

PREDIKSI VISIBILITY MENGGUNAKAN LSTM DAN MLP DI BANDARA SULTAN MAHMUD BADARUDDIN II PALEMBANG

Fadel Muhammad Madjid¹, Tri Basuki Kurniawan¹

¹Program Studi Teknik Informatika, Fakultas Teknik Infomormatika, Universitas Binadarma, Palembang, Indonesia

email: madjid_fm96edu@gmail.com

Abstrak

Stasiun Meteorologi Sultan Mahmud Badaruddin II Palembang merupakan unit pelaksana tugas BMKG dalam melayani cuaca penerbangan di Bandara Sultan Mahmud Badaruddin II Palembang. Salah satu parameter cuaca adalah *visibility* (jarak mendarat) yang dilaporkan setiap 30 menit. *Visibility* merupakan salah satu faktor krusial dalam keselamatan sistem transportasi salah satunya penerbangan. *Visibility* rendah dapat berakibat pada gangguan lalu lintas transportasi hingga kecelakaan. Akan tetapi dalam membuat sebuah prakiraan cuaca cukup rumit karena adanya variabilitas masing-masing parameter cuaca. Penelitian ini berupaya untuk membuat prakiraan *visibility* dengan menggunakan model MLP dan LSTM. Dalam penelitian ini data yang digunakan adalah suhu, tekanan, kelembaban, dew point, kecepatan angin serta *visibility*. Data selama 24 jam tersebut digunakan untuk memprediksi *visibility* 3 jam kedepan, 6 jam ke depan serta 12 jam ke depan. Setelah itu, perbandingan antar metode dilakukan untuk mendapatkan metode yang paling bagus dalam memprakirakan *visibility*.

Kata kunci: *Visibility, prakiraan, MLP, LSTM*

Abstract

The Sultan Mahmud Badaruddin II Palembang Meteorological Station is the BMKG task force unit in serving the aviation weather at Sultan Mahmud Badaruddin II Airport Palembang. One of the weather parameters is visibility (horizontal distance) which is reported every 30 minutes. Visibility is one of the crucial factors in the safety of the transportation system, one of which is aviation. Low visibility can result in transportation traffic disruptions to accidents. However, making a weather forecast is quite complicated because of the variability of each weather parameter. This study attempts to forecast visibility using the MLP and LSTM models. In this study the data used are temperature, pressure, humidity, dew point, wind speed and visibility. The data for 24 hours is used to predict visibility for the next 3 hours, 6 hours and 12 hours ahead. After that, a comparison between methods is carried out to get the best method in predicting visibility.

Keywords: *Visibility, forecast, MLP, LSTM*

1. PENDAHULUAN

Visibility merupakan salah satu parameter cuaca yang berpengaruh dalam operasi dunia penerbangan. Oleh karena itu, Stasiun Meteorologi Sultan Mahmud Badaruddin II Palembang sebagai unit pelaksana tugas yang beroperasi di Bandara Sultan Mahmud Badaruddin II Palembang bertugas untuk menyampaikan laporan cuaca penerbangan kepada stakeholder terkait. Berdasarkan pada Perka Kep 001 Tahun 2009 Tentang Tata Cara Pelaksanaan Sandi Metar Dan Speci, laporan cuaca penerbangan yang dilakukan meliputi METAR/SPECI, LOCAL ROUTINE REPORT/SPECIAL yang dikirim setiap 30 menit selama 24 jam. Selain itu prakiraan cuaca penerbangan yang dikirim dengan format TAFOR yang dikirim setiap 6 jam sekali dalam 24 jam.

Visibility adalah jarak maksimum benda hitam di daerah mendarat yang dapat dilihat dan dikenali berdasarkan background yang lebih cerah [8]. *Visibility* yang rendah

akan berdampak pada pengoperasian lalu lintas hingga keselamatan transportasi. Secara umum *visibility* rendah yang diakibatkan oleh faktor cuaca adalah kabut, asap serta hujan dengan intensitas yang tinggi [1].

Meskipun bandara sudah dilengkapi dengan ILS (*Instrument Landing System*) yang canggih, pilot masih membutuhkan data *visibility* untuk keperluan take off dan mendarat [5]. Selain itu, *visibility* yang rendah dapat memicu terjadinya kecelakaan pesawat. Jika suatu ketika terjadi penurunan *visibility* yang signifikan, maka pilot akan memutuskan untuk menunggu cuaca semakin membaik (*rounding*) atau memutuskan untuk mendarat di bandara terdekat sesuai dengan kondisi cuaca dan bahan bakar [7]. Hal ini yang menyebabkan penerbangan penerbangan terganggu hingga berujung pada keterlambatan pesawat (*delay*) serta pembatalan penerbangan (*cancel*).

