



## Perbandingan Peramalan Harga Beras Menggunakan Metode ARIMA pada Amazon Forecast dan Sagemaker

Is Mardianto<sup>1</sup>, Muhamad Ichsan Gunawan<sup>2</sup>, Dedy Sugiarto<sup>3</sup>, Abdul Rochman<sup>4</sup>

<sup>1,2,3,4</sup>Teknik Informatika, Fakultas Teknologi Industri, Universitas Trisakti

<sup>1</sup>mardianto@trisakti.ac.id

### Abstract

Rice is one of the main commodities of trade in Indonesia. PT Food Station as the management company of Cipinang Rice Main Market every day publishes data on price, type of rice and the amount of rice that enters and exits Jakarta area. This study aims to forecast rice prices in the Jakarta area using data held by PT FoodStation during the 2016-2018 data period. Rice price prediction is carried out for the next 30 days using the Auto Regressive Integrated Moving Average (ARIMA) method on the Amazon Forecast and Amazon Sagemaker platforms. The ARIMA model is a form of regression analysis that measures the strength of one dependent variable that is relatively influential on other change variables. The ARIMA model is a special type of regression model in which the dependent variable is considered stationary and the independent variable is the lag or previous value of the dependent variable itself and the error lag. ARIMA is a combination of auto-regressive and moving average processes. The final result obtained in this experiment is that the ARIMA model on Amazon Sagemaker cloud computing is superior when compared to Amazon Forecast. From the experimental results obtained the results of Amazon Sagemaker RMSE (313.379941) are smaller than Amazon Forecast (322.4118029). So it can be concluded that the ARIMA model run at Amazon Sagemaker is more accurate than Amazon Forecast for forecasting the price of rice for 30 days at the Cipinang Rice Main Market

Keywords: forecasting, rice, ARIMA, Amazon Forecast, Amazon Sagemaker, RMSE.

### Abstrak

Beras merupakan salah satu komoditas utama perdagangan di Indonesia. PT Food Station selaku perusahaan pengelola Pasar Induk Beras Cipinang setiap hari mempublikasikan data harga, jenis beras dan jumlah beras yang masuk dan keluar dari wilayah Jakarta. Penelitian ini bertujuan untuk melakukan peramalan harga beras di wilayah Jakarta menggunakan data yang dimiliki oleh PT FoodStation selama periode data 2016-2018. Prediksi harga beras dilakukan selama 30 hari kedepan menggunakan metode *Auto Regressive Integrated Moving Average* (ARIMA) pada platform Amazon Forecast dan Amazon Sagemaker. Model ARIMA adalah bentuk analisis regresi yang mengukur kekuatan satu variabel dependen yang relatif berpengaruh terhadap variabel perubahan lainnya. Model ARIMA adalah tipe khusus dari model regresi di mana variabel dependen dianggap stasioner dan variabel independen adalah lag atau nilai sebelumnya dari variabel dependen itu sendiri dan lag kesalahannya. ARIMA adalah kombinasi antara auto-regresif dan proses rata-rata bergerak. Hasil akhir yang didapatkan pada percobaan ini adalah model ARIMA pada komputasi awan Amazon Sagemaker lebih unggul ketika dibandingkan dengan Amazon Forecast. Dari hasil percobaan didapatkan hasil nilai RMSE Amazon Sagemaker (313.379941) lebih kecil dari pada Amazon Forecast (322.4118029). Sehingga dapat disimpulkan model ARIMA yang dijalankan di Amazon Sagemaker lebih akurat dibanding Amazon Forecast untuk peramalan harga beras selama 30 hari di Pasar Induk Beras Cipinang

Kata kunci: peramalan, beras, ARIMA, Amazon Forecast, Amazon Sagemaker, RMSE.

