. Untuk melihat akurasi pada peramalan ini juga dilihat dari nilai MAPE. Hasil pengujian menggunakan model yang telah didapatkan menunjukkan bahwa setelah melakukan peramalan atau prediksi, rata-rata kesalahan.

Hasil menunjukkan bahwa nilai MAPE model SARIMA $(0,1,4)(0,1,1)^4$ sebesar 2% termasuk kriteria sangat baik dibandingkan dengan model lainnya. Maka model SARIMA $(0,1,4)(0,1,1)^4$ yang akan digunakan untuk melakukan prediksi nilai PDRB di Provinsi Kepulauan Bangka Belitung periode triwulan II 2025 hingga triwulan IV 2028.

4.6 Perbandingan Hasil Prediksi SVR dan SARIMA

Setelah didapatkan hasil prediksi terbaik dari masing-masing metode yaitu metode SVR dan SARIMA, maka selanjutnya dapat dilakukan perbandingan dari masing-masing hasil prediksi. Pada pengolahan menggunakan metode SVR diperoleh kernel terbaik yaitu kernel *Radial Basic Function* (RBF) sedangkan pada metode SARIMA model terbaik yang diperoleh adalah $(0,1,0)(0,1,4)^4$. Berikut perbandingan nilai MAPE pada masing-masing metode dalam memprediksi nilai PDRB di Provinsi Kepulauan Bangka Belitung pada Tabel 4.9:

Tabel 4.10 Perbandingan Hasil Prediksi Metode SVR dan SARIMA

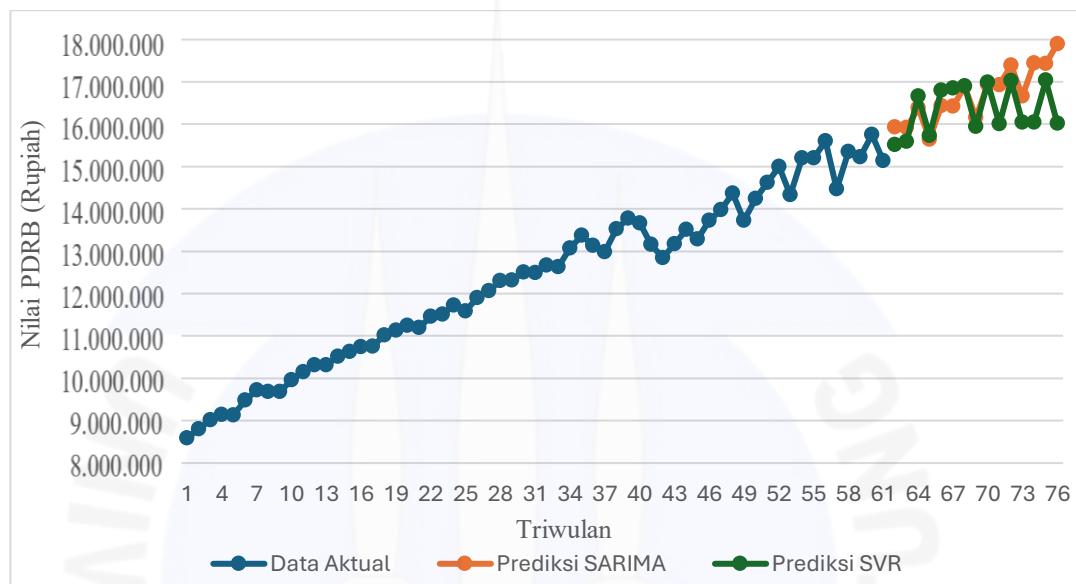
Variabel	Metode	MAPE
PDRB	SVR	3,08%
	SARIMA	2%

Sumber: Diolah Peneliti, 2025

Berdasarkan Tabel 4.10 dapat dilihat perbandingan nilai MAPE dari metode SVR dan SARIMA. Pada metode SVR nilai MAPE sebesar 3,08% sedangkan pada metode SARIMA nilai MAPE yang diperoleh sebesar 2%. Untuk nilai RMSE pada

metode SVR diperoleh sebesar 5,5, sedangkan nilai RMSE pada metode SARIMA diperoleh sebesar 4,2. Maka dapat disimpulkan bahwa metode yang terbaik untuk memprediksi nilai PDRB Provinsi Kepulauan Bangka Belitung adalah metode SARIMA dengan nilai MAPE dan RMSE terkecil dibandingkan dengan metode SVR.

