

Prediksi Penggunaan Energi Listrik Menggunakan Algoritma *Recurrent Neural Network*

Electrical Energy Prediction Using Recurrent Neural Network Algorithm

1st Arasy Bazwir
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

razrez@student.telkomunivers
ity.ac.id

2nd Casi Setianingsih
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

setiacasie@telkomuniversity.a
c.id

3rd Muhammad Ary Murti
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

arymurti@telkomuniversity.ac
.id

Abstrak—Penggunaan energi listrik merupakan salah satu faktor penting dalam kehidupan terutama pada sektor gedung dan bangunan. Penggunaan energi listrik dalam sektor gedung tentunya mengkonsumsi banyak energi listrik sehingga bisa menyebabkan keborosan, oleh karena itu dibutuhkan sesuatu yang bisa memprediksi serta memantau penggunaan energi listrik. Untuk memprediksi penggunaan energi listrik, penerapan deep learning dapat digunakan dalam bidang ini. Salah satu algoritma yang digunakan dalam penelitian ini adalah *Recurrent Neural Network* (RNN). Selain itu, akan dibangun sebuah sistem yang bisa memantau serta memprediksi penggunaan energi listrik secara langsung melalui sebuah website. Setelah melakukan pengujian parameter, didapatkan lah hasil untuk algoritma RNN dengan rasio pembagian antara data latih dan data tes yaitu 90% data latih dan 10% data tes, jumlah block sebanyak 1 Block RNN dengan 32 Neuron didalamnya, 1 Dense Layer dengan 8 Neuron, tipe algoritma optimasi Adam dengan learning rate sebesar 0,001, Epochs sejumlah 100 iterasi, dan Batch Size sebanyak 100 yang menghasilkan prediksi cukup baik dengan MAE 0,621, MSE 1,125, RMSE 1,060, R2 Score 72% dan MAPE 14%.

Kata Kunci—penggunaan energi listrik, prediksi, RNN.

Abstract—*The use of electrical energy is one of the important factors in life, especially in the building and building sector. The use of electrical*

energy in the building sector certainly consumes a lot of electrical energy so that it can cause waste, therefore something is needed that can predict and monitor the use of electrical energy. To predict the use of electrical energy, the application of machine learning can be used in this field. One of the algorithms used in this study is the Recurrent Neural Network (RNN). In addition, a system will be build that can monitor and predict the use of electrical energy directly thorough a website. After testing the parameters, the result were obtained for the RNN algorithm with a division ratio between the training data and the test data, name 90% of the training data and 10% of the test data, the number of blocks as many as 1 RNN Block with 32 Neuron in it, 1 Dense Layer with 8 Neuron, the adam optimization algorithm type with a learning rate of 0.001, Epoch of 100 iterations, and a Batch Size of 100 which produced quite good predictions with a MAE of 0.621, MSE 1.125, RMSE 1.060, R2 Score 72% and MAPE 14%.

Keywords— *electrical energy use, prediction, RNN.*

I. PENDAHULUAN

Dari sekian banyak macam energi, listrik adalah salah satu energi yang paling banyak diperhatikan [1]. Konsumsi energi listrik secara global teralokasi pada sektor gedung dan bangunan [2]. Penggunaan energi listrik pada sektor gedung atau bangunan tentunya mengonsumsi banyak energi listrik yang bisa menyebabkan pemborosan energi [3]. Untuk merencanakan pengelolaan kebutuhan energi yang tepat dan efisien, prediksi konsumsi energi yang handal dan akurat adalah sesuatu yang di perlukan, sehingga pengembangan sebuah

model konsumsi energi dengan pembelajaran mesin adalah suatu hal yang penting [4]. Dengan mempertimbangkan data historis energi listrik, di harapkan dapat memprediksi energi listrik di masa yang akan datang karena perencanaan pengelolaan energi listrik di masa yang akan datang sangatlah penting [5].