### 1. Pendahuluan

Pasar Induk Beras Cipinang (PIBC) merupakan sebuah pasar grosir yang menampung para pedagang besar dan dikelola oleh PT. Food Station, sebuah Badan Usaha Milik Daerah Pemerintah Provinsi DKI Jakarta. Para pedagang besar tersebut membeli beras yang dibawa oleh pedagang daerah ke Jakarta untuk kemudian

dipasarkan kembali kepedagang pasar retail baik di wilayah Jakarta dan sekitarnya serta antar pulau seperti Sumatera dan Kalimantan. PT. Food station setiap hari mempublikasikan data harga berbagai jenis beras serta jumlah beras masuk dan keluar berikut stoknya di PIBC melalui situs resminya [www.foodstation.co.id](http://www.foodstation.co.id). Data tersebut bisa menjadi tolok ukur pihak-pihak yang

Diterima Redaksi : 20-04-2020 | Selesai Revisi : 30-05-2020 | Diterbitkan Online : 20-06-2020

berkepentingan akan resiko instabilitas harga dan keperluan peramalan harga beras.

Analisis deret waktu adalah alat penting untuk memprediksi masa depan berdasarkan sejarah masa lalu. Peramalan adalah alat bantu yang kuat untuk proses pengambilan keputusan dan perencanaan untuk manajemen organisasi modern yang efektif [1]. Salah satu metode yang paling banyak digunakan dalam prediksi deret waktu adalah *Autoregressive Integrated Moving Average* (ARIMA). Model ARIMA adalah bentuk analisis regresi yang mengukur kekuatan satu variabel dependen yang relatif berpengaruh terhadap variabel perubahan lainnya [2]. Tujuan model adalah untuk memprediksi efek masa depan atau pergerakan pasar keuangan, lebih tepatnya dengan memeriksa perbedaan antara nilai-nilai dalam deret melalui nilai-nilai aktual.

Amazon Forecast menggunakan pembelajaran mesin untuk menggabungkan data deret waktu dengan variabel tambahan untuk membuat peramalan (Gambar. 1). Amazon Forecast tidak memerlukan pengalaman pembelajaran mesin untuk memulai. User hanya perlu memberikan data historis, ditambah data tambahan apa pun yang *User* yakini dapat mempengaruhi perkiraan *User*.

Amazon SageMaker adalah layanan yang dikelola sepenuhnya yang memungkinkan ilmuwan dan pengembang data dengan cepat dan mudah membangun, melatih, dan menggunakan model pembelajaran mesin pada skala apa pun (Gambar. 3). Amazon SageMaker mencakup modul yang dapat digunakan bersama atau secara mandiri untuk membangun, melatih, dan menerapkan model pembelajaran mesin.

Pada penelitian sebelumnya [3], Untuk peramalan 90 hari ke depan model ARIMA (1,1,2) menunjukkan grafik yang stabil dengan nilai validasi RMSE 58,7104, lebih kecil dibanding metode *Holt-Winters* yaitu 70,70758. Pada penelitian di Lingkungan Volatilitas Tinggi [4], pendekatan peramalan menggunakan metode ARIMA menghasilkan model peramalan yang andal. Namun, lingkungan volatilitas tinggi menciptakan kesalahan yang lebih besar. Oleh karena itu, peramalan di lingkungan dengan volatilitas tinggi memerlukan pertimbangan khusus untuk diagnostik kesalahan. Tindakan ini akan membantu investor untuk mendapatkan laba yang lebih baik dan mengurangi kerugian dalam keputusan investasi. Sedangkan Pada kasus peramalan penyakit Hepatitis B [5], didapatkan bahwa model ARIMA (3,1,1)(0,1,2)<sub>12</sub> memiliki kinerja prediksi yang lebih tinggi daripada model GM(1,1) dan lebih tepat dalam memperkirakan penyakit Hepatitis B. Model ARIMA tersebut mengubah faktor-faktor pengaruh penyakit menjadi beberapa variabel waktu khusus dan kemudian mencocokkannya.

