

Prediksi Network Capacity Planning PT XYZ Menggunakan Algoritma Recurrent Neural Network (RNN)

Muhammad Hafizh ¹, Faqih Hamami ², Tien Fabrianti Kusumasari ³

^{1,2,3} S1 Sistem Informasi, Fakultas Rekayasa Industri, Universitas Telkom
hafizhmuh@student.telkomuniversity.ac.id¹, faqihhamami@telkomuniversity.ac.id²,
tienkusumasari@telkomuniversity.ac.id³

Abstrak

PT XYZ merupakan perusahaan yang menyediakan jaringan internet. Selain itu mereka juga menggunakan jaringan internet untuk penggunaan sehari-hari. Jaringan yang digunakan pasti memiliki kapasitas. Ketika penggunaan jaringan internet mendekati kapasitasnya maka akan terjadi penurunan kecepatan, oleh karena itu dibutuhkan sesuatu yang dapat memprediksi serta memantau penggunaan jaringan internet. Untuk memprediksi penggunaan jaringan internet, penerapan deep learning dapat digunakan dalam kasus ini. Salah satu algoritma yang digunakan dalam penelitian ini adalah Recurrent Neural Network (RNN). Dilakukan pengujian terhadap beberapa parameter seperti hidden layer, jumlah neuron pada hidden layer, jumlah epoch, dan jumlah batch size. Setelah melakukan pengujian dan evaluasi terhadap model dan parameter yang digunakan, didapatkan hasil untuk algoritma RNN dengan nilai error pada setiap id adalah 0.918812 untuk nilai R Squared dan 0.002233 untuk nilai MSE. Dari hasil pengujian model tersebut dilakukan peramalan untuk 60 hari kedepan dan terdapat satu id yang penggunaan jaringan internet hampir mencapai kapasitasnya yaitu id 23 pada tanggal 8 September 2022 diprediksi akan mencapai 7.5E+12 bit.

Kata Kunci: *Recurrent Neural Network, Network Capacity Planning, parameter, prediksi*

Abstract

PT XYZ is a company that provides internet networks. In addition, they also use the internet network for daily use. The network used must have capacity. When the use of the internet network approaches its capacity, there will be a decrease in speed, therefore something is needed that can predict and monitor the use of the internet network. To predict internet network usage, the application of deep learning can be used in this case. One of the algorithms used in this study is the Recurrent Neural Network (RNN). Testing was carried out on several parameters such as the hidden layer, number of neurons on the hidden layer, number of epochs, and number of batch sizes. After testing and evaluating the model and parameters used, results were obtained for the RNN algorithm with the error value on each id being 0.918812 for the R Squared value and 0.002233 for the MSE value. From the test results of the model, forecasting was carried out for the next 60 days and there is one id whose internet network usage has almost reached its capacity, namely id 23 on September 8, 2022, predicted to reach 7.5E + 12 bits.

Keywords: *Recurrent Neural Network, Network Capacity Planning, parameters, predictions*

1. PENDAHULUAN

PT XYZ merupakan perusahaan yang bergerak di industri teknologi informasi dan komunikasi (TIK) dan jaringan telekomunikasi di Indonesia. PT XYZ memiliki jaringan internet yang besar dan merupakan salah satu penyedia jaringan internet terbesar di Indonesia. Kecepatan jaringan internet dapat terpengaruh oleh banyak faktor dan untuk mengidentifikasi kinerjanya, perusahaan melakukan Perencanaan Kapasitas Jaringan (Network Capacity Planning). Perencanaan kapasitas jaringan menggunakan elemen-elemen seperti trafik inbound dan outbound, kapasitas jaringan, dan occupancy. Jika penggunaan jaringan mencapai 75%, maka akan ada alert dan pertimbangan untuk upgrade

kapasitas jaringan. Dalam penelitian ini, fokus dari pembuatan model akan berfokus pada memprediksi network capacity planning menggunakan pendekatan deep learning.