Dalam kasus ini ada beberapa algoritma pembelajaran mesin konvensional maupun modern yang biasa digunakan untuk melakukan prediksi terhadap konsumsi energi listrik seperti Holt-Winter's (Exponential Smoothing) [6] dan Auto Regressive Integrated Moving Average (ARIMA) [7], adapun penerapan model algoritma pembelajaran mesin modern seperti Deep Neural Network (DNN) [8] dan Recurrent Neural Network (RNN) [9] yang bisa melakukan prediksi jangka pendek maupun jangka panjang.

Konsep dari RNN yaitu menggunakan hidden layer sebelumnya sebagai input di data selanjutnya, RNN memiliki kelebihan dibandingkan dengan Artificial Neural Network (ANN) dan Deep Neural Network (DNN) karena lebih banyak menghemat memori serta proses komputasi, kelemahan dari algoritma RNN adalah pemodelan untuk prediksi jangka panjang, akan tetapi RNN memiliki beberapa varian lain seperti Long-Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU) yang bisa memprediksi secara jangka pendek maupun jangka panjang.


II. KAJIAN TEORI

A. Recurrent Neural Network (RNN)

Pada dasarnya *Recurrent Neural Network (RNN)* atau jaringan syaraf tiruan yang berulang memiliki parameter yang sama dengan *neural network* biasa hanya saja yang membedakan adalah konsep dari *recurrent neural network* itu sendiri. *Recurrent Neural Network (RNN)* menjadikan *hidden layer* sebelumnya sebagai input di proses selanjutnya, karena *hidden layer* sebelumnya menyimpan informasi dari proses ekstraksi fitur di awal sehingga saat *hidden layer* dijadikan input di proses selanjutnya itu menyimpan *memory* (ingatan) dari input sebelumnya [10].

$$MAE = \frac{1}{n} \sum_{i=1}^n |Energy_{Actual} - Energy_{Predicted}|$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (Energy_{Actual} - Energy_{Predicted})^2$$



GAMBAR 2.1
STRUKTUR DASAR RECURRENT NEURAL NETWORK

Seperti yang tertera pada gambar diatas, X_t merupakan input saat waktu t , S_t merepresentasikan nilai keluaran dari *hidden layer* di waktu t , y_t di notasikan sebagai nilai keluaran dari seluruh proses perhitungan di waktu t , U merupakan parameter berupa nilai bobot pada saat keadaan masuk, W merupakan parameter berupa nilai bobot di *hidden layer*, dan V merupakan parameter berupa nilai bobot saat keadaan keluar. Berikut fungsi matematis pada algoritma RNN [10]:

$$S_t = f(Ux_t + WS_{t-1} + b_i)$$

$$y_t = f(Vs_t + b_o)$$

Keterangan:

U, V, W	= bobot (<i>weight</i>)
X_t	= data input di waktu t (saat ini)
S_t	= memori di waktu t (saat ini)
S_{t-1}	= memori di waktu $t - 1$ (waktu sebelumnya)
f	= fungsi aktivasi
b	= bias

B. Metrics

Untuk meninjau hasil performa model prediksi energi listrik, Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE) dan R2 Score diimplementasikan sebagai evaluasi penelitian ini. MAE menghitung nilai error absolut dengan rumus [6][11].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Energy_{Actual} - Energy_{Predicted})^2}$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (Energy_{Actual} - Energy_{Predicted})^2}{\sum_{i=1}^n (Energy_{Mean} - Energy_{Predicted})^2}$$

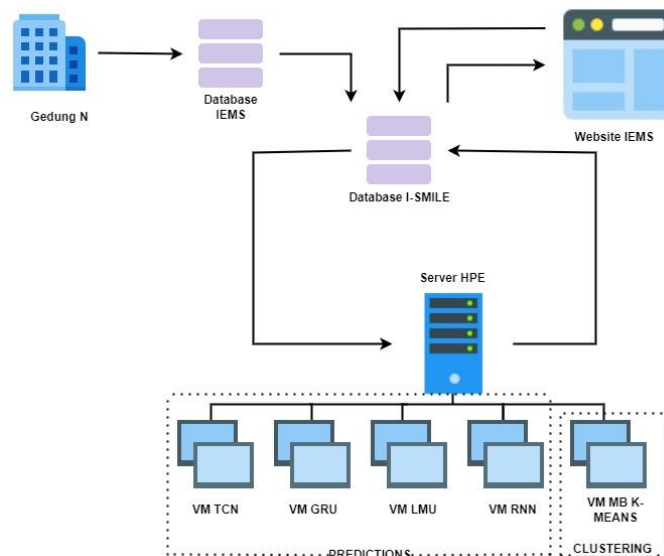
C. Time Series Data

Time series data atau data dengan deret waktu adalah sekumpulan data yang terikat dengan waktu, artinya data tersebut memiliki riwayat yang berkaitan dengan masa lalu. Data dengan deret waktu adalah suatu hal yang penting, dimana data hasil observasi dari masa