Perbedaan dengan penelitian sebelumnya terletak pada tinjauan pemanfaatan metode ARIMA pada teknologi

*cloud computing* Amazon Web Service (AWS) dan tingkat akurasi peramalan yang diperoleh pada kasus peramalan harga beras. Pada penelitian ini peramalan harga beras untuk 30 hari kedepan di PIBC menggunakan platform Amazon Forecast dan Amazon Sagemaker. Untuk menentukan model yang paling akurat antara model ARIMA yang dijalankan pada Amazon Forecast dan yang dijalankan pada Amazon Sagemaker, perlu dilakukan validasi pengecekan atau evaluasi menggunakan metode *Root Mean Squared Error*[6].

*Autoregressive Integrated Moving Average* (ARIMA)

Proses ARIMA ini merupakan model *time series* yang *nonstationer*. Model ARIMA didefinisikan dengan tiga orde yaitu p, d, dan q, di mana nilai *integer* menggantikan parameter untuk menunjukkan jenis model ARIMA yang digunakan. Parameter dapat didefinisikan sebagai:

p: jumlah observasi *lag* dalam model; juga dikenal sebagai *lag order*.

d: berapa kali pengamatan mentah dibedakan; juga dikenal sebagai derajat perbedaan.

q: ukuran jendela rata-rata bergerak; juga dikenal sebagai urutan *moving average* [7].

Persamaan peramalan dikonstruksi sebagai berikut. Pertama, biarkan y menunjukkan perbedaan dth dari Y, yang berarti:

$$\begin{aligned} \text{if } d = 0: y_t &= Y_t \\ \text{if } d = 1: y_t &= Y_t - Y_{t-1} \\ \text{if } d = 2: y_t &= (Y_t - Y_{t-1}) - (Y_{t-1} - Y_{t-2}) \\ &= Y_t - 2Y_{t-1} + Y_{t-2} \end{aligned} \quad (1)$$

Perhatikan bahwa perbedaan kedua Y (d=2 case) bukan perbedaan dari 2 periode yang lalu. Alih-alih, ini adalah *first-difference-of-the-first difference*, yang merupakan turunan kedua dari *analog* diskrit, yaitu akselerasi lokal deret daripada tren lokalnya.

Dalam hal y, persamaan peramalan umum adalah:

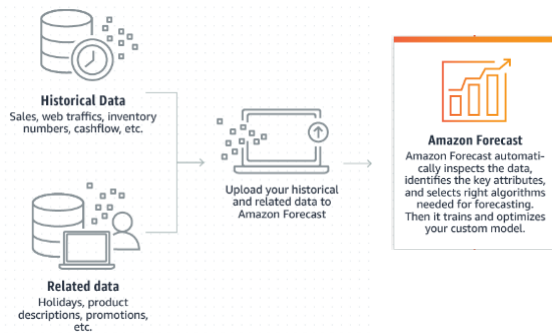
$$\hat{y}_t = \mu + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} - \theta_1 e_{t-1} - \dots - \theta_1 e_{t-q} \quad (2)$$

Di sini parameter *moving average* ( $\theta$ 's) didefinisikan, sehingga bernilai negatif dalam persamaan, mengikuti konvensi yang diperkenalkan oleh Box dan Jenkins. Beberapa penulis dan perangkat lunak (termasuk bahasa pemrograman R) mendefinisikan parameter *moving average* ( $\theta$ 's) dengan nilai kebalikannya yaitu nilai plus. Ketika angka aktual dipasang ke dalam persamaan, tidak ada ambiguitas, tetapi penting untuk mengetahui konvensi mana yang digunakan perangkat lunak ketika membaca hasilnya. Seringkali parameter dilambangkan dengan AR (1), AR (2),..., dan MA (1), MA (2),... dll [8].

*Amazon Forecast*

Amazon Forecast dapat menggunakan hampir semua data deret waktu historis (seperti harga, promosi, metrik kinerja ekonomi) untuk membuat perkiraan akurat untuk kegiatan bisnis (Gambar. 2). Misalnya, dalam skenario ritel, Amazon Forecast menggunakan pembelajaran mesin untuk memproses data deret waktu (seperti harga, promosi, dan lalu lintas toko) dan menggabungkannya dengan data terkait (seperti fitur produk, penempatan lantai, dan lokasi toko) untuk menentukan hubungan kompleks di antara mereka. Dengan menggabungkan data deret waktu dengan variabel tambahan, Amazon Forecast bisa 50% lebih akurat daripada alat peramalan pembelajaran non-mesin [9].

