

SISTEM PREDIKSI KECEPATAN DAN ARAH ANGIN MENGUNAKAN BIDIRECTIONAL LONG SHORT-TERM MEMORY

Anggraini Puspita Sari^{1,2}, Ermanu Azizul Hakim², Dwi Arman Prasetya^{1,2}, Rahman Arifuddin^{1,2},
Puput Dani Prasetyo Adi^{1,2}

¹ Universitas Merdeka Malang, Jl. Terusan Dieng 62-64 Malang

² Program Profesi Insinyur, Universitas Muhammadiyah Malang, Jl. Raya Tlogomas 246 Malang

Kontak Person:

Anggraini Puspita Sari

Jl. Terusan Dieng 62-64 Malang

E-mail: anggraini.puspita@unmer.ac.id

Abstrak

Makalah ini mengusulkan sistem prediksi kecepatan dan arah angin menggunakan sistem *bidirectional long short-term memory* (BILSTM) untuk periode prediksi satu jam ke depan. Sistem BILSTM menggunakan dua arah proses data, yaitu *forward* dan *backward* yang bertujuan untuk meningkatkan akurasi hasil prediksi kecepatan dan arah angin dan juga mereduksi waktu tunda. Input dari sistem prediksi menggunakan data kecepatan dan arah angin pada waktu yang sama yang diambil dari AMEDAS (Automated Meteorological Data Acquisition System), Jepang. Performa dari sistem prediksi dievaluasi menggunakan MAE (mean absolute error) dan RMSE (root mean square error) antara nilai aktual dan nilai prediksi. Target dari sistem prediksi yang diusulkan adalah meningkatkan akurasi hasil prediksi yang diperbandingkan dengan sistem FCNN (fully connected neural network) dan sistem SLSTM (stacked long short-term memory) pada setiap musim dalam satu tahun.

Kata kunci: LSTM, BILSTM, energi angin, kecepatan angin, arah angin

1. Pendahuluan

Dalam beberapa tahun terakhir ini, *renewable energy* (RE) mendapatkan perhatian khusus dan sebagian besar negara-negara di dunia menggunakan RE untuk mengurangi ketergantungan terhadap bahan bakar fosil yang diketahui bahwa bahan bakar fosil merupakan jenis energi yang tidak dapat diperbarui dan mengalami penipisan jumlahnya. Dengan mengurangi penggunaan bahan bakar fosil dapat mengurangi dampak buruk terhadap lingkungan, efek rumah kaca (pemanasan global), resiko terhadap kesehatan, minimalisasi limbah, dan polusi udara. RE merupakan sumber energi potensial yang dapat memberikan pasokan energi dengan sebagian besar nol emisi gas rumah kaca seperti gas metana (CH₄) dan karbondioksida (CO₂) [1][2][3]. RE dapat memproduksi listrik secara global sebesar 26,2% di akhir tahun 2019 dan ditargetkan dapat berkontribusi dalam memenuhi permintaan penggunaan energi di dunia sebesar 47,7% di tahun 2040 [1][4].

Energi angin merupakan salah satu jenis dari RE dan dengan cepat menarik perhatian negara-negara di dunia sebagai sumber energi alternatif pembangkit tenaga listrik. Keuntungan dalam menggunakan energi angin adalah terjangkau, bersih, berlimpah, dapat diandalkan, berkelanjutan dan terbarukan sehingga memiliki potensi yang besar dalam meningkatkan jumlah produksi energi secara signifikan di masa depan [5][6]. Masalah utama dalam menggunakan pembangkit listrik energi angin adalah fluktuasi output yang bergantung terhadap kecepatan dan arah angin sehingga sulit untuk memberikan pasokan energi yang stabil. Solusi menangani masalah ini adalah membuat sistem prediksi yang akurat sehingga pembangkit listrik dapat diatur secara efektif dan efisien.

Dalam makalah ini, kami mengusulkan sistem prediksi baru untuk kecepatan dan arah angin dengan metode AI (*artificial intelligence*) menggunakan BILSTM (*bidirectional long-short term memory*). BILSTM dapat menganalisis deret waktu dan menggunakan dua arah dalam proses data, yaitu *forward* dan *backward* sehingga dapat meningkatkan akurasi hasil prediksi. Periode prediksi dari sistem prediksi adalah satu jam kedepan. Tingkat efektivitas dari sistem prediksi diperbandingkan dengan sistem FCNN (*fully connected neural network*) dan sistem SLSTM (*stacked long-short term memory*) pada masing-masing musim dalam satu tahun yang merupakan karakteristik dari iklim Jepang. Performa seluruh sistem prediksi dievaluasi menggunakan MAE (*mean absolute error*) dan RMSE (*root mean square error*).

2. Sistem prediksi

2.1 Definisi tentang Kecepatan dan Arah Angin

Kecepatan dan arah angin (data angin) diambil dari data AMEDAS (*Automated Meteorological Data Acquisition System*), Jepang dengan interval waktu 10 menit pada kota Takamatsu. Data angin divisualisasikan dalam sistem koordinat dua dimensi (koordinat 2D) yang ditunjukkan dalam Gambar 1. Sumbu X menunjukkan arah angin dari timur (T) ke barat (W). Sumbu Y menunjukkan arah angin dari utara (U) ke selatan (S). Arah angin yang digunakan dalam sistem prediksi adalah 16 arah yang ditunjukkan dalam Gambar 2.

