

Perbandingan Metode-Metode Deep Learning Dalam Prediksi Konsumsi Daya Listrik Rumah Jangka Pendek

Panca Wardana^{1*}, Novalio Daratha², M.Khairul Amri Rosa³

¹²³ Teknik Elektro Universitas Bengkulu, *E-mail: pancawardana24@gmail.com

ABSTRAK

Konsumsi tenaga listrik terus meningkat setiap harinya, seiring dengan kemajuan teknologi, peningkatan penggunaan mesin yang bergantung pada listrik dan pertumbuhan populasi manusia. Prediksi konsumsi daya listrik sulit dilakukan karena berbagai hal seperti kondisi cuaca dan perilaku dinamis warga. Maka untuk mengatasi hal tersebut, digunakan metode deep learning yaitu CNN (convolutional neural network), LSTM (long-short term memory), BDLSTM (bi-directional long short term memory), CNN-LSTM dan CNN-M-BDLSTM dengan tiga tahap. Tahap pertama adalah memperbaiki nilai yang hilang. Tahap kedua melakukan pengolahan data dan membangun model dari metode deep learning. Tahap ketiga mengevaluasi hasil prediksi dengan metrik kesalahan. Dari hasil analisis, metode CNN menghasilkan loss dan training time terkecil sebesar 0,0010 9/step ms, metode LSTM dan CNN-LSTM menghasilkan loss terbesar sebesar 0,0019 sedangkan training time terlama adalah 139/step ms pada metode BDLSTM. Metode Nilai MSE, MAE, dan MAPE terbesar masing-masing adalah 0,150, 0,258 dan 0,176 hasil metode CNN. Nilai MSE dan MAE terkecil adalah 0,082 dan 0,174 hasil metode BDLSTM. Sedangkan nilai MAPE terkecil yang diperoleh dengan metode CNN-M-BDLSTM adalah 0,148. Hal ini membuktikan bahwa kemampuan memprediksi konsumsi daya listrik jangka pendek menggunakan metode deep learning memiliki kemampuan yang baik dalam hal hasil error metric. Kata kunci: Deep Learning, Error Metrics, Power Consumption.

ABSTRACT

The consumption of electrical power continues to increase every day, along with technological advances, the increase in the use of machines that depend on electricity and the growth of the human population. Prediction of electric power consumption is difficult due to various things such as weather conditions and dynamic behavior of residents. So to overcome this, deep learning methods are used, namely CNN (convolutional neural network), LSTM (long-short term memory), BDLSTM (bi-directional long short term memory), CNN-LSTM and CNN-M-BDLSTM with three stages. The first stage is fixing the missing value. The second stage performs data processing and building model from deep learning methods. The third stage evaluates the prediction results with error metrics. From the results of the analysis, the CNN

method produces the smallest loss and training time of 0.0010 9/step ms, the LSTM and CNN-LSTM methods produce the largest loss of 0.0019 while the longest training time is 139/step ms in the BDLSTM method. Method The largest MSE, MAE, and MAPE values are 0.150, 0.258 and 0.176 respectively the results of the CNN method. The smallest MSE and MAE values are 0.082 and 0.174 the results of the BDLSTM method. While the smallest MAPE value obtained by the CNN-M-BDLSTM method is 0.148. This proves that the ability to predict short-term electric power consumption using the deep learning method has a good ability in terms of the error metric results.

Key Words: Deep Learning, Error Metrics, Power Consumption.

1. PENDAHULUAN

Pada saat ini kebutuhan akan energi listrik tumbuh pesat diiringi dengan meningkatnya jumlah penduduk di dunia. Ketersediaan sumber energi listrik berbanding terbalik dengan kebutuhan energi listrik yang diinginkan. Sedangkan, energi listrik saat ini mempunyai peranan yang sangat penting untuk kehidupan manusia. Energi listrik merupakan pendukung bagi kegiatan ekonomi dan dipakai sebagai alat untuk mencapai tujuan sosial, ekonomi, dan lingkungan [1]. Peralatan rumah tangga juga merupakan salah satu penyumbang terbesar untuk konsumsi energi listrik yang seringkali digunakan secara tidak benar karena kesalahan pengelolaan dan menyebabkan sejumlah besar energi terbuang percuma setiap tahunnya. Untuk mengurangi pemborosan energi ini perlunya dilakukan manajemen untuk digunakan di masa mendatang dengan prediksi konsumsi yang efisien. Dalam memmanajementi energi dapat menggunakan beberapa algoritma untuk memprediksi permintaan selama beberapa tahun, bulan, minggu, hari dan jam kedepan guna mengetahui jumlah energi yang dibutuhkan [2]. Berbagai metode telah dikembangkan oleh para peneliti untuk meningkatkan kualitas jaringan listrik dan mengoptimalkan penggunaan energi seperti Kim dan Cho [3] menggunakan pendekatan *hybrid* yang menggabungkan CNN (*convolutional neural network*) dengan LSTM (*long-short term memory*) untuk ECP (*energy consumption prediction*) jangka pendek. Begitu pula Li dkk [4] mengembangkan algoritma *evolutioner* disebut TLBO (*teaching-learning-based optimisation*) untuk memprediksi konsumsi energi residensial jangka

pendek. Berdasarkan latar belakang tersebut, peneliti melakukan perbandingan metode-metode deep learning dalam prediksi konsumsi daya listrik rumah jangka pendek. Serta menggunakan software anaconda : jupyter notebook dengan bahasa pemrograman python dalam pengolahan data.

2. LANDASAN TEORI

A. Prediksi

Prediksi pada dasarnya merupakan dugaan atau prediksi mengenai terjadinya suatu kejadian atau peristiwa di waktu yang akan datang. Prediksi bisa bersifat kualitatif (tidak berbentuk angka) maupun kuantitatif (berbentuk angka). Prediksi berfungsi untuk membuat suatu rencana kebutuhan (demand) yang harus dibuat dan dinyatakan dalam kuantitas (jumlah) sebagai fungsi dari waktu. Prediksi berkaitan dengan pernyataan: *what will be demanded, how many, dan when it should be supplied*. Prediksi sangat diperlukan dengan melakukan perbandingan antara kebutuhan yang diramalkan dengan yang sebenarnya [5].