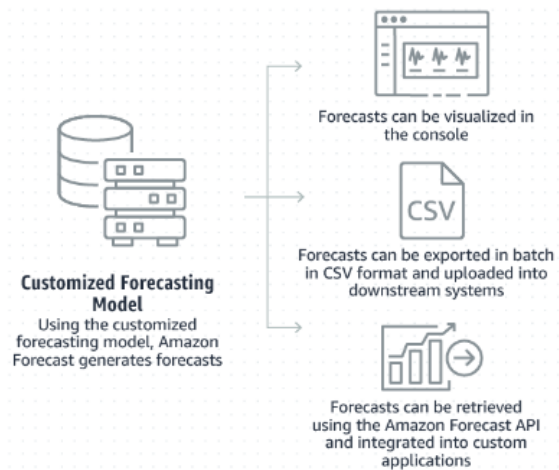
Misalnya, permintaan warna baju tertentu dapat berubah sesuai musim dan lokasi toko. Hubungan yang kompleks ini sulit ditentukan sendiri, tetapi pembelajaran mesin cocok untuk mengenalinya. Setelah User memberikan data, Amazon Forecast akan secara otomatis memeriksanya, mengidentifikasi apa yang bermakna, dan menghasilkan model peramalan yang mampu membuat prediksi hingga 50% lebih akurat daripada hanya melihat data *time series* saja [9]



Gambar 1. Sumber data untuk Amazon Forecast

*Amazon Sage Maker*


Amazon SageMaker dapat mempermudah dalam membangun model *Machine Learning* dan membuat model *Machine Learning* tersebut siap digunakan untuk melakukan *Training Model*, karena Amazon SageMaker menyediakan semua yang dibutuhkan secara cepat untuk melakukan *Training Model*, dan Amazon SageMaker dapat memilih dan mengoptimalkan algoritma dan kerangka kerja terbaik untuk aplikasi yang dibuat. Amazon SageMaker memiliki *notebook* Jupyter yang terhosting sehingga membuatnya mudah dalam mengeksplorasi dan memvisualisasikan data pelatihan yang tersimpan di Amazon S3. Amazon SageMaker dapat terhubung langsung ke dalam data yang berada di Amazon S3, atau menggunakan AWS Glue untuk memindahkan data dari Amazon RDS, Amazon DynamoDB, dan Amazon Redshift ke S3 untuk dianalisis pada *notebook* Jupyter [10].



Gambar 2. Kostumisasi model Forecast

Untuk membantu memilih algoritma, Amazon SageMaker menyertakan 10 algoritma pembelajaran mesin paling umum yang telah diinstal sebelumnya dan dioptimalkan untuk menghasilkan hingga 10 kali lipat dari kinerja biasa. Amazon SageMaker juga dilengkapi dengan pra-konfigurasi untuk menjalankan *TensorFlow* dan *Apache MXNet*, dua kerangka kerja *open source* paling populer. juga memiliki opsi untuk menggunakan kerangka kerja sendiri. *User* dapat mulai melatih model dengan satu klik di konsol Amazon SageMaker. Amazon SageMaker mengelola semua infrastruktur yang mendasari untuk dapat dengan mudah melatih model pada skala *petabyte*. Untuk membuat proses pelatihan lebih cepat dan lebih mudah, Amazon SageMaker dapat secara otomatis menyesuaikan model untuk mencapai akurasi setinggi mungkin [11].

Amazon SageMaker components



Gambar 3. Komponen Amazon Sagemaker

Setelah model dilatih, Amazon SageMaker mempermudah model untuk digunakan dalam produksi sehingga dapat memulai pembuatan prediksi pada data baru (proses yang disebut *inference*). Amazon SageMaker menyebarkan model kluster *auto-scaling* pada *instance* Amazon EC2 yang tersebar di beberapa zona untuk memberikan kinerja tinggi dan ketersediaan tinggi. Amazon SageMaker juga mencakup kemampuan pengujian A / B (*A/B testing*) untuk membantu menguji model dan bereksperimen dengan versi yang berbeda untuk mencapai hasil terbaik [12].