Komponen X dan Y dari vektor angin ($v(t)$) dapat dirumuskan sebagai berikut:

$$v_X(t) = v(t) \cdot \cos \beta(t) \quad (1)$$

$$v_Y(t) = v(t) \cdot \sin \beta(t) \quad (2)$$

dengan:

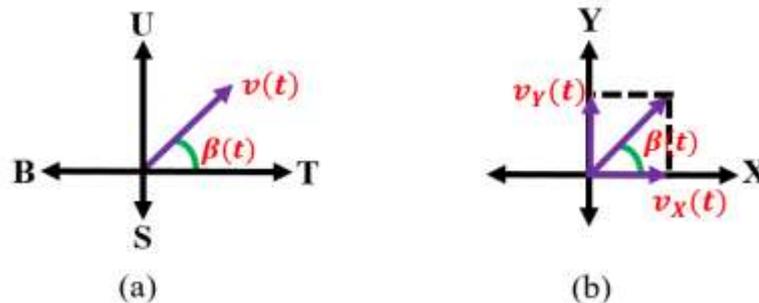
$\beta(t)$ = arah angin [$^\circ$],

$v(t)$ = kecepatan angin [m/s],

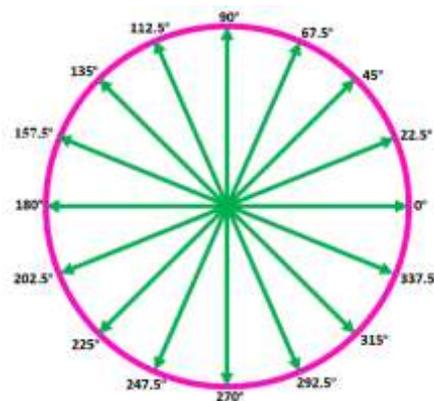
$v_X(t)$ = komponen X untuk $v(t)$,

$v_Y(t)$ = komponen Y untuk $v(t)$.

Input data dari sistem prediksi adalah $v_X(t)$ dan $v_Y(t)$. Periode sistem prediksi adalah satu jam ke depan dengan alasan mempertimbangkan kemampuan beradaptasi pembangkit listrik thermal dan pembangkit listrik tenaga air yang dipompa.



Gambar 1 Kecepatan dan arah angin dalam sistem koordinat $v(t)$
(a) Diagram vektor (b) Definisi komponen $v(t)$



Gambar 2 Definisi arah angin

2.2 Dataset untuk Kecepatan dan Arah Angin

Sistem prediksi yang diusulkan menggunakan tiga macam *dataset*, yaitu data *training*, data *validation* dan data *test* yang ditunjukkan dalam Tabel 1. Sistem prediksi menggunakan data angin dalam enam tahun dengan rincian sebagai berikut: tiga tahun untuk data *training*, dua tahun untuk data *validation*, dan satu tahun untuk data *test*. Panjang urutan waktu yang digunakan dalam sistem prediksi yang diusulkan adalah 144 (data angin dalam satu hari).

Tabel 1 Periode *Dataset*

Deskripsi	Data
<i>Training</i>	Des. 2013 - Nov. 2016
<i>Validation</i>	Des. 2016 - Nov.2018
<i>Test</i>	Des. 2018 – Nov. 2019

2.3 Parameter dan Prosedur Learning

Parameter *learning* pada sistem prediksi ditunjukkan dalam Tabel 2. Sistem prediksi menggunakan Leaky ReLU (*Leaky Rectified Linear Unit*) sebagai fungsi aktivasi yang dapat didefinisikan sebagai berikut:

$$\sigma(\mathbf{X}) = \begin{cases} X_q, & X_q \geq 0 \\ aX_q, & X_q < 0 \end{cases} \quad (3)$$

dengan:

X_q = input dari fungsi aktivasi,

σ = fungsi aktivasi,

a = parameter input data.

Fungsi parameter a adalah untuk mengatasi masalah *dying* ReLU sehingga gradien tidak menjadi nol selama waktu pelatihan. Penggunaan Leaky ReLU bertujuan juga untuk mempercepat waktu *training*. Jaringan dilatih menggunakan *optimizer root mean square propagation* (RMSProp) dengan parameter $\rho = 0.9$ dan *lr (learning rate)* = 0.001. Pada masing-masing jaringan sistem prediksi dilatih dan divalidasi dengan iterasi 100 menggunakan data *training* dan data *validation*. Performa sistem prediksi dievaluasi menggunakan *mean absolute error* (MAE) dan *root mean square error* (RMSE) yang dapat dirumuskan sebagai berikut:

$$MAE = \frac{1}{N} \sum_{q=1}^N |Y_q - \hat{Y}_q| \quad (4)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{q=1}^N (Y_q - \hat{Y}_q)^2} \quad (5)$$

dengan:

N = nomer data sampel,

Y_q = nilai aktual,

\hat{Y}_q = nilai prediksi.

RMSE merupakan teknik evaluasi yang paling sering digunakan dalam memprediksi sesuatu dan mengarah pada prediksi nilai mean (rata-rata) error. MAE merupakan teknik evaluasi lainnya dengan menghitung nilai error absolut dan mengarah pada prediksi nilai median error. Sistem prediksi menggunakan *batch size* dengan nilai 100.