lalu di kumpulkan dan di analisis untuk melihat suatu hubungan atau korelasi antar data tersebut [12].

III. METODE

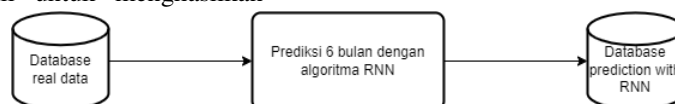
A. Arsitektur Sistem



GAMBAR 3.1
ARSITEKTUR UMUM SISTEM

Gambaran arsitektur umum sistem mencakup suatu sektor gedung atau bangunan di Fakultas Teknik Elektro, Universitas Telkom. Data yang digunakan berasal dari laboratorium *Intelligent Energy Management System* (IEMS) yang diambil melalui *Application Program Interface* (API), kemudian data tersebut di proses dan dibersihkan untuk disimpan kedalam database laboratorium *Intelligent System and Machine Learning* (I-SMILE). Data yang sudah tersimpan didalam database laboratorium I-SMILE diolah kembali untuk menghasilkan

prediksi penggunaan energi listrik harian dan bulanan serta data hasil prediksi tersebut disimpan kembali kedalam database laboratorium I-SMILE untuk ditampilkan dan dapat dipantau pada website. Website dirancang untuk menampilkan informasi mengenai penggunaan energi listrik harian dan bulanan, prediksi penggunaan energi listrik harian dan bulanan serta peningkatan dan penurunan penggunaan energi listrik.



GAMBAR 3.2
ARSITEKTUR KHUSUS SISTEM

Penelitian ini melakukan prediksi data masa depan menggunakan algoritma RNN yang menghasilkan data masa depan selama kurun waktu 6 bulan. Data hasil prediksi tersebut selalu terbaharui secara otomatis setiap pukul

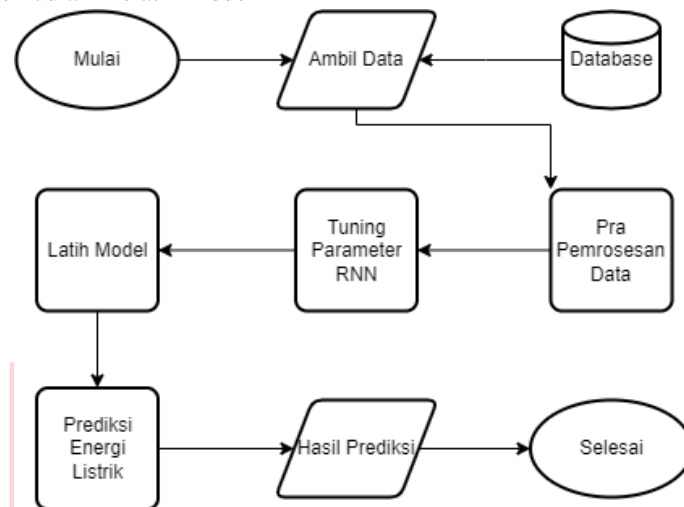
04:00 WIB dan kemudian tersimpan kembali ke dalam database laboratorium I-SMILE.

B. Perancangan Model RNN

Diagram alir menjelaskan alur dari pembuatan

sistem prediksi energi listrik mulai dari proses pengambilan data dari database, proses pembersihan data, proses membagi data menjadi data latih dan data tes, kemudian melatih model

RNN untuk melakukan prediksi serta evaluasi model.



