

Prediksi Deret Waktu Manajemen Lalu Lintas

Traffic Management Time Series Prediction

M. Ulul Albab¹, Elly Anjarsari², Rahma Febriyanti³, Marissa Dewi Fatimah⁴
mululalbab@unisla.ac.id

Universitas Islam Lamongan

Abstrak

Pengoptimalan layanan konsumen terhadap jumlah pengemudi di suatu area melalui prediksi permintaan *real time* sangat penting dalam membantu industri layanan transportasi *online* untuk *scale up*. Dalam penelitian ini *dataset* yang digunakan adalah *traffic management* dengan disertai atribut-atribut seperti *geohash* level 6, *day*, *timestamp* dan *demand*. *Dataset* yang digunakan berupa sampel dari *geohash6* berkode qp0991, memuat permintaan transportasi *online* selama 01/04/2018 hingga 31/05/2018 (61 hari). *Dataset training* dari sampel kode qp0991 yaitu mulai dari 01/04/2018 hingga 10/05/2018 dan sisanya sebagai *dataset testing*. Persentase untuk *dataset training* dan *testing* secara berturut-turut sebesar 67% dan 33%. Metode yang diterapkan untuk membangun *objective function* adalah tiga metode peramalan yang berbeda yaitu *Naïve approach*, *auto regressive integrated moving average* (ARIMA), dan *simple exponential smoothing*. Hasil dari penelitian ini menunjukkan bahwa metode *simple exponential smoothing* paling baik dibanding metode *naïve approach* dan *auto regressive integrated moving average* berdasarkan pada nilai *root mean square error* (RMSE), *mean absolute error* (MAE), dan *mean absolute percentage error* (MAPE). Metode *simple exponential smoothing* memiliki tingkat keakuratan yang mencapai 98.7% nilai RMSE, nilai MAE 98.9%, dan nilai MAPE 88.81%.

Kata kunci: deret waktu, *management* lalu lintas

Abstract

Optimizing customer service for the number of drivers in an area through real-time transportation service industry online to scale up. In this paper, the dataset used is traffic management accompanied by attributes such as level 6 geohash, day, timestamp, and demand. The dataset used is a sample from geohash6 coded qp0991, containing online transportation demands from 01/04/2018 until 31/05/2018 (61 days). The training datasets are from the qp0991 code sample, starting from 01/04/2018 until 10/05/2018 and the remaining datasets are used as the testing datasets. The percentages for training and testing are respectively 67% and 33%. The methods applied to construct the objective function are three different forecasting methods, namely the Naïve approach, auto-regressive integrated moving average (ARIMA), and simple exponential smoothing. The results of this study indicate that the simple exponential smoothing method is better than the naïve approach and auto-regressive integrated moving average based on the root mean square error (RMSE), mean absolute error (MAE), and mean absolute percentage error (MAPE). The simple exponential smoothing has an accuracy rate of 98.7% for the RMSE value, 98.9% for the MAE value, and 88.81% for the MAPE value.

Keywords: *time series, traffic management*

PENDAHULUAN

Kemacetan lalu lintas telah menjadi masalah besar di banyak kota besar di seluruh dunia. Sebuah studi oleh INRIX mengungkapkan bahwa ratusan

jam per tahun terbuang sia-sia karena kemacetan lalu lintas (Sunindyo & Satria, 2020). Berbagai penelitian telah dilakukan untuk mengurangi tingkat kemacetan lalu lintas yang semakin meningkat. Solusi yang diajukan dapat diklasifikasikan ke dalam 3 kategori: penambahan infrastruktur, transportasi umum, dan manajemen lalu lintas yang lebih baik (Lana et al., 2018).

Salah satu solusi lain dalam memperbaiki masalah kemacetan lalu lintas melalui kolaborasi dan kerjasama antar *stakeholders*, seperti layanan *taxi-calling* berbasis internet Grab dengan pemerintah daerah dan kota, berupa kemitraan berbagi data dengan proyek *The World Bank's Open-Traffic* untuk menyediakan *streaming data real-time* yang melaporkan volume layanan, pelacakan lokasi, dan riwayat waktu perjalanan. Proyek ini memiliki potensi yang menjanjikan untuk membantu pemerintah dapat terhubung ke platform untuk memodelkan lalu lintas dengan lebih baik, memeriksa data historis, memahami pola kemacetan lalu lintas dan merencanakan infrastruktur, serta meningkatkan tanggap darurat dan kesiapsiagaan bencana (Lin & Dula, 2016).