Tabel 2 Parameter Learning

Parameter	Data
Fungsi aktivasi	Leaky ReLU
<i>Optimizer</i>	RMSProp
	ρ 0.9
	<i>lr</i> 0.001
<i>Batch size</i>	100
Iterasi	100

2.4 FCNN

FCNN (*fully connected neural network*) merupakan salah satu jenis dari *neural network* (NN). Konfigurasi dari sistem FCNN terdiri dari sebuah layer input, lima layer *hidden*, dan sebuah layer output yang ditunjukkan dalam Gambar 3. Masing-masing layer dari FCNN dihubungkan dengan beberapa *weight* dan sebuah bias. Input dari sistem FCNN adalah 144 dimensi (satu hari data) yang didalamnya termasuk data angin sekarang dan sebelumnya. Nomer input data (M) yang digunakan adalah 2. Sistem

FCNN untuk bias dan *weight* di-update menggunakan algoritma BP (*back-propagation*). Rumus matematik untuk layer *hidden* ke-k dapat didefinisikan sebagai berikut [7]:

$$H_p^k = \sigma \left(\sum_{q=1}^M W_{pq}^k X_q^k + b_p^k \right) \quad (6)$$

dengan:

H = *hidden*,

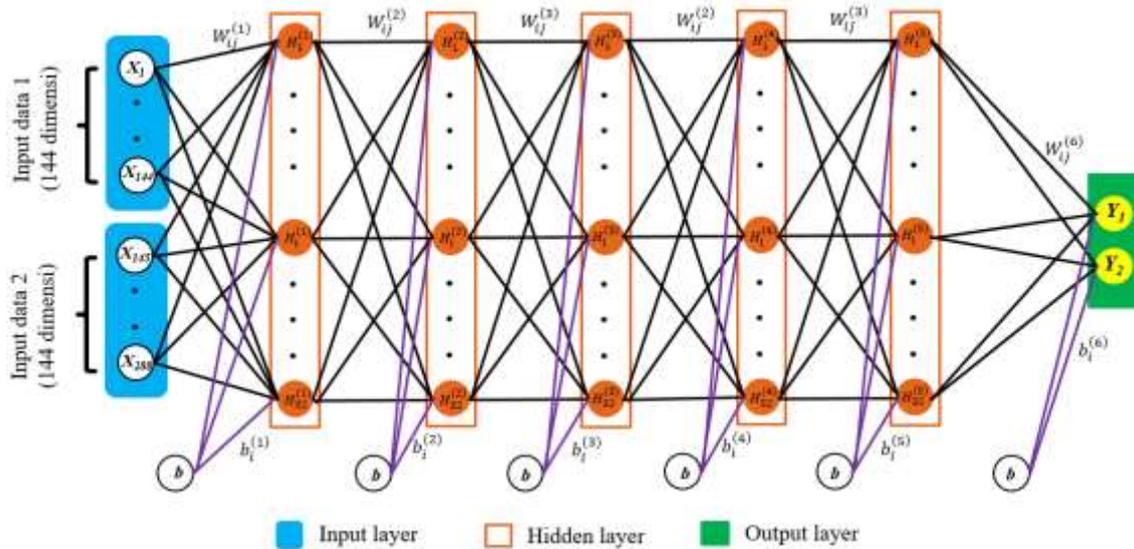
W = *weight*,

b = *bias*,

X = *data input*,

σ = *fungsi aktivasi*.

Fungsi aktivasi pada sistem FCNN menggunakan Leaky ReLU.



Gambar 3 Konfigurasi sistem FCNN

2.5 LSTM

Long short-term memory (LSTM) merupakan salah satu macam dari NN dan perkembangan dari sistem RNN (*recurrent neural network*). LSTM sangat terkenal untuk menganalisis data urutan waktu dan *learning* untuk *end ke end*. LSTM digunakan untuk mengatasi kekurangan pada RNN tentang masalah gradien *vanishing*. Keunggulan menggunakan LSTM adalah LSTM dilatih menggunakan algoritma BP, meningkatkan kemampuan RNN, jalannya program lebih cepat daripada menggunakan RNN, dan memiliki *cell state* (C) dan *gates* untuk mengatur aliran informasi. LSTM adalah sistem yang *powerful* dan stabil untuk mengatasi ketergantungan *long-range*, menangani *learning* untuk ketergantungan *short-term* dan *long-term* dengan baik [3][6]. Sistem LSTM terdiri dari tiga *gates*, yaitu:

- input gate* yang berfungsi untuk mengontrol data input,
- forget gate* berfungsi untuk menahan data,
- output gate* berfungsi untuk mengontrol data output.

Struktur inti pada LSTM ditunjukkan dalam Gambar 4. Arti masing-masing simbol pada Gambar 4, yaitu: i, o, f, C, H, σ, X masing – masing adalah *input gate, output gate, forget gate, hidden state, cell state, fungsi aktivasi, dan data input*. Secara umum, Komponen LSTM dapat dirumuskan sebagai berikut [7][8]:

$$i_t = \sigma (W_i \cdot [X_t, H_{t-1}] + b_i) \quad (7)$$

$$f_t = \sigma (W_f \cdot [X_t, H_{t-1}] + b_f) \quad (8)$$

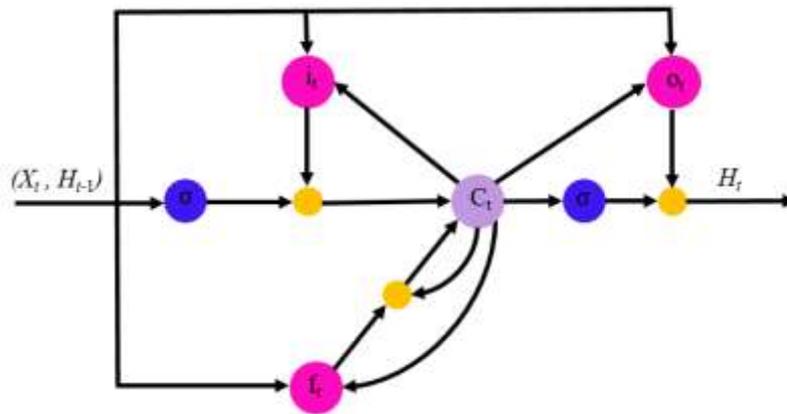
$$o_t = \sigma (W_o \cdot [X_t, H_{t-1}] + b_o) \quad (9)$$

$$C_t = f_t \circ C_{t-1} + i_t \circ \tanh(W_c \cdot [X_t, H_{t-1}] + b_c) \quad (10)$$

$$H_t = o_t \circ \tanh(C_t) \tag{11}$$

dengan:

- i = input gate,
- o = output gate,
- f = forget gate,
- X = data input,
- H = hidden state,
- C = cell state,
- W = weight,
- σ = fungsi aktivasi,
- b = bias,
- \circ = produk *hadamard*.

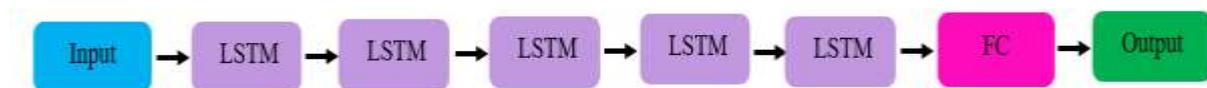


Gambar 4 Struktur inti pada LSTM

Sistem prediksi dengan LSTM dapat digunakan untuk menganalisis urutan waktu dari data angin. LSTM dapat diaplikasikan untuk studi tentang diagnosis medis [9], prediksi data angin [10], pengenalan suara [11], pembuatan teks [12], label scene [13] dan lain-lain. Fungsi aktivasi pada sistem LSTM menggunakan Leaky ReLU. Pada makalah ini disajikan dengan dua jenis LSTM, yaitu: *stacked* LSTM (SLSTM) dan *bidirectional* LSTM (BILSTM) yang bertujuan untuk meningkatkan akurasi dan mengurangi waktu tunda pada hasil prediksi.

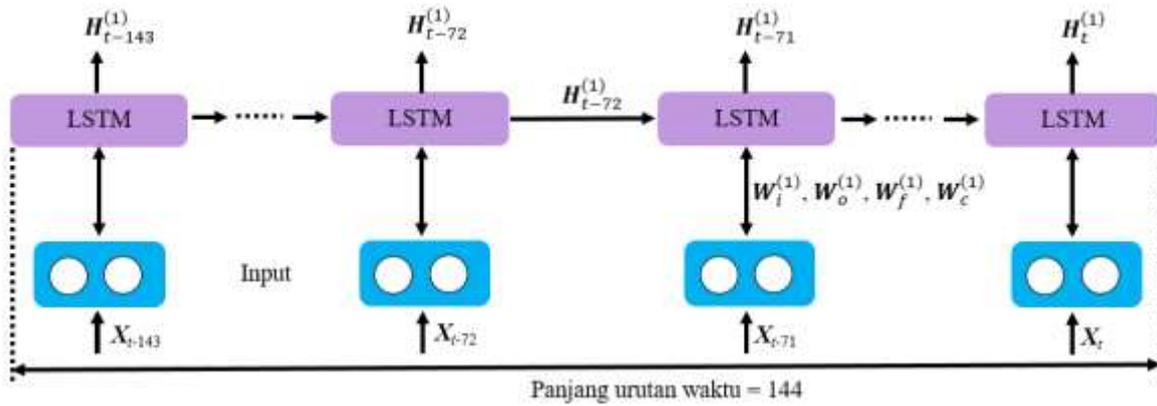
2.5.1 SLSTM

SLSTM adalah salah satu jenis dari LSTM yang merupakan perkembangan dari sistem RNN. Konfigurasi dari sistem SLSTM terdiri dari sebuah layer input, lima layer LSTM, sebuah layer FC (*fully connected*), dan sebuah layer output yang ditunjukkan dalam Gambar 5.



Gambar 5 Konfigurasi sistem SLSTM

Panjang urutan waktu pada sistem SLSTM adalah 144 (satu hari data) dan sama dengan dimensi input pada FCNN. Panjang urutan waktu yang terlalu panjang (144) pada sistem SLSTM mengakibatkan adanya kenaikan error sehingga untuk mengatasinya menggunakan BPTT (*truncated back-propagation through time*) yang digunakan untuk meng-*update weight* dan bias. Setiap layer LSTM menggunakan 128 neuron. Pada akhir proses SLSTM terdapat FC layer yang berfungsi untuk memudahkan dalam memperoleh output. Gambar 6 menunjukkan sistem operasi SLSTM yang merepresentasikan proses dari layer input ke layer LSTM.

