

Analisis Perbandingan Peramalan Indeks Harga Saham Hang Seng Menggunakan Metode Naive, Holt's Exponential Smoothing dan Neural Network Autoregressive (NNAR)

Christy Sheldy Sucipto¹, Winita Sulandari², Yuliana Susanti³

¹Statistika, Universitas Sebelas Maret, chrissheldy@student.uns.ac.id

²Statistika, Universitas Sebelas Maret, winita@mipa.uns.ac.id

³Statistika, Universitas Sebelas Maret, yulianasusanti@staff.uns.ac.id

Keywords:

Forecasting,
Hang Seng Index,
Naive,
Holt's Exponential
Smoothing,
NNAR

Abstract: The Stock Price Index indicates the performance of a country's stocks, which can provide an overview of its economic conditions. This research aims to determine the most accurate forecasting model for the Hang Seng Index (IHSHS) to provide important information for investors, market participants, and policy decision-makers about the prospects for future economic growth and potential job creation. The forecasting methods compared include Naive, Holt's Exponential Smoothing, and Neural Network Autoregressive (NNAR). The stages include model feasibility testing, estimating parameters, and determining the fitted value for forecasting in testing data. The most appropriate model is determined by comparing the forecasting errors using the smallest Mean Absolute Percentage Error (MAPE) parameter among the three methods. The MAPE error evaluation obtained for training and testing data respectively for the Naive method are 0.940% and 1.748%. Holt's Exponential Smoothing method ($\alpha=0.99$; $\beta=0.01$) are 0.408% and 0.75%, while the NNAR(6,3) method are 0.834% and 5.196%. Based on these results, it is known that Holt's Exponential Smoothing ($\alpha = 0,99$; $\beta = 0,01$) has the smallest MAPE value, both for training and testing data. Therefore, Holt's Exponential Smoothing ($\alpha = 0,99$; $\beta = 0,01$) is determined as the most appropriate model and can be considered for use in forecasting and monitoring IHSHS.

Kata Kunci:

Peramalan,
Indeks Harga
Saham Hang Seng,
Naive,
Holt's Exponential
Smoothing,
NNAR

Abstrak: Indeks Harga Saham mengindikasikan performa saham sebuah negara yang dapat memberikan gambaran mengenai kondisi perekonomian negara. Penelitian ini bertujuan untuk mengetahui model peramalan yang paling tepat untuk Indeks Harga Saham Hang Seng (IHSHS) guna memberikan informasi penting bagi investor, pelaku pasar, dan pengambil keputusan kebijakan tentang prospek pertumbuhan ekonomi di masa depan dan potensi penciptaan lapangan kerja. Metode peramalan yang dibandingkan yakni Naive, Holt's Exponential Smoothing dan Neural Network Autoregressive (NNAR). Tahapan yang dilakukan meliputi uji kelayakan model, penentuan estimasi parameter serta peramalan data *training* dan *testing*. Penentuan model paling tepat dilihat melalui perbandingan kesalahan peramalan menggunakan parameter *Mean Absolute Percentage Error* (MAPE) yang terkecil diantara ketiga metode. Evaluasi *error* MAPE yang diperoleh untuk data *training* dan *testing* secara berturut-turut pada metode Naive yaitu sebesar 0,940% dan 1,748%. Pada metode Holt's Exponential Smoothing ($\alpha = 0,99$; $\beta = 0,01$) sebesar 0,408% dan 0,75%. Sedangkan pada metode NNAR(6,3) sebesar 0,834% dan 5,196%. Berdasarkan hasil tersebut, diketahui bahwa Holt's Exponential Smoothing ($\alpha = 0,99$; $\beta = 0,01$) memiliki nilai MAPE terkecil, baik untuk data *training* maupun *testing*. Dengan demikian, Holt's Exponential Smoothing ($\alpha = 0,99$; $\beta = 0,01$) ditetapkan sebagai model yang paling tepat dan dapat menjadi pertimbangan untuk digunakan dalam peramalan serta *monitoring* IHSHS.