Dalam situasi kemacetan lalu lintas, layanan *taxi-calling* seperti transportasi *online* menjadi semakin populer, karena melalui aplikasi layanan tersebut penumpang dapat menelpon atau memesan transportasi *online* bahkan ketika penumpang berada di lokasi dimana transportasi *online* sulit untuk mendapatkan pengemudi (Markou et al., 2018). Di sisi lain, pengemudi yang bekerja melalui layanan transportasi *online* dapat memilih untuk bekerja pada waktu permintaan perjalanan (*travel demand*) yang tinggi guna meningkatkan pendapatannya (Ara & Hashemi, 2021).

Data manajemen lalu lintas dalam era industry 4.0 menjadi sesuatu yang berguna dalam menjalankan bisnis berbasis teknologi digital khususnya industri layanan transportasi *online*. Pengolahan data manajemen lalu lintas yang baik bagi industri ini dapat digunakan diantaranya untuk memahami *trend* pasar dan permintaan layanan dari konsumen. Industri ini sebagai *derived demand* memiliki tantangan berupa faktor ketidakpastian akan permintaan konsumen pada setiap area, sehingga perlu dilakukan *demand predict* secara deret waktu (*time series*) untuk mengoptimalkan jumlah layanan konsumen dengan persediaan pengemudi di setiap area dalam jangka waktu tertentu. *Demand predict* yang akurat dari data manajemen lalu lintas yang kompleks sangat penting untuk membangun model prediksi dan memperoleh *insight* yang dapat digunakan menjadi salah satu alat bantu pengambilan keputusan bagi *stakeholders* bisnis transportasi *online*.

Model prediksi dapat dibangun menggunakan berbagai algoritma komputasi diantaranya *Naïve approach* dan *simple exponential smoothing* (Hoshmand, 2010), *auto regressive integrated moving average* yang diterapkan oleh (Bisgaard & Kulahci, 2011). Metode *Naïve approach* (NA) hanya cocok

untuk *dataset* deret waktu. Jika pola *dataset* deret waktu mengandung pola musiman, di mana nilai musim ini sama dengan musim lalu, maka metode NA dapat memberikan prediksi yang tepat (Yudaruddin, 2019). Metode *simple exponential smoothing* (SES) bergantung terhadap nilai aktual, nilai prediksi terbaru, dan nilai konstanta smoothing yang dinotasikan α . Penentuan nilai α ditentukan diantara 0 dan 1 (Hoshmand, 2010).

Naïve approach (NA) dalam simulasi data deret waktu kemiskinan menghasilkan hasil prediksi data kemiskinan tahun yang akan datang dengan nilai akurasi terbaik (Kumila et al., 2019). Metode *simple exponential smoothing* (SES) digunakan untuk analisis data *time series* pendapatan suatu perusahaan setiap waktunya menghasilkan nilai kesalahan terkecil (Maricar, 2019). Metode *auto regressive integrated moving average* (ARIMA) dalam memprediksi data *time series* harga saham menggunakan analisa pemodelan yang telah diuji diperoleh hasil metode yang optimal (Sismi & Darsyah, 2018).

Prediksi deret waktu arus lalu lintas sebagai upaya menuju sistem transportasi cerdas menggunakan ARIMA dengan model validasi dari *dataset* arus lalu lintas (kendaraan/5 menit) sepanjang hari, waktu puncak pagi hari (09.00-11.00 AM), dan waktu puncak malam hari (05.00-07.00 PM) secara terpisah kemudian hasilnya dibandingkan sehingga diperoleh hasil performa yang baik (Kumar & Hariharan, 2022). Penelitian oleh (Thabassum & M, 2021), perhitungan laju pertumbuhan lalu lintas di jalan raya nasional dengan 4 pendekatan berbeda yaitu laju pertumbuhan berdasarkan registrasi kendaraan dari mode transportasi jalan raya, tiga indikator ekonomi model SES, dan ARIMA sebagai model prediktor pembeda untuk menentukan parameter laju pertumbuhan lalu lintas. Hasil prediksi laju pertumbuhan lalu lintas menggunakan ARIMA lebih baik daripada SES karena hasil prediksi laju pertumbuhan lalu lintas rendah.

Perbandingan antara NA dan SES untuk menemukan model terbaik sehingga mendapatkan *insight* data terpola pada jumlah kunjungan pasien rawat jalan kategori mandiri atau umum dan menggunakan Bantuan Penyelenggara Jaminan Sosial (BPJS). Performansi model prediktor menggunakan MSE dan MAPE. Model NA lebih cocok untuk *dataset* yang digunakan daripada model SES (Basri & Sumitra, 2019). Penelitian oleh (Ariffin et al., 2013), telah dibandingkan kemampuan model prediktor ARIMA dan *Exponential Smoothing* untuk membuat prediksi dengan jumlah sumber data dan waktu waktu yang berbeda. Model ARIMA menghasilkan prediksi yang lebih baik untuk sumber data yang tidak dibatasi dan deret waktu yang lama, sedangkan untuk sumber data yang dibatasi interval dan deret waktu yang pendek lebih baik model *Exponential Smoothing*.

