



Prediksi *Inflow* Daerah Aliran Sungai Larona Dengan Model *Seasonal Autoregressive Integrated Moving Average*

*Tukiyat¹, Sutrisno², Sajarwo Anggai³

^{1,2}) Badan Riset dan Inovasi Nasional, Indonesia

^{1,3}) Teknik Informatika, Program Pascasarjana, Universitas Pamulang, Tangerang Selatan, Banten

Email: ¹tukiyat@brin.go.id, ²sutris83@yahoo.com, ³sajarwo@gmail.com

ABSTRACT

Larona Watershed (DAS) Inflow Prediction entering the reservoir has a very important role in managing the reservoir's water resources. Various approaches using mathematical models have been carried out, the results of which can be used as management tools to understand estimates and predictions of future inflow values, especially in the context of managing and planning water utilization for company needs at PT Vale Indonesia Tbk. The research aims to find a prediction model for the water inflow of the Towuti, Matano and Mahalona reservoirs. The research method uses a statistical approach using the SARIMA (Seasonal Autoregressive Integrated Moving Average) model. Research data, time series data, monthly inflow of the Larona watershed for January 2006 – December 2019. The research results showed that the best model was SARIMA (2,0,1)(0,1,1)¹². The mathematical model prediction formulated is $4.786 + 1.459t-1 - 0.648t-2 - 0.714 e_{t-1}$. The model accuracy level was tested using the RMSE (Root Mean Squared Error) criteria of 0.767, MAE (Mean Absolute Error) level of 0.592, MAPE (Mean Absolute Percentage Error) of 14.58. To validate the predicted values, the F test, Siegel-Turkey, Bartlett, Levene was carried out at the $\alpha=5\%$ level. The test results for the difference between actual and predicted values were concluded to accept the null hypothesis, which means that there is no significant difference between the actual data values and the predicted data values

Keywords: Prediction; Inflow; Larona Watershed; SARIMA Model

ABSTRAK

Prediksi *Inflow* Daerah Aliran Sungai (DAS) Larona yang masuk ke waduk mempunyai peran yang sangat penting dalam pengelolaan sumberdaya air waduk. Berbagai pendekatan dengan model matematika sudah banyak dilakukan yang hasilnya dapat dipakai sebagai alat manajemen untuk memahami estimasi dan prediksi nilai *inflow* di masa depan, khususnya dalam rangka pengelolaan dan perencanaan pemanfaatan air untuk kebutuhan perusahaan di PT Vale Indonesia Tbk. Penelitian bertujuan menemukan model prediksi *inflow* aliran air waduk Towuti, Matano dan Mahalona. Metode penelitian dengan pendekatan statistik menggunakan model SARIMA (*Seasonal Autoregresif Integrated Moving Average*). Data penelitian data *time series inflow* bulanan DAS Larona bulan Januari 2006 – Desember 2019. Hasil penelitian diperoleh model terbaik adalah SARIMA (2,0,1)(0,1,1)¹². Model matematis prediksi diformulasikan adalah $4.786 + 1.459t_{-1} - 0.648t_{-2} - 0.714 e_{t-1}$. Tingkat akurasi model diuji dengan kriteria RMSE (*Root Mean Squared Error*) sebesar 0.767, tingkat MAE (*Mean Absolute Error*) sebesar 0.592, MAPE (*Mean Absolute Percentage Error*) sebesar 14.58. Untuk validasi nilai hasil prediksi dilakukan dengan uji F, Siegel-Turkey, Bartlett, Levene pada taraf $\alpha=5\%$. Hasil uji perbedaan nilai aktual dan prediksi disimpulkan menerima hipotesis nul yang berarti bahwa tidak terdapat perbedaan yang signifikan antara nilai data aktual dengan nilai data prediksi.

Kata kunci: Prediksi; Inflow; DAS Larona; SARIMA Model.

1. PENDAHULUAN

Dalam pengelolaan sistem operasi waduk memerlukan adanya kajian untuk mengetahui berapa besarnya debit masuk (*inflow*) dan debit keluar (*outflow*) sebagai pola perencanaan pemanfaatan sumberdaya air. Banyak model-model prediksi *time series* yang sudah dikembangkan dengan menggunakan SARIMA [1], [2], [3], [4] dan [5]. Penerapan model SARIMA [6] dimanfaatkan untuk pengoperasian waduk. Pengetahuan yang baik mengenai inflow waduk dibutuhkan dalam kegiatan pengelolaan sumberdaya air dalam rangka menyusun pola operasi waduk dan rencana tahunan dan kegiatan monitoring serta pengendalian operasional. Penelitian ini bertujuan untuk melakukan prediksi debit aliran masuk (*inflow*) waduk DAS Larona dalam rangka pengelolaan air waduk. Pengelolaan inflow ini sangat penting terkait dengan perencanaan operasional kebutuhan air dan kemungkinan perlunya dilakukan Teknologi Modifikasi Cuaca.

