

Prediksi Nilai Ekspor Migas Indonesia Menggunakan Metode SARIMA dan LSTM

Hasby Kuswanto¹, Pradita Eko Prasetyo Utomo^{2*}, Ulfa Khaira³, Akhiyar Waladi⁴

^{1,2*,3,4}Program Studi Sistem Informasi, Fakultas Sains Dan Teknologi, Universitas Jambi, Jambi, Indonesia

Email: ¹hasbykuswanto12@gmail.com, ^{2*}pradita.eko@unja.ac.id, ³ulfa.ilkom@gmail.com,

⁴akhiyar.waladi@unja.ac.id

ABSTRACT

This study aims to predict Indonesia's oil and gas (migas) export values using the Seasonal Autoregressive Integrated Moving Average (SARIMA) and Long Short-Term Memory (LSTM) methods. Time series data from Statistics Indonesia (BPS) was utilized to develop an optimal prediction model. The selected SARIMA model, SARIMA(1,1,1)(1,1,1,12), was chosen based on the lowest Akaike Information Criterion (AIC) value. Meanwhile, the LSTM model was developed to capture more complex patterns in time series data. The forecasting results indicate that the SARIMA model provides higher accuracy compared to LSTM based on the Mean Absolute Percentage Error (MAPE), although LSTM demonstrated lower Mean Squared Error (MSE) and Root Mean Squared Error (RMSE). This study emphasizes that the choice of forecasting model should align with the characteristics of the data, where SARIMA is more suitable for oil and gas export data with seasonal patterns. These forecasting results can be utilized to support economic policy planning, optimize investments in the oil and gas sector, and mitigate global market fluctuation risks.

Keywords: Prediction, Oil and Gas Export, ARIMA, LSTM, Time Series.

ABSTRAK

Penelitian ini bertujuan untuk memprediksi nilai ekspor minyak dan gas bumi (migas) Indonesia menggunakan metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA) dan *Long Short-Term Memory* (LSTM). Data runtun waktu dari Badan Pusat Statistik (BPS) digunakan untuk membangun model prediksi yang optimal. Model SARIMA yang terpilih adalah SARIMA(1,1,1)(1,1,1,12), dipilih berdasarkan nilai Akaike Information Criterion (AIC) terkecil. Sementara itu, model LSTM dikembangkan untuk menangkap pola yang lebih kompleks dalam data time series. Hasil peramalan menunjukkan bahwa model SARIMA memberikan akurasi lebih tinggi dibandingkan LSTM berdasarkan nilai *Mean Absolute Percentage Error* (MAPE), meskipun LSTM menunjukkan nilai *Mean Squared Error* (MSE) dan *Root Mean Squared Error* (RMSE) lebih kecil. Penelitian ini menegaskan bahwa pemilihan model peramalan harus disesuaikan dengan karakteristik data, di mana SARIMA lebih sesuai untuk data ekspor migas yang memiliki pola musiman. Hasil peramalan ini dapat dimanfaatkan untuk mendukung perencanaan kebijakan ekonomi, optimalisasi investasi sektor migas, dan mitigasi risiko fluktuasi pasar global.

Kata Kunci: Prediksi, Ekspor Migas, ARIMA, LSTM, *Time Series*.

1. Pendahuluan

Indonesia adalah negara dengan kekayaan sumber daya alam yang melimpah. Sumber daya alam Indonesia berasal dari berbagai sektor, seperti pertanian, kehutanan, kelautan dan perikanan, peternakan, perkebunan, serta pertambangan dan energi. Sektor pertambangan, khususnya minyak dan gas bumi, merupakan salah satu pilar utama dalam perekonomian Indonesia. Kekayaan alam ini tidak hanya penting untuk memenuhi kebutuhan domestik, tetapi juga menjadi salah satu komoditas ekspor yang signifikan bagi negara [1]. Oleh karena itu, pengelolaan sektor pertambangan,

terutama minyak dan gas bumi, memegang peranan yang sangat penting untuk meningkatkan kesejahteraan masyarakat Indonesia.

Minyak dan gas bumi memiliki peranan krusial dalam perekonomian Indonesia, baik sebagai sumber energi utama maupun sebagai komoditas ekspor. Indonesia dikenal sebagai salah satu penghasil utama minyak, gas bumi, dan batubara terbesar di dunia, dengan lebih dari 50% energi yang digunakan di Indonesia berasal dari minyak dan gas bumi [2]. Sebagai negara penghasil utama, nilai ekspor minyak dan gas bumi Indonesia sangat dipengaruhi oleh faktor-faktor eksternal seperti

fluktuasi harga global, perubahan permintaan internasional, dan kebijakan pemerintah. Ketidakpastian yang timbul dari faktor-faktor tersebut sering kali membuat perencanaan dan pengambilan keputusan dalam sektor ini menjadi lebih kompleks.

Dalam menghadapi ketidakpastian pasar global, prediksi yang akurat mengenai nilai ekspor minyak dan gas bumi (migas) menjadi hal yang sangat penting bagi perekonomian Indonesia. Pasar migas global dikenal sangat fluktuatif, dipengaruhi oleh berbagai faktor eksternal seperti harga minyak dunia, permintaan energi global, kebijakan negara penghasil migas utama, serta situasi geopolitik yang tidak dapat diprediksi. Ketidakpastian ini sering kali menyebabkan ketegangan di pasar energi global, yang berdampak langsung pada stabilitas ekonomi negara-negara pengimpor energi, termasuk Indonesia. Oleh karena itu, pemahaman yang lebih baik tentang pergerakan ekspor migas, dengan memanfaatkan alat prediksi yang andal, dapat memberikan keunggulan strategis bagi Indonesia dalam menghadapi dinamika global ini.

Dengan memprediksi nilai ekspor migas yang lebih tepat, pemerintah dan pelaku industri dapat merumuskan kebijakan ekonomi yang lebih responsif dan adaptif terhadap fluktuasi pasar. Misalnya, pemerintah dapat lebih siap dalam merancang kebijakan fiskal, seperti penentuan target penerimaan negara dari sektor migas, atau kebijakan moneter yang mengatur nilai tukar rupiah terhadap mata uang asing yang dipengaruhi oleh harga minyak dunia. Selain itu, pelaku industri migas, baik itu perusahaan negara maupun swasta, dapat memanfaatkan prediksi ini untuk perencanaan produksi dan ekspor yang lebih efisien, serta mengelola risiko bisnis mereka dengan lebih baik.

Lebih jauh lagi, pemahaman tentang faktor-faktor yang mempengaruhi nilai ekspor migas, seperti kebijakan energi global, tren permintaan di pasar internasional, atau perubahan dalam teknologi energi, juga dapat membantu Indonesia dalam merancang strategi jangka panjang yang lebih berkelanjutan. Di sisi lain, ketidakpastian yang tidak dapat diprediksi, seperti krisis ekonomi global atau perubahan drastis dalam harga energi yang dapat memiliki dampak besar terhadap perekonomian Indonesia. Oleh karena itu, penting bagi Indonesia untuk memiliki metode yang tidak hanya mampu memberikan prediksi yang akurat, tetapi juga dapat merespons perubahan yang cepat dan dinamis, agar sektor migas tetap menjadi andalan dalam perekonomian negara.

