

PREDIKSI PERMINTAAN BATU BARA MENGGUNAKAN MACHINE LEARNING

Kristina Febriani¹⁾ dan Chastine Fatichah²⁾

¹⁾ Manajemen Teknologi, Institut Teknologi Sepuluh Nopember
Jalan Cokroaminoto 12A, Surabaya

²⁾ Teknik Informatika, Institut Teknologi Sepuluh Nopember
Sukolilo, Surabaya

e-mail: kristfe312@gmail.com¹⁾, chastine@if.its.ac.id²⁾

ABSTRAK

Peramalan kebutuhan permintaan batu bara penting untuk dilakukan agar dapat meminimalkan biaya operasional. Dengan adanya peramalan akan membantu perusahaan dalam menentukan jumlah dan waktu yang tepat untuk pemesanan batu bara dari pemasok. Penelitian tentang peramalan batu bara di Indonesia umumnya menggunakan pendekatan statistika dan belum melakukan analisis kinerja model peramalan yang lain. Penelitian ini bertujuan melakukan peramalan kebutuhan batu bara dengan menggunakan metode statistika dan machine learning yaitu ARIMA, Exponential Smoothing, Support Vector Regression (SVR), Recurrent Neural Network (RNN) dan Long Short-Term Memory (LSTM). Metode evaluasi yang digunakan untuk menganalisis kinerja peramalan yaitu Mean Absolute Error (MAE) dan Mean Absolute Percentage Error (MAPE). Data permintaan batu bara yang digunakan sebanyak 1097 data harian diambil dari Januari 2021 sampai dengan Desember 2022 yang berbentuk timeseries dan bersifat stasioner yang telah diuji menggunakan Augmented Dickey-Fuller (ADF). Hasil uji coba menunjukkan bahwa model ARIMA dengan nilai MAPE 5.11%, MAE 2.91 dan R-Square 0.925, Exponential Smoothing MAPE 1.07%, MAE 0.55 dan R-Square 0.997, SVR dengan nilai MAPE 5.48%, MAE 3.16 dan R-Square 0.88, RNN dengan nilai MAPE 5.19%, MAE 2.91 dan R-Square 0.896, LSTM dengan nilai MAPE 4.83%, MAE 2.84 dan R-Square 0.897. Dari hasil pengujian didapatkan bahwa exponential smoothing memiliki nilai error yang paling kecil diantara model lain. Dengan hasil peramalan yang memiliki tingkat error yang kecil maka dapat membantu manajemen dalam pengambilan keputusan untuk dapat meminimalkan biaya dalam pemesanan batu bara dan manajemen pergudangan

Kata kunci: Peramalan, ARIMA, Exponential smoothing, SVR, RNN, LSTM

COAL DEMAND PREDICTION MODEL USING MACHINE LEARNING METHODS

Kristina Febriani¹⁾ dan Chastine Fatichah²⁾

¹⁾ Technology Management, Institut Teknologi Sepuluh Nopember
Jalan Cokroaminoto 12A, Surabaya

²⁾ Informatics, Institut Teknologi Sepuluh Nopember
Sukolilo, Surabaya

e-mail: kristfe312@gmail.com¹⁾, chastine@if.its.ac.id²⁾

ABSTRACT

Forecasting coal demand needs is important to minimize operational costs. Forecasting will help companies determine the right amount and time to order coal from suppliers. Research on coal forecasting in Indonesia generally uses a statistical approach and has not analyzed the performance of other forecasting models. This research aims to forecast coal demand using statistical and machine learning methods, namely ARIMA, Exponential Smoothing, Support Vector Regression (SVR), Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM). The evaluation methods used to analyze forecasting performance are Mean Absolute Error (MAE) and Mean Absolute Percentage Error (MAPE). The new coal demand data used is 1097 daily data taken from January 2021 to December 2022 in the form of a timeseries and is stationary which has been tested using Augmented Dickey-Fuller (ADF). The test results show that the ARIMA model has MAPE value of 5.11%, MAE 2.91 and R-Square 0.925, Exponential Smoothing MAPE 1.07%, MAE 0.55 and R-Square 0.997, SVR with MAPE value of 5.48%, MAE 3.16 and R-Square 0.88, RNN with MAPE value of 5.19%, MAE 2.91 and R-Square 0.896, LSTM with MAPE value of 4.83%, MAE 2.84 and R-Square 0.897. From the test results it was found that exponential smoothing had the smallest error values among the other models. With forecasting results that have a small error rate, it can help management in making decisions to minimize costs in coal ordering and warehouse management.

Keywords: Forecasting, ARIMA, Exponential smoothing, SVR, RNN, LSTM

I. PENDAHULUAN

Pembangkit listrik tenaga uap merupakan salah satu pembangkit yang menyumbangkan pasokan listrik terbesar hingga saat ini. Penentuan fluktuasi output atau daya listrik yang disalurkan berdasarkan pesanan dari konsumen yang dalam kasus ini adalah bagian penyaluran listrik negara. Pengiriman bahan baku (batu bara) juga tidak selalu sama karena bergantung dengan beberapa faktor kebutuhan konsumen, kapasitas Gudang, kapasitas mesin, biomasa dan juga cuaca maupun ketersediaan penyedia dan kontrak yang sudah dibuat sebelumnya. Oleh sebab itu, dibutuhkan penyimpanan batu bara di coalyard yang menimbulkan biaya (Aviso, 2023). Berdasarkan data Januari 2020 sampai dengan Desember 2022 harga batu bara dengan pemakaian rata-rata harian 56,506 MT. Biaya yang ditimbulkan dari penyimpanan jika dihitung rata-rata tahunan 2,7 milyar yang didapat dari bunga pinjaman BI Rate 5,75% (Bank Indonesia, 2023) dan asumsi harga batu bara USD 191/MT Dan kurs dolar Rp. 15357 (per 24/9/2023). Biaya penyimpanan tidak hanya dihitung dari biaya investasi tetapi juga biaya yang timbul oleh penyimpanan sebesar 20% (Aviso, 2023). Karena itu, rata-rata mencapai 9,4 milyar, yang artinya biaya tahunan yang timbul akan mencapai 2,7 milyar ditambahkan dengan 9,4 Milyar yaitu 12,1 milyar. Beberapa riset telah dilakukan untuk dapat menghitung nilai optimal kebutuhan konsumen sehingga dapat meminimalkan biaya yang timbul karena penyimpanan. Peramalan kebutuhan energi telah dilakukan dengan menggunakan *Artificial Inteligent* (AI) seperti (Sharma, et al., 2023) dalam jurnalnya *Energy* dan AI membahas metode deep learning LSTM, (Chao & Hui, 2020) dan (Xiao, Li, & Zhang, 2022) membahas metode *Support Vector Regression* (SVR) dan *Edited Nearest Neighbor* (ENN) sebagai metode optimasi terbaik untuk pembangkit batu bara di Queensland. Untuk penelitian peramalan jumlah kebutuhan batu bara yang ada di Indonesia (Effendi & Rusdiansyah, 2020) yang membahas dari ketidakpastian dari permintaan pasar maka mengusulkan model dynamic simulation, (Rizki, et al., 2021) (Putra & Maulud, 2020) (Dai, Fang, & Yu, 2021) mengatakan metode *Moving AVERAGE* (MA), *the wighted MA*, *the single exponential smooting* dan *linear regression* dalam metode peramalannya.

