



JURNAL STATISTIKA DAN SAINS DATA

Volume 3 Edisi 2, April, 2026, 154-163

<https://journal.student.uny.ac.id/index.php/jssd>

<https://dx.doi.org/10.21831/jssd.v3i2.23754>

Prediksi jumlah barang yang dimuat di Bandara Soekarno-Hatta dengan metode Elman Recurrent Neural Network

Hidayat Setiawan*, Universitas Negeri Yogyakarta
Dhoriva Urwatul Wustqa, Universitas Negeri Yogyakarta
*e-mail: hidayatsetiawan.2018@student.uny.ac.id

Abstrak.Transportasi udara berperan penting dalam mendukung mobilitas masyarakat dan pertumbuhan ekonomi, termasuk dalam distribusi barang melalui bandara. Penelitian ini bertujuan membangun model prediksi jumlah barang yang dimuat di Bandara Soekarno Hatta menggunakan metode Elman Recurrent Neural Network (ERNN). Data yang digunakan adalah jumlah kunjungan wisatawan periode Januari 2006 hingga Desember 2022 yang diperoleh dari Badan Pusat Statistik, karena pola kunjungan ini dianggap berkorelasi dengan pergerakan barang. Pemilihan variabel input dilakukan berdasarkan hasil analisis autokorelasi (ACF) dan autokorelasi parsial (PACF), dengan menggunakan lag signifikan dari data kunjungan wisatawan. Data dibagi menjadi dua bagian, yaitu 80% untuk pelatihan dan 20% untuk pengujian. Model terbaik dipilih berdasarkan nilai mean absolute percentage error (MAPE) terkecil. Uji residual dilakukan untuk memastikan bahwa hasil prediksi bersifat white noise, yang menunjukkan kecocokan model. Model ERNN terbaik memiliki 10 variabel input, 3 neuron tersembunyi, dan 1 output. Hasil evaluasi menunjukkan MAPE sebesar 44,55% pada data pelatihan dan 14,68% pada data pengujian. Ini menunjukkan bahwa model mampu memberikan prediksi yang cukup akurat pada data testing.

Kata Kunci: *Barang, Elman Recurrent Neural Network, prediksi, white noise, kunjungan wisatawan*

Abstrac. Air transportation plays a crucial role in supporting public mobility and economic growth, including the distribution of goods through airports. This study aims to develop a prediction model for the amount of cargo loaded at Soekarno-Hatta Airport using the Elman Recurrent Neural Network (ERNN) method. The data used is the number of tourist visits from January 2006 to December 2022 obtained from the Central Statistics Agency, as this visitation pattern is considered correlated with the movement of goods. The selection of input variables is based on the results of autocorrelation (ACF) and partial autocorrelation (PACF) analysis, using significant lags from tourist visitation data. The data is divided into two parts, 80% for training and 20% for testing. The best model is chosen based on the lowest mean absolute percentage error (MAPE) value. Residual testing is conducted to ensure that the prediction results are white noise, indicating model fit. The best ERNN model has 10 input variables, 3 hidden neurons, and 1 output. Evaluation results show a MAPE of 44.55% on training data and 14.68% on testing data. This indicates that the model is able to provide fairly accurate predictions on testing data.

Keywords: *Cargo, Elman Recurrent Neural Network, prediction, white noise, tourist visits*

