

METODE *STATE SPACE* DALAM MERAMALKAN JUMLAH PENUMPANG KERETA API DI PULAU JAWA

Fitri Ananda Dita Saraswita^{1§}, I Wayan Sumarjaya², Luh Putu Ida Harini³

¹Program Studi Matematika, Fakultas MIPA – Universitas Udayana [Email: fitri.ananda53@gmail.com]

²Program Studi Matematika, Fakultas MIPA – Universitas Udayana [Email: sumarjaya@unud.ac.id]

³Program Studi Matematika, Fakultas MIPA – Universitas Udayana [Email: ballidah@gmail.com]

[§]Corresponding Author

ABSTRACT

State space is an approach to model and predict together several time series data that are interconnected, and these variables have dynamic interactions. The purpose of this research is to model the number of train passengers in Java and find out the forecasting results using the state space method. The algorithm used to solve the state space model is the Kalman filter. In this research, a suitable final model is local level model with seasonal and produces MAPE value of 2%, this shows that the state space method is very accurately.

Keywords: train passengers, forecasting, state space, Kalman filter.

1. PENDAHULUAN

Pada era globalisasi, perkembangan dalam bidang transportasi sangat pesat. Transportasi merupakan salah satu sarana yang penting bagi penduduk untuk melakukan aktivitasnya. Salah satu transportasi darat yang sangat diperlukan masyarakat yaitu kereta api. Keunggulan kereta api dibanding alat transportasi umum lainnya yaitu lebih ramah biaya, lebih nyaman, dan tidak macet. Oleh karena itu, kereta api merupakan alat transportasi antarkota yang diminati oleh seluruh lapisan masyarakat, baik kelas menengah ke atas maupun ke bawah.

Data pada Badan Pusat Statistik (2019) menunjukkan jumlah penumpang kereta api di Indonesia, khususnya di Pulau Jawa pada tahun 2006 sampai tahun 2018, sangat bervariasi dan tidak stabil setiap bulannya. Oleh karena itu, peramalan tentang jumlah penumpang kereta api sangat diperlukan oleh perusahaan untuk mengetahui prediksi jumlah penumpang kereta api pada periode berikutnya.

Peramalan merupakan perhitungan objektif yang menggunakan data-data masa lalu, untuk menentukan sesuatu pada masa yang akan datang (Sumayang, 2003:24). Data deret waktu adalah sekumpulan data hasil dari pengamatan historis yang menggambarkan secara kronologis suatu karakteristik populasi di mana kaitan variabel waktu dengan pengamatan

diperhatikan, sehingga data dianggap sebagai fungsi atas waktu (Gujarati, 2004:25). Sedangkan deret waktu adalah deretan data atau amatan yang terurut berdasarkan waktu tertentu, dengan ketentuan memiliki selang waktu yang sama (Wei, 2006:1).

Salah satu metode yang dapat digunakan dalam peramalan adalah metode *state space*. *State space* adalah pendekatan untuk memodelkan dan memprediksi secara bersama beberapa data deret waktu yang saling berhubungan, serta peubah-peubah tersebut memiliki interaksi yang dinamis. Model *state space* menggambarkan data deret waktu melalui variabel keadaan (*state vector*). *State vector* berisi ringkasan semua informasi dari nilai sebelumnya dan nilai sekarang dari suatu deret waktu yang sesuai dengan prediksi nilai yang akan datang (SAS Institute Inc, 2014).

Algoritme yang dapat digunakan untuk menyelesaikan model *state space* adalah Kalman filter. Adapun konsep Kalman filter terdiri dari dua tahapan yaitu tahap peramalan dan tahap pembaharuan (Welch & Bishop, 2006). Pada tahap peramalan dihasilkan nilai estimasi untuk keadaan (*state*) pada waktu sekarang dan nilai kovarians galat yang digunakan sebagai informasi estimasi awal untuk langkah selanjutnya. Sedangkan pada

tahap pembaharuan berfungsi sebagai pengoreksi. Pada tahap ini akan dihasilkan pengukuran baru yang diperoleh dari nilai estimasi awal. Setelah kedua tahap terpenuhi, proses tersebut akan berulang kembali dengan nilai estimasi yang diperoleh dari tahap pengukuran digunakan sebagai informasi awal tahap peramalan yang kedua, begitu seterusnya hingga diperoleh nilai yang konvergen.