*Root Mean Square Error (RMSE)*


*Root Mean Square Error (RMSE)* adalah deviasi *residual* (kesalahan prediksi). *Residual* adalah ukuran seberapa jauh dari titik data garis *regresi*; RMSE adalah ukuran seberapa tersebar residu ini. Dengan kata lain, ini memberi tahu bagaimana data terkonsentrasi di sekitar garis yang paling cocok.

Dalam ilmu data, RMSE memiliki tujuan ganda:

1. Untuk berfungsi sebagai heuristik untuk model pelatihan
2. Untuk mengevaluasi model terlatih untuk kegunaan / akurasi

RMSE umumnya digunakan dalam klimatologi, peramalan, dan analisis regresi untuk memverifikasi hasil eksperimen. Perhitungan RMSE dimaksudkan untuk mengetahui akurasi koreksi.

**2. Metode Penelitian**



Gambar 4. Tahapan Penelitian

Tahapan penelitian (Gambar. 4) yang dilakukan dengan terlebih dulu mengubah data yang digunakan kedalam bentuk basis data *OLAP*, merupakan harga harian berbagai jenis beras yang berasal dari PT. Food Station dan dapat diakses melalui situs [www.foodstation.co.id](http://www.foodstation.co.id). Peneliti sudah mengolahnya dalam bentuk basis data *OLAP* pada MySQL dengan nama *db\_pasokanberas*. Terdapat 3 tabel yang peneliti gunakan *fact\_harga*, *dim\_race\_type*, dan *dim\_market*.

Tabel *fact\_harga* (Tabel. 1) merupakan data yang bersumber dari data transaksi sehari – hari yaitu dari *OLTP* data yang kemudian dimasukkan ke dalam data *warehouse*. Terdapat 25930 baris data dengan 14 tipe beras, dan 38 lokasi pasar berbeda di Jakarta dalam

rentang waktu 1 Januari 2016 sampai 31 Desember 2018.

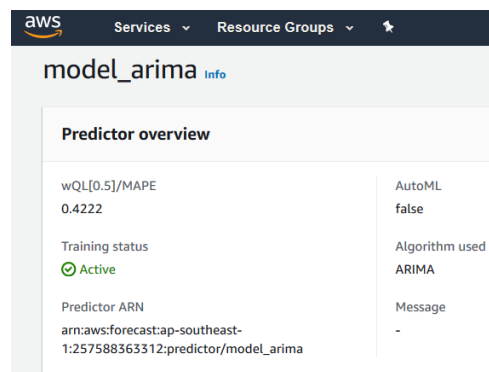
Tabel 1. Data Fact Harga

id	SK_DATE	SK_RICE_TYPE	SK_MARKET	PRICE
2115	20160101	1	0	13000
2116	20160101	2	0	12000
2117	20160101	3	0	12300
2118	20160101	4	0	10800
2119	20160101	5	0	10800
2120	20160101	6	0	9800
2121	20160101	7	0	9100
2122	20160101	8	0	10000
2123	20160101	9	0	9300
2124	20160101	10	0	8700
2125	20160101	11	0	10000
2126	20160101	12	0	15000
2127	20160101	13	0	20000
2128	20160101	14	0	16000
2129	20160102	1	0	13000
2130	20160102	2	0	12000
..	..	..	..	..
13066	20181231	3	35	15000

Namun pada penelitian ini menggunakan data harga beras (*SK\_RICE\_TYPE*) yaitu Pandan Wangi Premium dan nama pasar (*SK\_MARKET*) yaitu Pasar Induk Beras Cipinang.