GAMBAR 3.3
DIAGRAM ALIR MODEL RNN

C. Pra – Pemrosesan Data

Sebelum melakukan proses training, harus dilakukan pra – pemrosesan data terlebih dahulu agar model menghasilkan prediksi yang baik dari data latih. Berikut adalah alur pra – pemrosesan data:

1. Membuang format data “Date” dan “Time” yang salah menggunakan library Regular Expression (Regex).
2. Membersihkan data anomali pada kolom “Kwh”, jika terdapat nilai 0 pada Kwh maka nilai tersebut akan di “NaN” kan, jika nilai Kwh hari ini lebih besar dari nilai Kwh di hari setelahnya maka nilai tersebut akan di “NaN” kan, dan jika nilai Kwh di hari setelahnya lebih kecil dari nilai Kwh di hari ini maka nilai tersebut akan di “NaN” kan, setelah semua data anomali di “NaN” kan kemudian data “NaN” tersebut di isi dengan metode *Backward Fill*, yaitu metode yang mengisi nilai “NaN” dengan nilai yang diamati ke data setelahnya hingga nilai “NaN” nya terpenuhi.
3. Menguraikan data pada kolom “Date” dan “Time” menjadi kolom “DateTime”, membuang data pada kolom “Kwh” yang bernilai = 0, dan memotong 10% data awal agar data mulai dari tanggal 1 bulan September tahun 2020. Pemotongan data bertujuan agar proses pelatihan pada model mempunyai pola dalam bentuk bulan (*Month*).
4. Resample data, tujuan resample data yaitu agar data mempunyai rekaman per jam. Proses resample yang pertama mengambil data dengan nilai maksimum diantara jarak 1 jam yang dibagi kedalam waktu per 30 menit. Proses resample yang kedua, dari hasil sebelumnya terdapat 2 data yaitu data Kwh 30 menit pertama dan data Kwh 30 menit sesudahnya, kemudian diambil nilai minimum diantara 2 data pada proses sebelumnya, tujuan dilakukan proses resample sebanyak 2 kali yaitu agar pembagian Kwh per jamnya tidak menghasilkan selisih yang jauh sehingga pada saat proses pelatihan, model bisa beradaptasi terhadap perubahan Kwh dengan selisih yang rendah.
5. Interpolasi data, interpolasi data diterapkan untuk mengisi kekosongan data pada saat proses sesudah resample. Salah satu metode interpolasi yang diterapkan pada tahap pra – pemrosesan data ini yaitu metode interpolasi linier.
6. Mencari selisih data, tujuan mencari selisih pada nilai Kwh yaitu agar data berbentuk stasioner sehingga data bisa digunakan untuk prediksi runtun waktu (*Time Series Prediction*).
7. Mengisi data kosong pada rentang waktu 28 Desember 2021 sampai dengan 24 Januari 2022 dan 24 Maret 2022 sampai dengan 9 April 2022 menggunakan algoritma RNN. Langkah yang dilakukan

untuk mengisi kekosongan pada data bulan Desember - Januari adalah menggunakan data dari tanggal 1 September 2021 – 27 Desember 2021 kemudian dilakukan pra – pemrosesan data dari alur ke 1 hingga ke 6 seperti yang sudah di jelaskan diatas, lalu data tersebut di masukan ke dalam proses pelatihan model yang mencakup pembagian rasio data latih serta data tes (*splitting*), pengelompokkan (*sequencing*), dan model siap melakukan prediksi (*forecasting*). Metode diatas juga diterapkan untuk data kosong pada rentang waktu 24 Maret sampai dengan 9 April 2022, hanya saja data yang digunakan untuk proses pelatihan model dimulai dari tanggal 1 September 2021 – 23 Maret 2022.