Secara historis bahwa pola iklim di DAS Larona ini masuk musim kering pada bulan Agustus dan September, sementara bulan lainnya termasuk bulan basah [7]. Berdasar asumsi tersebut, maka prediksi inflow bulanan dapat diketahui lebih awal dalam rangka perencanaan dan pengelolaan air waduk untuk kebutuhan perusahaan secara optimal. Hal ini juga sebagai bagian dari monitoring bulanan inflow waduk untuk meningkatkan debit aliran dengan penerapan teknologi modifikasi cuaca.

Dengan penerapan teknologi modifikasi cuaca yang tepat waktu akan meningkatkan debit aliran waduk. Untuk menjaga kesinambungan pasokan airnya, pengelola bendungan perlu mempertahankan ketinggian muka air danau di atas batas yang ditetapkan. Mengingat pola data inflow mempunyai pola musiman maka model yang cocok untuk melakukan prediksi adalah dengan model SARIMA (*Seasonal Autoregressive Integrated Moving Average*) [8], [9].


SARIMA merupakan pengembangan dari model *Autoregressive Integrated Moving Average* (ARIMA) pada data runtun waktu (*time series*) yang memiliki pola musiman. Namun demikian model SARIMA memiliki beberapa keterbatasan karena model ini masih mempunyai error sehingga hasil kurang optimal dalam memilih nilai parameter yang terbaik. Box dan Jenkins [10] menjelaskan bahwa model ARIMA lebih tepat untuk analisis dan perkiraan waktu stasioner data runtun waktu, sementara model

SARIMA lebih tepat untuk perkiraan seri waktu musiman. Dalam konteks ini ada tiga hal penting yang perlu diperhatikan untuk peramalan data time series yaitu (1) ididentifikasi; (2) estimasi model, dan (3) diagnostik dan peramalan.

2. METODE

2.1. Lokasi Penelitian

DAS Larona terletak di Kabupaten Luwu Timur, Sulawesi Selatan. Secara geografis terletak pada 2.35° LS – 3.02° LS dan 121.15° BT – 121.82° BT. Luas DAS Larona sekitar 2.477 km². Sungai Larona yang merupakan sungai utama mempunyai panjang sekitar 120 km. DAS Larona mempunyai tiga buah danau alami yang tersusun secara Kaskade, yaitu Danau Matano, Danau Mahalona dan Danau Towuti. Lebih dari 50% luasan DAS Larona merupakan badan air dari ketiga danau kaskade tersebut.



Gambar 1. Peta Lokasi DAS Larona [11]

Dari tiga danau tersebut air mengalir melalui sungai Larona menuju turbin untuk tiga PLTA yaitu: Larona, Balambano, dan Karebbe yang berfungsi sebagai pemasok tenaga listrik untuk mengoperasikan *Furnace* (tanur peleburan dan pengolahan bijih nikel) di pusat pengolahan (*process plant*) di Sorowako milik PT Vale Indonesia Tbk. Uraian di atas menjelaskan betapa pentingnya data inflow aliran DAS Larona untuk mendukung proses produksi nikel PT Vale Indonesia Tbk.

2.2. Alat dan Bahan

Data penelitian berupa data sekunder dalam bentuk data *time series* inflow bulanan DAS Larona pada Januari 2006 – Desember 2019. Dalam dataset tersebut apabila ada data yang hilang atau *missing* maka akan diisi dengan metode rata-rata

aljabar. Metode rata-rata aljabar seperti yang dimodelkan oleh Saputro (2011) merupakan metode yang paling praktis digunakan untuk mencari data curah hujan yang hilang [12]. Data penelitian berupa data sekunder yang dikumpulkan dari pengelola waduk DAS Larona yaitu data inflow bulanan. Metode analisis data penelitian dengan pendekatan model SARIMA (*Seasonal Autoregressive Integrated Moving Average*). SARIMA adalah pengembangan dari model ARIMA (*Autorgresive Integrated Moving Average*) pada data runtun waktu yang mempunyai pola musiman. Secara konseptual model SARIMA [13] adalah SARIMA (p,d,q)(P,D,Q)^S dimana:

