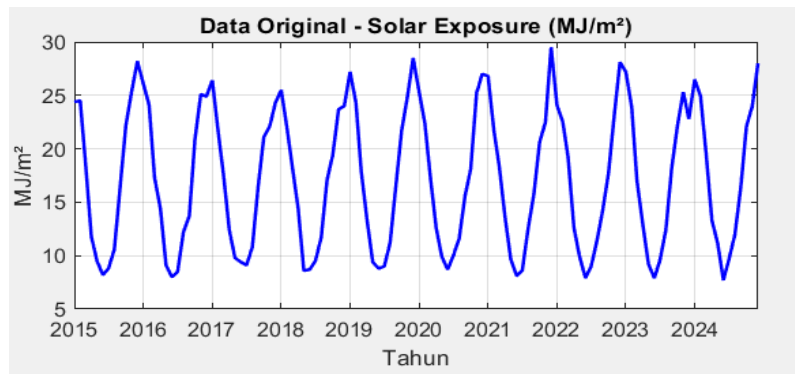


BAB IV HASIL DAN PEMBAHASAN

4.1. Deskripsi Data

Data Jumlah *monthly solar exposure* di north Adelaide Australia




Gambar 4.1 Grafik data *solar exposure*

Berdasarkan pada **Gambar 4.1**, dapat terlihat bahwa paparan sinar matahari mengalami fluktuasi yang teratur sepanjang tahun. Puncak tertinggi terlihat terjadi pada bulan Juni hingga Agustus, di mana paparan sinar matahari mencapai nilai lebih dari 25 MJ/m². Ini menunjukkan bahwa pada musim panas, intensitas sinar matahari lebih tinggi, sesuai dengan durasi siang hari yang lebih panjang dan posisi matahari yang lebih tinggi di langit. Sebaliknya, pada bulan Desember hingga Februari, paparan sinar matahari cenderung menurun dan mencapai titik terendah, berkisar antara 10 hingga 15 MJ/m². Penurunan ini mengindikasikan bahwa pada musim dingin, durasi siang hari lebih pendek, dan posisi matahari berada lebih rendah di langit, sehingga intensitas sinar matahari berkurang. Fluktuasi ini terjadi dengan pola yang sangat konsisten setiap tahun. Setiap tahun, kita dapat melihat peningkatan yang signifikan di bulan-bulan tengah tahun (musim panas), dan penurunan pada bulan-bulan akhir tahun (musim dingin). Secara keseluruhan, grafik ini menunjukkan bahwa data paparan sinar matahari mengikuti pola musiman yang stabil dengan variasi yang relatif sama dari tahun ke tahun. Tren ini juga menggambarkan bahwa intensitas sinar matahari di kawasan ini dipengaruhi oleh perubahan musim dan memiliki fluktuasi tahunan yang dapat diprediksi. Variasi antara bulan yang berbeda di setiap tahun menunjukkan bahwa faktor-faktor musiman seperti durasi siang hari dan posisi matahari memengaruhi perubahan paparan sinar matahari sepanjang tahun. Berdasarkan hasil ADF Test yang dilakukan nilai ADF Statistic = 0.2195 dan p-value = 0.7299 menunjukkan bahwa

data ini tidak stasioner dan perlu dilakukan *differencing* untuk membuatnya stasioner.


4.2. Analisis ACF Data Original (*Before Differencing*)



Gambar 4.2 Grafik ACF Data Original

Grafik ACF ini menunjukkan autokorelasi data sebelum dilakukan *differencing*. ACF mengukur sejauh mana nilai dalam deret waktu terkait dengan nilai sebelumnya. Pada grafik ini, kita dapat melihat bahwa ada puncak yang signifikan pada lag 12, 24, dan 36, yang menandakan adanya pola musiman tahunan dalam data, dengan interval satu tahun. Interpretasi pola musiman yang terlihat pada lag 12, 24, dan 36 menunjukkan bahwa data memiliki fluktuasi tahunan yang kuat. Nilai-nilai ACF yang signifikan di lag-lag tersebut menunjukkan adanya ketergantungan musiman yang jelas, yang menjadi alasan penting untuk mempertimbangkan model SARIMA dengan komponen musiman yang sesuai. ACF yang tinggi pada lag 12, 24, dan 36 mengindikasikan bahwa *differencing* musiman diperlukan untuk menghilangkan pola musiman tersebut dan membuat data stasioner.