Dengan data yang didapatkan dari PLTU diuji menggunakan beberapa metode seperti *plotting* dan *stationer augmented dickey fuller test* (ADF) dari situ ditemukan bahwa bentuk data adalah stasioner. Setelah melalui beberapa study literatur dan pengujian awal maka diputuskan untuk menggunakan beberapa Teknik dalam membuat model prediksi seperti ARIMA, *Single exponential smoothing*, SVR, RNN dan LSTM. Sebagai evaluasi validitas model menggunakan MAPE dan MAR. diharapkan dengan adanya peramalan permintaan energi maka akan lebih mudah untuk manajemen menentukan jumlah pembelian batu bara dan berapa jumlah yang harus distok, sehingga biaya akan dikeluarkan mendekati angka minimal.

II. KAJIAN PUSTAKA DAN DASAR TEORI

Pembangkit Listrik Tenaga Uap menggunakan energi panas yang didapat dari pembakaran batu bara untuk dapat menghasilkan listrik (BPPT, 2013). Proses pengiriman batu bara di PLTU Indonesia biasanya melibatkan beberapa tahapan (Cecep Mochammad Yasin, 2021) seperti perencanaan dan pembelian, penerimaan, penyimpanan dan penimbangan, persiapan dan penghancuran batu bara, pemuatan dan pengiriman, pemantauan dan rekonsiliasi *inventory*, penggunaan batu bara, penyusutan dan pembaruan *inventory*.

Data permintaan baru tersusun berdasarkan waktu yang dapat dikategorikan sebagai data *time series* atau data berdasarkan deret waktu (Geron, 2019). Peramalan dengan menggunakan deret waktu adalah proses memprediksi nilai-nilai masa depan suatu variabel berdasarkan data masa lalu variabel tersebut. Dalam hal ini perhitungan melibatkan pola analisis dan tren dalam data sebelumnya untuk memperoleh perkiraan yang paling akurat untuk masa depan. Sebelum menentukan metode mana yang harus dibuat untuk pemodelan maka kita harus menentukan pola data seperti *Trend*, data disebut *trend* ketika membutuhkan waktu lama untuk data bertambah atau berkurang dan bukan data linear. *Seasonal*, atau data musiman adalah ketika pola terbentuk atau dipengaruhi dari faktor musiman seperti waktu dalam tahun atau hari dalam minggu. *Cyclic* data muncul ketika data muncul naik dan jatuh dengan *frequency* yang tidak sama. Data yang fluktuatif biasanya terjadi karena kondisi ekonomi dan sering dihubungkan dengan perputaran bisnis.

Salah satu cara menentukan pola data yaitu dapat dilihat dari *ploting* datanya, apakah data membentuk pola tertentu, tetapi untuk lebih memastikan uji stasioner dapat dilakukan dengan metode *augmented Dickey-Fuller test* (ADF Test). Sangat penting untuk dapat mengetahui model data yang mana yang lebih cocok dalam peramalan (Kumar, 2023). *Augmented Dickey-Fuller test* (ADF Test) Metode ADF test sering disebut *root test* yang merupakan fitur dari proses *stochastic* yang dapat menyebabkan masalah dalam *model time series*. jika hasil *test* statistika $< \text{Critical value}$ dan $p\text{-value} < 0,05$ (*Reject Null Hypotesist* (H₀)) atau data *time series* tidak memiliki *unit root* yang artinya datanya stasioner.

Ada beberapa model *machine learning* yang dilakukan dalam penelitian ini yang akan ditulis dengan bantuan *software phyton*

a. ARIMA

Metode ARIMA memberikan pendekatan lain untuk peramalan dengan deret waktu. *Exponential smoothing* dan ARIMA adalah dua pendekatan yang paling banyak digunakan untuk peramalan deret waktu dan memberikan pendekatan komplementer untuk masalah ini. Model *Exponential smoothing* didasarkan pada deskripsi tren dan sensasional dalam data sedang model ARIMA bertujuan untuk menggambarkan korelasi dalam data. (Subagyo, 2004)

b. Single Exponential Smoothing

Metode *exponential smoothing* menggunakan pendekatan rata-rata yang dianalisa dari pengamatan sebelumnya. Semakin baru pengamatan semakin tinggi bobot pengamatannya. Kerangka kerja ini menghasilkan peramalan yang andal dengan cepat dan untuk berbagai rangkaian waktu. (Subagyo, 2004) *Taxonomy of exponential smoothing method* adalah metode yang tidak terbatas pada yang telah disediakan sejauh ini, dengan mempertimbangkan variasi dan kombinasi tren dan sensasional dan Sembilan metode *exponential smoothing* dimungkinkan. Rumus umum untuk menghitung ramalan dengan *single exponential smoothing* adalah

$$F_{t+1} = Y_t + (1 - \alpha) * F_t \tag{1}$$

F_{t+1} adalah ramalan untuk periode berikutnya.

Y_t adalah data aktual untuk periode saat ini.

F_t adalah ramalan untuk periode sebelumnya.

