

# PRAKIRAAN WAKTU TRANSIT PADA TRANSPORTASI INTERMODA MENGGUNAKAN METODE *PREDICTION TIME SERIES* DAN *COMPUTER VISION*

**Muhammad Amin Bakri<sup>1)</sup>, Syahri Ramadhan<sup>2)</sup>**

<sup>1)</sup>Jurusan Teknik Elektro, Fakultas Teknik, Universitas Islam “45” Bekasi

<sup>2)</sup>Departemen R&D, PT. Big Data Integrasi Indonesia

Email: amin@unismabekasi.ac.id<sup>1)</sup>, dhani@brilyan.com<sup>2)</sup>

## Abstrak

Meskipun model prediksi arus lalu lintas sudah banyak dikembangkan, hasilnya seringkali masih bersifat kurang memuaskan. Oleh karena itu, model prediksi lalu lintas dengan kebutuhan data yang bersifat *real-time* serta dalam jumlah besar, kompleks, dan dinamis, perlu dikaji ulang kembali untuk mendapatkan hasil yang optimal. Tulisan ini bertujuan untuk mengajukan sebuah prosedur peramal *transit time* transportasi intermoda dengan memanfaatkan data video kendaraan yang diperoleh dengan menggunakan sensor kamerayang diterapkan pada transportasi bus Transjakarta dan *commuter line* di Jabodetabek. Sistem *transit time journey* yang ditawarkan memiliki *input* sensor camera, kemudian outputnya dikonversi melalui computer vision, lalu diproses dengan menggunakan metode *prediction time series* setelah mendapatkan masukan informasi rute perjalanan. Luaran dari sistem ini menghasilkan *transit time* untuk rute yang diinginkan.

Kata Kunci: transportasi intermodal, waktu transit, *prediction time series*.

## Abstract

*Although many traffic prediction models have been developed, the results are often still unsatisfactory. Therefore, traffic prediction models on real-time, large, complex, and dynamic data, need to be developed to obtain optimal results. This paper aims to propose a procedure for the transition of intermodal transportation time by utilizing vehicle video data obtained using camera sensors applied to Trans Jakarta bus transportation and commuter lines case in Jabodetabek. The transit time journey system offered has a camera sensor input, then the output is converted through computer vision, then processed using the time series prediction method after getting input of travel route information. The results of this system is the transit time for desired route.*

*Keywords: intermodal transportation, transit time, prediction time series.*

## PENDAHULUAN

Keunggulan kompetitif layanan transportasi dapat dinilai dari hal-hal seperti efisiensi, kecepatan, dan kehandalan (Dotoli, 2014). Efisiensi penggunaan ruas jalan berimplikasi pada waktu yang dihabiskan oleh setiap individu, konsumsi bahan bakar, serta polusi udara yang menjadi salah satu kunci dari kualitas hidup masyarakat perkotaan (Loce *et.al*, 2017). Kecepatan transportasi terkait dengan dengan persoalan trafik, yakni volume pergerakan orang maupun barang dalam sebuah ruang publik. Pergerakan tersebut dapat melibatkan berbagai jenis kendaraan, seperti mobil, motor, sepeda, bus kota, maupun pejalan kaki. Masalah lain yang mempengaruhi kecepatan dalam transportasi adalah kongesti yang terjadi di jalan raya yang seringkali terjadi pada berbagai titik-titik keramaian dalam ruas jalan raya.

Untuk menjawab tantangan efisiensi, kecepatan, dan keandalan transportasi, telah terjadi pergeseran dari mode transportasi tunggal ke intermodal, yang mana komoditas dipindahkan melalui unit pemuatan yang disebut *Intermoda Transportation Unit* (ITU), dengan menggunakan dua atau lebih moda transportasi secara kontinyu, tanpa mengubah cara penanganan terhadap barang atau komoditas tersebut. Metode ini dianggap mampu memberikan layanan transportasi yang lebih fleksibel, *reliable*, menguntungkan, dan berkesinambungan. Tentu saja hasil yang dimikian akan diperoleh apabila pengelolaannya dilakukan secara terintegrasi (Capone *et.al*, 2017), (Dotoli, 2014).

