

# Forecasting Timbunan Sampah Kota Surabaya Menggunakan *Time Series Analysis*

Eka Fitriastutik, dan Maria Anityasari

Departemen Teknik dan Sistem Industri, Institut Teknologi Sepuluh Nopember (ITS)

*e-mail:* maria@ie.its.ac.id

**Abstrak**—Pengembangan sistem pengelolaan sampah kota yang efektif dan *environmentally sustainable* selalu menjadi tantangan bagi kota-kota di negara berkembang, termasuk bagi Kota Surabaya. Situasi ini diperburuk oleh tingginya angka sampah yang dihasilkan sebagai hasil meningkatnya angka urbanisasi, pertumbuhan penduduk, dan peningkatan ekonomi. Perencanaan manajemen pengelolaan sampah yang efisien memerlukan peramalan yang akurat, khususnya perkiraan jumlah sampah yang harus dikelola. *Forecasting* timbunan sampah dapat dilakukan dengan menggunakan beberapa pendekatan. Penelitian ini akan menggunakan model *Seasonal ARIMA* dan *Decomposition* baik untuk *Additive* dan *Multiplicative* untuk melakukan *forecasting* timbunan sampah DKRTH Kota Surabaya. Dari analisis yang dilakukan model *Seasonal ARIMA* memberikan performa yang terbaik sehingga dapat digunakan untuk melakukan *forecasting deployment*. Data histori yang digunakan adalah data Tahun 2017-2019 untuk *forecasting* Tahun 2020.

**Kata Kunci**—Sistem Pengelolaan Sampah Kota, *Time Series Analysis*, *Forecasting*, *Seasonal ARIMA*, *Decomposition*

## I. PENDAHULUAN

IMPLEMENTASI konsep *Sustainable City* menjadi tantangan tersendiri bagi kota-kota di negara berkembang, tak terkecuali bagi Kota Surabaya. Sebagai kota metropolitan terbesar di Indonesia dengan penduduk mencapai 2.904.751 jiwa pada 2019, Kota Surabaya telah berupaya menerapkan konsep *Sustainable/Eco City* sebagai bentuk keseriusan mengimplementasikan *Sustainable Development*. Konsep *Sustainable City* merupakan sebuah *framework* pengelolaan kota yang berdasar pada 4 pilar yang terdiri dari *social development*, *economic development*, *environmental management*, dan *urban governance*. Dalam konsep ini, *Sustainable Cities* harus memenuhi kebutuhan pembangunan tanpa memaksakan upaya pemenuhan *demand* yang tidak *sustain* terhadap *global natural resources system*. Hal penting yang harus diperhatikan dalam pengembangan *Sustainable City* adalah *Urban Logistics* yang mengacu pada aktivitas layanan untuk menyediakan air, keamanan, kesehatan, pengumpulan sampah, dan ruang terbuka hijau pada publik dengan kemungkinan biaya terendah ditinjau dari aspek dampak terhadap ekonomi, sosial, dan lingkungan [1]. Keseriusan Kota Surabaya telah mengantarkan pada diterimanya berbagai penghargaan nasional seperti Adipura Kencana, Adiwiyata, Muri, dan Status Lingkungan Hidup Daerah (SLHD) sejak 2006 hingga saat ini. Bahkan di kancah internasional, Kota Surabaya juga mendapat penghargaan sebagai *Global Green City* dari *Global Forum on Human Settlements* (GFHS) 2018 dan sebagai Kota Terpopuler versi *Guangzhou Award* 2018. Meskipun begitu, Kota Surabaya bukan berarti telah lepas dan jauh dari masalah lingkungan,

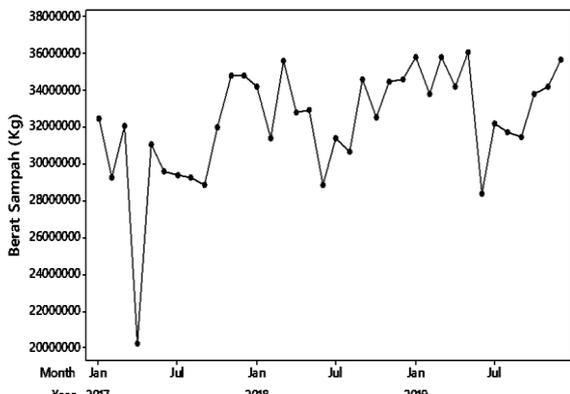
salah satunya terkait sistem pengelolaan sampah.

Pengembangan sistem pengelolaan sampah kota yang efektif dan *environmentally sustainable* selalu menjadi salah satu tantangan utama bagi kota-kota di negara berkembang [2]. Desain proses yang buruk tentu akan berdampak pada peningkatan biaya operasional dan mengakibatkan masalah yang serius jika meninjau konsekuensi yang diakibatkan terhadap lingkungan dan masyarakat. Proses pengumpulan dan pembuangan sampah kota yang buruk menyebabkan pengurangan nilai estetika lingkungan, banjir, dan polusi lingkungan (udara, air, dan tanah). Selain itu juga dapat mempengaruhi kesehatan manusia, berbahaya bagi biota darat dan laut, serta juga mengakibatkan efek terhadap perkembangan ekonomi seperti pengaruhnya terhadap pariwisata [3]. Situasi ini juga diperburuk oleh tingginya angka sampah yang dihasilkan sebagai hasil dari meningkatnya angka urbanisasi, pertumbuhan penduduk, pembiayaan yang tidak memadai, sikap pembuangan sampah masyarakat yang buruk, penggunaan sumber daya yang tidak efisien, kurang tepatnya instrumen pemerintah, dan penerapan teknologi yang tidak tepat [4].

