Pengaruh Tingkat Minat Penelusuran Antar Penyedia Transportasi Online di Google Trends

(The Effect of Search Interest Rates Between Online Transportation Providers on Google Trends)

Vania Orva Nur L¹, Paramita Dewanti^{2*}

²Badan Pusat Statistik Kabupaten Malang

e-mail: vaniaorva@gmail.com¹, pdewanti@bps.go.id^{2*}

Email: pdewanti@bps.go.id

ABSTRAK

Transportasi *online* adalah transportasi umum yang penggunaannya menggunakan aplikasi berbasis android dengan tujuan yang lebih efisien dalam hal waktu tempuh dan tarif yang jauh lebih murah. Transportasi *online* mempunyai banyak kelebihan dibandingkan dengan transportasi konvensional. Tarif yang jauh lebih murah menjadi alasan utama jenis transportasi ini banyak diminati. Hingga saat ini, transportasi *online* mengalami kemajuan yang sangat pesat di Indonesia. Hampir di semua tempat, transportasi *online* tersebut dapat dengan mudah ditemui dan juga siap digunakan dengan cara menggunakan aplikasi berbasis android agar bisa menikmati pelayanan transportasi tersebut. Sejak diakuisisinya Uber oleh Grab sejak awal tahun 2018, hanya ada dua penyedia jasa transportasi *online* yang merajai pasar di Indonesia yaitu Gojek dan Grab. Keduanya saling bersaing untuk menjaring banyak konsumen dengan mengeluarkan banyak promo kepada para penggunanya. Guna melihat pengaruh tingkat minat penelusuran "Grab" terhadap pengaruh tingkat minat penelusuran "Gojek" di *Google Trends* maka dipergunakanlah model Fungsi Transfer. Model fungsi transfer merupakan salah satu model time series yaitu gabungan pendekatan regresi dan ARIMA pada Analisis Deret Waktu (ADW). Berdasarkan model fungsi transfer dapat diketahui jika tingkat minat penelusuran "Grab" dan "Gojek" di *Google Trends* tidak saling mempengaruhi satu dengan lainnya.

Kata kunci: *Grab, Gojek, Fungsi Transfer, Google Trends*

ABSTRACT

Online transportation is public transportation that uses an Android-based application with the aim of being more efficient in terms of travel time and far cheaper rates. Online transportation has many advantages compared to conventional transportation. Far cheaper fares are the main reason this type of transportation is in great demand. Until now, online transportation has progressed very rapidly in Indonesia. In almost all places, online transportation can be easily found and is also ready to be used by means of an Android-based application in order to enjoy the transportation service. Since the acquisition of Uber by Grab since early 2018, there are only two online transportation service providers that dominate the market in Indonesia, namely Gojek and Grab. Both of them compete with each other to attract many consumers by issuing many promos to their users. In order to see the effect of "Grab" search interest on the influence of "Gojek" search interest on Google Trends, the Transfer Function model is used. The transfer function model is one of the time series models, which is a combination of the regression approach and ARIMA in Time Series Analysis (ADW). Based on the transfer function model, it can be seen if the level of interest in "Grab" and "Gojek" searches on Google Trends does not affect each other.

Keywords: *Grab, Gojek, Fungsi Transfer, Google Trends*

PENDAHULUAN

Dalam kurun waktu beberapa tahun ini, diferensiasi transportasi darat tidak lagi berputar pada jenisnya saja. Muncul istilah baru dalam masyarakat dimana saat ini, transportasi darat terbagi menjadi dua, yang itu transportasi *online* dan transportasi konvensional. Transportasi *online* adalah merupakan jenis moda transportasi umum yang lebih efisien dalam hal waktu tempuh dan sebaliknya dalam hal biaya perjalanan [1]. Transportasi *online* memiliki banyak keunggulan dibandingkan dengan transportasi konvensional. Salah satunya adalah biaya perjalanan yang lebih murah dibandingkan dengan transportasi konvensional.

Sejarah transportasi *online* di Indonesia di mulai dengan kemunculan Gojek pada Oktober 2010 dengan penemunya yaitu Nadiem Makarim. Ide sederhananya adalah bagaimana para pengemudi ojek bisa memanfaatkan waktu untuk mendapatkan penumpang sebanyak mungkin. Di awal kemunculannya, Gojek memiliki 20 pengemudi dengan sistem *call centre*. Persaingan antar *start up* penyedia jasa transportasi *online* di Indonesia di mulai sekitar tahun 2014-2015, dimana saat itu Uber dan Grab menjadi kompetitor dari Gojek.

Tepat di tahun tersebut, Gojek mengeluarkan aplikasinya dengan berbasis android sehingga para pelanggan dapat mengakses layanan Go-Jek melalui aplikasi pada ponsel pintar mereka.

Pada awal tahun 2015 itulah dimulailah persaingan antara ketiga penyedia jasa transportasi *online*, Gojek, Grab dan Uber. Tak hanya menyediakan layanan transportasi, di tahun 2015 Gojek mengeluarkan layanan terbaru yaitu Go-Food dimana para pelanggan tidak perlu lagi mengantri di restoran kegemaran mereka. Satu tahun kemudian, Grab dan Uber juga mengeluarkan layanan yang sama dengan Go-Food yaitu Grab Food dan Uber Eats. Ketiadaan regulasi yang mengatur tarif transportasi *online* menjadikan ketiganya melakukan perang tarif yang berdampak dengan semakin tergesernya keberadaan transportasi konvensional.