Salah satu metode yang paling sering digunakan dalam pemodelan runtun waktu untuk peramalan adalah *Autoregressive Integrated Moving Average* (ARIMA), yang dikenal dengan pendekatan *Box-Jenkins*. ARIMA memanfaatkan data *time series* untuk memodelkan hubungan temporal antara nilai-nilai dalam suatu periode waktu tertentu. Metode ini mengandalkan konsep-konsep seperti stasioneritas, autokovariansi,

autokorelasi, dan autokorelasi parsial untuk menghasilkan model yang dapat memberikan prediksi yang optimal. Agar model ARIMA dapat menghasilkan ramalan yang valid, model ini harus memenuhi asumsi *residual white noise* dan distribusi normal [3]. Namun dalam penelitian ini menggunakan unsur musiman dan variabel eksogen yang memiliki pengaruh signifikan terhadap data, sehingga mampu menambah nilai akurasi pada peramalan yang dilakukan [4]. Jika data memiliki unsur musiman, maka model yang digunakan adalah *Seasonal Autoregressive Integrated Moving Average* (SARIMA) yang merupakan perluasan dari model ARIMA [5]. Dengan kemampuan SARIMA dalam memodelkan fluktuasi yang ada, penelitian ini bertujuan untuk memanfaatkan metode tersebut dalam memprediksi nilai ekspor minyak dan gas bumi Indonesia.

Di samping metode SARIMA, penelitian ini juga menerapkan *Long Short-Term Memory* (LSTM) sebagai pendekatan berbasis kecerdasan buatan untuk menangani pola yang lebih kompleks dan hubungan non-linear dalam data *time series*. LSTM merupakan salah satu jenis *Recurrent Neural Network* (RNN) yang memiliki kemampuan untuk menyimpan informasi jangka Panjang [6], sehingga mampu mengenali pola yang sulit ditangkap oleh metode statistik konvensional seperti ARIMA atau SARIMA. Model LSTM tidak memerlukan data yang sepenuhnya stasioner, sehingga lebih fleksibel dalam menangani data dengan tren dan musiman yang kompleks. Dengan membandingkan performa SARIMA dan LSTM, penelitian ini bertujuan untuk mengidentifikasi metode yang lebih optimal dalam meramalkan nilai ekspor minyak dan gas bumi Indonesia.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan model prediksi yang lebih akurat mengenai nilai ekspor minyak dan gas bumi Indonesia menggunakan metode SARIMA. Di samping itu, penelitian ini juga akan menganalisis faktor-faktor yang berkontribusi terhadap fluktuasi nilai ekspor migas Indonesia, serta dampaknya terhadap perekonomian nasional. Dengan memanfaatkan data *time series*, diharapkan penelitian ini dapat memberikan pemahaman yang lebih mendalam mengenai dinamika ekspor migas dan faktor-faktor eksternal yang mempengaruhi fluktuasinya. Dengan demikian, penelitian ini juga diharapkan dapat memberikan kontribusi terhadap kebijakan ekonomi dan perdagangan yang lebih responsif, berbasis data, dan lebih tepat sasaran.

2. Metode Penelitian

Penelitian ini dilakukan dengan menggunakan metode kuantitatif berbasis analisis data runtun waktu (*time series*). Implementasi analisis dan pemodelan dilakukan menggunakan bahasa pemrograman *Python* dengan bantuan pustaka seperti *pandas*, *numpy*,

statsmodels, dan *matplotlib*. Tahapan metode penelitian ini dijelaskan sebagai berikut.

2.1. Pengumpulan Data

Data yang digunakan dalam penelitian ini bersumber dari Badan Pusat Statistik (BPS) berupa data nilai ekspor minyak dan gas (migas) serta nonmigas Indonesia[7]. Data ini kemudian diolah menggunakan *Python* untuk persiapan analisis.

2.2. Pengolahan Data

Data dari Badan Pusat Statistik (BPS) memiliki sejumlah variabel, sehingga diolah untuk mengambil variabel waktu dan migas dalam bulanan.

Tabel 1. Data Penelitian

No	Waktu	Nilai
1	Jan-2000	1144,6
2	Feb-2000	1100,4
3	Mar-2000	1104
4	Apr-2000	987,6
5	May-2000	1004,6
...
295	Jul-2024	1422,9
296	Aug-2024	1203,6
297	Sep-2024	1150,9
298	Oct-2024	1345,4
299	Nov-2024	1317,2
300	Dec-2024	1539,4
301	Jan-2025	1056,9

Data tersebut akan dibagi menjadi data *training* dan data *testing*, dengan proporsi 80% untuk data *training* dan 20% untuk data *testing*. Pembagian ini bertujuan untuk mengevaluasi performa model secara objektif, karena model akan diuji menggunakan data baru yang belum pernah dilihat sebelumnya.

2.3. Model SARIMA

Peramalan adalah salah satu metode statistik yang berperan penting dalam pengambilan keputusan. Peramalan berfungsi untuk memperkirakan apa yang akan terjadi pada masa depan berdasarkan data masa lalu. Salah satu metode yang digunakan dalam peramalan adalah metode *time series*. Pendugaan masa depan dilakukan berdasarkan informasi masa lalu dari suatu variabel atau kesalahan masa lalu ini dinamakan deret berkala atau *time series*[8].

Dalam metode *Box-Jenkins* ini terdapat beberapa model yang dapat digunakan, di antaranya adalah model *Moving Average* (MA), *Autoregressive* (AR), dan *Autoregressive Moving-Average* (ARMA). Ketiga model di atas adalah model linier dan model stasioner. Sedangkan, model non-stasioner dari metode *Box-Jenkins* adalah ARIMA dan SARIMA[9]. Penentuan menggunakan model ARIMA atau SARIMA dapat dilihat dari hasil dekomposisi *time series* musimannya.

Model *Autoregressive Integrated Moving Average* (ARIMA) merupakan model yang secara penuh mengabaikan variabel independen dalam membuat peramalan. ARIMA menggunakan nilai masa lalu dan

sekarang dari variabel dependen untuk menghasilkan peramalan jangka pendek yang akurat. ARIMA cocok jika observasi dari deret waktu secara statistik berhubungan satu sama lain (dependen)[9].

Di dalam *time series* terdapat metode yang dapat digunakan untuk memprediksi, salah satunya adalah SARIMA (*Seasonal Autoregressive Integrated Moving Average*). Metode ini dipopulerkan oleh George Box dan Gwilym Jenkins sekitar tahun 1970-an, model ini telah banyak dipelajari secara luas dan mengadopsi salah satu model yaitu ARIMA model. SARIMA juga merupakan metode analisis *time series*, sama seperti analisis tren, dan *moving average* [10].

Adapun proses peramalan dengan SARIMA melalui beberapa tahap, yaitu : Dekomposisi Musiman, Uji Stasioneritas, *Corellation Function*, Modeling SARIMA, Evaluasi Model SARIMA, dan Peramalan.