α adalah konstanta smoothing yang berada dalam rentang 0 hingga 1

Nilai α menentukan seberapa cepat sistem merespons perubahan baru dalam data. Menurut (Subagyo, 2004) metode ini lebih cocok digunakan untuk meramalkan hal-hal yang fluktuasinya secara random (tidak teratur)

c. SVR

(Geron, 2019) *Support Vector Regression* (SVR) adalah sebuah algoritma pembelajaran mesin yang digunakan untuk melakukan regresi, algoritma ini dapat melakukan klasifikasi yaitu dengan menemukan sebuah *hyperplane* (garis pembatas) yang paling baik untuk memisahkan kelas-kelas yang berbeda. Menurut (Scholkopt dan Smola, 2012), SVR bertujuan untuk menemukan sebuah fungsi $f(x)$ sebagai suatu *hyperplane* (garis pemisah) berupa fungsi regresi yang mana sesuai dengan semua *input* data dengan membuat *error* (ϵ) sekecil mungkin. Menurut Santoso (2007), Misalkan dipunyai l set data *training*, (X_i, Y_i) , $i = 1, 2, \dots, l$. x_i merupakan vektor *Input* $x = \{x_1, x_2, \dots, x_n\} \leq R^n$ dan *output* skalar $y = \{y_1, \dots, y_l\} \leq R$ dan l adalah banyaknya data *training*.

$$f(x) = w^T \vartheta(x) + b \tag{2}$$

w : *vector* pembobotan berdimensi l

$\vartheta(x)$: fungsi yang memetakan x pada ruang dengan l dimensi

b : bias

Agar mendapatkan generalisasi yang baik untuk fungsi regresi $f(x)$, dapat dilakukan dengan cara meminimalkan *norm* dari w . Oleh karena itu perlu adanya penyelesaian problem optimasi:


$$\text{Min } \frac{1}{2} \|w\|^2 \tag{3}$$

Dengan syarat

$$y_i - w^T \varphi(x_i) - b \leq \xi$$

$$w^T \varphi(x_i) - y_i + b \leq \xi \text{ dimana } i = 1, 2, \dots$$

Pada persamaan (3) diasumsikan bahwa semua titik berada dalam rentang $f(x) \pm \xi$ Dalam hal ke tidak layakkan (*infesiable*), dimana ada beberapa titik yang mungkin keluar dari



Gambar 1 Ilustrasi Support Vector Regression (SVR).


rentang $f(x) \pm \xi$ sehingga dapat ditambahkan variabel ξ dan ξ^* untuk mengatasi masalah pembatas yang tidak layak dalam masalah optimasi.

SVR memiliki fitur untuk memudahkan klasifikasi titik data dengan baik, maka di *convert* menjadi dimensi yang lebih rendah ke dimensi yang lebih tinggi menggunakan beberapa fungsi kuadrat yang memungkinkan untuk menemukan batasan data, fungsi ini dinamakan *kernel*. Berikut beberapa *kernel* dan rumus yang dapat di gunakan dalam SVR (Saini, 2023).

1. *Polinomial Kernel*

$$f(x_1, x_2) = (x_1^T \cdot x_{2+1})^d \tag{4}$$

yang mana x_1, x_2 adalah variable dan d adalah *degree*.




Gambar 2 Contoh polynomial kernel (Saini, 2023).

2. *Sigmoid Kernel*

Berikut adalah perhitungan matematis dari *sigmoid kernel*:

$$f(x_1, x_2) = \tanh(\alpha x^T x_2 + \beta) \tag{5}$$




Gambar 3 Contoh sigmoid kernel (Saini, 2023).

3. *Radial Basic Faction (RBF Kernel)*

Kernel ini juga disebut *kernel* Gaussian adalah *kernel* yang paling banyak digunakan dalam klasifikasi data yang tidak dapat dipisahkan secara linear, *kernel* ini dikenal memiliki performa yang baik dengan parameter tertentu dan hasil pelatihan memiliki nilai eror yang kecil dibandingkan *kernel* lainnya. berikut adalah rumus matematis dari RBF kernel.

$$f(x_1, x_2) = e \left(\frac{-\|x_1 - x_2\|^2}{2\sigma^2} \right) \tag{6}$$



Gambar 4 Contoh RBF kernel (Saini, 2023).

d. RNN

(Putra, 2020) Ide dasar RNN adalah membuat *topologi* jaringan yang mampu merepresentasikan data *sekuensial* atau *time series*. Secara lebih umum diberikan sebuah *sekuens input* $x = (x_1, \dots, x_t)$. data dari x_1 dipengaruhi oleh data sebelum-sebelum nya, ditulis sebagai $P(x_t | \{x_1, \dots, x_{t-1}\})$.

Perhitungan *hidden state* pada waktu ke t bergantung pada *input* pada waktu ke t (X_t) dan *hidden state* pada waktu sebelumnya (h_{t-1}). Konsep ini sesuai dengan prinsip *recurrent* yaitu mengingat kejadian sebelumnya yang dapat dituliskan dalam persamaan

$$h_t = f(x_t, h_{t-1}, b) \tag{7}$$

f = fungsi *aktivasi* (non-linier, dapat di turunkan)

t = waktu

X_t = *input* dengan waktu ke t

h_{t-1} = *hidden state* pada waktu sebelumnya


b = bias atau parameter yang diikuti sertakan pada fungsi *artificial neural network*

Kelebihan penggunaan model RNN adalah dapat memperkirakan hubungan antar data variabel dengan tetap memperhatikan sifat temporal dari variabel. Hasil performa model RNN juga terbukti dapat mengatasi kekurangan penelitian sebelumnya dimana orde dari *time lag* harus diatur secara manual dan menggunakan *delay feedback* pada *input layer* yang meningkatkan risiko *overfitting* data (Laubscher, 2019). Akan tetapi, *Recurrent neural network* sangat rentan terhadap masalah *exploding gradient* (gradien naik secara drastis) dan *vanishing gradient* (gradien hilang) pada proses *training*. Akibatnya, meskipun pada prinsipnya *recurrent neural network* memiliki kemampuan untuk menghubungkan informasi yang memiliki keterkaitan jarak jauh dalam *sekuens input*, masalah *vanishing gradient* dan *exploding gradient* ini akan membatasi kemampuan jaringan ini untuk mempelajari dependensi atau keterkaitan ini (Kelleher, et al., 2020)

e. LSTM

(Geron, 2019) *Long Short-Term Memory* (LSTM) adalah salah satu jenis arsitektur jaringan saraf tiruan yang digunakan untuk memproses data dalam bentuk urutan atau *sequence* data. LSTM dapat mempertahankan informasi yang relevan dari urutan sebelumnya dan mengabaikan informasi yang tidak relevan

