

PERBANDINGAN PREDIKSI PENGGUNAAN LISTRIK DENGAN MENGUNAKAN METODE LONG SHORT TERM MEMORY (LSTM) DAN RECURRENT NEURAL NETWORK (RNN)

Nurfatima Selle*¹, Novanto Yudistira², Candra Dewi³

^{1,2,3} Universitas Brawijaya, Malang

Email: ¹nurfatimaselle@student.ub.ac.id, ²yudistira@ub.ac.id, ³dewi_candra@ub.ac.id

*Penulis Korespondensi

(Naskah masuk: 22 September 2021, diterima untuk diterbitkan: 31 Januari 2022)

Abstrak

Energi listrik telah menjadi salah satu kebutuhan yang sangat penting dan membantu kehidupan manusia di era modern saat ini. Energi listrik yang tidak dapat disimpan dalam waktu yang lama dan harus dapat selalu tersalurkan menyebabkan penyedia energi listrik harus dapat mampu menyediakan energi listrik dengan tepat. Oleh karena itu, diperlukan sebuah sistem yang mampu melakukan prediksi terhadap penggunaan listrik dengan memanfaatkan data historis penggunaan listrik sebelumnya. Sehingga PT. PLN selaku penyedia energi listrik harus dapat mampu menyesuaikan jumlah listrik yang harus disediakan dengan permintaan kebutuhan pelanggan. Penelitian ini menggunakan metode *Recurrent Neural Network (RNN)* dan *Long Short Term Memory (LSTM)* yang merupakan metode pembelajaran *deep learning*. Kedua metode ini mampu mengolah data dan melakukan prediksi dengan format data *time series*. Proses implementasi yang dilakukan yaitu normalisasi data, transformasi data, pembangunan model, training, testing, denormalisasi, dan pengujian hasil prediksi menggunakan *Root Mean Square Error (RMSE)*. Berdasarkan penerapan metode LSTM dan pengujian pada fitur data siang dan malam, didapatkan kondisi terbaik pada penggunaan untuk fitur data siang dengan panjang *sequence* 20, *hidden size* 8, 3 LSTM layer, dan 70% data training menghasilkan rata-rata RMSE 46,72, sedangkan untuk fitur data malam didapatkan panjang *sequence* 30, *hidden size* 8, 1 LSTM layer, dan 80% data training menghasilkan rata-rata RMSE 51,05. Perbandingan antar RNN dan LSTM menghasilkan LSTM mampu menghasilkan kinerja yang lebih baik pada penggunaan deret waktu yang lebih panjang.

Kata kunci: prediksi, penggunaan listrik, LSTM, RNN, time series, RMSE

COMPARISON OF PREDICTING ELECTRICITY CONSUMPTION USING LONG SHORT TERM MEMORY (LSTM) AND RECURRENT NEURAL NETWORK (RNN)

Abstract

Electrical energy has become one of the most important needs and helped human life nowadays. The electrical energy that cannot be stored for a long time and must always be distributed leads to an obligation for electricity providers to provide appropriate electrical energy. Therefore, we need a system that can predict the use of electricity by leveraging historical data on previous electricity usage. It aims that PT. PLN as a provider of electrical energy can able to adjust the amount of electricity that must be provided with the demands of customer needs. Our method uses are *Recurrent Neural Network (RNN)* and *Long Short Term Memory (LSTM)*, which is a *deep learning* architecture that able to capture time-series data. The process of implementing system is data normalization, data transformation, model building, training, testing, denormalization, and testing the prediction results using the *Root Mean Squared Error (RMSE)*. Based on the experiments on day and night data features, the best conditions were obtained at the use for daylight data features with a sequence length of 20, hidden size of 8, 3 LSTM layers, and 70% data training resulted in an average RMSE of 46.72. For the night data feature, the best result was achieved with the sequence length of 30, hidden size of 8, 1 LSTM layer, and 80% of training data resulting in an average RMSE of 51.05. Comparison between RNNs and LSTM shows LSTM capable of producing better performance when the longer time series is incorporated.

Keywords: prediction, electricity consumption, LSTM, RNN, time series, RMSE

1. PENDAHULUAN

Energi listrik telah menjadi salah satu kebutuhan yang sangat penting dan dibutuhkan bagi kehidupan manusia di era modern sekarang ini. Dapat dikatakan energi listrik adalah salah satu sumber energi utama dalam setiap aktivitas yang dilakukan oleh manusia menjadi lebih praktis dan mudah. Perkembangan teknologi yang kian pesat sehingga ketergantungan manusia terhadap energi listrik semakin tinggi yang menjadikan energi listrik menjadi salah satu kebutuhan pokok.