Sejak diakuisisinya Uber oleh Grab awal tahun 2018, hanya ada dua penyedia jasa transportasi *onlineonline* yang merajai pasar di Indonesia yaitu Gojek dan Grab. Hingga Bulan Maret tahun 2018 Go-Jek menyediakan 19 jenis layanan dengan kekuatan 1 juta mitra pengemudi (angkutan roda dua dan roda empat). Selain itu Go-Jek memiliki 15 juta pengguna aktif per pekan dengan partner 12 bank, 3 jaringan ATM (Alto, Prima, ATM Bersama), dan 125.000 *merchant* serta layanan di 50 kota. Sedangkan Grab memiliki 8 layanan bidang transportasi, antar barang, dan pesan-antar makanan, dengan kekuatan 2 juta mitra pengemudi dalam *platform* (roda dua dan roda empat), menguasai 95 % pangsa pasar *third-party taxi hailing* dan 75 % *private vehicle hailing*, 3,5 juta perjalanan per hari, layanan di 7 negara, 142 kota di Asia Tenggara. Jika dilihat dari nilai valuasinya pada bulan April 2019 Go-Jek ditetapkan menjadi *decacorn* yaitu perusahaan *startup* yang memiliki nilai valuasi lebih dari USD 10 Milyar (Rp 141 Triliun) sekitar 10 kali lipat dari unicorn. Grab sendiri sudah ditetapkan sebagai *decacorn* sejak bulan Maret 2019, dan hingga April 2019 nilai valuasi dari Grab mencapai USD 14 miliar atau setara Rp 198 triliun. Valuasi ini diperoleh dari Grab berdasarkan pendanaan dari *SoftBank Vision Fund* sebesar USD 1,46 miliar atau setara Rp 20 triliun [3].

Kedua penyedia jasa transportasi *online* tersebut saling bersaing untuk memberikan banyak promo kepada para penggunanya. Oleh karena itu, pada kesempatan kali ini peneliti ingin meneliti apakah ada pengaruh tingkat minat penelusuran “Grab” terhadap tingkat minat penelusuran “Gojek” pada data pencarian di *Google Trends* dengan menggunakan metode Fungsi Transfer.

Google Trends merupakan grafik statistik pencarian Web yang menampilkan popularitas topik pencarian pada kurun waktu tertentu. Hasil dapat ditampilkan menurut kota wilayah atau bahasa. Berita-berita terkait topik yang menjadi tren juga ditampilkan di sini. Dengan aplikasi ini, pengguna bisa membandingkan topik-topik favoritnya dengan topik-topik yang diminati di seluruh dunia [4].

Model fungsi transfer merupakan salah satu model time series yaitu gabungan pendekatan regresi dan ARIMA pada Analisis Deret Waktu (ADW). Pada model ARIMA efektif digunakan pada pemodelan deret waktu dan masalah peramalan, dengan asumsi bahwa kondisi data yang dikumpulkan tetap sama namun pada kenyataannya data akan berubah seiring dengan berjalannya waktu. Sehingga model ARIMA dapat dikembangkan dengan memasukkan input tertentu yang mencerminkan perubahan tersebut, yang lebih dikenal dengan metode fungsi transfer [5]. Metode ini merupakan salah satu alternatif untuk menyelesaikan permasalahan jika terdapat lebih dari satu deret berkala di mana keadaan ini dalam ilmu statistik sering disebut *multivariate time series* [8]. Tujuan utama pemodelan fungsi transfer adalah untuk menetapkan model sederhana yang dapat digunakan untuk meramalkan deret output berdasarkan deret input pada masa mendatang. Model fungsi transfer yang dihasilkan diharapkan dapat menjelaskan pengaruh tingkat minat penelusuran “Grab” terhadap tingkat minat penelusuran “Gojek” pada data pencarian di *Google Trends*.

METODE

Data Penelitian

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari *Google Trends* dengan satuan jam, selama rentang waktu 7 hari mulai dari 23 April 2019 pukul 13.00 WIB hingga 30 April 2019 pukul 12.00 WIB. Data tersebut merupakan tingkat minat penelusuran mengenai istilah “Grab” dan “Gojek” di Indonesia berdasarkan poin tertinggi pada diagram untuk wilayah dan waktu tertentu. Nilai 100 menunjukkan istilah berada di puncak popularitas. Nilai 50 menunjukkan istilah dengan popularitas separuhnya. Nilai 0 menunjukkan tidak tersedia cukup data untuk istilah tersebut.

Metode Analisis

Partial Least Squares (PLS), merupakan *Structural Equation Modelling (SEM)* berbasis komponen. Metode ini tidak memerlukan asumsi data memiliki asumsi memiliki skala pengukuran tertentu, distribusi tertentu, dapat digunakan pada sampel kecil serta dapat digunakan untuk mengkonfirmasi suatu teori. Metode

ini juga memiliki keunggulan dibandingkan SEM berbasis kovarian karena dapat menyelesaikan masalah yaitu *inadmissible solution* dan faktor *indeterminacy* (Fornell & B. Dokstein, 1982).