penelitian ini berkonsentrasi pada perencanaan kapasitas jaringan PT XYZ untuk mengatasi masalah penurunan kecepatan jaringan. Penelitian ini menggunakan metode deep learning dengan model Recurrent Neural Network (RNN) untuk memprediksi kapasitas jaringan di masa yang akan datang. Recurrent Neural Network dipilih karena kemampuannya untuk menangani data yang memiliki hubungan temporal dan kompleksitas tinggi. Harapannya, hasil penelitian ini dapat menjadi solusi bagi PT XYZ dalam mengatasi masalah penurunan kecepatan jaringan.


2. KAJIAN TEORI

2.1 Network Capacity Planning

Capacity Planning adalah upaya memprediksi dan mengatasi kebutuhan produk di masa depan. Tujuannya adalah untuk mencapai jadwal produksi dan memastikan kapasitas yang tersedia sesuai dengan kebutuhan. perencanaan kapasitas merupakan fungsi untuk menentukan tingkatan kapasitas yang dibutuhkan agar mencapai jadwal produksi, selanjutnya dibandingkan dengan kapasitas yang tersedia dan membuat rancangan yang dibutuhkan sesuai dengan tingkat kapasitas dan jadwal produksi. [1]

2.2 Neural Network

Neural adalah istilah yang merujuk pada jaringan saraf manusia. Dalam ilmu komputer, neural network adalah model komputasi yang menirukan cara kerja otak manusia dan digunakan dalam proses machine learning. Neural network terdiri dari lapisan-lapisan neuron yang saling terhubung dan dapat diterapkan dalam berbagai bidang seperti pengolahan gambar, teks, dan suara.




Gambar 2.1 Arsitektur neural network

Pada gambar 2.1 kumpulan dari neuron yang berada di neural network disebut juga dengan hidden layer. setiap hidden layer saling terhubung dengan hidden layer lainnya dan output layer. Hidden layer dapat diatur menjadi beberapa hidden layer sesuai dengan kebutuhan pengguna.

2.3 Recurrent Neural Network

Recurrent Neural Network adalah jenis Neural Network yang membantu memproses data berurutan dengan menyimpan memori dan mengaitkan data masa lalu dengan input saat ini. Ini memproses data sampai sampai dan mengambil keputusan berdasarkan informasi yang sudah ada dalam memori internalnya [2]. Hal ini membuat Recurrent Neural Network lebih baik dalam membuat prediksi dan mengenali pola dari data berurutan.



Gambar 2.2 Arsitektur recurrent neural network


Gambar 2.2 diatas, gambar sebelah kiri menunjukkan proses dari diagram RNN sebelum dibuka (unrolled) menuju jaringan penuh (full network). gambar sebelah kanan menunjukkan RNN yang telah dibuka (full network) sehingga detail dari urutannya menjadi lebih jelas. kotak berwarna biru menandakan hidden layer. x_t adalah input pada time step (t). s_t adalah hidden state dari setiap time step (t), hidden state mempresentasikan “memory” dari sebuah network untuk menyimpan hasil perhitungan yang dilakukan. o_t adalah output pada step (t) yang berfungsi untuk melakukan prediksi data selanjutnya.

2.4 Fungsi Aktivasi

Fungsi aktivasi merupakan fungsi matematika yang berguna untuk mengontrol seluruh aktivitas neuron di dalam jaringan neural. Fungsi aktivasi digunakan dalam jaringan neural untuk mengatur aktivitas dari setiap neuron, yang digunakan untuk menentukan apakah neuron harus merespon atau tidak terhadap input yang diterima. Jenis fungsi aktivasi yang digunakan sangat berpengaruh terhadap kinerja suatu jaringan neural, oleh sebab itu pemilihan jenis fungsi aktivasi yang tepat sangat penting dalam proses pembuatan jaringan neural

1. Fungsi Aktivasi ReLU (Rectified Linear Unit)

ReLU (Rectified Linear Unit) adalah sebuah fungsi aktivasi yang digunakan dalam jaringan neural [3]. Fungsi ini memiliki bentuk yang sederhana yaitu output yang sama dengan input jika input lebih dari 0, dan output 0 jika input kurang dari atau sama dengan 0. Fungsi ini juga digunakan dalam proses pelatihan jaringan neural untuk meningkatkan kinerja jaringan neural. berikut grafik fungsi aktivasi ReLU (Rectified Linear Unit).