Berdasarkan RUPTL PLN tahun 2019 penjualan tenaga listrik pada 5 tahun terakhir (2013-2017) mengalami peningkatan dengan rata-rata 5,1% per tahun dengan penjualan terbanyak terjadi pada sektor rumah tangga. Pada wilayah Sulawesi penjualan tenaga listrik 5 tahun terakhir (2013-2017) meningkat dengan rata-rata 9,0% per tahun. Serta jumlah populasi manusia yang terus meningkat merupakan salah satu penyebab peningkatan jumlah pelanggan dan permintaan akan kebutuhan energi listrik. Realisasi peningkatan jumlah pelanggan menurut (RUTPL PLN, 2019) pada 2011-2017 mulai dari 45,6 juta menjadi 67,6 juta atau meningkat rata-rata 3,7 juta setiap tahun.

Pada negara-negara maju seperti Indonesia, kebutuhan listrik dari waktu ke waktu akan terus mengalami peningkatan karena kebutuhan energi listrik yang bersifat acak dan dinamis, sehingga PT PLN (Penyedia Listrik Negara) selaku penyedia dan penyalur tenaga energi listrik harus memiliki sebuah perencanaan yang tepat dan efektif dalam mempersiapkan ketersediaan energi listrik sesuai dengan dinamika kebutuhan konsumen. (Rajagukguk, et al., 2015)

Kerugian akibat perencanaan yang kurang tepat dapat menyebabkan energi listrik yang didistribusikan tidak mencukupi untuk memenuhi kebutuhan beban sehingga berdampak pada pemadaman listrik yang merugikan pihak konsumen dan sebaliknya (Fadillah, et al., 2015). Perencanaan yang dapat dilakukan adalah dengan melakukan sebuah prediksi terhadap penggunaan konsumsi daya listrik di masa yang akan datang. Ketersediaan akan informasi di masa lalu berupa data *time series* penggunaan energi listrik dapat digunakan untuk melakukan sebuah pendekatan dalam membangun model sistem prediksi konsumsi listrik.

Prediksi konsentrasi pencemaran udara menggunakan LSTM menghasilkan nilai MAPE 15,84% dan LSTM 11,93 yang dilakukan oleh (Li, et al., 2017). Prediksi kualitas air dengan data *time series* oleh (Wang, et al., 2017) menghasilkan nilai RMSE terbaik sebesar 0,049 dan 0,065 dengan metode LSTM pada penggunaan *time step* yang lebih panjang. Prediksi yang dilakukan oleh (Aldi, et al., 2018) dalam melakukan prediksi harga *bitcoin*

mendapatkan akurasi data latih 95,36% dan data uji 93,5%.

Penelitian-penelitian tersebut menunjukkan metode LSTM mampu melakukan prediksi dengan data *time series* dengan deret waktu yang panjang. Sehingga penelitian ini akan melakukan prediksi penggunaan listrik dengan metode LSTM dengan merumuskan permasalahan yaitu bagaimana hasil dan tingkat akurasi yang didapatkan pada penerapan metode LSTM, serta berapa panjang *sequence input time series* yang optimal dalam melakukan prediksi tersebut.

2. METODE PENELITIAN

2.1 Data Penelitian

Penelitian yang akan dilakukan dengan menggunakan dataset sekunder yang berasal dari PT. Brilyan Trimatra Utama. Dataset tersebut terdiri atas data siang dan data malam penggunaan listrik (kWh) harian Sulawesi Selatan mulai dari Januari 2016 – Februari 2020, sebanyak 1623 data. Sampel dataset yang digunakan dapat dilihat pada Tabel 1.