Berikut grafik hasil perbandingan metode SVR dan SARIMA dalam memprediksi nilai PDRB Provinsi Kepulauan Bangka Belitung pada Gambar 4.8.



Sumber: Diolah Peneliti, 2025

Gambar 4.17. Grafik Perbandingan Hasil Prediksi Metode SVR dan SARIMA

Berdasarkan Gambar 4.16 perbandingan metode SVR dan SARIMA dalam memprediksi nilai PDRB Provinsi Kepulauan Bangka Belitung pada triwulan II 2025 sampai dengan triwulan IV 2028 menunjukkan bahwa nilai PDRB tertinggi untuk metode SVR akan terjadi pada triwulan 75 atau triwulan III 2028 dengan nilai 17.032,95. Sedangkan nilai PDRB terendah terjadi pada triwulan 62 atau triwulan II 2028 dengan nilai 15.509,57. Hasil prediksi PDRB menggunakan metode SARIMA nilai PDRB tertinggi akan terjadi pada triwulan 76 atau triwulan IV 2028 sebesar 17.895,80 sedangkan nilai PDRB terendah akan terjadi pada triwulan 65 atau triwulan I tahun 2026, 15.646,71. Berikut hasil prediksi data PDRB Provinsi Kepulauan Bangka Belitung menggunakan metode SARIMA terlihat pada tabel 4.11.

Tabel 4.11 Hasil Prediksi PDRB Provinsi Kepulauan Bangka Belitung

Tahun	Triwulan	Nilai PDRB (Miliar Rupiah)
2025	II	15.930,19
	III	15.915,80
	IV	16.380,18
2026	I	15.646,71
	II	16.435,40
	III	16.421,01
	IV	16.885,38
2027	I	16.151,92
	II	16.940,61
	III	16.926,22
	IV	17.390,59
2028	I	16.657,13
	II	17.445,82
	III	17.431,43
	IV	17.895,80

Sumber: Diolah Peneliti, 2024

Nilai PDRB tertinggi akan terjadi pada triwulan 76 atau triwulan IV 2028 sebesar 17.895,80 sedangkan nilai PDRB terendah akan terjadi pada triwulan 65 atau triwulan I tahun 2026 sebesar 15.646,71.

4.7 Pembahasan

Hasil penerapan metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA) pada data PDRB Provinsi Kepulauan Bangka Belitung menunjukkan bahwa model ini mampu menangkap pola tren dan musiman triwulanan secara akurat. Berdasarkan hasil pengujian, diperoleh nilai MAPE sebesar 2% yang termasuk dalam kategori sangat baik karena berada di bawah 10%, sesuai dengan kriteria MAPE pada Tabel 2.1. Hal ini membuktikan bahwa tingkat kesalahan prediksi sangat rendah, sehingga model yang dibangun dapat diandalkan untuk peramalan jangka menengah.

Selain itu, hasil uji diagnostik menunjukkan bahwa residual dari model SARIMA bersifat *white noise* dan terdistribusi normal, yang berarti model telah

memenuhi asumsi dasar dalam analisis deret waktu. Kondisi ini mengindikasikan bahwa SARIMA berhasil memodelkan dinamika data PDRB secara menyeluruh tanpa meninggalkan pola yang signifikan pada residual. Dengan demikian, penerapan SARIMA dapat dikatakan untuk merepresentasikan karakteristik data PDRB yang memiliki pola tren dan musiman yang konsisten hal ini sejalan dengan penelitian Aburbeian *et al.*, 2022.

SARIMA lebih sesuai digunakan pada data PDRB Provinsi Kepulauan Bangka Belitung karena data yang dianalisis memiliki pola tren jangka panjang dan musiman triwulanan yang konsisten. Model SARIMA dirancang untuk mengakomodasi komponen *Autoregresif* (AR), *Moving Average* (MA), *Differencing* (I), serta komponen musiman (S) sehingga mampu merepresentasikan fluktuasi yang berulang dalam data ekonomi. Dengan kemampuan ini, SARIMA dapat memberikan hasil prediksi yang stabil serta akurat pada data yang memiliki pola periodik (Hyndman & Athanasopoulos, 2021).