Data-data yang diperoleh dari jalan raya secara *real time* dengan menggunakan sensor seperti kamera, seperti kepadatan lalu lintas, jumlah kendaraan, serta lalu-lintas pengguna, dapat dimanfaatkan untuk melakukan manajemen transportasi yang lebih baik. Berlandaskan data-data tersebut, pemerintah ataupun regulator dapat memperkirakan penggunaan jalan raya, tren volume kendaraan, dan periode arus kritis. Perkiraan ini dapat digunakan untuk mengoptimalkan jadwal perawatan, meminimalkan konflik, dan mengoptimalkan waktu penyelenggaraan lalu lintas. Data arus lalu lintas yang bersifat real-time juga memungkinkan dilakukannya manajemen kejadian yang lebih efisien, seperti deteksi, verifikasi, dan respons atas insiden yang terjadi di jalan raya (Yang *et.al*, 2017), (Loce *et.al*, 2017)]. Perkiraan ini sangat bergantung pada data historis lalu lintas maupun data real time yang didapatkan melalui sensor. Variasi sensor dan data yang makin meledak, telah mengantarkan kita kepada era transportasi big data (Yisheng, 2015). Bahkan big data yang dikombinasikan dengan transportasi sosial dipandang akan mendorong transformasi menuju dunia yang lebih terhubung mulus melalui infrastruktur, kendaraan, dan *Intelligent Transportation System (ITS)* (Zheng, 2016).

Persoalannya adalah, peran penting teknologi informasi dan komunikasi dalam meningkatkan kinerja pengelolaan transportasi terintegrasi secara keseluruhan, seringkali terhambat oleh persoalan seperti kurangnya interoperabilitas transmisi data, kesulitan dalam mengukur potensi manfaat, serta prakiraan waktu yang dibutuhkan untuk implementasi. Dalam konteks ini, pemodelan, analisis kerja, serta *tools* pengoptimalan, memiliki peran penting yang akan membantu pengelola dan regulator dalam memaksimalkan manfaat transportasi intermoda (Dotoli, 2014).

Meskipun sudah banyak dikembangkan model untuk memprediksi arus lalu lintas, hasilnya seringkali masih bersifat dangkal dan kurang memuaskan. Oleh karena itu, model prediksi lalu lintas dengan kebutuhan data yang bersifat real-time serta dalam jumlah besar, kompleks, dan dinamis, harus dikaji ulang kembali untuk mendapatkan hasil kinerja yang optimal. Penggunaan algoritma machine learning untuk menyelesaikan persoalan ini, kini semakin dilirik oleh baik akademisi maupun praktisi untuk melakukan tugas klasifikasi, pemrosesan bahasa, deteksi obyek, pemodelan gerak, dan sebagainya (Loce *et.al*, 2017). Aplikasi *machine learning* sendiri bisa dikatakan terdiri dari empat fase, mulai dari tahap pembelajaran, pemilihan model, penilaian akhir, dan operasional pengujian (prediksi) itu sendiri (Bacciu *et.al*, 2016).

Penerapan *machine learning* pada *big data* merupakan pekerjaan yang sangat menantang, mengingat sistem *machine learning* tradisional tidak dilengkapi dengan baik untuk menangani analisis data dengan volume besar ataupun dengan kecepatan yang sangat bervariasi. Menemukan sistem dan model pemrograman yang tepat untuk kepentingan analisis data yang cukup besar seringkali membingungkan. Ketersediaan sistem yang efisien dalam hal penggunaan *machine learning* untuk kasus pemrosesan big data, masih kurang (Nair *et.al*, 2017).

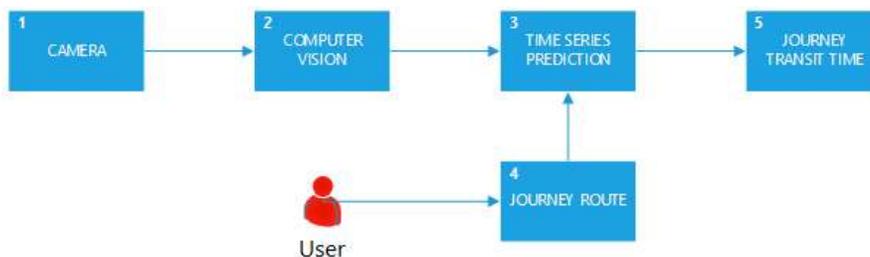
Dalam konteks itulah, paper ini bertujuan untuk mengajukan sebuah prosedur peramalam *transit time* untuk transportasi intermoda dengan memanfaatkan data video kendaraan yang diperoleh dengan menggunakan sensor kamera. Analisa data video dilakukan dengan menggunakan metode *prediction time series* yang diterapkan pada transportasi bus Trans Jakarta dan *commuter line* di Jabodetabek.