(p,d,q) = bagian data yang tidak ada musiman dari model

(P,D,Q) = bagian data yang ada musiman dari model

S = jumlah periode per musiman

Adapun rumus umum SARIMA (p,d,q)(P,D,Q)^S dapat diformulasikan sebagai berikut:

$$\phi_{pB^S} \cdot p^{(B)(1-B)^d(1-B^S)^D} Z_t = \gamma_{q^{(B)\theta} q^{(B^S)\alpha_t}}$$

Keterangan:

$p^{(B)}$ = AR non seasonal

ϕ_{pB^S} = AR seasonal

$(1 - B)^d$ = differencing non seasonal

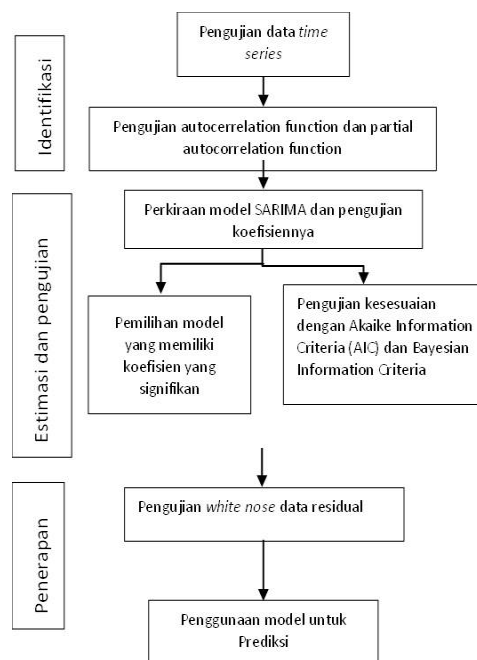
$(1 - B^S)^D$ = differencing seasonal

$\gamma_{q^{(B)\theta}}$ = MA non seasonal

$q^{(B^S)\alpha_t}$ = MA non seasonal

$q^{(B^S)\alpha_t}$ = MA non seasonal

Menurut [14] SARIMA terbagi atas model SAR (*Seasonal Autoregressive*), SMA (*Seasonal Moving Average*), SARMA (*Seasonal Autoregressive Moving Average*), dan SARIMA (*Seasonal Autoregressive Integrated Moving Average*). Secara konseptual model penelitian ini dapat digambarkan sebagai berikut:



Gambar 2. Kerangka Pemikiran Prosedur Model SARIMA[15]

Untuk menyelesaikan masalah pemodelan ini mengacu pada model Box-Jenkins [16] memberikan pedoman yang terdiri dari empat langkah yaitu:

1. Identifikasi model dengan memilih p , d , q sementara
2. Estimasi parameter
3. Diagnosis *residual* apakah sudah bersifat *white noise*. Dalam tahap ini dilakukan diagnosis secara terus menerus sampai model bersifat *white noise*
4. Melakukan prediksi

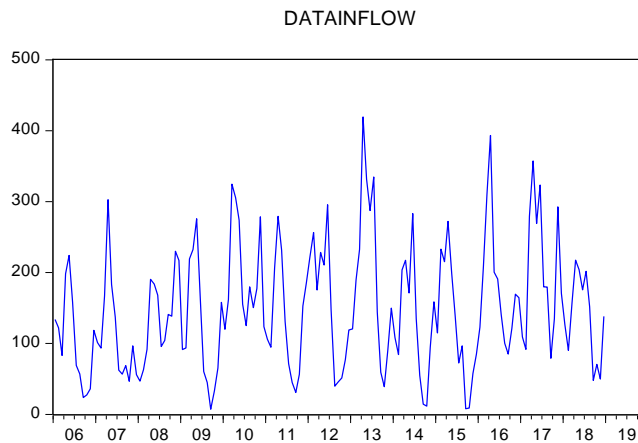
Untuk memilih model yang terbaik dilakukan dengan kriteria pada nilai (a) nilai Schwarz criterion yang kecil, (b) nilai Akaike info criterion (AIC) yang kecil, (c) nilai Sum Square Error (SSE) yang kecil dan (d) nilai Adjusted R squared yang besar. Pengujian akurasi model diuji dengan parameter RMSE (*root mean square error*), MAE (*mean absolute error*), dan MAPE (*mean absolute percentage error*). Uji data nilai data prediksi dengan data aktual dilakukan dengan statistik non parametrik melalui pendekatan dengan uji wilcoxon.