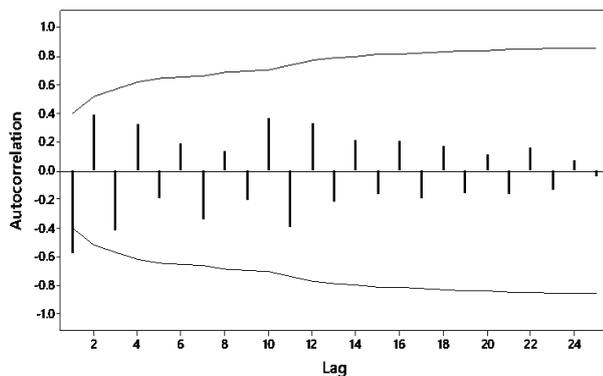
Berdasarkan data dari BPS Jatim Tahun 2020, proyeksi jumlah penduduk Kota Surabaya mengalami peningkatan dari tahun ke tahun. Pertumbuhan jumlah penduduk ini merupakan salah satu faktor kritis dari peningkatan jumlah sampah di Kota Surabaya. Selain jumlah penduduk, faktor lain yang mempengaruhi jumlah sampah di perkotaan adalah tingkat perekonomian, dimana semakin baik tingkat ekonomi pada suatu kota maka akan menghasilkan sampah yang lebih banyak pula. Hal ini benar melihat pengeluaran per kapita Kota Surabaya yang juga terus mengalami peningkatan. Peningkatan ekonomi dan jumlah penduduk Kota Surabaya berdampak signifikan pada peningkatan produksi sampah kota.

Pengelolaan sampah Kota Surabaya sendiri meliputi proses pembentukan sampah, pengumpulan, pengangkutan, pengolahan, dan *value recovery*. Pada proses pembentukan sampah, sampah dihasilkan oleh rumah tangga, penyapuan, saluran, pasar, dan sumber lain yang kemudian dikumpulkan pada tempat sampah atau *container* yang telah disediakan. Selanjutnya sampah tersebut dipindahkan ke Lokasi Penampungan Sampah Sementara (LPS) dengan gerobak dan diangkut dengan kendaraan pengangkut sampah ke Tempat Pembuangan Akhir (TPA) yang berlokasi di Benowo. Pada Tahun 2019, Kota Surabaya memiliki 254 LPS dimana sebanyak 223 LPS dikelola oleh DKRTH dan 31 lainnya dikelola oleh pihak Rekanan.

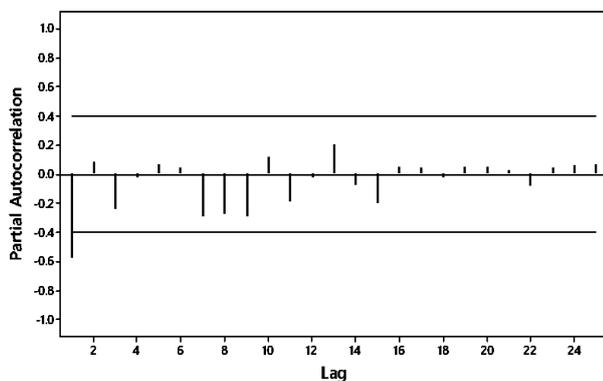
Perencanaan manajemen pengelolaan sampah yang efisien memerlukan peramalan yang akurat, khususnya perkiraan jumlah sampah yang harus dikelola. *Forecasting* terhadap



Gambar 1. Time Series Plot Berat Sampah Kota Surabaya yang dikelola DKRTH Tahun 2017-2019.



Gambar 2. Autocorrelation Berat Sampah Kota Surabaya Hasil Differences.



Gambar 3. Partial Autocorrelation Berat Sampah Kota Surabaya Hasil Differences.

produksi sampah dapat dilakukan dengan menggunakan beberapa pendekatan seperti *linear regression*, *time series forecasting*, dan *dynamic system*. Model umum yang banyak digunakan adalah *Auto-Regressive Integrated Moving Average (ARIMA)* yang dikembangkan oleh *Box* dan *Jenkins* pada 1976 [5]. Model ini digunakan untuk berbagai *non-stationary series* dan telah terbukti efektif digunakan dalam penelitian *waste collection vehicle scheduling* dan mengevaluasi bagaimana *recycling programs* mempengaruhi produksi sampah.

## II. METODOLOGI

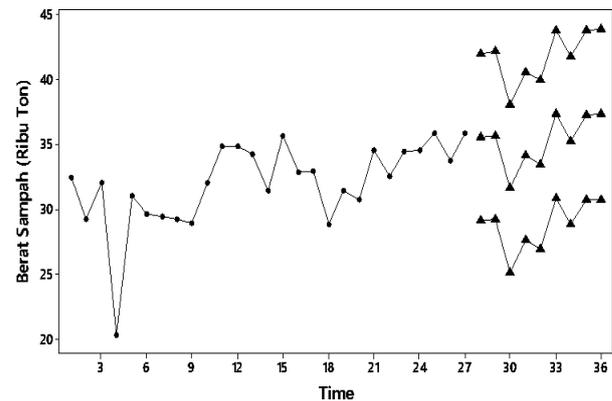
### A. Objek

Pengelolaan Sampah Kota Surabaya merupakan tanggung jawab dari Dinas Kebersihan dan Ruang Terbuka Hijau (DKRTH) Kota Surabaya. Tertuang pada Peraturan Daerah Kota Surabaya No. 14 Tahun 2016, DKRTH bertanggung

### Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	8.0	*	*	*
DF	11	*	*	*
P-Value	0.714	*	*	*

Gambar 4. Modified Box-Pierce Seasonal ARIMA (0,1,1) (0,1,0)<sup>12</sup>



Gambar 5. Seasonal ARIMA Forecasting.

jawab untuk menyelenggarakan urusan penataan ruang terbuka hijau, pekerjaan umum terkait pengelolaan sampah, pengelolaan kebersihan ruang publik, dan pengelolaan air limbah. Pada penelitian ini akan dilakukan peramalan timbulan sampah Kota Surabaya, khususnya sampah yang diangkut ke Tempat Pembuangan Akhir (TPA) oleh DKRTH Kota Surabaya.

### B. Pengumpulan Data

Data yang dikumpulkan adalah Data Histori Pengangkutan Sampah DKRTH ke TPA Benowo Tahun 2017-2019.

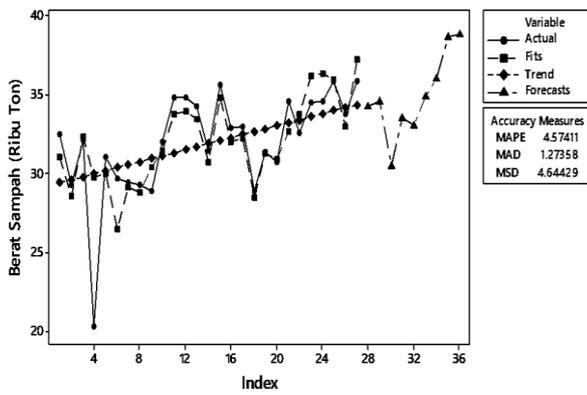
### C. Time Series Model

*Time series forecasting* digunakan untuk mengidentifikasi dan menjelaskan variasi keteraturan pada *series* data *seasonality*, pola siklus yang berulang setiap periode, *trend* data, dan *growth rate* dengan asumsi pola saat ini akan berlanjut di masa depan. Asumsi ini relatif akurat untuk masa depan jangka pendek [6].

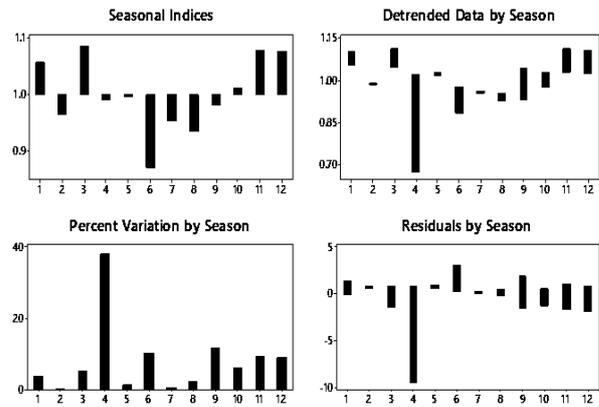
Penelitian ini akan menggunakan model *Seasonal ARIMA* dan *Decomposition* baik untuk *Additive* dan *Multiplicative*. Berikut ini merupakan penjabaran dari masing-masing model:

#### 1) Seasonal ARIMA (Seasonal Autoregressive Integrated Moving Average)

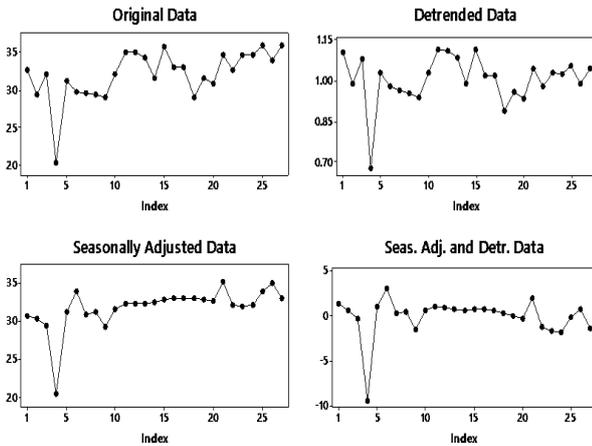
Model ini merupakan pengembangan dari model *ARIMA* dengan penambahan unsur pola musiman pada model. Proses *ARIMA* terdiri dari 3 bagian yaitu *AR (Autoregressive)*, *I (Integrated)*, dan *MA (Moving Average)* yang dinotasikan dengan (p, d, q). Dimana p merupakan parameter *autoregressive*, q merupakan parameter *moving Average*, dan d merupakan parameter *differencing*. Sedangkan pada model *Seasonal ARIMA* parameter yang digunakan dinotasikan sebagai (p,q,d) dan (P,D,Q)s yang berturut-turut merepresentasikan parameter *autoregressive*, *differencing*, dan *moving average non-sesonal* serta *seasonal*. Penentuan parameter merupakan bagian paling penting dalam analisis *time series* [5]. Parameter pertama yang dapat ditentukan adalah (d, D) dengan melakukan penilaian *stationerity* data, apakah data telah *stationer* terhadap rata-rata dan *varian*. Selanjutnya menentukan parameter (q, Q) menggunakan