Penelitian ini memiliki kebaruan dan kelebihan yaitu (i) menggunakan tiga model prediktor berbeda dan selanjutnya dibandingkan untuk

memperoleh model terbaik (ii) menggunakan data deret waktu permintaan (*demand*) layanan transportasi *online* dari *dataset geohash6* berdasarkan sistem *geocode* lokasi geografi *latitude* dan *longitude*, (iii) *dataset* deret waktu dari 0 hingga 23 jam dengan interval waktu per 15 menit setiap jam (0, 15, 30, 45), (iv) evaluasi performansi menggunakan *root mean square error* (RMSE), *mean absolute error* (MAE), dan *mean absolute percentage error* (MAPE).

Prediksi permintaan transportasi *online* merupakan suatu bagian penyusun penting untuk memungkinkan sistem transportasi cerdas di dalam *smart city*. Model prediksi yang akurat dapat membantu kota terlebih dahulu mengalokasikan sumber daya untuk memenuhi permintaan perjalanan dan mereduksi setiap taksi yang kosong di jalan-jalan yang membuang energi dan memperburuk kemacetan lalu lintas (Yao et al., 2018).

Dengan meningkatnya popularitas layanan permintaan transportasi *online*, diperoleh pengumpulan data permintaan transportasi *online* skala besar secara kontinu. Pertanyaan tentang bagaimana memanfaatkan *big data* untuk memprediksi dengan lebih baik permintaan lalu lintas telah menarik perhatian yang tinggi di dalam komunitas *artificial intelligence* (AI). Problem prediksi permintaan transportasi *online* yaitu bagaimana cara memprediksi jumlah permintaan transportasi *online* untuk wilayah tertentu dalam *timestamp* di masa depan dengan menggunakan data histori permintaan transportasi *online* (Yao et al., 2018).

Penelitian ini untuk pelaku bisnis transportasi *online* yang memiliki tantangan jangka panjang diantaranya kurangnya konektivitas dan transparansi logistik. Karena itu dibutuhkan percepatan digitalisasi aktifitas pelayanan konsumen dan persediaan pengemudi setiap area dalam jangka waktu tertentu melalui pemanfaatan teknologi dan analisa data. Sehingga semua proses dan indikator aktifitas pelayanan konsumen dan persediaan pengemudi dapat dimonitor dan dievaluasi. Melalui penelitian ini diharapkan mampu memberikan prediksi yang tepat antara permintaan konsumen yang diterima terhadap persediaan pengemudi setiap area menggunakan deret waktu.


METODE

Dalam penelitian, data yang digunakan merupakan *dataset* manajemen lalu lintas. Data ini berkaitan dengan bagaimana dapat mengurai kemacetan lalu lintas untuk jalan-jalan di Asia Tenggara dengan memanfaatkan data permintaan pemesanan Grab. *Dataset* penelitian berupa 5 sampel acak dari *dataframe column geohash6*. Lokasi penelitian di Universitas Islam Lamongan dengan data yang dikumpulkan dari <https://github.com/hkwi/python-geohash>. Data penelitian yang digunakan ditampilkan pada Tabel 1.

Tabel 1. Sampel Acak *Dataframe Column Geohash6*

No	Geohash6	Day	Timestamp <hour>:<minute>	Demand Normalised in the range [0,1]
1	qp03wc	18	20:0	0.020072
2	qp03qn	10	14:30	0.024721
3	qp09sw	9	6:15	0.102821
4	qp0991	32	5:0	0.088755
5	qp090q	15	4:0	0.074468