3. HASIL DAN PEMBAHASAN

3.1. Identifikasi Model

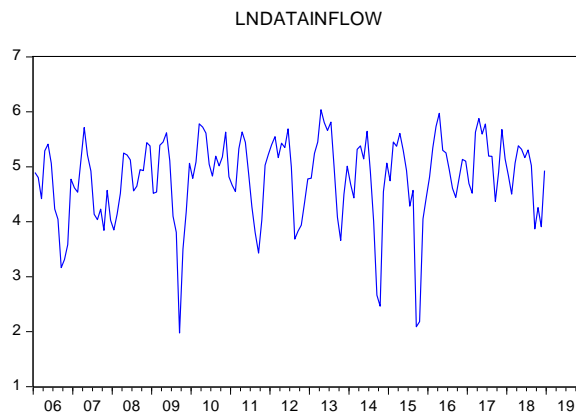
Identifikasi model diperlukan untuk menentukan tingkat stasioner dari sebuah rangkaian data. Tujuan dalam melakukan identifikasi model adalah untuk menentukan

apakah data tersebut sudah stasioner atau belum dalam rata-rata dan variansi. Jika data belum stasioner dalam rata-rata maka perlu dilakukan proses *differencing* dan jika belum stasioner dalam variansi maka perlu dilakukan proses transformasi. Dalam melakukan identifikasi model, langkah pertama yang dilakukan adalah dengan melakukan plot data. Hasil plot data dapat ditunjukkan pada gambar 3.



Gambar3. Hasil plot data rata-rata debit masuk bulanan DAS Larona periode Jan 2016 – Des 2019

Dari plot data tersebut bahwa data mempunyai pola naik turun yang berulang pada kurun waktu tertentu yang mengindikasikan bahwa dalam data terdapat unsur musiman. Hal ini dapat dilihat dari data inflow yang berupa data bulanan, dimana puncak data akan muncul setiap 6 bulan dalam setahun. Pola data ini juga mengindikasikan panjang periode musiman, karena data inflow bulanan maka panjang periode musiman adalah 12. Sebelum melakukan pendugaan dan indikasi model SARIMA, data perlu dilakukan proses transformasi logaritma natural untuk menyelaraskan *varians*. Hasil *plot dataset* hasil transformasi data terlihat pada gambar 4.



Gambar4. Plot data time series hasil transformasi


Dari plot data seperti gambar 4 tersebut di atas, bahwa pola data tersebut sudah mempunyai ragam/varians yang sama, namun data belum dikatakan stasioner pada rata-ratanya. Untuk mengidentifikasi stasioner data pada rata-ratanya maka dilakukan uji *Augmented Dickey-Fuller Test* (uji ADF), pada taraf uji $\alpha=5\%$. Berikut hasil uji stasioner pada rata-rata ditampilkan pada tabel 1

Tabel 1. Hasil uji ADF pada data inflow bulanan DAS Larona

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-6.73609	0.00000
Test critic: 1% level	-3.4731	
5% level	-2.88021	
10% level	-2.57681	
*MacKinnon (1996) one-sided p-values.		

Sumber: Hasil Pengolahan Data penelitian

Dari hasil uji ADF test pada taraf $\alpha=5\%$, diperoleh nilai probabilitas sebesar $0,000 < 0,05$, hasil uji ini menyimpulkan bahwa data tidak mempunyai unit root atau data stasioner pada rata-rata di tingkat level. Dengan demikian maka nilai $d=0$. Langkah selanjutnya untuk menentukan ordo parameter SARIMA dilakukan uji stasioner rata-rata pada bagian musiman dengan yaitu dengan melihat pola fungsi autokorelasi (ACF) dan autokorelasi parsial (PACF). Adapun hasil plot dataset hasil uji ACF dan PACF terlihat pada gambar 5.



Gambar 5: Plot Hasil Uji ACF dan PACF pada dataset inflow rata-rata bulanan DAS Larona

Dari gambar 5 diagram batang plot autokorelasi (ACF) dan plot autokorelasi parsial (PACF) mengindikasikan pada pola data grafik ACF terlihat signifikan pada lag 1 dan 2 dan menurun drastis pada lag 3 yang selanjutnya akan meningkat lagi pada lag ke 4 dan seterusnya serta mempunyai nilai signifikan pada puncak 6, 12, 18, 24, dan seterusnya setiap 6 bulan. Hal ini menunjukkan data inflow mempunyai pola musiman. Dengan demikian maka data belum stasioner pada rata-rata di bagian musiman. Dataset inflow yang dianalisis merupakan data bulanan, maka data akan dilakukan differencing 12 kali pada tingkat level. Mengingat data mempunyai pola musiman, maka perlu dilakukan *generate series data* untuk menetapkan data stasioner di bagian musiman. Hasil *generate data series* tersebut kemudian dilakukan uji ADF untuk mengetahui apakah data stasioner pada pola musiman.


