

PERBANDINGAN KINERJA ALGORITMA RECURRENT NEURAL NETWORK (RNN) DAN LONG SHORT-TERM MEMORY (LSTM): STUDI KASUS PREDIKSI KEMACETAN LALU LINTAS JARINGAN PT XYZ

Silmy Sephia Nurashila¹⁾, Faqih Hamami²⁾, Tien Fabrianti Kusumasari³⁾

1. Telkom University, Indonesia
2. Telkom University, Indonesia
3. Telkom University, Indonesia

Article Info

Kata Kunci: Kemacetan Jaringan; Prediksi; Deep Learning; RNN; LSTM.

Keywords: *Network Congestion; Prediction; Deep Learning; RNN; LSTM.*

Article history:

Received 12 April 2023

Revised 26 April 2023

Accepted 10 May 2023

Available online 1 September 2023

DOI :

<https://doi.org/10.29100/jifi.v8i3.3961>

* Corresponding author.

Corresponding Author

E-mail address:

silmysephia@student.telkomuniversity.ac.id

ABSTRAK

Peningkatan perkembangan teknologi sebanding dengan peningkatan penggunaan internet. Kualitas jaringan internet di Indonesia yang masih rendah dengan peningkatan penggunaan jaringan yang terus bertambah menyebabkan kemungkinan terjadinya kemacetan jaringan lebih tinggi. Penggunaan internet yang tinggi menyebabkan seringkali terjadi kemacetan jaringan yang menyebabkan penurunan kualitas dan performa jaringan. Pada penelitian ini akan dilakukan prediksi lalu lintas jaringan. Terdapat beberapa model algoritma yang dapat digunakan untuk melakukan prediksi dan penelitian ini akan dibahas mengenai perbandingan performa dari model Long Short-Term Memory (LSTM) dan Recurrent Neural Network (RNN). Dari hasil perbandingan diperoleh bahwa LSTM memiliki nilai yang lebih tinggi dalam performa dengan mendapatkan nilai akurasi R-Squard sebesar 99.2% jika dibandingkan dengan model dengan algoritma RNN yang memiliki nilai akurasi R-Squard sebesar 99.1%. Manfaat dari penelitian ini yaitu untuk menguji performa dari model LSTM dan RNN terhadap dataset PT XYZ. Penelitian ini diharapkan dapat memberikan referensi kepada pengembang model Deep Learning untuk pengembangan kedepannya agar mendapatkan hasil yang lebih baik.

ABSTRACT

The increase in technological development is proportional to the increase in internet usage. The internet network quality in Indonesia still needs to improve, with increasing network usage increasing, causing a higher possibility of network congestion. High internet usage causes frequent network congestion, which causes a decrease in network quality and performance. In this study, network traffic prediction will be carried out. Several algorithm models can be used to make predictions, and this research will discuss the performance comparison of the Long Short-Term Memory (LSTM) and Recurrent Neural Network (RNN) models. From the comparison results, it is found that LSTM has a higher value in performance by obtaining an R-Squard accuracy value of 99.2% compared to the model with the RNN algorithm, which has an R-Squard accuracy value of 99.1%. The benefit of this research is to test the performance of the LSTM and RNN models on the PT XYZ dataset. This research is expected to reference Deep Learning model developers for future development to get better results.

I. PENDAHULUAN

SAAT ini, teknologi dan internet menjadi prestise dan indikator kemajuan suatu negara[1]. Ookla selaku situs yang menyediakan pengujian kecepatan internet, menunjukkan bahwa kecepatan internet Indonesia yaitu sebesar 15,82 Mbps untuk median mobile internet dan 20,13 Mbps untuk median fixed internet. Dengan internet Indonesia saat ini, Indonesia menduduki peringkat 112 untuk mobile internet dan peringkat 123 untuk fixed internet [2]. Hal tersebut menunjukkan bahwa kualitas jaringan internet di Indonesia masih rendah. Kecepatan koneksi internet yang rendah dapat menyebabkan berbagai masalah kegagalan dalam penggunaan jaringan [3]. Kemacetan jaringan merupakan salah satu bentuk dari kegagalan jaringan [3]. Hal ini dapat menurunkan kualitas

layanan jaringan sehingga mengakibatkan delay antrian, pemblokiran koneksi, throughput rendah, kehilangan paket, dan jaringan yang lambat [4].

Banyak implementasi dan penelitian mengenai kemacetan jaringan saat ini. Salah satu penelitian yang telah dilakukan adalah melakukan prediksi kemacetan jaringan menggunakan Recurrent Neural Network (RNN) [5]. Selain itu, penelitian lainnya menggunakan Deep Neural Network (DNN) dalam melakukan prediksi kemacetan internet yang menghasilkan nilai error RSME dan MAE yang cukup baik [6].

Kegagalan pada jaringan sangat sulit diprediksi karena memiliki sifat yang dinamis, karena itu menjaga kualitas dan stabilitas jaringan untuk tetap berada pada kondisi yang baik merupakan hal penting [3]. Terdapat beberapa kelebihan penerapan prediksi kemacetan jaringan diantaranya dengan menjaga kualitas jaringan internet dari kegagalan jaringan sangat berpengaruh pada performa organisasi atau perusahaan, terutama perusahaan yang setiap harinya mengandalkan jaringan internet untuk seluruh proses bisnis. Selain itu, kemampuan untuk secara akurat memprediksi kegagalan pada jaringan komputer dapat membantu meminimalkan biaya administrasi perusahaan [3].

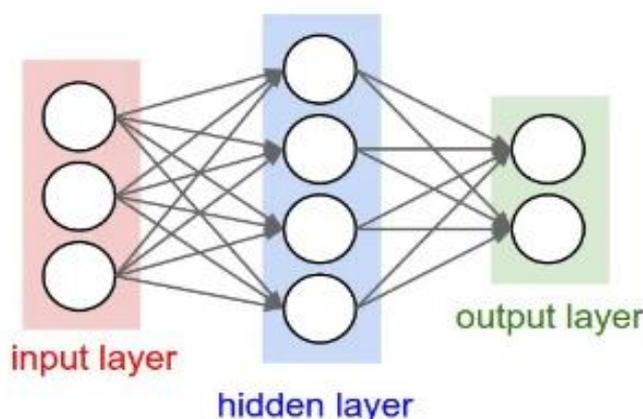
Terdapat beberapa algoritma yang dapat digunakan untuk melakukan prediksi. Beberapa algoritma yang dapat digunakan adalah Recurrent Neural Network (RNN) [5] dan Long Short-Term Memory [7]. Penelitian prediksi terhadap kemacetan internet menggunakan algoritma RNN menghasilkan nilai estimasi error yang relative lebih rendah daripada menggunakan ARIMA dengan nilai error MAE RNN yaitu [5]. Prediksi menggunakan algoritma LSTM terhadap kemacetan interne menghasilkan nilai error RSME sebesar 14.88 dan nilai error MAE sebesar 7.29 [6].

