

PENERAPAN METODE *SINGULAR SPECTRUM ANALYSIS* (SSA) PADA PERAMALAN JUMLAH PENUMPANG KERETA API DI INDONESIA TAHUN 2017

Hirlan Khaeri¹⁾, Eko Yulian²⁾, Gumgum Darmawan³⁾

¹⁾Program Studi Master Statistika UNPAD, Jl. Dipati Ukur, Bandung;
hirlan16001@mail.unpad.ac.id

²⁾ Program Studi Master Statistika UNPAD, Jl. Dipati Ukur, Bandung

³⁾Departemen Statistika UNPAD, Jatinangor, Sumedang

Abstrak

Peramalan data deret waktu dengan *Singular Spectrum Analysis* (SSA) tengah populer beberapa tahun terakhir. Kemampuan SSA dalam menguraikan pola data deret waktu dalam bentuk yang sederhana dianggap cukup baik dalam menghasilkan data ramalan. Pada penelitian ini SSA digunakan untuk meramalkan jumlah penumpang kereta api di pulau Jawa pada tahun 2017. Penggunaan Metode *Periodogram* dan *Tracking signal* juga dibahas dalam penelitian ini. Model SSA yang paling tepat dalam kasus ini diperoleh pada *windows length* 19 dan jumlah grup 5 dengan MAPE 7,11 persen.

Kata Kunci. Metode spektral, *Periodogram*, SSA, *tracking signal*

1. Pendahuluan

Kereta Api merupakan salah satu moda transportasi masal yang memiliki sejarah panjang di Indonesia. Awalnya kereta digunakan sebagai alat angkut hasil pertanian di pulau Jawa, seiring perkembangan zaman kereta menjadi salah satu alat transportasi masal yang digunakan secara umum. Alat transportasi dengan daya angkut besar dan tanpa hambatan ini memiliki potensi untuk dikembangkan menjadi salah satu moda transportasi darat utama untuk rute jarak jauh. Layanan transportasi kereta sudah mencakup pulau Jawa dan sebagian wilayah Sumatra. Pada tahun 2015 pembangunan jalur kereta juga mulai dilakukan di pulau Sulawesi dengan target menghubungkan Makassar Hingga Manado [8].

Jaringan dan layanan kereta Jawa hingga saat ini masih yang terbesar di Indonesia dengan rata-rata tidak kurang dari 60 juta penumpang per tahun. Artinya kereta

masih memiliki daya tarik dan potensi yang cukup besar untuk terus berkembang. Jumlah penumpang KAI di Indonesia dipengaruhi oleh momen-momen tertentu sepanjang tahun. Data deret waktu berstruktur dan dapat dipertahankan untuk periode waktu berikutnya dapat diramal dengan metode statistik, Golyandina (2001). Data lampau yang mampu merefleksikan masa yang akan datang bisa digunakan untuk meramal kondisi yang akan terjadi di masa depan (Pepelyshev dan Zhilgjavsky, 2009).

Salah satu metode peramalan data deret waktu yang tengah berkembang saat ini adalah *Singular Spectrum Analysis (SSA)*. Hassani (2007), pernah melakukan perbandingan antara SSA, SARIMA, ARAR, dan *Seasonal Holt-Winter* dalam meramal data kematian akibat kecelakaan di USA pada tahun 1973. Hasilnya, SSA merupakan salah satu metode terbaik yang bisa digunakan untuk melakukan peramalan, berdasarkan nilai *Mean Absolute Error (MAE)* dan *Mean Relative Absolute Error (MRAE)*. Myung (2009), menunjukkan bahwa SSA adalah teknik analisis data deret waktu yang baik untuk menguraikan pola trend dan komponen lainnya dengan struktur yang sederhana.