Langkah Analisis

Berikut ini adalah tahapan-tahapan dalam melakukan analisis:

1. Melakukan analisis deskriptif terhadap data
2. Melakukan pemodelan dengan menggunakan fungsi transfer, dengan langkah-langkah:
 - a. Identifikasi deret input
 - b. Menentukan model ARIMA sementara untuk deret input
 - c. Melakukan estimasi parameter
 - d. Melakukan uji signfikansi parameter
 - e. Melakukan uji kesesuaian model menggunakan uji Ljung Box.
 - f. Memilih model ARIMA terbaik untuk deret input
 - g. Prewhitening deret input dan deret output
 - h. Melakukan perhitungan cross correlation function (CCF) dan membentuk plot CCF
 - i. Menentukan orde b, r, s untuk model fungsi transfer berdasarkan plot CCF.
 - j. Menetapkan model ARIMA untuk deret noise
 - k. Membentuk model fungsi transfer
 - l. Memilih model fungsi transfer terbaik
3. Apabila model fungsi transfer yang dilakukan tidak memberikan hasil yang baik, dalam artian variabel input tidak mempengaruhi variabel output, maka dilakukan pemodelan univariat dengan prosedur ARIMA
4. Menarik kesimpulan dan saran.

HASIL DAN PEMBAHASAN

Deskripsi Data Gojek dan Grab dari Google Trends

Pada analisis ini akan dilakukan pemodelan fungsi transfer dengan tingkat minat penelusuran istilah “Grab” sebagai deret input dan tingkat minat penelusuran istilah “Gojek” sebagai deret ouput, serta sebaliknya. Sehingga akan dihasilkan dua model fungsi transfer. Sebelumnya akan dilihat time series plot dari tingkat minat penelusuran istilah “Grab” dan “Gojek” yang disajikan dalam Gambar 1 berikut ini

Gambar 1. Time Series Plot Tingkat Minat penelusuran “Gojek” dan “Grab”

Gambar 1 menunjukkan pola data tingkat minat penelusuran “Gojek” dan “Grab di Indonesia. Dari gambar tersebut dapat diketahui bahwa tingkat minat penelusuran “Grab” lebih tinggi dibandingkan tingkat minat penelusuran “Gojek”. Serta, dari pola tersebut diindikasikan kedua variabel memiliki efek seasonal karena memiliki pola naik turun pada lag-lag tertentu

Pemodelan Fungsi Transfer dengan “Gojek” sebagai Deret Input

Pada pemodelan ini ditentukan bahwa tingkat minat penelusuran istilah “Gojek” sebagai deret *input*, dan tingkat minat penelusuran istilah “Grab” sebagai deret *output*. Artinya, dalam pemodelan ini dianggap bahwa tingkat minat penelusuran istilah “Gojek” mempengaruhi tingkat minat penelusuran istilah “Grab”

Tahapan pertama dari pemodelan ini adalah *Prewhitening* deret *input*. Dalam tahap ini dilakukan identifikasi model ARIMA untuk deret *input*, dan penentuan model ARIMA deret *input* untuk sementara.

Identifikasi awal dilakukan secara visual dengan melihat plot ACF dan PACF untuk deret *input* yaitu tingkat minat penelusuran istilah “Gojek”, yang dapat dilihat pada Gambar 2

Gambar 2. Plot ACF Deret *Input* (Tingkat Minat Penelusuran “Gojek”)

Gambar 3. Plot PACF Deret *Input* (Tingkat Minat Penelusuran “Gojek”)

Gambar 2 dan Gambar 3 diatas menunjukkan plot ACF dan PACF dari deret *input*, pada plot ACF memiliki pola yang turun lambat atau *dies down* yang mengindikasikan bahwa data memiliki efek *seasonal*. Pada pola plot PACF juga mengindikasikan memiliki efek *seasonal*. Dilakukan tahap identifikasi selanjutnya yaitu *differencing* hingga didapatkan model ARIMA sementara untuk deret *input* adalah ARIMA (0,1,1)(0,1,1)²⁴ dengan hasil estimasi parameter yang telah signifikan dapat dilihat pada tabel berikut ini

Tabel 1. Hasil Estimasi Parameter Model Deret *Input* (Grab)

<i>Parameter</i>	<i>Estimate</i>	<i>Standard Error</i>	<i>t Value</i>	<i>Approx Pr > t </i>	<i>Lag</i>
MA1,1	0.66821	0.06298	10.61	<.0001	1
MA2,1	0.64844	0.06922	9.37	<.0001	24

Tabel 1 menunjukkan bahwa kedua parameter telah signifikan dengan tingkat kepercayaan 95%, karena kedua parameter tersebut memiliki *Pvalue* kurang dari 0.05. Selanjutnya dilakukan uji *Ljung Box* untuk mengetahui apakah model tersebut telah *white noise*. Berikut ini adalah hasil uji *Ljung Box* yang sudah memenuhi asumsi *white noise* yang disajikan dalam Tabel 2 berikut ini:

Tabel 2. Hasil Uji White Noise Model Deret *Input* (Gojek)

<i>To Lag</i>	<i>Chi-Square</i>	<i>DF</i>	<i>Pr > ChiSq</i>
6	2.86	4	0.5816
12	10.99	10	0.3587
18	19.68	16	0.2350
24	23.99	22	0.3478

Berdasarkan tabel 2, model ARIMA terbaik untuk deret *Input* (tingkat minat penelusuran istilah “Gojek”) adalah ARIMA (0,1,1)(0,1,1)²⁴ karena parameternya telah signifikan dan telah memenuhi asumsi *white noise*. Tahapan selanjutnya adalah *prewhitening* deret *input* dan deret *output*. Tahap ini dilakukan dengan mengkonversikan deret x_t menjadi deret a_t .