4.3. Setelah *Regular + Seasonal Differencing*

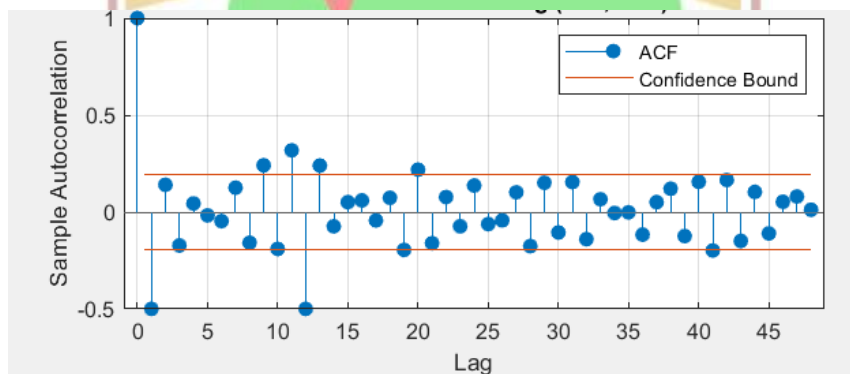


Gambar 4.3 Grafik Data Setelah *Regular + Seasonal Differencing*

Setelah dilakukan *regular differencing* ($d=1$) dan *seasonal differencing* ($D=1$ dengan periode musiman $s=12$), grafik menunjukkan data yang lebih stabil. Pola yang sebelumnya sangat fluktuatif telah lebih terkendali, dengan nilai yang lebih konsisten, meskipun masih ada sedikit variasi yang bisa dilihat.

Interpretasi: Setelah melakukan *differencing*, data menjadi lebih stasioner, yang terlihat pada grafik yang lebih stabil dan tidak lagi menunjukkan pola tren atau musiman yang kuat. Namun, masih terdapat sedikit fluktuasi *residual* yang menunjukkan adanya komponen noise yang harus ditangani oleh model. *Differencing* ini telah menghilangkan sebagian besar ketergantungan musiman dan tren, menjadikan data lebih cocok untuk dimodelkan dengan SARIMA. Hasil dari ADF Test setelah *regular differencing* ($d=1$) menunjukkan ADF Statistic = -7.9250 dan $p\text{-value} = 0.0010$, yang berarti bahwa data sudah stasioner setelah *differencing* pertama. Dengan demikian, data siap digunakan untuk membangun model SARIMA.

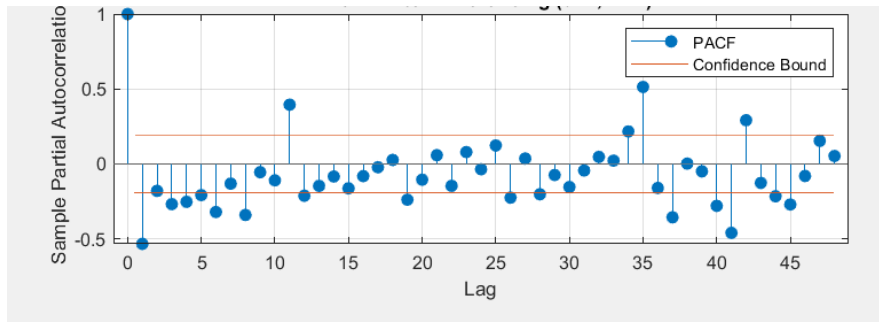
4.4. Analisis ACF Setelah *Differencing* ($d=1, D=1$)



Gambar 4.4 Grafik ACF Setelah *Differencing*

Grafik ACF setelah *differencing* menunjukkan hasil autokorelasi setelah data ditransformasikan untuk menjadi stasioner. Terlihat bahwa pada lag yang lebih besar, terutama setelah lag 12, nilai autokorelasi menjadi sangat kecil dan tidak signifikan. Ini mengindikasikan bahwa ketergantungan musiman telah berhasil dikurangi, dan data telah lebih bersifat acak. Interpretasi: Hasil ACF setelah *differencing* menunjukkan bahwa pola musiman telah hilang setelah dilakukan *differencing* musiman dan *regular*. Tidak ada lagi puncak signifikan di lag 12 atau 24, yang menunjukkan bahwa komponen musiman tahunan telah sepenuhnya dihilangkan. ACF yang hampir nol pada lag lebih tinggi menunjukkan bahwa data sudah cukup acak dan siap untuk dimodelkan dengan model ARMA (*Autoregressive Moving Average*) atau SARIMA.