Penelitian mengenai *state space* dilakukan oleh Saputra (2018) yang meramalkan ekspor batubara dan minyak bumi. Penelitian tersebut memperlihatkan aplikasi model *state space* cukup baik berdasarkan plot yang dihasilkan dengan nilai MAPE untuk batubara sebesar 3,21% dan untuk minyak bumi sebesar 6,09%. Sedangkan penelitian mengenai jumlah penumpang kereta api di Pulau Jawa dilakukan oleh Arianto (2017) yang meramalkan jumlah penumpang kereta api di Jawa pada periode Februari 2017 sampai Januari 2018 dengan menggunakan metode ARIMA, penelitian tersebut memperlihatkan model yang diperoleh yaitu ARIMA ([12],1,1) dengan jumlah penumpang tertinggi berada pada bulan Desember.

Pada penelitian ini penulis menggunakan metode *state space* untuk memodelkan dan mengetahui hasil peramalan jumlah penumpang kereta api di Pulau Jawa pada periode Februari 2018 sampai Januari 2019.

2. METODE PENELITIAN

2.1 Jenis dan Sumber Data

Jenis data yang digunakan pada penelitian ini adalah data sekunder yaitu data jumlah penumpang kereta api di Pulau Jawa pada Badan Pusat Statistik (BPS). Data ini diambil pada periode Januari 2006 sampai Januari 2018. Berikut merupakan laman resminya <https://www.bps.go.id>.

2.2 Metode Analisis Data

Pada penelitian ini, peneliti meramalkan jumlah penumpang kereta api untuk periode berikutnya menggunakan metode *state space* dengan bantuan *software R*. Adapun langkah-langkah yang dilakukan dalam penelitian ini adalah:

1. Plot data deret waktu
Plot data deret waktu dilakukan guna untuk menunjukkan secara deskriptif gambaran umum mengenai data.
2. Pemodelan *state space*
Pada langkah ini dilakukan pemeriksaan

diagnostik berdasarkan asumsi yang harus dipenuhi, yaitu asumsi kebebasan dengan didiagnosis menggunakan uji Ljung-Box. Hipotesis yang digunakan dalam pengujian asumsi kebebasan yaitu:

$H_0: \rho_1 = \rho_2 = \rho_3 = \dots = 0$ (tidak ada korelasi residual antar *lag*),

H_1 : terdapat paling sedikit satu $\rho_k \neq 0, k = 1, 2, \dots, \ell$ (ada korelasi residual antar *lag*).

Asumsi kenormalan didiagnosis dengan menggunakan uji Shapiro-Wilk. Hipotesis yang digunakan dalam pengujian kenormalan yaitu:

H_0 : data berdistribusi normal,

H_1 : data tidak berdistribusi normal.

Dan asumsi homoskedastisitas dengan cara mengamati plot kuadrat residualnya (Koopman & Commandeur, 2015). Untuk pemodelan *state space* dimulai dari model paling sederhana yaitu *local level model*. Apabila ketiga asumsi tidak terpenuhi maka pemodelan dilanjutkan dengan *local linear trend model*, apabila ketiga asumsi tidak terpenuhi lagi maka pemodelan dilanjutkan ke *local level model with seasonal*.

3. Penerapan algoritme Kalman filter

Tahap 1 : *Initial state*

Dalam tahap ini dimulai dengan mengasumsikan nilai dari rata-rata (a_1) dan varians (P_1) telah diketahui.

Tahap 2 : Tahap peramalan

Dalam tahap ini dilakukan dengan menghitung nilai a_{t+1} dan P_{t+1} .

Tahap 3 : Tahap pembaharuan

Dalam tahap ini dilakukan pembaharuan nilai $a_{t|t}$ dan $P_{t|t}$ hingga diperoleh nilai yang konvergen.

Setelah tahap 1 sampai tahap 3 diperoleh, langkah selanjutnya yaitu menghitung nilai \hat{y}_t berdasarkan model yang diperoleh.