Kebanyakan bandara memakai *visibility* kurang dari 1600 m dan kurang dari 800 m untuk keselamatan *take off* dan *landing* [6]. Akan tetapi, dalam pembuatan prakiraan cuaca cukup menantang karena cuaca bersifat kontinu, dinamis, multidimensi dan bervariasi (Maqsood, 2004). Oleh karena itu, diperlukan cara untuk mempermudah dan meningkatkan efektivitas prakiraan cuaca terutama *visibility*. Teknologi informasi sekarang sudah meningkatkan efektivitas dalam mengumpulkan, menyimpan dan memproses sejumlah data yang besar. Hal ini menyebabkan keluaran informasi yang lebih efektif terutama dalam algoritma machine learning sendiri untuk keperluan di segala bidang.

Penelitian tentang machine learning dengan menggunakan data input data cuaca (suhu, tekanan, kelembaban udara serta angin) sudah dilakukan oleh [6] dan [3]. Akan tetapi, penelitian tersebut dilakukan di luar Indonesia dan berbeda kondisi iklim wilayahnya jika dibandingkan di Indonesia. Penelitian terkait estimasi *visibility* menggunakan *machine learning* di Indonesia juga masih minim. Tentunya jika penggunaan *machine learning* tersebut dapat diaplikasikan untuk perhitungan estimasi *visibility*, maka hal tersebut dapat membantu para prakirawan cuaca dalam membuat prakiraan cuaca. Hal ini dapat membantu mengatasi masalah cuaca yang bersifat kompleks dan non-linear baik secara temporal maupun spasial. Di dalam bidang *machine learning*, terdapat *neural network* yang bisa melakukan pendekatan dalam pemecahan permasalahan non-linear.

Dalam penelitian ini berupaya untuk mengeksplorasi 2 metode machine learning dengan menggunakan data pengamatan cuaca untuk estimasi prakiraan *visibility* untuk beberapa jam ke depan. Metode yang digunakan dalam penelitian ini adalah MLP (*Multi Layer Perceptron*) serta LSTM (*Long Short-Term Memory*). Penelitian ini mencoba untuk membandingkan 2 metode tersebut untuk mendapatkan metode terbaik dalam estimasi prakiraan *visibility* terutama di Bandara Sultan Mahmud Badaruddin II Palembang. Dalam penelitian ini bertujuan untuk memprediksi nilai *visibility* 3 jam ke depan, 6 jam ke depan serta 12 jam ke depan secara kontinu dengan menggunakan data parameter cuaca 24 jam terakhir.

1.1. Cuaca

Cuaca merupakan keadaan atmosfer pada tempat dan waktu yang sama [2]. Kondisi cuaca selalu dinamis dan perubahannya pun selalu bervariasi. Cuaca dapat bervariasi dalam jangka periode pendek dan dipengaruhi oleh topografi dari suatu tempat. Kondisi ini dipengaruhi oleh beberapa parameter cuaca seperti suhu, tekanan, kelembaban, awan, presipitasi, *visibility* serta angin [12].

Suhu udara permukaan merupakan data yang dicatat berdasarkan skala termometer bola kering yang terpasang dalam sangkar meteorologi dengan tinggi $\pm 1,2$ meter dari permukaan tanah. Suhu udara ini merupakan salah satu data untuk menentukan prakiraan maupun analisa cuaca [13]. Secara umum, kondisi dengan *visibility* rendah diikuti dengan suhu yang rendah jika dalam keadaan halimun atau kabut. Hal ini terjadi karena biasanya penurunan *visibility* terjadi pada saat dini hari hingga pagi dimana cahaya matahari belum bersinar. Besaran nilai suhu udara diukur dengan satuan derajat Celcius ($^{\circ}\text{C}$)

Secara umum, RH (kelembaban udara) merupakan gambaran jumlah uap air yang ada di udara dan dinyatakan dalam persen dari jumlah uap air maksimum kondisi jenuh. Data RH selalu diamati dan dilaporkan pada sandi sinoptik merupakan hasil perhitungan suhu thermometer bola kering dan basah. Secara umum, kondisi dengan *visibility* rendah diikuti dengan RH yang tinggi jika dalam keadaan halimun atau kabut. Hal ini terjadi karena penumpukan partikel massa udara basah yang menyebabkan penurunan *visibility* terjadi pada saat dini hari hingga pagi hari. Partikel massa udara yang mengumpul tersebut melayang di permukaan bumi dan menyebabkan jarak pandang menurun. Hal ini berbeda dengan keadaan cuaca kabut asap dimana RH cenderung rendah karena massa udara kering mengumpul di permukaan bumi. Besaran RH diukur dengan satuan persen (%).

