

PERBANDINGAN METODE *HOLT WINTER'S EXPONENTIAL SMOOTHING* DAN *EXTREME LEARNING MACHINE* UNTUK PERAMALAN JUMLAH BARANG YANG DIMUAT PADA PENERBANGAN DOMESTIK DI BANDARA UTAMA SOEKARNO HATTA

Kevin Togos Parningotan Marpaung¹, Agus Rusgiyono², Yuciana Wilandari³

^{1,2,3}Departemen Statistika, Fakultas Sains dan Matematika, Universitas Diponegoro
kevinm0402@yahoo.com

DOI: 10.14710/j.gauss.11.3.439-446

Article Info:

Received: 2022-08-12

Accepted: 2022-11-18

Available Online: 2023-01-03

Keywords:

Forecasting; Loaded Goods; Main Airports; Holt Winter's Exponential Smoothing; Extreme Learning Machine; sMAPE.

Abstract: The loading of goods carried out at the airport is an essential part of the transporting goods system. In this regard, it is necessary to have a prediction to make the right policy or to solve the problems that occur. Holt Winter's Exponential Smoothing, which one of the classic methods of analyzing time series data, and Extreme Learning Machine which is part of the artificial neural network method, are methods that can be used as a tool for forecasting problems. Holt Winter's Exponential Smoothing uses three times of smoothing on related data, which are level smoothing, trend smoothing, and season smoothing, while Extreme Learning Machine goes through three stages, which are normalization, training, and denormalization. In measuring the error rate in related forecasting, the symmetric Mean Absolute Percentage Error (sMAPE) value is used. The Holt Winter's Exponential Smoothing method Additive model produces a sMAPE value of 26.14%; while the Multiplicative model with the same method resulted in the sMAPE value of 25.69%. For the Extreme Learning Machine method, the sMAPE value is 49.85%. Based on the accuracy test using the sMAPE value, Holt Winter's Exponential Smoothing method Multiplicative model is the better method than Extreme Learning Machine.

1. PENDAHULUAN

Pemuatan barang merupakan hal yang sangat penting untuk keberlangsungan hidup manusia. Terutama sebagai pendukung kegiatan perekonomian masyarakat. Selain itu tentu saja transportasi angkutan barang merupakan elemen yang memudahkan masyarakat dalam aktivitas sehari-hari. Kontribusi pemuatan barang juga semakin penting dan dapat terlihat dari upaya-upaya yang dilakukan oleh berbagai pihak dalam usaha peningkatan sistem yang berlaku serta kapasitas barang yang diangkut.

Salah satu moda pengangkutan yang digunakan untuk pengangkutan barang menggunakan pesawat terbang baik pesawat sipil, maupun pesawat kargo. Hal ini dikarenakan pesawat terbang memiliki jangkauan jarak yang cukup jauh, tidak hanya antar kota, ataupun provinsi, pesawat terbang dapat mencakup jarak antar pulau, antar negara, bahkan antar benua. Selain itu pesawat terbang tidak memakan waktu tempuh yang lama dibandingkan moda transportasi lainnya. Hal tersebut dikarenakan pesawat memiliki jalur yang relatif lebih bebas hambatan.

Peramalan untuk data *time series* yang berindikasi *seasonal* atau musiman dan *trend* mengalami sejumlah pengembangan, salah satu metode yang cukup relevan dengan kemajuan penelitian masa kini adalah metode *Holt Winter's Exponential Smoothing*. Metode terkait memiliki keunggulan dalam analisis dengan adanya tiga langkah pemulusan, yaitu pemulusan pada level, pemulusan pada tren, dan pemulusan pada tren, sehingga

memprediksi tingkat kesalahan yang relatif kecil. Oleh karena itu, penelitian ini menggunakan metode *Holt Winter's Exponential Smoothing*, mengikuti asumsi awal pola data penelitian.

Metode jaringan syaraf tiruan (*artificial neural network*), juga merupakan metode yang digunakan dalam peramalan kali ini selain metode statistika klasik tersebut, yakni sistem *artificial intelligence*, dengan kemampuan menganalisis pola data untuk menghasilkan prediksi. *Extreme Learning Machine* (ELM) merupakan salah satu metode jaringan syaraf tiruan dengan kecepatan belajar yang relatif tinggi dan akurasi yang relatif tinggi.