B. Jenis-Jenis Metode Prediksi

Ada beberapa metode yang biasa digunakan untuk melakukan prediksi, tergantung pada jenis prediksi yang akan dilakukan. Beberapa metode antara lain :

1. Metode Deret Waktu (*Time Series*) [6]

Metode *time-series* dibagi menjadi beberapa metode yaitu :

- a. Metode Pemulusan (*Smoothing Methods*)
- b. Metode Dekomposisi (*Decomposition Methods*)
- c. Metode Box-Jenkins (ARIMA)

2. Metode Kausal (Sebab – Akibat) [7]

Metode ini terbagi menjadi :

- a. Metode Regresi dan Korelasi,
- b. Model Input Output
- c. Model Ekonometrik

3. Program yang Bisa Digunakan untuk Prediksi

Prediksi tidak harus menggunakan metode yang khusus dirancang untuk melakukan prediksi. Beberapa program yang canggih juga dapat digunakan untuk prediksi karena kemampuannya dalam membaca pola melalui proses pembelajaran. Program yang dapat digunakan untuk prediksi antara lain :

- a. Logika Fuzzy
- b. Jaringan Syaraf Tiruan (Neural Network)

Prediksi kebutuhan daya listrik dapat dikelompokkan menurut jangka waktunya menjadi tiga kelompok, yaitu :

1. Prediksi Jangka Pendek

Prakiraan jangka pendek untuk jangka waktu beberapa jam sampai satu minggu (168 jam).

2. Prediksi Jangka Menengah

Prakiraan beban listrik jangka menengah merupakan satu bulan sampai dengan satu tahun. Pada jangka waktu ini, masalah makro ekonomis merupakan masalah

ekstern perusahaan listrik yang merupakan faktor utama menentukan perkiraan beban listrik [8]. Prediksi jangka menengah merupakan prediksi untuk jangka waktu dari satu bulan sampai dengan satu tahun.

3. Prediksi Jangka Panjang

Prediksi jangka panjang merupakan prediksi untuk jangka waktu diatas satu tahun [5].

C. Energi Listrik

Listrik merupakan salah satu sumber energi utama yang digunakan hampir pada seluruh aspek kehidupan. Kebutuhan energi listrik semakin berkembang seiring kemajuan pembangunan di bidang teknologi, industri, dan informasi. Energi listrik adalah energi yang berkaitan dengan akumulasi arus elektron, dinyatakan dalam watt-jam atau kilowatt-jam. Energi listrik adalah energi akhir yang dibutuhkan peralatan listrik untuk menggerakkan motor, lampu penerangan, pemanas, pendingin ruangan, ataupun untuk menggerakkan kembali suatu peralatan mekanik untuk menghasilkan energi lain [9].

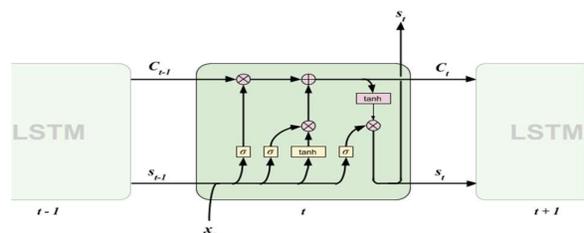
D. Convolutional Neural Network (CNN)

Arsitektur CNN sangat sederhana terdiri atas satu lapisan masukan (*input layer*), suatu lapisan keluaran (*output layer*), dan sejumlah lapisan tersembunyi (*hidden layer*). Lapisan tersembunyi umumnya berisi *convolutional layers, pooling layers, normalization layers, ReLU layer, dan fully connected layers*. Semua lapisan ini tersusun secara bertumpuk-tumpuk, seperti sepotong *sandwich* yang berisi roti bagian bawah, sayuran, daging, keju, saus tomat, mayones, saus sambal dan roti bagian atas [10].

E. Long Short-Term Memory (LSTM)

Adapun proses dari LSTM dapat dijelaskan dalam beberapa langkah sebagai berikut yaitu langkah pertama, menentukan informasi yang akan dibuang dari C_{t-1} menggunakan fungsi sigmoid yang disebut sebagai *forget gate*. Gerbang ini menerima nilai s_{t-1} dan x_t yang disambungkan, dan menghasilkan nilai antara nol dan satu. Hasil ini dikalikan dengan *cell state* C_{t-1} menggunakan *hadamard product*. Nilai nol menandakan bahwa informasi akan dibuang sedangkan satu berarti informasi diteruskan. Formulasinya sebagai berikut.

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



Gambar 1 *Cell* LSTM dengan 4 Lapis Fungsi Aktivasi [11].

Langkah berikutnya adalah menentukan informasi yang akan ditambahkan ke C_t . Langkah ini memproses hasil penggabungan dari s_{t-1} dan x_t menggunakan dua fungsi, yaitu fungsi sigmoid sebagai *input gate* dan fungsi tanh sebagai *intermediate gate*. Hasil dari kedua fungsi tersebut dikalikan untuk mendapatkan informasi yang akan ditambahkan pada C_t .

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

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

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

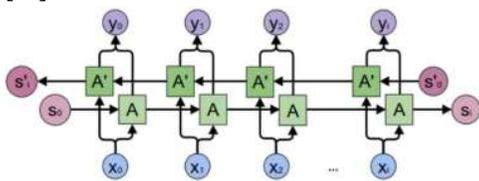
Setelah itu, ditambahkan dengan *output* dari *forget gate* pada langkah pertama. Langkah terakhir adalah menentukan *output* dari unit LSTM. Untuk menghasilkan *output*, perlu menghitung sigmoid dari gabungan s_{t-1} dan x_t yang disebut *output gate*. *Output gate* ini menentukan seberapa besar nilai dari *cell state* akan dihasilkan pada s_t . Lalu hitung nilai fungsi tanh dari C_t dan dikalikan dengan nilai dari *output gate*. Hasil perkalian tersebut menjadi *output* dari unit LSTM [10].