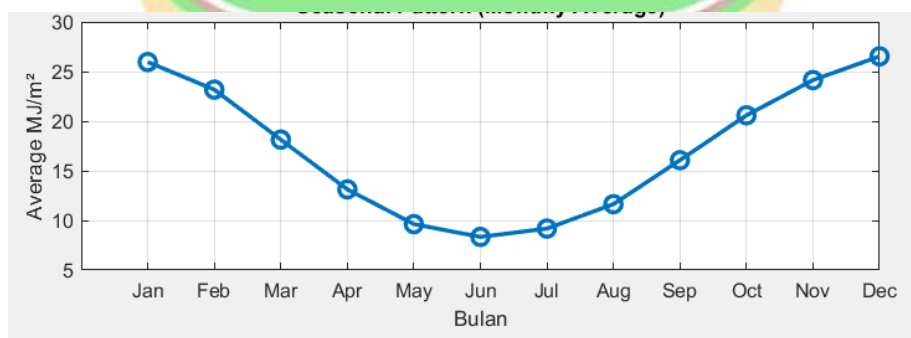
4.5. Analisis PACF Setelah *Differencing* ($d=1, D=1$)



Gambar 4.5 Grafik PACF Setelah *Differencing*

Grafik PACF ini menunjukkan autokorelasi parsial setelah *differencing*. Pada grafik PACF setelah *differencing*, terlihat bahwa ada potongan (*cut-off*) yang jelas setelah lag 1. Hal ini menunjukkan bahwa hubungan antar data terutama hanya terjadi antara nilai saat ini dan nilai sebelumnya (AR(1)). *Cut-off* yang jelas pada lag 1 menunjukkan bahwa hanya satu lag sebelumnya yang memiliki pengaruh signifikan terhadap nilai saat ini. Dengan demikian, parameter AR (*autoregressive order*) untuk model SARIMA dapat dipilih sebesar 1, yang menyarankan bahwa model hanya membutuhkan satu nilai sebelumnya untuk memprediksi nilai saat ini. Ini berarti bahwa model AR(1) akan cukup untuk menangkap ketergantungan jangka pendek dalam data.

4.6. Grafik *Seasonal Pattern*



Gambar 4.6 Grafik *Seasonal Pattern*

Grafik ini menggambarkan pola musiman data setelah dilakukan *differencing*. Pada grafik *seasonal pattern*, kita dapat melihat bagaimana data berubah sepanjang tahun dan menunjukkan fluktuasi yang berulang secara tahunan, dengan puncak-puncak yang terjadi pada periode tertentu setiap tahun. Setelah melakukan *differencing*, pola musiman yang muncul di grafik ini menunjukkan perubahan yang teratur setiap 12 bulan, yang sesuai dengan perubahan siklus

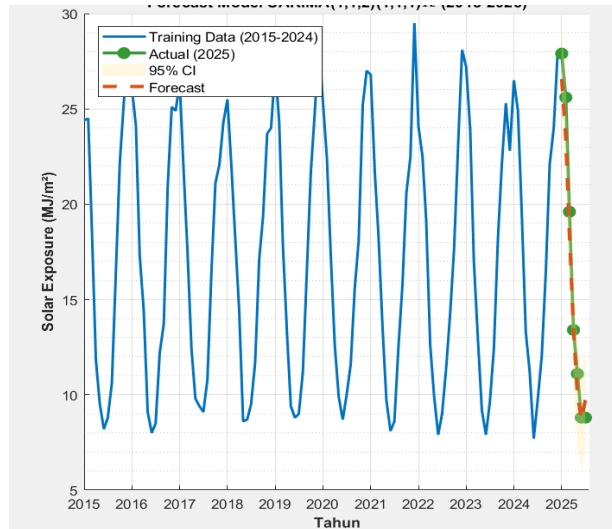
tahunan. Pola ini mengonfirmasi bahwa data memiliki komponen musiman yang kuat yang mempengaruhi nilai-nilai daya listrik, dan ini menjadi alasan penting untuk memasukkan faktor musiman dalam model SARIMA.