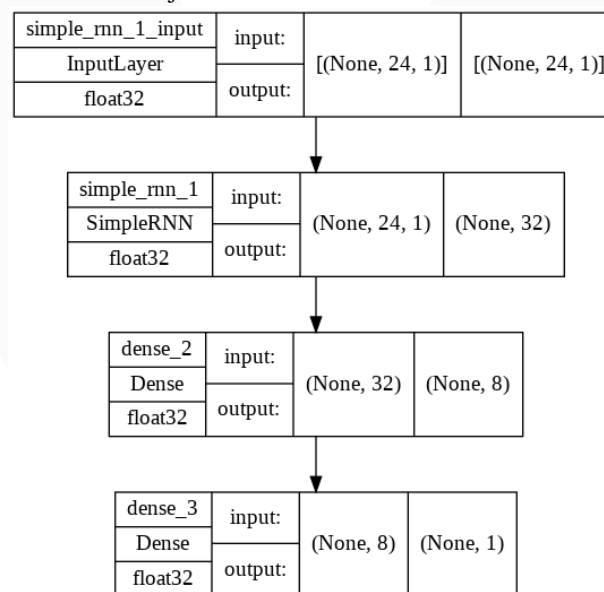
8. Penskalaan data, data yang sudah bersih kemudian dilakukan penskalaan. Penskalaan adalah metode pra – pemrosesan data yang bertujuan untuk mendekatkan titik titik data yang berjauhan, secara umum jika ada suatu data yang memiliki skala terlalu jauh

metode ini akan membuat skala data tersebut menjadi rendah.

9. Pembagian rasio data latih dan data uji bertujuan untuk menentukan seberapa baik algoritma RNN menampung data untuk di latih dan di uji.
10. Pengelompokkan data (*sequencing*), dalam kasus prediksi runtun waktu data harus di kelompokkan sesuai dengan kebutuhannya. Pada penelitian ini data dikelompokkan setiap 24 jam, tujuan pengelompokkan ini agar data yang di latih dalam tahap pemodelan dapat menghasilkan model yang prediktif.

D. Desain Model RNN

Desain dari model *Recurrent Neural Network* yang digunakan pada penelitian ini adalah satu block RNN, 1 dense layer dan satu dense layer yang berfungsi sebagai output layer. Terdapat 24 input yang masuk secara sekuensial kedalam 32 neuron didalam satu block RNN, 8 neuron dalam 1 dense layer dan 1 neuron pada output layer yang menandakan hanya mengeluarkan 1 keluaran dan fungsi aktivasi yang digunakan pada output layer adalah fungsi aktivasi ReLU.



GAMBAR 3. 4
DESAIN MODEL RNN

IV. HASIL DAN PEMBAHASAN

A. Pengujian Rasio Data Latih dan Data Uji

Pembagian data latih dan data uji bertujuan untuk menentukan seberapa baik algoritma RNN menampung data untuk di latih dan di uji. Inisialisasi parameter awal untuk pengujian menggunakan parameter default dari library

Tensorflow untuk *learning rate* sebesar 0,001 dengan jenis algoritma optimasi Adam, 1 *block* RNN dengan jumlah 8 *neuron*, jumlah iterasi 100, dan jumlah *batch size* 100. Berikut hasil pengujian rasio data latih dan uji:

TABEL 4. 1
HASIL PENGUJIAN RASIO DATA

Tra ning	Tes ting	MA E	MSE	RM SE	R2 SCO RE
50%	50 %	0.95 6091	2.75 2308	1.65 9008	0.69 5059
60%	40 %	0.97 3970	1.98 6541	1.40 9447	0.68 5892
70%	30 %	0.79 5903	1.66 5817	1.29 0665	0.75 5996
80%	20 %	0.93 3785	1.52 3958	1.23 4487	0.61 2961
90%	10 %	0.70 0090	1.20 4434	1.09 7467	0.70 1267

Setelah dilakukan pengujian pembagian rasio pada dataset, dapat disimpulkan bahwa penelitian ini menggunakan dataset dengan rasio 90% data latih dan 10% data uji dengan hasil evaluasi MAE 0.700090, MSE 1.204434, RMSE 1.097467, dan R2 Score 0.701267.