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

$$s_t = o_t * \tanh(C_t) \quad (6)$$

F. Bidirectional LSTM (BDLSTM)

Bidirectional LSTM adalah salah satu varian LSTM yang umum digunakan. *Input* yang dimasukkan ke dalam BiLSTM ada 2 jenis yaitu *input forward* dan *input backward*. *Output* dari lapisan ini umumnya digabungkan menjadi satu. Dengan *layer* ini, model dapat mempelajari informasi masa lalu (*past*) dan informasi masa mendatang (*future*) untuk tiap sekuen *input* [11].



Gambar 2 Arsitektur BDLSTM

Bi-LSTM adalah kombinasi LSTM maju dan LSTM mundur, yang berarti satu langkah data dimasukkan secara bersamaan dalam arah maju dan mundur. Meskipun Bi-LSTM perlu melatih lebih banyak generasi untuk menyatu dengan stabilitas, Bi-LSTM juga memiliki presisi yang lebih tinggi karena mendapat lebih banyak informasi masukan [12].

G. Python

Python merupakan bahasa pemrograman tingkat tinggi multiguna yang dapat digunakan untuk mengembangkan berbagai macam keperluan perangkat lunak. Python memiliki berbagai macam paradigma utamanya namun tidak terbatas pada pemrograman berorientasi objek. Kode pada python dirancang untuk memiliki tingkat keterbacaan yang tinggi (*readability*). Python juga memiliki *standard library* yang mendukung berbagai macam tugas pemrograman. Ukuran kode python secara umum hanya 1/3 hingga 1/5 kode yang dibuat dengan Bahasa pemrograman C++ atau java. Python secara otomatis mengalokasikan memori untuk objek dan menghapusnya ketika objek sudah tidak bisa digunakan [11].

H. Keras

Keras adalah *open source network library* yang dituliskan dalam python. Keras mampu dioperasikan menggunakan *MXnet*, *deeplearning4j*, *tensorflow*, *microsoft cognitive toolkit* atau *theano*. Keras direncanakan untuk melakukan eksperimen cepat dengan *deep neural network*, hal ini berfokus pada ukuran minimal, modular dan dapat diperluas kembali. Keras dikembangkan sebagai bagian dari upaya penelitian proyek ONEIROS dan untuk penulis serta pengelolanya adalah Francois Chollet. Pada tahun 2017, tim *google tensorflow* memutuskan untuk mendukung keras dalam *tensorflow's core library* [13].

3. METODOLOGI

A. Deskripsi Dataset

Peneliti tidak menggunakan data dari hasil pengukuran yang dilakukan secara langsung, namun menggunakan dataset yang disediakan oleh Sung Wook Baik dkk [14]. Dataset ini dapat diunduh pada laman UCI *Machine Learning Repository*. Adapun datanya berisi tentang konsumsi daya listrik sebuah rumah di Sceaux (7 Km dari Paris, Prancis) antara tahun 2006 sampai dengan tahun 2010. Data terdiri dari 2.075.259 sampel, termasuk 25.979 sample yang hilang (1,25% dari total data). Dataset ini berisi pengukuran konsumsi listrik dengan laju pengambilan sampel satu menit selama hampir 4 tahun. Adapun rincian analisis kuantitatif dataset konsumsi daya rumah tangga.

Tabel 1 Rincian Analisis Kuantitatif Dataset Konsumsi Daya Rumah Tangga.

Fitur-Fitur	Minimum	Maksimal	Std. Dev.	Rata-rata
Tanggal	16/12/2006	26/11/2010	---	---
Daya Aktif Global	0.076	11.122	1.055	1.089
Daya Reaktif Global	0.000	1.390	0.113	0.124
Tegangan	223.200	254.150	3.239	240.844

Intensitas Global	0.200	48.400	4.435	4.618
Sub-metering 1 (S1)	0.000	88.000	6.139	1.117
Sub-metering 2 (S2)	0.000	80.000	5.794	1.289
Sub-metering 3 (S3)	0.000	31.000	8.436	6.453

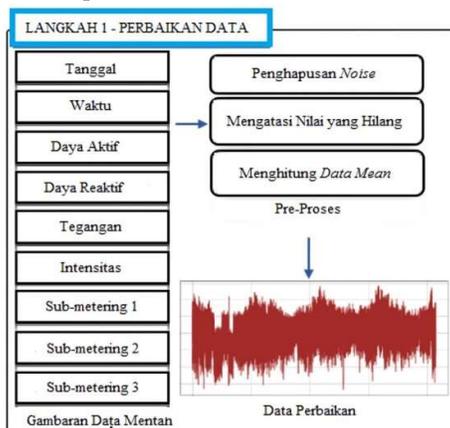
Berdasarkan Tabel 1 dapat dilihat bahwa daya aktif maksimum yang dikonsumsi sebesar 11.122 Kilowatt, sedangkan daya aktif minimum sebesar 0.076 Kilowatt. Ini berarti *sub-metering* 1 mengonsumsi lebih banyak energi dibandingkan dengan *sub-metering* 2 dan 3. Hal ini dikarenakan *sub-metering* 1 terkait dengan perangkat-perangkat dapur yang sangat banyak memakai energi listrik.

B. Pengolahan Data

Urutan tahapan-tahapan pengolahan data dibagi menjadi tiga tahapan :

1. Perbaiki Data

Adapun langkah pertama yaitu perbaikan data yang diilustrasikan pada Gambar 3 berikut :



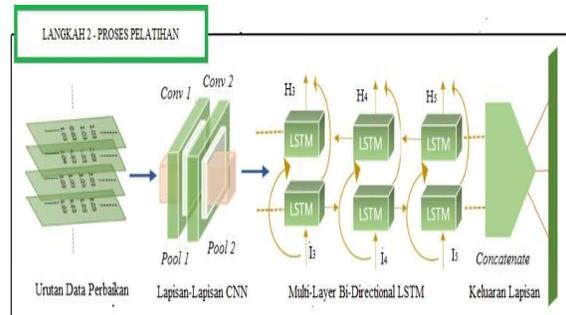
Gambar 3 Langkah Pertama Perbaiki Data [14].