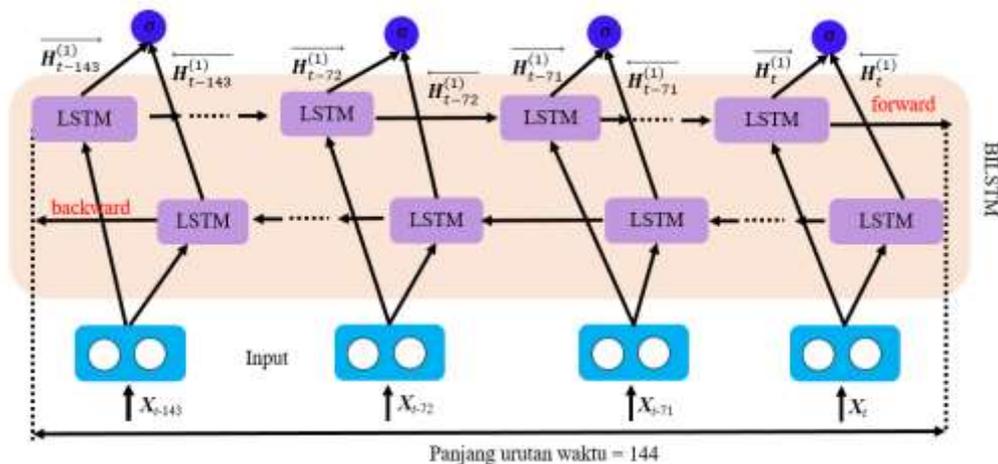


Gambar 6 Sistem operasi SLSTM

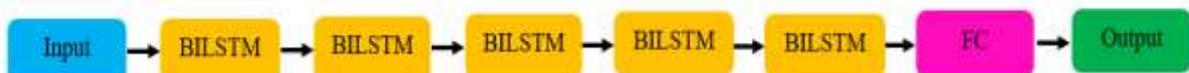
2.5.1 BILSTM

BILSTM adalah salah satu jenis dari LSTM yang versi lanjutan dengan mempertimbangkan data *forward* dan *backward* untuk meningkatkan akurasi dari hasil prediksi. Perbedaan sistem SLSTM dan BILSTM adalah proses data pada SLSTM hanya satu arah (lihat pada Gambar 6) tetapi proses data pada BILSTM terjadi dua arah yaitu arah *forward* dan *backward* yang ditunjukkan dalam Gambar 7. Pada BILSTM terdapat dua jaringan LSTM dengan jaringan LSTM pertama memproses urutan masukan data ke arah depan (*forward*) dan jaringan LSTM kedua memproses urutan data dalam arah sebaliknya (*backward*). Output dari jaringan LSTM pertama dan kedua digabungkan pada setiap urutan waktu [14][15]. Sistem BILSTM diharapkan dapat bekerja lebih efektif dan efisien daripada sistem SLSTM sehingga dapat meningkatkan akurasi dari hasil prediksi.

Konfigurasi dari sistem BILSTM terdiri dari sebuah layer input, lima layer BILSTM, sebuah layer FC, dan sebuah layer output yang ditunjukkan dalam Gambar 8. Panjang urutan waktu pada sistem BILSTM adalah 144 (satu hari data) dan sama dengan dimensi input pada sistem FCNN dan SLSTM. Panjang urutan waktu yang terlalu panjang (144) pada sistem BILSTM mengakibatkan adanya kenaikan error sehingga untuk mengatasinya menggunakan BPTT yang digunakan untuk meng-*update weight* dan bias. Setiap layer BILSTM menggunakan 128 neuron. Pada akhir proses BILSTM terdapat FC layer yang berfungsi untuk memudahkan dalam memperoleh output.



Gambar 7 Sistem operasi BILSTM



Gambar 8 Konfigurasi sistem BILSTM

3. Hasil dan Pembahasan

Nilai prediksi kecepatan angin dan arah angin dapat dirumuskan sebagai berikut:

$$\hat{v}(t) = \sqrt{\hat{v}_x(t)^2 + \hat{v}_y(t)^2} \quad (12)$$

$$\hat{\beta}(t) = \tan^{-1} \left(\frac{\hat{v}_y(t)}{\hat{v}_x(t)} \right) \quad (13)$$

dengan:

$\hat{v}(t)$ = hasil prediksi kecepatan angin [m/s]

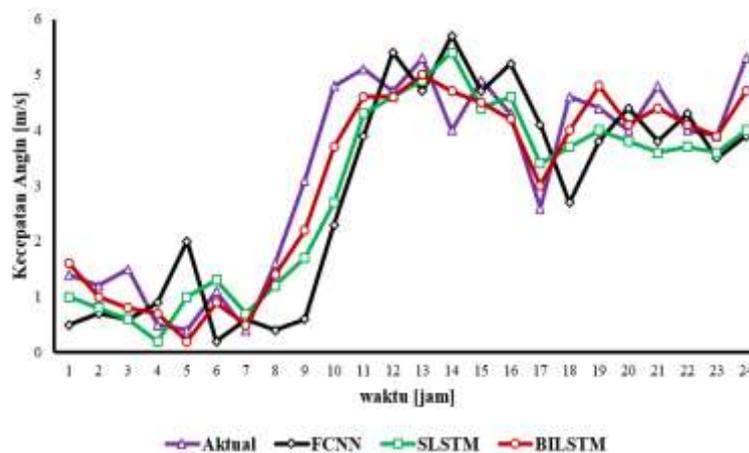
$\hat{v}_x(t)$ = komponen X untuk prediksi $\hat{v}(t)$