## Tahapan Pengambilan Keputusan

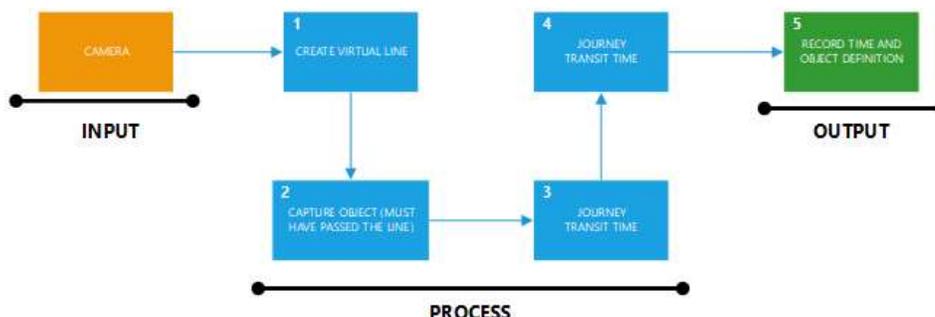
Sistem *transit time journey* yang ditawarkan memiliki *input* sensor camera, kemudian outputnya dikonversi melalui *computer vision*, lalu diproses dengan menggunakan metode *prediction time series* setelah mendapatkan masukan *journey route*. Output dari sistem ini menghasilkan *transit time journey* yang diinginkan. Komponen-komponen dan keterkaitan yang membentuk sistem tersebut ditunjukkan dalam diagram yang ditampilkan pada Gambar 1.

Secara singkat, prosedur kerja dari sistem *transit time journey* ini adalah dimulai dengan penangkapan (*capturing*) secara *real-time* kedatangan kendaraan melalui *video camera* yang dipasang pada stasiun/halte yang akan diambil datanya. Data video yang ditangkap oleh kamera selanjutnya akan diolah oleh *computer vision* yang akan menghasilkan data waktu kedatangan kendaraan. Data waktu ini kemudian akan diolah dengan menggunakan metode *prediction time series* yang akan menghasilkan output berupa pola kedatangan kendaraan serta prediksi kedatangan kendaraan ke depan.

Pada saat bersamaan, data pengguna yang memilih rute awal dan akhir perjalanan akan dipelajari oleh sistem *journey route* untuk memperoleh rute-rute yang dapat ditempuh berikutnya. Selanjutnya, sistem akan mampu memperkirakan rute dan waktu keberangkatan selanjutnya. Dari sinilah akan diperoleh prediksi *transit time* yang diinginkan. Ide dasar penggunaan *computer vision* sendiri adalah mendeteksi kedatangan kendaraan dengan menggunakan patokan garis maya yang telah ditetapkan oleh aplikasi. Selanjutnya, hasil deteksi tersebut didata dengan menggunakan metode klasifikasi kemudian data tersebut didefinisikan dan direkam ke dalam sistem. Prosedur penangkapan dan perekaman data video dengan menggunakan *computer vision* dtunjukkan dalam Gambar 2.



Gambar 1. Blok diagram sistem *transit time journey* untuk transportasi intermoda



Gambar 2. Prosedur penangkapan dan perekaman video dengan computer vision

Data video yang diperoleh kamera sebagai *input*, akan dideteksi berdasarkan garis maya yang selanjutnya menjadi batas perhitungan computer vision. Setiap benda yang melewati garis maya akan di-*capture* untuk kemudian menjadi *input* bagi proses pengkategorian. Tahapan ini dilakukan dengan menentukan kategori ukuran masing-masing kendaraan. Selanjutnya, hasil deteksi obyek kendaraan tersebut kemudian dikalsifikasi untuk menghasilkan bank data jenis moda, banyaknya moda, serta penomoran moda. Hasil klasifikasi ini lalu disimpan ke dalam *log time* moda.

Data hasil proses *computer vision* yang tersimpan dalam *log time* moda selanjutnya dengan menggunakan metode *prediction time series* dipakai untuk melakukan peramalan/prediksi kedatangan moda pada setiap stasiun. Proses perhitungannya dilakukan dengan menggunakan persamaan berikut.

$$t_{\text{modal}} = t_{\text{modal (now)}} - t_{\text{modal (before)}} \tag{1}$$

Dimana:

- $t_{\text{modal}}$  = waktu tempuh moda dari stasiun sebelumnya ke stasiun saat ini
- $t_{\text{modal (now)}}$  = waktu kedatangan di stasiun/terminal saat ini
- $t_{\text{modal (before)}}$  = waktu kedatangan di stasiun/terminal sebelumnya

Dengan mengetahui waktu yang ditempuh, maka dapat diperoleh kecepatan rata-rata perjalanan, dengan syarat jarak yang ditempuh antar stasiun/terminal sudah di-*input* terlebih dahulu. Persamaan yang digunakan untuk menghitung kecepatan rata-rata adalah:

$$V_{\text{modal}} = S / t_{\text{modal}} \tag{2}$$

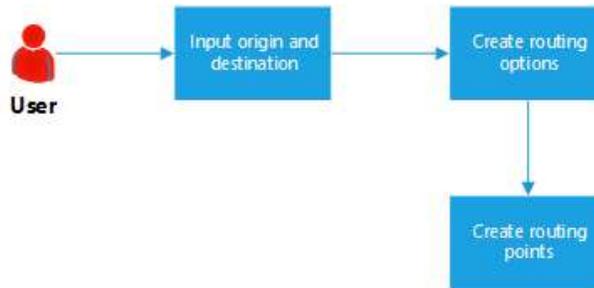
Dimana:

$V_{\text{modal}}$  = kecepatan rata-rata modal dari stasiun pertama ke stasiun berikutnya

$S$  = jarak antar stasiun/terminal

$t_{\text{modal}}$  = waktu tempuh moda dari stasiun sebelumnya ke stasiun saat ini

Setelah kecepatan dapat ditentukan, maka proses dilanjutkan untuk menggambarkan grafik *time series* untuk kecepatan rata-rata sebuah mode transportasi. Selanjutnya, proses dilanjutkan untuk menghitung rute perjalanan yang diinginkan oleh pengguna. Proses penentuan rute perjalanan ditunjukkan dalam Gambar 3.



Gambar 3. Penentuan rute perjalanan

Dengan menggunakan *time series prediction*, data berupa kecepatan rata-rata dari sebuah mode transportasi serta data rute perjalanannya, dikumpulkan kemudian dilanjutkan dengan menghitung transit time perjalanan dengan bantuan rata-rata perpindahan.

$$V_{\text{prediction}} = V_1 + V_2 + V_3 + \dots / n \quad (3)$$

Dimana:

$V_{\text{prediction}}$  = kecepatan rata-rata prediksi

$V_1$  = kecepatan periode (1)

$V_2$  = kecepatan periode (2)

$V_3$  = kecepatan periode (3)

$n$  = jumlah periode rata-rata pergerakan

Dengan menentukan prediksi kecepatan rata-rata, maka proses dapat dilanjutkan untuk menyelesaikan perhitungan perkiraan waktu perjalanan dengan menggunakan persamaan 4.

$$t_{\text{estimate}} = S / V_{\text{prediction}} \quad (4)$$

Dimana:

$t_{\text{estimate}}$  = perkiraan waktu perjalanan

$S$  = jarak

$V_{\text{prediction}}$  = kecepatan perkiraan rata-rata

## STUDI KASUS

### Data Umum

Studi kasus ini dilakukan di Jakarta, yang merupakan salah satu kota dengan tingkat kemacetan yang sangat tinggi. Moda transportasi yang dipilih adalah layanan bus umum dan kereta api. Keduanya merupakan moda transportasi yang paling banyak digunakan oleh penduduk Jakarta dan kota-kota sekitarnya. Layanan bus umum yang dipilih adalah Transjakarta yang beroperasi di 13 koridor dan sejumlah rute khusus. Masing-masing koridor dihubungkan oleh sekitar 200 hate bus. Jarak ke-tiga belas koridor dan jalur khusus tersebut mencapai 172 km. Tabel 1 merinci data ke-tiga belas koridor yang dimaksud.

Empat koridor dipilih dan dianalisis untuk keperluan pengambilan sampel data, yaitu Kota - Blok M, Ancol - Kampung Melayu, PGC - Tanjung Priok, dan Pulo Gadung - Dukuh Atas. Sedangkan untuk layanan kereta yaitu KRL beroperasi di enam jalur dan sejumlah rute khusus. Masing-masing jalur digabung menjadi sekitar 80 stasiun. Enam jalur dan jalur khusus mencapai 235 km sebagaimana dirinci dalam Tabel 2.

Tabel 1. Koridor layanan bus Transjakarta

Kode	Asal - Tujuan	Berhenti	Kode Stasiun
K.1	Blok M – Kota	19	K1.01 – K1.20
K.2	Kota Harapan Indah – Harmoni	32	K2.01 – K2.32
K.3	Kalideres – Pasar Baru	17	K3.01 – K3.16
K.4	Pulo Gadung – Dukuh Atas	17	K4.01 – K4.17
K.5	Ancol – Kampung Melayu	18	K5.01 – K5.18
K.6	Dukuh Atas 2 – Ragunan	20	K6.01 – K6.20
K.7	Kampung Melayu – Kampung Rambutan	14	K7.01 – K7.14
K.8	Lebak Bulus – Harmoni	20	K8.01 – K8.22
K.9	Pluit – Pinang Ranti	29	K9.01 – K9.26
K.10	Tanjung Priok – Cililitan	22	K10.01 – K10.24
K.11	Kampung Melayu – Wali Kota Jakarta Timur	15	K11.01 – K11.15
K.12	Pluit – Tanjung Priok	24	K12.01 – K12.24
K.13	Puri Beta 2 – Tendean	13	K13.01 – K13.13