Berdasarkan Gambar 3 dalam pengumpulan data, *smart meter* dipasang di tepi papan utama tempat kabel dari semua peralatan dibawa ke satu titik. Data biasanya dikumpulkan setiap bulan atau setiap tahun, yang menyebabkan ketidaknormalan dan *noise* pada data karena pengaruh iklim, masalah pengukuran, ataupun kesalahan individu. Data-data ini perlu diperbaiki sebelum diteruskan ke proses pelatihan seperti penghapusan *noise*, mengatasi nilai yang hilang dan menghitung *mean data*. Dalam mengatasi permasalahan data tersebut, terdapat berbagai filter penghalusan (*smoothing filter*) yang bisa digunakan untuk membersihkan data seperti LOESS, LOWESS, RLOESS, RLOWESS, Savitsky-Golay, atau filter rata-rata bergerak (*moving average filter*) [14]

Pada penelitian ini untuk menghilangkan *noise* dengan mempertimbangkan nilai resolusi waktu sebelumnya maka dapat diterapkan filter rata-rata bergerak yang banyak digunakan untuk memperhalus data. Setelah itu, didapatkanlah data perbaikan yang kemudian dapat dilatih.

2. Proses Pelatihan

Adapun langkah kedua yaitu proses pelatihan data dengan menggunakan salah satu metode *deep learning* yaitu gabungan dari CNN dan MBDLSTM yang diilustrasikan pada Gambar 4 berikut :

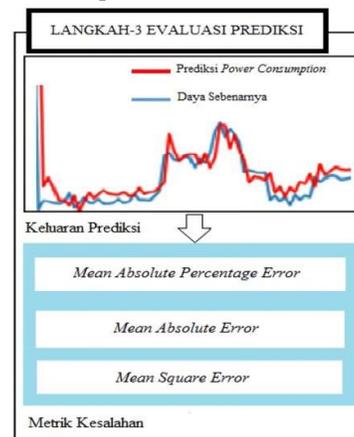


Gambar 4 Langkah Kedua Proses Pelatihan [14].

Berdasarkan Gambar 4 M-BDLSTM bertindak sebagai hubungan seri setelah CNN, dan mengambil informasi jangka pendek dari urutan masukan yang terkait dengan konsumsi daya dan memprosesnya baik dalam arah maju maupun mundur. Keluaran yang diperoleh dari lapisan-lapisan CNN yang kemudian diumpungkan ke dalam unit gerbang [14].

3. Evaluasi Prediksi

Adapun langkah terakhir yaitu evaluasi prediksi yang diilustrasikan pada Gambar 5 berikut :



Gambar 5 Langkah Ketiga Evaluasi Prediksi [14].

Berdasarkan Gambar 5 setelah di dapatkan keluaran prediksi, untuk mengevaluasi kualitas model prediksi dapat menggunakan metrik kesalahan seperti MSE (*mean square error*), MAE (*mean absolute error*) dan MAPE (*mean absolute percentage error*) seperti yang diberikan dalam persamaan (7) ,(8) dan (9) yang banyak

digunakan untuk mengevaluasi tingkat kesalahan untuk prediksi yang menggunakan model regresi.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2 \quad (7)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \tilde{y}_i| \quad (8)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \tilde{y}_i}{y_i} \right| \quad (9)$$

Keterangan :

n = Jumlah sampel data.

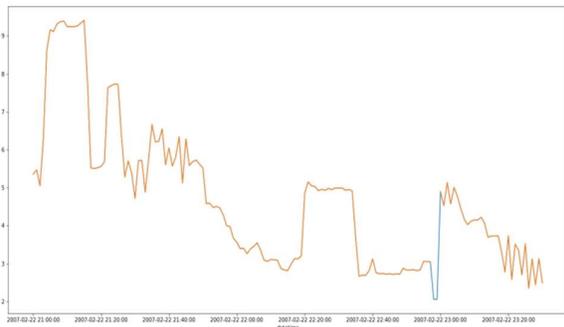
y_i = Nilai yang diamati.

\tilde{y}_i = Nilai yang diprediksi.

4. HASIL DAN PEMBAHASAN

A. Hasil Perbaikan Dataset

Pada dataset lama berisi nilai yang kosong atau hilang sebanyak 25.979 sampel (1,25% dari total data). Dataset baru ini berisi nilai perbaikan dari dataset lama sehingga tidak terdapat lagi nilai data yang hilang atau kosong. Adapaun untuk mengatasi *missing value* atau *noise* data menggunakan *moving average filter* dengan mempertimbangkan nilai resolusi waktu sebelumnya. Untuk grafik dataset baru dapat dilihat pada Gambar 6 yang diwakilkan dengan dataset 22 Februari 2007 pukul 21:00:00 sampai dengan 22 Februari 2007 pukul 23:30:00 pada bagian *Global Active Power*.



Gambar 6 Grafik Dataset Baru (22-02-2007 21:00:00 s/d 22-02-2007 23:30:00).

Berdasarkan Gambar 6 dapat dijelaskan bahwa data yang sebelumnya kosong pada tanggal 22 Februari 2007 pukul 22:58:00 sampai dengan pukul 22:59:00 sekarang memiliki nilai. Adapun informasi dataset baru seperti minimum, maksimum, std.Dev dan rata-rata dapat dilihat pada Tabel 2.

Tabel 2 Rincian Analisis Kuantitatif Dataset Baru Konsumsi Daya Rumah Tangga.