LSTM sendiri terdiri dari unit-unit memori yang disebut *memory cell*, *input gate*, *output gate* dan *forget gate*. *Memory cell* dapat mengambil keputusan untuk menyimpan atau mengabaikan informasi yang dilewatkan ke dalamnya melalui *input gate*. *Output gate* mengontrol bagaimana informasi yang disimpan dalam *memory cell* dilewatkan ke dalam unit berikutnya secara berurutan. *Forget gate* memungkinkan LSTM untuk mengabaikan informasi yang tidak relevan dalam memori *cell*.



Gambar 5 Arsitektur LSTM (Dolphin, 2020).

Arsitektur LSTM memungkinkan jaringan saraf untuk mempelajari hubungan jangka pandang pada urutan data yang sulit dilakukan oleh arsitektur jaringan biasa seperti jaringan saraf berulang (RNN). Hal ini membuat LSTM sangat cocok digunakan dalam aplikasi pengenalan suara, analisis sentimen teks dan prediksi harga saham, yang semuanya melibatkan data dalam bentuk urutan.

Dalam pelatihan LSTM, algoritma optimasi yang digunakan biasanya adalah adam *optimizer* dan fungsi *aktivasi* yang digunakan adalah fungsi signoid atau fungsi tangen hiperbolik. Selain itu, untuk menghindari *overfitting* penggunaan regulasi seperti *dropout* dan L2 regularisasi sangat dianjurkan.

Secara keseluruhan, LSTM adalah arsitektur jaringan saraf yang kuat dan efektif untuk memproses data dalam bentuk urutan dan telah digunakan dalam berbagai aplikasi dalam bidang pengolahan bahasa alami dan analisis *time series*. Namun penggunaannya memerlukan pemahaman yang cukup mengenai arsitektur dan teknik pelatihan yang tepat untuk menghindari *overfitting*

f. Metode Evaluasi

Untuk proses evaluasi, metode pengujian data eror yang digunakan adalah MAPE (Mean Absolute Percentage Error) dan MAE (Mean Absolute Error)

1) MAPE (Mean Absolute Percentage Error)

(Geron, 2019) Adalah alat statistik yang digunakan untuk mengukur keakuratan suatu model statistik dalam melakukan prediksi atau peramalan. Berikut adalah rumus MAPE

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right| \times 100 \% \tag{8}$$

n adalah ukuran sampel

A_i adalah nilai data aktual

F_i adalah nilai data peramalan

MAPE termasuk alat ukur ketepatan model peramalan yang paling sering digunakan dibandingkan MAD, MAE, RMSE atau lain nya. Hal ini karena MAPE lebih mudah diinterpretasikan dibandingkan alat ukur yang lain tersebut. Nilai MAPE sebesar 10% dapat diartikan bahwa selisih rata-rata nilai peramalan dengan nilai yang sebenarnya adalah 10%. Semakin kecil MAPE maka semakin akurat sebuah model dalam melakukan peramalan. Hal ini berarti sebuah model yang memiliki nilai MAPE kurang dari 10% merupakan model yang lebih baik daripada yang diatas 10%

2) MAE (Mean Absolute Error)

rata-rata selisih mutlak nilai sebenarnya (aktual) dengan nilai prediksi (peramalan) . MAE digunakan untuk mengukur keakuratan suatu model statistik dalam melakukan prediksi atau peramalan. MAE Bersama dengan MAPE merupakan ukuran keakuratan yang sering digunakan dalam analisis deret waktu (*time series*) (Geron, 2019)

$$MAE = \frac{1}{n} \sum_{i=1}^n |A_i - F_i| \tag{9}$$

n adalah ukuran sampel

A_i adalah nilai data aktual ke- i

F_i adalah nilai data peramalan ke- i

Karena pada rumus MAE diatas terdapat tanda mutlak ($| |$), maka nilai MAE akan selalu bernilai positif. Berdasarkan rumus MAE komponen $|A_i - F_i|$ menunjukkan nilai kesalahan atau perbedaan nilai sebenarnya dengan nilai peramalan. Perbedaan (kesalahan) yang diharapkan adalah nilai yang terkecil.

III. METODE PENELITIAN

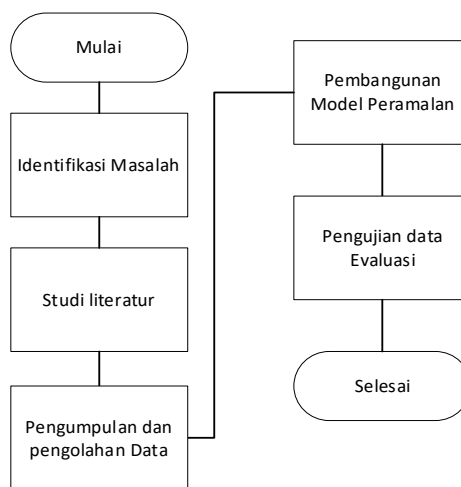
Metode yang akan dilakukan pada penelitian ini adalah metode kuantitatif untuk menangkap kebutuhan sistem, perhitungan statistika untuk menganalisis keadaan saat ini dan masa depan dan pemodelan sistem. Diharapkan model yang dibuat akan membantu dalam pengambilan keputusan dengan perhitungan optimasi pemesanan batu bara dan dapat dibuat dengan merepresentasikan sistem yang sebenarnya,