Article History:

Received: 25-03-2023

Online : 05-04-2023



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license



A. LATAR BELAKANG

Indeks harga saham merupakan ukuran statistik mengenai seluruh pergerakan harga sekumpulan saham sesuai dengan kriteria tertentu dan dievaluasi secara berkala sebagai indikator kesehatan perekonomian negara. Hong Kong memiliki indeks saham yang dinamakan Indeks Harga Saham Hang Seng (IHSHS) atau yang biasa disebut dengan *Hang Seng Index*. IHSHS mewakili 65% kapitalisasi bursa di Hong Kong. (*Hang Seng Indexes*, 2022)

IHSHS mempengaruhi Indeks Harga Saham Gabungan (IHSG) di Bursa Efek Indonesia dengan pengaruh positif (Aji & Abundanti, 2022). Dengan kata lain, saat IHSHS mengalami peningkatan atau dollar Hong Kong menguat, maka IHSG juga akan menaik atau rupiah menguat dan begitu juga sebaliknya. Pergerakan indeks harga saham merupakan hasil dari berbagai faktor yang dapat mempengaruhi, seperti angka pertumbuhan perusahaan, ekonomi negara, kondisi sosial dan politik, dan situasi ekonomi secara global. Berbagai faktor menjadikan tidak menentukannya pergerakan indeks harga saham di masa depan, maka penting untuk melakukan peramalan IHSHS menggunakan model peramalan yang tepat.

Pada penelitian ini, peneliti menerapkan tiga metode peramalan sebagai perbandingan metode peramalan sederhana dan kompleks. Metode sederhana yang digunakan yakni *Naive* dan *Holt's Exponential Smoothing* atau yang biasa disingkat dengan *Holt's*, sedangkan metode kompleks yang digunakan yaitu *Neural Network Autoregressive* (NNAR). Metode *Naive* digunakan karena kesederhanaannya dalam meramalkan periode ke depan, dimana nilai peramalan satu periode ke depan merupakan nilai periode saat ini dan tak jarang digunakan sebagai metode pembanding.

Dalam memprediksi suatu data runtun waktu, penting untuk melakukan eksplorasi pola data guna memperoleh tingkat akurasi yang baik dari metode peramalan yang tepat. Runtun waktu dikatakan memiliki tren jika terdapat kenaikan atau penurunan nilai dalam periode waktu tertentu. Umumnya, data yang mengandung tren adalah data ekonomi (Hyndman & Athanasopoulos, 2018). Data *closing price* harian IHSHS sepanjang periode April 2021 hingga April 2022 cenderung mengalami penurunan, yang mengindikasikan bahwa data mengandung pola tren turun, sehingga diterapkan metode *Holt's* pada penelitian ini. Berbeda dengan dua metode sederhana sebelumnya, NNAR merupakan metode peramalan kompleks yang dikembangkan dari model Jaringan Syaraf Tiruan (JST) dengan berdasar pada model matematika sederhana dari otak. NNAR telah diterapkan untuk meramalkan pendapatan *disposable* per kapita (Sena & Nagwani, 2016), inflasi bulanan (As'ad & Farida, 2019) dan penerimaan bea masuk (Hartono, 2022).

Penentuan model terbaik dalam artikel ini ditentukan menggunakan parameter *Mean Absolute Percentage Error* (MAPE). Metode yang memiliki nilai MAPE terkecil artinya memiliki tingkat keakuratan yang baik dan merupakan metode yang tepat dalam meramalkan IHSHS di masa depan.

B. METODE

Naive

Naive merupakan metode yang paling sederhana, dengan menganggap bahwa peramalan periode berikutnya sama dengan nilai aktual periode sebelumnya. Dengan demikian data aktual periode waktu yang baru saja berlalu merupakan alat peramalan yang terbaik untuk meramalkan keadaan di masa yang akan datang. Metode *Naive* melakukan pemodelan untuk berbagai pola data, seperti stasioner, tren, musiman, serta musiman dan tren. Data runtun waktu yang mengandung tren memiliki bentuk model yang ditunjukkan melalui persamaan (1).

$$\hat{Y}_{t+1} = Y_t + (Y_t - Y_{t-1}) \quad (1)$$

dengan, Y_t merupakan nilai aktual pada waktu t , \hat{Y}_{t+1} menunjukkan peramalan pada periode berikutnya dan Y_{t-1} menunjukkan nilai aktual pada periode sebelum (Hanke & Wichern, 2013).