Nilai error dan performance dari model yang disebutkan sebelumnya juga bergantung pada dataset yang digunakan. Hal ini disebabkan karena pada penelitian sebelumnya menyatakan bahwa prediksi kemacetan jaringan yang dilakukan dapat menggunakan dataset yang lebih umum [6]. Dari pernyataan tersebut dapat disimpulkan bahwa setiap nilai error dan performa model yang dihasilkan memiliki perbedaan sesuai dengan dataset yang digunakan. Pada paper ini penulis akan melakukan perbandingan performa model RNN dan LSTM khususnya pada dataset lalu lintas jaringan PT XYZ. Pengujian akan dilakukan dengan melakukan pengujian performa pada setiap model dan selanjutnya akan dihitung Root Mean Square Error (RMSE) dan Mean Absolute Error (MAE) yang digunakan untuk evaluasi kinerja prediksi [6].

II. TINJAUAN LITERATUR

A. Deep Learning

Deep learning merupakan teknik pembelajaran yang diperkenalkan oleh Geoffrey Hinton sejak tahun 2006 yang memiliki kemampuan feature engineering yang dapat melakukan rekayasa fitur secara otomatis dan dapat memberikan peningkatan akurasi yang sebanding dengan penambahan jumlah data [8]. Deep Learning adalah salah satu cabang Machine Learning (ML) yang menggunakan Deep Neural Network untuk menyelesaikan permasalahan pada domain Machine Learning [9]. Gambar 1 merupakan arsitektur umum dari Deep Learning.



Gambar 1 Arsitektur Deep Learning [9]

Gambar 1 merupakan arsitektur utama dari Deep Learning adalah terdapat 3 layer utama yaitu, input layer, hidden layer, dan output layer. Pada Deep Learning terdapat komponen yang dinamakan fungsi aktivasi. Fungsi ini memiliki tugas untuk membantu memahami pola-pola kompleks pada data. Fungsi aktivasi ini sangat dibutuhkan oleh Deep Learning yang memiliki banyak lapisan neuron yang terdiri dari node yang digunakan untuk klasifikasi dan prediksi data. Jika fungsi aktivasi tidak digunakan dalam jaringan saraf yang ada pada Neural Network maka

sinyal keluaran hanya akan menjadi fungsi linier sederhana yang hanya merupakan polinomial berderajat satu [10]. Terdapat beberapa jenis fungsi aktivasi, diantaranya sebagai berikut.

1) Fungsi Aktivasi Sigmoid

Fungsi aktivasi sigmoid ini adalah fungsi aktivasi yang paling banyak digunakan karena merupakan fungsi non-linear. Fungsi sigmoid mengubah nilai yang masuk menjadi dalam rentang 0 hingga 1.

2) Fungsi Aktivasi Tanh

Fungsi aktivasi tanh adalah fungsi yang nilainya berkisar antara -1 hingga 1. Dibandingkan dengan fungsi sigmoid, gradien fungsi tanh lebih curam [10].

3) Fungsi Aktivasi Rectified Liner Unit (ReLU)

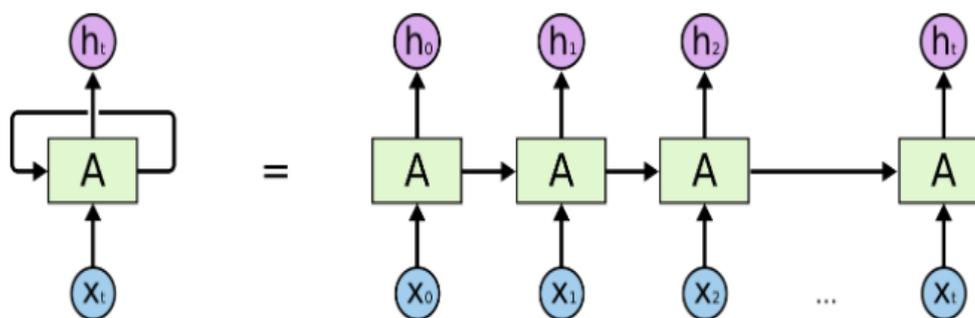
Fungsi aktivasi Rectified Liner Unit atau ReLU adalah aktivasi non-linear yang banyak digunakan dalam neural network. Kelebihan dari fungsi aktivasi ReLU adalah bahwa semua neuron tidak diaktifkan secara bersamaan. Ini menyiratkan bahwa neuron akan dinonaktifkan hanya ketika keluaran transformasi linier adalah nol [10].

B. Recurrent Neural Network

Recurrent Neural Network (RNN) merupakan salah satu jenis algoritma pembelajaran mesin yang berbasis pengolahan informasi dari sebuah data dan merupakan algoritma deep learning. RNN menyimpan pola-pola informasi masa lalu dengan melakukan perulangan di dalam arsitekturnya agar dapat membuat informasi tersebut tetap tersimpan. RNN merupakan pengembangan dari Jaringan Saraf Tiruan (JST) dan arsitekturnya mirip dengan Multilayer Perceptron (MLP).

Pada dasarnya Recurrent Neural Network (RNN) memiliki parameter yang sama dengan neural network biasa, yang membedakan adalah konsep dari RNN itu sendiri. Recurrent Neural Network (RNN) menjadikan hidden layer sebelumnya sebagai input di proses selanjutnya. Hidden layer sebelumnya menyimpan informasi dari proses ekstraksi fitur di awal sehingga saat hidden layer dijadikan input untuk proses selanjutnya itu menyimpan memory (ingatan) dari input sebelumnya [11].

Gambar 2 memperlihatkan proses RNN sebelum dan setelah dibuka (unrolled) ke jaringan penuh. X_t merupakan input pada waktu t dan h_t adalah output dari proses RNN. Saat proses RNN dibuka, jaringan penuh akan terlihat seluruhnya secara lengkap. Proses RNN diawali dengan mengambil X_0 dari input dan kemudian menghasilkan h_0 yang bersamaan dengan masuknya X_1 sebagai input untuk langkah selanjutnya. Jadi, h_0 dan X_1 adalah input untuk langkah selanjutnya dan seterusnya. Dengan cara inilah RNN mengingat konteks saat melakukan pelatihan [12].

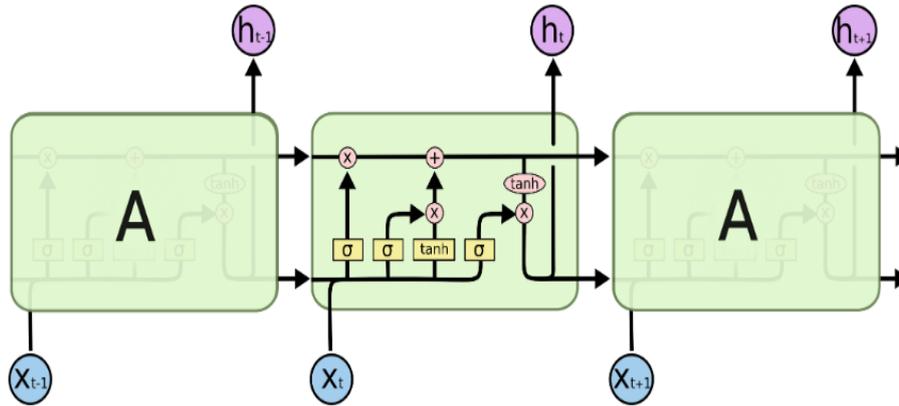


Gambar 2 Arsitektur Recurrent Neural Network (RNN) [13]

RNN selalu melakukan tugas yang sama secara berurutan, hasil dari RNN bergantung pada perhitungan sebelumnya [12].

C. Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) merupakan sebuah evolusi dari arsitektur Recurrent Neural Network (RNN), dimana pertama kali diperkenalkan oleh Hochreiter & Schmidhuber [7]. Long Short-Term Memory (LSTM) memiliki kelebihan daripada sekedar Recurrent Neural Network (RNN) biasa, yaitu adanya arsitektur mengingat dan melupakan output yang akan diproses kembali menjadi input dan memiliki kemampuan untuk mengolah informasi lebih akurat [7]. Selain itu, kemampuan Long Short-Term Memory (LSTM) yang kedua adalah menyimpan error yang terjadi saat back propagation agar error tidak meningkat. [14].



Gambar 3 Arsitektur Long Short-Term Memory (LSTM) [13]

Gambar 3 merupakan arsitektur umum dari Long Short-Term Memory (LSTM) terdiri dari 3 gate, yaitu forget gate, input gate, dan output gate [15]. Forget gate adalah tempat untuk menentukan informasi mana yang akan dihapus menggunakan fungsi aktivasi sigmoid. Jika keluarannya 1, semua data disimpan dan jika keluarannya 0, semua data dibuang [7], [12]. Adapun rumus forget gate didefinisikan sebagai persamaan (1) berikut.

$$F_t = \sigma(W_f \times [h_{t-1}, X_t] + b_f) \quad (1)$$

Dengan W_f = bobot dari forget gate, W_{t-1}, X_t = keadaan sebelumnya atau keadaan pada waktu t-1, b_f = bias dari forget gate, dan σ = fungsi aktivasi sigmoid.

Pada input gate terdapat dua gates yang akan dilaksanakan [7]. Fungsi sigmoid memutuskan nilai mana yang akan melewati 0,1. dan fungsi tanh memberi bobot pada nilai-nilai yang diteruskan untuk menentukan tingkat kepentingannya mulai dari -1 hingga 1 [12]. Adapun rumus input gate didefinisikan sebagai persamaan (2) dan (3) berikut.

$$i_t = \sigma(W_i \times [h_{t-1}, X_t] + b_i) \quad (2)$$

$$C_t = \tanh(W_c \times [h_{t-1}, X_t] + b_c) \quad (3)$$

Dengan W_i = bobot dari input gate, W_c = bobot pada cell state.

Output gate menghasilkan output setelah memory cell melewati forget gate dan input gate [7]. Pada output gate memiliki dua alur yang diimplementasikan, pertama diputuskan bagian mana dari sel memori yang diberikan oleh fungsi aktivasi sigmoid dan mana yang akan diputuskan yang akan diberikan fungsi aktivasi tanh [16]. Fungsi sigmoid memutuskan nilai mana yang akan melewati 0,1. dan fungsi tanh memberi bobot pada nilai-nilai yang dilewatkan menentukan tingkat kepentingannya mulai dari -1 hingga 1 dan dikalikan dengan keluaran sigmoid [12]. Adapun rumus output gate dapat didefinisikan sebagai persamaan (4) dan (5) berikut.

$$O_t = \sigma(W_o \times [h_{t-1}, X_t] + b_o) \quad (4)$$

$$h_t = O_t \times \tanh(C_t) \quad (5)$$

Dengan W_o = bobot dari output gate.

D. Metric Evaluation

Metric evaluasi digunakan untuk mengukur kesesuaian antara data yang sudah ada dengan data yang di prediksi. Ketepatan prediksi adalah suatu hal yang penting untuk peramalan [17]. Adapun uraian dari beberapa perhitungan performa prediksi, sebagai berikut.

1) Mean Absolute Error (MAE)

Mean Absolute Error (MAE) merupakan rata-rata nilai kesalahan yang bernilai mutlak positif dari jumlah data. MAE dapat didefinisikan dengan persamaan (6) berikut.

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (6)$$

Hal tersebut bertujuan untuk mengantisipasi kesalahan atau error yang bernilai negatif, sehingga dapat menentukan nilai rata-rata kesalahan secara tepat [17]. Dimana e_i merupakan rata-rata nilai kesalahan dan n merupakan banyaknya data.

2) Root Mean Square Error (RMSE)

Root Mean Square Error (RMSE) adalah cara mengukur kesalahan suatu model dalam memprediksi. RMSE secara formal didefinisikan sebagai persamaan (7) berikut.

$$RSME = \sqrt{\frac{\sum_{i=1}^n (X_t - F_t)^2}{n}} \quad (7)$$

Diman X_t merupakan data actual pada waktu t , F_t merupakan nilai prediksi pada waktu t , dan n merupakan banyak data.

3) R-Squared

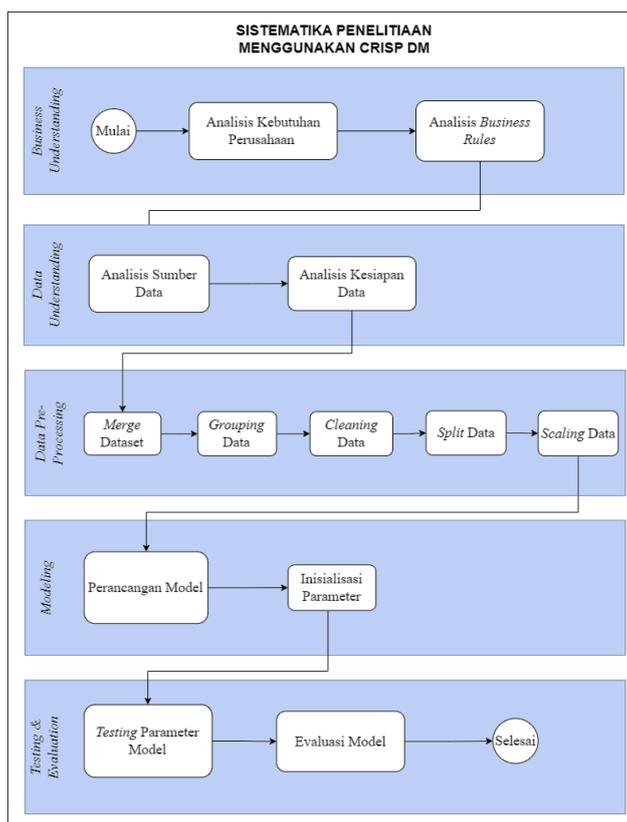
R-Squared mengukur seberapa cocok garis prediksi dengan data yang ada. R-Squared dapat diartikan sebagai persentase varian dalam variabel dependen yang dapat dijelaskan oleh model dan digunakan untuk mengukur seberapa jauh kemampuan model dalam menerangkan variasi variabel terikat [18]. R-Squared dapat didefinisikan sebagai persamaan (8) berikut.

$$R^2 = 1 - \frac{\sum_{i=1}^n (X_t - F_t)^2}{\sum_{i=1}^n (Y_t - F_t)^2} \quad (8)$$

Dimana X_t merupakan data actual pada waktu t , F_t merupakan nilai prediksi pada waktu t , Y_t merupakan nilai rata-rata data pada waktu t , dan n merupakan banyak data.