B. Pengujian Jumlah RNN Block

Pengujian jumlah *block* algoritma RNN bertujuan untuk mencari penggunaan optimal dari *block* RNN, banyaknya RNN *block* mempengaruhi proses komputasi pada pelatihan model, semakin banyak parameter yang digunakan semakin lama pula proses komputasinya. Berikut hasil pengujian jumlah RNN *block*:

TABEL 4. 2
HASIL PENGUJIAN RNN 1 BLOCK

1 Bl oc k	MA E	MS E	RM SE	R2 SC OR E
8 ne uro n	0.70 009 0	1.20 443 4	1.09 746 7	0.70 126 7
16 ne uro n	0.72 630 7	1.18 150 6	1.08 697 1	0.70 695 4
32 ne uro n	0.68 211 3	1.15 056 4	1.07 264 4	0.71 462 8

Pengujian pertama menguji penggunaan RNN *block* sebanyak 1 *block* dengan jumlah *neuron* yang berbeda-beda di setiap bloknya. Hasil pengujian ini mendapatkan error terkecil menggunakan 1 RNN *block* dengan jumlah 32 *neuron* serta nilai evaluasi MAE 0.682113, MSE 1.150564, RMSE 1.072644, dan R2 Score 0.71462.

Pengujian kedua menguji penggunaan RNN *block* sebanyak 2 *block* dengan jumlah *neuron* yang berbeda-beda di setiap bloknya. Berikut hasilnya:

TABEL 4. 3
HASIL PENGUJIAN RNN 2 BLOCK

2 Bl oc k	MA E	MS E	RM SE	R2 SC OR E
8, 8 ne ur o n	0.7 73 00 2	1.3 35 46 8	1.1 55 62 5	0.6 68 76 7
16, 8 ne ur o n	0.6 53 06 0	1.1 30 12 5	1.0 63 07 4	0.7 19 69 8
16, 1 ne ur o n	0.7 33 85 1	1.2 46 76 7	1.1 16 58 7	0.6 90 76 7
32, 1 ne ur o n	0.6 70 92 1	1.1 71 80 4	1.0 82 49 9	0.7 09 36 0
32, 3 ne ur o n	0.6 89 82 8	1.2 75 49 1	1.1 29 37 6	0.6 83 64 3

Hasil pengujian ini mendapatkan error terkecil menggunakan 2 RNN *block* dengan jumlah 16 *neuron* untuk *block* pertama dan 8 *neuron* untuk *block* kedua serta nilai evaluasi MAE 0.653060, MSE 1.130125, RMSE 1.063074, dan R2 Score 0.719698.

C. Pengujian Jumlah Dense Layer

Pengujian jumlah *dense layer* bertujuan untuk mencari penggunaan optimal dari *dense layer*. Pada tahap ini menguji penggunaan *dense layer* sebanyak 1 *dense layer* diikuti dengan 1 RNN *block* yang sudah di uji pada tahap sebelumnya dan dengan jumlah *neuron* yang berbeda-beda. Berikut hasil pengujiannya:

TABEL 4. 4
HASIL PENGUJIAN DENSE LAYER

1 H i d d e n	MA E	MS E	RM SE	R2 SC OR E
8 n e u r o n	0.62 116 3	1.12 550 5	1.06 089 8	0.72 084 3
16 n e u r o n	0.73 835 5	1.19 060 9	1.09 115 1	0.70 469 6
32 n e u r o n	0.74 107 8	1.24 199 1	1.11 444 6	0.69 195 2

Hasil pengujian jumlah *dense layer* yang diikuti dengan RNN *block* sejumlah 1 *block* dengan jumlah 32 *neuron* didalamnya mendapatkan hasil terbaiknya pada 1 *dense layer* dengan jumlah 8 *neuron* didalamnya serta nilai evaluasi MAE 0.621163, MSE 1.125505, RMSE 1.060898, dan R2 Score 0.720843.

D. Pengujian Learning Rate dan Optimizer

Pengujian *learning rate* dan tipe *optimizer* bertujuan untuk mengatur kecepatan belajar algoritma ditahap pelatihan model. Pada tahap ini juga menguji beberapa tipe algoritma optimasi seperti Adam dan RMSprop dengan *learning rate* yang bervariasi. Berikut hasil pengujian *learning rate* beserta tipe algoritma optimasinya:

TABEL 4. 3
HASIL PENGUJIAN LEARNING RATE

Op ti mi zer	M A E	M S E	R M SE	R2 SC O R E
Ad am 0.0 00 01	0. 83 53 79	1. 46 06 97	1. 20 85 93	0. 63 77 06
Ad am 0.0 00 01	0. 68 82 03	1. 13 17 55	1. 06 38 40	0. 71 92 93
Ad am 0.0 01	0. 62 11 63	1. 12 55 05	1. 06 08 98	0. 72 08 43
R M	0. 73	1. 28	1. 13	0. 68

Op ti mi zer	M A E	M S E	R M SE	R2 SC O R E
Sp ro p 0.0 00 01	55 51	19 47	22 31	20 41
R M Sp ro p 0.0 00 01	0. 74 12 40	1. 23 51 27	1. 11 13 63	0. 69 36 54
R M Sp ro p 0.0 01	0. 65 90 64	1. 11 71 27	1. 05 69 42	0. 72 29 21

Hasil pengujian pada tahap ini menggunakan parameter terbaik yang sudah diuji pada tahap sebelumnya yaitu 1 RNN *block* dengan 32 *neuron* dan 1 *dense layer* dengan 8 *neuron*. Nilai error terkecil didapatkan pada jenis algoritma optimasi Adam dengan *learning rate* sebesar 0,001 serta nilai evaluasi MAE 0.621163, MSE 1.125505, RMSE 1.060898, dan R2 Score 0.720843.

E. Pengujian Epoch

Pengujian *epoch* bertujuan untuk mengatur jumlah iterasi selama proses pelatihan berlangsung. Pada pengujian epoch dilakukan beberapa pengujian dimulai dari 25, 50, 75, 100, 125, 150, 175 dan 200 *epoch*. Berikut hasil pengujian *epoch*:

TABEL 4. 6
HASIL PENGUJIAN EPOCH

Ep oc h	MA E	MS E	RM SE	R2 SC OR E
25	0.65 537 0	1.14 944 1	1.07 212 0	0.71 490 7
50	0.63 526 1	1.13 206 1	1.06 398 4	0.71 921 7
75	0.67 567 7	1.15 458 1	1.07 451 4	0.71 363 2


Epoch	MAE	MSE	RMSE	R2 Score
100	0.621163	1.125505	1.060898	0.720843
125	0.674927	1.210454	1.100206	0.699774
150	0.668159	1.195803	1.093528	0.703408
175	0.665812	1.134001	1.064895	0.718736
200	0.683002	1.158211	1.076202	0.712732

Hasil pengujian pada tahap ini menggunakan parameter terbaik yang sudah diuji pada tahap sebelumnya yaitu 1 RNN block dengan 32 neuron, 1 dense layer dengan 8 neuron dan tipe optimizer Adam dengan learning rate 0.001 mendapatkan hasil terbaiknya pada epoch dengan jumlah 100 iterasi serta nilai evaluasi MAE 0.621163, MSE 1.125505, RMSE 1.060898, dan R2 Score 0.720843.

F. Pengujian Batch Size

Pengujian batch size bertujuan untuk mengatur ukuran data dalam 1 kelompok yang masuk kedalam proses pelatihan model. Pada tahap ini dilakukan beberapa pengujian batch size yang dimulai dari 50, 100, 150 dan 200 batch size. Berikut hasil pengujian batch size:

TABEL 4. 7



GAMBAR 4. 1
GRAFIK PREDIKSI HARIAN 31 MEI 2022

V. KESIMPULAN DAN SARAN

A. Kesimpulan

Algoritma RNN dapat memprediksi penggunaan energi listrik dengan cukup baik, dengan parameter yang digunakan adalah rasio data latih sebesar 90% dan data uji sebesar 10%, 1 block RNN dengan 32 neuron, 1 dense layer dengan 8 neuron, tipe algoritma optimasi adam dengan learning rate 0.001, epoch sebanyak 100 dan batch size sebanyak 100. Menghasilkan nilai untuk tiap metrics evaluasi MAE 0.621, MSE 1.125, RMSE 1.060, R2 Score 72% dan

HASIL PENGUJIAN BATCH SIZE

Batch Size	MAE	MSE	RMSE	R2 Score
50	0.715419	1.185083	1.088615	0.706067
100	0.621163	1.125505	1.060898	0.720843
150	0.700845	1.177985	1.085350	0.707827
200	0.695865	1.248773	1.117485	0.690270

Hasil pengujian pada tahap ini menggunakan parameter terbaik pada pengujian sebelumnya yaitu 1 RNN block dengan 32 neuron, 1 dense layer dengan 8 neuron, tipe optimizer Adam dengan learning rate 0.001, dan 100 epoch. Nilai error terkecil didapatkan pada batch size dengan jumlah 100 serta nilai evaluasi MAE 0.621163, MSE 1.125505, RMSE 1.060898, dan R2 Score 0.720843.