Penelitian ini bertujuan untuk mendapatkan model, nilai ramalan, dan menunjukkan apakah SSA secara konsisten memiliki kemampuan yang baik dalam peramalan pada data jumlah penumpang kereta di Indonesia. Data yang digunakan adalah jumlah penumpang kereta pada layanan pulau Jawa tanpa melibatkan wilayah Jabodetabek.

2. Tinjauan Pustaka

2.1 *Singular Spectrum Analysis (SSA)*

SSA merupakan metode deret waktu mutakhir dan cukup *powerfull*, terutama untuk menangani deret waktu yang mengandung pola musiman. Broomhead dan King (1986) telah menunjukkan bahwa dekomposisi nilai matrik singular (SVD) efektif dalam mengurangi eror. Vautard dkk (1992), Ghil dan Taricco (1997), Allen dan Smith (1986), Danilov (1997), Yiou dkk (2000) telah mempublikasikan beberapa jurnal yang berhubungan dengan metodologi dan penerapan SSA. Elsner dan Tsonis (1996) telah mempublikasikan buku deret waktu yang berjudul *SSA: A New Tool in Time Series Analysis*. Buku ini menjadi pengantar utama untuk SSA. Pada dasarnya SSA terdiri dari dua tahap, yaitu: *Dekomposisi dan Rekonstruksi*. Algoritma dasar SSA membagi data deret waktu awal ke dalam data deret waktu yang baru yang terdiri dari trend, komponen musiman, dan eror. Tahap dekomposisi terdiri dari tahapan *embedding* dan SVD sedangkan tahap rekonstruksi terdiri dari tahapan *Grouping* dan *Diagonal Averaging*.

2.2 Dekomposisi

2.2.1 Embedding

Pada tahap *embedding* data deret waktu diubah ke dalam bentuk matriks lintasan (*Tajectory Matrix*) yakni mentransformasi data yang berdimensi satu (vektor) menjadi data yang multidimensional (matriks). Misalkan data deret waktu dengan panjang N , tanpa data hilang dinyatakan dengan $X = \{x_1, x_2, \dots, x_N\}$, data di transformasi ke dalam bentuk matriks berukuran $L \times K$. Dengan L merupakan panjang jendela (*windows length*) di mana $2 < L < N/2$. Belum ada metode khusus untuk menentukan nilai L secara pasti, sehingga untuk menentukan nilai L dilakukan dengan proses coba-coba (*trial and error*) dan $K = N - L + 1$. Dalam bentuk matriks dapat ditulis sebagai berikut:

$$X = [X_1, X_2, \dots, X_K] = \begin{bmatrix} x_1 & x_2 & \dots & x_K \\ x_2 & x_3 & \dots & x_{K+1} \\ \vdots & \dots & \ddots & \vdots \\ x_L & x_{L+1} & \dots & x_N \end{bmatrix}$$

matriks X disebut juga matriks *Hankel* dimana semua elemen anti diagonal-nya bernilai sama. Jadi pada tahap ini output yang diperoleh adalah matriks *Hankel* yang berukuran $L \times K$.

2.2.2 Singular Value Decomposition (SVD)

Setelah proses *embedding* yang menghasilkan matriks *Hankel* tahap berikutnya pada proses penguraian matriks singular (SVD). Penentuan matriks singular dalam SSA dapat dijelaskan, $S = XX^T$ misalkan $\lambda_1 \dots \lambda_L$ adalah nilai eigen dari matriks dimana $\lambda_1 \geq \dots \geq \lambda_L \geq 0$ dan $U_1 \dots U_L$ adalah vektor eigen dari masing- masing nilai eigen. $V_i = X^T U_i \sqrt{\lambda_i}$, maka SVD dari matriks lintasan X diperoleh sebagai berikut:

$$X = X_1 + \dots + X_d, \text{ dimana : } X_i = \sqrt{\lambda_i} U_i V_i^T$$

$(\sqrt{\lambda_i} U_i V_i^T)$ disebut juga dengan *eigentriple*. Jadi pada tahapan ini output yang dihasilkan adalah *eigentriple* $(\sqrt{\lambda_i} U_i V_i^T)$ yakni matriks singular, vektor eigen, dan matriks komponen utama.