PENDAHULUAN

Transportasi merupakan elemen fundamental dalam mendukung pembangunan dan aktivitas ekonomi suatu negara. Mobilitas manusia dan distribusi barang sangat bergantung pada sistem transportasi yang efisien. Di antara berbagai moda transportasi, transportasi udara menjadi pilihan utama bagi masyarakat modern yang mengutamakan kecepatan, kenyamanan, dan efisiensi waktu. Pesawat terbang, sebagai bagian dari moda ini, semakin diminati seiring meningkatnya daya beli masyarakat dan pertumbuhan ekonomi nasional. Di Indonesia sendiri, sekitar 20% dari masyarakat memilih menggunakan transportasi udara, mengungguli transportasi laut, darat, dan kereta api dalam proporsi penggunaannya. Selain menghubungkan daerah-daerah terpencil dengan pusat-pusat ekonomi, transportasi udara juga memfasilitasi arus barang dalam konteks perdagangan domestik dan internasional. Perkembangan industri penerbangan nasional mengalami lonjakan signifikan sejak pemerintah membuka peluang pendirian maskapai baru pada tahun 2000. Hal ini memicu persaingan antar maskapai dalam menawarkan layanan, harga, dan promosi terbaik untuk menarik pelanggan. Meski dihadapkan pada tantangan seperti naiknya harga bahan bakar dan regulasi ketat, sektor ini tetap tumbuh dengan cepat, mendorong inovasi di bidang layanan dan teknologi penerbangan. Di balik kelancaran aktivitas penerbangan, keberadaan infrastruktur bandara menjadi sangat penting. Bandara tidak hanya berfungsi sebagai titik awal dan akhir perjalanan udara, tetapi juga sebagai pusat logistik dan distribusi barang. Fasilitas utama di bandara seperti terminal penumpang dan terminal kargo berperan vital dalam memastikan efisiensi operasional. Terminal penumpang menyediakan berbagai fasilitas penunjang kenyamanan dan keselamatan penumpang, sedangkan terminal kargo menangani proses bongkar muat barang yang diangkut melalui udara. Volume dan karakteristik kargo yang dilayani sangat memengaruhi kebutuhan kapasitas dan pengelolaan terminal kargo di suatu bandara.

Bandara Internasional Soekarno-Hatta merupakan salah satu bandara tersibuk di Asia Tenggara. Menurut data tahun 2019, bandara ini menempati posisi ke-25 dunia dalam hal lalu lintas penumpang. Selain menjadi gerbang utama Indonesia, Soekarno-Hatta juga menjadi pusat distribusi logistik melalui jalur udara. Namun, pandemi Covid-19 pada tahun 2020 berdampak besar terhadap sektor penerbangan global, termasuk Bandara Soekarno-Hatta. Pembatasan perjalanan, kekhawatiran akan keselamatan, serta penurunan aktivitas ekonomi mengakibatkan penurunan tajam jumlah penumpang dan volume kargo. Data dari BPS menunjukkan penurunan penumpang domestik sebesar 55,27% dan internasional sebesar 80,63% dibandingkan tahun sebelumnya. Meskipun demikian, terdapat sinyal positif terhadap pemulihan industri ini. Menjelang akhir tahun 2020, tercatat kenaikan jumlah penumpang di Soekarno-Hatta sebesar 13,17% dari bulan November ke Desember. Pada sektor kargo, meskipun sempat menurun dari 21,2 ton pada 2018 menjadi 14,7 ton pada 2019, volume kargo kembali meningkat pada 2021 dan 2022. Selama periode Januari–Juni 2021, tercatat 271.769 ton kargo ditangani, dan selama masa angkutan Lebaran 2022, volume mencapai 32.365 ton, menjadikan Soekarno-Hatta tetap sebagai bandara dengan lalu lintas kargo tertinggi di Indonesia. Dalam konteks perencanaan dan pengelolaan bandara, prediksi volume barang dan penumpang menjadi aspek penting. Variasi jumlah barang yang dibawa oleh penumpang, perbedaan tarif antar maskapai, serta fluktuasi musiman menuntut adanya sistem yang mampu memprediksi secara akurat volume kargo yang akan datang. Oleh karena itu, dibutuhkan metode peramalan yang andal dan mampu menangani data bersifat deret waktu (*time series*).

Peramalan (*forecasting*) merupakan proses menganalisis data historis untuk memperkirakan kejadian di masa depan. Model peramalan tradisional seperti regresi atau ARIMA sering digunakan, namun pendekatan berbasis kecerdasan buatan kini makin banyak diterapkan karena keakuratannya yang lebih tinggi. Salah satu metode yang terbukti efektif

dalam analisis data time series adalah Jaringan Saraf Tiruan (JST), khususnya model Elman Recurrent Neural Network (ERNN).