$$\alpha_t = \frac{1}{(1-\theta_1 B)(1-\Theta_1 B^{24})} x_t = \frac{1}{(1-\theta_1 B - \Theta_1 B^{24} + \theta_1 \Theta_1 B^{25})} x_t \dots\dots\dots (1)$$

$$= \frac{1}{1-0.668B-0.648B^{24}+0.433B^{25}} x_t$$

Serta didapatkan *prewhitening* deret *output* menggunakan model deret *input* ARIMA (0,1,1)(0,1,1)²⁴, sehingga didapatkan *prewhitening* deret *output* menjadi :

$$\beta_t = \frac{1}{(1-\theta_1 B)(1-\Theta_1 B^{24})} y_t = \frac{1}{(1-\theta_1 B - \Theta_1 B^{24} + \theta_1 \Theta_1 B^{25})} y_t \dots\dots\dots (2)$$

$$= \frac{1}{1-0.668B-0.648B^{24}+0.433B^{25}} y_t$$

Setelah didapatkan model *prewhitening* deret *input* dan deret *output*, selanjutnya dilakukan perhitungan korelasi silang atau *Cross Correlation Function* (CCF). Didapatkan hasil plot CCF sebagai berikut:

Gambar 4. Plot CCF antara α_t dan β_t (Deret Input : “Gojek”)

Gambar 4 menunjukkan plot CCF antara α_t dan β_t yang digunakan untuk menentukan orde b , r , dan s dalam model fungsi transfer. Dari plot diatas dapat dilihat bahwa hanya terdapat satu *lag* yang keluar batas setelah *lag* 0, dan jaraknya cukup jauh dengan *lag* 0, sehingga ditentukan orde $b=0$, $r=0$, $s=0$. Hal ini menunjukkan bahwa deret input yaitu tingkat minat penelusuran istilah “Gojek” tidak akan mempengaruhi tingkat minat penelusuran istilah “Grab”.

Pemodelan Fungsi Tranfer dengan “Grab” sebagai Deret Input

Pada pemodelan ini ditentukan bahwa tingkat minat penelusuran istilah “Grab” sebagai deret *input*, dan tingkat minat penelusuran istilah “Gojek” sebagai deret *output*. Artinya, dalam pemodelan ini dianggap bahwa Tingkat minat penelusuran istilah “Grab” mempengaruhi tingkat minat penelusuran istilah “Gojek”. Berikut ini merupakan tahapan-tahapan dalam pemodelan fungsi transfer.

Tahapan pertama dari pemodelan ini adalah *Prewhitening* deret *input*. Dalam tahap ini dilakukan identifikasi model ARIMA untuk deret input, dan penentuan model ARIMA deret *input* untuk sementara. Langkah awal yaitu melihat pola plot ACF dan PACF untuk tingkat minat penelusuran istilah “Grab”, yang dapat dilihat pada gambar berikut ini. Gambar 5 dan 6 menunjukkan plot ACF dan PACF dari deret *input* (tingkat minat penelusuran istilah “Grab”), pada plot ACF memiliki pola yang turun lambat atau *dies down* yang mengindikasikan bahwa data memiliki efek *seasonal*. Pada pola plot PACF juga mengindikasikan memiliki efek *seasonal* karena terdapat beberapa *lag* yang keluar dari batas.

Gambar 5. Plot ACF Deret *Input* (Tingkat Minat penelusuran “Grab”)

Gambar 6. Plot PACF Deret Input (Tingkat Minat penelusuran “Grab”)

Selanjutnya dilakukan tahap identifikasi selanjutnya yaitu *differencing* hingga didapatkan model ARIMA sementara untuk deret *input* adalah ARIMA (0,1,1)(0,1,1)²⁴ dengan hasil estimasi parameter yang telah signifikan dapat dilihat pada tabel berikut ini:

Tabel 3. Hasil Estimasi Parameter Model Deret *Input* (Grab)

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.50842	0.07320	6.95	<.0001	1
MA2,1	0.57696	0.08414	6.86	<.0001	24

Tabel 3 menunjukkan bahwa kedua parameter telah signifikan dengan tingkat kepercayaan 95%, karena kedua parameter tersebut memiliki *Pvalue* kurang dari 0.05. Selanjutnya dilakukan uji *Ljung Box* untuk mengetahui apakah model tersebut telah *white noise*. Berikut ini adalah hasil uji *Ljung Box* yang sudah memenuhi asumsi *white noise* yang disajikan dalam Tabel 4.

Tabel 4. Hasil Uji *White Noise* Model Deret *Input* (Grab)

To Lag	Chi-Square	DF	Pr > ChiSq
6	4.65	4	0.3253
12	8.93	10	0.5392
18	16.55	16	0.4153
24	19.69	22	0.6026

Berdasarkan Tabel 4, model ARIMA terbaik untuk deret *Input* (tingkat minat penelusuran istilah “Grab”) adalah ARIMA (0,1,1)(0,1,1)²⁴ karena parameternya telah signifikan dan telah memenuhi asumsi *white noise*.