2.3 Rekonstruksi

2.3.1. Grouping

Tahap *grouping* pada langkah rekonstruksi merupakan pengelompokan matriks $X_{(L \times K)}$ ke dalam subkelompok berdasarkan pola pembentuk data deret waktu yakni

trend, musim, dan eror. Tahap *grouping* pada langkah rekonstruksi merupakan partisi himpunan dari indeks $\{1, \dots, d\}$ ke dalam kelompok himpunan *disjoin* m $I = \{I_1, \dots, I_m\}$. Jadi $\mathbf{X}$ berkorespondensi dengan kelompok $I = \{I_1, \dots, I_m\}$. $\mathbf{X}$ dapat ditulis $\mathbf{X} = \mathbf{X}_{I1} + \dots + \mathbf{X}_{Im}$.

2.3.2. Diagonal Averaging

Pada tahap ini matriks $\mathbf{X}_{ij}$ yang diperoleh pada tahap *grouping* disusun ulang menjadi data deret baru dengan panjang N . Misalkan $\mathbf{Y}$ adalah matriks berukuran $L \times K$ dengan elemen y_{ij} , dimana $1 \leq i \leq L$ dan $1 \leq j \leq K$. Misalkan kita tentukan $L^* = \min(L, K)$ dan $K^* = \max(L, K)$, $N = L + K - 1$. Misalkan $y_{ij}^* = y_{ij}$ jika $L < K$ dan $y_{ij}^* = y_{ji}$ selainnya. Dengan menggunakan metode *Diagonal Averaging* matriks $\mathbf{Y}$ ditransformasi ke dalam bentuk series kembali, $\{y_1, \dots, y_N\}$ dengan menggunakan persamaan berikut:

$$y_k = \begin{cases} \frac{1}{k} \sum_{m=1}^k y_{m, k-m+1}^* & \text{untuk } 1 \leq k \leq L^* \\ \frac{1}{L^*} \sum_{m=1}^{L^*} y_{m, k-m+1}^* & \text{untuk } L^* \leq k \leq K^* \\ \frac{1}{N-k+1} \sum_{m=k-K^*+1}^{N-K^*+1} y_{m, k-m+1}^* & \text{untuk } K^* \leq k \leq N \end{cases}$$

sehingga $\mathbf{X}_{ij}$ akan menjadi deret $\tilde{\mathbf{Y}}^{(k)} = \tilde{y}_1^{(k)}, \dots, \tilde{y}_N^{(k)}$ karena itu, deret asli akan menjadi jumlah dari m deret sebagai berikut:

$$y_n = \sum_{k=1}^m \tilde{y}_n^{(k)} \quad (n = 1, 2, \dots, N)$$

2.4 Periodogram

Deteksi plot untuk keberadaan pola musiman bersifat subjektif. Untuk mengatasi masalah ini Schuster (1898) memperkenalkan metode periodogram. Adapun langkah-langkahnya adalah sebagai berikut:

1. Plot Data Deret waktu.
2. Tentukan Koefisien *differencing* (d), Melalui Metode GPH atau Sperio.
3. Jika Nilai $d > 0,5$ maka lakukan *differencing* terlebih dahulu.
4. Tentukan Nilai Frekuensi Fourier

$$\omega_k = \frac{2\pi k}{N}, \text{ dengan } k = 1, 2, \dots, \left\lfloor \frac{N}{2} \right\rfloor$$