Tabel 2. Hasil uji ADF pada hasil *generate data series* setelah dilakukan *differencing* 6 kali pada tingkat level

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-15.92793	0.0000
Test critical values:		
1% level	-3.481217	
5% level	-2.883753	
10% level	-2.578694	

*MacKinnon (1996) one-sided p-values.

Sumber: Hasil Pengolahan Data

Dari hasil uji ADF pada taraf $\alpha=5\%$ seperti di atas, terlihat bahwa nilai probabilitas 0.000 dimana nilai ini lebih kecil dari 0,05. Maka dalam hasil uji ini artinya data tidak mempunyai unit root. Dengan demikian, maka dapat disimpulkan bahwa data sudah stasioner dalam bagian non musiman dan musiman. Setelah data sudah stasioner pada differencing tingkat level, yang berarti $d=0$, maka selanjutnya untuk menentukan nilai parameter p dan q dalam model ARIMA dapat dideteksi dengan melihat pola fungsi autokorelasi (ACF) dan autokorelasi parsial (PACF). Adapun hasil plot dataset hasil uji ACF dan PACF terlihat pada gambar 6.



Gambar 6: Hasil plot dataset hasil uji ACF dan PACF

Dari plot grafik autokorelasi (ACF) dan grafik autokorelasi parsial (PACF) menunjukkan bahwa dalam grafik ACF pada lag 1 signifikan dan menurun pada lag 2,3, dan lalu pada lag 5 dan 6 signifikan lagi. Sedang plot grafik PACF menunjukkan bahwa pada lag 1 signifikan dan menurun pada lag 2,3 dan seterusnya menurun secara terus menerus. Berdasar dari hasil analisis data dan pengujian serta melihat pola korelogram tersebut, maka dugaan model yang cocok antara lain: SARIMA (1,0,1)(0,1,1)¹²; SARIMA (2,0,1)(0,1,1)¹²; dan SARIMA (1,0,2)(0,1,1)¹².

3.2. Pendugaan Parameter dan Pemilihan Model

Berdasar pada kandidat model SARIMA yang telah diduga maka akan dipilih model terbaik yang representatif. Model yang dipilih akan dipakai untuk mengestimasi parameter p, q yang signifikan. Untuk memilih model yang terbaik dilakukan dengan kriteria parameter *Akaike Info Criterion* (AIC) dan *Schwarz Criterion* (SIC). Model yang baik merupakan model yang mempunyai nilai lebih kecil. Selain itu, dapat juga dilakukan dengan parameter pada *Adjusted R-Squared* dimana nilai *Adjusted R-Squared* yang besar adalah yang lebih baik. Hasil pendugaan parameter dan pemilihan model yang terbaik ditunjukkan pada tabel 3.

Tabel 3: Perbandingan Kriteria memilih Model SARIMA

Keterangan	SARIMA Model		
	(1,0,1) (0,1,1) ¹²	(2,0,1) (0,1,1) ¹²	(1,0,2) (0,1,1) ¹²
Akaike Info Criterion (AIC)	1.580	1.535	1.613
Schwarz criterion (SIC)	1.678	1.652	1.710
Adjusted R-Squared	0.535	0.559	0.520

Sumber: Hasil Pengolahan Data Penelitian

Berdasar pada tabel 3 tersebut, maka pemilihan model terbaik adalah SARIMA (2,0,1) (0,1,1)¹², dengan pertimbangan model tersebut mempunyai nilai AIC dan SIC yang paling kecil serta mempunyai *Adjusted R-Square* paling besar. Disarankan oleh [17] model yang baik adalah memberikan kriteria Informasi Akaike minimum (AIC). Dari model SARIMA (2,0,1)(0,1,1)¹² yang telah terpilih, maka model dan dugaan parameter model dapat diformulasikan pada tabel 4.