Tekanan udara permukaan didefinisikan sebagai gaya atau berat yang diberikan oleh kolom udara di atas suatu permukaan kepada permukaan tersebut. Tekanan yang diberikan tersebut sebanding dengan massa udara secara vertikal di atas permukaan tersebut sampai pada batas lapisan atmosfer terluar, sehingga tekanan udara selalu berkurang dengan bertambahnya ketinggian. Tekanan yang dikoreksi dalam rata-rata permukaan laut dikoreksi menjadi QFF dan dilakukan oleh semua stasiun sinoptik [13]. Besaran nilai tekanan dihitung dalam satuan milibar (mb)

Suhu dimana udara menjadi jenuh disebut dew point atau titik embun. Pendinginan dalam udara akan menyebabkan kondensasi uap air [12]. Kejenuhan dapat dicapai jika penambahan kadar uap air melalui penguapan atau melalui pencampuran udara. Semakin dekat nilai titik embun dengan suhu udara maka RH akan cenderung tinggi. Besaran nilai titik embun dihitung dengan satuan derajat Celcius ($^{\circ}\text{C}$).


Angin merupakan suatu parameter cuaca yang memiliki 2 nilai yang terdiri dari arah dan kecepatan. Arah dan kecepatan angin dalam bidang meteorologi diukur dengan menggunakan anemometer [12]. Dalam bidang meteorologi, arah angin yang tercatat adalah arah dari angin tersebut. Semisal anemometer mengukur angin dan mengeluarkan nilai sebesar 90° , maka dapat diartikan bahwa arah angin dari arah Timur. Lalu, untuk kecepatan angin biasanya diukur dengan menggunakan besaran knot (kt). Di dalam pengoperasiannya, Stasiun Meteorologi SMB II Palembang mengukur arah & kecepatan angin di ketinggian 10 meter.

Visibility adalah jarak maksimum benda hitam di daerah mendatar yang dapat dilihat dan dikenali berdasarkan background yang lebih cerah [8]. *Visibility* dapat diukur dengan menggunakan alat otomatis serta pengamatan manual yang dilakukan oleh pengamat cuaca. Dalam pengamatan *visibility* yang menggunakan alat otomatis, *visibility* diukur dengan menggunakan sensor *visibility* yang terpasang di AWS (*Automatic Weather Station*). Sementara untuk pengamatan manual, *visibility* diamati oleh pengamat cuaca dengan membandingkan jarak pandang yang teramati dengan patokan jarak suatu

benda yang sudah diketahui jaraknya sebelumnya. Besaran nilai *visibility* dihitung dalam satuan meter (m).

1.2. LSTM

LSTM merupakan ANN yang memiliki *layer* yang banyak dan masuk ke dalam *Deep Learning*. LSTM mengambil input dalam bentuk matriks 2 dimensi (jumlah parameter x panjang parameter input) [11]. Dengan input seperti itu, LSTM terdiri dari banyak sel dimana 1 sel akan mengambil input 1 nilai dari parameter input secara urut. Output LSTM dalam bentuk matriks 2 dimensi (panjang urut parameter x *hidden state*). *Hidden state* merupakan suatu parameter konstanta untuk LSTM yang analog dengan *hidden neuron*. Pada kasus pemetaan masukan *many to one*, output LSTM akan melewati *layer* terakhir yang disebut *fully connected layer* untuk mendapatkan output sebenarnya. Matriks yang digabungkan antara (x_t dan h_{t-1}) sebelum memasuki *layer* neuron pada sel LSTM akan memiliki bentuk (*hidden state* ditambah panjang urut parameter input x *hidden state*).



Gambar 1. LSTM

Dalam 1 sel terdiri dari beberapa *gate* yaitu *forget gate*, *input gate* serta *output gate*. Sel LSTM akan mengeluarkan 2 output yang keduanya akan diteruskan lagi ke sel-sel selanjutnya dalam barisan sel LSTM. Salah satu output yang dikeluarkan diteruskan ke sel LSTM yang membuat hubungan urut pada parameter masukan sel LSTM dinamakan *cell state*. *Cell state* akan diteruskan ke sel selanjutnya setelah mendapatkan informasi dari *input gate*. Tujuan dari *gate* adalah untuk melakukan pembaruan pada *cell state*.