Gambar 2.3 Grafik fungsi aktivasi ReLU

Pada gambar 2.3 terlihat fungsi aktivasi ReLU memiliki bentuk linear ke atas dan input yang masuk akan diubah menjadi nilai 0 atau nilai inputannya.

2.5 Optimizer

Optimizer adalah sebuah algoritma atau metode yang digunakan dalam jaringan neural untuk menyesuaikan bobot dan bias dari jaringan neural dengan cara mengurangi error atau loss function yang dihasilkan oleh jaringan neural. Proses ini disebut sebagai pelatihan jaringan neural. Ada beberapa jenis optimizer yang umum digunakan dalam neural network, pemilihan jenis optimizer dapat berpengaruh terhadap kinerja neural network, oleh karena itu pemilihan optimizer yang tepat sangat penting dalam pelatihan neural network. Berikut beberapa jenis optimizer.

1. Optimizer Adam (Adaptive Moment Estimation)

Adam adalah optimizer yang digunakan dalam jaringan neural yang merupakan gabungan dari dua konsep optimisasi, yaitu Stochastic Gradient Descent (SGD) dan momentum. Adam memperbaiki bobot dan bias jaringan neural dengan pendekatan acak dan mempertimbangkan momentum untuk mengatasi osilasi. Adam juga menyesuaikan learning rate secara terpisah untuk setiap parameter dengan mengukur rata-rata dan variansi gradien setiap parameter.

2.6 Matriks Evaluasi

Metrik evaluasi adalah sebuah ukuran atau indikator yang digunakan untuk mengevaluasi kinerja dari suatu model atau algoritma. Metrik evaluasi digunakan untuk menentukan seberapa baik suatu model atau algoritma dapat menyelesaikan suatu masalah atau tugas tertentu.

1. Mean Squared Error (MSE)

Mean Squared Error (MSE) adalah matrik evaluasi yang digunakan dalam proses regresi. MSE mengukur rata-rata perbedaan kuadrat antara nilai yang dihasilkan oleh model dan nilai aktual dari data. Semakin kecil nilai MSE, semakin baik kinerja dari model tersebut [4]. MSE digunakan untuk mengevaluasi model regresi karena memberikan nilai yang mudah diinterpretasikan dan memberikan bobot yang lebih besar pada nilai yang jauh dari nilai aktual.

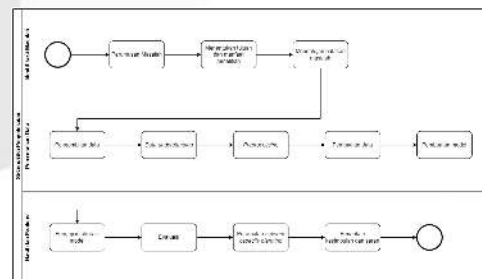
2. R-Squared (Coefficient of Determination)

R-Squared (Coefficient of Determination) adalah matrik evaluasi yang digunakan dalam proses regresi. R-Squared mengukur seberapa baik variansi dari nilai yang dihasilkan oleh model dapat menjelaskan variansi dari nilai aktual dari data. R-Squared berkisar antara 0 dan 1, nilai yang lebih tinggi menunjukkan bahwa model lebih baik dalam menjelaskan variansi dari nilai aktual. Hair et al menyatakan bahwa nilai R square 0,75 termasuk ke dalam kategori kuat, nilai R square 0,50 termasuk kategori moderat dan nilai R square 0,25 termasuk kategori lemah (Hair et al., 2011).

$$R^2 = 1 - \frac{\sum_{i=1}^n (X_i - F_i)^2}{\sum_{i=1}^n (Y_i - F_i)^2} \quad (3)$$

3. METODE

Dalam sistematika penyelesaian masalah akan dilakukan tiga tahapan yaitu identifikasi masalah, pemrosesan data, dan evaluasi. Berikut gambar dari sistematika penyelesaian masalah.