2.3.1. Uji Stasioneritas

Uji stasioneritas ini bertujuan untuk mengetahui apakah data runtut waktu yang digunakan sudah stasioner atau belum. Regresi palsu (*spurious regression*) dihasilkan jika data tidak stasioner. Dalam penelitian, pada dasarnya data runtut waktu sering mengalami ketidakstasioneran pada level *series*. Oleh karena itu, diperlukan proses diferensiasi satu atau dua kali untuk menghasilkan data yang stasioner. Untuk mengetahui apakah data runtut waktu yang digunakan stasioner atau tidak stasioner, salah satu cara yang dapat dilakukan adalah dengan menggunakan uji akar unit (*unit roots test*)[11].

Uji akar unit dilakukan dengan metode *Augmented Dicky Fuller* (ADF), dengan hipotesis sebagai berikut: H_0 menunjukkan terdapat akar unit, artinya data tidak stasioner, sedangkan H_1 menunjukkan tidak terdapat akar unit, artinya data stasioner. Hasil statistik dari estimasi pada metode ADF kemudian dibandingkan dengan nilai kritis McKinnon pada tingkat signifikansi 1%, 5%, dan 10%[11].

Jika nilai t-statistik lebih kecil dari nilai kritis McKinnon, maka H_0 diterima, yang berarti data memiliki akar unit atau data tidak stasioner. Sebaliknya, jika nilai t-statistik lebih besar dari nilai kritis McKinnon, maka H_0 ditolak, yang menunjukkan data tidak memiliki akar unit atau data stasioner[11].

2.3.2. Correlation Function

Autocorrelation Function (ACF), adalah kolerasi antara pengamatan deret waktu yang diatur pada plot di setiap *lag*[12]. ACF digunakan untuk mengidentifikasi pola autokorelasi pada data runtun waktu dan membantu menentukan parameter q (*Moving Average*) dan Q dalam model SARIMA. Pola pada plot ACF memberikan informasi tentang efek musiman, tren, atau siklus dalam data, di mana penurunan lambat pada plot ACF dapat mengindikasikan data tidak stasioner.

Partial Autocorrelation Function (PACF) adalah kolerasi antar deret observasi dalam *lag-lag* observasi yang mengukur kedekatan antar observasi dalam *periodic*[13]. PACF digunakan untuk menentukan nilai parameter p (*Autoregressive*) dan P dalam model SARIMA. Analisis PACF membantu mengidentifikasi hubungan langsung antara suatu pengamatan dengan lag sebelumnya, dengan mengontrol efek pengamatan antara. Plot PACF digunakan untuk menentukan jumlah lag signifikan yang perlu dimasukkan dalam model.

2.3.3. Modeling SARIMA

Model *Seasonal Autoregressive Integrated Moving Average* (SARIMA) merupakan bentuk khusus dari model ARIMA yang mendukung data deret waktu univariat dengan unsur musiman. Bagian musiman dari model terdiri dari suku-suku yang sangat mirip dengan komponen model ARIMA, namun melibatkan pergeseran balik dari periode musiman [15]. Model SARIMA ditulis dalam bentuk (p, d, q) (P, D, Q, s). (p, d, q) merupakan bagian non-musiman, (P, D, Q, s) merupakan bagian musiman, dan s menunjukkan panjang periode musiman, yang mengintegrasikan *autoregression* (p) dan *moving average* (q) dengan tambahan orde d (*diferensiasi*) untuk mengatasi data yang tidak stasioner. Model ini dirancang untuk menangkap pola jangka pendek melalui parameter q (*moving average*) dan pola jangka panjang melalui parameter p (*autoregression*). Penambahan orde d (*diferensiasi*) berfungsi untuk memastikan data menjadi stasioner sebelum proses pemodelan dilakukan[16][17][18][19].

2.3.4. Evaluasi Model SARIMA

Evaluasi dilakukan dengan algoritma *grid search*, Algoritma ini membagi jangkauan parameter yang akan dioptimalkan ke dalam grid dan melintasi semua titik untuk mendapatkan parameter yang optimal [20]. Model terbaik dipilih berdasarkan nilai AIC dan BIC yang dimasukkan kedalam algoritma *grid search*. Ketika nilai AIC dan BIC semakin kecil maka model tersebut dikatakan lebih baik dari model lainnya. *Akaike's Information Criterion* (AIC) merupakan metode yang digunakan dalam memilih model dari sekumpulan data. *Bayesian Information Criterion* (BIC) adalah salah satu metode dalam memilih model model terbaik menggunakan *Penalized Maximum Likelihood* sebagai pendekatannya[21].

Untuk membuktikan kecukupan model, dilakukan uji diagnosis menggunakan *Ljung-Box statistics*. *Ljung-Box* merupakan statistik uji yang digunakan untuk melihat ketidaksesuaian model *time series*. Model peramalan dikatakan cukup baik jika memiliki residual yang memenuhi asumsi normalitas dan *white noise* dimana residual bersifat independen dan identik. Residual pada model bersifat *white noise* jika *p-value* bernilai lebih besar dari tingkat kesalahan yang digunakan[22].

2.4. Model LSTM

Long Short-Term Memory (LSTM) adalah algoritma yang dikenal memiliki kemampuan mumpuni dalam membangun model prediksi. LSTM merupakan turunan dari *Recurrent Neural Network* (RNN), sebuah metode yang dirancang untuk mengolah data berurutan (*sequence*). RNN memiliki masalah *vanishing* dan *exploding gradient*. LSTM dikembangkan untuk mengatasi masalah gradien yang menghilang pada RNN ketika menghadapi *vanishing* dan *exploding gradient* [23]. Dalam peramalan, LSTM bekerja dengan berikut, 1. *Input Sequences*, yaitu Model menerima data historis sebagai input dalam bentuk deret waktu, lalu 2. *Memori Jangka Panjang & Pendek*, yaitu LSTM memiliki *cell state* (memori utama) dan *gates* (*Forget, Input, Output*) yang mengatur informasi mana yang harus disimpan atau dilupakan [24].

2.4.1. Evaluasi Model LSTM

Model dievaluasi menggunakan metode *grid search*, di mana dilakukan pencarian kombinasi parameter terbaik untuk arsitektur LSTM yang menghasilkan performa optimal. Evaluasi dilakukan dengan menghitung nilai *Mean Square Error* (MSE) dan *Root Mean Square Error* (RMSE) pada data uji. Model dengan nilai MSE dan RMSE terkecil dianggap sebagai model terbaik karena menunjukkan bahwa prediksi yang dihasilkan memiliki tingkat kesalahan paling rendah dibandingkan model lainnya. Dengan demikian, model yang terpilih memiliki kemampuan generalisasi yang lebih baik dalam memprediksi data masa depan [sabar].

2.5. Peramalan Model SARIMA dan LSTM

Peramalan adalah kegiatan mengestimasi apa yang akan terjadi pada masa yang akan datang. Peramalan diperlukan karena adanya kesenjangan waktu (*timelag*) antara kesadaran akan kebutuhan suatu kebijakan baru dengan waktu pelaksanaan kebijakan tersebut. Jika perbedaan waktu tersebut cukup panjang, maka peran peramalan menjadi sangat penting, terutama dalam menentukan waktu terjadinya suatu peristiwa sehingga dapat dipersiapkan tindakan yang diperlukan. Metode peramalan membantu dalam menganalisis tingkah laku atau pola dari data historis, sehingga memberikan pendekatan yang sistematis dan pragmatis dalam pemecahan masalah. Selain itu, metode ini juga meningkatkan tingkat keyakinan terhadap ketepatan hasil ramalan yang dihasilkan. Peramalan dilakukan menggunakan model SARIMA terbaik, yang mengombinasikan *autoregression* (AR), *moving average* (MA), dan *diferensiasi* untuk menghasilkan prediksi yang lebih akurat terhadap data runtun waktu dengan pola musiman. Selain itu, peramalan juga dilakukan menggunakan model LSTM terbaik, yang telah dipilih berdasarkan evaluasi nilai *Mean Square Error* (MSE) dan *Root Mean Square Error* (RMSE), memastikan model yang digunakan memiliki performa optimal dalam memprediksi data masa depan.