Forget gate adalah *gate* yang menentukan seberapa besar informasi yang dibiarkan lewat. Jika *cell state* bernilai 1 maka akan dibiarkan lewat, sementara jika bernilai 0 tidak akan dibiarkan lewat. Alurnya adalah *output* dari sel rangkaian sebelumnya (h_{t-1}) matriks di gabungkan dengan *input* pada runtut sel sekarang (x_t). Matriks ini dinamakan matriks *concat*. Informasi yang telah digabungkan tersebut kemudian akan melalui *layer neuron* dengan fungsi aktivasi σ dan menjadi f_t . kemudian f_t dikalikan secara *element wise* dengan *cell state* output rangkaian sebelumnya (c_{t-1}).


Setelah itu, *cell state* akan diupdate oleh *input gate*. Gate ini bertujuan untuk mengupdate nilai pada *cell state* melalui operasi penjumlahan matriks. Alurnya adalah matriks *concat* akan melewati *layer neuron* dengan fungsi aktivasi σ dan *layer neuron* lainnya dengan fungsi aktivasi *tanh* secara terpisah. Output dari kedua *layer* itu kemudian akan dikalikan secara *element wise* lalu hasilnya dijumlah secara *element wise* dengan c_{t-1} .

Terakhir adalah *output gate*. Gate ini merupakan pembeda antara output sel sesungguhnya dan *cell state*. *Cell state* akan langsung diteruskan ke rangkaian sel selanjutnya (jika masih ada) sebagai c_t . Sementara output sebenarnya untuk menjadi h_t dan diteruskan lagi ke rangkaian sel selanjutnya (jika masih ada), matriks *concat* yang akan menjadi cikal bakal output akan melewati *layer neuron* dengan fungsi aktivasi σ . Salinan dari matriks *cell state* akan diproses oleh fungsi *tanh* (bukan *layer neuron*) secara *element*

wise. Matriks concat dan salinan dari *cell state* kemudian saling dikalikan secara *element wise* dan menjadi output dari sel rangkaian ini h_t .

1.3. MLP

MLP (*Multi Layer Perceptron*) merupakan Jaringan Saraf Tiruan yang termasuk ke dalam bagian jaringan *feedforward* dan *supervised machine learning* [9]. MLP terdiri dari beberapa *neuron* yang terhubung dengan menggunakan bobot. Setiap bobot terhubung ke setiap bobot pada lapisan berikutnya [11]. Jaringan MLP terdiri dari 3 atau lebih *layer* yaitu satu *layer input*, satu atau lebih *hidden layer* dan satu *layer output*. *Input layer* menerima sinyal dari luar dan meneruskan ke *hidden layer* pertama dan akan berlanjut hingga mencapai *output layer*.

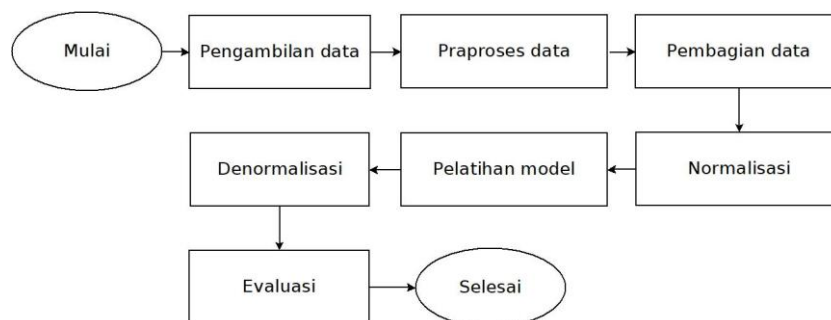


Gambar 2. MLP

Model ini diketahui sebagai jaringan yang terkoneksi penuh (*Fully Connected Network*), dimana *neuron* pada *layer* l_i terkoneksi dengan *neuron* lain pada *layer* l_{i-1} . Sebagai tambahan, *neuron* terorganisir dalam *layer* yang terkoneksi secara maju ke depan dari *layer* satu ke *layer* lain. Pelatihan MLP bertujuan untuk menyesuaikan nilai *output* dengan pola pasangan *input* yang dimasukkan. Proses pelatihan tersebut secara iterasi menentukan bobot-bobot koneksi antar *neuron* agar optimal. Jaringan MLP yang telah dilatih diharapkan memberikan hasil yang baik. *Multi Layer Perceptron* merupakan jaringan yang menggunakan algoritma *backpropagation* yang meliputi 3 tahap yaitu umpan maju (*feed forward*) dari pola *input*, perhitungan dan propagasi balik dari *error* serta penyesuaian bobot.

2. METODE

Penelitian ini terdiri dari identifikasi masalah, pengumpulan data, praproses data, perancangan model LSTM dan MLP, pelatihan masing-masing model serta pengujian masing-masing model. Tahapan penelitian ini dapat digambarkan sebagai gambar 3 berikut.