4. Kriteria peramalan

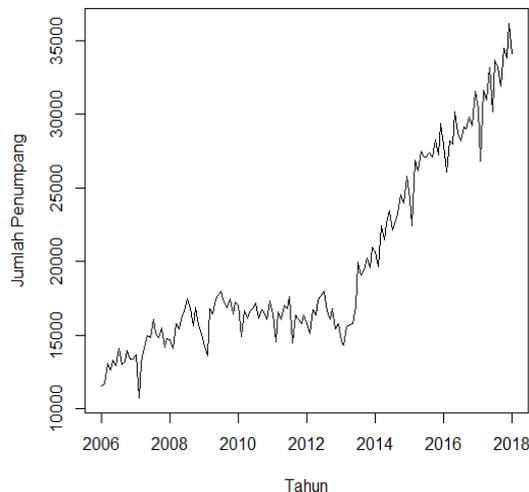
Setelah model diperoleh dan memenuhi asumsi kebebasan, kenormalan, dan homoskedastisitas, maka langkah selanjutnya yaitu menghitung nilai MAPE untuk dapat mengetahui tingkat keakuratan hasil dari peramalan.

3. HASIL DAN PEMBAHASAN

3.1 Analisis Deskriptif

Pada tahap ini terlebih dahulu dilakukan plot data jumlah penumpang kereta api di Pulau

Jawa pada periode Januari 2006 sampai Januari 2018 dengan data sebanyak 145 data. Langkah ini dilakukan untuk menunjukkan secara deskriptif gambaran umum mengenai data. Hasil plot data jumlah penumpang kereta api di Pulau Jawa dapat dilihat pada Gambar 3.1.



Gambar 3.1 Plot Data Jumlah Penumpang Kereta Api di Pulau Jawa

Hasil plot data jumlah penumpang kereta api di Pulau Jawa pada periode Januari 2006 sampai Januari 2018 menunjukkan pola yang berulang, sehingga dapat dikatakan bahwa adanya pola musiman yang memengaruhi pada data.

3.2 Pemodelan State Space

Pada tahap ini dilakukan pemilihan model berdasarkan asumsi yang harus dipenuhi, yaitu asumsi *independence*, *normalitas*, dan *homoscedasticity*. Untuk pemilihan model dimulai dari model yang paling sederhana yaitu *local level model*. Apabila ketiga asumsi tidak terpenuhi maka pemodelan dilanjutkan dengan *local linear trend model*, kemudian apabila ketiga asumsi tidak terpenuhi lagi maka pemodelan dilanjutkan dengan *local level model with seasonal*. Hasil diagnostik ketiga model ditunjukkan dalam Tabel 3.1.

Berdasarkan pada Tabel 3.1 untuk *local level model* menyatakan bahwa *normality test* menghasilkan $p - value = 0,07599 > \alpha = 0,05$. Karena $p - value > \alpha$, maka kriteria keputusannya adalah terima H_0 , yang artinya bahwa *local level model* memiliki sisaan yang berdistribusi normal, sehingga untuk asumsi *normalitas* terpenuhi. Sedangkan *independence*

test menghasilkan $p - value = 2,416 \times 10^{-5} < \alpha = 0,05$. Karena $p - value < \alpha$, maka kriteria keputusannya adalah tolak H_0 , yang artinya bahwa terdapat korelasi residual antar *lag* pada *local level model*, sehingga asumsi *independence* tidak terpenuhi. Karena salah satu asumsi tidak terpenuhi, maka pemodelan dilanjutkan ke *local linear trend model*.

Tabel 3.1. Hasil Uji Normality dan Independence

<i>p - value</i>	<i>Normality test</i>	<i>Independence test</i>
<i>Local Level Model</i>	0,07599	$2,416 \times 10^{-5}$
<i>Local Linear Trend Model</i>	0,1244	$2,056 \times 10^{-8}$
<i>Local Level Model with Seasonal</i>	0,0858	0,5787

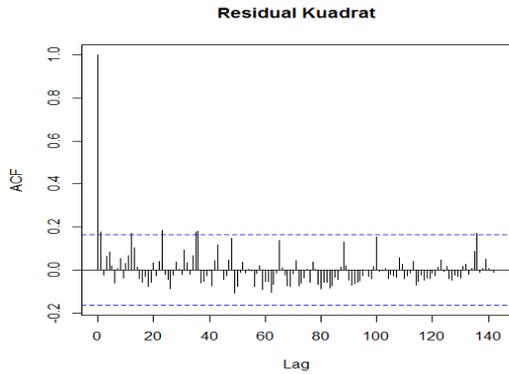
Sumber: Data diolah (2019)