Tahapan selanjutnya adalah *prewhitening* deret *input* dan deret *output*. Tahap ini dilakukan dengan mengkonversikan deret x_t menjadi deret α_t .

$$\alpha_t = \frac{1}{(1-\theta_1 B)(1-\Theta_1 B^{24})} x_t = \frac{1}{(1-\theta_1 B - \Theta_1 B^{24} + \theta_1 \Theta_1 B^{25})} x_t \dots\dots\dots(4)$$

$$= \frac{1}{1-0.508B - 0.577B^{24} + 0.293B^{25}} x_t$$

Serta didapatkan *prewhitening* deret *output* menggunakan model deret *input* ARIMA (0,1,1)(0,1,1)²⁴, sehingga didapatkan *prewhitening* deret *output* menjadi

$$\beta_t = \frac{1}{(1-\theta_1 B)(1-\Theta_1 B^{24})} y_t = \frac{1}{(1-\theta_1 B - \Theta_1 B^{24} + \theta_1 \Theta_1 B^{25})} y_t \dots\dots\dots(5)$$

$$= \frac{1}{1-0.508B - 0.577B^{24} + 0.293B^{25}} y_t$$

Setelah didapatkan model *prewhitening* deret *input* dan deret *output*, selanjutnya dilakukan perhitungan korelasi silang atau *Cross Correlation Function* (CCF). Didapatkan hasil plot CCF seperti pada Gambar 7.

Gambar 7 menunjukkan plot CCF antara α_t dan β_t yang digunakan untuk menentukan orde b , r , dan s dalam model fungsi transfer. Dari plot diatas dapat dilihat bahwa hanya terdapat satu *lag* yang keluar batas setelah *lag* 0, dan jaraknya cukup jauh dengan *lag* 0, sehingga ditentukan orde $b=0$, $r=0$, $s=0$. Hal ini menunjukkan bahwa deret input yaitu tingkat minat penelusuran istilah “Grab” tidak akan mempengaruhi tingkat minat penelusuran istilah “Gojek”.

Gambar 7. Plot CCF antara α_t dan β_t (Deret Input : “Grab”)

Pemodelan ARIMA untuk Data Minat Penelusuran Istilah “Gojek” dan “Grab”

Hasil analisis dari kedua fungsi transfer menunjukkan bahwa tidak terdapat hubungan ataupun pengaruh minat penelusuran istilah “Grab” terhadap minat penelusuran istilah “Gojek” ataupun sebaliknya. Sehingga untuk memodelkan minat penelusuran istilah “Grab” dan “Gojek” dilakukan pemodelan ARIMA terhadap masing-masing data. Sebelum melakukan pemodelan, dilakukan pembagian data *training* yaitu selama 6 hari mulai 23 April 2019 pukul 13.00 WIB hingga 29 April 2019 pukul 12.00 WIB sebanyak 144 waktu dan data *testing* yaitu selama 1 hari pada tanggal 29 April 2019 pukul 13.00 WIB hingga 30 April 2019 pukul 12.00 sebanyak 24 waktu.

1. Pemodelan ARIMA untuk Data Minat Penelusuran Istilah “Gojek”

Sebelum melakukan pemodelan dengan ARIMA, perlu dilakukan pengujian asumsi yang harus dipenuhi yaitu uji stasioneritas pada data *training*. Untuk mengetahui stasioner data *training* maka dapat dilakukan dengan melihat plot ACF. Gambar 7 berikut merupakan plot ACF dan PACF untuk data *training*.

Gambar 7. Plot ACF dan PACF Data Training Minat Penelusuran Istilah “Gojek”

Secara visual berdasarkan Gambar 7 dapat diketahui bahwa plot ACF menunjukkan pola sinus atau bergelombang dan cenderung tinggi pada kelipatan 24, sehingga dapat diindikasikan bahwa data tingkat minat penelusuran istilah “Gojek” belum stasioner. Untuk mengetahui stasioner secara pengujian dapat dilakukan dengan menggunakan uji *Augmented Dickey Fuller* (ADF Test) dengan hasil ditampilkan pada Tabel 5 berikut.

Tabel 5. Hasil ADF Test untuk Data Training Minat Penelusuran Istilah “Gojek”

Dickey Fuller	P-value
-1,2605	0,8843

Berdasarkan pengujian stasioneritas data dengan ADF test maka dapat disimpulkan bahwa data belum stasioner karena hasil p-value lebih besar dari $\alpha = 5\%$. Selanjutnya dilakukan *differencing* terhadap data *training* yaitu dengan *differencing* musiman 24. Hal ini dikarenakan pada pola ACF data *training* menunjukkan nilai yang cukup tinggi pada kelipatan data ke-24. Kemudian dilakukan visualisasi terhadap ACF dan PACF data *differencing* musiman 24 dari data *training* yang ditampilkan pada Gambar 8.

Ditinjau dari pola ACF pada Gambar 8 maka dapat diketahui bahwa penurunan nilai ACF masih cenderung lambat sehingga diindikasikan belum stasioner. Seperti pada penjelasan sebelumnya, perlu dilakukan pengujian stasioneritas data dengan menggunakan ADF test dengan hasil ditampilkan pada Tabel 6.