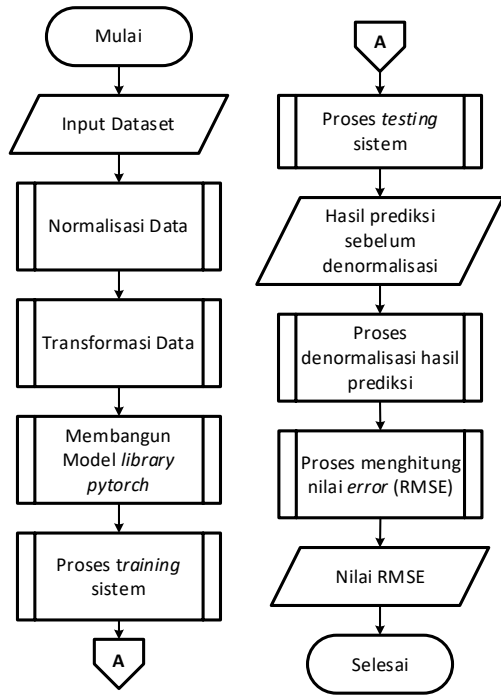
Tabel 1. Dataset Penggunaan Listrik

Tanggal	Data Siang	Data Malam
01/01/2016	631,1	821
02/01/2016	652,4	854,2
03/01/2016	643,7	858,3
04/01/2016	717,7	858,3
...
06/02/2020	1044,17	1230,14

2.2 Perancangan Algoritma

Penelitian ini akan dilakukan beberapa tahapan, yaitu data *preparation* yang terdiri atas normalisasi data menggunakan metode MinMax pada Persamaan 7 dan transformasi data untuk mengubah bentuk data ke bentuk *sequence-sequence* yang lebih kecil, membangun model LSTM, *training*, *testing*, dan pengujian. Tahapan tersebut digambarkan secara sistematis pada diagram alir Gambar 1.

Data masukan berupa data historis harian penggunaan listrik di siang dan malam kemudian dilakukan pengolahan data yaitu normalisasi data, transformasi data, dan inisialisasi data training dan data testing. Selanjutnya yaitu membangun model LSTM, dilanjutkan dengan melakukan training dan testing menggunakan data hasil pengolahan data sebelumnya. Hasil prediksi yang didapatkan pada proses testing selanjutnya di denormalisasi untuk mendapatkan nilai prediksi sebelumnya. Hasil prediksi tersebut kemudian dilakukan pengujian dengan menghitung nilai eror terhadap data aktual menggunakan RMSE




Gambar 1. Diagram Alir Penelitian

3. DASAR TEORI


3.1 Long Short Term Memory (LSTM)

Long Short Term Memory (LSTM) merupakan sebuah evolusi dari arsitektur RNN yang diperkenalkan oleh Hochreiter & Schmidhuber (1997). Recurrent Neural Network (RNN) adalah jenis arsitektur jaringan saraf berulang yang didesain khusus untuk dapat mengatasi permasalahan dengan data berurutan (*sequence data*) (Wiranda & Sadikin, 2019). Jaringan ini adalah yang menggunakan masukan berupa data berurutan atau *sequence of items* dan akan menghasilkan sebuah vektor yang merangkum urutan tersebut.



Gambar 2. Arsitektur Jaringan RNN (De, 2018)

Pada Gambar 2 menjelaskan arsitektur dari RNN yang terdiri atas *input layer*, *hidden layer* dan *output layer*. Pada RNN masih terdapat sebuah masalah *vanishing gradient* seiring bertambah panjang data berurut yang ingin di *training*. Perbedaan yang terletak pada bagaimana proses komputasi pada *hidden layer* atau yang disebut isi *memory cell*.



Gambar 3. Struktur Memory Cell LSTM (Ryan, 2017)

Gambar 3 memperlihatkan struktur dan alur dari *memory cell* LSTM yang memiliki fungsi sama dengan neuron pada pembelajaran jaringan saraf tiruan lainnya. Pada LSTM memiliki *memory cell* dan *gates unit* yang berfungsi untuk mengatur setiap memori pada neuron. Terdapat empat proses dalam *cell* dengan fungsi aktivasi sigmoid atau tanh untuk setiap *inputan* pada neuron yang disebut *gates unit*. *Gates units* tersebut yaitu *input gate*, *forget gate*, dan *output gate*. C_t atau *cell gate* yang berfungsi untuk mengganti nilai pada *memory cell* dengan nilai yang baru.