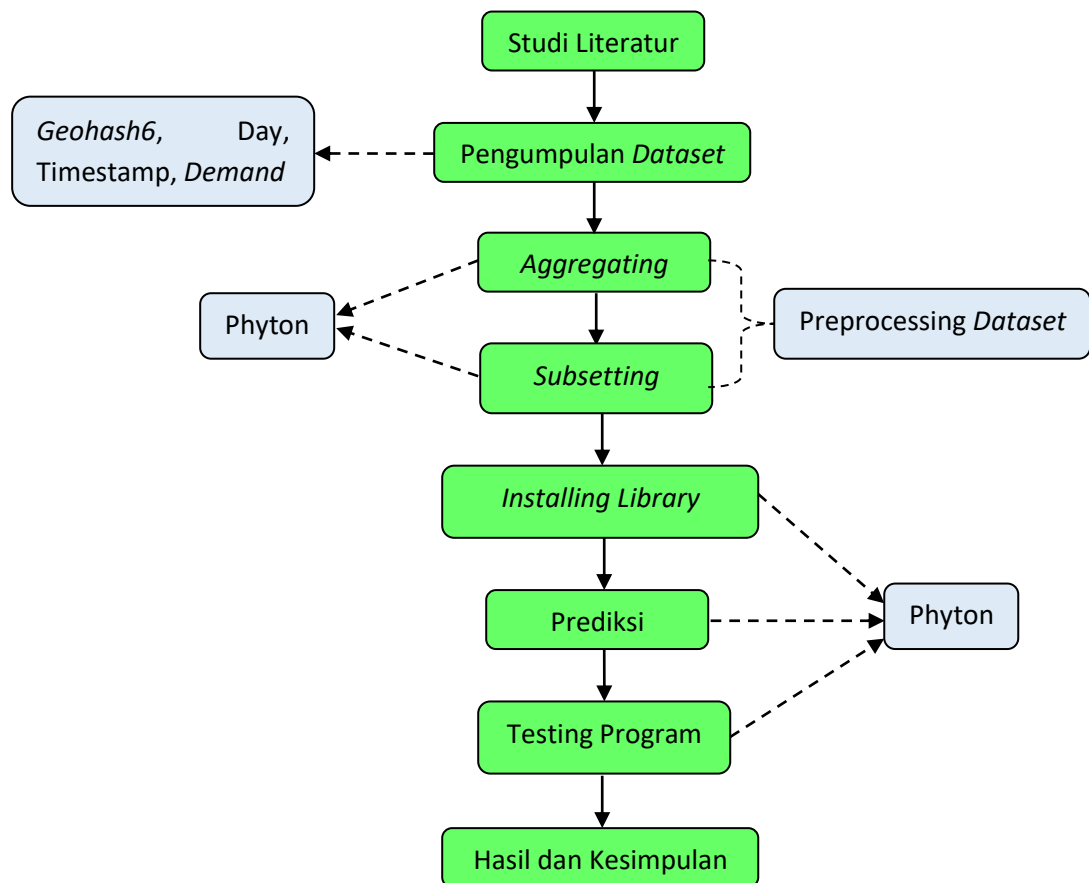
Sebelum sampel acak *geohash6* dilatih dan diuji menjadi informasi yang diinginkan, sampel acak *geohash6* perlu dilakukan *groupby* pada masing-masing *dataset* dengan mengambil *column* 'day' dan untuk *column* 'demand' menggunakan rata-rata sehingga diketahui pada setiap hari hingga 60 hari ke depan berapa rata-rata *demand* penumpang pada masing-masing *dataset* *geohash6*. Dalam penelitian ini, sampel dari *geohash6* yang dipilih dan ditampilkan pada Gambar 1 merupakan visualisasi 'demand' hingga 60 hari ke depan dengan kode qp099.



Gambar 1. Visualisasi *Dataset 'Demand' qp0991*

Tahapan-tahapan yang diterapkan dalam penelitian (1) studi literatur dilakukan setelah identifikasi masalah dari berbagai sumber referensi untuk mendukung pengerjaan penelitian. (2) Pengumpulan *dataset* berupa histori jumlah layanan permintaan (*demand*) per hari selama dua bulan yang terdiri dari empat atribut yaitu *geohash6* (geohash level 6), *day*, *timestamp*, *demand*. (3) *Preprocessing dataset* berupa tahapan proses *subsetting* yaitu menentukan persentase data latih dan data uji serta tahapan proses *aggregating dataset* sebelum diterapkan metode peramalan yang berbeda yaitu *metode simple exponential smoothing* (SES), *naïve approach* (NA), dan *auto regressive integrated moving average* (ARIMA). Persentase dalam proses *subsetting* untuk data latih sebesar 67% sedangkan persentase data uji sebesar 33%. Proses *aggregating dataset* berbasis secara harian (*daily*). (4) *Installing library* dengan tujuan agar dapat melakukan prediksi menggunakan tiga metode peramalan yang berbeda. *Tool* bahasa pemrograman yang digunakan dalam penelitian adalah *Python Jupyter Notebook*. (5) Prediksi dan testing program dengan menerapkan metode peramalan yang berbeda yaitu metode SES, NA dan auto ARIMA untuk mengenali pola-pola *dataset* setelah dilakukan *preprocessing dataset*. (6) Hasil dan kesimpulan sebagai evaluasi terhadap performa dari tiga metode peramalan maka dilakukan perhitungan nilai keakuratan prediksinya

menggunakan RMSE, MAE, dan MAPE sesuai yang terapkan oleh (Peng & Xiang, 2020) (Chen et al., 2021). Secara umum metodologi penelitian ini dapat dilihat pada Gambar 2.