ERNN merupakan varian dari Recurrent Neural Network (RNN) yang memiliki kemampuan untuk menyimpan dan memproses informasi dari waktu sebelumnya melalui lapisan konteks. Ini membuat ERNN sangat cocok digunakan dalam memodelkan data time series, di mana hubungan antar data historis sangat memengaruhi nilai masa depan. Arsitektur ERNN menggunakan algoritma backpropagation dan memiliki lapisan tersembunyi yang dilengkapi dengan bobot dan fungsi aktivasi non-linear seperti sigmoid atau tansig, sementara output menggunakan fungsi linear seperti purelin. Berbagai penelitian sebelumnya menunjukkan keberhasilan model ini. Misalnya, (Hawas,2020) menggunakan RNN untuk memprediksi kasus Covid-19 di Brazil dengan akurasi 85%. Penelitian oleh (Yanti dkk.,2019) dalam memprediksi radiasi matahari mencatat akurasi hingga 96,33%. Sementara itu, Sitinjak (2023) menggunakan ERNN untuk memprediksi persediaan barang dan mendapatkan nilai MAPE rendah dengan konfigurasi tertentu. Hal ini menunjukkan bahwa ERNN tidak hanya unggul dalam satu domain, tetapi juga adaptif di berbagai bidang, termasuk transportasi dan logistik. Melalui penelitian ini, akan dilakukan prediksi jumlah barang yang dimuat di Bandara Soekarno-Hatta berdasarkan data bulanan dari Januari 2006 hingga Agustus 2022. Dengan menggunakan metode Elman Recurrent Neural Network, diharapkan dapat diperoleh model prediksi yang akurat dan bermanfaat dalam pengambilan keputusan oleh pengelola bandara dan stakeholder lainnya. Hasil penelitian ini diharapkan mampu mendukung perencanaan kapasitas, efisiensi operasional, serta peningkatan layanan kargo di Bandara Soekarno-Hatta di masa mendatang.

METODE

Penelitian ini menggunakan data sekunder yang diperoleh dari situs resmi Badan Pusat Statistik (BPS) di alamat <https://www.bps.go.id>. BPS merupakan lembaga resmi yang menyediakan berbagai macam informasi statistik nasional yang valid dan dapat dipertanggungjawabkan. Dalam konteks penelitian ini, data yang digunakan secara spesifik adalah jumlah barang yang dimuat di Bandara Soekarno-Hatta, salah satu bandara utama di Indonesia. Data yang dikumpulkan mencakup periode waktu yang cukup panjang, yaitu dari bulan Januari 2006 hingga bulan Agustus 2022. Selama periode tersebut, berhasil dikumpulkan sebanyak 205 titik data. Data ini menjadi dasar dalam proses analisis dan pemodelan prediksi. Seluruh rincian data yang digunakan dapat ditemukan pada Lampiran 1.

Langkah-Langkah Penelitian

Penelitian ini menerapkan metode Elman Recurrent Neural Network (ERNN), sebuah varian dari jaringan saraf tiruan (*Neural Network*) yang dikembangkan dari model feedforward. ERNN memiliki keunggulan dalam menangani data runtun waktu (*time series*) karena memiliki struktur umpan balik (*feedback loop*) yang memungkinkan jaringan mengingat informasi dari waktu sebelumnya. Pemodelan dilakukan menggunakan perangkat lunak Python, dengan tahapan-tahapan teknis sebagai berikut:

Menentukan Input : Tahapan awal dalam pemodelan ERNN adalah menentukan variabel input yang akan digunakan. Input ini diperoleh dengan mengidentifikasi pola dari fungsi autokorelasi (ACF) dan autokorelasi parsial (PACF) terhadap data deret waktu. Lag yang menunjukkan nilai autokorelasi atau autokorelasi parsial yang signifikan akan dipilih sebagai variabel input. Misalnya, jika lag 1, lag 2, dan lag 3 memiliki nilai signifikan, maka input yang digunakan dalam model adalah data pada waktu $t-1$, $t-2$, dan $t-3$.

Pembagian Data : Setelah menentukan input, langkah berikutnya adalah membagi data ke dalam dua kelompok utama: data pelatihan (training) dan data pengujian (testing). Dalam penelitian ini, pembagian dilakukan secara proporsional dengan perbandingan 80% untuk training dan 20% untuk testing. Pembagian ini dilakukan melalui proses trial and error, dengan mengevaluasi performa model berdasarkan nilai Mean Absolute Percentage Error (MAPE) yang dihasilkan dari prediksi pada masing-masing set data.

Normalisasi Data : Data yang telah dibagi kemudian dinormalisasi agar lebih mudah diproses oleh model jaringan saraf. Normalisasi dilakukan menggunakan distribusi normal, yang membantu menyamakan skala antar data sehingga proses pelatihan model menjadi lebih stabil dan cepat. Normalisasi ini menghasilkan data dengan nilai mean mendekati nol dan standar deviasi satu.