Mengekspor data baru dari Pasar Induk Beras Cipinang pada jenis beras Pandan Wangi Premium dengan variable ``SK_MARKET = 0``, ``SK_RICE_TYPE = 1``, serta ``SK_DATE`` sebagai *timestamp*, dan ``PRICE`` sebagai variable target. Ini menyesuaikan *format* pengolahan Amazon Forecast yaitu *id objek*, *timestamp*, dan *target*. Data baru ini disimpan di penyimpanan *cloud* yaitu Amazon S3 (*Simple Storage Service*). Dilanjutkan proses *import* menggunakan lokasi penyimpanan Amazon S3 untuk target *time series* data peramalan pada Amazon forecast. Sedangkan untuk Amazon Sagemaker data hasil *export* dapat langsung diupload ke Amazon Sagemaker.

Membuat peramalan di Amazon forecast (Gambar. 5) ada beberapa tahap yaitu *import data*, *train predictor* (membuat model arima), serta *generate forecast* menghasilkan *forecast* dari model yang sudah dibuat.




Gambar 5. Pembuatan model arima di amazon Forecast


Untuk konfigurasi parameter pada pembuatan model arima yaitu *Number of backtest windows* = 3 dan *Backtest window offset* 30. Untuk nilai *lag order*, derajat perbedaan, dan urutan *moving average* Amazon Forecast akan secara otomatis memeriksanya, mengidentifikasi apa yang bermakna, dan menghasilkan model peramalan yang mampu membuat prediksi yang akurat.

Pada Amazon Sagemaker penelitian ini memanfaatkan fitur Notebook instance dengan type *ml.t2.medium*. *Notebook* ini adalah Jupyter notebok untuk melakukan proses eksekusi source code python yang biasa digunakan pada *Data Mining*.


Untuk konfigurasi nilai order terbaik untuk p, d, dan q. Menghitung *number of lags* diatas *level of significance* pada *partial autocorrelation* untuk nilai p (Gambar. 6). Menghitung dengan *auto correlation* pada *Order Differencing* untuk d (Gambar. 7), dan menggunakan Fungsi autokorelasi untuk menentukan urutan istilah MA, q, dengan menghapus autokorelasi (Gambar. 8) dalam deret *stasioner* [13].



Gambar 6. Partial Autocorrelation



Gambar 7. Auto Correlation pada Order Differencing ke 2



Gambar 8. Autocorrelation

Sehingga untuk membuat model Arima menggunakan parameter nilai *number of lags* ( $p$ ) = 1, *order of differencing* ( $d$ ) = 1, dan *number of lagged forecast errors / order of MA terms* = 1.

Dari hasil model yang telah dibuat (Gambar. 9). Model telah memperkirakan nilai AIC dan P dari koefisien terlihat signifikan [14].

ARIMA Model Results

Dep. Variable:	D.PRICE	No. Observations:	910
Model:	ARIMA(1, 1, 1)	Log Likelihood:	-5075.512
Method:	css-mle	S.D. of innovations:	63.976
Date:	Mon, 23 Mar 2020	AIC:	10159.025
Time:	14:00:09	BIC:	10178.279
Sample:	1	HQIC:	10166.376


  

	coef	std err	z	P> z	[0.025	0.975]
const	0.5897	3.384	0.174	0.862	-6.042	7.221
ar.L1.D.PRICE	0.8991	0.048	18.612	0.000	0.804	0.994
ma.L1.D.PRICE	-0.8385	0.059	-14.233	0.000	-0.954	-0.723

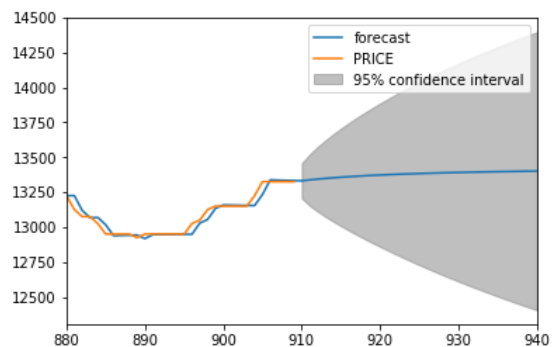
Gambar 9. Ringkasan Model ARIMA

### 3. Hasil dan Pembahasan

Hasil Peramalan harga beras Pandan Wangi Premium pada Pasar Induk Beras Cipinang dari model ARIMA yang dijalankan di Amazon Forecast (Gambar. 10) dan Amazon Sagemaker (Gambar. 11), keduanya menunjukkan grafik yang *Stationary* namun untuk melihat model mana yang paling akurat perlu pengecekan atau evaluasi menggunakan metode *Root Mean Squared Error* [6].