Kemudian untuk *local linear trend model* menyatakan *normality test* menghasilkan $p - value = 0,1244 > \alpha = 0,05$. Oleh karena $p - value > \alpha$, maka kriteria keputusannya adalah terima H_0 , yang artinya bahwa *local linear trend model* memiliki sisaan yang berdistribusi normal, sehingga asumsi *normalitas* terpenuhi. Sedangkan untuk *independence test* menghasilkan $p - value = 2,056 \times 10^{-8} < \alpha = 0,05$. Karena $p - value < \alpha$, maka kriteria keputusannya adalah tolak H_0 , yang artinya bahwa terdapat korelasi residual antar *lag* pada *local linear trend model*, sehingga asumsi *independence* tidak terpenuhi. Karena salah satu asumsi tidak terpenuhi, maka pemodelan di lanjutkan ke *local level model with seasonal*.

Selanjutnya untuk *local level model with seasonal* menyatakan bahwa *normality test* menghasilkan $p - value = 0,0858 > \alpha = 0,05$. Karena $p - value > \alpha$, maka kriteria keputusannya adalah terima H_0 , yang artinya bahwa *local level model with seasonal* memiliki sisaan yang berdistribusi normal, sehingga asumsi *normalitas* terpenuhi. Sedangkan untuk *independence test* menghasilkan $p - value = 0,5787 > \alpha = 0,05$. Karena $p - value > \alpha$, maka kriteria keputusannya adalah terima H_0 , yang artinya bahwa tidak ada korelasi residual antar *lag* pada *local level model with seasonal*, sehingga asumsi *independence* juga terpenuhi.

Lebih lanjut, asumsi *homoscedasticity* dapat dilihat berdasarkan plot kuadrat residual

model data jumlah penumpang kereta api di Pulau Jawa pada Gambar 3.2.



Gambar 3.2 Plot ACF (*Autocorrelation Function*) pada Kuadrat Residual.

Berdasarkan plot ACF pada Gambar 3.2 terlihat bahwa tidak adanya indikasi heteroskedastisitas yang ditunjukkan oleh beberapa *lag* yang keluar dari garis *Bartlett*. Oleh karena itu, dapat dikatakan sisaan pada model data penumpang kereta api bersifat homoskedastisitas.

Karena berdasarkan hasil uji asumsi kenormalan, kebebasan, dan homoskedastisitas yang memenuhi adalah *local level model with seasonal*, sehingga model akhir untuk data jumlah penumpang kereta api di Pulau Jawa yaitu *local level model with seasonal*. Selanjutnya *local level model with seasonal* untuk data bulanan jumlah penumpang kereta api di Pulau Jawa ditulis dengan:

$$\begin{aligned}\hat{Y}_t &= \hat{\mu}_t + \hat{\nu}_{1,t} \\ \hat{\mu}_{t+1} &= \hat{\mu}_t \\ \hat{\gamma}_{1,t+1} &= -\hat{\nu}_{1,t} - \hat{\nu}_{2,t} - \hat{\nu}_{3,t} - \hat{\nu}_{4,t} - \hat{\nu}_{5,t} - \hat{\nu}_{6,t} - \\ &\quad \hat{\nu}_{7,t} - \hat{\nu}_{8,t} - \hat{\nu}_{9,t} - \hat{\nu}_{10,t} - \hat{\nu}_{11,t} \\ \hat{\nu}_{2,t+1} &= \hat{\nu}_{1,t} \\ \hat{\nu}_{3,t+1} &= \hat{\nu}_{2,t} \\ \hat{\nu}_{4,t+1} &= \hat{\nu}_{3,t} \\ \hat{\nu}_{5,t+1} &= \hat{\nu}_{4,t} \\ \hat{\nu}_{6,t+1} &= \hat{\nu}_{5,t} \\ \hat{\nu}_{7,t+1} &= \hat{\nu}_{6,t} \\ \hat{\nu}_{8,t+1} &= \hat{\nu}_{7,t} \\ \hat{\nu}_{9,t+1} &= \hat{\nu}_{8,t} \\ \hat{\nu}_{10,t+1} &= \hat{\nu}_{9,t} \\ \hat{\nu}_{11,t+1} &= \hat{\nu}_{10,t}\end{aligned}$$