$\hat{v}_y(t)$ = komponen Y untuk prediksi $\hat{v}(t)$

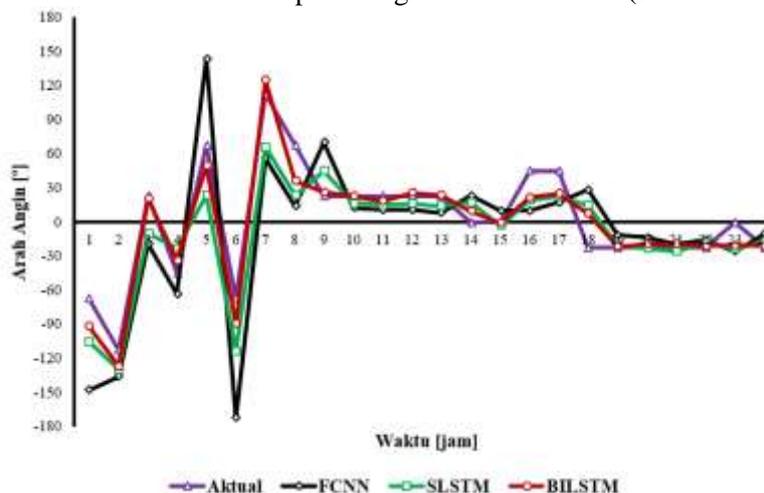
$\hat{\beta}(t)$ = hasil prediksi arah angin[°]

Sistem prediksi diimplementasikan menggunakan program *python, framework* menggunakan *Keras*, dan *Tensorflow* sebagai *backend*. Target dari sistem prediksi adalah satu jam ke depan untuk masing-masing musim dari Des. 2018 – Nov. 2019 dan evaluasi error pada sistem prediksi menggunakan RMSE dan MAE.

Hasil prediksi kecepatan dan arah angin sistem prediksi diperbandingkan dengan nilai aktual dalam satu hari (3 Desember 2018) ditunjukkan dalam Gambar 9 dan 10. Pada Gambar 10, arah angin dari $180^\circ = -180^\circ$. Berdasarkan Gambar 9 dan 10, hasil prediksi FCNN paling rendah tingkat akurasi baik pada kecepatan maupun arah angin dan adanya waktu tunda terutama perubahan yang sangat cepat pada kecepatan dan arah angin. Adanya waktu tunda pada sistem FCNN dapat dikurangi dengan menggunakan sistem SLSTM dan BILSTM. Hasil prediksi dari sistem BILSTM lebih baik daripada sistem lainnya, dapat mengurangi waktu tunda secara efektif dan hasil prediksi paling mendekati dengan nilai aktual. Hal ini membuktikan bahwa sistem BILSTM adalah sistem prediksi terbaik daripada sistem lainnya.



Gambar 9 Hasil Prediksi kecepatan angin dalam satu hari (3 Desember 2018)



Gambar 10 Hasil Prediksi arah angin dalam satu hari (3 Desember 2018)

RMSE dan MAE dari kecepatan dan arah angin untuk masing-masing musim ditunjukkan dalam Tabel 3 dan 4. Nilai MAE menghasilkan lebih rendah daripada RMSE karena MAE menggunakan

perhitungan nilai absolutnya dan memiliki varian yang kecil. Pada semua sistem prediksi menghasilkan prediksi akurasi tertinggi baik kecepatan maupun arah angin di musim dingin dikarenakan perubahan nilai kecepatan dan arah angin cenderung lebih kecil dibandingkan dengan musim lainnya. Sistem BILSTM menghasilkan prediksi akurasi tertinggi baik pada kecepatan angin maupun arah angin dan juga pada RMSE dan MAE pada semua musim. Hal ini mengindikasikan bahwa sistem BILSTM merupakan sistem prediksi terbaik daripada sistem lainnya.

Gambar 11 dan 12 menunjukkan MAE dan RMSE kecepatan dan arah angin pada setiap bulan mulai Des. 2018 – Nov. 2019. Berdasarkan Gambar 11, prediksi akurasi kecepatan angin pada sistem BILSTM yang tertinggi dibandingkan dengan sistem lainnya baik pada MAE maupun RMSE di setiap bulannya. Begitupun pada Gambar 12, prediksi akurasi arah angin pada sistem BILSTM yang tertinggi dibandingkan dengan sistem lainnya baik pada MAE maupun RMSE di setiap bulannya. Hal ini menunjukkan bahwa sistem BILSTM adalah sistem terbaik dibandingkan dengan sistem lainnya.