Gambar 10. Grafik Arima Amazon Forecast



Gambar 11. Grafik Arima Amazon Sagemaker

Dari kedua grafik dilakukan perbandingan harga dari data aktual atau observasi untuk melihat nilai error yang paling sedikit (Gambar. 12).



Gambar 12. Perbandingan Grafik Observasi

Karena hasil penghitungan nilai RMSE yang paling rendah menunjukkan bahwa variasi nilai yang dihasilkan mendekati variasi nilai obeservasinya, maka hasil perhitungan RMSE yang terkecil berarti akurasi semakin baik [15].

$$RMSE = \left( \frac{\sum (y_i - \hat{y}_i)^2}{n} \right)^{1/2} \quad (3)$$

Keterangan:

RMSE = nilai root mean square error

y = nilai hasil observasi

$\hat{y}$  = nilai hasil prediksi

i = urutan data pada *database*

n = jumlah data

Setelah melakukan perhitungan nilai RMSE didapat (Tabel. 2), nilai RMSE Amazon Sagemaker (313.379941) lebih kecil dari pada Amazon Forecast (322.4118029) dengan selisih 9.031. Sehingga model ARIMA yang dijalankan di Amazon Sagemaker lebih akurat untuk peramalan harga beras Pandan Wangi Premium selama 30 hari di PIBC.

Tabel 2. Perbandingan Nilai RMSE

Tanggal Forecast	Observasi	Amazon Forecast	Amazon Sagemaker
2019-01-01	13325	13322.34367	13331.63890
2019-01-02	13425	13420.85638	13337.66750
2019-01-03	13525	13516.06911	13343.14736
2019-01-04	13625	13422.89452	13348.13385
2019-01-05	13625	13329.61492	13352.67675
2019-01-06	13625	13323.92591	13356.82080
2019-01-07	13700	13324.94902	13360.60625
2019-01-08	13725	13322.34367	13364.06928
2019-01-09	13800	13420.85638	13367.24242
2019-01-10	13800	13516.06911	13370.15491
2019-01-11	13775	13422.89452	13372.83305
2019-01-12	13775	13329.61492	13375.30048
2019-01-13	13775	13323.92591	13377.57847
2019-01-14	13750	13324.94902	13379.68612
2019-01-15	13725	13322.34367	13381.64062
2019-01-16	13700	13420.85638	13383.45743
2019-01-17	13650	13516.06911	13385.15043
2019-01-18	13625	13422.89452	13386.73211
2019-01-19	13625	13329.61492	13388.21371
2019-01-20	13625	13323.92591	13389.60532
2019-01-21	13625	13324.94902	13390.91603
2019-01-22	13625	13322.34367	13392.15399
2019-01-23	13650	13420.85638	13393.32654
2019-01-24	13675	13516.06911	13394.44029
2019-01-25	13700	13422.89452	13395.50116
2019-01-26	13700	13329.61492	13396.51450
2019-01-27	13700	13323.92591	13397.48509
2019-01-28	13775	13324.94902	13398.41725
2019-01-29	13800	13322.34367	13399.31485
2019-01-30	13800	13420.85638	13400.18139
Nilai RMSE		322.4118029	313.379941

#### 4. Kesimpulan

Hasil peramalan harga beras Pandan Wangi Premium pada Pasar Induk Beras Cipinang, dari Perbandingan Nilai RMSE model ARIMA yang dijalankan pada Amazon Forecast dan Amazon Sagemaker untuk 30 hari kedepan yaitu 1 Januari 2019 sampai 30 Januari 2019, didapatkan kesimpulan Amazon Sagemaker lebih unggul dari Amazon Forecast karena model ARIMA yang dijalankan pada Amazon Sagemaker memiliki nilai Root Mean Square Error terkecil dengan hasil = 313.379941. serta nilai *number of lags* ( $p$ ) = 1, *order of differencing* ( $d$ ) = 1, dan *number of lagged forecast errors / order of MA terms* = 1.