Fitur-Fitur	Minimum	Maksimal	Std. Dev.	Rata-rata
Tanggal	16/12/2006	26/11/2010	---	---
Daya Aktif Global	0.076	11.122	1.051171	1.089737
Daya Reaktif Global	0.000	1.390	0.112029	0.123707
Tegangan	223.200	254.150	3.232243	240.8368

Intensitas Global	0.200	48.400	4.418457	4.619999
Sub-metering 1 (S1)	0.000	88.000	6.114622	1.118163
Sub-metering 2 (S2)	0.000	80.000	5.785782	1.294906
Sub-metering 3 (S3)	0.000	31.000	8.386891	6.454182

Berdasarkan Tabel 2 dapat dilihat bahwa nilai yang mengalami perubahan pada dataset baru dibandingkan dengan dataset lama yaitu nilai standar deviasi dan rata-rata, walaupun perubahan nilainya tidak begitu besar. Pada daya aktif global nilai standar deviasi dataset lama yaitu 1.057294 sedangkan nilai standar deviasi dataset baru yaitu 1.051171. Kemudian, nilai rata-rata pada tegangan dataset lama bernilai 240.8399 Volt sedangkan nilai rata-rata pada tegangan dataset baru bernilai 240.8368 Volt.

B. Hasil Training Data

Pemodelan dilakukan 5 macam yaitu CNN, LSTM, BDLSTM, CNN-LSTM dan CNN-MBDLSTM. Untuk hasil pelatihan data dari berbagai pemodelan dapat dilihat pada Tabel 3.

Tabel 3 Hasil Pelatihan Data dari Berbagai Pemodelan

No	Model	Loss	Waktu (ms)
1	CNN	0.0010	9/step
2	LSTM	0.0019	75/step
3	BDLSTM	0.0018	139/step
4	CNN-LSTM	0.0019	44/step
5	CNN-MBDLSTM	0.0015	78/step

Struktur arsitektur jaringan dari tiap-tiap model berbeda-beda. Akan tetapi, Semua model menggunakan *optimizer Adam* dan *loss* jenis metrik *mean square error*. Model dilatih hingga 10 *epoch* dengan *batch_size* sebesar 32 dan menghasilkan nilai *loss* dan waktu pelatihan data dari berbagai pemodelan seperti pada Tabel.3, model yang memiliki nilai *loss* terkecil dan waktu *epoch* tercepat yaitu model CNN dengan nilai masing-masing sebesar lebih kurang 0.0010 dan 9/step ms. Sedangkan model yang memiliki *loss* terbesar yaitu LSTM dan CNN-LSTM dengan nilai lebih kurang 0.0019. Untuk model yang memiliki waktu *epoch* terlambat yaitu model BDLSTM dengan nilai lebih kurang 139/step ms.

C. Hasil Prediksi

Dataset yang digunakan dalam penelitian yaitu data tanggal 1 Januari 2007 pukul 00:00:00 s/d 7 Januari 2007 pukul 23:59:00 resolusi menit atau 10080 sampel dengan 7 variabel, data tersebut digunakan juga sebagai data untuk pelatihan pembelajaran algoritma pemodelan *deep learning*. Sedangkan dahasil yang diprediksi yaitu variabel *global active power* tanggal 8 Januari 2007

pukul 00:00:00 s/d pukul 23:59:00 resolusi menit atau 1440 sampel. Berikut hasil prediksi dari masing-masing pemodelan :

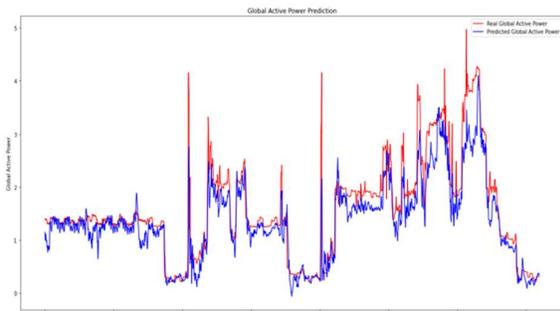
1. CNN (*Convolutional Neural Network*)

Hasil Perbandingan selisih nilai-nilai data aktual dan data hasil prediksi *global active power* untuk 3 menit pertama dan 3 menit terakhir pada metode CNN dapat dilihat pada Tabel 4.

Tabel 4 Hasil Prediksi dengan Metode CNN

No	Waktu	Data Aktual (kW)	Data Prediksi (kW)
1	8 Januari 2007 00:00:00	1.402	1.1487827
2	8 Januari 2007 00:01:00	1.382	0.9998261
3	8 Januari 2007 00:02:00	1.398	1.1124096
..
1438	8 Januari 2007 23:57:00	0.314	0.3622144
1439	8 Januari 2007 23:58:00	0.314	0.35434365
1440	8 Januari 2007 23:59:00	0.314	0.34835052

Setelah didapatkan perbandingan nilai data aktual dan data prediksi selama 24 jam atau 1440 menit. Maka akan ditampilkan dalam bentuk grafik perbandingan pada Gambar 7.



Gambar 7 Grafik Perbandingan Data Aktual dan Data Hasil Prediksi dengan Metode CNN.

Berdasarkan Gambar 7 dapat dianalisa bahwa data aktual diindikasikan dengan garis grafik berwarna merah dan data prediksi diindikasikan dengan garis grafik berwarna biru. Pada tiga menit pertama nilai prediksi lebih kecil dari nilai aktual sedangkan pada tiga menit terakhir nilai prediksi lebih besar dari nilai aktual dengan selisih nilai yang kecil. Jika dilihat dari Gambar 4.7 rata-rata nilai prediksi lebih kecil daripada nilai aktual. Untuk rentang selisih yang besar terjadi pada kisaran menit ke 1200 s/d 1250. Jika melihat pola data dari hasil perbandingan bahwa pemakaian listrik terus mengalami penurunan di kisaran menit ke 1300 s/d 1400 pada tanggal 8 Januari 2007.

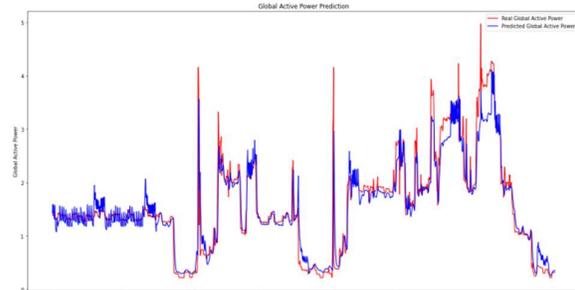
2. LSTM (*Long Short Term Memory*)

Hasil Perbandingan selisih nilai-nilai data aktual dan data hasil prediksi *global active power* untuk 3 menit pertama dan 3 menit terakhir pada metode LSTM dapat dilihat pada Tabel 5.