Pembentukan dan Pemilihan Model ERNN Terbaik : Setelah proses normalisasi, tahap berikutnya adalah pembentukan model ERNN. Model ini dibangun dengan menggunakan algoritma backpropagation. Pemilihan model terbaik dilakukan dengan mencoba berbagai konfigurasi jumlah neuron pada lapisan tersembunyi (hidden layer). Tujuannya adalah menemukan struktur jaringan yang menghasilkan tingkat akurasi tertinggi, yaitu dengan nilai MAPE terkecil pada data pelatihan dan pengujian. Proses pembentukan model meliputi inisialisasi bobot awal, penentuan jumlah epoch maksimum, target error, serta proses feedforward dan backpropagation hingga model menghasilkan output yang optimal.

Denormalisasi : Setelah model menghasilkan prediksi, data yang telah dinormalisasi perlu dikembalikan ke skala aslinya melalui proses denormalisasi. Hal ini penting agar hasil prediksi bisa dibandingkan secara langsung dengan data asli dan memiliki makna dalam konteks nyata. Tanpa proses ini, hasil model hanya akan merepresentasikan data dalam skala standar, bukan dalam satuan sebenarnya.


Uji White Noise : Untuk mengevaluasi kelayakan model, dilakukan uji white noise terhadap error atau sisa hasil prediksi. Uji ini dilakukan dengan menganalisis plot ACF dan PACF dari error model. Jika tidak ditemukan autokorelasi yang signifikan pada setiap lag, maka error dinyatakan bersifat white noise, artinya model sudah tidak memiliki pola yang bisa diprediksi lebih lanjut dan cocok untuk digunakan dalam proses prediksi.

Analisis Hasil Prediksi : Tahap akhir dari penelitian adalah melakukan analisis terhadap hasil prediksi jumlah barang yang dimuat di Bandara Soekarno-Hatta menggunakan model ERNN terbaik. Prediksi ini didasarkan pada struktur model dengan konfigurasi optimal yang telah melalui tahapan-tahapan sebelumnya. Hasil prediksi kemudian digunakan untuk mengevaluasi seberapa baik model dalam menangkap pola historis dan menghasilkan estimasi yang akurat terhadap nilai di masa depan.


HASIL DAN PEMBAHASAN

PEMBAHASAN

Data yang digunakan adalah data jumlah barang yang dimuat dari tahun 2006 hingga Agustus 2022 dibandingkan dengan data dari tahun 2006 sampai 2019 dan data tahun 2006 sampai 2022. Dimana data tahun 2006 hingga 2019 memuat data saat sebelum Covid-19 dan data tahun 2006 hingga 2022 memuat data saat pandemi Covid-19 (2020-2021). Data tersebut merupakan data time series bulanan.



Gambar 1. Plot Jumlah Barang yang Dimuat di Bandara Soekarno Hatta 2006 - 2022




Gambar 2. Plot Jumlah Barang yang Dimuat di Bandara Soekarno Hatta 2006 – 2019


Pola jumlah barang yang dimuat di Bandara Soekarno-Hatta dari tahun 2006 hingga 2022 menunjukkan fluktuasi yang signifikan, terutama dengan adanya kecenderungan penurunan pada bulan ke-150 hingga ke-175. Data historis mencatat bahwa bulan Juni 2007 merupakan titik terendah dengan hanya 7.272 Ton barang yang dimuat, yang dapat mencerminkan dampak kondisi ekonomi yang tidak stabil, kebijakan perdagangan yang kurang mendukung, atau faktor musiman yang menyusutkan volume pengiriman. Sebaliknya, lonjakan luar biasa terjadi pada bulan April 2022, di mana jumlah barang mencapai 25.419 Ton, mewakili pemulihan yang signifikan dari dampak pandemi COVID-19 dan peningkatan aktivitas ekonomi.

Penentuan Input Jaringan

Penentuan input jaringan ditentukan dengan menggunakan plot ACF pada Januari 2006 hingga Desember 2019 dan Januari 2006 hingga Desember 2022. Lag dikatakan signifikan jika garis plot melewati selang kepercayaan. Plot ACF diperoleh menggunakan software Python yang ditunjukkan pada Gambar berikut.