Gambar 3. Diagram alir

Pada penelitian ini menggunakan data parameter cuaca seperti suhu, dew point, RH (kelembaban udara), tekanan udara permukaan, kecepatan angin permukaan serta *visibility* setiap jam dengan rentang antara tahun 2016 hingga 2020. Data tersebut diambil dari Stasiun Meteorologi Sultan Mahmud Badaruddin II Palembang yang berlokasi di Bandara Internasional Sultan Mahmud Badaruddin II Palembang. Data parameter cuaca tersebut masih dalam keadaan mentah sehingga perlu dilakukan praproses data seperti penggabungan data, pembersihan data serta penambahan data yang kosong.

Setelah data dianggap sudah lengkap maka dilakukan pembagian data yang terdiri dari data pelatihan dan evaluasi. Pada penelitian ini perbandingan antara data pelatihan dan evaluasi adalah 70:30. Pembagian data tersebut bertujuan untuk melatih model dengan menggunakan data pelatihan serta mengevaluasi model tersebut dengan menggunakan data evaluasi. Selain itu, untuk meminimalisir variasi data serta mempercepat proses dalam menjalankan model maka dilakukan normalisasi data. Normalisasi data dalam penelitian ini menggunakan min-max scalling dengan rumus sebagai berikut.

$$X_n = \frac{X_0 - X_{min}}{X_{max} - X_{min}} \quad (1)$$

Dimana:

X_n adalah nilai hasil normalisasi; X_0 adalah nilai data actual; X_{max} adalah nilai maksimum dari data actual; X_{min} adalah nilai minimum dari data actual

2.1. Perancangan model

Perancangan model dalam penelitian ini bertujuan untuk mendapatkan hasil yang bagus dalam memprediksi *visibility*. Oleh karena itu, diperlukan *setting hyperparameter* untuk mencapai hal tersebut. Dalam penelitian ini *setting hyperparameter* yang dilakukan adalah dengan merubah masing-masing parameter secara berturut-turut yaitu jumlah lapisan tersembunyi (*hidden layer*), *node (neuron)* masing-masing *layer*, penambahan *dropout rate* untuk meminimalisir terjadinya *overfitting* serta *epoch* (jumlah putaran) sebanyak 100 untuk setiap model.

Dalam model LSTM hyperparameter setting memakai batch size sebesar 256, activation function tanh, optimizer adam, dropout rate sebesar 0.25 serta epoch sebesar 100. Lalu untuk model MLP hyperparameter setting memakai batch size sebesar 256, activation function tanh, optimizer adam, dropout rate sebesar 0.1 serta epoch sebesar 100. Sementara itu, penelitian ini membatasi node setiap layer sejumlah 150 hingga 300. Selain itu, dalam tiap model tersebut menggunakan early stop untuk menghentikan *epoch* jika nilai loss pada fase pelatihan tidak menurun secara signifikan serta mempercepat komputasi.

Penelitian ini merupakan model *multivariate multisteps* sehingga jumlah output didasarkan pada jumlah data *visibility* yang akan diprediksi ke depannya. Dalam penelitian ini bertujuan untuk memprediksi nilai *visibility* secara kontinu pada 3 jam kedepan (t+3), 6 jam kedepan (t+6) serta 12 jam kedepan (t+12). Oleh karena itu, jika model digunakan untuk memprediksi 3 jam ke depan, maka jumlah *output* pada model tersebut bernilai 3. Jika model digunakan untuk memprediksi 6 jam ke depan, maka jumlah *output* pada model tersebut bernilai 6. Sama halnya untuk prediksi 12 jam ke depan, maka *output* dalam model tersebut bernilai 12. Dengan demikian ada 3 model LSTM dan 3 model MLP terbaik yang akan dibandingkan untuk mencari 3 model terbaik dalam memprediksi *visibility*.

2.2. Pelatihan

Pada penelitian ini fase pelatihan didasarkan pada *setting hyperparameter* masing-masing model. Masing-masing model dengan *setting hyperparameter* tersebut untuk menghitung *train loss* dan *evaluation loss*. Hal ini bertujuan untuk mengetahui nilai *loss* pada saat pelatihan serta nilai *loss* pada evaluasi pada masing-masing rancangan model. Selain itu, nilai *loss* setiap iterasi berdasarkan kurva pembelajaran menunjukkan seberapa optimal model mempelajari semesta data model. Nilai *loss* dihitung menggunakan MAE (*mean absolute error*) dengan rumus sebagai berikut.

$$MAE = \frac{1}{n} \sum_{i=1}^n |A_i - F_i| \quad (2)$$

Dimana:

N adalah ukuran sampel; A_i adalah nilai data actual ke-i; F_i adalah nilai data prediksi ke-i.