5. Tentukan Nilai Periode dari ω_k
6. Tentukan Nilai Periodogram

$$a_k = \begin{cases} \frac{1}{n} \sum_{t=1}^n z_t \sin \omega_k t, & k = 0 \text{ dan } k = \frac{n}{2} \text{ jika } n \text{ genap.} \\ \frac{2}{n} \sum_{t=1}^n z_t \sin \omega_k t, & k = 1, 2, \dots, \frac{(n-1)}{2}. \end{cases}$$

$$b_k = \frac{2}{n} \sum_{t=1}^n z_t \cos \omega_k t \quad k = 1, 2, \dots, \frac{(n-1)}{2}$$

$$I(\omega_k) = \begin{cases} n a_0^2 & k = 0 \\ \frac{n}{2} (a_k^2 + b_k^2) & k = 1, 2, \dots, \frac{(n-1)}{2}. \\ n a_k^2 & k = \frac{n}{2} \text{ saat } n \text{ genap.} \end{cases}$$

7. Lakukan uji hipotesis sebagai berikut

$H_0: \alpha = \beta = 0$ (tidak ada pola musiman)

$H_1: \alpha \neq 0$ atau $\beta \neq 0$ (ada musiman)

statistik uji

$$F = \frac{(n-3)(a_k^2 + b_k^2)}{2 \sum_{j=1}^{n/2} (a_j^2 + b_j^2)} \quad \text{dengan } j = 1, 2, \dots, (n-1)/2 \text{ dan } k = n/2$$

Daerah kritis:

Tolak H_0 jika $F > F_{\text{tabel}}(2, n-3; \alpha)$

2.5 Peramalan (Forecasting)

Ada beberapa metode yang dapat digunakan untuk melakukan peramalan dalam SSA diantaranya metode vektor dan metode *Linear Recurrent Formula* (LRF). Misalkan U'_j adalah vektor komponen pertama L-1 dari vektor eigen U_j dan π_j adalah komponen terakhir dari $U_j (j = 1, 2, \dots, r)$, dimana r adalah koefisien LRF, definisikan vektor koefisien LRF yaitu r sebagai berikut

$$r = \frac{1}{1 - v^2} \sum_{j=1}^r \pi_j U'_j, \text{ dimana } v^2 = \sum_{j=1}^r \pi_j^2$$

$$\hat{y}_i = \begin{cases} \tilde{y}_i, & i = 1, \dots, T \\ R^T Z_i, & i = T + 1, \dots, T + M \end{cases}$$

dimana $Z_i = [\hat{y}_{i-L+1}, \dots, \hat{y}_{i-1}]^T$ dan $\tilde{y}_1, \tilde{y}_2, \dots, \tilde{y}_T$ diperoleh dari *Diagonal Averaging*.

2.6 Keandalan Peramalan

Penilaian keandalan peramalan bertujuan untuk mengetahui sejauh mana kemampuan model dapat digunakan untuk meramal. Prosedur ini bisa dilakukan dengan cara *tracking signal* (TS) yang dirumuskan sebagai berikut:

$$\text{Tracking Signal} = \frac{\sum_{t=1}^n e_t}{\sum_{t=1}^n |e_t|}$$

model peramalan dikatakan baik selama nilai-nilai *tracking signal* berada di dalam batas yang dapat diterima, yaitu ± 5 (Bovas dan Ledolter, 1983).

3. Metode Penelitian

SSA merupakan salah satu metode analisis data deret waktu nonparametrik yang *powerful* (Hassani, 2003) (Lawalkane dan Yusof, 2013). Karena itu selain stasioneritas uji-uji asumsi pada analisis deret waktu klasik tidak urgen lagi untuk dilakukan.


Langkah-langkah Analisis

1. Plot data deret waktu
2. Periksa pola data
3. Dekomposisi
4. Rekonstruksi
5. Peramalan
6. Pemeriksaan keandalan model

4. Hasil Dan Pembahasan

Plot data

Hal-hal yang dieksplorasi dalam tahap plot data diantaranya identifikasi adanya pola trend, musiman, siklis, dan *irregular*. Plot yang terbentuk sebagai berikut:




Gambar 1. Jumlah Penumpang KAI di Pulau Jawa Tahun 2006-2016

dari plot di atas sepintas dapat kita kenali adanya pengaruh trend yang positif dan musiman dengan beberapa periode. Titik waktu 90-132 menunjukkan pola yang lebih rapat dan teratur. Hal ini bisa jadi disebabkan oleh perubahan tata kelola PT.