Tabel 2. Jalur layanan kereta api umum KRL

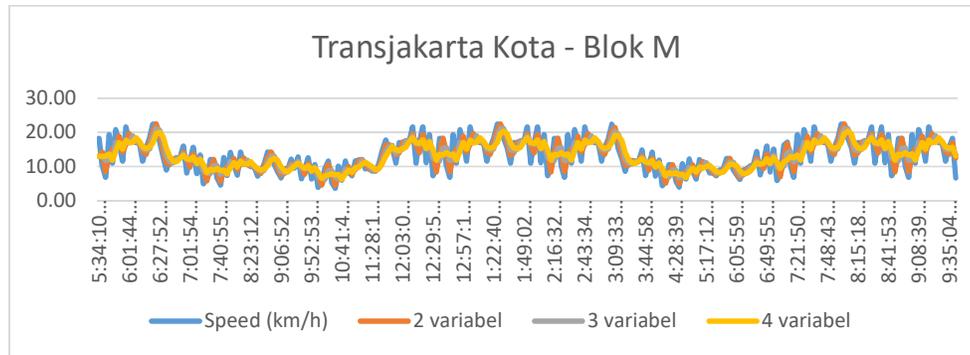
Jalur	Asal – Tujuan	Stasiun
Merah	Bogor/Depok – Manggarai – Jakarta Kota	24
Orange	Bogor/Depok – Tanah Abang – Pasar Senen - Jatinegara	30
Biru	Bekasi – Jatinegara – Manggarai – Jakarta Kota	19
Hijau	Rangkasbitung/Maja/Parung Panjang/Serpong – Tanah Abang	19
Coklat	Tangerang – Duri	11
Pink	Tanjung Priok – Jakarta Kota	4

Dari keenam jalur tersebut, lalu dipilih jalur biru dari Stasiun Bekasi ke Stasiun Manggarai. Perhitungan untuk prediksi waktu perjalanan dilakukan dengan melakukan tiga tindakan berturut-turut. Pertama, pola deret waktu diekstraksi dari setiap perjalanan moda transportasi. Kedua, pola kedatangan mode transportasi diambil berdasarkan data visual. Terakhir, waktu perjalanan penumpang kemudian disimulasikan.

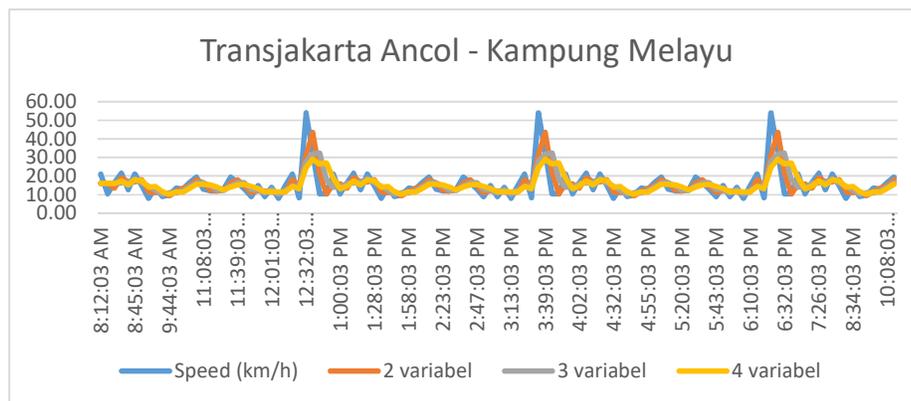
### Hasil ekstraksi pola *time series* untuk setiap moda transportasi

#### Layanan bus umum Transjakarta

Hasil ekstraksi pola *time series* dari layanan bus umum disajikan dalam Gambar 4, yaitu diambil dari catatan perjalanan Transjakarta pada rute Kota—Blok M. Tiga variabel rata-rata bergerak dibandingkan, dan hasilnya adalah sebagai berikut. Dua variabel memiliki tingkat kesalahan rata-rata 13,8%. Tiga variabel memiliki tingkat kesalahan rata-rata 15,1%. Empat variabel memiliki tingkat kesalahan rata-rata 15,6%. Selain itu, dipahami juga bahwa kecepatan rata-rata moda transportasi adalah *clock* pada 13,2 km / jam.