Holt's Exponential Smoothing

Holt mengembangkan metode *Simple Exponential Smoothing* menjadi *Holt's Exponential Smoothing*, yang memungkinkan untuk peramalan data dengan pola tren. Metode ini melibatkan persamaan ramalan yang ditunjukkan melalui persamaan (4) dan dua persamaan pemulusan, yakni untuk level dan tren yang ditunjukkan melalui persamaan (2) dan (3).

$$\text{Estimasi level.} \quad L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (2)$$

$$\text{Estimasi tren.} \quad T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (3)$$

$$\text{Peramalan.} \quad \hat{Y}_{t+p} = L_t + pT_t \quad (4)$$

dengan L_t merupakan nilai *smoothed* yang baru (estimasi dari tingkat saat ini), α adalah konstanta *smoothing* untuk level ($0 \leq \alpha \leq 1$), β menunjukkan konstanta *smoothing* untuk tren ($0 \leq \beta \leq 1$), T_t merupakan estimasi tren, dan p merupakan jumlah periode yang diramalkan untuk masa depan. Beberapa kombinasi konstanta α dan β sangat diperlukan untuk dapat memperoleh nilai evaluasi *error* yang terkecil (Hanke & Wichern, 2013).

NNAR

Jaringan Syaraf Tiruan (JST) atau *Neural Network* (NN) merupakan salah satu model yang umum digunakan dalam *machine learning*. Konsep JST terinspirasi oleh jaringan syaraf biologi pada otak. JST lebih baik digunakan untuk memprediksi fungsi berdasarkan ukuran data *training* yang besar dan mampu untuk memodelkan hubungan nonlinear yang kompleks tanpa asumsi hubungan yang mendasarinya (Thoplan, 2014).

Arsitektur JST terdiri dari terdiri dari tiga lapisan, yakni lapisan *input*, lapisan tersembunyi (*hidden layer*) dan lapisan *output*. Model matematika NNAR (z_t) ditunjukkan melalui persamaan (5).

$$z_t = v_0 + \sum_{j=1}^h v_j \cdot f(w_{0j} + \sum_{i=1}^m w_{ij} \cdot y_{t-i}) + \varepsilon_t \quad (5)$$

dengan, m adalah jumlah *nodes* pada *input layer*, k adalah jumlah *nodes* pada *hidden layer*, v_0 dan w_{0j} adalah bobot koneksi dari bias yang selalu memiliki nilai sama dengan 1. $w_{ij} (i=1,2,\dots,m; j=1,2,\dots,h)$ dan $v_j (j=1,2,\dots,h)$ merupakan parameter model atau bobot koneksi dari *input* ke *hidden nodes*. Notasi f merupakan fungsi nonlinear pada *hidden layer*, yaitu fungsi sigmoid sebagai fungsi transfer untuk memberikan input pada lapisan berikutnya. Fungsi sigmoid ditunjukkan pada persamaan (6) (Hyndman & Athanasopoulos, 2018).

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (6)$$

Seminar Nasional LPPM UMMAT

Universitas Muhammadiyah Mataram

Mataram, 05 April 2023

ISSN 2964-6871 | Volume 2 April 2023

pp. 423-430

Model NNAR merupakan model jaringan *feedforward single hidden layer* yang dinotasikan dengan NNAR (m, h) (As'ad et al., 2020). Penelitian ini menggunakan *software* R dengan fungsi *nnetar* pada package "*forecast*" untuk melakukan pemodelan peramalan.

MAPE

Error atau residu merupakan selisih antara nilai pengamatan aktual dan nilai peramalannya. MAPE dihitung dengan mencari kesalahan absolut dalam setiap periode, membaginya dengan nilai pengamatan aktual untuk periode tersebut, dan merata-ratakan kesalahan persentase absolut ini. Hasil akhir kemudian dikalikan dengan 100 dan dinyatakan sebagai persentase. Pendekatan ini berguna saat ukuran dari variabel prediksi signifikan dalam mengevaluasi akurasi dari prediksi (Khair et al., 2017). Persamaan MAPE ditunjukkan melalui persamaan (7).