2.3. Evaluasi

Langkah selanjutnya dalam penelitian ini adalah mengevaluasi hasil prediksi dari model tersebut dengan data evaluasi. Hasil prediksi model tersebut harus dinormalisasi untuk mendapatkan nilai yang nyata karena nilai hasil prediksi masih dalam bentuk normalisasi. Berikut adalah rumus untuk denormalisasi data.

$$dn_i = (n_i + 1)(X_{max} - X_{min}) + \left(\frac{2(X_{min})}{2}\right) \quad (3)$$

Dimana:

dn_i adalah data denormalisasi ke i; n_i adalah data normalisasi ke i; X_{min} adalah data minimum; X_{max} adalah data maksimum.

Setelah mendapatkan hasil nyata dari masing-masing nilai *visibility*, langkah selanjutnya adalah mengevaluasi data prediksi *visibility* tersebut dengan data evaluasi yang sudah tersedia. Dalam penelitian ini evaluasi yang digunakan adalah RMSE (*Root Mean Square Error*) pada masing-masing model terbaik dari LSTM dan MLP. Nilai RMSE didapatkan dengan rumus sebagai berikut.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (A_i - F_i)^2}{n}} \quad (4)$$

Dimana:

N adalah ukuran sampel; A_i adalah nilai data actual ke-i; F_i adalah nilai data prediksi ke-i.

3. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan parameter cuaca seperti *visibility*, suhu, t_d , r_h , tekanan dan kecepatan angin selama 24 jam untuk memprediksi nilai *visibility* pada 3 jam ke depan, 6 jam ke depan serta 12 jam ke depan. Oleh karena itu, untuk menentukan model yang dapat memprediksi nilai *visibility* yang bagus dapat dilihat dari seberapa besar selisih antara nilai prediksi *visibility* dibandingkan dengan data aktual *visibility* sesuai dengan langkah waktunya. Dalam penelitian ini tentu membandingkan model LSTM terbaik dengan model MLP terbaik dalam setiap langkah waktu.

3.1. Prediksi 3 jam ke depan

<i>Node hidden layer</i>	<i>Dropout rate</i>	<i>Epoch</i>	<i>Train Loss</i>	<i>Val Loss</i>	RMSE
100	0.1	59	0.1802	0.1743	6237

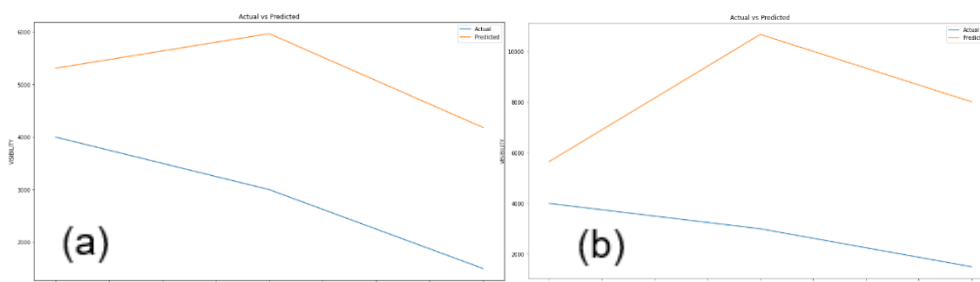
150	0.1	57	0.1896	0.1837	5554
200	0.1	21	0.2164	0.2412	5447
250	0.1	44	0.1810	0.1721	5797
300	0.1	43	0.1612	0.1774	6441

Tabel 3.1 Pemilihan node hidden layer prediksi MLP 3 jam ke depan

Hidden layer 1	Hidden layer 2	Dropout rate	Epoch	Train loss	Eval loss	RMSE
200	150	0.25	100	0.2246	0.2357	2429
200	200	0.25	100	0.2497	0.2625	3153
250	150	0.25	100	0.2387	0.2499	5370
150	150	0.25	100	0.2504	0.2607	4946
150	100	0.25	100	0.2431	0.2388	2922

Tabel 3.2 Pemilihan node hidden layer prediksi LSTM 3 jam ke depan

Berdasarkan evaluasi nilai RMSE terhadap data evaluasi yang dibandingkan dengan data prediksi untuk 3 jam ke depan pada LSTM dengan menggunakan *node hidden layer* pertama 200 serta *node hidden layer* kedua 150 memiliki nilai RMSE terendah yaitu sebesar 2429 m. Sementara evaluasi nilai RMSE terhadap data evaluasi yang dibandingkan dengan data prediksi untuk 3 jam ke depan pada MLP dengan menggunakan *node hidden layer* 200 memiliki nilai RMSE terendah yaitu sebesar 5447 m. Oleh karena itu, model terbaik untuk memprediksi nilai *visibility* 3 jam ke depan dengan menggunakan 6 parameter cuaca 24 jam sebelumnya adalah model LSTM.