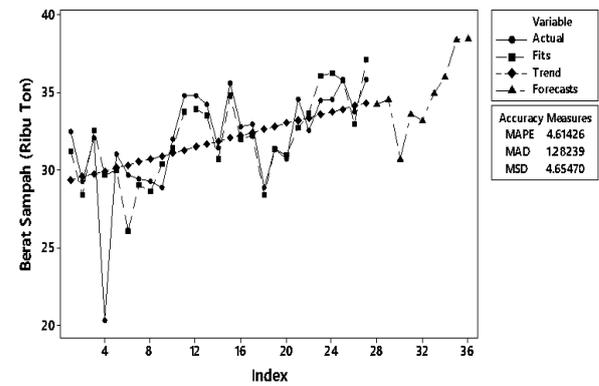
Gambar 6. Time Series Decomposition Plot Multiplicative Model.



Gambar 8. Seasonal Analysis Multiplicative Model.



Gambar 7. Component Analysis Multiplicative Model.



Gambar 9. Time Series Decomposition Plot Additive Model.

autocorrelation dan parameter (p, P) menggunakan *partial autocorrelation*.

2) *Decomposition Model*

Dekomposisi terhadap data *time series* menjadi beberapa *sub-component* dilakukan untuk mengetahui bagaimana efek setiap komponen terhadap deret data. Umumnya data *time series* memiliki pola musiman dan *trend*. Terdapat 2 model *decomposition* sebagai berikut:

a. *Additive Decomposition*

Total data dari model ini diambil dari penjumlahan pola yang telah terdekomposisi. Model ini efektif digunakan apabila nilai puncak dari data musiman tidak bervariasi signifikan.

$$X_t = seasonal (S_t) + trend (T_t) + random \tag{1}$$

b. *Multiplicative Decomposition*

Pada model ini *time series* data diperlakukan sebagai produk dari pola dekomposisi. Model ini efektif digunakan apabila nilai musiman berubah sepanjang waktu.

$$X_t = seasonal (S_t) \times trend (T_t) + random \tag{2}$$

D. Tahapan

Berikut ini merupakan tahapan-tahapan yang dilakukan untuk melakukan *time series analysis* dan *forecasting* timbulan sampah Kota Surabaya:

1) *Pembagian Data Set*

Data Pengangkutan Sampah DKRTH Kota Surabaya dibagi menjadi *data training* dan *data testing* dengan pembagian berturut-turut 75% dan 25%. Dari data yang

dikumpulkan data berat sampah periode Januari 2017-Maret digunakan sebagai *data training* sedangkan periode April – Desember 2019 menjadi *data testing*.

2) *Model Specification*

Analisis *time series* dimulai dengan membuat visualisasi *data training* berupa *time series plot*. Hal ini bertujuan untuk mengidentifikasi pola *time series* dan mendeteksi *stationarity*, *seasonality*, dan *trend*. Setelah pola data teridentifikasi selanjutnya dapat ditentukan metode *forecast* apa yang tepat untuk dilakukan. Pola data dapat ditinjau dari *time series plot*.

3) *Model Fitting*

*Model fitting* dilakukan untuk memodelkan data dengan metode yang tepat sesuai *model specification*. Penelitian ini menggunakan metode *Seasonal ARIMA* dan *Decomposition*.

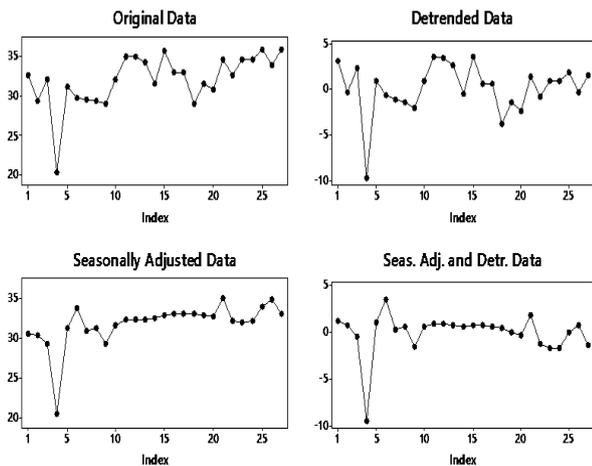
4) *Model Diagnosis*

Model Diagnosis dilakukan untuk membandingkan performa model. Parameter yang digunakan adalah nilai *Mean Absolute Percentage Error* (MAPE). MAPE merupakan ukuran yang mewakili persentase kesalahan absolut rata-rata yang terjadi. Nilai MAPE tidak tergantung pada skala pengukuran, tetapi dipengaruhi oleh transformasi data, dan tidak menunjukkan arah kesalahan. Rekapitulasi Nilai MAPE dapat dilihat pada Tabel 2.