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100\% \quad (7)$$

dengan n menunjukkan jumlah data runtun waktu, Y_t merupakan nilai aktual dalam periode waktu t dan \hat{Y}_t merupakan nilai ramalan untuk periode waktu t .

Langkah penelitian

Langkah dalam penelitian ini diuraikan sebagai berikut.

- Langkah 1. Mengeksplorasi data untuk mengetahui karakteristik data.
- Langkah 2. Membagi data runtun waktu menjadi data *training* dan *testing* dengan proporsi 80% dan 20%.
- Langkah 3. Melakukan pemodelan data *training*.
 - a) Menentukan nilai peramalan menggunakan persamaan (1) untuk model Naive.
 - b) Menentukan nilai peramalan menggunakan persamaan (4) dengan menentukan nilai α dan β yang terbaik terlebih dahulu untuk model *Holt's Exponential Smoothing*.
 - c) Menentukan parameter *input* jaringan (m) dalam model NNAR yang terbaik.
- Langkah 4. Menentukan residu dan melakukan uji kelayakan model pada residu setiap model
- Langkah 5. Melakukan peramalan pada data *testing*.
- Langkah 6. Menentukan model peramalan terbaik dengan ukuran kesalahan MAPE.

C. HASIL DAN PEMBAHASAN

1. Karakteristik Data IHSHS

Data yang digunakan dalam penelitian ini merupakan Indeks Harga Saham negara Hong Kong yang bernama *Hang Seng Index*. Rentang data yang digunakan mulai dari 1 April 2021 hingga 29 April 2022 dengan jumlah sebanyak 265 data harian. Data IHSHS yang digunakan dibagi menjadi dua bagian, yakni data *training* dan *testing*. Pembagian ini bertujuan untuk melatih model menggunakan data *training* yang selanjutnya digunakan untuk memprediksi keakuratan data *testing*. Data *training* yang digunakan mulai pada tanggal 1 April 2021 hingga 10 Februari 2022 sedangkan data *testing* yang digunakan mulai pada tanggal 11 Februari 2022 hingga 29 April 2022. Proporsi pembagian data *training* dan *testing* sebesar 80% dan 20% dimana terdapat 212 data *training* dan 53 data *testing*.

Seminar Nasional LPPM UMMAT

Universitas Muhammadiyah Mataram

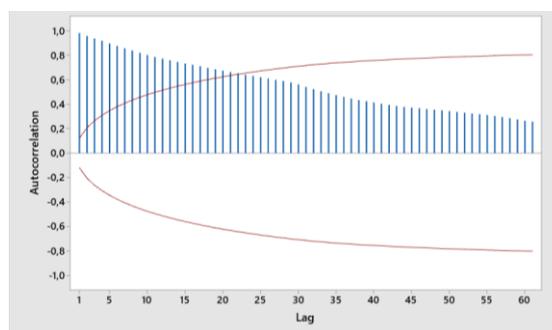
Mataram, 05 April 2023

ISSN 2964-6871 | Volume 2 April 2023

pp. 423-430



Gambar 1. Plot Data *Closing Price* IHSHS periode 1 April 2021-29 April 2022



Gambar 2. ACF Data IHSHS periode 1 April 2021-29 April 2022

Pola data IHSHS periode 1 April 2021-29 April 2022 dapat dilihat pada Gambar 1. Secara visual, diketahui bahwa data tersebut memiliki grafik turun seiring berjalannya waktu. Hal tersebut menandakan bahwa data IHSHS memiliki pola data tren turun. Tidak hanya melalui visualisasi plot data, melalui ACF data yang ditunjukkan pada Gambar 2, terlihat bahwa lag awal signifikan kemudian turun secara perlahan mendekati nol, yang menandakan bahwa data memiliki pola tren.

2. *Naive*

Pemodelan dengan *Naive* menggunakan persamaan (1). Nilai ramalan yang didapatkan merupakan penjumlahan dari nilai aktual data pada periode t dengan selisih antara nilai aktual dengan periode sebelumnya. *Software Excel* digunakan untuk membantu pemodelan dan menentukan residu model.