III. METODELOGI

Penelitian ini menggunakan metode komparatif dengan membandingkan performa antara dua algoritma yang ada pada Deep Learning yaitu Recurrent Neural Network (RNN) dan Long Short-Term Memory (LSTM). Pada Gambar 4 menjelaskan metode peneliti dalam melakukan perbandingan akurasi model yang ada pada prediksi menggunakan Deep Learning, metode yang digunakan adalah dengan modifikasi CRISP-DM. Metodologi penelitian ini terdiri dari business understanding, data understanding, data pre-processing, modeling, dan testing & evaluation.



Gambar 4 Tahapan Penelitian

A. Business Understanding

Fase pertama merupakan pemahaman bisnis (business understanding), fase ini merupakan fase untuk mengenali permasalahan dan melakukan analisis kebutuhan perusahaan dalam studi kasus, menganalisis business rules perusahaan, dan tahap pengumpulan data. Pada fase juga ini merupakan tahap dari identifikasi masalah serta gambaran solusi yang akan dilakukan. Permasalahan dan kebutuhan perusahaan nantinya akan diterjemahkan ke dalam rancangan model prediksi yang akan dibangun. Selain itu, pada fase ini dilakukan analisis terhadap business rules perusahaan yang menjadi batasan dan aturan dalam melakukan pembangunan model dan dilakukannya proses pengumpulan data. Setelah itu dilanjutkan dengan fase berikutnya yaitu fase pemahaman data (data understanding).

B. Data Understanding

Fase data understanding merupakan fase kedua pada penelitian ini. Fase ini berfokus pada analisis terhadap data yang didapatkan dan memeriksa data sehingga dapat mengidentifikasi masalah pada data. Tahapan ini juga menjadi pondasi untuk dapat mengetahui nilai-nilai yang hilang, outlier, dan distribusi pada data yang akan digunakan.

Pada penelitian ini, untuk proses pengumpulan data dilakukan secara wawancara dengan pihak perusahaan PT XYZ. Teknik wawancara yang dilakukan adalah dengan teknik wawancara tidak terstruktur. Wawancara dilakukan beberapa kali, dimulai dari tahapan mengenal karakteristik data, jenis data, dan struktur data hingga dilakukannya tanda tangan perjanjian kebijakan privasi data perusahaan. Dari hasil wawancara tersebut peneliti mendapatkan dataset yang dibutuhkan untuk penelitian ini.

Data yang digunakan pada penelitian ini adalah data traffic network element yang diambil melalui Multi Router Traffic Grapher (MRTG) PT XYZ yang tercatat mulai dari Januari 2022 sampai dengan Oktober 2022. Pada dataset traffic network element terdiri dari beberapa kolom, yaitu kolom id, dt (datetime), inbound, dan outbound seperti terlihat pada Tabel 1.

Tabel 1 Deskripsi Dataset Traffic Network Element PT XYZ

No	Nama Kolom	Tipe Data	Deskripsi
1.	id	Integer	Merupakan kolom yang merepresentasikan identitas data pada PT XYZ.
2.	dt	Object	Merupakan kolom yang menyimpan data tanggal dan waktu penggunaan jaringan <i>inbound</i> dan <i>outbound</i> .

3.	inbound	Integer	Merupakan kolom yang menunjukkan jumlah penggunaan jaringan <i>inbound</i> dalam satuan bits di PT XYZ.
4.	outbound	Integer	Merupakan kolom yang menunjukkan jumlah penggunaan jaringan <i>outbound</i> dalam satuan bits di PT XYZ.
5.	capacity	Integer	Merupakan kolom kapasitas maksimal penggunaan jaringan di PT XYZ.

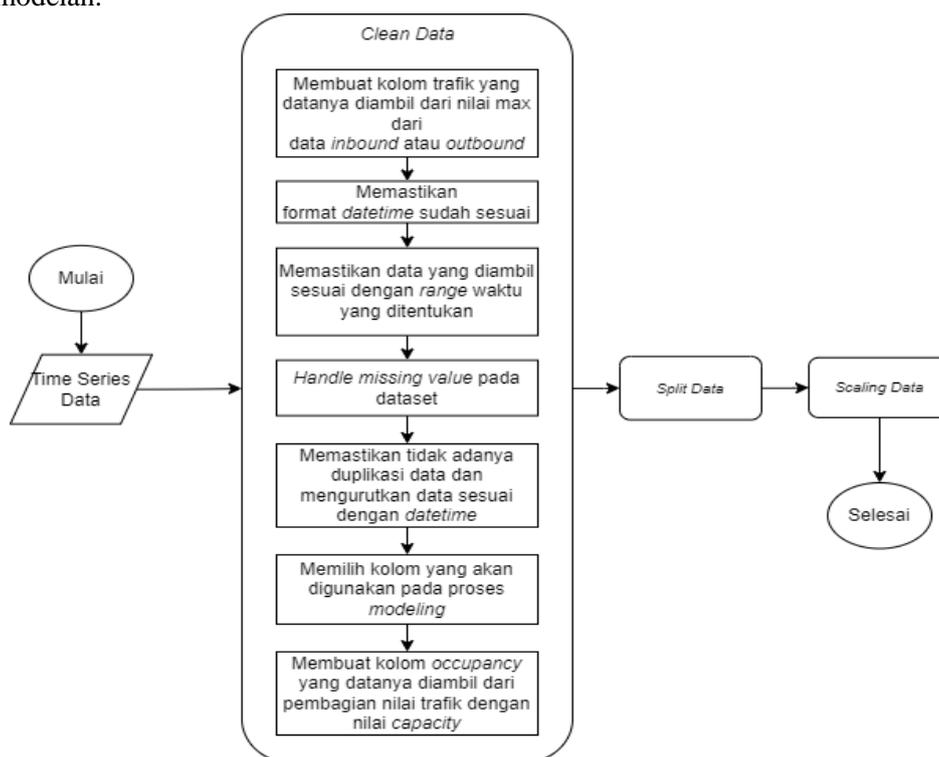
Pada Tabel 2 terlihat bahwa data yang tercatat pada dataset traffic network element adalah data jaringan inbound, outbound, dan capacity setiap 5 menit di PT XYZ dalam satuan data bits.

Tabel 2 Sample Dataset Traffic Network Element PT XYZ

id	dt	inbound	outbound	capacity
7	2022-04-13 02:50:00	8.407706e+09	2.433980e+09	1.000000e+11
7	2022-04-13 02:55:00	7.930997e+09	2.308914e+09	1.000000e+11
7	2022-04-13 03:00:00	7.879706e+09	2.429166e+09	1.000000e+11
7	2022-04-13 03:05:00	7.876626e+09	2.435341e+09	1.000000e+11
7	2022-04-15 03:10:00	7.414139e+09	2.472385e+09	1.000000e+11