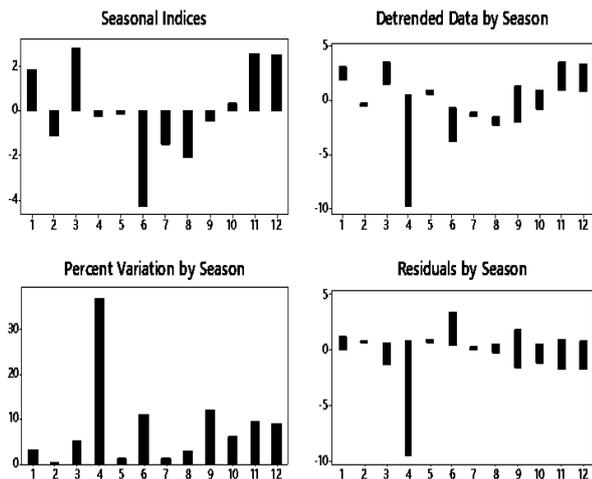
III. HASIL DAN DISKUSI

A. *Model Specification*

Pada tahap model *specification* dilakukan analisis *time series* pada grafik *time series plot* dengan mengidentifikasi pola *time series* dan mendeteksi *stationarity*, *seasonality*, dan *trend*. Setelah pola data teridentifikasi selanjutnya dapat ditentukan metode *forecast* apa yang tepat untuk dilakukan



Gambar 10. Component Analysis Additive Model.



Gambar 11. Seasonal Analysis Additive Model.

sesuai dengan *model specification*. *Time series plot* berat sampah yang dikelola oleh DKRTH Kota Surabaya ditunjukkan pada Gambar 1.

Dari grafik plot tersebut nampak adanya pola berupa *trend* naik dan pola musiman pada data berat sampah yang dikelola oleh DKRTH Kota Surabaya. Pola musiman tahunan terjadi dengan jumlah periode sebanyak 12 karena berasal dari data bulanan. Pada grafik nampak pada bulan yang sama terjadi peningkatan produksi sampah kota dari tahun ke tahun. Meskipun terdapat penurunan yang terjadi pada Bulan Juni, September, dan November, mayoritas peningkatan yang terjadi memiliki pola yang stabil, dengan peningkatan signifikan terdapat pada bulan April. Pada grafik juga nampak pola *seasonality* atau musiman. Hal ini disebabkan oleh adanya pergantian musim penghujan dan musim kemarau yang mempengaruhi kandungan air pada sampah. Pada musim penghujan, *density* sampah tinggi karena sampah cenderung basah akibat adanya air hujan yang tertampung pada sumber sampah atau LPS. Sedangkan pada musim kemarau, *density* sampah rendah sehingga sampah yang diangkut cenderung kering dan lebih ringan beratnya.

Pada 2017, pola berupa lembah terjadi antara bulan April-September dan bukit terjadi antara bulan Oktober-Maret. Selanjutnya pada 2018, pola berupa lembah juga terjadi antara bulan April-September dan bukit terjadi antara bulan Oktober-Maret. Berbeda pada 2019, pola berupa lembah terjadi antara bulan Juni-November dan bukit terjadi antara bulan Desember-Mei. Pola ini menunjukkan data series

memiliki pola *non-stationary* oleh karena itu diperlukan transformasi untuk menyesuaikan model *stationary*.

**B. Model Fitting**

Pada tahap *model fitting* dilakukan *modelling* data dengan metode *forecast* yang sesuai dengan *model specification*. Model yang digunakan adalah model yang mempertimbangkan pola *seasonality* dan *trend*.

**1) Seasonal ARIMA**

*Seasonal ARIMA* merupakan pendekatan *forecasting* yang digunakan untuk data *non-stationer* yang memiliki pola musiman. Hal yang harus dilakukan dalam pendekatan ini adalah menentukan parameter (p, d, q) dan (P, D, Q). Parameter pertama yang dapat ditentukan adalah (d, D) dengan melakukan penilaian *stationerity data*, apakah data telah *stationer* terhadap rata-rata dan *varian*. Selanjutnya menentukan parameter (q, Q) menggunakan *autocorrelation* dan parameter (p, P) menggunakan *partial autocorrelation*. Berikut ini dijabarkan langkah-langkah yang *forecasting* dengan *Seasonal ARIMA*:

**a. Stationerity Data**

Penilaian *stationerity* terhadap *varian* dapat dilakukan dengan menggunakan *Box-Cox Plot Transformation*, yaitu dengan melihat nilai *rounded value* ( $\lambda$ ). Data dikatakan *stationer* terhadap *varian* apabila memiliki nilai *rounded value* sebesar 1. Berdasarkan *Box-Cox Plot* yang diperoleh, data berat sampah belum *stationer* terhadap *varian* karena nilai *rounded value* sebesar 5. Oleh karena itu perlu dilakukan transformasi data. Setelah dilakukan transformasi, *stationerity* terhadap *varian* ditunjukkan oleh *rounded value* yang telah bernilai 1. Langkah selanjutnya adalah melakukan penilaian *stationerity data* terhadap rata-rata secara visual melalui grafik *time series* dan plot ACF (*Autocorrelation Function*). Plot ACF tersebut juga mengindikasikan nilai parameter *autoregressive* (AR). Untuk memperoleh plot ACF pada *Software Minitab* dilakukan dengan menggunakan data hasil transformasi dan dengan menggunakan *number of lag* sebesar 26. Berdasarkan hasil plot ACF diperoleh data pada lag 2 melebihi nilai *significant limit*. Hal ini menunjukkan terdapat autokorelasi pada data, sehingga dapat disimpulkan bahwa data tidak *stationer* terhadap rata-rata. Hal ini disebabkan oleh data yang memiliki dependensi terhadap waktu. Selanjutnya dilakukan *differencing* terhadap data hasil transformasi dengan *future differences* pada *Software Minitab*. *Differencing* terhadap data berat sampah ini merupakan *differencing non-seasonal* dan *seasonal* yang dilakukan sebanyak satu kali, sehingga dapat disimpulkan sebagai nilai parameter non-seasonal (d) dan seasonal (D) bernilai 1.