4.7. Pemilihan Model Sarima

4.7.1 Parameter Model SARIMA Terpilih

Model SARIMA(1,1,2)(1,1,1)₁₂ yang dipilih untuk meramalkan daya listrik PLTS *off-grid* didasarkan pada pertimbangan yang matang terhadap struktur data dan tujuan peramalan. Parameter AR(1) = -0.533455 dan MA(1) = -0.368058 serta MA(2) = -0.502062 memungkinkan model untuk menangkap dependensi jangka pendek yang penting dalam data, mengingat adanya korelasi signifikan pada lag 1 dan lag 2. Komponen musiman, yaitu *Seasonal AR(1)* = -0.323804 dan *Seasonal MA(1)* = -0.680506, bersama dengan *Seasonality* = 12, memungkinkan model ini untuk menangkap pola musiman tahunan yang kuat dalam data energi surya, yang sangat penting untuk meramalkan perubahan daya yang dipengaruhi oleh fluktuasi musiman. Selain itu, $d = 1$ dan $D = 1$ memastikan bahwa data menjadi stasioner, menghilangkan tren jangka panjang dan pola musiman yang tidak teratasi. Dengan AIC terendah (425.01), model ini terbukti efektif dalam menangkap pola data tanpa menjadi terlalu kompleks, yang menghindari overfitting. Nilai konstanta = -0.00227065 dan variansi *residual* = 1.82926 menunjukkan bahwa model ini menghasilkan prediksi yang stabil dengan kesalahan yang terkontrol. Secara keseluruhan, model ini memberikan keseimbangan yang optimal antara kesederhanaan dan kecocokan data, menghasilkan peramalan yang andal dan efisien untuk aplikasi perencanaan dan pengelolaan sistem PLTS *off-grid*.

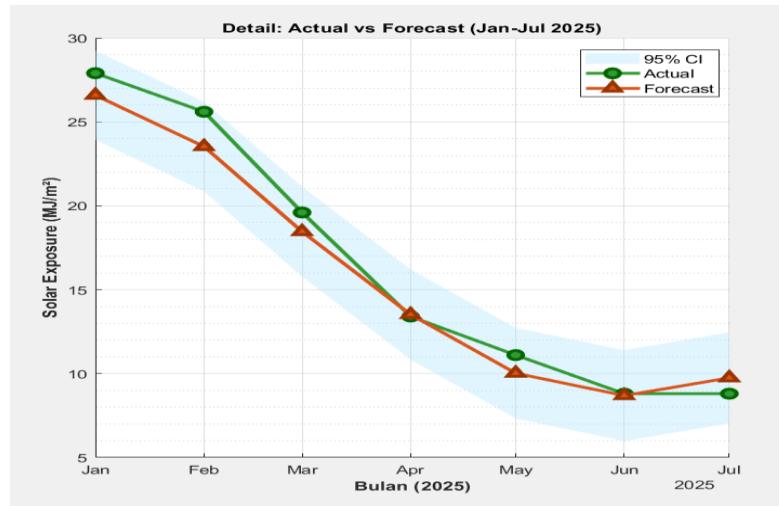
Kesimpulan dan Evaluasi Model. Model SARIMA(1,1,2)(1,1,1)₁₂ dipilih karena mampu menangkap dependensi jangka pendek dan pola musiman tahunan dengan AIC terendah. Hasil model ini menunjukkan bahwa peramalan untuk periode Januari 2025 hingga Juli 2025 memberikan hasil yang sangat baik dengan *error* yang kecil, yang tercermin dalam MAE (*Mean Absolute Error*), RMSE (*Root Mean Squared Error*), dan MAPE (*Mean Absolute Percentage Error*).