G. Pengujian Parameter Terbaik

Hasil pengujian parameter terbaik yang didapatkan oleh algoritma RNN untuk penelitian ini adalah pembagian rasio data latih dan data uji dengan perbandingan 90:10, 1 block RNN dengan 32 neuron, 1 dense layer dengan 8 neuron, tipe algoritma optimasi adam dengan learning rate 0.001, epoch sebanyak 100 iterasi, dan batch size sebanyak 100, dengan MAPE sebesar 4.71%.

MAPE 14%.

B. Saran

Berdasarkan hasil penelitian dan pengujian yang dilakukan pada tugas akhir ini, maka saran yang dapat diusulkan untuk penelitian selanjutnya yaitu:

1. Melakukan pengecekan terhadap alat pencatat Kwh sehingga data yang diperoleh bisa lebih baik.
2. Memastikan data telah siap digunakan setelah pra pemrosesan data untuk masuk ke tahap pemodelan.

3. Menggunakan varian RNN versi bidirectional untuk mendapatkan hasil yang lebih akurat.

REFERENSI

- [1] e. a. Kuhua Wu, An Attention Based CNN – LSTM – BiLSTM Model for Short Term Electric Load Forecasting in Integrated Energy System, WILEY, 2020.
- [2] M. L. Abdurahman, "A Review on Deep Learning with Focus on Deep Recurrent Neural Network for Electricity Forecasting in Residential Building", 10th International Young Scientists Conference on Computational Science, 2021.
- [3] S. L. A. D. G. K. Hao Tu, "An LSTM Based Online Prediction Method for Building Electric Load during Covid-19", Annual Conference of The Prognostics and Health Management Society, 2020.
- [4] C. H. G. L. W. X. Kangji Li, "Building's Electricity Consumption Prediction using Optimized Artificial Neural Network and Principal Component Analysis", Energy and Buildings, 2015..
- [5] Yi Chung Hu, "Electricity Consumption Prediction using a Neural Network Based Grey Forecasting Approach", Journal of the Operational Research Society, 2017.
- [6] A. M. A. A. S. A. M. R. A. S. N. A. Abdulla I Almazrouee, "Long-Term Forecasting of Electrical Loads in Kuwait using Prophet and Holt-Winters Models", Applied Science, 2020.
- [7] X. W. Z. Z. Q. W. Y. B. M. Z. [7] Zhiyong Zou, "Prediction of Short Term Electric Load Based on Backpropagation Neural Network and ARIMA Combination", 4th Information Technology and Mechatronics Engineering Conference (ITOECE), 2018.
- [8] D. L. M. M. M. Kasun Amarasinghe, "Deep Neural Network for Energy Load Forecasting", IEEE, 2017.
- [9] S. P. H. L. M. P. Muhammad Amri Yahya, "Short Term Electric Load Forecasting using Recurrent Neural Network", 4th International Conference on Science Technology (ICST), 2018.
- [10] J. X. C. L. Y. T. B. Z. C. L. Yun Bai, "Regression Modelling for Enterprise Electricity Consumption : A Comparison of Recurrent Neural Network and its Variants", International Journal of Electrical Power and Energy Systems, 2021.
- [11] M. Imani, "Long-Short Term Memory Network and Support Vector Regression for Electrical Load Forecasting" International Conference on Power Generation Systems and Renewable Energy Technologies, (PGSRET), 2019.
- [12] G. P. Zhang, "Time Series Forecasting using Hybrid ARIMA and Neural Network Model", Neurocomputing, 2003.