**b. Autocorelation dan Partial Aurocorelation**

Langkah selanjutnya adalah menentukan parameter MA dan AR. *Future* yang digunakan adalah *plot Autocorrelation* (ACF) dan *Partial Autocorrelation* (PACF). Plot ACF menunjukkan parameter MA (q, Q) dan plot PACF menunjukkan parameter AR (p, P) [7]. Parameter *non-seasonal* dapat diperoleh berdasarkan *lag* yang melebihi nilai *significant limit* pada 3 lag pertama, sedangkan parameter *seasonal* diperoleh pada lag 12, 24, dst.

Plot ACF ditunjukkan pada Gambar 2. Pada grafik plot tersebut nampak data memiliki pola *dying down*, dimana penurunan mendekati nilai 0 terjadi secara perlahan-lahan.

Tabel 1.  
Hasil Pengujian Signifikansi Parameter Model

Model	Parameter	P-VALUE	Signifikansi
(1,1,1)(0,1,0) <sup>12</sup>	AR=1	0.610	Tidak
	MA=1	0.000	Signifikan
(1,1,0)(0,1,0) <sup>12</sup>	AR=1	0.253	Tidak
	MA=1	0.000	Signifikan

Tabel 2.  
Rekapitulasi Nilai MAPE

Error	Seasonal ARIMA	Multiplicative	Additive
MAPE	5.63%	6.52%	6.57%

Pada 3 lag pertama, lag 1 melebihi nilai melebihi *significant limit*, namun untuk *seasonal lag* 12, 24 dst telah berada dibawah *significant limit*. Sehingga dapat disimpulkan data telah stationer terhadap rata-rata dan *varian*. Langkah selanjutnya melakukan *partial autocorrelation*.

Plot PACF ditunjukkan pada Gambar 3. Pada grafik plot tersebut nampak data mengalami penurunan mendekati 0 secara drastis atau mengikuti pola *cut-off*. Pada 3 lag pertama, lag 1 melebihi nilai *significant limit*, namun untuk *seasonal lag* 12, 24, dst telah berada dibawah *significant limit*.

Berdasarkan grafik plot ACF dan PACF selanjutnya dapat ditentukan parameter *Seasonal ARIMA* sebagai dugaan model sementara dengan nilai parameter yang dijabarkan sebagai berikut:

- $p = 1$ , diperoleh berdasarkan plot PACF setelah *differencing* 1, pada 3 lag pertama terdapat lag yang keluar dari nilai *significant limit* yaitu lag 1.
- $P = 0$ , diperoleh berdasarkan plot PACF setelah *differencing* 1, pada lag 12, 24, dst tidak terdapat lag yang keluar dari nilai *significant limit*.
- $d = D = 1$ , diperoleh berdasarkan proses *differencing* dan transformasi untuk memperoleh data yang stationer terhadap rata-rata dan *varian* dilakukan sebanyak 1 kali.
- $q = 1$ , diperoleh berdasarkan plot ACF untuk data dengan *differencing* 1 terdapat 1 lag yang keluar dari nilai *significant limit* yaitu lag 1.
- $Q = 0$ , diperoleh berdasarkan plot ACF untuk data setelah *differencing* 1, pada lag 12, 24, dst tidak terdapat lag yang keluar dari nilai *significant limit*.

c. Overfitting

Untuk melakukan *forecasting* dengan model *Seasonal ARIMA* perlu dipastikan terlebih dahulu bahwa parameter yang digunakan seluruhnya signifikan. *Overfitting* dilakukan untuk menentukan kombinasi model yang ada untuk selanjutnya dapat diuji untuk mencari kombinasi parameter yang signifikan. Nilai  $p=1$  maka kombinasi maksimal  $p$  adalah 1, nilai  $d=1$  maka nilai  $d$  adalah 1, dan nilai  $q=1$  maka kombinasi maksimal  $q$  adalah 1. Selanjutnya dilakukan pengujian parameter, dari kombinasi model yang mungkin dipilih model yang memiliki parameter yang seluruhnya signifikan, dimana seluruh parameter memiliki nilai  $< 0,05$ .

Parameter model dikatakan signifikan apabila mempunyai  $p\text{-value} < 0,05$ . Berdasarkan uji coba yang dilakukan yang ditunjukkan pada Tabel 1, diperoleh model dengan parameter  $(p, d, q)$  bernilai  $(0, 1, 1)$  dan  $(P, D, Q)^S$  bernilai  $(0, 1, 0)^{12}$  telah memiliki parameter yang seluruhnya signifikan dengan  $p\text{-value} < 0,05$ . Hasil dari pengujian signifikansi parameter

ini akan dilanjutkan untuk dilakukan pengujian asumsi residual.

d. Uji modified box-pierce (Ljung-Box) chi-square statistic.

Model *Seasonal ARIMA* memberikan nilai yang mendekati sebenarnya dengan asumsi nilai residual menyebar bebas (*independent*) dan identik (*normality*). Uji *modified box-pierce* dapat digunakan untuk memeriksa asumsi *independency* pada residual. Apabila nilai  $p\text{-value} > 0,05$ , maka dapat disimpulkan residual independen dan model memenuhi asumsi.