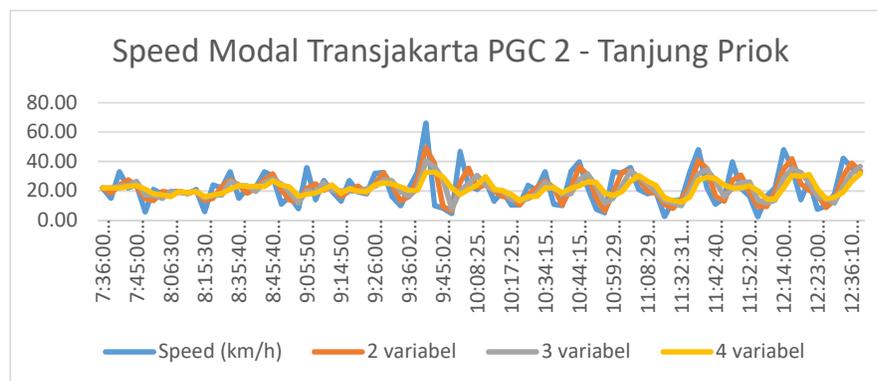


Gambar 4. Moda kecepatan Transjakarta Koridor Kota—Blok M



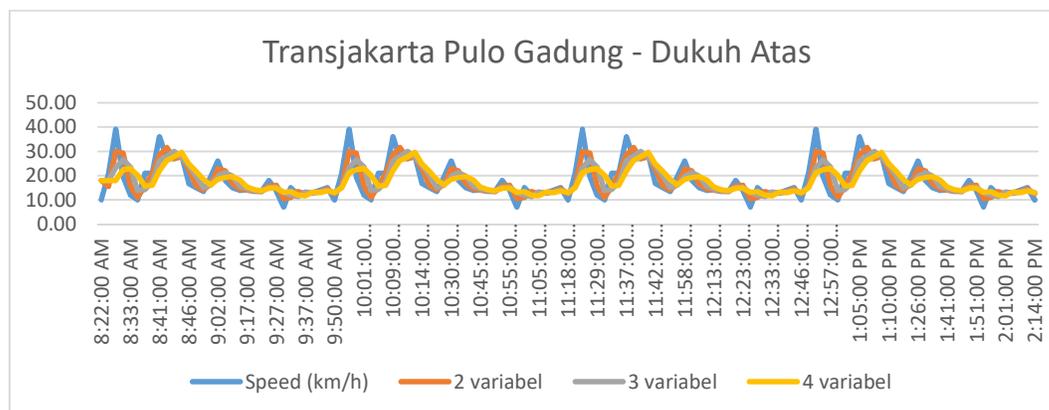
Gambar 5. Kecepatan moda Transjakarta Koridor Ancol – Kampung Melayu

Grafik pada Gambar 5 diambil dari catatan perjalanan Transjakarta pada rute Ancol-Kampung Melayu. Tiga variabel rata-rata bergerak dibandingkan, dan hasilnya adalah sebagai berikut. Dua variabel memiliki tingkat kesalahan rata-rata 14,05%. Tiga variabel memiliki tingkat kesalahan rata-rata 15,33%. Empat variabel memiliki tingkat kesalahan rata-rata 16,16%. Selain itu, tampak juga bahwa kecepatan rata-rata moda transportasi adalah clock pada 15,7 km / jam.



Gambar 6. Kecepatan moda Transjakarta Koridor PGC 2 – Tanjung Priok

Grafik pada Gambar 6 diambil dari catatan perjalanan Transjakarta pada rute PGC 2—Tanjung Priok. Tiga variabel rata-rata bergerak dibandingkan, dan hasilnya adalah sebagai berikut. Dua variabel memiliki tingkat kesalahan rata-rata 19,61%. Tiga variabel memiliki tingkat kesalahan rata-rata 20,45%. Empat variabel memiliki tingkat kesalahan rata-rata 28,44%. Selain itu, tampak juga bahwa kecepatan rata-rata moda transportasi adalah clock pada 21,98 km / jam.



Gambar 7. Kecepatan moda Transjakarta Koridor Pulo Gadung – Dukuh Atas

Grafik pada Gambar 7 diambil dari catatan perjalanan Transjakarta pada rute Pulo Gadung—Dukuh Atas. Tiga variabel rata-rata bergerak dibandingkan, dan hasilnya adalah sebagai berikut. Dua variabel memiliki tingkat kesalahan rata-rata 10,64%. Tiga variabel memiliki tingkat kesalahan rata-rata 12,99%. Empat variabel memiliki tingkat kesalahan rata-rata 14,11%. Selain itu, tampak juga bahwa kecepatan rata-rata moda transportasi adalah clock pada 17,82 km / jam.

### Layanan kereta api umum—KRL

Pola hasil ekstraksi time series dari layanan kereta api KRL disajikan dalam Tabel 3.