2.6. Perbandingan Model SARIMA dan LSTM

Peramalan Dalam evaluasi performa, model terbaik dipilih berdasarkan nilai kesalahan terkecil, yaitu *Mean Square Error* (MSE), *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE) [26]. MSE dan RMSE memberikan penalti lebih besar pada kesalahan yang lebih besar, sedangkan MAE mengukur rata-rata selisih absolut antara nilai aktual dan prediksi tanpa mempertimbangkan arah kesalahan, serta MAPE mengukur kesalahan dalam bentuk persentase untuk mempermudah perbandingan dalam berbagai skala data. Jika data menunjukkan pola musiman yang stabil dan hubungan linear yang kuat, model SARIMA lebih akurat dalam menangkap pola musiman dan tren yang dapat direpresentasikan secara statistik, sedangkan model LSTM lebih unggul dalam menangkap pola yang kompleks dan non-linear yang sulit ditangkap oleh metode statistik. Oleh karena itu, pemilihan model terbaik bergantung pada karakteristik data serta hasil evaluasi performa masing-masing metode berdasarkan metrik MSE, RMSE, MAE, dan MAPE.

3. Hasil dan Pembahasan

Pada bagian ini akan dijelaskan hasil dari analisis data ekspor migas Indonesia menggunakan model SARIMA dan LSTM. Proses analisis SARIMA mencakup tahapan dekomposisi musiman, uji stasioneritas, analisis ACF dan PACF, pembangunan model SARIMA, aluasi model SARIMA. Sedangkan proses analisis LSTM mencakup pembangunan model LSTM dan evaluasi model LSTM. Serta proses peramalan data untuk memproyeksikan nilai ekspor migas 11 bulan ke depan dari kedua model tersebut, lalu uji model terbaik. Setiap tahapan dilengkapi dengan visualisasi data berupa *plot* untuk memberikan gambaran yang lebih jelas mengenai hasil analisis. Hasil tersebut disajikan secara sistematis melalui subbab berikut.

3.1. Pengolahan Data

Pengolahan data dilakukan dengan bantuan *library numpy* dan *matplotlib*. Gambar berikut menunjukkan grafik data ekspor migas Indonesia dari bulan Januari 2000 hingga bulan Januari 2025 yang telah diolah menggunakan *python*. Data ini memberikan gambaran fluktuasi ekspor migas dalam kurun waktu tersebut.



Gambar 1. Grafik Ekspor Migas

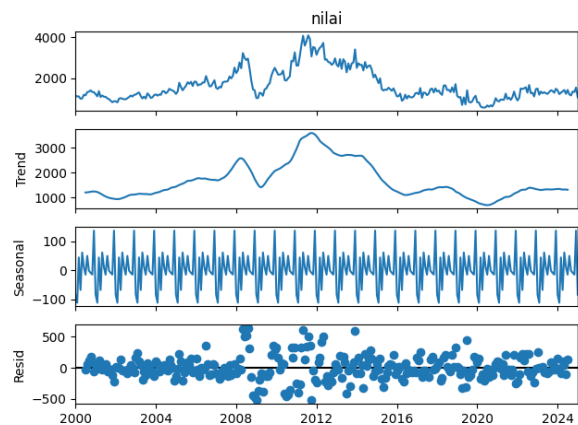


Gambar 2. Data Training dan Data Testing

Dari grafik ini, terlihat bahwa data memiliki pola fluktuatif dengan tren tertentu, yang perlu dianalisis lebih lanjut untuk menentukan model yang sesuai. Untuk menganalisis tren tersebut, maka peneliti membagi data tersebut menjadi data *train* (80%) dan data *testing* (20%) untuk hasil prediksi yang lebih akurat.

3.2. SARIMA

Melakukan uji dekomposisi dengan *library statsmodels* untuk melihat tren dan pola dari data training agar dapat menentukan penggunaan model ARIMA atau SARIMA.



Gambar 3. Tren dan Pola data

Data menunjukkan adanya komponen tren dengan pola kenaikan dan penurunan jangka panjang yang mencerminkan perubahan tren secara keseluruhan. Selain itu, terdapat komponen musiman yang ditandai dengan pola naik-turun yang berulang secara teratur, kemungkinan dengan periode 12 bulan ($s = 12$), yang mengindikasikan adanya musiman tahunan dalam data berskala bulanan. Sementara itu, komponen residual menunjukkan fluktuasi acak tanpa pola tertentu, yang mencerminkan adanya faktor-faktor lain yang tidak dijelaskan oleh tren dan musiman dalam data. Sehingga peneliti menyimpulkan bahwa model SARIMA lebih bagus digunakan untuk data yang memiliki pola musiman.

3.2.1. Uji Stasioneritas

Uji stasioneritas dilakukan dengan *library statsmodels*. Untuk menguji apakah data runtut waktu yang digunakan dalam penelitian ini stasioner atau tidak,

dilakukan uji akar unit menggunakan metode *Augmented Dickey-Fuller* (ADF). Uji ini bertujuan untuk menghindari regresi palsu (*spurious regression*) yang dapat terjadi jika data tidak stasioner. Hipotesis yang diuji dalam metode ini adalah:

H_0 : Data tidak stasioner (memiliki akar unit)

H_1 : Data stasioner (tidak memiliki akar unit)

Hasil uji ADF dibandingkan dengan nilai kritis McKinnon pada tingkat signifikansi 1%, 5%, dan 10%. Jika nilai t-statistik lebih besar dari nilai kritis McKinnon, maka H_0 ditolak, yang menunjukkan bahwa data sudah stasioner. Berikut adalah hasil pengujian yang dilakukan:

```
Hasil Uji ADF:  
ADF Statistic: -1.9142854323685172  
P-Value: 0.3253709223534479  
Kritikal Nilai:  
1%: -3.458128284586202  
5%: -2.873761835239286  
10%: -2.5732834559706235  
Data tidak stasioner (Gagal tolak  $H_0$ )
```

Gambar 4. *Augmented Dickey-Fuller* data asli

Hasil uji ADF pada data asli menunjukkan nilai t-statistik sebesar -1.914285 dengan *p-value* sebesar 0.325370. Nilai ini lebih besar dibandingkan dengan nilai kritis McKinnon pada tingkat signifikansi 1% (-3.458128), 5% (-2.873761), dan 10% (-2.573283). Oleh karena itu, H_0 tidak dapat ditolak, yang berarti data tidak stasioner pada level *series*. Karena data tidak stasioner maka di perlukan tahapan *differencing* agar data menjadi stasioner.

```
Hasil Uji ADF:  
ADF Statistic: -20.697818560104434  
P-Value: 0.0  
Kritikal Nilai:  
1%: -3.458128284586202  
5%: -2.873761835239286  
10%: -2.5732834559706235  
Data stasioner (Tolak  $H_0$ )
```

Gambar 5. ADF Setelah satu kali *differencing*


Setelah dilakukan *differencing* satu kali, hasil uji ADF menunjukkan nilai t-statistik sebesar -5.805633 dengan *p-value* sebesar 4.523561e-07. Nilai ini juga lebih kecil dibandingkan dengan nilai kritis McKinnon pada tingkat signifikansi 1% (-3.453423), 5% (-2.871699), dan 10% (-2.572183). Dengan demikian, H_0 ditolak, yang berarti data sudah stasioner setelah dilakukan *differencing* satu kali.