Gambar 3.1 Plot prediksi LSTM (a) dan MLP 3 jam ke depan (b)

3.2. Prediksi 6 jam ke depan

Node hidden layer	Dropout rate	Epoch	Train Loss	Val Loss	RMSE
100	0.1	60	0.1910	0.1850	5705
150	0.1	57	0.1980	0.2036	5190
200	0.1	52	0.1876	0.1843	6190
250	0.1	20	0.2264	0.2150	4675
300	0.1	17	0.1824	0.2024	5285


Tabel 3.3 Pemilihan node hidden layer prediksi MLP 6 jam ke depan

Hidden layer 1	Hidden layer 2	Dropout rate	Epoch	Train loss	Eval loss	RMSE
200	150	0.25	100	0.2101	0.2128	2305
200	200	0.25	28	0.2508	0.2974	3531

250	150	0.25	45	0.2455	0.2379	1464
150	150	0.25	70	0.2496	0.2435	5246
150	100	0.25	81	0.2437	0.2238	3340

Tabel 3.4 Pemilihan node hidden layer prediksi LSTM 6 jam ke depan

Berdasarkan evaluasi nilai RMSE terhadap data evaluasi yang dibandingkan dengan data prediksi untuk 6 jam ke depan pada LSTM dengan menggunakan *node hidden layer* pertama 250 serta *node hidden layer* kedua 150 memiliki nilai RMSE terendah yaitu sebesar 1464 m. Sementara evaluasi nilai RMSE terhadap data evaluasi yang dibandingkan dengan data prediksi untuk 3 jam ke depan pada MLP dengan menggunakan *node hidden layer* 250 memiliki nilai RMSE terendah yaitu sebesar 4675 m. Oleh karena itu, model terbaik untuk memprediksi nilai *visibility* 6 jam ke depan dengan menggunakan 6 parameter cuaca 24 jam sebelumnya adalah model LSTM.



Gambar 3.2 Plot prediksi LSTM (a) dan MLP 6 jam ke depan (b)

3.3. Prediksi 12 jam ke depan

Node Hidden Layer	Dropout rate	Epoch	Train Loss	Val Loss	RMSE
100	0.1	33	0.2168	0.2099	3704
150	0.1	41	0.2315	0.2397	3557
200	0.1	39	0.2290	0.2024	4943
250	0.1	54	0.2296	0.2130	4924
300	0.1	33	0.2062	0.2042	5328

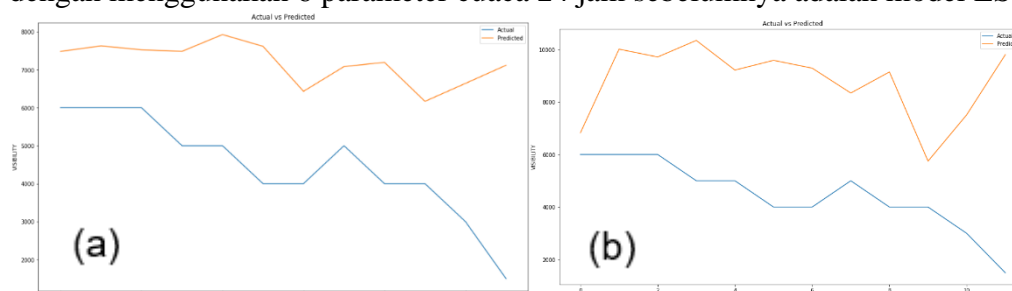
Tabel 3.5 Pemilihan node hidden layer prediksi MLP 12 jam ke depan

Hidden layer 1	Hidden layer 2	Dropout rate	Epoch	Train loss	Eval loss	RMSE
200	150	0.25	90	0.2184	0.2214	3406
200	200	0.25	42	0.2320	0.2312	3500
250	150	0.25	43	0.2631	0.2500	2958
150	150	0.25	100	0.2152	0.2098	3904
150	100	0.25	78	0.2265	0.2311	3227

Tabel 3.6 Pemilihan node hidden layer prediksi LSTM 12 jam ke depan

Berdasarkan evaluasi nilai RMSE terhadap data evaluasi yang dibandingkan dengan data prediksi untuk 12 jam ke depan pada LSTM dengan menggunakan *node hidden layer* pertama 250 serta *node hidden layer* kedua 150 memiliki nilai RMSE terendah yaitu sebesar 2958 m. Sementara evaluasi nilai RMSE terhadap data evaluasi yang dibandingkan dengan data prediksi untuk 12 jam ke depan pada MLP dengan menggunakan *node hidden layer* 150 memiliki nilai RMSE terendah yaitu sebesar 3557

m. Oleh karena itu, model terbaik untuk memprediksi nilai *visibility* 12 jam ke depan dengan menggunakan 6 parameter cuaca 24 jam sebelumnya adalah model LSTM.