Identifikasi masalah dilakukan dengan identifikasi masalah dengan wawancara dengan tim ahli dari pembangkit listrik tenaga uap untuk dapat menentukan masalah yang dihadapi. Tim ahli kesulitan untuk memprediksi jumlah pasokan batu bara yang akan disimpan dan menjadi cadangan sehingga kebutuhan batu bara selalu sesuai dengan permintaan pelanggan dan stok selalu tersedia jika ada kebutuhan yang melebihi kebiasaan. Penelitian dilanjutkan dengan studi literatur untuk memprediksi kebutuhan dan study dari jurnal terbaru untuk mendapatkan metode yang terbaik dan efisien dalam memprediksi kebutuhan pelanggan. Banyak jurnal yang membahas tentang peramalan atau *forecasting* dalam permintaan *energi* kebanyakan jurnal membahas tentang metode statistika tradisional dan juga metode *machine learning* yang dikombinasikan dengan perhitungan statistika sehingga mencapai hasil perhitungan yang *valid* dan optimal. Proses pengumpulan data dilakukan dengan pengumpulan data *sekunder* dari pengamatan dengan melakukan wawancara dengan staf yang bekerja di PLTU bagian logistik. Data yang didapatkan dari hasil wawancara adalah data langgam stok batu bara dan data histori dari tahun Januari 2020 sampai Desember 2022. Pembangunan model peramalan permintaan pasokan batu bara untuk 50 hari berikutnya berdasarkan data historis dan menghitung dari pengendalian persediaan batu bara didalam Gudang yang sudah

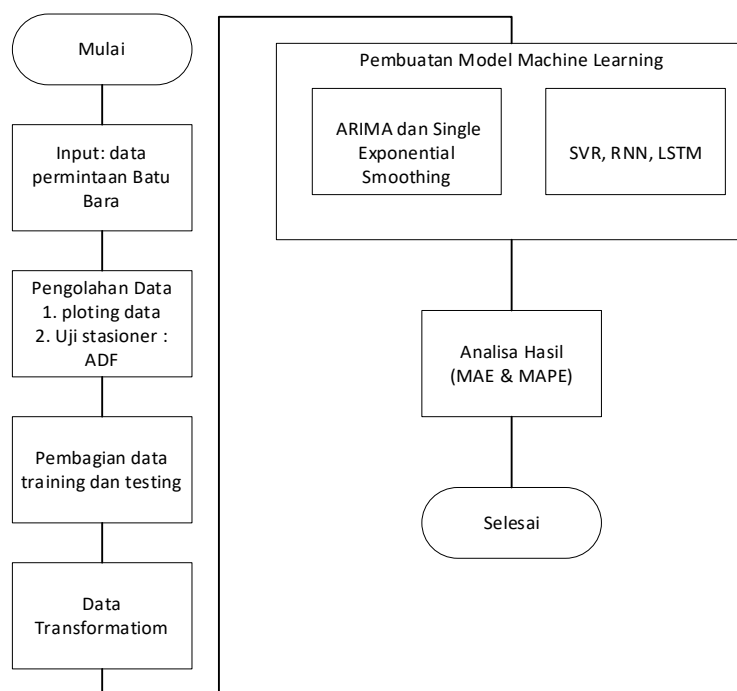
diproses menggunakan metode *preprocessing plotting* data dan uji stasioner ADF, kemudian data dibagi untuk dapat *training* dan ditesing dengan menggunakan metode *machine learning* sebanyak 80:20, yaitu 80% *training* dan 20% *testing* dan ditransformasi dengan menggunakan *library* dari *sklearn.preprocessing* dengan modul *MinMaxScaler*, setelah itu dijalankan modul *fit_transform(Coal)* untuk mentransformasikan data sebagai *input* baru kemudian dibuat model dengan metode Statistika *Time Series Machine Learning* seperti *ARIMA*, *Single exponential smoothing*, *SVR*, *RNN* dan *LSTM* metode tersebut akan dibuat dengan menggunakan fungsi *sklearn* dalam bahasa pemrograman *Python* dan akan dibandingkan untuk mendapatkan angka yang mendekati dengan pengesanan data dengan menggunakan *MAE* dan *MAPE*. Setelah melalui proses peramalan model maka hasil pengujian akan dibandingkan dan dari sana akan dilihat hasil yang terbaik untuk dapat dilakukan usulan biaya penyimpanan yang seminimal mungkin.

IV. HASIL DAN PEMBAHASAN


Dalam penelitian dibuat beberapa model dari statistika machine learning (statistika dan *deep learning*) untuk mendapatkan hasil perbandingan hasil peramalan yang *maximal*. Setelah membaca dari beberapa penelitian maka diputuskan untuk mencoba memasukkan data permintaan batu bara dengan data study kasus pembangkit listrik tenaga uap yang berada di Indonesia.



Gambar 6 Diagram alur penelitian.



Gambar 7 Proses perancangan proses prediksi.



Gambar 8 Plotting data.

a. Pengolahan data

Dari *potting* Gambar 8 belum dapat ditentukan apakah tipe data lebih ke stasioner maupun musiman, maka dilakukan Analisa lanjut yang dapat menunjukkan tipe data tersebut maka dilakukan analisa pola data apakah stasioner maka dilakukan Analisa pengujian dengan menggunakan metode *Augmented Dickey-Fuller test* (ADF Test) dengan hasil Tes statistik 3.057 dan *p-value* = 0,029, yang mana nilai *p-value* < 0,05 yang artinya data termasuk stasioner.

b. Pembagian data training dan testing


Pada tahap ini dilakukan pemodelan untuk membuat model peramalan dilakukan pembagian *dataset* menjadi data *training* dan data testing. Rasio pembagian *dataset training* dan *test* adalah 80:20, dengan komposisi data training 877 dan data testing 219 dengan total data 1096 data.

c. Data transformation

Pada tahap ini dilakukan data transformasi data agar nilai yang beragam dapat diseragamkan sehingga variasi data menjadi lebih rendah. Transformasi data dilakukan dengan menggunakan modul *sklearn.preprocessing* yaitu *MinMaxScaler* dalam *python*. Data set diubah menjadi skala dengan interval 0-1 dan selanjutnya menggunakan modul *fit_transform (dataset_train)*

d. Autoregressive Integrated Moving Average (ARIMA)

Pembuatan model ARIMA dilakukan setelah beberapa proses analisis data dengan satu parameter waktu (*time series*) dengan memvisualisasi data *mean* untuk mengetahui bentuk data *plotting*, uji stasioner dengan *pengetestan* ADF dan melakukan *differencing* agar data menjadi lebih *stationer*, setelah data *stationer* maka di lakukan lah pemodelan dengan ARIMA. Setelah mendapatkan hasil peramalan maka di hitunglah nilai MAPE dari data uji untuk dapat mengetahui ke akuratan dari peramalan.