Gambar 2. Metodologi Penelitian

Naïve Approach

Metode NA memberikan hasil prediksi yang sama dengan nilai observasi masa lalu, secara matematis, didefinisikan sebagai berikut (Ahuja & Kumar, 2022) (Hoshmand, 2010):

$$y_{t+1} = y_t \quad (1)$$

dengan y_t adalah *dataset* observasi masa lalu ke- t , y_{t+1} adalah *dataset* hasil prediksi atau estimasi ke- $t + 1$, dan t adalah deret waktu *dataset demand*.

Metode NA mengasumsikan bahwa nilai observasi terbaru adalah satu-satunya yang penting, dan semua observasi sebelumnya tidak memberikan informasi untuk masa depan. Hal ini dapat dianggap sebagai rata-rata tertimbang di mana semua bobot diberikan pada observasi terakhir (Hyndman & Athanapoulos, 2018).

Model persamaan (1) sangat berguna ketika data historis aktual berubah sangat lambat dan dengan sedikit titik balik. Namun, keterbatasan model persamaan (1) adalah prediksi masa depan hanya bergantung pada masa lalu dan adanya keacakan yang signifikan dalam data (Hoshmand, 2010).

Simple Exponential Smoothing

Metode SES secara umum digunakan sebagai metode peramalan yang cocok untuk data deret waktu (Ramesh et al., 2018). Dalam metode ini untuk nilai bobot naik dipengaruhi oleh nilai data aktual waktu sekarang dan nilai bobot turun secara eksponensial karena pengaruh nilai prediksi pada waktu sebelumnya (Aminifar et al., 2014).

Formula matematis metode SES didefinisikan (Ramesh et al., 2018) (Hoshmand, 2010):

$$y_{t+1} = \alpha y_t + (1 - \alpha)y_{t-1} \quad (2)$$

dengan y_{t+1} adalah *dataset* prediksi yang diperoleh dari waktu $t + 1$, α adalah nilai konstanta *smoothing*, y_t adalah *dataset* aktual yang diobservasi dalam waktu t , dan y_{t-1} adalah *dataset* prediksi sebelumnya di waktu $t - 1$.

Persamaan (2) menunjukkan bahwa metode SES bergantung pada tiga bagian *dataset* yaitu aktual terbaru, prediksi sebelumnya, dan konstanta *smoothing*. Nilai yang ditetapkan untuk konstanta *smoothing* adalah yang paling berpengaruh terhadap hasil prediksi (Hoshmand, 2010).

Konstanta *smoothing* α berfungsi sebagai faktor pembobot. Ketika α mendekati 0, prediksi baru sangat mirip dengan prediksi lama. Ketika α mendekati 1, prediksi baru akan menyertakan penyesuaian substansial untuk setiap *error* yang terjadi pada prediksi sebelumnya (Ostertagová & Ostertag, 2012).

Konstanta *smoothing* α bukanlah pilihan sembarang tetapi secara umum berada di antara 0.1 dan 0.5. Nilai α yang rendah digunakan ketika rata-rata yang mendasarinya cenderung stabil; nilai yang lebih tinggi digunakan ketika rata-rata yang mendasarinya rentan terhadap perubahan (Ostertagová & Ostertag, 2012).

Auto Regressive Integrated Moving Average

Metode ARIMA merupakan generalisasi metode *auto regressive moving average* (ARMA) karena metode ARMA hanya dapat digunakan untuk deret waktu stasioner. Namun dalam praktek penerapannya banyak deret waktu yang bersifat non-stasioner seperti deret waktu yang memuat *trend* dan pola musiman. Dalam metode ARIMA, deret waktu non-stasioner dibuat menjadi stasioner dengan menerapkan *differencing* berhingga dari *dataset* (Adhikari & Agrawal, 2013).

Formula metode ARIMA didefinisikan (Bisgaard & Kulahci, 2011):

$$z_t = \sum_{i=1}^{p+d} \varphi_i z_{t-i} + a_t - \sum_{i=1}^q \theta_i a_{t-i} \quad (3)$$

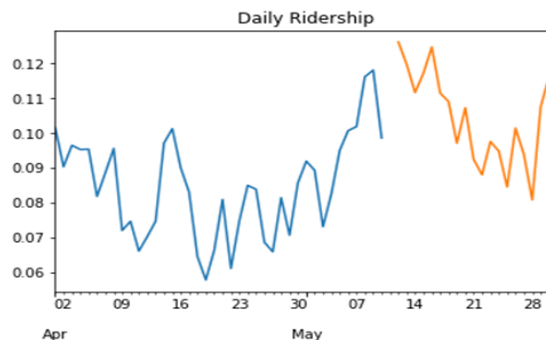
dengan z_t adalah variabel terikat dalam waktu t , p adalah *auto regressive* (AR), d adalah *differencing* atau *integration* (I), q adalah *moving average* (MA), φ_i

adalah koefisien *computed regression* ke- i , z_{t-i} adalah variabel bebas dalam waktu $t - i$, a_t adalah *random error* dalam waktu t , θ_i adalah parameter MA terprediksi atau terestimasi dalam waktu t , dan a_{t-i} adalah *error* dalam $t - i$.