Keunggulan SARIMA menghasilkan prediksi dengan kesalahan yang sangat rendah dibandingkan metode lain. Hal ini dibuktikan dengan hasil penelitian yang menunjukkan bahwa SARIMA seringkali mengungguli model berbasis *machine learning* ketika data memiliki musiman yang kuat, misalnya pada indikator ekonomi makro dan deret waktu keuangan (Aburbeian *et al.*, 2022). Hasil penelitian lain juga menyebutkan bahwa model statistik berbasis deret waktu seperti SARIMA cenderung lebih efisien dan interpretatif pada data dengan pola musiman yang jelas, sementara model berbasis *machine learning* lebih unggul pada data non-linear yang tidak memiliki pola musiman (Ghani *et al.*, 2021).

Pada metode SVR, dilakukan pengujian dengan empat kernel yaitu Linear, Polynomial, Sigmoid, dan RBF. Hasil menunjukkan bahwa kernel RBF memberikan performa terbaik dengan nilai MAPE terendah pada data latih 2,61% maupun data uji 3,55% sehingga menjadi kernel paling optimal dibandingkan kernel linear, polynomial, maupun sigmoid. Namun, ketika dirata-ratakan, nilai MAPE SVR sebesar 3,08% dengan RMSE sebesar 5,5, yang menunjukkan bahwa tingkat akurasi prediksi SVR masih lebih rendah dibandingkan SARIMA.

Meskipun SVR dengan kernel RBF mampu mengikuti tren data historis, terlihat adanya deviasi pada beberapa periode tertentu, terutama ketika terjadi

fluktuasi mendadak pada PDRB. Hal ini menunjukkan bahwa SVR kesulitan menangkap pola musiman triwulanan yang kuat pada data, meskipun performanya cukup baik dalam mengenali pola non-linear jangka pendek (Ghani *et al.*, 2021).

Metode SVR kurang optimal dalam memprediksi PDRB triwulanan Bangka Belitung karena data yang digunakan memiliki pola musiman dan tren yang konsisten. Karakteristik ini lebih cocok dimodelkan dengan pendekatan deret waktu seperti SARIMA. SVR yang berbasis *machine learning* pada dasarnya lebih unggul ketika digunakan pada data non-linear, kompleks, dan tanpa pola musiman yang jelas, misalnya data keuangan harian, lalu lintas jaringan, atau data sensor yang bersifat dinamis (Aburbeian *et al.*, 2022). Selain itu, SVR sangat bergantung pada pemilihan (C , ε , γ). Ketidaktepatan dalam menentukan parameter dapat menyebabkan *overfitting* atau *underfitting*, sehingga memengaruhi kualitas prediksi. Meskipun parameter pada penelitian ini telah dioptimalkan, hasilnya tetap menunjukkan bahwa SVR tidak seefektif SARIMA dalam menangkap pola musiman triwulanan pada data PDRB (Hyndman & Athanasopoulos, 2021).

Perbandingan kedua metode memperlihatkan bahwa SARIMA lebih unggul dibandingkan SVR. Nilai MAPE SARIMA 2% lebih kecil dibandingkan SVR 3,08%, demikian pula dengan nilai RMSE SARIMA 4,2 yang lebih rendah dari SVR 5,5. Nilai error yang lebih kecil membuktikan bahwa SARIMA mampu memberikan prediksi yang lebih akurat dan stabil (Aburbeian *et al.*, 2022), yang menunjukkan bahwa SARIMA seringkali lebih unggul dibandingkan model *machine learning* pada data ekonomi dengan pola musiman.

Hal ini menunjukkan bahwa model SARIMA mampu memberikan hasil prediksi yang lebih akurat dan stabil. Perbedaan ini dapat dijelaskan oleh karakteristik data PDRB yang memiliki tren dan pola musiman yang kuat, sehingga metode berbasis deret waktu seperti SARIMA lebih sesuai (Makridakis *et al.*, 2020). Sementara itu, SVR yang bersifat non-parametrik dan berbasis *machine learning* lebih unggul ketika data bersifat non-linear dan tidak terikat pada pola musiman tertentu (Ghani *et al.*, 2021). Metode SVR lebih cocok digunakan pada data non-linear yang bersifat kompleks dan fluktuatif, seperti data harga saham, kualitas udara, maupun lalu lintas internet (Zhang *et al.*, 2019). Namun dalam penelitian ini, pola musiman yang kuat membuat SARIMA lebih optimal.