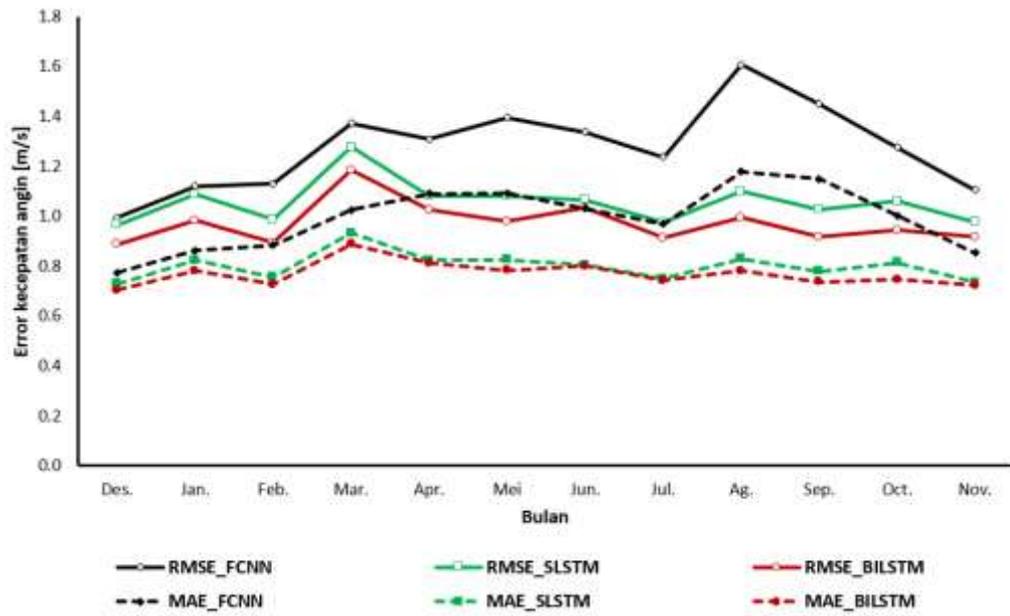
Kenaikan akurasi pada kecepatan dan arah angin yang diperbandingkan dengan sistem FCNN pada setiap musim ditunjukkan dalam Tabel 5 dan 6. Berdasarkan Tabel 5 pada kolom RMSE, sistem SLSTM dapat meningkatkan akurasi berkisar 6.37% – 25.32%, sistem BILSTM dapat meningkatkan akurasi berkisar 15.94% – 40.27%, dan pada kolom MAE, sistem SLSTM dapat meningkatkan akurasi berkisar 8.41% – 25.03%, sistem BILSTM dapat meningkatkan akurasi berkisar 16.05% – 42.66% untuk kecepatan angin. Berdasarkan Tabel 6 pada kolom RMSE, sistem SLSTM dapat meningkatkan akurasi berkisar 4.51% – 8.15%, sistem BILSTM dapat meningkatkan akurasi berkisar 11.10% – 21.80%, dan pada kolom MAE, sistem SLSTM dapat meningkatkan akurasi berkisar 5.48% – 9.98%, sistem BILSTM dapat meningkatkan akurasi berkisar 17.55% – 28.62% untuk arah angin. Berdasarkan Tabel 5 dan 6, sistem BILSTM dapat meningkatkan akurasi secara signifikan daripada sistem SLSTM baik pada kecepatan angin maupun arah angin sehingga hal ini mengindikasikan bahwa sistem BILSTM merupakan sistem *benchmark*.

Tabel 3 RMSE pada kecepatan dan arah angin

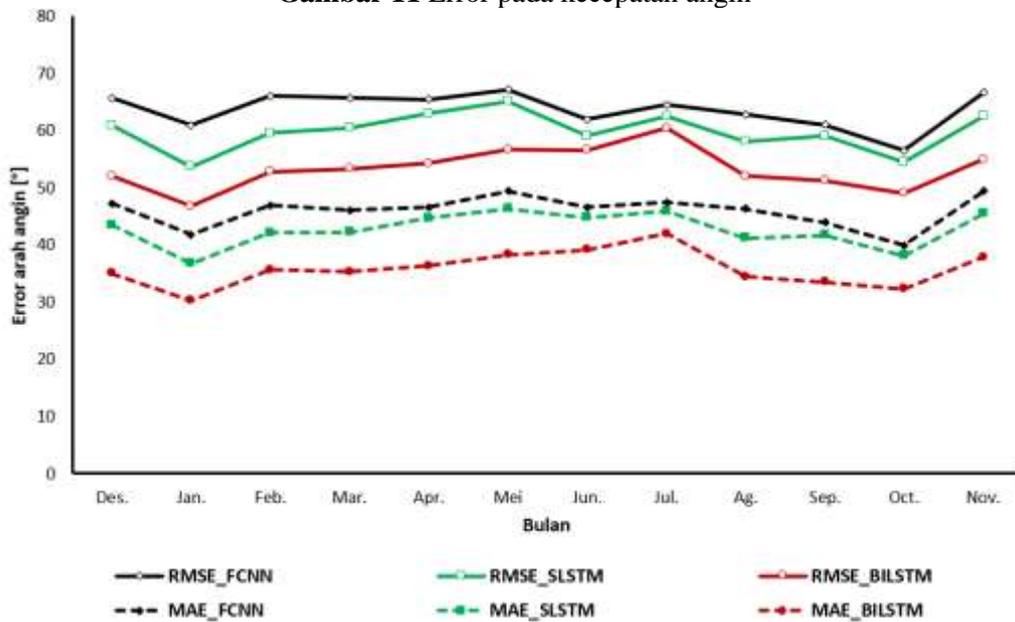
Musim	FCNN [m/s]	SLSTM [m/s]	BILSTM [m/s]	FCNN [°]	SLSTM [°]	BILSTM [°]
Dingin	1.0835	1.0145	0.9218	63.2744	58.1203	50.6056
Semi	1.3577	1.1459	1.0625	66.1680	62.9865	54.8059
Panas	1.4035	1.0482	0.9814	63.0865	60.2412	56.4002
Gugur	1.2836	1.0209	0.9248	63.6019	58.8100	51.8361
Rata-rata	1.2874	1.0579	0.9735	63.986	58.5572	53.4477

Tabel 4 MAE pada kecepatan dan arah angin

Musim	FCNN [m/s]	SLSTM [m/s]	BILSTM [m/s]	FCNN [°]	SLSTM [°]	BILSTM [°]
Dingin	0.8402	0.7695	0.7167	45.3079	40.7897	33.6322
Semi	1.0408	0.8576	0.8256	48.3939	44.4582	36.6832
Panas	1.0601	0.7948	0.7210	46.1055	43.5796	38.4558
Gugur	1.0008	0.7752	0.7345	46.4679	41.8294	34.5745
Rata-rata	0.9851	0.7988	0.7490	46.2061	41.9027	35.8307