KAI di sekitar tahun 2013. Identifikasi dengan plot sifatnya sangat subjektif. Metode empiris untuk pemeriksaan pola pola data bisa dilakukan dengan periodegram.

Pemeriksaan Pola Musiman

Analisis Plot menunjukkan adanya indikasi pola trend dan musiman. Periodogram yang dihasilkan menunjukkan bahwa data memiliki lebih dari satu pola musiman, sekitar 4-5. Dengan program R diperoleh kesimpulan bahwa data yang digunakan berpola musiman dengan periode tiga. Alat analisis yang lebih *powerfull* diperlukan untuk menganalisis data-data yang memiliki pola musim lebih dari satu. Salah satu teknik yang bisa digunakan adalah *Singular Spectrum Analysis* (SSA).



Gambar 2. Periodogram Data Jumlah Penumpang KAI

Proses Analisis SSA

1. Dekomposisi

1.1 *Embedding*

Dalam proses *embedding* hal pertama adalah menentukan *Windows Length*. Pada kasus ini jumlah data sebanyak 132 sehingga nilai L berkisar antara 2 sampai 66. Untuk memudahkan pencarian L optimum, digunakan metode grid dengan mencoba nilai L 10, 20, 30, 40, 50, 60. Selanjutnya dipilih nilai L dengan MAPE minimum. Hasilnya sebagai berikut:

L	10	20	30	40	50	60
MAPE	5,19	5,18	5,66	6,48	8,68	10,03

Diperoleh L dengan MAPE minimum adalah 20. Dengan cara yang sama dilakukan *tracking* di sekitar nilai 20 untuk mendapatkan nilai L yang paling tepat, hasilnya:

L	17	18	19	20	21	22
MAPE	5,10	5,98	4,69	5,18	6,54	6,44

Diperoleh nilai L dengan MAPE minimum adalah 19 yakni 4,69 persen. Dengan MAPE tersebut diharapkan bahwa hasil prediksi yang diperoleh dari model tidak berbeda jauh dengan nilai data sebenarnya. Dengan nilai L = 19 maka nilai K = 114. Matriks X (Hankel) dapat disusun sebagai berikut:

$$X = (x_{ij})_{i,j=1}^{19;114} = \begin{bmatrix} y_1 & y_2 & \cdots & y_{114} \\ y_2 & y_3 & \cdots & y_{115} \\ \vdots & \vdots & \ddots & \vdots \\ y_{19} & y_{20} & \cdots & y_{132} \end{bmatrix} = \begin{bmatrix} 2823 & 3561 & \cdots & 5567 \\ 3561 & 4146 & \cdots & 5540 \\ \vdots & \vdots & \ddots & \vdots \\ 5331 & 4491 & \cdots & 6332 \end{bmatrix}$$

1.2 Singular Value Decomposition (SVD)


Dari matriks Hankel yang diperoleh, selanjutnya SVD yang menghasilkan 19 *eigentruple* (sebanyak L). *Eigentruple* terdiri dari nilai *singular* (λ_i), vektor eigen (U_i) dan komponen utama (V) sebagai berikut:

Singular value (λ_i)			Eigenvector ($U_1 \dots U_{19}$)				$V_1 \dots V_{19}$				
No	λ_i	$\sqrt{\lambda_i}$	U1	U2	...	U19	No	V1	V2	...	V19
1	5.58E+10	236315.50	-0.225	-0.36	...	0.17	1	-	855.45	...	-298.99
2	1.56E+08	12490.79	-0.226	-0.35	...	-0.35	2	-	319.59	...	61.49
3	85089100	9224.37	-0.227	-0.32	...	0.00	3	-	-114.75	...	-123.38
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
17	10161427	3187.69	-0.231	0.31	...	-0.00	112	-23104	-492.48	...	-347.62
18	9285363	3047.18	-0.231	0.34	...	0.02	113	-	-837.83	...	586.47
19	8997144	2999.52	-0.232	0.35	...	0.03	114	-	-266.87	...	68.81