Sebuah model dikatakan baik digunakan untuk memprediksi jika residu berdistribusi normal dan tidak memiliki autokorelasi antar residu. Residu sendiri merupakan selisih dari data aktual dan nilai peramalan. *Kolmogorov-Smirnov* digunakan untuk uji normalitas pada penelitian ini. Model *Naive* menunjukkan $p\text{-value} > 0,15$ yang mana menunjukkan lebih besar dari tingkat signifikansi, 0,05, sehingga residu model *Naive* dikatakan berdistribusi normal. Uji autokorelasi residu dilakukan menggunakan visualisasi plot ACF dari residu dan dilakukan uji *Ljung-Box* untuk melihat apakah lag signifikan secara statistik. Pada metode *Naive*, terdapat autokorelasi pada residu, ditandai dengan terdapat lag yang menyentuh garis konfidensi.

Berdasarkan Uji *Ljung-Box*, terdapat autokorelasi pada lag ke-4 yang selanjutnya dilakukan transformasi *Box-Cox*. Hasil transformasi memperoleh nilai $\lambda = -1$ yang artinya menggunakan transformasi $1/Y_t$. Setelah dilakukan transformasi dan dilakukan pemodelan ulang, residu telah menunjukkan non-autokorelasi sehingga model dapat digunakan untuk peramalan data *testing*.

3. *Holt's Exponential Smoothing*

Kombinasi parameter α dan β dalam pemodelan *Holt's* penting untuk memperoleh hasil peramalan yang optimum. Pada penelitian ini, dilakukan beberapa kombinasi α dan β untuk menghasilkan *error* paling kecil yang ditunjukkan pada Tabel 1.

Tabel 1. Perbandingan MAPE pada parameter α dan β model *Holt's*

α	β	MAPE
0,1	0,9	1,442%
0,9	0,1	0,515%
0,99	0,01	0,408%

Berdasarkan perbandingan MAPE pada Tabel 1, diketahui bahwa kombinasi dengan nilai α yang besar dan nilai β yang kecil menghasilkan keakuratan peramalan yang lebih baik. Kombinasi dengan $\alpha = 0,99$ dan $\beta = 0,01$ memiliki nilai MAPE terkecil dibandingkan dua model *Holt's* yang lainnya, sehingga kombinasi ini dipilih untuk digunakan sebagai pemodelan.

Uji normalitas pada model *Holt's* menghasilkan nilai *p-value* $> 0,15$ yang mana lebih besar dari tingkat signifikansi, $0,05$, sehingga residu model *Holt's* dikatakan berdistribusi normal. Pada plot ACF residu metode *Holt's* ($\alpha = 0,99; \beta = 0,01$), secara visual terdapat lag yang menyentuh batas konfidensi yaitu lag ke-3 dan 4. Hasil Uji *Ljung-Box* menunjukkan bahwa nilai $T_3 = -1,92 > -t_{(211;0,025)} = -1,97$ dan nilai $T_4 = 1,95 < t_{(n-1;\alpha/2)} = 1,97$ dimana H_0 gagal ditolak, yang artinya tidak terdapat autokorelasi pada lag ke-3 dan 4 residu model *Holt's*. Hal tersebut menunjukkan bahwa model *Holt's* baik untuk digunakan dalam peramalan data *testing*.