Berdasarkan hasil pengujian ADF, data asli tidak stasioner pada level *series*. Namun, setelah dilakukan *differencing* sebanyak satu kali, data menjadi stasioner. Oleh karena itu, proses *differencing* satu kali digunakan untuk memastikan bahwa data runtut waktu yang digunakan dalam penelitian ini telah memenuhi asumsi stasioneritas, maka diketahuilah nilai $d = D = 1$.


3.2.2. Analisis *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (ACF)

Selanjutnya setelah melakukan stasioneritas data, maka akan di lakukan analisis terhadap *lag* ACF dan PACF. Plot ACF dan PACF di buat dengan *library statsmodels*, dimana data yang akan digunakan untuk melakukan analisis ini adalah data sebelum *differencing* sebagai analisis nilai *p* dan *q* dan data yang telah di *differencing* sebanyak satu kali yang menjadi acuan nilai *P* dan *Q*.

Berikut adalah plot *Autocorrelation Function* (ACF) dari data ekspor migas sebelum *differencing* dan sesudah *differencing*.



Gambar 6. *Autocorrelation Function* sebelum *differencing*




Gambar 7. *Autocorrelation Function* sesudah *differencing*


Plot *Autocorrelation Function* (ACF) sebelum *differencing* menunjukkan pola eksponensial decay secara perlahan, yang merupakan ciri khas dari proses *Autoregressive* (AR). Pola ini menandakan bahwa data memiliki komponen AR yang dominan, dan karena ACF tidak langsung terputus (*cutoff*) tetapi mengalami peluruhan bertahap, hal ini lebih mendukung model AR dibandingkan MA. Selain itu, karena ACF tidak menunjukkan *cutoff* yang jelas dalam beberapa *lag* pertama, tetapi justru mengalami penurunan bertahap, ini mengindikasikan bahwa nilai *q* kemungkinan kecil, 0, 1, atau 2. Namun, karena tidak menunjukkan terjadinya *cutoff* pada lag-lag ACF, sehingga dapat di

ambil nilai $q = 0$. Sedangkan pada plot ACF setelah *diffrencing* menunjukkan adanya *cutoff* pada *lag* pertama, sehingga nilai $Q = 1$.

Gambar berikut menunjukkan plot *Partial Autocorrelation Function* (PACF) sebelum *diffrencing* dan sesudah *diffrencing*.



Gambar 8. *Partial Autocorrelation Function* sebelum *diffrencing*



Gambar 9. *Partial Autocorrelation Function* sesudah *diffrencing*

Terlihat dari plot *Partial Autocorrelation Function* bahwa nilai PACF signifikan hingga lag 2 sebelum mengalami pemotongan tajam (*cutoff*) dan kembali ke sekitar nol pada lag berikutnya. Pola ini merupakan indikasi bahwa model *Autoregressive* (AR) lebih dominan dibandingkan *Moving Average* (MA). Dengan adanya nilai PACF yang signifikan hingga lag 2, pemilihan orde p (*Autoregressive*) yang optimal adalah $p = 2$, karena *lag* tersebut masih memiliki pengaruh terhadap observasi saat ini, sementara lag selanjutnya tidak menunjukkan signifikansi yang cukup. Sedangkan pada plot PACF setelah *diffrencing* menunjukkan adanya *cutoff* pada *lag* pertama, sehingga nilai $P = 1$. Hal ini mendukung penggunaan model SARIMA dengan komponen *autoregressive* hingga orde 2 untuk menangkap pola hubungan dalam data secara lebih akurat.

Kombinasi antara hasil ACF dan PACF memberikan dasar untuk menentukan struktur model SARIMA yang sesuai. Berdasarkan analisis ini, nilai parameter awal yang disarankan adalah $p = 2, q = 0, P = 1, dan Q = 1$.

3.2.3 Evaluasi Model SARIMA


Pemilihan model terbaik dilakukan dengan metode *searching grid* yang membandingkan nilai *Log Likelihood*, *Akaike's Information Criterion* (AIC), dan *Bayesian Information Criterion* (BIC) dari masing-masing model yang diuji. Model dengan nilai *Log Likelihood*, AIC, dan BIC terkecil dianggap sebagai model yang paling baik untuk menggambarkan data dan menghasilkan peramalan yang optimal. Hasil perbandingan kinerja model dapat dilihat pada tabel berikut:

Tabel 2. Nilai Perbandingan Model SARIMA

Model SARIMA (p, d, q, P, D, Q, S)	Log Likelihood	AIC	BIC
(2, 1, 1)x(1, 1, 1, 12)	-1571.067	3154.134	3174.684
(2, 1, 0)x(1, 1, [1], 12)	-1570.794	3151.588	3168.713
(1, 1, 0)x(2, 1, [1], 12)	-1570.942	3151.885	3169.009
(1, 1, 1)x(1, 1, 1, 12)	-1570.671	3151.343	3168.467
(2, 1, 2)x(2, 1, 2, 12)	-1569.173	3156.347	3187.171
(2, 1, 2)x(1, 1, [1], 12)	-1569.265	3152.530	3176.505

Berdasarkan hasil estimasi model SARIMA, pemilihan model terbaik dilakukan dengan mempertimbangkan nilai *Akaike's Information Criterion* (AIC), *Bayesian Information Criterion* (BIC), dan *Log Likelihood*, di mana model dengan nilai AIC dan BIC lebih kecil dianggap lebih baik karena menunjukkan keseimbangan antara kompleksitas model dan kecocokan data. Dari hasil estimasi, model dengan AIC terkecil adalah (1, 1, 1)x(1, 1, 1, 12) dengan nilai AIC sebesar 3151.343, sedangkan model dengan BIC terkecil adalah (2, 1, 0)x(1, 1, [1], 12) dengan nilai BIC sebesar 3168.713. Model dengan AIC lebih kecil cenderung memberikan akurasi prediksi yang lebih baik, sementara model dengan BIC lebih kecil lebih sederhana dan berpotensi menghindari *overfitting*.

Berdasarkan pertimbangan tersebut, model (1, 1, 1)x(1, 1, 1, 12) dipilih sebagai model terbaik karena memiliki AIC terendah, yang menunjukkan keseimbangan optimal antara akurasi dan kompleksitas model. Model ini diharapkan mampu menghasilkan prediksi yang lebih akurat dibandingkan model lainnya, sehingga lebih sesuai untuk digunakan dalam peramalan ke depan.