Tabel 4: Formulasi Dugaan Parameter dan Model Prediksi

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	4.785609	0.095399	50.16425	0.0000
AR(1)	1.458863	0.165805	8.798676	0.0000
AR(2)	-0.648429	0.096303	-6.733234	0.0000
MA(1)	-0.714274	0.203615	-3.507959	0.0006
SMA(12)	0.292004	0.074995	3.893653	0.0001
SIGMASQ	0.248403	0.022694	10.94592	0.0000

Sumber: Hasil Pengolahan Data Penelitian

Berdasar pada tabel 4 selanjutnya secara matematis dapat dibuat formulasi model prediksi inflow rata-rata bulanan DAS Larona sebagai $Inflow_t = 4.786 + 1.459_{t-1} - 0.648_{t-2} - 0.714 e_{t-1}$. Model tersebut dapat dipakai untuk memprediksi nilai inflow untuk bulan ke-t.

3.3. Pemeriksaan Diagnostik

Pada uji signifikansi parameter pada model SARIMA menunjukkan bahwa semua parameter sudah signifikan sehingga asumsi uji signifikansi parameter sudah terpenuhi. Selanjutnya dilakukan uji asumsi residual. Salah satu cara untuk melihat *white noise* dilakukan dengan diuji melalui korelogram ACF dan PACF dari residual. Bila ACF dan PACF tidak signifikan, hal ini mengindikasikan bahwa residual bersifat *white noise* artinya model sudah baik.

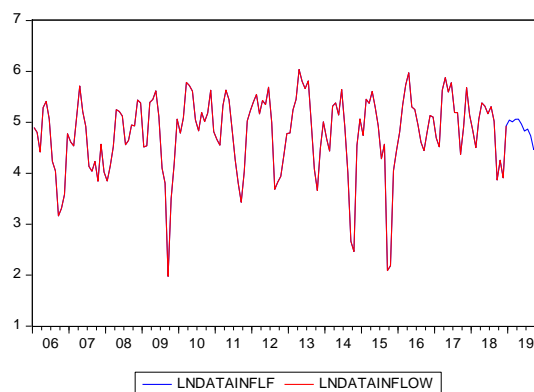
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.007	0.007	0.0083	
		2	-0.003	-0.003	0.0094	
		3	0.019	0.019	0.0660	
		4	-0.053	-0.054	0.5250	
		5	0.049	0.050	0.9164	0.338
		6	-0.055	-0.057	1.4094	0.494
		7	0.012	0.016	1.4322	0.698
		8	0.127	0.122	4.0972	0.393
		9	-0.098	-0.095	5.6923	0.337
		10	-0.180	-0.191	11.188	0.083
		11	0.110	0.127	13.247	0.066
		12	0.039	0.054	13.504	0.096
		13	0.079	0.059	14.570	0.103
		14	-0.013	-0.018	14.601	0.147
		15	-0.089	-0.084	15.982	0.142
		16	0.040	0.002	16.270	0.179
		17	0.012	0.072	16.296	0.234
		18	-0.126	-0.107	19.152	0.159
		19	0.003	-0.069	19.154	0.207
		20	0.009	-0.001	19.168	0.260
		21	0.002	0.040	19.168	0.319
		22	-0.084	-0.079	20.452	0.308
		23	0.070	0.129	21.358	0.317
		24	0.183	0.141	27.600	0.119
		25	0.037	-0.013	27.852	0.144
		26	-0.143	-0.130	31.723	0.082
		27	-0.087	-0.077	33.175	0.078
		28	0.029	-0.005	33.332	0.097
		29	-0.104	-0.093	35.425	0.081
		30	-0.052	-0.033	35.960	0.092
		31	-0.043	-0.060	36.319	0.108
		32	-0.029	-0.081	36.487	0.131
		33	-0.111	-0.067	38.976	0.102
		34	-0.087	0.004	40.502	0.096
		35	0.163	0.175	45.896	0.041
		36	0.193	0.133	53.544	0.010

Gambar 7: Korelogram Q-Statistik Residual Diagnostik

Hasil uji residual menunjukkan bahwa dari lag 1 sampai lag 34 tidak ada data yang signifikan. Hal ini berarti bahwa dalam model tidak terdapat korelasi antar residual sehingga dapat disimpulkan data sudah homogen. Data yang homogen berarti data sudah *white noise* sehingga model tersebut sudah layak dapat digunakan untuk melakukan prediksi.

3.4. Prediksi/Ramalan Inflow

Dari hasil analisis data dan prosedur yang telah dilakukan, maka dipilih model terbaik yaitu SARIMA (2,0,1)(0,1,1)¹² dan model tersebut dapat dipakai untuk melakukan peramalan atau prediksi inflow untuk bulan-bulan ke depan.