Gambar 9 Peramalan batu bara dengan metode ARIMA.

Nilai MAPE 5.1% menunjukkan tingkat validitas dari model peramalan dengan menggunakan ARIMA sebesar 94,9% benar. Angka yang cukup tinggi untuk peramalan prediksi batu bara.


e. Pembuatan Model Statistika *Single Exponential Smoothing*

Data permintaan batu bara yang sama dengan parameter waktu, di uji stasioner dengan *Augmented Dickey-Fuller Test* (ADF) menghasilkan *p-value* = 0,029 yang menunjukkan data stasioner maka model statistika *single exponential smoothing* termasuk metode yang cocok untuk dapat membuat peramalan dari data permintaan batu bara. Untuk mendapatkan nilai peramalan dengan menggunakan *single exponential smoothing* dilakukan dengan mencoba beberapa hitungan dengan nilai *alpha* 0-1, dengan nilai *alpha* semakin mendekati satu artinya semakin dekat dengan peramalannya. Untuk membuktikan apakah teori tersebut dapat dilakukan dengan data permintaan batu bara akan dibuat percobaan dengan perhitungan dengan *alpha* 0.2, 0.4, 0.6 dan 0.8. dengan data *future windows / frame* 50. Data di uji dengan menggunakan perhitungan MAPE dari perbandingan data peramalan dan data test, maka menghasilkan data berikut.

Tabel I Pemodelan *single exponential smoothing* dengan dengan *alpha* yang berbeda.

	Alpha	MAE	MAPE
0	0.2	3.52	6.91
1	0.4	1.93	3.85
2	0.6	1.13	2.25
3	0.8	0.54	1.07

Dari hasil diatas maka dapat disimpulkan dari nilai MAPE dan MAE terkecil yang ditemukan dengan menggunakan nilai *alpha* 0.8 dengan nilai MAE 0,54 dan nilai MAPE sebesar 1,07 % tingkat *error*. Dengan grafik yang tergambar dibawah ini



gambar 10 peramalan batu bara dengan metode *exponential smoothing* dengan ($\alpha = 0.8$).

Pembangunan model *single exponential smoothing* dengan menggunakan *alpha* 0,8 dapat menghasilkan nilai MAPE sampai dengan 1.07% yang artinya tingkat validitas dari model mencapai 98,7 %. Angka yang sangat baik untuk model prediksi permintaan batu bara

f. Model *Support Vector Regression* (SVR)

Model ke tiga yang di coba adalah salah satu model *machine learning* yang banyak digunakan dalam peramalan *time series*. Setelah data permintaan batu bara dengan parameter waktu di satukan dan dibagi menjadi 80% data *training* dan 20% data testing sebanyak 877 dan 219 data. Data set diubah menjadi skala dengan interval 0-1 dengan menggunakan *library sklearn.preprocessing* dengan modul *MinMaxScaler* selanjutnya menggunakan modul *fit_transform (dataset_train)*. Data set dibagi menjadi beberapa *frame* dengan 50 data/*frame* untuk dapat memprediksi hari selanjutnya. Dengan membagi data menjadi beberapa *frame* diharapkan model dapat melihat pola dan tren secara keseluruhan, agar lebih mudah dalam memahami perilaku data. Data dilatih menggunakan hyperparameter untuk dapat mencari nilai optimal pada model SVR, dengan penambahan beberapa jenis kernel yang tersedia dalam *library sklearn*.


Setelah beberapa percobaan maka disimpulkan bahwa kombinasi yang optimal menggunakan model kernel Linear. Setelah di lakukan pengetesan pada model SVR maka dapat di lihat nilai MAPE menunjukkan nilai 5,48% yang artinya validitas dari model sebesar 94,52%.

g. Model *Recurrent Neural Network* (RNN)

Untuk penelitian pembuatan model selanjutnya menggunakan model RNN salah satu model *deep learning* untuk mendapatkan peramalan *time series*. Berikut Langkah-langkah yang dilakukan dalam pembuatan model peramalan dengan menggunakan RNN sebagai berikut Bagi data permintaan batu bara menjadi data *training* dan data *testing* dengan perbandingan 80% data *training* dan 20% data testing *Dataset* diubah menjadi skala dengan interval 0-1 dengan menggunakan *library sklearn.preprocessing* dengan modul *MinMaxScaler* selanjutnya menggunakan modul *fit_transform (dataset_train)*. Data set dibagi menjadi beberapa *frame* dengan data per *frame* mencakup 50 data untuk dapat memprediksi hari selanjutnya. Dengan membagi data menjadi beberapa *frame* diharapkan model dapat melihat pola dan *tren* secara keseluruhan, agar lebih mudah dalam memahami perilaku data. Selanjutnya adalah pencarian *hyperparameter* optimal pada model RNN yang dilakukan pada jenis fungsi *aktivasi*, ukuran *hidden layer*. Susunan parameter yang digunakan adalah menggunakan opsi jenis parameter yang tersedia pada *library sklearn* dan uji coba layer dan neuron yang terdapat pada model. Dengan pengulangan 20 kali.

Tabel II Hasil perbandingan pengujian dari variasi kernel.