Tabel 5 Hasil Prediksi dengan Metode LSTM

No	Waktu	Data Aktual (kW)	Data Prediksi (kW)
1	8 Januari 2007 00:00:00	1.402	1.4246739
2	8 Januari 2007 00:01:00	1.382	1.5878073
3	8 Januari 2007 00:02:00	1.398	1.4228115
..
1438	8 Januari 2007 23:57:00	0.314	0.34831637
1439	8 Januari 2007 23:58:00	0.314	0.34786046
1440	8 Januari 2007 23:59:00	0.314	0.34658888

Setelah didapatkan perbandingan nilai data aktual dan data prediksi selama 24 jam atau 1440 menit. Maka akan ditampilkan dalam bentuk grafik perbandingan pada Gambar 8.



Gambar 8 Grafik Perbandingan Data Aktual dan Data Hasil Prediksi dengan Metode LSTM.

Berdasarkan Gambar 4.8 dapat dianalisa bahwa data aktual diindikasikan dengan garis grafik berwarna merah dan data prediksi diindikasikan dengan garis grafik berwarna biru. Pada hasil prediksi dengan metode LSTM sebagian besar nilai data prediksinya lebih besar daripada nilai dari data aktual yang diperkuat dengan Tabel 5. Pada kisaran menit ke-1 s/d menit ke-250 rentang selisih antara data aktual dan prediksi bernilai cukup besar dilihat dari garis grafiknya yang fluktuatif.

3. BDLSTM (*Bidirectional Long Short Term Memory*)

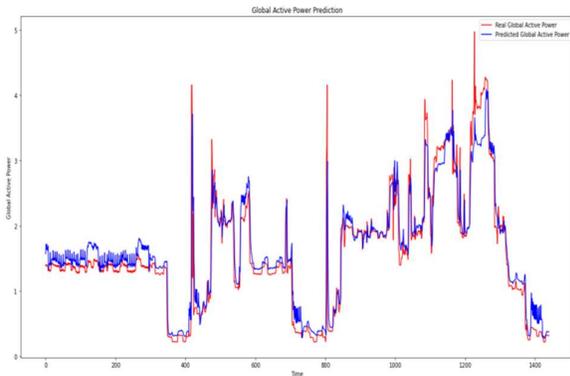
Hasil Perbandingan selisih nilai-nilai data aktual dan data hasil prediksi *global active power* untuk 3 menit

pertama dan 3 menit terakhir pada metode BDLSTM dapat dilihat pada Tabel 6.

Tabel 6 Hasil Prediksi dengan Metode BDLSTM

No	Waktu	Data Aktual (kW)	Data Prediksi (kW)
1	8 Januari 2007 00:00:00	1.402	1.566597
2	8 Januari 2007 00:01:00	1.382	1.7117347
3	8 Januari 2007 00:02:00	1.398	1.6332021
..
1438	8 Januari 2007 23:57:00	0.314	0.37359688
1439	8 Januari 2007 23:58:00	0.314	0.36977592
1440	8 Januari 2007 23:59:00	0.314	0.36780554

Setelah didapatkan perbandingan nilai data aktual dan data prediksi selama 24 jam atau 1440 menit. Maka akan ditampilkan dalam bentuk grafik perbandingan pada Gambar 9.



Gambar 9 Grafik Perbandingan Data Aktual dan Data Hasil Prediksi dengan Metode BDLSTM.

Gambar 9 menunjukkan hasil prediksi yang dilakukan pada 8 Januari 2007 dengan menggunakan data pembanding sebanyak 1440. Data aktual diindikasikan dengan garis grafik warna merah dan data hasil prediksi diindikasikan dengan warna biru. Jika dilihat pola data dari hasil perbandingan bahwa hasil prediksi dengan metode BDLSTM nilai aktual dan prediksinya rata-rata memiliki rentang selisih yang kecil. Nilai *global active power* mengalami kenaikan pada kisaran menit ke-1100 s/d menit ke 1250 atau sekitar pukul 6-8 malam kemudian mengalami penurunan pada kisaran menit ke-1250 s/d menit ke 1400 atau sekitar pukul 9-12. Hal ini dipengaruhi faktor pemakaian konsumen itu sendiri.

4. CNN-LSTM

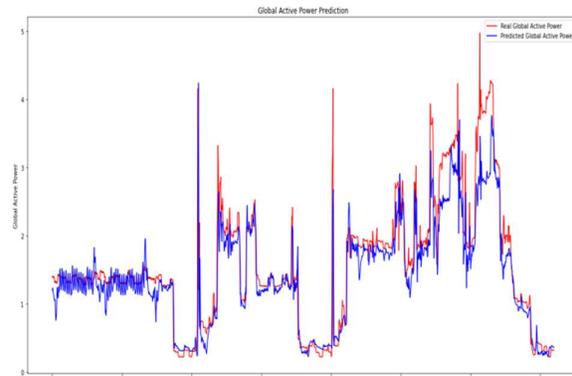
Hasil Perbandingan selisih nilai-nilai data aktual dan data hasil prediksi *global active power* untuk 3 menit

pertama dan 3 menit terakhir pada metode CNN-LSTM dapat dilihat pada Tabel 7.

Tabel 7 Hasil Prediksi dengan Metode CNN-LSTM

No	Waktu	Data Aktual (kW)	Data Prediksi (kW)
1	8 Januari 2007 00:00:00	1.402	1.1932191
2	8 Januari 2007 00:01:00	1.382	1.2281392
3	8 Januari 2007 00:02:00	1.398	1.1747175
..
1438	8 Januari 2007 23:57:00	0.314	0.36040518
1439	8 Januari 2007 23:58:00	0.314	0.36019480
1440	8 Januari 2007 23:59:00	0.314	0.35638148

Setelah didapatkan perbandingan nilai data aktual dan data prediksi selama 24 jam atau 1440 menit. Maka akan ditampilkan dalam bentuk grafik perbandingan pada Gambar 10.