Tabel 3. Pola time series layanan kereta api KRL untuk Jalur Biru

No	Asal	Tujuan	Log Time	Jarak waktu	Jarak	Waktu (detik)	Kecepatan (km/h)
1	Bekasi	Kranji	06.02.00	00.04.00	2500	240	37,50
2	Kranji	Cakung	06.06.00	00.05.00	3100	300	37,20
3	Cakung	Klender Baru	06.11.00	00.03.00	1400	180	28,00
4	Klender Baru	Buaran	06.14.00	00.03.00	1260	180	25,20
5	Buaran	Klender	06.17.00	00.04.00	3160	240	47,40
6	Klender	Jatinegara	06.21.00	00.06.00	3260	360	32,60
7	Jatinegara	Manggarai	06.27.00	00.07.00	2660	420	22,80
8	Manggarai	Cikini	06.34.00	00.04.00	1630	240	24,45
9	Cikini	Gondangdia	06.38.00	00.04.00	1700	240	25,50
10	Gondangdia	Juanda	06.42.00	00.05.00	2240	300	26,88
11	Juanda	Sawah Besar	06.47.00	00.02.00	720	120	21,60
12	Sawah Besar	Mangga Besar	06.49.00	00.03.00	1240	180	24,80
13	Mangga Besar	Jayakarta	06.52.00	00.03.00	1050	180	21,00
14	Jayakarta	Jakarta Kota	06.55.00	00.04.00	1330	240	19,95
15	Jakarta Kota		06.59.00				
16	Jakarta Kota	Jayakarta	07.13.00	00.04.00	1330	240	19,95
17	Jayakarta	Mangga Besar	07.17.00	00.03.00	1050	180	21,00
18	Mangga Besar	Sawah Besar	07.20.00	00.02.00	1240	120	37,20
19	Sawah Besar	Juanda	07.22.00	00.04.00	720	240	10,80
20	Juanda	Gondangdia	07.26.00	00.05.00	2240	300	26,88
21	Gondangdia	Cikini	07.31.00	00.03.00	1700	180	34,00
22	Cikini	Manggarai	07.34.00	00.07.00	1630	420	13,97
23	Manggarai	Jatinegara	07.41.00	00.06.00	2660	360	26,60
24	Jatinegara	Klender	07.47.00	00.07.00	3260	420	27,94

25	Klender	Buaran	07.54.00	00.05.00	3160	300	37,92
26	Buaran	Klender Baru	07.59.00	00.03.00	1260	180	25,20
27	Klender Baru	Cakung	08.02.00	00.06.00	1400	360	14,00
28	Cakung	Kranji	08.08.00	00.03.00	3100	180	62,00
29	Kranji	Bekasi	08.10.00	00.03.00	2500	180	50,00
30	Bekasi		08.13.00				
Rata-rata							29,10

Karena rute layanan kereta umum steril dari perjalanan satu arah, maka tepat untuk menentukan kecepatan rata-rata waktu jalur biru, yang mana perhitungan menunjukkan bahwa kecepatan rata-rata adalah 29,10 km / jam.

### Ekstraksi pola kedatangan ke stasiun transit

Karena ukuran rute yang besar, maka diputuskan hanya akan ada beberapa stasiun pada setiap mode yang digunakan untuk keperluan ekstraksi data, sebagaimana dirinci dalam Tabel 4 dan 5.

Tabel 4. Hasil monitoring stasiun bus Transjakarta

Nama stasiun	Tujuan	Koridor	Rata-rata waktu (menit)
Halte Kota	Blok M	K.1	5
Halte Harmoni	Pulo Gadung	K.2	25
Halte Dukuh Atas	Pulo Gadung	K.2	15
Halte Manggarai	Pulo Gadung	K.2	11
Halte Manggarai	Dukuh Atas	K.2	9
Halte Ancol	Kampung Melayu	K.5	12
Halte Tanjung Priok	PGC 2	K.10	14

Tabel 5. Hasil monitoring stasiun kereta KRL

Nama stasiun	Rata-rata waktu (menit)
Kota	16
Manggarai	14
Ancol	18
Tanjung Priok	20
Jatinegara	14

### Simulasi Perjalanan Penumpang

Untuk tujuan simulasi, skenario yang digunakan adalah; penumpang menggunakan layanan kereta api dari Bekasi ke Manggarai, kemudian berjalan kaki dari stasiun kereta Manggarai ke halte bus Manggarai, lalu dari halte tersebut penumpang naik bus menuju halte Pulo Gadung. Hasil simulasi menunjukkan durasi waktu perjalanan dan waktu tiba sebagaimana disajikan dalam Tabel 6.