	Kernel							
	Linear		poly			RBF		
C	100	10	100	100	10	100	10	100
Gamma			0,01	Auto	Scale (1/50)	0,01	Auto	Scale (1/50)
MAPE	5,48	5,48	10,44	9,70	18,90	5,80	5,62	11,54
MAE	3,16	3,16	5,96	5,46	10,87	3,34	3,24	6,48

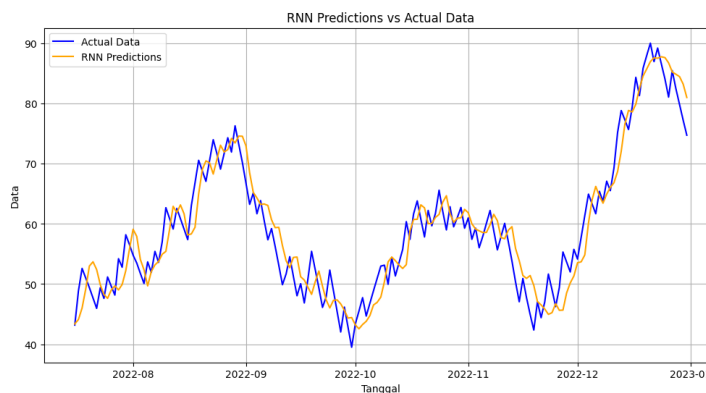


Gambar 11 Grafik Prediction Vs Actual data model SVR.

```

Layer (type)              Output Shape              Param #
-----
simple_rnn (SimpleRNN)     (None, 50, 50)           2600
dropout (Dropout)         (None, 50, 50)           0
simple_rnn_1 (SimpleRNN)   (None, 50, 50)           5050
simple_rnn_2 (SimpleRNN)   (None, 50, 50)           5050
simple_rnn_3 (SimpleRNN)   (None, 50)                5050
dense (Dense)              (None, 1)                 51
=====
Total params: 17801 (69.54 KB)
Trainable params: 17801 (69.54 KB)
Non-trainable params: 0 (0.00 Byte)
    
```

Gambar 12 Model arsitektur RNN.



Gambar 13 Grafik Prediction vs Actual data model RNN.

Pembuatan model RNN dengan menggunakan *python* dengan hasil prediksi yang digambarkan dengan grafik yang ditunjukkan pada Gambar 13. Dari data pengujian yang di jalankan di model prediksi RNN maka nilai MAPE yang didapat 5.2% yang artinya tingkat validitas peramalan sebesar 94,8%

h. Model *Long Short-Term Memory* (LSTM)

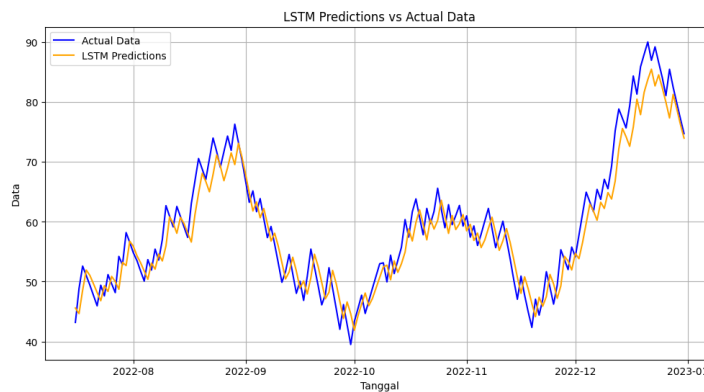
Untuk penelitian pembuatan model selanjutnya menggunakan model LSTM salah satu model *deep learning* untuk mendapatkan peramalan *time series*. Berikut Langkah-langkah yang dilakukan dalam pembuatan model peramalan dengan menggunakan LSTM sebagai berikut Bagi data permintaan batu bara menjadi data *training* dan data *testing* dengan perbandingan 80% data *training* dan 20% data *testing* Data set diubah menjadi skala dengan interval 0-1 dengan menggunakan *library sklearn.preprocessing* dengan modul *MinMaxScaler* selanjutnya menggunakan modul *fit_transform (dataset_train)*. Data set dibagi menjadi beberapa *frame* dengan data per *frame* mencakup 50 data untuk dapat memprediksi hari selanjutnya. Dengan membagi data menjadi beberapa *frame* diharapkan model dapat melihat pola dan tren secara keseluruhan, agar lebih mudah dalam memahami perilaku data. Selanjutnya adalah pencarian *hyperparameter* optimal pada model LSTM yang dilakukan pada jenis fungsi *aktivasi*, ukuran *hidden layer*. Susunan parameter yang digunakan adalah menggunakan opsi jenis parameter yang tersedia pada *library sklearn* dan uji coba layer dan neuron yang terdapat pada model. Dengan pengulangan 12 kali. Dengan *hidden layer* sebanyak 4 kali.

Pembuatan model LSTM dengan menggunakan *python* dengan hasil prediksi yang diberikan pada Gambar 15. Dari data pengetesan yang dijalankan di model prediksi RNN maka nilai MAPE yang didapat 4,8 % yang artinya tingkat validitas peramalan sebesar 95,2%.

Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 50, 50)	10400
lstm_1 (LSTM)	(None, 50)	20200
dense (Dense)	(None, 25)	1275
dense_1 (Dense)	(None, 1)	26

=====
 Total params: 31901 (124.61 KB)
 Trainable params: 31901 (124.61 KB)
 Non-trainable params: 0 (0.00 Byte)

Gambar 14 Arsitektur LSTM.




Gambar 15 Grafik *Prediction Vs Actual* data model LSTM.

i. Perbandingan Hasil Prediksi

Setelah dilakukan pembangunan model maka dapat kita rangkum hasil MAE dan MAPE yang digunakan sebagai pengetesan apakah model mempunyai peramalan yang baik. Dari perbandingan pengetesan maka dapat kita lihat model mana yang memiliki validitas tertinggi dengan tingkat eror yang rendah

Tabel III Hasil pengetesan MAE dan MAPE

No	Model	MAE	MAPE	Validitas
1	ARIMA	2,91	5,11%	94,89%
2	Exponential Smoothing	0,55	1,07%	98,93%
3	SVR	3,16	5,48%	94,52%
4	RNN	2,96	5,19%	94,81%
5	LSTM	2,84	4,83%	95,17%



Gambar 16 Gambar plotting perbandingan data actual vs data model.