2. Rekonstruksi


2.1 Grouping

Perkiraan banyaknya grup yang terbentuk bisa dilihat dari *scree plot*, berikut:



Gambar 3. Scree Plot Data

dari gambar terlihat bahwa akan ada sekitar 4 atau 5 grup yang terbentuk. Untuk menentukan anggota-anggota dari group bisa dilakukan dengan melihat plot dari eigenvector.



Gambar 4. Plot Eigen Vektor Data

Grouping dapat dilakukan melalui analisis plot namun sifatnya sangat subjektif. Untuk mengatasi hal dilakukan perhitungan nilai periode dari setiap vektor eigen. Periodesitas yang berdekatan terindikasi berada pada kelompok yang sama. Dengan menggunakan program R diperoleh:

Eigen Vektor	Periode
1,2,3,4	Komponen trend
5	3.16
6	2.37
7	6.3
⋮	⋮
19	3.8

dari tabel di atas dapat dibentuk beberapa group yang mungkin. Berikut beberapa kombinasi group yang mungkin beserta nilai MAPE masing-masing:

No	Model	MAPE
1	trend (1,2,3,4)	7,4
	s1 (13,14)	
	s2 (5,18,19)	
	s3 (6,8,9,10,11,12,15,16)	
2	trend (1,2)	7,2
	s1 (3,4)	
	s2 (13,14)	
	s3 (6,8,9,10,11,12,15,16,18,19)	
3	Trend (1,2,3,4)	7,1
	s1(13,14)	
	s2(5,18,19)	
	s3 (12,15)	
	s4 (6,8,9,10,16,17)	


Nilai MAPE terkecil sebesar 7,1 dihasilkan oleh model ke-3.

2.2 Diagonal Averaging

Pada tahap ini group yang sudah terbentuk disusun kembali menjadi deret series yang baru. Berikut adalah hasil dari diagonal averaging

No	Data Asli (Y)	Tahapan Rekonstruksi					DA	Res
		T	S1	S2	S3	S4		
1	2823	3446.03	-91.08	118.46	-348.38	-145.83	2979.21	-156.21
2	3561	3624.90	27.32	-109.93	142.39	-143.93	3540.75	20.25
3	4146	3878.14	49.82	-126.58	29.11	286.28	4116.78	29.22
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
118	5316	5254.36	-94.41	15.01	-76.91	234.45	5332.50	-16.50
119	4898	5214.05	-72.14	-23.27	102.57	-420.28	4800.93	97.07
120	6332	5350.48	53.82	266.81	13.79	448.04	6132.94	199.06

Plot di bawah ini menunjukkan bahwa data hasil *diagonal averaging* dapat mengikuti pola dari data awal artinya bahwa model SSA dengan $L=19$ dan $r=5$ yang terbentuk cukup baik dalam merepresentasikan data sebenarnya.



Gambar 5. Plot perbandingan data awal dan hasil diagonal averaging

Tracking Signal (TS)

Tracking Signal (TS) dilakukan untuk menilai kehandalan model dalam memprediksi. Dengan LRF diperoleh koefisien berikut:

No	Koefisien LRF
1	-0.172
2	-0.118
3	-0.072
⋮	⋮
18	-0.121

diperoleh hasil ramalan dari data *insample*, kemudian kita lakukan *tracking signal*. Berikut ini adalah tabel hasil ramalan dan *tracking signal*:

No	Outsample (D_t)	Forecast (F_t)	Err (e_t)	$\sum e_t = \sum (D_t - F_t)$	MAD	TS
121	5648	4936.63	711.369	711.37	711.36	1
122	4829	5241.26	-412.258	299.11	561.81	0.53
123	4950	5231.17	-281.167	17.94	468.26	0.04
124	4851	4846.08	4.914	22.86	352.43	0.06
125	5775	5354.31	420.695	443.55	366.08	1.21
126	4909	5114.11	-205.106	238.45	339.25	0.70
127	6642	5392.47	1249.526	1487.97	469.29	3.17
128	5202	4829.91	372.088	1860.06	457.14	4.06
129	5448	5473.47	-25.471	1834.59	409.17	4.48
130	5232	5276.70	-44.7	1789.89	372.73	4.80
131	5074	4980.42	93.573	1883.46	347.35	5.42
132	6689	5497.39	1191.602	3075.06	417.71	7.36

Data ke 131 dan 132 nilai TS melebihi ambang batas, model hanya bisa digunakan meramalkan 10 data ke depan.

Peramalan/Forecasting

Tracking signal menunjukkan bahwa model yang dibentuk hanya bisa meramalkan 10 titik data ke depan dari data terakhir yang digunakan dalam penelitian. Dengan metode LRF diperoleh hasil ramalan untuk bulan Januari - Oktober 2017 sebagai berikut:

Jan	Feb	Mar	Apr	Mei	Jun	Jul	Agu	Sep	Okt
5671	5854	5382	5430	5657	5492	5981	5598	5744	5694

5. Kesimpulan

Dari keseluruhan proses di atas dapat ditarik kesimpulan bahwa model SSA terbaik adalah model dengan nilai $L = 19$ dan r (jumlah group) = 5. Metode SSA cukup baik digunakan dalam mengekstraksi data deret waktu berdasarkan komponen-komponen pembentuknya. Plot hasil diagonal averaging yang berhimpit dengan plot data awal menunjukkan bahwa SSA memberikan hasil yang relatif presisi dalam menduga data pada setiap periode waktu.

Prediksi jumlah penumpang KAI 10 bulan di tahun 2017 dengan SSA menggunakan *R-forecasting* menunjukkan bahwa jumlah penumpang tahun 2017 relatif belum akan berubah signifikan dibandingkan tahun 2016 dengan rata-rata bulanan sekitar 5.650 penumpang dan puncak-puncak kepadatan terjadi pada akhir januari sampai dengan awal february dan akhir juni sampai awal juli.

Daftar Pustaka

- Abraham, Bovas dan Johannes, Ledolter. 1983. *Statistical Method for Forecasting*. New York: Jhon Wiley & Sons. Inc.
- Darmawan, Gumgum. 2016. *Identifikasi Pola Data Curah Hujan Pada Proses Grouping dalam Metode Singular Spectrum Analysis*. Universitas Padjadjaran.
- Golyandina N., Zigljavsky A. 2013. *Singular Spektrum Analysis for Time Series*. Springer.

Hassani. Hossein dan Zigljavsky A. 2009. *Singular Spectrum Analysis: Methodology and Application to Economic Data*. Springer Science+Business Media, LLC.

Lawal Kane, Ibrahim, Yusof Fadilah, *Rainfall Time Series Exploration via Non Parametric Approach*, International Journal of Applied Mathematics and Statistics, Int. J. Appl. Math. Stat.; Vol. 45; Issue No. 15; Year 2013.

Myung, No Kang. 2009. *Singular Spectrum Analysis*. Thesis. University of California.

Pornomo R., Nurmulia, *Pembangunan Fisik Jalur Kereta Trans Sulawesi dimula Tahun Ini*, diambil dari <http://regional.kompas.com/read/2015/01/13/03085361/Pembangunan.Fisik.Jalur.Kereta.Trans.Sulawesi.Dimulai.Tahun.ini>, pada tanggal, 1 mei 2017.