C. Data Pre-Processing

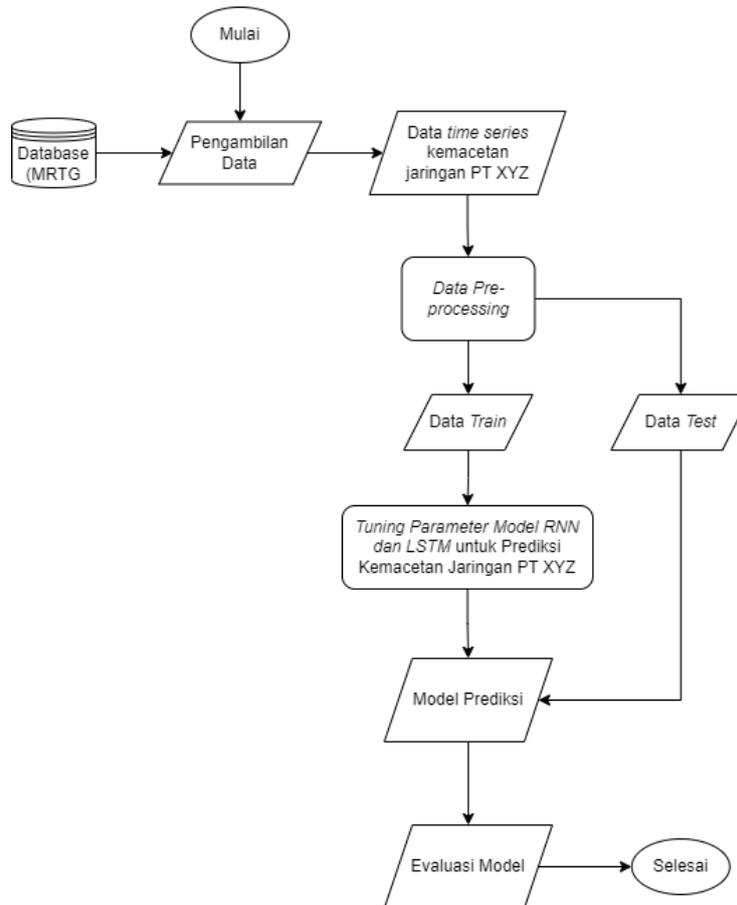
Fase persiapan data (data preprocessing) ini dilakukan untuk memastikan data yang ada merupakan data yang siap diproses guna menghasilkan model yang berkualitas. Pada Gambar 5 terlihat bahwa fase ini terdapat beberapa hal yang dilakukan, yaitu cleaning pada data, melakukan split data untuk data train dan data test, serta melakukan scaling data agar dapat sesuai dengan business rules yang menjadi persyaratan untuk studi kasus dan siap digunakan untuk proses pemodelan.



Gambar 5 Proses Data Pre-Processing

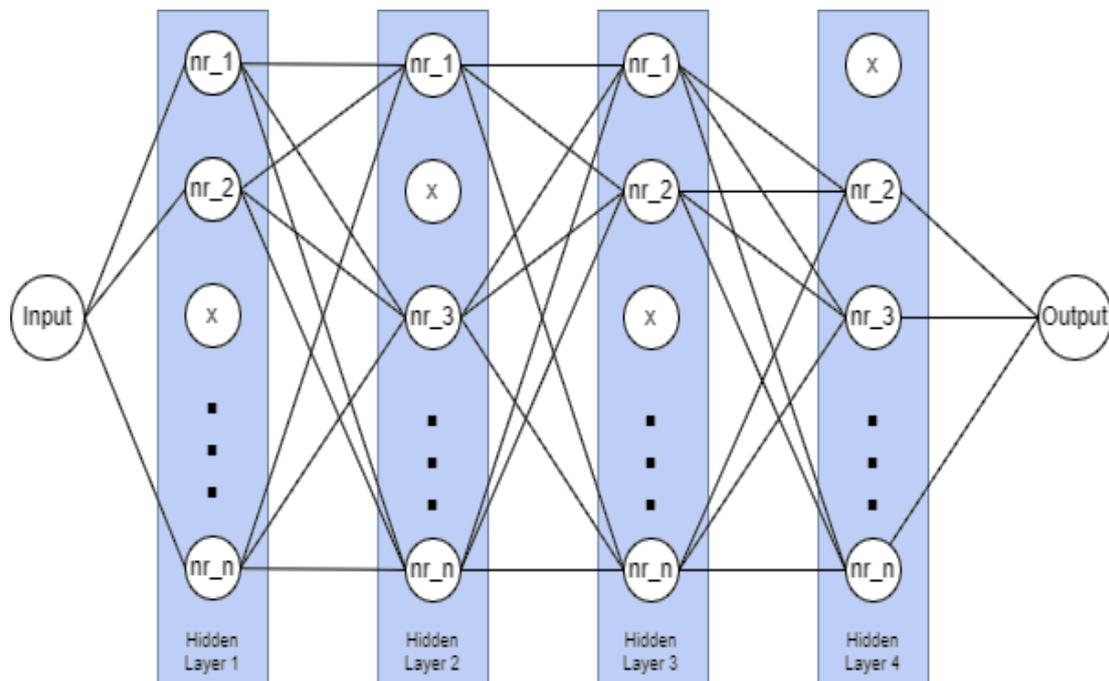
D. Modeling

Setelah data telah siap, selanjutnya akan masuk ke fase berikutnya yaitu fase pembuatan model (modeling) yang merupakan inti proses dari penelitian ini. Model yang dibangun akan menggunakan algoritma Recurrent Neural Network (RNN) dan Long Short-Term Memory (LSTM) sesuai dengan alur yang terlihat pada Gambar 6.



Gambar 6 Alur Model Prediksi

Model ini akan berisikan input layer, hidden layer, dan output layer sesuai arsitektur model dan dengan menggunakan parameter-parameter dari untuk memaksimalkan hasil model yang dibangun. Gambar 6 merupakan arsitektur model yang akan dirancang.



Gambar 7 Arsitektur Model

Model LSTM yang digunakan dalam penelitian ini adalah model dengan 1 input layer, 4 hidden layer LSTM, 1 output layer. Input layer berfungsi sebagai gerbang awal dari proses model dan tempat untuk menampung data awal

yang masuk. Hidden layer LSTM untuk meneliti dan mengklasifikasikan data dengan menggunakan fungsi aktivasi. Dan yang terakhir output layer yang menjadi keluaran dari model. Pada setiap hidden layer juga dilakukan dropout pada unit neuron yang berfungsi untuk menon-aktifkan neuron, dropout ini juga berfungsi mencegah terjadinya overfitting pada model dan mempercepat proses belajar model.

Isialisasi parameter pada penelitian yang dilakukan di antaranya adalah rasio data, unit neuron, epoch dan batch size. Berikut inialisasi parameter yang digunakan saat melatih model.

Tabel 3 Inialisasi Parameter Model

No	Parameter LSTM	Jumlah
1.	Rasio Data	80:20
2.	Unit neuron	75
3.	Epoch	25
4.	Optimizer	Adam
5.	Batch size	64

E. Testing dan Evaluasi

Setelah itu, model yang dibangun akan dilakukan testing dan evaluasi di fase yang terakhir. Testing berfokus pada melakukan pengujian data dan uji performa terhadap model yang telah dibangun. Dan proses evaluasi ini ditujukan untuk memberikan perbandingan hasil akurasi yang dilakukan berdasarkan parameter model yang sudah ditentukan sebelumnya. Mean Absolute Error (MAE) menggunakan persamaan (6), Root Mean Squared Error (RMSE) menggunakan persamaan (7) dan R-Squared menggunakan persamaan (8) akan diimplementasikan sebagai evaluasi pada penelitian ini. Metode-metode ini dipilih karena hasil diberikan berupa nilai error dan performa dari model yang dibangun mampu mengidentifikasi data yang relevan, sehingga dapat membantu dalam menyimpulkan akurasi dari model.