Gambar 10 Grafik Perbandingan Data Aktual dan Data Hasil Prediksi dengan Metode CNN-LSTM.

Berdasarkan Gambar 10 menunjukkan hasil prediksi yang dilakukan pada 8 Januari 2007. Data aktual diindikasikan dengan garis grafik warna merah dan data hasil prediksi diindikasikan dengan warna biru. Pada dasarnya hasil prediksi mengikuti pola dari data aktual akan tetapi pada kisaran menit ke-1 s/d menit ke-250 terlihat nilai data prediksi mengalami fluktuatif yang akan mengakibatkan besarnya selisih nilai antara data aktual dan data prediksi. Untuk rentang yang cukup besar terjadi pada kisaran menit ke-1100 s/d menit ke-1300 dilihat dari garis grafiknya.

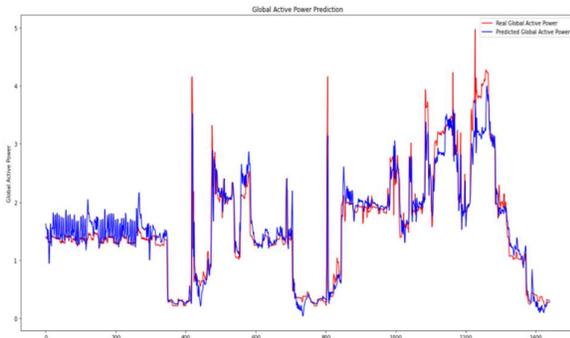
5. CNN-MBDLSTM

Hasil Perbandingan selisih nilai-nilai data aktual dan data hasil prediksi *global active power* untuk 3 menit pertama dan 3 menit terakhir pada metode CNN-MBDLSTM dapat dilihat pada Tabel 4.5.

Tabel 8 Hasil Prediksi dengan Metode CNN-MBDLSTM

No	Waktu	Data Aktual (kW)	Data Prediksi (kW)
1	8 Januari 2007 00:00:00	1.402	1.6261307
2	8 Januari 2007 00:01:00	1.382	1.5540953
3	8 Januari 2007 00:02:00	1.398	1.5613092
..
1438	8 Januari 2007 23:57:00	0.314	0.28223544
1439	8 Januari 2007 23:58:00	0.314	0.28158924
1440	8 Januari 2007 23:59:00	0.314	0.28129488

Setelah didapatkan perbandingan nilai data aktual dan data prediksi selama 24 jam atau 1440 menit. Maka akan ditampilkan dalam bentuk grafik perbandingan pada Gambar 11



Gambar 11 Grafik Perbandingan Data Aktual dan Data Hasil Prediksi dengan Metode CNN-MBDLSTM.

Berdasarkan Gambar 11 menunjukkan hasil prediksi yang dilakukan pada 8 Januari 2007. Data aktual diindikasikan dengan garis grafik warna merah dan data hasil prediksi diindikasikan dengan warna biru. Pada kisaran menit ke-1 s/d menit ke-250 rata-rata nilai data prediksi lebih besar daripada nilai data aktualnya serta dilihat dari garis grafik data hasil prediksi mengalami fluktuatif dalam rentang waktu yang dekat dan memiliki selisih rentang nilai yang cukup besar dengan data aktualnya. Sedangkan pada menit ke-250 s/d menit ke-1440, hasil prediksi tidak terlalu memiliki selisih nilai yang besar dari nilai aktualnya.

D. Evaluasi Metrik Kesalahan

Prediksi dilakukan selama 24 jam pada tanggal 8 Januari 2007 dengan resolusi tiap menit. Untuk melihat ketepatan prediksi *global active power* dapat dilakukan perhitungan metrik kesalahan seperti *Mean Squared*

Error (MSE), *Mean Absolute Error* (MAE) dan *Mean Absolute Percentage Error* (MAPE) pada tiap-tiap pemodelan yang digunakan. Untuk hasil evaluasi metrik kesalahan pada tiap pemodelan pada Tabel 9.

Tabel 9 Hasil Evaluasi Metrik Kesalahan

No	Model	MSE	MAE	MAPE
1	CNN	0.150	0.258	0.176
2	LSTM	0.098	0.182	0.160
3	BDLSTM	0.082	0.174	0.164
4	CNN-LSTM	0.129	0.223	0.158
5	CNN-M-BDLSTM	0.097	0.191	0.148

Berdasarkan Tabel 9 dapat dijelaskan bahwa metode yang memiliki nilai MSE terkecil yaitu metode BDLSTM sebesar 0.098 sedangkan nilai MSE terbesar yaitu 0.150 pada metode CNN. Untuk nilai MAE terkecil yaitu sebesar 0.174 pada metode BDLSTM sedangkan metode yang memiliki nilai MAE terbesar yaitu CNN dengan nilai 0.258 pada metrik kesalahan jenis MAPE nilai terbesar juga terjadi pada metode CNN dengan nilai 0.176 atau 17.6% sedangkan nilai MAPE terkecil yaitu 0.148 atau 14.8% pada metode CNN-M-BDLSTM.

Menurut Lewis (1982), nilai MAPE dapat diinterpretasikan atau ditafsirkan ke dalam 4 kategori yaitu: nilai kurang dari 10% dikatakan "Sangat Baik", nilai 10-20% dikatakan "Baik", nilai 20-50% dikatakan "Wajar", nilai lebih dari 50% dikatakan "Tidak Akurat" atau "Gagal". Berdasarkan nilai MAPE yang diperoleh dari penelitian sebesar kurang dari 20% artinya model sudah baik untuk meramalkan beban listrik. Berdasarkan nilai MSE dan MAE, semakin kecil nilai metrik kesalahan yang dihasilkan menunjukkan *error* dari nilai sebenarnya dengan nilai prediksi semakin kecil. Sebaliknya, semakin besar nilai metrik kesalahan yang dihasilkan menunjukkan *error* dari nilai sebenarnya dengan nilai prediksi semakin besar artinya semakin buruk model untuk meramalkan beban listrik.