Gambar 10. Model SARIMA (1, 1, 1)x(1, 1, 1, 12)


3.2.4. Implementasi Peramalan SARIMA

Setelah menentukan model terbaik, yaitu SARIMA (1, 1, 1)x(1, 1, 1, 12), langkah selanjutnya adalah mengimplementasikan model tersebut untuk melakukan peramalan. Implementasi dilakukan menggunakan *library statsmodels* pada *Python*. Peramalan ini bertujuan untuk memprediksi nilai ekspor migas Indonesia selama 11 bulan ke depan (11 langkah ke depan). Hasil peramalan disajikan dalam Tabel 3 berikut:

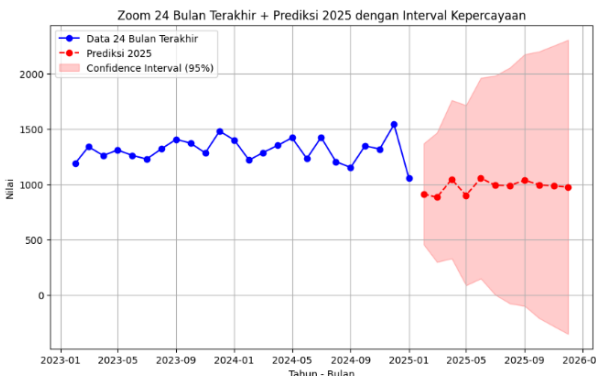
Tabel 3. Hasil Peramalan

Waktu	Nilai (Juta \$)
Feb-2025	911.605108
Mar-2025	881.500522
Apr-2025	1043.689382
May-2025	899.488579
Jun-2025	1054.102580
Jul-2025	990.500661
Aug-2025	987.414695
Sep-2025	1036.541426
Oct-2025	994.173266
Nov-2025	983.959530
Dec-2025	974.910587

Hasil peramalan ini juga divisualisasikan dalam bentuk grafik untuk memberikan gambaran yang lebih jelas mengenai tren pergerakan nilai ekspor migas di masa depan.



Gambar 11. Grafik Hasil Peramalan SARIMA




Gambar 12. Grafik Hasil Peramalan SARIMA (Zoom 24 Bulan)

Dari tabel dan grafik, terlihat bahwa nilai ekspor migas Indonesia diproyeksikan akan mengalami Peningkatan dan penurunan secara bergantian selama 11 bulan ke depan.

3.3. LSTM

Model LSTM di buat menggunakan *python* dengan bantuan dari *library tensorflow*. Model ini otomatis di bangun dalam pemrograman, dimana LSTM mengambil 80% data training sebagai datasetnya, lalu melakukan prediksi dengan mengvaluasi model berdasarkan nilai MSE, RMSE, MAE, dan MAPE terkecil. Berikut merupakan hasilnya.



Gambar 13. Hasil Evaluasi Model LSTM

Dari Hasil tersebut terlihat LSTM mengevaluasi beberapa model, hingga model terbaik terpilih dengan nilai MSE: 0.0068, RMSE: 0.0827, MAE: 0.0604, dan MAPE: 98.21%.


3.3.1. Implementasi Peramalan LSTM

Setelah menentukan model terbaik selanjutnya adalah mengimplementasikan model tersebut untuk melakukan peramalan. Implementasi dilakukan menggunakan *library statsmodels* pada *Python*. Peramalan ini bertujuan untuk memprediksi nilai ekspor migas Indonesia selama 11 bulan ke depan (11 langkah ke depan). Hasil peramalan disajikan dalam Tabel 4 berikut:


Tabel 4. Hasil Peramalan

Waktu	Nilai (Juta \$)
Feb-2025	1382.788818
Mar-2025	1398.062500
Apr-2025	1425.431030
May-2025	1448.948730
Jun-2025	1475.994751
Jul-2025	1506.997681
Aug-2025	1538.367920
Sep-2025	1583.971436
Oct-2025	1627.620605
Nov-2025	1675.514160
Dec-2025	1705.800293

Hasil peramalan ini juga divisualisasikan dalam bentuk grafik untuk memberikan gambaran yang lebih jelas mengenai tren pergerakan nilai ekspor migas di masa depan.



Gambar 14. Grafik Hasil Peramalan LSTM



Gambar 15. Grafik Hasil Peramalan LSTM (Zoom 24 Bulan)

Dari tabel dan grafik, terlihat bahwa nilai ekspor migas Indonesia diproyeksikan akan mengalami Peningkatan dan penurunan secara bergantian selama 11 bulan ke depan.

3.4. Uji Model Terbaik

Setelah mendapatkan hasil dari peramalan menggunakan model SARIMA dan LSTM, penelitian akan dilanjutkan dengan menguji model terbaik berdasarkan nilai MSE, RMSE, dan MAPE. Berikut merupakan perbandingannya.

Tabel 5. Perbandingan Model

Metrik	LSTM	SARIMA	Mana yang Lebih Baik
MSE (<i>Mean Squared Error</i>)	0.0068	114732.26	LSTM lebih baik (lebih kecil)
RMSE (<i>Root Mean Squared Error</i>)	0.0827	338.72	LSTM lebih baik (lebih kecil)
MAPE (<i>Mean Absolute Percentage Error</i>)	98.21%	27.20%	SARIMA lebih baik (lebih kecil)

LSTM memiliki MSE dan RMSE yang sangat kecil, yang menunjukkan bahwa kesalahan absolutnya lebih rendah dibandingkan SARIMA. Namun, meskipun kesalahan absolutnya kecil, model ini tidak menjamin akurasi yang baik dalam perhitungan kesalahan relatif terhadap data asli.

Di sisi lain, SARIMA memiliki MAPE yang jauh lebih kecil (27.20%) dibandingkan LSTM (98.21%), yang menunjukkan bahwa SARIMA lebih akurat dalam memprediksi nilai dengan mempertimbangkan skala data asli. MAPE LSTM yang sangat besar (98.21%) mengindikasikan bahwa model ini tidak mampu menangkap pola data dengan baik atau mungkin mengalami *overfitting*, di mana model terlalu menyesuaikan dengan data latih tetapi tidak bekerja dengan baik untuk data baru.

Berdasarkan evaluasi ini, SARIMA lebih direkomendasikan karena lebih stabil dan memiliki akurasi relatif yang lebih baik (MAPE lebih rendah), sehingga lebih dapat diandalkan untuk peramalan data ke depan.



Gambar 16. Grafik Hasil Peramalan Nilai Ekspor MIGAS

3.5. Implikasi Hasil

1. Implikasi Teoritis

Penelitian ini memberikan kontribusi signifikan dalam pengembangan metode peramalan data runtun waktu, khususnya melalui implementasi model SARIMA dan LSTM. Dengan memanfaatkan analisis ACF, PACF, uji stasioneritas, dan evaluasi model, penelitian ini menawarkan pendekatan yang sistematis dalam menentukan model terbaik untuk peramalan data ekonomi. Hasil penelitian menunjukkan bahwa SARIMA lebih unggul dibandingkan LSTM dalam peramalan nilai ekspor migas Indonesia, berdasarkan evaluasi metrik kesalahan peramalan.