Gambar 3.4 Sistematika penyelesaian

Tahap Identifikasi Masalah memiliki beberapa aktivitas yaitu menentukan identifikasi masalah, menentukan solusi masalah, menentukan tujuan dan manfaat, dan menentukan batasan penelitian pada studi kasus ini. Pada tahap ini juga disertakan literatur mengenai teori-teori yang akan digunakan, serta model konseptual untuk

penyelesaian masalah dengan membuat rumusan solusi yang akan digunakan. Pada tahap ini juga akan menentukan data-data yang akan dipakai. Setelah menyelesaikan tahap identifikasi masalah dan menentukan data-data yang akan digunakan, selanjutnya masuk ke tahap pemrosesan data. Tahap ini memiliki beberapa aktivitas yaitu Pengumpulan data, Preprocessing, Pembagian Data, dan Pembuatan Model. Setelah melewati tahap pemrosesan data, terakhir akan dilakukan tahap evaluasi. Pada tahap ini akan dilakukan beberapa aktivitas, yaitu pengujian akurasi model, peramalan network capacity planning, dan penarikan kesimpulan dan saran.

3.1 Data Understanding

Setelah mendapatkan data, tahap selanjutnya adalah data understanding. Berikut hasil analisis data understanding.

Tabel 3.1 Deskripsi Dataset *Traffic Network Element* PT XYZ

Nama Kolom	Tipe Data	Deskripsi
id	Integer	Merupakan kolom yang merepresentasikan identitas <i>network interface</i> pada PT XYZ.
dt	Object	Merupakan kolom yang menyimpan data tanggal dan waktu penggunaan jaringan <i>inbound</i> dan <i>outbound</i> .
<i>inbound</i>	Integer	Merupakan kolom yang menunjukkan jumlah penggunaan jaringan <i>inbound</i> dalam satuan bits di PT XYZ.
<i>outbound</i>	Integer	Merupakan kolom yang menunjukkan jumlah penggunaan jaringan <i>outbound</i> dalam satuan bits di PT XYZ.

Tabel 3.2 Deskripsi Dataset *Capacity* PT XYZ

Nama Kolom	Tipe Data	Deskripsi
id	Integer	Merupakan kolom yang merepresentasikan identitas <i>network interface</i> pada PT XYZ.
<i>capacity</i>	Float	Merupakan kolom yang merepresentasikan kapasitas maksimal internet untuk setiap <i>network interface</i> dalam satuan bits di PT XYZ.

Setelah dilakukannya analisis terhadap data, dari 10 id yang ada pada dataset *traffic network element* dan dataset *capacity*, didapatkan bahwa hanya 4 id yang dapat digunakan dan sesuai dengan *business rules* perusahaan PT XYZ adalah sebagai berikut.