IV. HASIL DAN PEMBAHASAN

A. Proses Pre-Processing Data

Terdapat beberapa tahap yang dilakukan pada proses data pre-processing, adapun tahapan-tahapan tersebut sebagai berikut.

- 1) Membuat kolom baru yaitu kolom “trafik”. Kolom trafik adalah kolom yang menyimpan nilai yang didapatkan dari nilai tertinggi (maximum) antara kolom inbound atau outbound. Data juga diurutkan berdasarkan datetime. Hasil dari tahap ini, data akan terlihat seperti pada Tabel 4.

Tabel 4 Kolom Trafik Ditambahkan pada Dataset

id	dt	inbound	outbound	capacity	trafik
7	2022-04-13 02:50:00	8.407706e+09	2.433980e+09	1.000000e+11	8.407706e+09
7	2022-04-13 02:55:00	7.930997e+09	2.308914e+09	1.000000e+11	7.930997e+09
7	2022-04-13 03:00:00	7.879706e+09	2.429166e+09	1.000000e+11	7.879706e+09
7	2022-04-13 03:05:00	7.876626e+09	2.435341e+09	1.000000e+11	7.876626e+09
7	2022-04-15 03:10:00	7.414139e+09	2.472385e+09	1.000000e+11	7.414139e+09

- 2) Kolom “dt” menggunakan format tanggal. Memastikan format tanggal sesuai dengan format yang digunakan yaitu “%Y-%m-%d %H:%M:%S”.
- 3) Memastikan data yang digunakan adalah data dari tanggal 1 Januari 2022 sampai dengan 31 Oktober 2022.
- 4) Mengisi missing value. Data NaN akan diisi secara otomatis menggunakan metode interpolasi. Interpolasi adalah proses menebak nilai dari data NaN dengan memperhatikan data lain yang ada pada dataset.
- 5) Memastikan tidak ada data yang terduplikasi dengan menggunakan fungsi “drop_duplicates” dan mengurutkan data berdasarkan kolom “dt”.

- 6) Dilanjutkan dengan memilih kolom-kolom yang akan digunakan untuk fase modeling, yaitu kolom id, dt, trafik, dan capacity. Hasil dari tahap ini, data akan terlihat seperti pada Tabel 5.

Tabel 5 Drop Kolom Inbound dan Outbound

id	dt	capacity	trafik
7	2022-04-13 02:50:00	8.407706e+09	1.000000e+11
7	2022-04-13 02:55:00	7.930997e+09	1.000000e+11
7	2022-04-13 03:00:00	7.879706e+09	1.000000e+11
7	2022-04-13 03:05:00	7.876626e+09	1.000000e+11
7	2022-04-15 03:10:00	7.414139e+09	1.000000e+11

- 7) Membuat kolom “occupancy”. Kolom ini berisikan nilai dari pembagian antara kolom “trafik” dengan kolom “capacity”. Data occupancy ini juga yang akan menjadi input dari model yang dilakukan pada penelitian.

$$\text{occupancy} = \frac{\text{trafik}}{\text{capacity}} \times 100 \quad (9)$$

Hasil dari tahap ini, data akan terlihat seperti pada Tabel 6.

Tabel 6 Kolom Occupancy Ditambahkan pada Dataset

dt	id	capacity	trafik	occupancy(%)
2022-01-01 00:00:00	7	1.686599e+10	1.000000e+11	16.865989
2022-01-01 00:05:00	7	1.754626e+10	1.000000e+11	17.546259
2022-01-01 00:10:00	7	1.762915e+10	1.000000e+11	17.629151
2022-01-01 00:15:00	7	1.709390e+10	1.000000e+11	17.093898
2022-01-01 00:20:00	7	1.664540e+10	1.000000e+11	16.645397

- 8) Sebelum membuat perancangan model, dilakukan split data guna membagi data menjadi 2 bagian, yaitu menjadi data train dan data test.
- 9) Melakukan scaling pada data, yang bertujuan agar tahan terhadap pencilaan data (outliers).

B. Proses Pelatihan Model

Data yang sudah dibersihkan saat tahap pre-processing selanjutnya dimasukkan kedalam tahap pelatihan model. Proses pelatihan model terus berulang sebanyak jumlah epoch yang telah ditentukan. Berikut pemisalan kalkulasi pada algoritma dari model.

Diketahui input dari data untuk model sebagai berikut:

$$h_{t-1}, X_t = 16.86$$

Diketahui pemisalan nilai bobot sebagai berikut:

$$W_f = 0.57$$

$$b_f = 0.2$$

$$W_i = 0.63$$

$$b_i = 0.1$$

$$W_c = 0.51$$

$$b_c = 0$$

$$W_o = 0.68$$

$$b_o = 0.05$$

Berdasarkan fungsi matematis pada persamaan (1), maka hasil forget gate di waktu t adalah sebagai berikut.

$$F_t = \sigma(W_f \times [h_{t-1}, X_t] + b_f)$$

$$F_t = \sigma(0.57 \times 16.86 + 0.2)$$
$$F_t = \sigma(9,6102 + 0.2)$$
$$F_t = \sigma(9,8102)$$
$$F_t = 0.9999451141446952$$

Berdasarkan fungsi matematis pada persamaan (2) dan (3), maka hasil input gate di waktu t adalah sebagai berikut

$$i_t = \sigma(W_i \times [h_{t-1}, X_t] + b_i)$$
$$i_t = \sigma(0.63 \times 16.86 + 0.1)$$
$$i_t = \sigma(10,6218 + 0.1)$$
$$i_t = \sigma(10,7218)$$
$$i_t = 0.9999779417099014$$

$$C_t = \tanh(W_c \times [h_{t-1}, X_t] + b_c)$$
$$C_t = \tanh(0.51 \times 16.86 + 0)$$
$$C_t = \tanh(10,6218 + 0)$$
$$C_t = \tanh(8.5986 + 0)$$
$$C_t = 0.9999999932$$

Berdasarkan fungsi matematis pada persamaan (4), maka hasil output gate di waktu t adalah sebagai berikut

$$O_t = \sigma(W_o \times [h_{t-1}, X_t] + b_o)$$
$$O_t = \sigma(0.68 \times 16.86 + 0.05)$$
$$O_t = \sigma(11.4648 + 0.05)$$
$$O_t = \sigma(11.5148)$$
$$O_t = 0.9999900188274167$$