Gambar 8. Plot ACF dan PACF Data Training Minat Penelusuran Istilah “Gojek” Hasil *Differencing* 24

Tabel 6. Hasil ADF *Test* untuk Data *Training* Minat Penelusuran Istilah “Gojek” Hasil *Diferencing* 24

<i>Dickey Fuller</i>	<i>P-value</i>
-0,56581	0,9775

Berdasarkan pengujian stasioneritas data dengan ADF *test* sesuai dengan Tabel 6 maka dapat disimpulkan bahwa data hasil *differencing* 24 juga masih belum stasioner karena hasil *p-value* yang lebih besar dari $\alpha = 5\%$. Selanjutnya dapat dilakukan *differencing* kembali dengan *differencing* non musiman yaitu lag 1. Hasil dari data *training* yang telah dilakukan *differencing* 24 dan 1 memberikan visualisasi ACF dan PACF sebagai berikut.

Gambar 9. Plot ACF dan PACF Data Training Minat Penelusuran Istilah “Gojek” Hasil *Differencing* 24 dan 1

Berdasarkan pada Gambar 9 maka dapat diketahui bahwa pada ACF maupun PACF telah *cut off* pada beberapa lag. Hasil ADF *test* untuk mengetahui stasioneritas data hasil *differencing* 24 dan 1 diberikan pada Tabel 7 berikut.

Tabel 7. Hasil ADF *Test* untuk Data *Training* Minat Penelusuran Istilah “Gojek” Hasil *Diferencing* 24 dan 1

<i>Dickey Fuller</i>	<i>P-value</i>
-7,4138	< 0,01

Hasil pengujian ADF pada data *training* hasil *differencing* 24 dan 1 sesuai Tabel 7, maka dapat disimpulkan bahwa data hasil *differencing* 24 dan 1 telah stasioner karena hasil *p-value* sangat kecil dan kurang dari $\alpha = 5\%$. Sehingga selanjutnya dapat dilakukan pemodelan dengan menggunakan ARIMA. Dengan mengacu pada ACF dan PACF pada Gambar 4 dapat diketahui bahwa model yang memungkinkan adalah ARIMA(0,1,1)(0,1,1)²⁴. Tabel 8 berikut ini merupakan estimasi parameter dari model dugaan yaitu ARIMA(0,1,1)(0,1,1)²⁴.

Tabel 8. Estimasi Parameter ARIMA untuk Training Minat Penelusuran Istilah “Gojek”

Koefisien	Estimasi	SE	<i>z-value</i>	<i>p-value</i>
θ_1	-0,6626	0,062	-10,73	<0,001
Θ_1	-0,8298	0,2413	-3,44	<0,001

Model ARIMA yang diduga telah menunjukkan signifikansi parameter, baik pada MA reguler maupun musiman 24. Sehingga dapat dituliskan model ARIMA untuk data tingkat minat penelusuran istilah “Gojek”.

$$Y_t = a_t + 0,6626a_{t-1} + 0,8298a_{t-24} + 0,549825a_{t-25} \dots\dots\dots(6)$$

Selanjutnya dilakukan pengujian pada *Ljung Box* untuk mengetahui apakah residual model dugaan telah *white noise*. Hasil uji *Ljung Box* diberikan pada Tabel 9 berikut:

Tabel 9. Hasil Pengujian *Ljung Box* untuk Residual Model ARIMA Data Minat Penelusuran Istilah “Gojek”

Lag	12	24	36	48
Chi-Square	13,89	28,05	45,31	58,02
P-Value	0,18	0,17	0,09	0,11

Berdasarkan uji *Ljung Box* diketahui bahwa model dugaan ARIMA untuk memodelkan data *training* tingkat minat penelusuran istilah “Gojek” telah memenuhi asumsi *white noise*. Selanjutnya untuk mengetahui asumsi distribusi normal pada residual model dilakukan pengujian dengan *Kolmogorov Smirnov* sebagai berikut.

Tabel 10. Hasil Pengujian Kolmogorov Smirnov untuk Residual ARIMA Data Minat Penelusuran Istilah “Gojek”

Nilai KS	P-value
0,13746	0,008663

Sesuai dengan pengujian *Kolmogorov Smirnov* pada residual model ARIMA yang ditampilkan pada Tabel 10 dapat diketahui bahwa *p-value* memiliki nilai sebesar 0,008663 dimana nilai tersebut lebih kecil dari pada $\alpha_{0,05}$ maka dapat disimpulkan bahwa residual tidak mengikuti sebaran distribusi normal. Berikut ini perbandingan data *training* dengan *fits* model dan data *testing* dengan prediksi.

Gambar 10. Plot Data *Training* dan *Fits* serta Data *Testing* dengan Ramalan pada Model ARIMA Data Minat Penelusuran Istilah “Gojek”

Time series plot yang ditampilkan pada Gambar 10 menunjukkan pola *fits* model yang telah mengikuti pola data *training*. Begitupula dengan hasil ramalan yang telah mengikuti pola data *testing*. Untuk mengetahui kebaikan model ARIMA yang digunakan maka dapat diketahui melalui nilai RMSE dan MAPE yang ditampilkan pada Tabel 11 berikut.

Tabel 11. Kebaikan Model ARIMA dalam Memodelkan Data Minat Penelusuran Istilah “Gojek”

Training		Testing	
RMSE	MAPE	RMSE	MAPE
2,36	3,99	4,70	10,02

Nilai RMSE maupun nilai MAPE baik pada data *training* maupun data *testing* menunjukkan nilai yang cukup kecil sehingga model ARIMA yang digunakan sudah cukup baik untuk memodelkan data minat penelusuran istilah “Gojek” di *Google Trends*.