5. KESIMPULAN

Berdasarkan pembahasan dan analisis yang telah dilakukan, adapun kesimpulan yang dapat ditarik adalah sebagai berikut :

1. Metode CNN, LSTM, BDLSTM, CNN-LSTM, dan CNN-M-BDLSTM menghasilkan *loss* dan waktu *training* masing-masing sebesar 0.0010 9/step ms, 0.0019 75/step ms, 0.0018 139/step ms, 0.0019 44/step ms dan 0.0015 78/step ms. Berdasarkan nilai *loss* dan waktu *training* tersebut, metode yang memiliki nilai *loss* dan waktu *training* terkecil yaitu metode CNN sedangkan metode yang memiliki nilai *loss* terbesar yaitu LSTM dan CNN-LSTM. Untuk metode yang memiliki nilai waktu *training* terbesar

yaitu BDLSTM. Oleh karena itu, untuk mendapatkan nilai *loss* yang kecil dan waktu *training* yang cepat dapat menggunakan metode CNN-M-BDLSTM. Metode-metode *deep learning* tersebut dapat diterapkan dalam prediksi konsumsi listrik rumah dengan resolusi menit ditunjukkan dengan pengujian pada hasil prediksi yang sudah dilakukan dan mendapatkan nilai selisih antara data aktual dan data prediksi yang kecil.

2. Ketepatan hasil prediksi konsumsi listrik yang digunakan dengan metode CNN, LSTM, BDLSTM, CNN-LSTM, dan CNN-M-BDLSTM pada suatu rumah mendapatkan nilai MSE berturut-turut sebesar 0.150, 0.098, 0.082, 0.129, dan 0.097. Untuk nilai MAE yang diperoleh masing-masing sebesar 0.258, 0.182, 0.174, 0.223, dan 0.191. Sedangkan, nilai MAPE yang dihasilkan sebesar 0.176, 0.160, 0.164, 0.158, dan 0.148. Berdasarkan nilai metrik kesalahan tersebut, metode CNN memperoleh nilai MSE, MAE dan MAPE terbesar. Metode BDLSTM memperoleh nilai MSE dan MAE terkecil sedangkan Metode CNN-M-BDLSTM memperoleh nilai MAPE terkecil. Hal ini menunjukkan bahwa kemampuan dalam memprediksi konsumsi daya listrik jangka pendek menggunakan metode *deep learning* mempunyai kemampuan yang baik berdasarkan nilai MAPE yang berada kurang dari 20%.

REFERENSI

- [1] M. Josep *et al*, 2017. "Networked and Distributed Control Method with Optimal Power Dispatch for Islanded Microgrids" dalam *IEEE Transactions On Industrial Electronics*.
- [2] A. S. Ahmad *et al*, 2014. "A Review On Applications Of ANN And SVM For Building Electrical Energy Consumption Forecasting" dalam *Renewable and Sustainable Energy Reviews* (vol. 33, 2014, hal. 102–109).
- [3] T. Kim dan S. Cho, 2019. "Predicting Residential Energy Consumption Using CNN-LSTM Neural Networks" dalam *Energy* (vol. 182, hal. 72–81, 2019).
- [4] K. Li, X. Xie, W. Xue, *et al*, 2018. "A Hybrid Teaching-Learning Artificial Neural Network For Building Electrical Energy Consumption Prediction Energy & Buildings A Hybrid Teaching-Learning Artificial Neural Network For Building Electrical Energy Consumption Prediction" dalam *Energy Buildings* (vol. 174, hal. 323–334, 2018).
- [5] Syafruddin, M, dkk, 2014. "Metode Regresi Linier untuk Prediksi Kebutuhan Energi Listrik Jangka Panjang (Studi Kasus Provinsi Lampung)". Lampung : Universitas Lampung.
- [6] Adha, B. N, 2018. "Analisis Prakiraan Kebutuhan Energi Listrik Pada PT. PLN (Persero) WS2JB Area Palembang Dengan

- [7] Menggunakan Metode Explanatory". Fakultas Teknik, Universitas Negeri Jakarta, Jakarta.
- [8] Kurniawati, Desi, 2019. "Prediksi Energi Listrik Dengan Metode Jaringan Syaraf Tiruan Backpropagation Menggunakan Matlab Untuk Kota Semarang Tahun 2019 – 2024". Fakultas Teknik, Universitas Negeri Semarang, Semarang.
- [9] Bandri, Sepannur, 2020. "Prediksi Perkembangan Kebutuhan Energi Listrik di Unit PLN Kayu Aro". dalam LPPM UMSB (vol. XIII, no. 6, hal. 187–205, 2020).
- [10] Ekananta, Y, dkk, 2018. "Penerapan Metode Average-Based Fuzzy Time Series Untuk Prediksi Konsumsi Energi Listrik Indonesia" dalam *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer* (vol. 2, no. 3, hal. 1283–1288, 2018).
- [11] Suyanto dkk, 2019. "Deep Learning Modernisasi Machine Learning Untuk Big Data,".
- [12] R. S. Panigas, 2018. "Pembangunan Model Pembelajaran Mesin untuk Identifikasi Struktur Kalimat Bahasa Indonesia".
- [13] Jin, Xuebo dkk, 2020. "Prediction for Time Series with CNN and LSTM".
- [14] Arfian, 2018. "Implementasi Convolutional Neural Network Terhadap Transportasi Tradisional Menggunakan Keras". Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Islam Indonesia, Yogyakarta.
- [15] Ullah, F. U. M. I. N, Ullah, Amin, *et al*, 2020. "Short-Term Prediction of Residential Power Energy Consumption via CNN and Multi-Layer Bi-Directional LSTM Networks" dalam *IEEE Access* (vol. 8, hal. 123369–123380, 2020).