Tahapan-tahapan pada proses penerapan metode LSTM adalah sebagai berikut:

Forget gate (f_t), berperan untuk menentukan apakah informasi dari setiap data masukan diolah dan dipilih data yang mana yang akan disimpan atau dibuang pada *memory cell* (Aldi, et al., 2018). Persamaan yang digunakan menggunakan fungsi aktivasi sigmoid, sebagai berikut:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

Keterangan:

f_t = *forget gate*

σ = fungsi aktivasi *sigmoid*

W_f = bobot *forget gate*

h_{t-1} = nilai *hidden state cell* sebelum

x_t = nilai *input*

b_f = bias *foget gate*

Input gate (i_t), memiliki fungsi untuk mengambil nilai *output* sebelumnya (h_{t-1}) dan *input* baru (x_t). Persamaan pada *gate* ini menggunakan dua fungsi aktivasi, yaitu fungsi aktivasi *sigmoid* yang akan menentukan nilai mana yang akan diperbarui dan fungsi aktivasi *tanh* yang akan membuat vektor nilai untuk disimpan pada *memory cell* sebagai nilai yang baru (Aldi, et al., 2018). Persamaan yang digunakan sebagai berikut:

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

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

Keterangan:

i_t = *input gate*

W_i = bobot *input gate*

b_i = bias *input gate*

\tilde{C}_t = *candidate gate*

Tanh = fungsi aktivasi tanh

W_c = bobot *candidate gate*

b_c = bias *candidate gate*

Cell state (c_t), berfungsi untuk menggantikan nilai pada *memory cell* sebelumnya dengan nilai *memory cell* yang baru dengan melakukan operasi terhadap hasil pada *gate unit* sebelumnya (Aldi, et al., 2018). Persamaan yang digunakan sebagai berikut:

$$c_t = (i_t * \tilde{C}_t + f_t * c_{t-1}) \quad (4)$$

Keterangan:

c_t = *cell gate*

i_t = *input gate*

\tilde{C}_t = *candidate gate*

f_t = *forget gate*

c_{t-1} = nilai *cell state* sebelum

Output gate (o_t), berperan untuk menentukan nilai pada bagian *memory cell* mana yang akan dikeluarkan dengan menggunakan fungsi aktivasi *sigmoid*. Nilai pada *memory cell* ditempatkan dengan menggunakan fungsi aktivasi *tanh*. Terakhir kedua *gates* tersebut dikalikan sehingga menghasilkan nilai yang akan dikeluarkan (h_t) (Aldi, et al., 2018). Persamaan yang digunakan sebagai berikut:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(c_t) \quad (6)$$

Keterangan:

o_t = *output gate*

W_o = bobot *output gate*

b_o = bias *output gate*

h_t = *hidden state*

c_t = *cell gate*

3.2 Min-Max Normalization

Normalisasi data adalah proses transformasi nilai suatu data dalam rentang nilai tertentu. salah satu metode yang dapat digunakan untuk melakukan normalisasi data adalah *Min-Max Normalization*.

Min-Max Normalization adalah metode normalisasi sederhana yang melakukan transformasi linear terhadap data aktual sehingga dapat menghasilkan keseimbangan nilai antara data sebelum dan sesudah diproses (Nasution, et al., 2019). Persamaan yang digunakan sebagai berikut:

$$d' = \frac{d - \min}{\max - \min} \quad (7)$$

Keterangan:

d' = hasil transformasi suatu nilai

d = nilai data aktual yang akan dinormalisasi

\min = nilai terkecil pada data set fitur X

\max = nilai terbesar pada data set fitur X

3.3 Denormalisasi

Proses denormalisasi adalah proses membangkitkan kembali nilai yang telah dinormalisasi ke bentuk nilai aktual. Proses denormalisasi dilakukan dengan menggunakan persamaan sebagai berikut:

$$d = d'(\max - \min) + \min \quad (8)$$

Keterangan:

d' = nilai hasil prediksi yang dinormalisasi

d = nilai asli setelah di denormalisasi

\min = nilai terkecil pada data set fitur X

\max = nilai terbesar pada data set fitur X

3.4 Root Mean Squared Error (RMSE)

Root Mean Squared Error (RMSE) merupakan suatu parameter yang dapat digunakan dalam sebuah peramalan untuk menguji keakuratan hasil peramalan yang dilakukan. Semakin kecil nilai RMSE yang dihasilkan, maka semakin akurat hasil peramalan yang dilakukan (Gofur & Widiyanti, 2013). Persamaan RMSE yang digunakan adalah sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^l (y_i - \bar{y}_i)^2} \quad (9)$$

Keterangan:

n = banyaknya data

$i = (1, 2, 3, \dots, l)$, l merupakan keseluruhan data

y_i = nilai aktual

\bar{y}_i = nilai hasil prediksi


4. HASIL DAN PEMBAHASA

Pengujian yang dilakukan pada penelitian ini yaitu pengujian terhadap *hyperparameter* yang digunakan dalam arsitektur LSTM dan bersifat sekuensial. Setiap kondisi terbaik yang didapatkan akan digunakan pada pengujian selanjutnya.