Gambar 4.7 (a) Grafik Model Sarima(1,1,2)(1,1,1)₁₂

Gambar 4.7 (a) memperlihatkan peramalan daya listrik PLTS *off-grid* di Australia dari 2015 hingga 2025 dengan menggunakan model SARIMA(1,1,2)(1,1,1)₁₂. Data pelatihan dari tahun 2015 hingga 2024 (ditandai dengan garis biru) menunjukkan fluktuasi yang jelas, mengikuti pola musiman tahunan yang khas. Pola ini mencerminkan variasi musiman yang konsisten sepanjang tahun, dipengaruhi oleh faktor-faktor lingkungan seperti radiasi matahari yang bervariasi setiap tahun. Data aktual untuk tahun 2025, yang diwakili oleh titik hijau, menunjukkan bahwa meskipun hanya beberapa titik yang tersedia pada bulan-bulan pertama, nilai aktual tersebut cenderung mengikuti tren yang diprediksi oleh model dengan cukup akurat. Peramalan untuk tahun 2025 ditunjukkan dengan garis oranye, yang dimulai dari titik terakhir pada tahun 2024. Meskipun ada beberapa ketidakpastian pada titik-titik ramalan tertentu, model ini memberikan perkiraan yang cukup akurat, dengan interval kepercayaan 95% (CI) yang digambarkan oleh area hijau di sekitar garis ramalan. Ini memberikan gambaran yang jelas mengenai ketidakpastian dalam peramalan. Fluktuasi sepanjang grafik menunjukkan pola musiman yang kuat, di mana puncak dan lembah yang terjadi setiap tahun (2015-2024) berulang secara teratur, mencerminkan pengaruh pola musiman tahunan yang sangat dominan dalam data ini.


4.7.2 Perbandingan data actual dan *forecast*



Gambar 4.7 (b) Grafik perbandingan data actual dan *forecast*

Gambar 4.7 (b) memperlihatkan perbandingan antara data actual (*solar exposure*) yang tercatat dari Januari hingga Juli 2025 dan hasil peramalan yang dihasilkan oleh model SARIMA. Titik hijau mewakili data actual pengukuran radiasi matahari, sementara titik oranye menunjukkan nilai peramalan yang dihasilkan oleh model. Area biru menggambarkan interval kepercayaan 95%, yang menunjukkan rentang prediksi yang dapat diandalkan, mencerminkan ketidakpastian dalam peramalan tersebut. Grafik ini menunjukkan bahwa baik data actual maupun peramalan mengikuti pola yang serupa, dengan penurunan nilai *solar exposure* dari Januari hingga Juli, yang konsisten dengan pola musiman yang terjadi di Australia, di mana radiasi matahari biasanya menurun pada bulan-bulan musim dingin. Fluktuasi musiman yang terlihat sepanjang grafik mencerminkan variabilitas tahunan yang dapat diprediksi dengan cukup baik oleh model SARIMA, yang berhasil menangkap perubahan intensitas radiasi matahari dan dampaknya terhadap produksi energi surya.