Tabel 3.3 Status Id Dataset

Id	Status Data	Alasan
1	Data tidak digunakan.	Data pada id 1 tidak sesuai dengan <i>business rules</i> , karena nilai dari data pada id ini sebagian besar bernilai 0.
2	Data tidak digunakan.	Data pada id 2 tidak sesuai dengan <i>business rules</i> , karena id ini tidak memiliki data kapasitas yang ada pada dataset <i>capacity</i> .
7	Data digunakan.	Data pada id 7 sesuai dengan <i>business rules</i> .
12	Data tidak digunakan.	Data pada id 12 tidak sesuai dengan <i>business rules</i> , karena data <i>capacity</i> pada id ini belum dilakukan <i>update</i> .
13	Data tidak digunakan.	Data pada id 13 tidak sesuai dengan <i>business rules</i> , karena data <i>capacity</i> pada id ini belum dilakukan <i>update</i> dan data pada id ini sebagian besar memiliki nilai 0.
14	Data tidak digunakan.	Data pada id 14 tidak sesuai dengan <i>business rules</i> , karena seluruh nilai dari data pada id ini bernilai 0.
19	Data digunakan.	Data pada id 19 sesuai dengan <i>business rules</i> .
23	Data digunakan.	Data pada id 23 sesuai dengan <i>business rules</i> .
28	Data digunakan.	Data pada id 28 sesuai dengan <i>business rules</i> .
70	Data tidak digunakan.	Data pada id 70 tidak sesuai dengan <i>business rules</i> , karena data <i>capacity</i> pada id ini belum dilakukan <i>update</i> .

3.1 Data Pre-Processing

Data yang telah didapatkan akan melalui tahap preprocessing terlebih dahulu. Tools pengolahan data yang digunakan pada penelitian kali ini adalah Google Collab. Google Collab adalah software dari Google untuk menulis kode program secara online berbasis cloud yang terintegrasi langsung dengan Drive. Biasanya digunakan untuk pemrograman dan pengolahan data. Preprocessing


harus dilakukan agar model menghasilkan hasil prediksi yang baik dari data train. Tahapan *data pre-processing* antara lain akan dijelaskan pada tabel berikut.

Tabel 3.4 Deskripsi Tahapan *Data Pre-Processing*

Tahapan	Deskripsi
<i>Merge Dataset</i>	Kombinasi dari 2 dataset, yaitu dataset Traffic Network Element dan dataset Capacity, dilakukan dengan mempertimbangkan ID sebagai kriteria utamanya.
<i>Grouping Data</i>	Melakukan <i>grouping</i> pada dataset sesuai dengan Id setiap data.
<i>Clean Data</i>	Ada beberapa langkah yang harus dilakukan dalam menggabungkan kedua dataset, yaitu membuat kolom baru bernama "trafik", memastikan format tanggal dan waktu sudah sesuai, memastikan rentang periode data yang digunakan cocok, mengatasi data yang hilang, mengatasi data ganda, menghapus kolom yang tidak digunakan, dan membuat kolom baru bernama "occupancy"..
<i>Split data</i>	Pembagian data menjadi data train dan data test.
<i>Scaling Data</i>	Penggunaan <i>Scaling</i> pada data bertujuan untuk melindungi data dari pengaruh dari nilai-nilai yang tidak biasa (outliers).

3.2 Modeling

Model Recurrent Neural Network (RNN) dipilih karena memiliki kecocokan dengan data time series. Pada proses pembuatan model Recurrent Neural Network (RNN) akan menggunakan beberapa parameter yaitu, hidden layer, block, epoch, dan batch size.



Gambar 3.5 Desain model RNN

Pada gambar IV.3-11 terlihat desain dari model Recurrent Neural Network yang digunakan dalam penelitian ini adalah dua hidden layer RNN, 1 dense layer yang berfungsi sebagai output. Terdapat 1 input yang masuk secara sekuensial kedalam 8 neuron ke dalam hidden layer pertama RNN, output hidden layer 1 menjadi input kedalam 16 neuron hidden layer 2, output hidden layer 2 menjadi input kedalam layer output dan menghasilkan 1 buah output.

Terdapat beberapa atribut arsitektur LSTM yang digunakan untuk membangun model pada penelitian ini. Model LSTM yang dibangun dapat dilihat seperti pada gambar 3.5.

Setelah membuat model, dilakukan inialisasi parameter pada model penelitian ini akan dicoba dengan beberapa parameter dengan jumlah yang berbeda. Berikut inialisasi parameter yang digunakan saat melatih model.