Oleh karena itu, dilakukan penelitian untuk memprediksi jumlah barang yang dimuat di bandara utama Soekarno-Hatta berdasarkan data *time-series* dari Januari 2016 hingga Januari 2022. Penelitian kali ini juga menggunakan nilai *symmetric Mean Absolute Percentage Error* (sMAPE) sebagai kriteria metode yang lebih baik. Tujuan dari penelitian ini adalah untuk membandingkan metode *Holt Winter's Exponential Smoothing* dan metode *Extreme Learning Machine* dengan hasil prediksi jumlah barang yang dimuat di Bandara Soekarno-Hatta pada penerbangan domestik untuk menentukan metode yang paling baik.

2. TINJAUAN PUSTAKA

Bandar udara mempunyai kapasitas tertentu pada barang yang dimuatnya. Kapasitas itu dapat dipergunakan dengan baik bila barang yang dimuat terdapat tidak terlalu jauh, ataupun terlalu dekat dengan kapasitas bandar udara tersebut.

Peramalan adalah prediksi nilai-nilai sebuah variabel berdasarkan nilai yang diketahui dari variabel tersebut atau variabel yang berhubungan (Makridakis, 1995). Dalam melakukan peramalan, hal yang pertama kali harus dilakukan adalah mengkaji data pada periode yang lalu.

Analisis runtun waktu merupakan metode yang bertujuan untuk menganalisis rangkaian data *time series* dan memiliki asumsi bahwa dengan data historis dari series tersebut dapat diidentifikasi pola dasarnya dan kombinasi pola tersebut selalu berulang di masa yang akan datang (Ishak, 2010). Runtun waktu adalah serangkaian pengamatan dari suatu variabel yang direkam dan dicatat sesuai dengan urutan dari waktu ke waktu menurut urutan kejadian dalam periode waktu tertentu (Wei, 2006).

Metode *exponential smoothing* atau disebut juga sebagai prosedur pemulusan eksponensial, merupakan metode yang menampilkan pembobotan menurun secara eksponensial terhadap nilai pengamatan sebelumnya (Mahkya et al., 2014). Menurut Arisoma et al., (2019) terdapat tiga parameter pemulusan. Dengan nilai untuk masing-masing parameter antara 0 hingga 1 yaitu α (untuk elemen level dari proses), β (untuk elemen tren), dan γ (untuk elemen musiman). Menurut Montgomery (2015), terdapat dua model metode *Holt Winter's Exponential Smoothing* yaitu:

1. *Holt-Winter's Additive Model*

a. Pemulusan untuk level

$$L_t = \alpha(X_t - S_{t-s}) + (1 - \alpha)(L_{t-1} - b_{t-1}) \quad (1)$$

b. Pemulusan untuk tren

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (2)$$

c. Pemulusan untuk musiman

$$S_t = \gamma(X_t - L_t) + (1 - \gamma)S_{t-s} \quad (3)$$

d. Prediksi untuk m periode ke depan

$$F_{t+m} = L_t + mb_t + S_{t+m-s} \quad (4)$$

2. Holt-Winter's Multiplicative Model

a. Pemulusan untuk level

$$L_t = \alpha \left(\frac{X_t}{S_{t-s}} \right) + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (5)$$

b. Pemulusan untuk tren

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (6)$$

c. Pemulusan untuk musiman

$$S_t = \gamma \frac{X_t}{L_t} + (1 - \gamma)S_{t-s} \quad (7)$$

d. Prediksi untuk m periode ke depan

$$F_{t+m} = (L_t + mb_t)S_{t+m-s} \quad (8)$$

Keterangan berdasarkan persamaan metode *Holt Winter's Exponential Smoothing* baik model *multiplicative* maupun *additive* dapat dijelaskan sebagai berikut:

L_t adalah estimasi level deret data untuk periode t

α adalah konstanta pemulusan untuk elemen level dari proses, $0 \leq \alpha \leq 1$

X_t adalah data pada periode t

b_t adalah perkiraan kemiringan tren untuk periode t

β adalah konstanta pemulusan untuk elemen tren, $0 \leq \beta \leq 1$

S_t adalah perkiraan panjang musiman periode t

γ adalah konstanta pemulusan untuk elemen musiman, $0 \leq \gamma \leq 1$

m adalah jumlah periode mendatang untuk diprediksi

Jaringan syaraf tiruan (JST) atau artificial neural network (ANN) merupakan sistem jaringan yang dirancang agar menyerupai sistem kinerja otak manusia dengan tujuan untuk melaksanakan tugas tertentu (Haykin, 2009). Metode ELM dikembangkan berdasarkan metode *Single Hidden Layer Feedforward Neural Networks* (SLFNs). Metode ini dikembangkan dengan tujuan untuk mengatasi permasalahan yang dihadapi oleh jaringan syaraf tiruan lainnya terutama dalam hal kecepatan belajar. Metode ini memungkinkan untuk secara acak memilih parameter seperti bobot input dan *hidden bias*, sehingga metode ini memiliki kecepatan belajar memberikan kinerja generalisasi yang baik (Huang, 2006).