Tabel 6. Hasil Simulasi Perhitungan *Transit Time*

No	Kedatangan	Keberangkatan	Jarak (m)	Kecepatan			Waktu	Durasi Perjalanan (menit)	Estimasi Waktu Kedatangan
				Last 1	Last 2	Rata-rata			
1	St. Bekasi	St. Manggarai	17340			29,1	08.15	36	08.50
2	St. Manggarai	Halte Manggarai					08.50	14	09.04
3	Manggarai	Matraman 2	1400	19,5	26	22,75	09.04	4	09.07
4	Matraman 2	Pasar Genjing	950	12,00	19,5	15,75	09.07	4	09.10

**JREC**

**Journal of Electrical and Electronics**

**Vol. 6 No. 2**

5	Pasar Genjing	Utan Kayu	450	10,00	12	11	09.10	2	09.12
6	Utan Kayu	Pramuka LIA	450	21,00	10	15,5	09.12	2	09.13
7	Pramuka LIA	Pramuka BPKP	600	21,00	21	21	09.13	2	09.14
8	Pramuka BPKP	UNJ	700	36,00	21	28,5	09.14	1	09.15
9	UNJ	Sunan Giri	350	27,00	36	31,5	09.15	1	09.15
10	Sunan Giri	Velodrome	500	27,00	27	27	09.15	1	09.16
11	Velodrome	Pemuda Rawamangun	400	28,50	27	27,75	09.16	1	09.16
12	Pemuda Rawamangun	Layur	650	16,80	28,5	22,65	09.16	2	09.17
13	Layur	TU Gas	650	15,00	16,8	15,9	09.17	2	09.19
14	TU Gas	Ps. Pulogadung	700	13,50	15	14,25	09.19	3	09.21
15	Ps. Pulogadung	Pulugadung 2	1000	19,50	13,5	16,5	09.21	4	09.24
16	Pulogadung 2	Ps. Pulogadung	1000	26,00	19,5	22,75	09.24	3	09.26
Total								80	01.11

## KESIMPULAN

Penelitian ini mengusulkan suatu model prediksi waktu transit perjalanan untuk transportasi antar moda dengan mensimulasikan dua layanan angkutan umum di Jakarta, yaitu Transjakarta yang merupakan layanan bus umum dan KRL yang merupakan layanan kereta umum. Dengan mengambil sampel data dari empat koridor halte Transjakarta serta enam jalur KRL, prediksi kecepatan rata-rata moda transportasi berhasil ditentukan seperti halnya kedua moda transportasi yang digunakan dalam model. Yang paling penting, model juga berhasil menentukan prediksi waktu perjalanan dengan menggunakan skenario seorang penumpang yang berangkat dari tempat asal ke tujuan, melewati terminal kedua moda transportasi di sepanjang jalan.

Untuk studi lebih lanjut dan pengembangan di masa depan, model prediksi ini dapat diterapkan pada skala yang lebih besar dari skenario transportasi antar modalnya, misalnya dengan menambahkan moda transportasi ke dan dari Bandara Internasional Soekarno Hatta.

## Daftar Pustaka

- Yisheng Lv, Duan, Y., Kang, W., Li, Z., Wang, F.Y.: Traffic Flow Prediction With Big Data: A Deep Learning Approach. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 16, No. 2, April (2015)
- Zheng, X., Chen, W., Wang, P., Shen, D., Chen, S., Wang, X., Zhang, Q., Yang, L.: Big Data for Social Transportation [IEEE Transactions on Intelligent Transportation Systems](#), Volume: 17, Issue: 3, March (2016)
- Yang, Z., Lilian S. C., Pun-Cheng: Vehicle Detection in Intelligent Transportation Systems and its Applications under Varying Environments: A Review. *Image and Vision Computing* (2017)
- Bacciu, D., Cartaa, A., Gnesib, S., Semina, L.: An Experience in using Machine Learning for Short-term Predictions in *Smart Transportation Systems*. *Journal of Logical and Algebraic Methods in Programming* (2016)
- Cavone, G., Dotoli, M., Epicoco, N., Seatzu, C.: Intermodal terminal planning by Petri Nets and Data Envelopment Analysis. *Control Engineering Practice* 69 pp 9–22 (2017)
- Dotoli, M., Epicoco, N., Falagario, M., Cavone, G.: Timed Petri Nets Model for Intermodal Freight Transport Terminals. *12th IFAC/IEEE Workshop on Discrete Event Systems Cachan, France*. May pp 14–16, (2014)
- Nair, L.R., Shetty, S.D., Shetty, S.D.: Applying spark based machine learning model on streaming big data for health status prediction. *Computers and Electrical Engineering* 000 (2017) 1–7
- Rahman, M.N., Esmailpour, A., Zhao, J.: Machine Learning with Big Data An Efficient Electricity Generation Forecasting System. *Big Data Research* 5 (2016) 9–15.
- Loce, R.P., Raja Bala, Trivedi. M.: *Computer Vision and Imaging in Intelligent Transportation Systems*. John Wiley & Sons Ltd, Hoboken USA, (2017)