Gambar 8: Hasil prediksi inflow DAS Larona untuk tahun 2019 dari model SARIMA (2,0,1)(0,1,1)¹²

Dari grafik di atas menunjukkan bahwa pola aktual dan prediksi dalam beberapa data ke depan mempunyai pola yang sama antara aktual dengan prediksinya. Model prediksi ini digunakan dengan metode yang dinamis karena model ini dapat melakukan prediksi beberapa data ke depan sesuai dengan yang diinginkan, namun mempunyai kelemahan yaitu tingkat kesalahan yang semakin besar pada periode ke-t yang semakin besar. Tingkat akurasi hasil model prediksi dilakukan dengan kriteria RMSE (*Root Mean Squared Error*) sebesar 0.767, tingkat MAE (*Mean Absolute Error*) sebesar 0.592, dan MAPE (*Mean Absolute Percentage Error*) sebesar 14,58.

3.5. Validasi Data Prediksi

Untuk menguji kesamaan data aktual dan prediksi dilakukan dengan uji F, Siegel-Tukey, Bartlett, Levene, dan Brown Forsythe. Dalam pengujian ini bertujuan untuk mengetahui adanya keselarasan yang signifikan antara data inflow aktual dan prediksi. Adapun hipotesis yang dibangun adalah:

- H_0 = Tidak ada perbedaan yang signifikan nilai data aktual dengan nilai data prediksi
 H_1 = Terdapat perbedaan antara nilai data inflow aktual dengan inflow prediksi.

Pengujian dilakukan dengan taraf $\alpha=5\%$. Kriteria keputusan pengujian adalah apabila nilai probabilitas hasil uji $> 0,05$ maka akan menerima H_0 , sebaliknya apabila nilai probabilitas hasil uji $< 0,05$ maka keputusan akan menerima H_1 .

Tabel 5: Hasil pengujian keselarasan data inflow aktual dan prediksi

Method	df	Value	Probability
F-test	(155, 167)	1.070001	0.6669
Siegel-Tukey		0.655798	0.512
Bartlett	1	0.183548	0.6683
Levene	(1, 322)	0.268042	0.605
Brown-Forsythe	(1, 322)	0.206866	0.6495

Sumber: Hasil Pengolahan Data Penelitian

Berdasar hasil uji, semua nilai probabilitas untuk semua metode mempunyai nilai $> 0,05$. Dengan demikian, dapat disimpulkan hasil pengujian memutuskan menerima H_0 artinya tidak terdapat perbedaan yang signifikan antara data inflow aktual dengan data prediksi.

4. KESIMPULAN

Berdasarkan hasil analisis data penelitian, maka kesimpulan dari penelitian ini antara lain:

1. Berdasarkan hasil pengolahan data volume inflow kumulatif bulanan DAS Larona (m^3/bulan) Januari 2006 hingga Desember 2018 untuk pembangkitan model *time series* dengan menggunakan model SARIMA diketahui bahwa data inflow kumulatif di DAS Larona menunjukkan adanya pola musiman.
2. Dengan memasukkan unsur musiman model pembangkitan *time series* SARIMA diperoleh hasil persamaan modelnya sebagai berikut: SARIMA (2,0,1)(0,1,1)¹². Model tersebut dapat digunakan untuk meramal inflow untuk periode bulan ke depan dengan tingkat akurasi RMSE sebesar 0.767, MAE sebesar 0.592, dan MAPE sebesar 14.58.
3. Dengan hasil validasi model: SARIMA (2,0,1)(0,1,1)¹² antara data observasi (aktual) dengan data prediksi model yang menunjukkan hasil tidak berbeda nyata secara signifikan, berarti model SARIMA (2,0,1)(0,1,1)¹² dapat digunakan untuk memprediksi atau memprakirakan besaran volume inflow rata-rata bulanan di DAS Larona.
4. Validasi model dengan antara data inflow aktual (observasi) dan data inflow prediksi diuji dengan pendekatan uji F, Uji Seigel-Tukey, Bartlet, Levene dan Brown Forsythe pada taraf $\alpha=5\%$ menyimpulkan bahwa tidak terdapat perbedaan yang signifikan secara statistik data aktual dengan data prediksi.