Dalam perbandingan kedua model, SARIMA memiliki tingkat akurasi yang lebih baik dibandingkan LSTM, terutama dalam *Mean Absolute Percentage Error* (MAPE), yang menunjukkan bahwa SARIMA lebih mampu menangkap pola tren data dibandingkan LSTM yang cenderung mengalami *overfitting*. Meskipun model berbasis deep learning seperti LSTM sering digunakan dalam peramalan data runtun waktu, hasil penelitian ini menunjukkan bahwa dalam kasus nilai ekspor migas Indonesia, model SARIMA lebih dapat diandalkan dalam menghasilkan prediksi yang lebih akurat dan stabil.

Selain itu, penelitian ini memperkaya literatur tentang metode peramalan dan memberikan bukti empiris mengenai efektivitas model SARIMA dalam menghasilkan prediksi yang akurat. Hasil penelitian ini juga menegaskan bahwa pemilihan model peramalan harus disesuaikan dengan karakteristik data yang digunakan, di mana dalam konteks ini, data ekspor migas dengan pola musiman lebih sesuai dengan pendekatan SARIMA dibandingkan LSTM. Pendekatan yang digunakan dalam penelitian ini dapat menjadi referensi bagi peneliti lain yang ingin menerapkan metode serupa pada berbagai jenis data runtun waktu dengan pola musiman yang kuat.

2. Implikasi Praktis

Hasil peramalan nilai ekspor migas Indonesia memiliki berbagai manfaat praktis yang dapat digunakan oleh

pemerintah dan pemangku kepentingan terkait dalam mendukung pengambilan keputusan strategis.

1. Interpretasi Hasil Prediksi

Hasil prediksi menunjukkan adanya fluktuasi nilai ekspor migas selama periode peramalan. Fluktuasi ini dapat disebabkan oleh berbagai faktor, seperti pola musiman, volatilitas harga minyak global, perubahan permintaan dan penawaran internasional, serta kebijakan ekonomi domestik dan global. Pola musiman yang muncul dalam hasil prediksi dapat mengindikasikan adanya siklus tertentu dalam ekspor migas, yang perlu dianalisis lebih lanjut untuk memahami tren jangka panjang dan faktor yang memengaruhinya.

2. Perencanaan Kebijakan Ekonomi

Hasil peramalan ini dapat menjadi dasar dalam penyusunan kebijakan ekonomi terkait ekspor migas. Pemerintah dapat menggunakan informasi ini untuk menyesuaikan tarif ekspor, menyusun strategi perdagangan internasional, serta merancang diversifikasi sumber pendapatan negara agar lebih berkelanjutan.

3. Manajemen Risiko Ekonomi

Prediksi tren ekspor migas membantu stakeholder mengantisipasi potensi risiko ekonomi, seperti fluktuasi harga minyak global atau ketidakstabilan pasar internasional. Dengan memanfaatkan hasil peramalan ini, pemerintah dan industri dapat merencanakan tindakan mitigasi risiko yang lebih efektif guna menjaga stabilitas ekonomi.

4. Optimalisasi Investasi Sektor Migas

Perusahaan migas dapat memanfaatkan hasil penelitian ini untuk mengarahkan investasi jangka panjang dan mengoptimalkan kapasitas produksi sesuai dengan proyeksi permintaan ekspor. Dengan prediksi yang lebih akurat, industri dapat mengalokasikan sumber daya secara lebih efisien guna meningkatkan profitabilitas dan daya saing.

5. Penguatan Diplomasi Ekonomi

Informasi dari hasil peramalan ini dapat menjadi salah satu indikator dalam proses negosiasi perdagangan internasional. Tren ekspor migas yang stabil dapat memberikan posisi tawar yang lebih baik dalam perjanjian dagang atau kerja sama strategis dengan mitra internasional.

6. Analisis Lebih Mendalam dan Rekomendasi Kebijakan

Penelitian ini masih terbatas pada prediksi nilai ekspor tanpa mengevaluasi dampak fluktuasi ekspor terhadap perekonomian Indonesia. Analisis lebih lanjut diperlukan untuk memahami bagaimana perubahan nilai ekspor migas memengaruhi pendapatan negara, stabilitas ekonomi, serta

investasi di sektor energi. Selain itu, rekomendasi kebijakan berbasis hasil prediksi dapat dikembangkan, seperti strategi diversifikasi ekspor, optimalisasi kapasitas produksi, serta penguatan kerja sama perdagangan internasional guna menjaga stabilitas pasar migas.

Secara keseluruhan, penelitian ini tidak hanya memberikan gambaran tentang proyeksi nilai ekspor migas Indonesia selama 11 bulan ke depan, tetapi juga menyediakan dasar bagi evaluasi, perencanaan, dan implementasi kebijakan ekonomi yang lebih terarah. Dengan memahami tren data historis dan prediksi masa depan, pemerintah dan pemangku kepentingan dapat mengambil langkah strategis yang lebih terukur guna mendukung pertumbuhan ekonomi nasional.

4. Kesimpulan

Penelitian ini membandingkan metode SARIMA dan LSTM dalam memprediksi nilai ekspor migas Indonesia. Model SARIMA(1,1,1)(1,1,1,12) dipilih sebagai model terbaik berdasarkan nilai AIC terendah dan hasil evaluasi residual yang menunjukkan bahwa model memenuhi asumsi stationarity. Model LSTM diuji dengan optimasi parameter dan evaluasi berbasis *Mean Squared Error* (MSE) serta *Root Mean Squared Error* (RMSE), namun menunjukkan *Mean Absolute Percentage Error* (MAPE) yang lebih tinggi dibandingkan SARIMA.

Hasil peramalan menunjukkan adanya fluktuasi nilai ekspor migas selama 11 bulan ke depan, dengan tren kenaikan dan penurunan musiman. Model SARIMA terbukti lebih akurat dalam menangkap pola musiman dibandingkan LSTM, yang cenderung mengalami *overfitting* terhadap data latih. Oleh karena itu, SARIMA lebih direkomendasikan untuk peramalan data ekspor migas yang memiliki pola musiman yang jelas.

Implikasi dari hasil penelitian ini mencakup dukungan bagi perumusan kebijakan perdagangan dan ekonomi, optimalisasi kapasitas produksi migas, serta perencanaan strategi investasi yang lebih adaptif terhadap dinamika pasar global. Meskipun model SARIMA telah memberikan hasil prediksi yang baik, penelitian lebih lanjut dapat dilakukan dengan mempertimbangkan model *hybrid* atau teknik *deep learning* lainnya untuk meningkatkan akurasi prediksi jangka panjang.

SUMBER RUJUKAN

Referensi

- [1] N. K. Rumokoy, "Pelanggaran hukum terhadap penggunaan minyak dan gas bumi (migas) yang terkandung di dalam wilayah hukum pertambangan Indonesia oleh pihak yang tidak berwenang," *Jurnal Hukum Unsrat*, vol. 22, no. 5, pp. 40-55, 2016.
- [2] F. Y. Tryono, "Peranan geologi dalam sistem hidrokarbon serta potensi dan tantangan eksplorasi migas di Indonesia," *Swara Patra: Majalah Ilmiah PPSDM Migas*, vol. 6, no. 2. [Online]. Available: <https://ejournal.ppsdmmigas.esdm.go.id/sp/index.php/swaraptra/article/view/131>. [Accessed: Dec. 20, 2024].