Pengujian *hyperparameter* yang dilakukan, yaitu panjang *sequence* data *timeseries*, jumlah neuron pada *hidden layer*, perbandingan jumlah data *training* dan data *testing*, dan jumlah LSTM *layer* yang digunakan pada proses *training*. Hasil akhir dari penggunaan metode LSTM dilakukan perbandingan terhadap metode RNN terhadap nilai RMSE.

4.1 Pengujian Panjang Sequence Input

Hasil pengujian terhadap jumlah neuron pada *hidden layer* hasil prediksi data siang dan data malam digambarkan pada grafik Gambar 4.


Gambar 4. Grafik Hasil Pengujian Panjang *Sequence Input*

Berdasarkan grafik pada Gambar 4, kondisi terbaik dengan nilai rata-rata RMSE didapatkan pada penggunaan panjang 20 dan 30 *sequence*, fitur data siang menghasilkan 49,33 pada penggunaan panjang 20 *sequence*, dan untuk fitur data malam menghasilkan 57,90 pada penggunaan panjang 30 *sequence*. Sedangkan pada pengujian dengan panjang *sequence* yang lebih pendek cenderung menghasilkan kinerja yang kurang baik dengan nilai RMSE yang tinggi. Hal tersebut sesuai dengan tujuan dari metode LSTM yang mampu mengatasi masalah ada metode RNN pada penggunaan deret waktu yang lebih panjang (Li, et al., 2017).

Penentuan jumlah *sequence* yang digunakan dalam membangun sistem tidak memiliki aturan yang pasti, sehingga perlu dilakukan beberapa varian percobaan untuk mendapatkan kondisi yang terbaik.

4.2 Pengujian Jumlah Neuron pada *Hidden Layer*

Hasil pengujian terhadap jumlah neuron pada *hidden layer* hasil prediksi data siang dan data malam digambarkan pada grafik Gambar 5.

Gambar 5. Grafik Hasil Pengujian Jumlah Neuron pada *Hidden layer*

Berdasarkan grafik pada Gambar 5, kondisi terbaik didapatkan pada penggunaan jumlah neuron pada *hidden layer* sebanyak 8 dengan rata-rata RMSE untuk fitur data siang sebesar 47,98 dan fitur data malam 49,87.


Penentuan jumlah neuron pada *hidden layer* tidak memiliki aturan yang pasti (Aldi, et al., 2018), sehingga perlu dilakukan beberapa varian untuk mendapatkan jumlah yang tepat untuk hasil yang optimal. Penggunaan jumlah neuron pada *hidden*

layer yang melebihi dari yang dibutuhkan oleh sebuah jaringan dapat menyebabkan *overfitting* sehingga dapat menghasilkan nilai eror yang tinggi (Panchal, 2014 disitasi dalam Utami, 2020).

Menurut (Keim, 2020) untuk menemukan dimensi yang optimal pada *hidden layer* dan menghindari terlalu banyak neuron atau node yang tidak diinginkan, sehingga diperlukan jumlah yang optimal yang mampu menangkap kompleksitas hubungan antara *input-output* dengan cara melakukan uji coba beberapa varian.

4.3 Pengujian Perbandingan Jumlah Data *Training* dan *Testing*

Hasil pengujian terhadap perbandingan jumlah data *training* dan data *testing* hasil prediksi data siang dan data malam digambarkan pada grafik Gambar 6. Jumlah keseluruhan data yang digunakan pada dataset adalah 1623 *record* data.

Gambar 6. Grafik Hasil Pengujian Perbandingan Data *Training* dan *Testing*

Berdasarkan grafik pada Gambar 6, kondisi terbaik didapatkan pada penggunaan 70%-80% data *training* dari seluruh total dataset. Rata-rata RMSE yang didapatkan untuk fitur siang sebesar 47,02 dan fitur data malam sebesar 51,05.