V. KESIMPULAN DAN SARAN

KESIMPULAN

Berdasarkan penelitian yang telah dilakukan berikut disampaikan kesimpulan yang dapat diambil :

1. *Dataset* permintaan batu bara dengan *parameter* waktu adalah data *time series* yang stasioner yang dibuktikan dengan *plotting* data dan pengujian stasioner *Augmented Dickey-Fuller Test (ADF)* dengan *p-value* = 0,029 yang menunjukkan *p-value* kurang dari 0.05.
2. Dengan data yang menunjukkan *time series* stasioner maka dipilihlah model *machine learning* yang cocok yaitu *ARIMA*, *exponential smoothing* dan *support vector regression (SVR)*. Penelitian juga membangun model *deep learning* menggunakan *Recurrent Neural Network (RNN)* dan *Long Short-Term Memory (LSTM)*
3. Setelah model dibangun maka terlihat hasilnya *ARIMA* dengan nilai error *MAPE* 5.11. *Exponential Smoothing* dicoba menggunakan beberapa *alpha* dari 0-1. Uji coba menyatakan *alpha* 0,8 yang menghasilkan *MAPE* terbaik yaitu 1.07%, *SVR* diuji coba dengan menggunakan *hyperparameter tuning* dengan menggunakan kombinasi *kernel* linear, *polynomial* dan *rbf*. Setelah dilakukan percobaan ditemukan bahwa *kernel* linear dengan nilai *MAPE* 5.48%. *RNN* dijalankan dengan 6-layer dengan nilai *MAPE* 5.19%. sedang *LSTM* dijalankan dengan layer sebanyak 4 *layers* dengan nilai *MAPE* 4.83%. Model dengan yang nilai akurasi yang tertinggi didapatkan dari *exponential smoothing* dengan nilai *MAPE* 1.07% dan *MAE* 0.55, yang artinya validitas dari model mencapai 98.97%. Walaupun model dengan akurasi tertinggi adalah *exponential smoothing* tetapi model yang lainnya juga termasuk memiliki akurasi yang cukup dapat diperhitungkan..

SARAN

Berdasarkan penelitian yang telah dilakukan, berikut disampaikan saran yang diusulkan untuk perusahaan untuk dapat mengembangkan penelitian ini

1. Dalam penerapan *machine learning* untuk *predictive maintenance*, peneliti perlu mengumpulkan lebih banyak data dari waktu ke waktu agar model memiliki nilai *akurasi* lebih tinggi.
2. Jika memungkinkan peneliti dapat menambahkan data *variable* lain untuk dapat meningkatkan akurasi dari peramalan.
3. Manajemen dapat membuat *system* yang terintegrasi antar bagian yang di Kelola dengan perhitungan tertentu seperti *machine learning* untuk dapat mengelola dan memonitor *system* agar lebih baik.

DAFTAR PUSTAKA

- [1] Aviso, A. (2023, 3 30). <https://fitsmallbusiness.com>. Retrieved 9 24, 2013, from <https://fitsmallbusiness.com/inventory-carrying-cost/>
- [2] Bank Indonesia. (2023, 7 25). <https://www.bi.go.id/>. (Bank) Retrieved 8 1, 2023, from <https://www.bi.go.id/id/default.aspx>
- [3] BPPT. (2013). *Daya Dukung Pembangkit Listrik Tenaga Uap Bahan Bakar Batu Bara* (ISBN 978-979-3733-97-5 ed.). (BPPT, Ed.) Badan Pengkajian dan Penerapan Teknologi.
- [4] Cecep Mochammad Yasin. (2021). *Road Map Pengembangan dan Pemanfaatan Batubara 2021 - 2045*. Jakarta: Direktorat Jenderal Mineral dan Batubara - 2021.
- [5] Chao, C., & Hui, L. (2020). Medium-term wind power forecasting based on multi-resolution multi learner ensemble and adaptive model selection. *Energy And Confesion Energy*.
- [6] Dai, Q., Fang, Y., & Yu, J. (2021). Research on Coal Price Forecast Based on Exponential Smothing Forecast and Multiple Linear Regression. *Financial Engineering and Risk Management*, 4, 59-63.
- [7] Dolphin, R. (2020, October 22). *A Detailed Explanation*. Retrieved Juni 19, 2023, from <https://towardsdatascience.com/lstm-networks-a-detailed-explanation-8fae6aefc7f9>
- [8] Effendi, M., & Rusdiansyah, A. (2020). Dynamic Simulation to Minimize Inventory Cost of Coal Considering Uncertainty Demand of Product. *IPTEK Journal of Proceedings Series*.

- [9] Geron, A. (2019). *Hand On Machine Learning with Scikit-Learn, Keras and TensorFlow* (5 ed.). United States of America: O'Reilly Media, Inc.
- [10] Kelleher, J., Mac Namee, B., & D'Arcy, A. (2020). *Fundamentals of Machine Learning for Predictive Data Analytics, second edition: Algorithms, Worked Example and case studies*. Second ed. ed. The MIT Press.
- [11] Kumar, V. (2023). *Analytics Vidhya*. Retrieved 10 26, 2023, from <https://www.analyticsvidhya.com/blog/2021/06/statistical-tests-to-check-stationarity-in-time-series-part-1/>
- [12] Laubscher, R. (2019). Time-series forecasting of coal-fired power plant reheater metal temperatures using encoder-decoder recurrent neural networks. *Energy*.
- [13] Putra, G., & Maulud, A. R. (2020). Peramalan Kebutuhan Batubara Menggunakan Metode Single Exponential Smoothing di PT Solusi Bangun Andalas. *joptimalisasi*, 6(2 Oktober 2020), 2.
- [14] Putra, J. W. (2020). *Pengenalan Konsep Pembelajaran Mesin dan Deep Learning* (1.4 ed.). Tokyo, Jepang.
- [15] Rizki, M., Wenda, A., Umam, M. I., Hamzah, M. L., Pahlevi, F. D., & Sutoyo. (2021). Comparison of Four Time Series Forecasting Methods for Coal Material Supplies: Case Study of.
- [16] Saini, A. (2023, 7 7). *analyticsvidhya*. Retrieved 10 18, 2023, from <https://www.analyticsvidhya.com/blog/2021/10/support-vector-machinessvm-a-complete-guide-for-beginners/>
- [17] Sharma, Himanshu, Marinovici, Laurentiu, Adetola, Veronica, . . . T, H. (2023). Data-driven modeling of power generation for a coal power plant undercycling. *Energy and AI*.
- [18] Subagyo, P. (2004). Forcasting Konsep dan Aplikasi. In *Forcasting Konsep dan Aplikasi*.
- [19] Xiao, L., Li, M., & Zhang, S. (2022). Short-term power load interval forecasting based on nonparametric Bootstrap errors sampling. *Energy Reports*.