1. Normalisasi

Salah satu metode pada proses ini adalah metode normalisasi minimum-maksimum. Berikut adalah rumus yang digunakan dalam proses normalisasi data normalisasi minimum-maksimum (Nasution et al., 2019).

$$d' = \frac{y_t - D_{min}}{D_{max} - D_{min}} (D_{maxb} - D_{minb}) + D_{minb} \quad (9)$$

2. Training

Proses *training* adalah proses yang harus dilalui sebelum dilakukannya proses prediksi (Huang et al., 2006). Berikut adalah langkah-langkah proses *training* (Giusti et al., 2018):

- a. Inisialisasi semua bobot input secara acak dalam rentang -1 hingga 1.
- b. Mengalikan input data yang dinormalisasi dengan matriks bobot input untuk menghitung output dari *hidden layer*.

$$h_j = \left(\sum_k^n w_{jk} \times x_{ik} \right) b_j \quad (10)$$

- c. Menggunakan fungsi aktivasi sigmoid biner untuk menghitung output dari *hidden layer*.

$$H(x) = \frac{1}{1 + e^{-x}} \quad (11)$$

- d. Menghitung \mathbf{H}^+ , ini adalah matriks umum *Inverse Moore-Penrose* yang menghitung invers dari matriks $\mathbf{H}(x)$.

$$\mathbf{H}^+ = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \quad (12)$$

- e. Menghitung *output weight*.

$$\boldsymbol{\beta} = \mathbf{H}^+ \mathbf{T} \quad (13)$$

- f. Menghitung luaran *output layer*.

$$y = \mathbf{H} \boldsymbol{\beta} \quad (14)$$

3. Denormalisasi

Proses denormalisasi digunakan untuk menghasilkan nilai asli (Giusti et al., 2018).

$$d = d'(D_{max} - D_{min}) + D_{min} \quad (15)$$

Keterangan berdasarkan persamaan metode *Extreme Learning Machine* dapat dijelaskan sebagai berikut:

d'	adalah nilai data setelah normalisasi
y_t	adalah nilai data asli untuk periode t
D_{min}	adalah nilai minimum dari data asli
D_{max}	adalah nilai maksimum dari data asli
D_{minb}	adalah nilai yang ditetapkan sebagai nilai minimum baru
D_{maxb}	adalah nilai yang ditetapkan sebagai nilai maksimum baru
h_j	adalah komponen luaran ke-j
i	[1, 2, ..., N], di mana N adalah keseluruhan jumlah data
j	[1, 2, ..., \tilde{N}], di mana \tilde{N} adalah banyaknya <i>hidden neuron</i>
n	adalah jumlah <i>input neuron</i>
w	adalah bobot <i>input</i>
x	adalah <i>input</i> data yang digunakan
b	adalah nilai bias
\mathbf{H}^+	adalah matriks <i>Moore Penrose Generalized Invers</i>
\mathbf{H}^T	adalah matriks H yang telah ditranspose
$\boldsymbol{\beta}$	adalah matriks bobot <i>output</i>
\mathbf{T}	adalah matriks target
y	adalah <i>output</i> sebagai hasil prediksi

- d adalah nilai setelah denormalisasi
- d' adalah nilai sebelum denormalisasi
- D_{min} adalah nilai minimum data asli
- D_{max} adalah nilai maksimum data asli

Salah satu acuan yang dapat digunakan untuk evaluasi ketepatan model yaitu nilai *symmetric Mean Absolute Percentage Error* (sMAPE). Menurut Chen et al., (2017), berikut merupakan rumus perhitungan sMAPE:

$$sMAPE = \frac{1}{n} \left(\sum_{t=1}^n \frac{|X_t - F_t|}{(X_t + F_t)/2} \right) \times 100\% \quad (16)$$

Keterangan berdasarkan persamaan evaluasi ketepatan model sMAPE dapat dijelaskan sebagai berikut:

- n adalah banyaknya observasi
- X_t adalah data asli periode ke-t
- F_t adalah ramalan untuk periode ke-t

Menurut Chang et al., (2007) kriteria ketepatan model peramalan berdasarkan nilai sMAPE antara lain, bila nilai sMAPE $\leq 10\%$ hasil peramalan dapat dikatakan “Sangat Baik”, bila nilai sMAPE $10\% < sMAPE \leq 20\%$ hasil peramalan dapat dikatakan “Baik”, bila nilai sMAPE $20\% < sMAPE \leq 50\%$ hasil peramalan dapat dikatakan “Cukup Baik”, dan bila nilai sMAPE $> 50\%$ hasil peramalan dapat dikatakan “Buruk”.