Tabel 3.5 Parameter Model Recurrent Neural Network (RNN)

Parameter RNN	Jumlah / Jenis
Hidden Layer	1 dan 2
Neuron	8 dan 16
Optimizer	Adam
Fungsi Aktivasi	ReLU
Epoch	15, 30, dan 45
Batch Size	2, 4, dan 16

4. HASIL DAN PEMBAHASAN


4.1 Model dan Parameter Id 23

Setelah dilakukan pengujian terhadap model dan parameter-parameter yang telah ditentukan, didapatkan hasil pengujian dengan parameter terbaik, dimana hasil pengujian model dan parameter ini menunjukkan nilai error performa yang rendah. Adapun parameter terbaik untuk Id 23 dapat dilihat pada tabel berikut.

Tabel 4.6 Model dan Parameter Id 7

Model dan Parameter	Jumlah/Jenis
Rasio	90:10
Hidden layer	2
Unit Neuron	16, 16
Epoch	15
Batch Size	2

Hasil yang didapatkan untuk Id 23 ini memiliki nilai matriks R2 Score senilai 0.886835 dan MSE senilai 0.002951 yang berarti model yang dihasilkan sudah memiliki akurasi yang baik. Berikut grafik hasil prediksi



Gambar 4.6 Perbandingan Data *Test* dan Prediksi Id 23


4.2 Model dan Parameter Id 28

Setelah dilakukan pengujian terhadap model dan parameter-parameter yang telah ditentukan, didapatkan hasil pengujian dengan parameter terbaik, dimana hasil pengujian model dan parameter ini menunjukkan nilai error performa yang rendah. Adapun parameter terbaik untuk Id 28 dapat dilihat pada tabel berikut.

Tabel 4.7 Model dan Parameter Id 7

Model dan Parameter	Jumlah/Jenis
Rasio	80:20
Hidden layer	2
Unit Neuron	16, 16
Epoch	50
Batch Size	8

Hasil yang didapatkan untuk Id 28 ini memiliki nilai matriks R2 Score senilai 0.929394 dan MSE senilai 0.00118 yang berarti model yang dihasilkan sudah memiliki akurasi yang baik. Berikut grafik hasil prediksi



Gambar 4.7 Perbandingan Data *Test* dan Prediksi Id 28

4.3 Model dan Parameter Id 19


Setelah dilakukan pengujian terhadap model dan parameter-parameter yang telah ditentukan, didapatkan hasil pengujian dengan parameter terbaik, dimana hasil pengujian model dan parameter ini menunjukkan nilai error performa yang rendah. Adapun parameter terbaik untuk Id 19 dapat dilihat pada tabel berikut.

Tabel 4.8 Model dan Parameter Id 7

Model dan Parameter	Jumlah/Jenis
Rasio	80:20
Hidden layer	1
Unit Neuron	16
Epoch	15

Batch Size	8
------------	---

Hasil yang didapatkan untuk Id 19 ini memiliki nilai matriks R2 Score senilai 0.940168 dan MSE senilai 0.002568 yang berarti model yang dihasilkan sudah memiliki akurasi yang baik. Berikut grafik hasil prediksi



Gambar 4.8 Perbandingan Data *Test* dan Prediksi Id 23

Pengujian performa dan analisis evaluasi yang telah dilakukan terhadap model RNN menghasilkan model-model prediksi dengan parameter yang cocok untuk setiap *network interface* dan menghasilkan nilai *metric performace* yang baik. Data hasil dari analisis ini digambarkan pada tabel 4.10 berikut.

Tabel 4.9 Data Evaluasi Model LSTM

Id	MSE	R2 SCORE
23	0,002951	0.886832
28	0,00118	0.929434
19	0.002568	0.940168

4.4 Analisis Hasil Prediksi

Penelitian ini melakukan prediksi *network capacity planning* selama 60 hari kedepan. Data hasil prediksi adalah sebagai berikut.

a. Prediksi untuk Id 23


Berdasarkan hasil prediksi menggunakan algoritma RNN pada Id 23 selama 60 hari kedepan didapatkan bahwa nilai *occupancy* terkecil dengan nilai $3.16E+12$ bit pada tanggal 1 Oktober 2022 dan nilai *occupancy* terbesar dengan nilai $7.95E+12$ bit pada tanggal 29 Agustus 2022. Grafik dari prediksi seperti gambar 4.12 dibawah berikut.