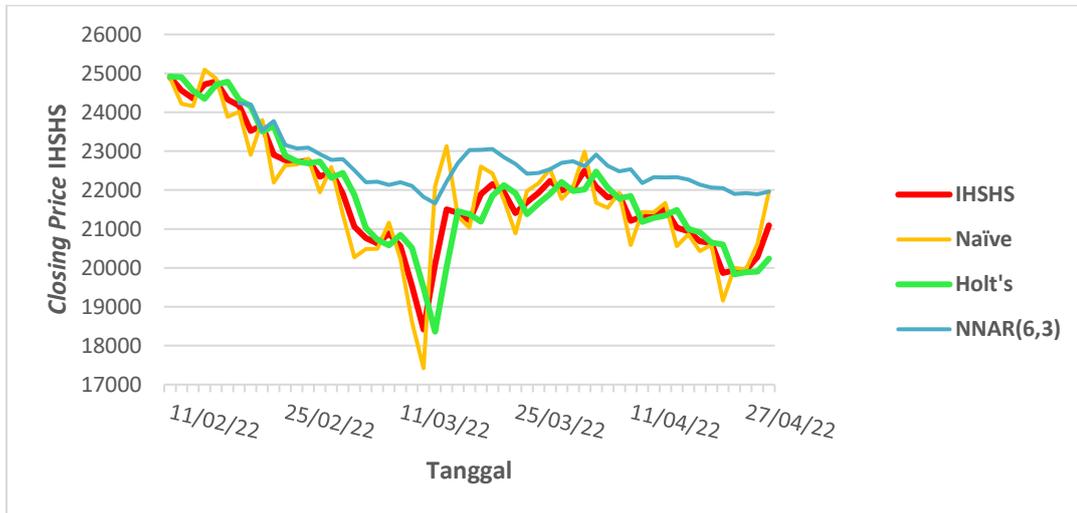
4. NNAR

Berbeda dengan dua metode sebelumnya, pada pemodelan NNAR dilakukan penentuan parameter *input h* dengan melihat nonlinearitas pada lag tertentu menggunakan uji *Terasvirta*. Pada lag 1 hingga 5, nilai χ^2_{hitung} menunjukkan lebih kecil dari χ^2_{tabel} yang artinya tidak terdapat nonlinearitas. Pada lag ke-6, nilai χ^2_{hitung} sebesar 106,83 yang lebih besar dari $\chi^2_{(0,05;77)}$ sebesar 98,48, sehingga parameter *input* yang ditentukan sebagai pemodelan pada NNAR adalah $m = 6$. Penentuan jumlah *nodes* pada lapisan tersembunyi ditentukan menggunakan rumus $k = (m + P + 1)/2$ dengan $P = 0$ dan dilakukan pembulatan nilai m pada bilangan bulat terdekat. Jumlah *nodes* yang diperoleh yakni $m = 3$ dan 4.

Selanjutnya, dilakukan uji kelayakan model NNAR(6,3) dan NNAR(6,4) menggunakan residu. Model NNAR(6,3) dan NNAR(6,4) menunjukkan bahwa residu berdistribusi normal dengan nilai *p-value* lebih besar dari $0,05$ dan tidak terdapat autokorelasi yang ditunjukkan dengan tidak adanya lag pada ACF yang melebihi garis konfidensi. Model NNAR dengan parameter terbaik ditentukan dengan perbandingan MAPE. Model NNAR(6,3) memiliki nilai MAPE yang lebih kecil dibandingkan NNAR(6,4) sehingga NNAR(6,3) dipilih untuk meramalkan data *testing*.

5. Peramalan Data *Testing*

Peramalan pada data *testing* dilakukan untuk melihat performa model untuk data IHSHS di masa mendatang menggunakan parameter terbaik dari setiap metodenya.



Gambar 3. Perbandingan Peramalan Data *Testing* IHSHS

Hasil perbandingan peramalan setiap metode dengan nilai aktual ditunjukkan pada Gambar 3. Garis berwarna merah menunjukkan data *testing Closing Price* IHSHS. Peramalan dengan *Naive* ditunjukkan dengan garis berwarna oranye, sedangkan peramalan *Holt's* dan *NNAR* ditunjukkan dengan garis berwarna hijau dan biru secara berturut-turut. Berdasarkan visualisasi plot di atas, dapat diketahui bahwa garis peramalan *Holt's* yang paling mendekati dengan nilai aktual IHSHS.

6. Perbandingan Evaluasi *Error*

Model peramalan yang paling tepat ditentukan melalui perbandingan nilai akurasi MAPE. Nilai akurasi untuk masing-masing metode ditunjukkan pada Tabel 2.

Tabel 2. Perbandingan Evaluasi *Error* MAPE

Metode	Training	Testing
Naive	0,940%	1,748%
Holt's Exponential Smoothing ($\alpha = 0,99; \beta = 0,01$)	0,408%	0,750%
NNAR (6,3)	0,834%	5,196%

Berdasarkan hasil perbandingan evaluasi *error* dari setiap metode, diketahui bahwa metode *Holt's* dengan parameter $\alpha = 0,99$ dan $\beta = 0,01$ memiliki nilai akurasi yang paling kecil baik untuk data *training* maupun data *testing*. Hal tersebut menunjukkan bahwa metode *Holt's* merupakan metode yang paling tepat diantara dua metode lainnya untuk pemodelan serta peramalan periode kedepan data IHSHS.