3. METODE PENELITIAN

Populasi untuk penelitian kali ini adalah jumlah total barang yang dimuat pada penerbangan domestik di Bandara Soekarno Hatta. Sampel yang digunakan dalam penelitian ini adalah jumlah produk yang dimuat di Bandara Soekarno Hatta untuk penerbangan domestik dari bulan Januari 2016 sampai dengan Januari 2022.

Variabel pada penelitian ini adalah jumlah barang yang menunjukkan banyaknya barang yang dimuat pada Bandara Soekarno Hatta. Banyak data yang digunakan adalah sebanyak 73 data dalam bulan selama 6 tahun.


1. Tahapan Penelitian untuk metode *Holt Winter's Exponential Smoothing*
 - a. Melakukan proses *input* data.
 - b. Mengidentifikasi perihal adanya pola *trend* dan musiman pada data tersebut.
 - c. Melakukan *training* pada data.
 - d. Mengestimasi nilai parameter pemulusan.
 - e. Membandingkan nilai parameter pemulusan.
 - f. Melakukan peramalan.
 - g. Menentukan nilai akurasi menggunakan *sMAPE*.
 - h. Pemilihan model terbaik.
2. Tahapan Penelitian untuk metode *Extreme Learning Machine*
 - a. Melakukan *input* data.
 - b. Melakukan proses normalisasi.
 - c. Melakukan *training* pada data.
 - d. Mencari nilai peramalan berdasarkan hasil dari *training*.
 - e. Melakukan proses denormalisasi menjadi nilai asli.
 - f. Menentukan nilai akurasi menggunakan *sMAPE*.

4. HASIL DAN PEMBAHASAN

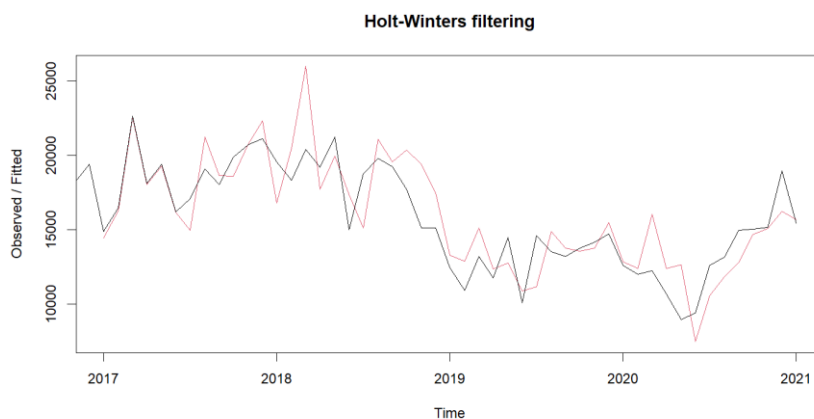
Berdasarkan nilai parameter pemulusan model *additive* $\alpha = 0,6422694$; $\beta = 0$; dan $\gamma = 1$; serta parameter pemulusan model *multiplicative* $\alpha = 0,6801895$; $\beta = 0$; dan $\gamma = 1$; diperoleh hasil peramalan dari masing-masing model seperti pada Tabel 1. Perbandingan antara data prediksi dengan aktual cukup mendekati, baik pada model *additive*, maupun model *multiplicative*, perbandingan tersebut dapat dilihat dari Gambar 1, dan Gambar 2.

Tabel 1. Hasil Peramalan Metode *Holt Winter's Exponential Smoothing*

Periode	Model <i>Additive</i>	Model <i>Multiplicative</i>
Februari 2021	15140,64	15048,64
Maret 2021	18153,82	18265,83
April 21	17805,81	17504,63
Mei 2021	18768,92	18231,75
Juni 2021	16745,09	16117,32
Juli 2021	18670,18	18968,12
Agustus 2021	18327,52	18330,55
September 21	18601,85	18634,16
Oktober 2021	18317,05	18405,08
November 2021	18340,68	18449,05
Desember 2021	20399,42	20680,25
Januari 2022	17225,02	17003,79



Gambar 1. Grafik Perbandingan Data Aktual dan Data Prediksi Model *Additive*




Gambar 2. Grafik Perbandingan Data Aktual dan Data Prediksi Model *Multiplicative*

Metode normalisasi *Min-Max Normalization* menggunakan *range* -1 sampai dengan 1, serta 12 *node input* yang mewakili jumlah bulan pada data *input* yang digunakan, *hidden node* sebanyak 47 *node*, dan *output node* sebesar 1 *node*, dihasilkan data pemalan seperti pada Tabel 2. Perbandingan antara data prediksi dengan aktual cukup jauh, perbandingan tersebut dapat dilihat dari Gambar 3.