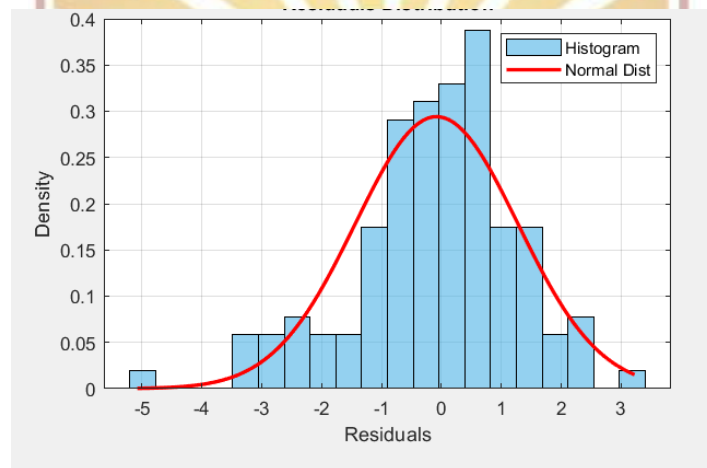
4.8. Residual Plot



Gambar 4.8 Grafik *Residual plot*

Grafik di atas menggambarkan *residuals* (selisih antara data aktual dan nilai prediksi) terhadap waktu (sumbu horizontal). Titik-titik pada grafik ini menunjukkan bagaimana *residuals* berfluktuasi sepanjang waktu. Fluktuasi ini penting karena menunjukkan seberapa baik model dalam menangkap pola yang ada. Dari grafik tersebut, terlihat bahwa *residuals* tidak menunjukkan pola yang jelas atau tren, yang mengindikasikan bahwa model telah menangkap sebagian besar pola dalam data, tanpa adanya sisa pola yang perlu ditangkap lagi. Jika ada pola tertentu dalam *residuals*, ini menunjukkan bahwa model belum sepenuhnya menangkap beberapa ketergantungan dalam data. *Residuals* yang acak seperti ini biasanya mengindikasikan bahwa model cukup baik dalam peramalan.

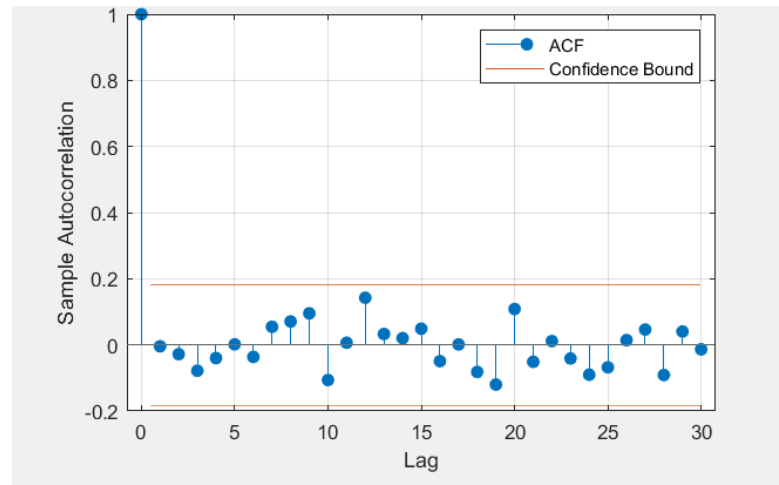
4.9. *Residuals Distribution (Distribusi Residual)*



Gambar 4.9 Grafik *Residual Distribution*

Histogram yang digabungkan dengan distribusi normal menunjukkan bagaimana *residuals* terdistribusi. Jika distribusi *residuals* mendekati distribusi normal, ini menunjukkan bahwa kesalahan peramalan model tidak bias dan dapat dianggap acak. Dalam hal ini, grafik menunjukkan bahwa histogram *residuals* memiliki bentuk yang mendekati distribusi normal, dengan garis merah mewakili distribusi normal yang diharapkan. Ini mendukung asumsi bahwa model memiliki kesalahan acak yang terdistribusi secara normal, yang penting untuk keakuratan prediksi dan validitas statistik.