#### Ucapan Terimakasih

Penulis mengucapkan banyak terimakasih kepada Fakultas Teknologi Industri Universitas Trisakti atas hibah penelitian internal yang diberikan hingga selesainya penelitian.

#### Daftar Rujukan

- [1] I. Unggara, A. Musdholifah, and A. K. Sari, "Optimization of ARIMA Forecasting Model Using Firefly Algorithm," *Indones. J. Comput. Cybern. Syst.*, vol. 13, no. 2, pp. 127–136, 2019, doi: 10.22146/ijccs.37666.
- [2] J. Agribisnis *et al.*, "Penerapan Autoregressive Integrated Moving Average (ARIMA) Pada Peramalan Produksi Kedelai di Sumatera Utara," vol. 9, no. 2, pp. 90–100, 2016.
- [3] A. B. Ariwibowo, D. Sugiarto, I. A. Marie, and J. F. Agatha, "Peramalan harga beras IR64 kualitas III menggunakan metode Multi Layer Perceptron, Holt-Winters dan Auto Regressive Integrated Moving Average," *ULTIMATICS*, vol. XI, 2019.
- [4] N. A. Bakar and S. Rosbi, "Autoregressive Integrated Moving Average (ARIMA) Model for Forecasting Cryptocurrency Exchange Rate in High Volatility Environment: A New Insight of Bitcoin Transaction," *Int. J. Adv. Eng. Res. Sci.*, vol. 4, no. 11, 2017.
- [5] Y. Wang, Z. Shen, and Y. Jiang, "Comparison of ARIMA and GM (1, 1) models for prediction of hepatitis B in China," *PLoS One*, pp. 1–11, 2018.
- [6] Muhammad Reza and Suprayogi, "Prediksi Jangka Waktu Pengiriman Barang Pada PT. Pos Indonesia menggunakan Backpropagation," *Cogito Smart J.*, vol. 3, pp. 111–122, 2017.
- [7] T. Safitri, N. Dwidayati, T. Safitri, N. Dwidayati, and S. P. Peramalan, "PERBANDINGAN PERAMALAN MENGGUNAKAN METODE EXPONENTIAL SMOOTHING HOLT-WINTERS DAN ARIMA," *UNNES J. Math.*, vol. 6, no. 1, pp. 48–58, 2017.
- [8] F. N. Hadiansyah, "Prediksi Harga Cabai dengan Pemodelan," *Ind. J. Comput.*, vol. 2, no. 1, pp. 71–78, 2017, doi: 10.21108/indojc.2017.21.144.
- [9] AWS Service Team, "Time Series Forecasting Principles with Amazon Forecast," *Amazon Web Service*. 2020.
- [10] AWS Service Team, "Introducing Amazon SageMaker," *Amazon Web Service*. 2017.
- [11] AWS Service Team, *Amazon SageMaker Developer Guide*. Amazon Web Service, 2020.
- [12] AWS Service Team, "Amazon SageMaker Documentation," *Amazon Web Service*. 2020.
- [13] D. Holmberg, "ARIMA Forecasting in Python," *towards data science*. 2019.
- [14] A. Lestari, "PERBANDINGAN MODEL ARIMA DAN MODEL REGRESI DENGAN RESIDUAL ARIMA DALAM MENERANGKAN PERILAKU PELANGGAN LISTRIK DI KOTA PALOPO," *PYTHAGORAS*, vol. 5, pp. 73–82, 2009.

- [15] C. S. W. Widayati, "KOMPARASI BEBERAPA METODE ESTIMASI KESALAHAN PENGUKURAN," *J. Penelit. dan Eval. Pendidik.*, pp. 182–197, 2009.