untuk $t = 1, \dots, n$; dengan $\mu_1 \sim N(a_1, P_1)$, dimana a_1 dan P_1 diketahui. Nilai $a_1 = 19908,84$ dan $P_1 = 38252647$. Selanjutnya $\hat{\mu}_1 = 34459,16$; $\hat{\nu}_{1,1} = -3095,7827$; $\hat{\nu}_{2,1} = -352,1559$; $\hat{\nu}_{3,1} = 1397,2770$; $\hat{\nu}_{4,1} = -615,2570$; $\hat{\nu}_{5,1} = 761,0342$; $\hat{\nu}_{6,1} = -698,4130$; $\hat{\nu}_{7,1} = 532,3999$;

$$\hat{\nu}_{8,1} = 1032,3000; \hat{\nu}_{9,1} = -844,4664;$$

$$\hat{\nu}_{10,1} = 1651,3231; \hat{\nu}_{11,1} = -431,9723;$$

Karena deret waktu yang diamati merupakan data bulanan pada jumlah penumpang kereta api di Pulau Jawa, sehingga matriks $\alpha_t, R_t, \eta_t, H_t, T_t, Z_t, Q_t$ diperoleh sebagai berikut:

$$Z_t = [1 \ 1 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0],$$

$$H_t = \sigma_\varepsilon^2 = 0,3577659,$$

$$\alpha_t = \begin{bmatrix} \mu_t \\ \gamma_{1,t} \\ \gamma_{2,t} \\ \gamma_{3,t} \\ \gamma_{4,t} \\ \gamma_{5,t} \\ \gamma_{6,t} \\ \gamma_{7,t} \\ \gamma_{8,t} \\ \gamma_{9,t} \\ \gamma_{10,t} \\ \gamma_{11,t} \end{bmatrix}, R_t = \begin{bmatrix} 1 & 0 \\ 0 & 1 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \end{bmatrix}, \eta_t = \begin{bmatrix} \xi_t \\ \omega_t \end{bmatrix},$$

$$T_t = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix},$$

$$Q_t = \begin{bmatrix} 418759 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 51967,81 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix},$$

Nilai σ_ε^2 pada matriks H_t diperoleh dari varians residual pada model data penumpang kereta api (y_t). Nilai σ_ξ^2 pada matriks Q_t diperoleh dari varians residual pada rata-rata (μ_t). Kemudian untuk nilai σ_ω^2 pada matriks Q_t diperoleh dari varians residual pada efek musiman (γ_t).

3.3 Peramalan

Setelah diperoleh model *state space*, tahap berikutnya adalah peramalan dengan menggunakan algoritme Kalman filter. Berikut hasil peramalan jumlah penumpang kereta api di Pulau Jawa untuk periode Februari 2018 sampai Januari 2019 pada Tabel 3.2.

Tabel 3.2. Hasil Peramalan Menggunakan Kalman filter

Tahun	Bulan	Hasil
2018	Februari	31.363
2018	Maret	35.123
2018	April	34.027
2018	Mei	36.110
2018	Juni	33.615
2018	Juli	35.491
2018	Agustus	34.992
2018	September	33.761
2018	Oktober	35.220
2018	November	33.844
2018	Desember	35.856
2019	Januari	34.107

Sumber: Data diolah (2019)

Berdasarkan Tabel 3.2 terlihat bahwa jumlah penumpang tertinggi berada pada bulan Mei. Hal ini disebabkan pada bulan Mei merupakan bulan Ramadhan dan Hari Raya Idul Fitri, sehingga diperkirakan banyak masyarakat yang mudik lebaran. Kemudian, jumlah penumpang tertinggi kedua berada pada bulan Desember. Hal ini disebabkan pada bulan Desember merupakan Hari Raya Natal serta hari libur nasional, sehingga diperkirakan lonjakan jumlah penumpang kereta api juga terjadi pada bulan ini.