Bagian AR dalam ARIMA menunjukkan deret waktu terregresi terhadap data masa lalunya sendiri. Bagian I dari ARIMA menunjukkan nilai data yang terganti dengan nilai d yang berbeda untuk mendapatkan data yang stasioner, yang merupakan syarat dari pendekatan model ARIMA. Bagian MA dari ARIMA mengindikasikan bahwa *error* prediksi adalah kombinasi linear dari *error* yang terjadi di masa lalu (Kotu & Deshpande, 2019).

HASIL DAN PEMBAHASAN

Sebelum proses prediksi, *dataset* qp0991 ditentukan persentase data latih dan data uji sehingga harus melalui proses *subsetting* dengan menggunakan index sebesar 67 % sebagai data latih sedangkan untuk data uji sebesar 33 % seperti pada Gambar 3 menunjukkan *dataset* qp0991 untuk data latih garis grafik berwarna biru mulai tanggal 1 April 2018 hingga 10 Mei 2018, sedangkan *dataset* qp0991 untuk data uji garis grafik berwarna orange mulai tanggal 11-31 Mei 2018.

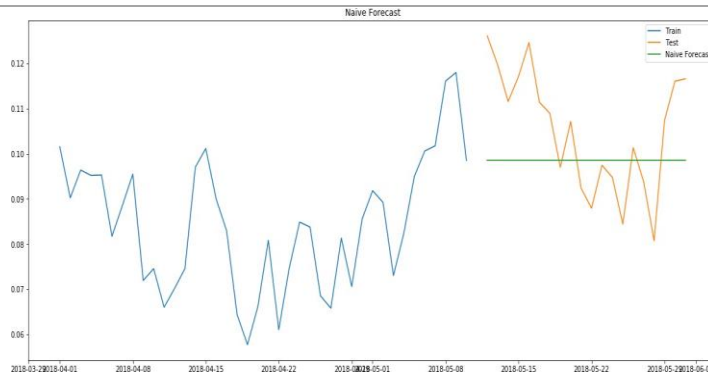


Gambar 3. *Subsetting Dataset 'Demand' qp0991*

Berikutnya adalah prediksi menggunakan tiga metode peramalan yang berbeda dan hasilnya ditampilkan dalam bentuk grafik dua dimensi.

1. *Naïve Approach*


Metode *naïve approach* (NA) memberikan akurasi RMSE dengan nilai optimalisasi sebesar 0.014, akurasi MAE sebesar 0.012 dan akurasi MAPE sebesar 11.4. Plot hasil prediksi ditampilkan dalam bentuk 2 dimensi pada Gambar 4 menunjukkan garis berwarna hijau berada dinilai hari terakhir dan memperkirakan nilai yang sama untuk hari berikutnya.



Gambar 4. Prediksi Dataset 'Demand' qp0991 dengan Naive Approach

2. Simple Exponential Smoothing

Metode *simple exponential smoothing* (SES) memberikan akurasi RMSE, MAE, dan MAPE berturut-turut sebesar 0.013, 0.011, dan 11.19. *Plot* hasil prediksi ditampilkan dalam bentuk 2 dimensi pada Gambar 5 dengan garis berwarna hijau berada di *weighted averages*.



Gambar 5. Prediksi Dataset 'Demand' qp0991 dengan SES

3. Auto Regressive Integrated Moving Average

Metode *auto regressive integrated moving average* (ARIMA) yang digunakan adalah *seasonal auto regressive integrated moving average* (SARIMA) dengan memilih parameter sesuai dengan pola *auto correlation function* (ACF) dan *partial auto correlation function* (PACF) memberikan akurasi RMSE 0.046, akurasi MAE 0.04 dan akurasi MAPE 40.46. *Plot* hasil prediksi ditampilkan dalam bentuk 2 dimensi pada Gambar 6 dengan garis berwarna hijau sebagai garis prediksi merupakan level yang menunjukkan *weighted averages* antara pengamatan yang disesuaikan secara musiman dan perkiraan non-musiman.



Gambar 6. Prediksi Dataset ‘Demand’ qp0991 dengan ARIMA

Hasil optimalisasi metode-metode peramalan untuk memprediksi dataset ‘demand’ qp0991 ditampilkan pada Tabel 2.