2. Pemodelan ARIMA untuk Data Minat Penelusuran Istilah “Grab”

Langkah analisis yang digunakan sama dengan pemodelan data minat penelusuran istilah “Gojek” pada subbab sebelumnya. Sebelum melakukan pemodelan dengan ARIMA, perlu dilakukan pengujian asumsi yang harus dipenuhi yaitu uji stasioneritas pada data *training*. Untuk mengetahui stasioner data *training* maka dapat dilakukan dengan melihat plot ACF. Gambar 11 berikut merupakan plot ACF dan PACF untuk data *training*.

Secara visual berdasarkan Gambar 11 dapat diketahui bahwa plot ACF menunjukkan pola sinus atau bergelombang dan cenderung tinggi pada kelipatan 24, sehingga dapat diindikasikan bahwa data tingkat minat penelusuran istilah “Grab” belum stasioner. Untuk mengetahui stasioner secara pengujian dapat dilakukan dengan menggunakan uji *Augmented Dickey Fuller* (ADF Test) dengan hasil ditampilkan pada Tabel 12 berikut.

Gambar 11. Plot ACF dan PACF Data Training Minat Penelusuran Istilah “Grab”

Tabel 12. Hasil ADF Test untuk Data Training Minat Penelusuran Istilah “Grab”

Dickey Fuller	P-value
-0,5321	0,9792

Berdasarkan pengujian stasioneritas data dengan ADF test maka dapat disimpulkan bahwa data belum stasioner karena hasil p -value lebih besar dari $\alpha = 5\%$. Selanjutnya dilakukan *differencing* terhadap data *training* yaitu dengan *differencing* musiman 24. Hal ini dikarenakan pada pola ACF data *training* menunjukkan nilai yang cukup tinggi pada kelipatan data ke-24. Kemudian dilakukan visualisasi terhadap ACF dan PACF data *differencing* musiman 24 dari data *training* yang ditampilkan pada Gambar 12.

Gambar 12. Plot ACF dan PACF Data Training Minat Penelusuran Istilah “Grab” Hasil *Differencing* 24

Ditinjau dari pola ACF pada Gambar 12 maka dapat diketahui bahwa penurunan nilai ACF masih cenderung lambat sehingga diindikasikan belum stasioner. Seperti pada penjelasan sebelumnya, perlu dilakukan pengujian stasioneritas data dengan menggunakan ADF test dengan hasil ditampilkan pada Tabel 13.

Tabel 13. Hasil ADF Test untuk Data Training Minat Penelusuran Istilah “Grab” Hasil *Differencing* 24

Dickey Fuller	P-value
-3,0898	0,1239

Berdasarkan pengujian stasioneritas data dengan ADF test sesuai dengan Tabel 13 maka dapat disimpulkan bahwa data hasil *differencing* 24 juga masih belum stasioner karena hasil p -value yang lebih besar dari $\alpha = 5\%$. Selanjutnya dapat dilakukan *differencing* kembali dengan *differencing* non musiman yaitu lag 1. Hasil dari data *training* yang telah dilakukan *differencing* 24 dan 1 memberikan visualisasi ACF dan PACF sebagai berikut.

Gambar 13. Plot ACF dan PACF Data Training Minat Penelusuran Istilah “Grab” Hasil *Differencing* 24 dan 1

Berdasarkan pada Gambar 13 maka dapat diketahui bahwa pada ACF maupun PACF telah *cut off* pada beberapa lag. Hasil ADF test untuk mengetahui stasioneritas data hasil *differencing* 24 dan 1 diberikan pada Tabel 14 berikut.

Tabel 14. Hasil ADF Test untuk Data *Training* Minat Penelusuran Istilah “Grab” Hasil *Differencing* 24 dan 1

Dickey Fuller	P-value
-5,4459	< 0,01

Hasil pengujian ADF pada data *training* hasil *differencing* 24 dan 1 sesuai Tabel 7, maka dapat disimpulkan bahwa data hasil *differencing* 24 dan 1 telah stasioner karena hasil *p-value* sangat kecil dan kurang dari dari $\alpha = 5\%$. Sehingga selanjutnya dapat dilakukan pemodelan dengan menggunakan ARIMA. Dengan mengacu pada ACF dan PACF pada Gambar 4 dapat diketahui bahwa model yang memungkinkan adalah ARIMA(0,1,1)(0,1,1)²⁴. Tabel 8 berikut ini merupakan estimasi parameter dari model dugaan yaitu ARIMA(0,1,1)(0,1,1)²⁴.

Tabel 15. Estimasi Parameter ARIMA untuk *Training* Minat Penelusuran Istilah “Grab”

Koefisien	Estimasi	SE	z-value	p-value
θ_1	-0,37193	0,10704	-3,4746	<0,001
Θ_1	-0,83339	0,26554	-3,1384	<0,001

Model ARIMA yang diduga telah menunjukkan signifikansi parameter, baik pada MA reguler maupun musiman 24. Sehingga dapat dituliskan model ARIMA untuk data tingkat minat penelusuran istilah “Grab”.

$$Y_t = a_t + 0,37193a_{t-1} + 0,83339a_{t-24} + 0,309963a_{t-25} \dots \dots \dots (7)$$

Selanjutnya dilakukan pengujian pada *Ljung Box* untuk mengetahui apakah residual model dugaan telah *white noise*. Hasil uji *Ljung Box* diberikan pada Tabel 16 berikut.