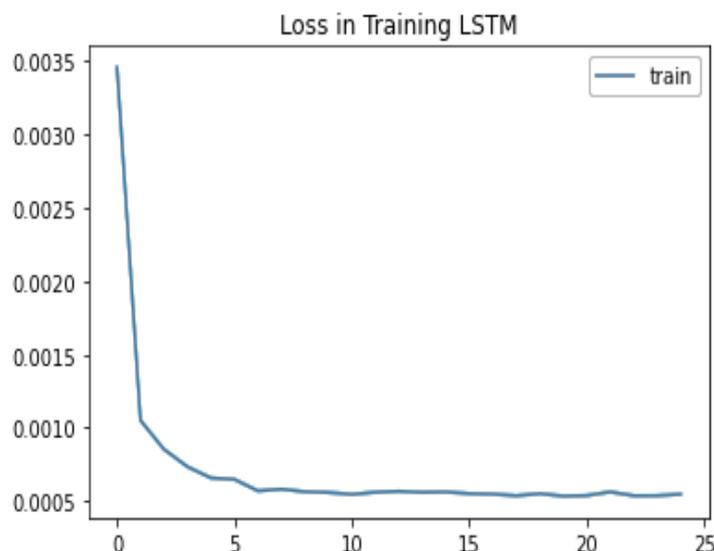
Berdasarkan fungsi matematis pada persamaan (5), maka hasil di waktu t adalah sebagai berikut

$$h_t = O_t \times \tanh(C_t)$$
$$h_t = 0.9999900188274167 \times \tanh(0.9999999932)$$
$$h_t = 0.9999900188274167 \times 0.7615941531$$
$$h_t = 0.7615865515$$

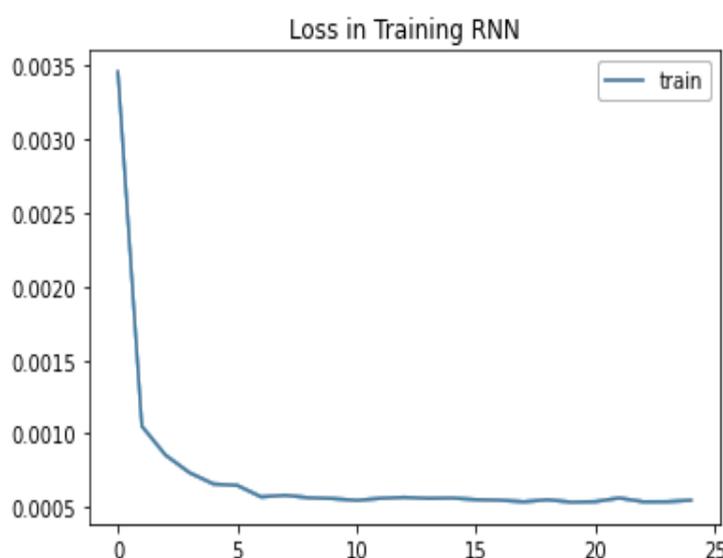
C. Hasil Training dan Test

Penelitian ini memiliki tujuan untuk melakukan perbandingan performa model Recurrent Neural Network (RNN) dan Long Short-Term Memory (LSTM) yang ada pada Deep Learning dengan menggunakan dataset lalu lintas jaringan PT XYZ. Output dari penelitian ini adalah perbandingan performa dari setiap model. Percobaan dilakukan beberapa kali dengan mencoba parameter model RNN dan LSTM.

Proses training disajikan dalam bentuk grafik pada Gambar 8 dan Gambar 9, dimana rata-rata loss berbanding dengan berapa kali epoch yang dilakukan.



Gambar 8 Grafik Loss Training Model LSTM



Gambar 9 Grafik Loss Training RNN

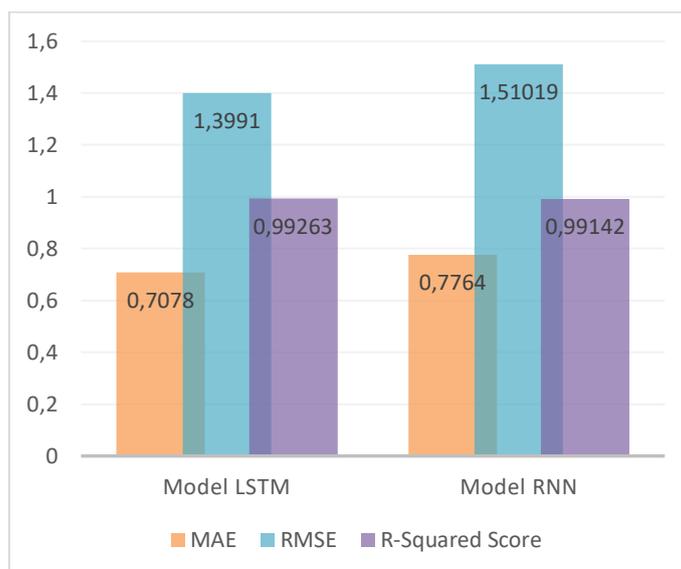
Tabel 7 menunjukkan performa prediksi dari algoritma model RNN dan LSTM, yang berbeda adalah parameter pengujian yang dilakukan. Model dengan performa terbaik ditandai dengan huruf tebal.

Tabel 7 Performa Pengujian Model

Model	MAE	RMSE	R-Squard Score
LSTM	0.70780	1.39910	0.99263 / 99.2%
RNN	0.77640	1.51019	0.99142 / 99.1%

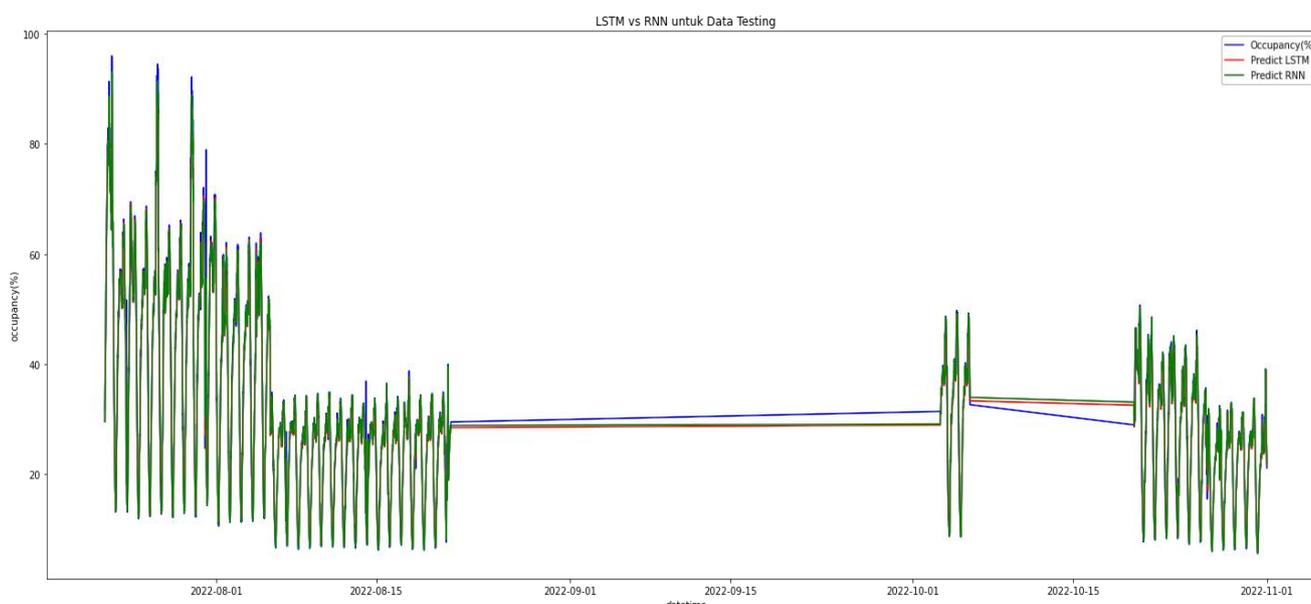
Setelah dilakukan pengujian, diperoleh hasil performance metric dari kedua model. Untuk model LSTM didapatkan hasil nilai error MAE sebesar 0.70780, nilai error RMSE sebesar 1.39910 dengan nilai akurasi S-Squard sebesar 0.99263 atau sekitar 99.2%. Dan untuk model RNN didapatkan hasil nilai error MAE sebesar 0.77640, nilai error RMSE sebesar 1.51019 dengan nilai akurasi R-Squard sebesar 0.99142 atau sekitar 99.1%.