- [3] Cynthia, S. Sugiman, and Z. Zaenuri, "Analisis perbandingan menggunakan ARIMA dan bootstrap pada peramalan nilai ekspor Indonesia," *Jurnal Matematika Unnes*, DOI: 10.15294/ujm.v5i1.13102, 2017.
- [4] E. Nurhasanah, Y. Sukmawaty, and M. Maisarah, "Peramalan Ekspor Migas di Indonesia Menggunakan Pendekatan Seasonal Autoregressive Integrated Moving Average with Exogenous (SARIMAX)," *Indonesian Journal of Applied Statistics*, vol. 7, no. 1, p. 87, Oct. 2024, doi: 10.13057/ijas.v7i1.84934.
- [5] A. Dwi Ramadhan, A. Fauzan, and R. Artikel, "Prediksi Nilai Ekspor Non-Migas Di Jawa Barat Menggunakan Metode Seasonal Auto Regresif Integrated Moving Average (SARIMA) P-ISSN E-ISSN," 2023.
- [6] R. Julian and M. R. Pribadi, "Peramalan Harga Saham Pertambangan Pada Bursa Efek Indonesia (BEI) Menggunakan Long Short Term Memory (LSTM)," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 8, no. 3, 2021, [Online]. Available: <http://jurnal.mdp.ac.id>
- [7] Badan Pusat Statistik (BPS), "Nilai Ekspor Migas-NonMigas," Jakarta, 2024. [Online]. Available: <https://www.bps.go.id/id/statistics-table/2/MTc1MyMy/nilai-ekspor-migas-nonmigas.html>. [Accessed: Dec. 20, 2024].
- [8] R. Rahmadayanti, B. Susilo, dan D. Puspitaningrum, "Perbandingan Keakuratan Metode Autoregressive Integrated Moving Average (ARIMA) dan Exponential SMOOTHING Pada Peramalan Penjualan Semen di PT. Sinar Abadi", *Rekursif*, vol. 3, no. 1, Jul 2015.
- [9] Z. Ihwati, I. Rosyidah, Y. S. Sirait, and R. S. Pontoh, "Prediksi Nilai Ekspor Migas di Indonesia Menggunakan Analisis Autoregressive Integrated Moving Average (ARIMA)," in *E-Prosiding Seminar Nasional Statistika Aktuaria*, Dept. Statistika FMIPA, Universitas Padjadjaran, vol. 1, pp. 136–149, 2022. DOI: 10.1234/snsa.v1i.273.
- [10] F. Inka Durrah, T. Prihartina Parhusip, A. Rusyana, J. Statistika, U. Syiah Kuala, and B. Aceh, "Peramalan Jumlah Penumpang Pesawat Di Bandara Sultan Iskandar Muda Dengan Metode SARIMA (Seasonal Autoregressive Integrated Moving Average)," 2018.
- [11] P. Astuti and F. J. Ayuningtyas, "Pengaruh ekspor dan impor terhadap pertumbuhan ekonomi di Indonesia," *Jurnal Ekonomi dan Studi Pembangunan*, vol. 19, no. 1, DOI: 10.18196/jesp.19.1.3836, 2018.
- [12] Y. Siswanti, "Peramalan curah hujan di kota Yogyakarta dengan model fungsi transfer multivariant," in *Pemantapan Keprofesionalan Peneliti Pendidik Dan Prakt. MIPA Untuk Mendukung Pembangunan Karakter Bangsa*, 2011.
- [13] R. P. Budiman, "Pembuatan aplikasi peramalan indeks harga saham gabungan dengan metode time series autoregressive integrated moving average (ARIMA)," B.S. thesis, Institut Teknologi Sepuluh Nopember, Surabaya, 2017. [Online]. Available: <http://repository.its.ac.id/id/eprint/42214>.
- [14] R. J. Hyndman and G. Athanasopoulos, *Forecasting: principles and practice*. Melbourne: OTexts, 2018.
- [15] The Ohio State University, "ARMA Models." [Online]. Available: <http://www.econ.ohio-state.edu/dejong/note2.pdf>. [Accessed: May 2018].
- [16] Wharton School of the University of Pennsylvania, "Introduction to ARMA Models." [Online]. Available: http://www.stat.wharton.upenn.edu/~stine/stat910/lectures/08_intro_arma.pdf. [Accessed: May 2018].
- [17] "Applied problems of data analysis," Coursera. [Online]. Available: <https://www.coursera.org/learn/data-analysisapplications/lecture/8yR4G/arima>. [Accessed: May 2018].
- [18] S. Abu, "Seasonal ARIMA with Python," 2016. [Online]. Available: <http://www.seanabu.com/2016/03/22/time-series-seasonalARIMA-model-in-python/>. [Accessed: May 2018].
- [19] D. M. Putri and Aghsilni, "Estimasi Model Terbaik Untuk Peramalan Harga Saham PT. Polychem Indonesia Tbk. Dengan Arima," *MAP Journal*, vol. 1, no. 1, pp. 1–12, 2019.
- [20] H. Yasin, A. Prahutama, T. W. Utami, D. Jurusan, and S. Undip, "PREDIKSI HARGA SAHAM MENGGUNAKAN SUPPORT VECTOR REGRESSION DENGAN ALGORITMA GRID SEARCH," *MEDIA STATISTIKA*, vol. 7, pp. 29–35, 2014.
- [21] B. Y. Pandji, I. Indwiarti, and A. A. Rohmawati, "Perbandingan Prediksi Harga Saham dengan model ARIMA dan Artificial Neural Network," *Indonesia Journal on Computing (Indo-JC)*, vol. 4, no. 2, pp. 189–198, 2019. DOI: 10.21108/indojc.2019.4.2.344.
- [22] Sudarsono, "Jaringan syaraf tiruan untuk memprediksi laju pertumbuhan penduduk menggunakan metode backpropagation (studi kasus di Kota Bengkulu)," *Jurnal Media Infotama*, vol. 12, no. 1, pp. 61–69, 2016.
- [23] M. F. Rizkilloh and S. Widiyanesti, "Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short Term Memory (LSTM)," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 1, pp. 25–31, Feb. 2022, doi: 10.29207/resti.v6i1.3630.
- [24] R. Luthfiansyah and B. Wasito, "Penerapan Teknik Deep Learning (Long Short Term Memory) dan Pendekatan Klasik (Regresi Linier) dalam Prediksi Pergerakan Saham BRI," 2023.
- [25] S. Sautomo and H. F. Pardede, "Prediksi Belanja Pemerintah Indonesia Menggunakan Long Short-Term Memory (LSTM)," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 1, pp. 99–106, Feb. 2021, doi: 10.29207/resti.v5i1.2815.
- [26] H. D. E. Sinaga and N. Irawati, "PERBANDINGAN DOUBLE MOVING AVERAGE DENGAN DOUBLE EXPONENTIAL SMOOTHING PADA PERAMALAN BAHAN MEDIS HABIS PAKAI," *JURTEKSI (Jurnal Teknologi dan Sistem Informasi)*, vol. 4, pp. 197–204, 2018.