Tabel 2. Nilai Akurasi

No	Metode	Nilai Akurasi		
		RMSE	MAE	MAPE
1	<i>Naïve Approach</i>	0.014	0.012	11.4
2	<i>Simple Exponential Smoothing</i>	0.013	0.011	11.19
3	<i>Auto Regressive Integrated Moving Average</i>	0.046	0.04	40.46

Berdasarkan Tabel 2 diperoleh informasi bahwa metode *simple exponential smoothing* memberikan akurasi terbaik dengan RMSE, MAE, dan MAPE secara berturut-turut terkecil yaitu 0.013, 0.011, dan 11.19. Dengan kata lain tingkat kebenaran prediksinya berturut-turut mencapai 98.7%, 98.9%, dan 88.81%. Sedangkan hasil prediksi dari metode *naïve approach* diperoleh RMSE 0.014 atau tingkat kebenaran prediksi 98.6%, MAE 0.012 atau tingkat kebenaran prediksi 98.8%, dan MAPE 11.4 atau tingkat kebenaran prediksi 88.6%.

Di sisi lain metode *auto regressive integrated moving average* memperoleh nilai RMSE 0.046 atau tingkat kebenaran prediksi 95.4%, nilai MAE 0.04 atau tingkat kebenaran prediksi 96%, dan nilai MAPE 40.46 atau 59.54%. Metode *auto regressive integrated moving average* memberikan nilai akurasi lebih rendah daripada metode *simple exponential smoothing* dan *naïve approach*.

KESIMPULAN DAN SARAN

Penelitian ini menggunakan tiga metode peramalan untuk memprediksi dataset ‘demand’ qp0991, yaitu metode *naïve approach*, *simple exponential smoothing*, dan *auto regressive integrated moving average*. Persentase dataset ‘demand’ qp0991 untuk data latih 67% dan untuk data uji 33%. Hasil prediksi dengan *naïve approach* menunjukkan garis berwarna hijau berada di nilai hari terakhir dan memperkirakan nilai yang sama untuk hari berikutnya. Sedangkan dari hasil prediksi dengan *simple exponential smoothing* menunjukkan garis berwarna hijau berada di *weighted averages*. Garis berwarna

hijau menunjukkan *weighted averages* antara pengamatan yang disesuaikan secara musiman dan perkiraan non-musiman untuk hasil prediksi dengan *auto regressive integrated moving average*. Dari ketiga metode peramalan tersebut, *simple exponential smoothing* memberikan akurasi terbaik dengan RMSE 0.013, MAE 0.011, dan MAPE 11.19, dengan kata lain tingkat kebenaran identifikasinya mencapai 98.7% untuk RMSE, 98.9% untuk MAE, dan 88.81% untuk MAPE. Untuk penelitian selanjutnya perlu dilakukan dengan menggunakan metode-metode peramalan yang lain, ataupun metode lain untuk prediksi misalkan menggunakan *machine learning* atau *deep learning*.

DAFTAR PUSTAKA

- Adhikari, R., & Agrawal, R. . (2013). An Introductory Study on Time Series Modeling and Forecasting Ratnadip Adhikari R. K. Agrawal. *ArXiv Preprint ArXiv:1302.6613, 1302.6613*, 1–68.
- Ahuja, S., & Kumar, A. (2022). Expectation-Based Probabilistic Naive Approach for Forecasting Involving Optimized Parameter Estimation. *Arabian Journal for Science and Engineering*.
<https://doi.org/10.1007/s13369-022-06819-0>
- Aminifar, F., Shahidepour, M., Fotuhi-Firuzabad, M., & Kamalinia, S. (2014). Power system dynamic state estimation with synchronized phasor measurements. *IEEE Transactions on Instrumentation and Measurement*, 63(2), 352–363. <https://doi.org/10.1109/TIM.2013.2278595>
- Ara, Z., & Hashemi, M. (2021). Ride hailing service demand forecast by integrating convolutional and recurrent neural networks. *Proceedings of the International Conference on Software Engineering and Knowledge Engineering, SEKE, 2021-July(MI)*, 441–446. <https://doi.org/10.18293/SEKE2021-009>
- Ariffin, W. K., Ahmad, W., & Ahmad, S. (2013). Arima model and exponential smoothing method: A comparison. *AIP Conference Proceedings*, 1522(1), 1312–1321. <https://doi.org/10.1063/1.4801282>
- Basri, K. I., & Sumitra, I. D. (2019). Comparison of Forecasting the Number of Outpatients Visitors Based on Naïve Method and Exponential Smoothing. *IOP Conference Series: Materials Science and Engineering*, 662(4). <https://doi.org/10.1088/1757-899X/662/4/042002>
- Bisgaard, S., & Kulahci, M. (2011). *Time Series Analysis and Forecasting by Example* (First Editio). John Wiley & Sons, Inc.
- Chen, X., Chen, H., Yang, Y., Wu, H., Zhang, W., Zhao, J., & Xiong, Y. (2021). Traffic flow prediction by an ensemble framework with data denoising and deep learning model. *Physica A: Statistical Mechanics and Its Applications*, 565, 125574. <https://doi.org/10.1016/j.physa.2020.125574>
- Hoshmand, A. R. (2010). *Business Forecasting: A Practical Approach, Second Edition*.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting : Principles and Practice* (2nd Editio). Otexts. <https://otexts.org/fpp2/>
- Kotu, V., & Deshpande, B. (2019). *Time Series Forecasting*. <https://doi.org/10.1016/B978-0-12-814761-0.00012-5>