3.4 Kriteria Peramalan

Sebagai suatu criteria dalam menguji ketepatan model, MAPE merepresentasikan model yang dibuat bahwa semakin kecil nilai MAPE, maka semakin baik model yang digunakan. Berikut hasil kekuatan peramalan

dari MAPE dinyatakan dalam Tabel 3.3.

Tabel 3.3 Kriteria Peramalan dengan Menggunakan MAPE

y_t	\hat{y}_t	$\left \frac{y_t - \hat{y}_t}{y_t} \right \times 100\%$
30.721	31.363	0,02091
35.272	35.123	0,004228
35.135	34.027	0,03153
34.877	36.110	0,035367
32.270	33.615	0,04167
36.089	35.491	0,016557
34.560	34.992	0,012487
33.878	33.761	0,003461
35.602	35.220	0,010724
34.637	33.844	0,022897
37.197	35.856	0,03604
34.435	34.107	0,009525
$\sum MAPE$		2,044979 = 2%

Sumber: Data diolah (2019)

Menurut Zhang *et al.* (2015), nilai MAPE yang kurang dari 10% menunjukkan bahwa peramalan sangat akurat. Sedangkan nilai MAPE antara 10% hingga 20% menunjukkan bahwa peramalan baik. Berdasarkan Tabel 3.3, diketahui bahwa nilai MAPE untuk data jumlah penumpang kereta api di Pulau Jawa sebesar 2,044979 atau 2%. Dengan demikian, dapat disimpulkan bahwa metode *state space* sangat akurat digunakan dalam meramalkan jumlah penumpang kereta api di Pulau Jawa.

4. KESIMPULAN DAN SARAN

4.1 Kesimpulan

Berdasarkan pembahasan pada bab sebelumnya, diperoleh model yang cocok untuk data jumlah penumpang kereta api di Pulau Jawa pada periode Januari 2006 sampai Januari 2018 adalah *local level model with seasonal*. Peramalan jumlah penumpang kereta api di Pulau Jawa untuk duabelas periode kedepan menggunakan algoritme Kalman filter dari bulan Februari 2018 sampai Januari 2019 diperoleh hasil secara berturut-turut, yaitu 31363; 35123; 34027; 36110; 33615; 35491; 34992; 33761; 35220; 33844; 35856; 34107. Dengan jumlah penumpang tertinggi berada pada bulan Mei dan nilai MAPE diperoleh sebesar 2%, sehingga peramalan jumlah penumpang kereta api dengan metode *state space* sangat akurat digunakan.

4.2 Saran

Pada penelitian ini hanya menggunakan *state space* linear Gaussian dalam meramalkan jumlah penumpang kereta api di Pulau Jawa, maka penelitian selanjutnya disarankan untuk menggunakan metode *state space* dengan *noise* (gangguan) yang lain.

DAFTAR PUSTAKA

- Arianto, B Wicaksono. 2017. Peramalan Jumlah Penumpang Kereta Api di Pulau Jawa dan Sumatera Menggunakan Arima Box-Jenkins. *Skripsi*. Surabaya: Institut Teknologi Sepuluh Nopember.
- Gujarati, D. 2004. *Basic Econometrics*. New York: McGraw-Hill.
- Koopman, S. J., & Commandeur, J. J. 2015. Time Series: State Space Methods. *International Encyclopedia of the Social & Behavioral Sciences*. Vol.24 (354-360).
- Saputra, Ramadhani. 2018. Kontruksi Model Peramalan dengan Menggunakan Metode State Space. *Skripsi*. Bandar Lampung: Universitas Lampung.
- SAS Institute Inc. 2014. *SAS/ETS User's Guide, Version 13.2*. New York: SAS Institute Inc.
- Sumayang, L. 2003. *Dasar-Dasar Manajemen Produksi dan Operasi*. Jakarta: Salemba Empat.
- Wei, W. 2006. *Time Series Analysis: Univariate and multivariate*. New York: Pearson Addison Wesley.
- Welch, G., & Bishop, G. 2006. *An Introduction to the Kalman Filter*. Chapel Hill: University of North Carolina.
- Zhang, T., Wang, K., & Zhang, X. 2015. Modeling and Analyzing the Transmission Dynamics of HBV Epidemic in Xinjiang, China. *Journal PLOS One*, Volume 10, No.9, 1-14.