Gambar 11 Error pada kecepatan angin



Gambar 12 Error pada arah angin

Tabel 5 Kenaikan akurasi pada kecepatan angin

Musim	RMSE		MAE	
	SLSTM [m/s]	BILSTM [m/s]	SLSTM [m/s]	BILSTM [m/s]
Dingin	6.37	15.94	8.41	16.05
Semi	15.60	25.76	17.60	25.09
Panas	25.32	40.27	25.03	42.66
Gugur	20.47	35.15	22.54	34.35
Rata-rata	17.83	29.67	18.91	29.56

Tabel 6 Kenaikan akurasi pada arah angin

Musim	RMSE		MAE	
	SLSTM [°]	BILSTM [°]	SLSTM [°]	BILSTM [°]
Dingin	8.15	21.80	9.97	28.62
Semi	4.81	18.04	8.13	26.34
Panas	4.51	11.10	5.48	17.55
Gugur	7.53	20.01	9.98	28.43
Rata-rata	8.48	18.00	9.31	24.76

4. Kesimpulan

Pada makalah ini mengusulkan sistem prediksi kecepatan dan arah angin menggunakan sistem BILSTM. Tingkat keefektifan seluruh sistem prediksi dievaluasi menggunakan MAE dan RMSE. Berdasarkan hasil simulasi, sistem SLSTM dan BILSTM dapat meningkatkan akurasi dari sistem FCNN. Hasil prediksi dari sistem BILSTM lebih baik dari sistem FCNN dan SLSTM. Dalam perbandingan kenaikan akurasi menggunakan sistem FCNN, sistem BILSTM dapat meningkatkan akurasi secara signifikan dibandingkan dengan sistem SLSTM. Secara keseluruhan, sistem BILSTM merupakan sistem prediksi *benchmark* dan terbaik dibandingkan sistem lainnya.

Referensi

- [1] Panwar NL, Kaushik SC, Surendra K. *Role of Renewable Energy Sources in Environmental Protection: A Review*. Journal of Elsevier Renewable and Sustainable Energy Reviews. 2011; 15(3): 1513-1524.
- [2] Anggraini PS, Hiroshi S, Takahiro K, Takashi Y, Dwi AP. *Prediction Model of Wind Speed and Direction using Deep Neural Network*. Journal of Electrical Engineering, Mechatronic and Computer Science (JEEMECES). 2020; 3(1): 01-10.
- [3] Anggraini PS, Hiroshi S, Takahiro K, Takashi Y, Dwi AP, Abdur R. *Prediction of Wind Speed and Direction using Encoding-forecasting Network with Convolutional Long Short-term Memory*. IEEE Xplore: Proc. 2020 59th Annual Conference of the Society of Instrument and Control Engineers (SICE). Chiang Mai. 2020; 958-963.
- [4] Ren21. *Renewables 2019 Global Status Report*. <https://www.ren21.net/reports/global-status-report/>. Access: 1 Maret 2021.
- [5] Priya RK, Kedarnath S. *Short-term Wind Speed Forecasting using S-Transform with Compactly Supported Kernel*. Journal of Wiley Wind Energy. 2021; 24(3): 260-274.
- [6] Anggraini PS, Hiroshi S, Takahiro K, Takashi Y, Dwi AP, Abdur R. *Deep Convolutional Long Short-term Memory for Forecasting Wind Speed and Direction*. SICE Journal of Control, Measurement, and System Integration (SICE JCMSI). 2021: 1-9.
- [7] Anggraini PS, Hiroshi S, Takahiro K, Takashi Y, Dwi AP, Nachrowie. *Prediction Model of Wind Speed and Direction using Convolutional Neural Network – Long Short Term Memory*. IEEE Xplore: Proc. 2020 IEEE International Conference on Power and Energy (PECon). Penang. 2020; 358-363.
- [8] Sisheng L, Long N, Fang J. *A Multi-variable Stacked Long-short Term Memory Network for Wind Speed Forecasting*. Journal of arXiv. 2018; 1811.09735v1: 1-4.
- [9] Zachary CL, David CK, Charles E, Randall W. *Learning to Diagnose with LSTM Recurrent Neural Networks*. Journal of arXiv. 2017; 1511.03677v7: 1–18.
- [10] Rui F, Hiroshi S, Takahiro K, Akinobu K, Takashi Y, Kiyoshi T. *Prediction of Rapid Wind Speed Fluctuation by LSTM using Observed Data of Multiple Points*. Proc. 2019 RISP International Workshop on Nonlinear Circuits, Communications and Signal Processing (NCSP2019). Honolulu. 2019; 76–79.
- [11] Tara NS, Oriol V, Andrew S, Hasim S. *Convolutional, Long Short-Term Memory, Fully Connected Deep Neural Network*. Proc. 2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). South Brisbane. 2015;4580-4584.

- [12] Xinpeng C, Lin M, Wenhao J, Jian Y, Wei L. *Regulazing RNNs for Caption Generation by Reconstructing The Past with The Present*. Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2018). Salt Lake. 2018; 7795–8003.
- [13] Wonmin B, Thomas MB, Federico R, Marcus L. *Scene Labeling with LSTM Recurrent Neural Networks*. Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2015). Boston. 2015; 3547–3555.
- [14] Hao Z, Dongxiao N, Min Y, Keke W, Yi L, Xiaomin X. *A Hybrid Deep Learning Model and Comparison for Wind Power Forecasting Considering Temporal-Spatial Feature Extraction*. Journal of Sustainability. 2020; 12(9490): 1-24.
- [15] Jaseena KU, Binsu CK. *Decomposition-based Hybrid Wind Speed Forecasting Model using Deep Bidirectional LSTM Networks*. Journal Elsevier Energy Conversion and Management. 2021; 234:1-26.