Hasil uji *modified box-pierce* ditunjukkan pada Gambar 4 dan diperoleh nilai  $p\text{-value} > 0,05$ . Sehingga dapat disimpulkan model *Seasonal ARIMA*  $(0,1,1) (0,1,0)^{12}$  diterima dan dapat digunakan untuk melakukan *forecasting deployment*.

Selanjutnya dilakukan *forecasting* untuk periode 9 bulan sesuai dengan jumlah *data testing* sebanyak 9 bulan yang ditunjukkan pada Gambar 5.

2) Time Series Decomposition

*Decomposition* digunakan untuk memisahkan data *time series* menjadi komponen-komponen yang terdiri dari *trend linear*, *seasonal*, dan *error* serta untuk memberikan hasil *forecasting* atau peramalan. Selanjutnya pada penelitian ini analisis dekomposisi dilakukan dengan menggunakan komponen *trend* dan *seasonal* baik dengan model *multiplicative* maupun *additive*. *Software Minitab* digunakan untuk melakukan perhitungan.

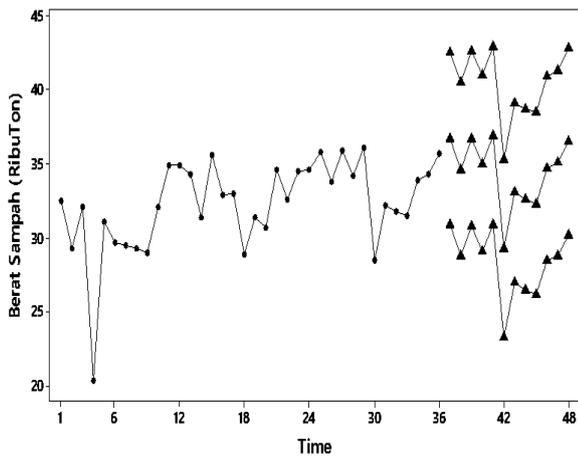
a. Multiplicative Model

Dalam Gambar 6 ditunjukkan *fitted trend equation* yang diperoleh:  $Y_t = 29.222 + 0.1907x$ .

Grafik dalam Gambar 6 menunjukkan *observation data versus time*, termasuk juga terdapat plot *trend line*, *forecast*, dan *accuracy measures*. Nilai *trend* pada metode *decomposition* memiliki pola linear dan konstan. Sedangkan *fits* merupakan nilai yang dihitung dari *trend equation* dan *seasonal indices*. Pada grafik plot nampak nilai *fits* mengikuti data aktual berat sampah. Dan pada akhir periode terdapat *forecast* untuk periode 9 bulan yang dihitung berdasarkan *trend equation* dan *seasonal indices*. Sedangkan *accuracy measures* merupakan pengukuran *error* yang selanjutnya dapat digunakan untuk membandingkan *fits* dengan model *time series* yang berbeda.

Gambar 7 menunjukkan *component analysis* yang terdiri dari grafik plot *original data*, *detrended data*, *seasonally adjusted data*, dan *seasonal adjusted and detrended data*. *Original data* menunjukkan plot *time series* dari data berat sampah Kota Surabaya dimana data memiliki *trend* dan *seasonal pattern*. *Detrended data* menunjukkan plot data dengan komponen *trend* yang telah dihilangkan dengan membagi data dengan nilai *trend*. *Seasonally adjusted data* menunjukkan data dengan komponen *seasonal* yang telah dihilangkan dengan membagi data dengan *seasonal index*. Apabila grafik *original data* dan *seasonally adjusted data* dibandingkan, nampak terdapat perbedahaan yang cukup signifikan, hal ini membuktikan terdapat komponen *seasonal* pada data. Sedangkan *seasonal adjusted and detrended data* menunjukkan nilai *residuals*, perbedaan nilai antara nilai yang diamati dengan nilai yang diprediksi.

Gambar 8 menunjukkan *seasonal analysis* yang terdiri dari *bar chart* dari *seasonal indices*, *detrended data by season*, *percen variation by season*, dan *residuals by season*. Grafik



Gambar 12. Forecasting Deployment.

*seasonal indices* menunjukkan perbandingan relatif nilai pada  $t$  terhadap nilai *baseline* sebagai efek *seasonal pattern*. Sedangkan *detrended data* merupakan data dengan komponen *trend* yang dihilangkan, dengan visualisasi berupa *boxplots* yang menunjukkan *seasonal period* yang memberikan variasi yang signifikan dan tidak. Nilai *detrended* pada model *multiplicative* ini menunjukkan rasio antara nilai yang diamati dan nilai *trend*. *Percent variation by season* menunjukkan plot variasi dari setiap *season* dalam *percent*. Variasi nilai signifikan terdapat pada data dengan *index 4*, hal ini dikarenakan pada *raw data* bulan ke-4, data berat sampah Kota Surabaya mengalami penurunan tidak wajar dan kembali naik mengikuti pola musiman normal pada bulan selanjutnya. Sedangkan *residuals by season* menunjukkan perbedaan antara nilai yang diamati dan nilai yang diprediksi sebagai hasil pengaruh dari *seasonal*.

#### b. Additive Model

Dalam Gambar 9 ditunjukkan *fitted trend equation* yang diperoleh:  $Y_t = 29.199 + 0.1913 \times t$

Sama halnya dengan grafik plot yang disajikan pada *multiplicative model*, Gambar 9 menunjukkan *observation data versus time*, *trend line*, *forecast*, dan *accuracy measures* untuk *decomposition* dengan *additive model*. Nilai *trend* memiliki pola linear dan konstan, nilai *fits* mengikuti pola data aktual berat sampah, pada akhir periode terdapat *forecast* untuk periode 9 bulan yang dihitung berdasarkan *trend equation* dan *seasonal indices*, serta terdapat *accuracy measures* sebagai pengukuran *error additive model* untuk dibandingkan dengan model lainnya.