Tabel 16. Hasil Pengujian *Ljung Box* untuk Residual Model ARIMA Data Minat Penelusuran Istilah “Grab”

Lag	12	24	36	48
Chi-Square	13,08	21,28	30,48	35,65
P-Value	0,219	0,503	0,641	0,865

Berdasarkan uji *Ljung Box* diketahui bahwa model dugaan ARIMA untuk memodelkan data *training* tingkat minat penelusuran istilah “Grab” telah memenuhi asumsi *white noise*. Selanjutnya untuk mengetahui asumsi distribusi normal pada residual model dilakukan pengujian dengan *Kolmogorov Smirnov* sebagai berikut.

Tabel 17. Hasil Pengujian *Kolmogorov Smirnov* untuk Residual ARIMA Data Minat Penelusuran Istilah “Grab”

Nilai KS	P-value
0,10484	0,08438

Sesuai dengan pengujian *Kolmogorov Smirnov* pada residual model ARIMA yang ditampilkan pada Tabel 17 dapat diketahui bahwa *p-value* memiliki nilai sebesar 0,08438 dimana nilai tersebut lebih besar dari pada $\alpha_{0,05}$ maka dapat disimpulkan bahwa residual telah mengikuti sebaran distribusi normal. Berikut ini perbandingan data *training* dengan *fits* model dan data *testing* dengan prediksi.

Gambar 14. Plot Data *Training* dan *Fits* serta Data *Testing* dengan Ramalan pada Model ARIMA Data Minat Penelusuran Istilah “Grab”

Time series plot yang ditampilkan pada Gambar 14 menunjukkan pola *fits* model yang telah mengikuti pola data *training*. Begitupula dengan hasil ramalan yang telah mengikuti pola data *testing*. Untuk mengetahui kebaikan model ARIMA yang digunakan maka dapat diketahui melalui nilai RMSE dan MAPE yang ditampilkan pada Tabel 18 berikut.

Tabel 18. Keباian Model ARIMA dalam Memodelkan Data Minat Penelusuran Istilah “Grab”

Training		Testing	
RMSE	MAPE	RMSE	MAPE
3,493	3,947	5,498	6,345

Nilai RMSE maupun nilai MAPE baik pada data *training* maupun data *testing* menunjukkan nilai yang cukup kecil sehingga model ARIMA yang digunakan sudah cukup baik untuk memodelkan data minat penelusuran istilah “Grab” di *Google Trends*.

KESIMPULAN

Kesimpulan yang diperoleh dari hasil analisis dan pembahasan pada penelitian ini, bahwa pada pemodelan pertama dengan tingkat minat penelusuran istilah “Gojek” sebagai deret input diketahui berdasarkan plot CCF tidak menunjukkan tingkat minat penelusuran istilah “Gojek” mempengaruhi tingkat minat penelusuran istilah “Grab”. Pada pemodelan kedua dengan tingkat minat penelusuran istilah “Grab” sebagai deret input diketahui berdasarkan plot CCF tidak menunjukkan tingkat minat penelusuran istilah “Grab” mempengaruhi tingkat minat penelusuran istilah “Gojek”. Maka untuk selanjutnya dilakukan pemodelan secara univariat dengan menggunakan ARIMA pada masing-masing data yang digunakan. Model ARIMA untuk data tingkat minat penelusuran istilah “Gojek” adalah

$$Y_t = a_t + 0,6626a_{t-1} + 0,8298a_{t-24} + 0,549825a_{t-25}$$

Sedangkan untuk model ARIMA untuk data tingkat minat penelusuran istilah “Grab” mengikuti persamaan:

$$Y_t = a_t + 0,37193a_{t-1} + 0,83339a_{t-24} + 0,309963a_{t-25}$$

DAFTAR PUSTAKA

- Bowerman, B.L. and O’Connel. (1993). *Forecasting and Time Series: An Applied Approach 3rd ed*, Belmont, California : Duxbury Press.
- Box, G.E.P., Jenkins, G.M., and Reissel. G.C. (1994). *Time Series Analysis Forecasting and Control, 3rd edition*, Englewood Cliffs : Prentice Hall.
- BPS. 2018. *Statistik Indonesia 2018*. Jakarta: BPS.
- Donnie Pratama. 9 April 2019. <https://selular.id/2019/04/jadi-decacorn-valuasi-Go-Jek-belum-mencapai-usd-10-miliar-kok-bisa/>
- https://id.wikipedia.org/wiki/Google_Trend
- Makridakis, S., Wheelwright, S.C., and McGee, V.E. (1999). Jilid 1 edisi kedua, Terjemahan Ir. Hari Suminto, *Metode dan Aplikasi Peramalan*, Jakarta, Bina Rupa Aksara.
- McSweeney, A.J. (1978). “The Effects of Response Cost on the Behavior of a Million Persons: Charging for Directory Assistance in Cincinnati.” *Journal of Applied Behavioral Analysis* 11, 47-51.
- Montgomery, D.C., Jennings, C. L., Kulahci, M. 2008. *Introduction to Time Series Analysis And Forecasting*. New Jersey: A John Wiley & Sons, Inc.
- Safrimo, Aprima. 2017. *Efisiensi Dan Dampak Ojek Online Terhadap Kesempatan Kerja Dan Kesejahteraan*. Skripsi
- Wei, W.W.S. (1996). *Time Series Analysis Univariate and Multivariate Method, 2nd edition*. Pearson Addison Welsey. USA