Gambar 4.9 Grafik Prediksi 1 November 2022 untuk Id 7

b. Prediksi untuk Id 28

Berdasarkan hasil prediksi menggunakan algoritma RNN pada Id 28 selama 60 hari kedepan didapatkan bahwa nilai occupancy terkecil dengan nilai $8.25E+10$ bit pada tanggal 20 September 2022 dan nilai occupancy terbesar dengan nilai $1.75E+12$ bit pada tanggal 8 Oktober 2022. Grafik dari prediksi seperti gambar 4.12 dibawah berikut.



Gambar 4.10 Grafik Prediksi 1 November 2022 untuk Id 7

c. Prediksi untuk Id 19

Berdasarkan hasil prediksi menggunakan algoritma RNN pada Id 19 selama 60 hari kedepan didapatkan bahwa nilai occupancy terkecil dengan nilai $3.41E+12$ bit pada tanggal 23 Agustus 2022 dan nilai occupancy terbesar dengan nilai $6.16E+12$ bit pada tanggal 27 September 2022. Grafik dari prediksi seperti gambar 4.12 dibawah berikut.



Gambar 4.11 Grafik Prediksi 1 November 2022 untuk Id 7

5. KESIMPULAN

Dari hasil penelitian ini, dapat disimpulkan sebagai berikut.

1. Berdasarkan hasil pengujian yang dilakukan pada model yang dibuat, model dengan pendekatan algoritma Recurrent Neural Network (RNN) dapat melakukan prediksi dengan cukup baik dan mendapatkan hasil performa untuk setiap model LSTM dengan rata-rata nilai error MSE 0.002233 dan R2 Score 0,918812.
2. Analisis performa dari model Recurrent Neural Network (RNN) untuk setiap network interface adalah sebagai berikut.
 - a. Untuk id 23, model yang cocok adalah

model RNN dengan rasio data train 90%, menggunakan 2 hidden layer, kedua hidden layer menggunakan 16 neuron, epoch sebanyak 15, dan batch size sebanyak 2. Menghasilkan nilai R2 Score 0.886835 dan MSE 0.002951.

- b. Untuk id 28, model yang cocok adalah model RNN dengan rasio data train 80%, menggunakan 2 hidden layer, kedua hidden layer menggunakan 16 neuron, epoch sebanyak 50, dan batch size sebanyak 8. Menghasilkan nilai R2 Score 0.929434 dan MSE 0.00118.
- c. Untuk id 19, model yang cocok adalah model RNN dengan rasio data train 80%, menggunakan 1 hidden layer dengan 16 neuron, epoch sebanyak 15, dan batch size sebanyak 8. Menghasilkan nilai R2 Score 0.940168 dan MSE 0.002568.

REFERENSI

- | | |
|-----|--|
| [1] | Angling sugiatna, "ANALISIS PERENCANAAN KAPASITAS PRODUKSI DENGAN MENGGUNAKANMETODA ROUGHT CUT CAPACITYPLANNING PENDEKATAN CPOFDI PT. XYZ".Available : https://sistemik.sttbandung.ac.id/index.php/sistemik/article/view/61/46 |
| [2] | Arasy Bazwor, "Prediksi Penggunaan Energi Listrik Menggunakan Algoritma Recurrent Neural Network". |
| [3] | Ichsan Firmansyah, "Komparasi Fungsi Aktivasi ReLU dan TanH Pada Multilayer Perceptron". |
| [4] | Ulul Azmi, "ARDL METHOD: Forecasting Data Jumlah Hari Terjadinya Hidan Di NTB". |