Hal tersebut membuktikan penggunaan jumlah data *training* yang lebih banyak dibandingkan dengan data *testing* mampu menghasilkan kinerja yang lebih baik.

4.4 Pengujian Jumlah *Layer*

Hasil pengujian terhadap jumlah LSTM *layer* hasil prediksi data siang dan data malam digambarkan pada grafik Gambar 7.

Berdasarkan grafik pada Gambar 7, rata-rata RMSE terendah untuk kedua fitur data mendapatkan kondisi yang berbeda. fitur data siang menghasilkan kondisi terbaik pada penggunaan 3 *layer* dengan rata-rata RMSE sebesar 46,72, sedangkan fitur data malam mendapatkan kondisi terbaik pada penggunaan 1 *layer* dengan rata-rata RMSE sebesar 51,05. Sehingga dapat disimpulkan, jumlah LSTM *layer* yang digunakan pada sebuah arsitektur

jaringan yang dibangun dapat memberikan pengaruh yang signifikan.




Gambar 7. Grafik Hasil Pengujian Jumlah Layer

Penentuan jumlah *layer* pada sebuah arsitektur tidak memiliki aturan yang pasti, sehingga diperlukan beberapa varian percobaan untuk mendapatkan kinerja terbaik. Penggunaan *layer* yang berlebihan dapat menyebabkan *overfitting*, sehingga menghasilkan nilai eror yang tinggi, sedangkan penggunaan *layer* yang terlalu sedikit dapat menyebabkan *underfitting* yang menyebabkan proses *training* belum mampu mengenali pola pembelajaran yang menghasilkan nilai eror yang tinggi (Gnana Sheela, et al, 2013 disitasi dalam Ashar, 2018).

4.5 Perbandingan RNN dan LSTM

LSTM adalah metode improvisasi dari metode RNN yang mampu mengatasi masalah yang terdapat pada RNN. Tidak seperti RNN, LSTM memiliki *memory cell* yang spesial pada *hidden layer*. Setiap *memory cell* memiliki *input gate* yang berfungsi untuk mengatur *memory cell* dari masukan yang tidak relevan, *output gate* mampu untuk melindungi unit lain dari informasi yang tidak relevan yang akan disimpan, dan *forget gate* mampu mengontrol sejauh mana suatu nilai akan disimpan di *memory cell* (Salmana, et al., 2018).


Perbandingan yang dilakukan dengan menggunakan *single layer* RNN/LSTM terhadap beberapa varian panjang *sequence* yang akan menjadi *input* pada sistem, yaitu 5, 20, dan 30. Pengujian juga dilakukan dengan menggunakan konfigurasi parameter terbaik dari hasil pengujian sebelumnya, yaitu menggunakan *hidden size* 8, dan perbandingan data training dan data testing adalah 70%:30%. Hasil perbandingan dapat dilihat pada diagram Gambar 8.




Gambar 8. Diagram Hasil Perbandingan RNN dan LSTM

Berdasarkan diagram pada Gambar 8 yang menunjukkan hasil perbandingan kinerja antara RNN dan LSTM terhadap hasil prediksi penggunaan listrik yaitu dengan melakukan perbandingan terhadap jumlah panjang *sequence* atau panjang deret waktu yang digunakan sebagai *input* sistem. Hasil tersebut menunjukkan bahwa LSTM mampu menghasilkan kinerja yang lebih baik dari pada RNN dengan deret waktu yang lebih panjang, yaitu 20 dan 30 *sequence* dengan menghasilkan nilai RMSE yang lebih rendah sebesar 49,18 dan 49,47 untuk fitur data siang dan 58,68 dan 57,08 untuk fitur data malam. Sedangkan pada penggunaan deret waktu yang lebih pendek, yaitu 5 *sequence* RNN dan LSTM menghasilkan perbedaan yang tidak terlalu signifikan.

Menurut (Gers, et al., 2000) LSTM yang mampu mengungguli RNN memiliki '*forget gate*' yang memungkinkan LSTM untuk dapat mengatur ulang memori blok yang harus dilupakan atau dipertahankan untuk diteruskan ke *output gate* pada *memory cell*.