Tabel 2. Hasil Peramalan Metode *Extreme Learning Machine*

Periode	Hasil Prediksi
Februari 2021	9406,509
Maret 2021	9005,835
April 21	8643,838
Mei 2021	8270,434
Juni 2021	7664,815
Juli 2021	8195,917
Agustus 2021	7774,845
September 21	8272,573
Oktober 2021	8036,560
November 2021	7989,601
Desember 2021	8365,969
Januari 2022	8021,099



Gambar 3. Grafik Perbandingan Data Aktual dan Data Prediksi Metode ELM

Berdasarkan proses perhitungan didapatkan hasil, nilai sMAPE untuk metode *Holt Winter's Exponential Smoothing* model *additive* sebesar 26,14%, sedangkan untuk model *multiplicative* dengan metode yang sama dihasilkan nilai sMAPE sebesar 25,69%. Untuk metode *Extreme Learning Machine* dihasilkan nilai sMAPE sebesar 49,85%.

5. KESIMPULAN

Berdasarkan pengolahan data yang dilakukan maka dapat disimpulkan bahwa metode *Extreme Learning Machine* memiliki nilai sMAPE sebesar 49,85%, *Holt Winter's Exponential Smoothing* model *additive* sebesar 26,14%, dan *Holt Winter's Exponential Smoothing* model *multiplicative* sebesar 25,69%. Sehingga berdasarkan nilai sMAPE metode *Holt Winter's Exponential Smoothing* model *multiplicative* dapat lebih baik meramalkan untuk 12 periode ke depan.

DAFTAR PUSTAKA

- Arisoma, D. S., Supangat, & Narulita, L. F. 2019. System Design and Development of Financial Product Sales Forecasting with exponentially weighted moving average and exponential smoothing method. *Uii-Icabe 2019*, 2.
- Chang, P.C., Wang, & Liu, C.H. 2007. The Development of a Weighted Evolving Fuzzy Neural Network for PCB Sales Forecasting. *Journal Expert System with Applications*. 32(1): 86-96.
- Chen, C. Twycross, J. & Garibaldi., J.M. 2017. A New Accuracy Measure Based on Bounded Relative Error for Time Series Forecasting. *PLOS ONE 12*(3).
- Giusti, A., Widodo, A. W., & Adinugroho, S. 2018. Prediksi Penjualan Mi Menggunakan Metode Extreme Learning Machine (ELM) di Kober Mie Setan Cabang Soekarno Hatta. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, Vol. 2, No. 8, 2974.
- Haykin, S. 2009. *Neural Networks and Learning Machines, Third Edition*. United States of America: Pearson Prentice Hall. All rights reserved, ISBN- 13:978-0-13-147139-9, ISBN-10: 0-13-147139-2. pp. 10-24.
- Huang Guang-Bin, Zhu Qin-Yu, & Siew Chee-Kheong, 2006, Extreme learning machine: Theory and applications. *Neurocomputing 70 (2006)*, Elsevier, Page 489-501.
- Ishak, A. 2010. *Manajemen Operasi*. Yogyakarta: Graha Ilmu.
- Mahkya, D. A., Yasin, H., Mukid, M. A. 2014. Aplikasi Metode Golden Section untuk Optimasi Parameter pada Metode Exponenstal Smoothing. *Jurnal Gaussian Vol. 3, No. 4: Hal. 605-614*.
- Makridakis, S. 1995. *Metode dan Aplikasi Peramalan*. Jakarta: Penerbit Erlangga.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. 2015, *Introduction to Time Series Analysis and Forecasting*. Hoboken New Jersey: John Wiley & Sons.
- Nasution, D. A., Khotimah, H. H., & Chamidah, N. 2019. Perbandingan Normalisasi Data untuk Mengklasifikasi Wine Menggunakan Algoritma K-NN. *CESS (Journal of Computer Engineering System and Science)*, 78-82.
- Wei, W.S. 2006. *Time Series Analysis: Univariate and Multivariate Methods, 2nd Edition*. USA: Addison Wesley.