Gambar 3.3 Plot prediksi LSTM (a) dan MLP 12 jam ke depan (b)

3.4. Pembahasan

Berdasarkan pada tabel pemilihan *node* pada *hidden layer* pada masing-masing model memiliki jumlah yang berbeda. *Node* pada *hidden layer* berfungsi untuk mengolah nilai input lalu menghubungkannya dengan *node output*, sehingga jumlah *node* pada *hidden layer* menentukan nilai output yang dihasilkan oleh model LSTM dan model MLP. Tidak ada aturan pasti dalam menentukan jumlah *node* pada *hidden layer* yang optimal untuk memprediksi data khususnya pada data *visibility* seperti pada penelitian ini. Oleh karena itu, sebagai langkah dalam mendapatkan jumlah *node* pada *hidden layer* perlu melakukan percobaan dengan merubah masing-masing jumlah *node* pada *hidden layer*.

Hal ini menandakan bahwa pembelajaran pada model LSTM lebih unggul daripada model MLP. Lalu, berdasarkan selisih pada prediksi nilai *visibility* model LSTM lebih unggul dalam memprediksi nilai *visibility* baik untuk 3 jam ke depan, 6 jam ke depan serta 12 jam ke depan daripada model MLP. Hal ini sesuai dengan (Freire, 2021) yang menyebutkan bahwa model LSTM dapat secara kompleks mampu mempelajari dinamika data. Model LSTM dapat bekerja lebih baik karena memiliki *memory cell* sehingga dapat mengingat informasi untuk periode waktu lebih lama.

4. KESIMPULAN

Berdasarkan pada perbandingan nilai RMSE data evaluasi, masing-masing model prediksi nilai *visibility* menunjukkan bahwa model LSTM lebih bagus untuk memprediksi *visibility* 3 jam ke depan, 6 jam ke depan serta 12 jam ke depan. Sementara untuk memprediksi *visibility* 6 jam lebih baik menggunakan model MLP.

DAFTAR PUSTAKA

- [1] Abdel-Aty MA, Lee J. Investigation of Low Visibility Related Crashes in Florida, Orlando. 2019.
- [2] Ahrens CD. Meteorology Today An Introduction to Weather, Climate, and the Environment. Ninth Edition. 2009.
- [3] Bueno CL, Mateo CC, Justo JS, Prada EC, Sanz SS. Efficient Prediction of Low Visibility Events at Airports Using Machine-Learning Regression. 2017. Boundary-Layer Meteorology.
- [4] BMKG. Tata Cara Tetap Pelaksanaan Sandi Metar Dan Speci. Kep 001/2009. 2009.

- [5] Colabone RO, Ferrari AL, Vecchia FAS, Tech, ARB. Application of Artificial Neural Network for Fog Forecast. 2015. Journal of Aerospace Technology and Management.
- [6] Deng T, Cheng A, Han W, Lin HX. Visibility Forecast for Airport Operations by LSTM Neural Network. 2019. Journal Computer.
- [7] Dewi R, Prawito, Harsa H. Fog Predicyion Using Artificial Intelligence: A Case Study in Wamena Airport. 2019. J. Phys: Conf. Ser. 1528 012021.
- [8] International Civil Aviation Organization (ICAO). Manual on Low Level Wind Shear, Doc 9817 AN/449. 2005.
- [9] Maqsood, I., Khan, M., Abraham, A., An ensemble of neural networks for weather forecasting. Neural Comput. 2004; 13; 2: 112–122.
- [10] Nair V, Hinton GE. Rectified Linear Units Improve Restricted Boltzmann Machines, 2010. Proc. 27th Int. Conf. Mach. Learn.
- [11] Oktavianti I, Ernatita, Rini DP. Analisis Pola Prediksi Data Time Series menggunakan Support Vector Regression, Multilayer Perceptron, dan Regresi Linear Sederhana. Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi). 2019; 3: 2: 282 – 287.
- [12] Tjasyono BHK, Harijono SWB. Meterologi Indonesia II, Jakarta : BMKG. 2012.
- [13] Zakir A, Sulistya W, Khotimah M K. Perspektif Operasional Cuaca Tropis. Badan Meteorologi Klimatologi dan Geofisika. Jakarta. 2012