Gambar 9. Grafik Hasil Prediksi Penggunaan Listrik (Dataset Malam)



Gambar 10. Grafik Hasil Prediksi Penggunaan Listrik (Dataset Siang)

5. KESIMPULAN

Berdasarkan pengujian dan analisis yang dilakukan dalam penerapan metode LSTM untuk melakukan prediksi penggunaan listrik, sehingga didapatkan kesimpulan:

1. Panjang *sequence time series* prediksi pengujian dengan rata-rata RMSE terbaik pada penggunaan panjang *sequence* 20 -30 *sequence*.
2. Jumlah neuron pada *hidden layer* yang digunakan menghasilkan rata-rata RMSE terbaik pada penggunaan 8 neuron.
3. Perbandingan jumlah data *training* dan data *testing* didapatkan kondisi terbaik pada penggunaan 70% - 80% data *training* dan 20%-30% data *testing*.
4. Pengujian terhadap jumlah LSTM *layer* yang digunakan kondisi terbaik yang didapatkan adalah pada penggunaan 1-3 *layer*.
5. Hasil perbandingan yang didapatkan antara RNN dan LSTM, menyimpulkan bahwa LSTM memiliki kinerja yang lebih baik dan mampu menurunkan nilai eror pada penggunaan deret waktu yang lebih panjang dalam melakukan prediksi.

DAFTAR PUSTAKA

- ALDI, M. W. P., JONDRI & ADITSANIA, A., 2018. Analisis dan Implementasi Long Short Term Memory Neural Network untuk Prediksi Bitcoin. *e-Proceeding of Engineering Fakultas Informatika, Universitas Telkom, Bandung*.
- DE, D., 2018. *RNN or Recurrent Neural Network for Noobs*. [Online] Available at: <<https://medium.com/hackernoon/rnn-or-recurrent-neural-network-for-noobs-a9afbb00e860>> [Accessed 19 March 2021].
- FADILLAH, M. B., SUKMA, D. Y. & NURHALIM, 2015. Analisis Prakiraan Kebutuhan Energi Listrik Tahun 2015-2024 Wilayah Pln Kota Pekanbaru Dengan Metode Gabungan. *Jom FTEKNIK*, pp. 1-2.
- GERSE, F. A., SCHMIDHUBER, J. U. & CUMMINS, F., 2000. Learning to Forget: Continual Prediction with LSTM. *IDSIA, 12(Neural Computation)*, pp. 1-21.
- GOFUR, A. A. & WIDIANTI, U. D., 2013. Sistem Peramalan Untuk Pengadaan Material Unit Injection Di Pt. Xyz. *Jurnal Ilmiah Komputer dan Informatika (KOMPUTA)*.
- KEIM, R., 2020. *How Many Hidden Layers and Hidden Nodes Does a Neural Network Need?*, s.l.: All About Circuits.
- LI, X. ET AL., 2017. Long short-term memory neural network for air pollutant concentration predictions: Method development and evaluation. *Institute of Remote Sensing and Digital Earth, Chinese Academy of Sciences*.
- NASUTION, D. A., KHOTIMAH, H. H. & CHAMIDAH, N., 2019. Perbandingan Normalisasi Data Untuk Klasifikasi Wine Menggunakan Algoritma K-Nn. *CESS (Journal of Computer Engineering System and Science)*, p. 78.
- RAJAGUKGUK, A. S. F., IR. MARTHINUS PAKIDING, M. & DR.ENG MEITA RUMBAYAN, S. M., 2015. Kajian Perencanaan Kebutuhan dan Pemenuhan Energi Listrik di Kota Manado. *E-journal Teknik Elektro dan Komputer*, pp. 1-12.
- RYAN, M., 2017. *Pengenalan LSTM (Long Short Term Memory)*. s.l., academia.edu.
- SALMANA, A. G., HERIYADIB, Y., ABDURAHMANB, E. & SUPARTAC, W., 2018. Single Layer & Multi-layer Long Short-Term Memory (LSTM) Model with Intermediate Variables for Weather Forecasting. *International Conference on Computer Science and Computational Intelligence 2018*, pp. 1-10.
- WANG, Y. ET AL., 2017. Water Quality Prediction Method Based on LSTM Neural Network. *International Conference on Intelligent Systems and Knowledge Engineering (ISKE)*.
- WIRANDA, L. & SADIKIN, M., 2019. Penerapan Long Short Term Memory Pada Data Time Series Untuk Memprediksi Penjualan Produk PT. Metiska Farma. *Jurusan Teknik Informatika, Fakultas Ilmu Komputer*.

Halaman ini sengaja dikosongkan