Selanjutnya Gambar 10 merupakan *component analysis* yang terdiri dari grafik plot *original data*, *detrended data*, *seasonally adjusted data*, dan *seasonal adjusted and detrended data* untuk *decomposition* dengan *additive model*. Grafik plot yang ditampilkan pada model ini tidak berbeda signifikan dengan yang ditampilkan oleh *multiplicative model*. Perbedaan terdapat pada *fits* yang dihitung dari *fitted trend equation* dan *seasonal indices*. Nilai *fitted trend* pada *additive model* diperoleh dari penambahan nilai *trend*, *seasonal*, dan *error*, sedangkan pada *multiplicative model* merupakan hasil perkalian dari 3 komponen tersebut.

Sedangkan gambar 11 menunjukkan *seasonal analysis* untuk *additive model* yang terdiri dari *bar chart* dari *seasonal indices*, *detrended data by season*, *percent variation by season*, dan *residuals by season*. *Bar chart* pada *additive model* juga tidak berbeda signifikan dari *multiplicative*

*model*. Perbedaan terdapat pada perhitungan *detrended data*, pada model ini *detrended data* diperoleh dari pengurangan antara nilai yang diamati dengan *trend*.

#### C. Model Diagnosis

Untuk melakukan perbandingan terhadap 3 metode di atas, dapat dilakukan dengan menghitung parameter *error* dan membandingkannya dengan *data testing*. Parameter yang digunakan adalah MAPE (*Mean Absolute Percentage Error*). Metode yang memberikan hasil *forecast* dengan MAPE terkecil akan dipilih untuk melakukan *forecasting* berat Sampah Kota Surabaya 5 tahun ke depan. Formula yang digunakan untuk membandingkan nilai MAPE ditampilkan sebagai berikut:

$$MAPE = \frac{1}{N} \times \sum \frac{|X_t - F_t|}{X_t} \times 100 \quad (3)$$

Keterangan:

$X_t$  = Data testing pada  $t$

$F_t$  = Forecast pada  $t$

$N$  = Jumlah periode (bulan)

Dua metode yang digunakan memberikan nilai MAPE > 10%, yang mana hasil ini menunjukkan model yang dikembangkan memberikan hasil *highly accurate forecast* [8]. Model *Seasonal ARIMA (0,1,1)(0,1,0)*<sup>12</sup> memberikan MAPE terkecil sebesar 5,63. Model ini selanjutnya akan digunakan untuk *forecasting deployment*.

#### D. Forecasting Deployment

Berdasarkan analisis *time series* yang telah dilakukan, *forecasting* terhadap berat sampah Kota Surabaya dapat dilakukan dengan model *Seasonal ARIMA (0,1,1)(0,1,0)*<sup>12</sup>. *Forecasting* yang ditunjukkan pada Gambar 12 dilakukan untuk *forecasting* timbulan sampah Kota Surabaya Tahun 2020 dengan menggunakan seluruh data histori berat sampah Kota Surabaya yang diangkut oleh kendaraan yang dikelola DKRTH dari Bulan Januari 2017-Desember 2019.

## IV. KESIMPULAN

Telah dilakukan *forecasting* atau estimasi peningkatan berat sampah yang dihasilkan Kota Surabaya untuk Tahun 2020 menggunakan *Seasonal ARIMA model* dengan parameter  $(0,1,1)(0,1,0)$ <sup>12</sup>.

## DAFTAR PUSTAKA

- [1] J. A. Saucedo Martinez, A. Mendoza, and M. del R. Alvarado Vazquez, "Collection of solid waste in municipal areas: urban logistics," *Sustainability*, vol. 11, no. 19, p. 5442, 2019.
- [2] S. T. Amoah and E. A. Kosoe, "Solid waste management in urban areas of Ghana: issues and experiences from wa," vol. 2, 2014.
- [3] N. H. Hoang and C. Fogarassy, "Sustainability evaluation of municipal solid waste management system for hanoi (vietnam)—why to choose the 'waste-to-energy' concept," *Sustainability*, vol. 12, no. 3, p. 1085, 2020.
- [4] A. Sulemana, E. A. Donkor, E. K. Forkuo, and S. Oduro-Kwarteng, "Optimal routing of solid waste collection trucks: a review of methods," *J. Eng.*, vol. 2018, 2018.
- [5] I. Boulahna, N. El Khattabi, and Z. El Hadri, "Time series analysis for waste quantities prediction in a north african city," in *Proceedings of the 2017 International Conference on Smart Digital Environment*, 2017, pp. 74–79.
- [6] D. C. Montgomery, C. L. Jennings, and M. Kulahci, *Introduction to Time Series Analysis and Forecasting*, 2nd ed. New Jersey: John Wiley & Sons, 2015.
- [7] F. A. Razaq, M. Shitan, A. H. Hashim, and I. Z. Abidin, "Load

forecasting using time series models,” *J. Kejuruter.*, vol. 21, pp. 53–62, 2009.

- [8] C. D. Lewis, *Industrial and Business Forecasting Methods: A practical Guide to Exponential Smoothing and Curve Fitting*. Butterworth-Heinemann, 1982.