Selanjutnya hasil perhitungan tersebut akan digambarkan dalam bentuk diagram batang. Gambar 10 adalah perbandingan hasil perhitungan nilai error dan nilai R-Squared diatas, dapat dilihat pada diagram batang bahwa secara umum model dengan algoritma LSTM dan model dengan algoritma RNN tersebut memiliki nilai error yang cukup baik dan tidak memperlihatkan perbedaan yang begitu signifikan dari kedua model. Namun, model LSTM memiliki nilai error yang lebih rendah dan nilai R-Squard yang lebih tinggi dibandingkan dengan model RNN.



Gambar 10 Diagram Perbandingan Error Performa dan Akurasi Model

Dari pengujian yang dilakukan terhadap dataset didapatkan grafik perbandingan antara data test dengan model LSTM dan model RNN seperti pada Gambar 11.



Gambar 11 Perbandingan Data Testing dengan Prediksi yang Dilakukan Model

Dari hasil pengujian, dapat disimpulkan bahwa model LSTM dan RNN yang dilakukan pada penelitian ini menghasilkan model yang cukup baik. Dimana pada penelitian sebelumnya melakukan prediksi kemacetan jaringan menggunakan RNN mendapatkan nilai error MAE sebesar 13 dan untuk prediksi kemacetan jaringan menggunakan LSTM mendapatkan nilai error MAE sebesar 9.27. Nilai error yang dihasilkan pada penelitian ini terbilang cukup rendah dibandingkan dengan penelitian sebelumnya karena nilai error MAE model LSTM dan RNN sebesar 0.7764 dan 0.77078.

V. KESIMPULAN

Penelitian ini menghasilkan sebuah hasil perbandingan dari model dengan algoritma yang ada pada Deep Learning dengan menggunakan dataset lalu lintas jaringan PT XYZ. Pengujian pada model dilakukan dengan arsitektur model LSTM dan model RNN yang memiliki 1 input layer, 4 hidden layer, dan 1 output layer. Model LSTM memiliki nilai error dan nilai akurasi R-Squared lebih baik dibanding model RNN, dimana model LSTM memiliki nilai error MAE sebesar 0.70780, nilai error RMSE sebesar 1.39910 dengan nilai akurasi S-Squard sebesar 0.99263 atau sebesar 99.2%. Dari hasil penelitian ini, peneliti memberikan kesimpulan bahwa model dengan Algoritma

LSTM yang terdapat pada Deep Learning dapat digunakan untuk melakukan prediksi kemacetan lalu lintas jaringan yang terjadi di PT XYZ.

DAFTAR PUSTAKA

- [1] M. Ngaffi, "KEMAJUAN TEKNOLOGI DAN POLA HIDUP MANUSIA DALAM PERSPEKTIF SOSIAL BUDAYA," Sukoharjo, 2014. [Daring]. Tersedia pada: <http://www.tempo.co/read/news/2010/12/23>
- [2] Simon Kemp, "DATAREPORTAL," 15 Februari 2022. <https://datareportal.com/reports/digital-2022-indonesia> (diakses 2 Desember 2022).
- [3] E. Harahap, "Prediksi Kemacetan pada Jaringan Komputer Menggunakan Metode Naive Bayesian Classifier," 2012.
- [4] M. NJ, S. Sahib, N. Suryana, dan B. Hussin, "UNDERSTANDING NETWORK CONGESTION EFFECTS ON PERFORMANCE-ARTICLES REVIEW," *Journal of Theoretical and Applied Information Technology*, vol. 92, no. 2, hlm. 311–321, Okt 2016, [Daring]. Tersedia pada: www.jatit.org
- [5] M. E. Dodan, Q. T. Vien, dan T. T. Nguyen, "Internet Traffic Prediction Using Recurrent Neural Networks," *EAI Endorsed Transactions on Industrial Networks and Intelligent Systems*, vol. 9, no. 4, 2022, doi: 10.4108/eetinis.v9i4.1415.
- [6] W. Jiang, "Internet traffic prediction with deep neural networks," *Internet Technology Letters*, vol. 5, no. 2, Mar 2022, doi: 10.1002/itl2.314.
- [7] U. Khaira, M. Alfalah, P. Claudia Septiani Gulo, dan R. Purnomo, "Prediksi Kemunculan Titik Panas Di Lahan Gambut Provinsi Riau Menggunakan Long Short Term Memory," vol. 5, no. 3, 2020.
- [8] Suryanto, K. N. Ramadhani, dan S. Mandala, *Deep Learning Modernisasi Machine Learning untuk Big Data*. Bandung: Informatika Bandung, 2019.
- [9] W. Nusalina, "Pengenalan Deep Learning : Neural Network," <https://medium.com/>, 25 Juni 2019.
- [10] S. Sharma, S. Sharma, dan A. Athaiya, "ACTIVATION FUNCTIONS IN NEURAL NETWORKS," 2020. [Daring]. Tersedia pada: <http://www.ijeast.com>
- [11] Y. Bai, J. Xie, C. Liu, Y. Tao, B. Zeng, dan C. Li, "Regression modeling for enterprise electricity consumption: A comparison of recurrent neural network and its variants," *International Journal of Electrical Power and Energy Systems*, vol. 126, Mar 2021, doi: 10.1016/j.ijepes.2020.106612.
- [12] A. Mittal, "Understanding RNN and LSTM," <https://aditi-mittal.medium.com/>, 12 Oktober 2019.
- [13] O. C, "Understanding LSTM Networks," *Internet*: <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>, 2015.
- [14] Z. Shen, Y. Zhang, J. Lu, J. Xu, dan G. Xiao, "A novel time series forecasting model with deep learning," *Neurocomputing*, vol. 396, hlm. 302–313, Jul 2020, doi: 10.1016/j.neucom.2018.12.084.
- [15] X. Shi dkk., "Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting," 2015.
- [16] X. Ma, Z. Tao, Y. Wang, H. Yu, dan Y. Wang, "Long short-term memory neural network for traffic speed prediction using remote microwave sensor data," *Transp Res Part C Emerg Technol*, vol. 54, hlm. 187–197, Mei 2015, doi: 10.1016/j.trc.2015.03.014.
- [17] U. Azmi, Z. N. Hadi, dan S. Soraya, "ARDL METHOD: Forecasting Data Curah Hujan Harian NTB," *Jurnal Varian*, vol. 3, no. 2, hlm. 73–82, Mei 2020, doi: 10.30812/varian.v3i2.627.
- [18] M. Kuncoro, *Metode kuantitatif: Teori dan aplikasi untuk bisnis dan ekonomi*, 4 ed. Yogyakarta: Unit Penerbit dan Percetakan, 2011.