Seminar Nasional LPPM UMMAT

Universitas Muhammadiyah Mataram
Mataram, 05 April 2023
ISSN 2964-6871 | Volume 2 April 2023
pp. 423-430

D. SIMPULAN DAN SARAN

Berdasarkan hasil analisis dan pembahasan, dapat disimpulkan bahwa penerapan model *Naive*, *Holt's Exponential Smoothing* dan NNAR untuk peramalan IHSHS menghasilkan nilai *error* yang cukup kecil. Model *Holt's Exponential Smoothing* dengan parameter $\alpha = 0,99$ dan $\beta = 0,01$ memiliki nilai evaluasi *error* MAPE yang paling kecil jika dibandingkan dengan dua model lainnya. Dengan demikian, *Holt's Exponential Smoothing* dapat dipertimbangkan sebagai metode untuk melakukan peramalan IHSHS pada periode berikutnya. Hal ini juga menunjukkan bahwa metode yang kompleks, yaitu NNAR, tidak selalu dapat memberikan hasil peramalan yang lebih akurat dibandingkan dengan metode yang lebih sederhana, yaitu *Holt's Exponential Smoothing*.

Pada penelitian selanjutnya, prediksi pada IHSHS dapat menggunakan periode rentang waktu yang terbaru. Selain itu, model yang dipilih dapat menggunakan kombinasi model NNAR dengan model linear dan nonlinear lainnya sebagai pembanding peramalan yang dapat meningkatkan keakuratan hasil peramalan.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Universitas Muhammadiyah Mataram yang telah menyelenggarakan Seminar Nasional ke-II LPPM Universitas Muhammadiyah Mataram 2023 dengan tema "Optimalisasi Inovasi IPTEK Dalam Mendukung Implementasi SDG'S".

REFERENSI

- Aji, R. D. P., & Abundanti, N. (2022). The Effect of Asia Regional Stock Price Index on the Indonesia Composite Index (ICI) on the Indonesia Stock Exchange. *European Journal of Business and Management Research*, 7(2), 100–106. <https://doi.org/10.24018/ejbmr.2022.7.2.1337>
- As'ad, M., & Farida, E. (2019). Implementasi Jaringan Syaraf Tiruan untuk Memprediksi Inflasi Bulanan di Kota Malang. *Jurnal Ilmiah KOMPUTASI*, 18(2), 101–106.
- As'ad, M., Sujito, S., & Setyowibowo, S. (2020). Neural Network Autoregressive For Predicting Daily Gold Price. *Jurnal INFORM*, 5(2), 69. <https://doi.org/10.25139/inform.v0i1.2715>
- Hang Seng Indexes*. (2022). www.hsi.com.hk/eng/indexes/all-indexes/hsi
- Hanke, J. E., & Wichern, D. W. (2013). *Business Forecasting: Pearson New International Edition*.
- Hartono, Y. K. (2022). COMPARING NEURAL NETWORK AUTOREGRESSIVE METHOD FOR IMPORT DUTY REVENUE FORECASTING. *Jurnal Perspektif Bea Dan Cukai*, 6(1), 2022.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice (2nd ed)*. <https://otexts.com/fpp2/>
- Khair, U., Fahmi, H., Hakim, S. Al, & Rahim, R. (2017). Forecasting Error Calculation with Mean Absolute Deviation and Mean Absolute Percentage Error. *Journal of Physics: Conference Series*, 930(1). <https://doi.org/10.1088/1742-6596/930/1/012002>
- Sena, D., & Nagwani, N. K. (2016). A NEURAL NETWORK AUTOREGRESSION MODEL TO FORECAST PER CAPITA DISPOSABLE INCOME. 11(22). www.arpnjournals.com
- Thoplan, R. (2014). Simple v/s Sophisticated Methods of Forecasting for Mauritius Monthly Tourist Arrival Data. *International Journal of Statistics and Applications*, 4(5), 217–223. <https://doi.org/10.5923/j.statistics.20140405.01>