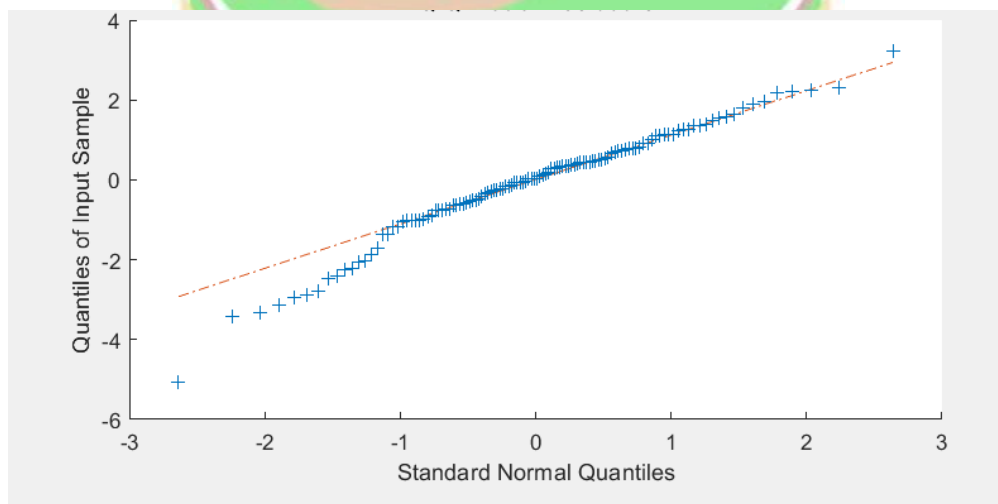
4.10. ACF of Residuals



Gambar 4.10 Grafik ACF Residuals

Gambar 4.10 menampilkan *Autocorrelation Function* (ACF) dari *residuals*, yang digunakan untuk memeriksa apakah *residuals* masih memiliki pola autokorelasi. Jika ACF *residuals* menunjukkan nilai signifikan pada beberapa lag, ini mengindikasikan bahwa model belum sepenuhnya menangkap ketergantungan waktu dalam data. Namun, grafik ini menunjukkan bahwa nilai ACF *residuals* tidak melewati batas signifikan, yang berarti tidak ada autokorelasi yang tersisa pada *residuals*, menunjukkan bahwa model berhasil menangkap pola temporal dalam data dengan baik.

4.11. Q-Q Plot of Residuals (Plot Q-Q Residuals)



Gambar 4.11 Q-Q Plot Residuals

Grafik yang ditampilkan merupakan Q-Q Plot yang digunakan untuk memeriksa distribusi dari *residual* model SARIMA. Q-Q Plot ini membandingkan kuantil dari *residual* model dengan kuantil distribusi normal standar. Jika titik-titik

pada plot mengikuti garis referensi (garis putus-putus), maka *residual* dapat dianggap terdistribusi normal. Berdasarkan grafik ini, sebagian besar titik *residual* berada dekat dengan garis referensi, yang menunjukkan bahwa model SARIMA secara umum berhasil menangkap pola data dan residualnya mendekati distribusi normal. Namun, terdapat penyimpangan di bagian ujung kiri dan kanan, yang menunjukkan adanya *outliers* atau deviasi yang lebih besar dari yang diharapkan, terutama pada sisi kiri bawah dan kanan atas plot. Hal ini mengindikasikan bahwa meskipun model SARIMA cocok untuk sebagian besar data, model ini mungkin kurang baik dalam menangani fluktuasi ekstrem atau faktor luar biasa dalam data energi surya, seperti perubahan cuaca yang drastis atau ketidakpastian lainnya. Meskipun demikian, penyimpangan ini tidak terlalu signifikan dan model SARIMA masih dapat diterima sebagai model peramalan yang baik untuk data jangka pendek.

Grafik ini menunjukkan perbedaan antara nilai aktual dan nilai peramalan (*forecast error*) untuk periode Januari hingga Juli 2025. Secara keseluruhan, grafik ini menggambarkan fluktuasi *error* antara bulan-bulan yang menunjukkan prediksi lebih tinggi atau lebih rendah dari nilai aktual. Pada bulan Februari, terjadi kesalahan peramalan terbesar dengan *error* sebesar 2.07, yang menunjukkan bahwa nilai aktual pada bulan tersebut jauh lebih tinggi dari yang diprediksi. Bulan Januari, Maret, dan Mei juga menunjukkan *error* positif yang cukup besar, meskipun tidak sebesar Februari, dengan masing-masing *error* 1.32, 1.14, dan 1.08. Sementara itu, bulan Juni menunjukkan *error* yang sangat kecil dengan hanya 0.11, menunjukkan prediksi yang sangat mendekati nilai aktual. Di bulan Juli, terjadi kesalahan peramalan negatif dengan *error* sebesar -0.94, yang berarti nilai aktual lebih rendah daripada yang diprediksi. Fluktuasi signifikan ini dapat disebabkan oleh ketidakstabilan musiman atau faktor eksternal yang mempengaruhi produksi energi surya pada bulan-bulan tertentu. Secara keseluruhan, meskipun ada beberapa bulan dengan kesalahan prediksi yang cukup besar, model SARIMA masih menunjukkan prediksi yang cukup akurat pada bulan-bulan lainnya, seperti Juni dan Juli, yang menunjukkan kesalahan yang sangat kecil.