- Kumar, P. B., & Hariharan, K. (2022). Time Series Traffic Flow Prediction with Hyper-Parameter Optimized ARIMA Models for Intelligent Transportation System. *Journal of Scientific and Industrial Research*, 81(4), 408–415. <https://doi.org/10.56042/jsir.v8i04.50791>
- Kumila, A., Sholihah, B., Evizia, E., Safitri, N., & Fitri, S. (2019). Perbandingan Metode Moving Average dan Metode Naïve Dalam Peramalan Data Kemiskinan. *JTAM | Jurnal Teori Dan Aplikasi Matematika*, 3(1), 65. <https://doi.org/10.31764/jtam.v3i1.764>
- Lana, I., Del Ser, J., Velez, M., & Vlahogianni, E. I. (2018). Road Traffic Forecasting: Recent Advances and New Challenges. *IEEE Intelligent Transportation Systems Magazine*, 10(2), 93–109. <https://doi.org/10.1109/MITS.2018.2806634>
- Lin, M., & Dula, C. W. (2016). Case in Point Grab Taxi : Grab Taxi: Navigating New Frontiers. *Grab Taxi: Navigating New Frontiers*, 3(2), 40–45.
- Maricar, M. A. (2019). Analisa perbandingan nilai akurasi moving average dan exponential smoothing untuk sistem peramalan pendapatan pada Perusahaan XYZ. *Jurnal Sistem Dan Informatika*, 13(2), 36–45.
- Markou, I., Rodrigues, F., & Pereira, F. C. (2018). Real-Time Taxi Demand Prediction using data from the web. *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC, 2018-Novem*, 1664–1671. <https://doi.org/10.1109/ITSC.2018.8569015>
- Ostertagová, E., & Ostertag, O. (2012). Forecasting using simple exponential smoothing method. *Acta Electrotechnica et Informatica*, 12(3), 62–66. <https://doi.org/10.2478/v10198-012-0034-2>
- Peng, Y., & Xiang, W. (2020). Short-term traffic volume prediction using GA-BP based on wavelet denoising and phase space reconstruction. *Physica A: Statistical Mechanics and Its Applications*, 549, 123913. <https://doi.org/10.1016/j.physa.2019.123913>
- Ramesh, B., Madhusudanarao, R., Vamsi, V. H., & Kumari, S. V. R. L. (2018). Power system dynamic state estimation using exponential smoothing methods. *2018 3rd IEEE International Conference on Recent Trends in Electronics, Information and Communication Technology, RTEICT 2018 - Proceedings*, ii, 1202–1205. <https://doi.org/10.1109/RTEICT42901.2018.9012352>
- Sismi, & Darsyah, M. Y. (2018). Perbandingan Prediksi Harga Saham PT.BRI, Tbk dengan Metode ARIMA dan Moving Average. *Prosiding Seminar Nasional Mahasiswa Unimus*, 1(1), 351–360. <http://prosiding.unimus.ac.id/index.php/mahasiswa/article/view/170>
- Sunindyo, W. D., & Satria, A. S. M. (2020). Traffic congestion prediction using multi-layer perceptrons and long short-term memory. *EECCIS 2020 - 2020 10th Electrical Power, Electronics, Communications, Controls, and Informatics Seminar*, 209–212. <https://doi.org/10.1109/EECCIS49483.2020.9263483>
- Thabassum, S., & M, K. (2021). Time Series Modeling for Forecasting TRAFFIC GROWTH RATE. *Indian Road Congress Indian Highways*, 49(August), 37–42. <https://www.irc.nic.in>

-
- Yao, H., Wu, F., Ke, J., Tang, X., Jia, Y., Lu, S., Gong, P., Li, Z., Ye, J., & Chuxing, D. (2018). Deep multi-view spatial-temporal network for taxi demand prediction. *32nd AAAI Conference on Artificial Intelligence, AAAI 2018*, 2588–2595. <https://doi.org/10.1609/aaai.v32i1.11836>
- Yudaruddin, R. (2019). *Forecasting untuk Kegiatan Ekonomi dan Bisnis* (Edisi Pert). RV Pustaka Horizon.