5. DAFTAR PUSTAKA

- [1] A. P. Astuti, "Analisis prediksi jumlah wisatawan mancanegara yang masuk melalui pintu kedatangan entikong menggunakan metode sarima dengan software eviews," 2016.
- [2] H. A. Maulana, M. Z. Sampe, and F. Hanifah, "Pemodelan dan Peramalan Deret Waktu Studi kasus : Suhu Permukaan Laut di Selatan Jawa Timur," vol. 1, no. 2, pp. 187–199, 2017.
- [3] D. dan A. E. Ruhiat, "Pengaruh faktor musiman pada pemodelan deret waktu untuk peramalan debit sungai dengan metode sarima," vol. 2, no. 2, pp. 117–128, 2018.

- [4] S. Kasus *et al.*, “PERAMALAN CURAH HUJAN DENGAN PENDEKATAN SEASONAL AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (SARIMA) RAINFALL FORECASTING USING SEASONAL AUTOREGRESSIVE INTEGRATED MOVING AVERAGE MODEL (SARIMA),” vol. 11, pp. 63–74, 2017.
- [5] H. Liu *et al.*, “Journal of Infection and Public Health Forecast of the trend in incidence of acute hemorrhagic conjunctivitis in China from 2011 – 2019 using the Seasonal Autoregressive Integrated Moving Average (SARIMA) and Exponential Smoothing (ETS) models,” *J. Infect. Public Health*, vol. 13, no. 2, pp. 287–294, 2020, doi: 10.1016/j.jiph.2019.12.008.
- [6] K. Birhanu, T. Abcdef, M. Olumana, and D. Abcdef, “Application of SARIMA model to forecasting monthly flows in Waterval River , South Africa,” 2017, doi: 10.1515/jwld-2017-0088.
- [7] D. Syaifullah, “Karasteristik Curah Hujan Dan Aliran Das Larona Kabupaten Luwu Timur Sulawesi Selatan,” *J. Sains Teknol. Modif. Cuaca*, vol. 14, no. 2, p. 83, 2013, doi: 10.29122/jstmc.v14i2.2687.
- [8] J. Farajzadeh, A. Fakheri Fard, and S. Lotfi, “Modeling of monthly rainfall and runoff of Urmia lake basin using ‘feed-forward neural network’ and ‘time series analysis’ model,” *Water Resour. Ind.*, vol. 7–8, pp. 38–48, Sep. 2014, doi: 10.1016/j.wri.2014.10.003.
- [9] T. Dimri, S. Ahmad, and M. Sharif, “Time series analysis of climate variables using seasonal ARIMA approach,” *J. Earth Syst. Sci.*, vol. 129, no. 1, 2020, doi: 10.1007/s12040-020-01408-x.
- [10] E. H. Etuk, S. Aboko, P. Harcourt, and P. Harcourt, “An additive seasonal Box-Jenkins model for Nigerian monthly savings deposit rates,” vol. 2, no. March, pp. 54–59, 2014.
- [11] BPPT, “Monitoring TRMM untuk TMC DAS Larona (Sorowako),” *BPPT*, 2023.
- [12] F. Prawaka, A. Zakaria, and S. Tugiono, “Analisis Data Curah Hujan yang Hilang Dengan Menggunakan Metode Normal Ratio , Inversed Square Distance , dan Rata-Rata Aljabar (Studi Kasus Curah Hujan Beberapa Stasiun Hujan Daerah Bandar Lampung),” vol. 4, no. 3, pp. 397–406, 2016.
- [13] P. Chen, A. Niu, D. Liu, W. Jiang, and B. Ma, “Time Series Forecasting of

- Temperatures using SARIMA : An Example from Nanjing Time Series Forecasting of Temperatures using SARIMA : An Example from Nanjing,” 2018, doi: 10.1088/1757-899X/394/5/052024.
- [14] S. E. Sim, K. G. Tay, A. Huong, and W. K. Tiong, “Forecasting Electricity Consumption Using SARIMA Method in IBM SPSS Software,” vol. 6, pp. 103–114, 2019, doi: 10.13189/ujeee.2019.061614.
- [15] J. Cong, M. Ren, S. Xie, and P. Wang, “Predicting seasonal influenza based on SARIMA model, in mainland China from 2005 to 2018,” *Int. J. Environ. Res. Public Health*, vol. 16, no. 23, 2019, doi: 10.3390/ijerph16234760.
- [16] W. W. Winarno, *Analisis Ekonometrika dan Statistika dengan Eviews*, 4th Editio. Yogyakarta: UPP STIM YKPN, 2015.
- [17] K. Hamidi, H. Sedghi, and A. Telvari, “Forecasting by Stochastic Models to Inflow of Karkheh Dam at,” vol. 3, no. 5, pp. 340–350, 2017.