Gambar 3. Plot ACF Jumlah Barang yang Dimuat di Bandara Soekarno Hatta 2006 - 2022



Gambar 4. Plot ACF Jumlah Barang yang Dimuat di Bandara Soekarno Hatta 2006 – 2019

1. Berdasarkan Gambar yang merupakan plot ACF dari data Jumlah Barang yang Dimuat di Bandara Soekarno Hatta 2006 - 2022 menunjukkan bahwa lag-lag yang signifikan adalah lag 1, lag 2, lag 3, lag 4, lag 5, lag 6, lag 7 lag 8, lag 9, lag 11, lag 12, dan lag 13. Sehingga dapat diperoleh data input adalah $Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}, Y_{t-5}, Y_{t-6}, Y_{t-7}, Y_{t-8}, Y_{t-9}, Y_{t-11}, Y_{t-12}$, dan Y_{t-13} dengan target $(Y_t)^{\wedge}$. Selanjutnya tugas akhir ini menggunakan 199 data yang terdiri atas 12 variabel input dan 1 variabel output.
2. Berdasarkan Gambar yang merupakan plot ACF dari data Jumlah Barang yang Dimuat di Bandara Soekarno Hatta 2006 - 2019 menunjukkan bahwa lag-lag yang signifikan adalah lag 1, lag 2, lag 3, lag 4, lag 5, lag 6, lag 7 lag 8, lag 12, dan lag 13. Sehingga dapat diperoleh data input adalah $Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}, Y_{t-5}, Y_{t-6}, Y_{t-7}, Y_{t-8}, Y_{t-12}$, dan Y_{t-13} dengan target $(Y_t)^{\wedge}$. Selanjutnya tugas akhir ini menggunakan 167 data yang terdiri atas 10 variabel input dan 1 variabel output.

Pembagian Data

Sebelum model dibangun terlebih dahulu dilakukan pembagian data input dan output menjadi dua yaitu training dan testing. Pembagian dilakukan secara urut sesuai periode dengan perbandingan untuk data training 80% dan untuk data testing 20%. Sehingga untuk data tahun 2006-2022, dari 199 data digunakan 159 pengamatan untuk data training dan 40 pengamatan untuk data testing. Sedangkan untuk data tahun 2006-2019, dari 167 data digunakan 133 pengamatan untuk data training dan 34 pengamatan untuk data testing.

Normalisasi

Normalisasi data adalah merubah skala nilai data yang akan di inputkan menjadi lebih kecil tanpa merubah isi kandungan data tersebut (Hasim, 2008). Normalisasi dilakukan untuk menyetarakan range dari data asli agar sama dengan range dari arsitektur jaringan yang dipakai (Rahmawati, 2013). Normalisasi data dapat mempercepat kecepatan konvergensi, menstabilkan pelatihan, meningkatkan kinerja model, dan secara efektif mengurangi risiko kenaikan gradien dalam proses deep-learning (Sola & Sevila, 1997). Pada penelitian ini, digunakan bantuan software Python dengan fungsi MinMaxScaler dengan $X_{max} = 22628$ dan $X_{min} = 7272$. Berikut adalah contoh data pertama sebelum dilakukan normalisasi.

y_{t-1}	y_{t-2}	y_{t-3}	y_{t-4}	y_{t-5}	y_{t-6}	y_{t-7}	y_{t-8}	y_{t-1} 2	y_{t-1} 3	$\hat{y}_t$
1245	1092	1319	1177	1447	1006	1458	1351	13217	13740	1116
8	6	5	7	1	9	3	8			9

Kemudian dilakukan normalisasi menggunakan rumus pada Persamaan berikut dengan contoh data di Y_{t-13} sebagai berikut :

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} = \frac{13740 - 7272}{22628 - 7272} = 0,421$$

Normalisasi dengan perintah Python dengan library MinMaxScaler sebagai berikut

```
MinMaxScaler()
```

```
data_scales = scaler.fit_transform(data[['Jumlah-Barang']].values.astype(float))
```

Berikut adalah contoh data pertama setelah dilakukan normalisasi

y_{t-1}	y_{t-2}	y_{t-3}	y_{t-4}	y_{t-5}	y_{t-6}	y_{t-7}	y_{t-8}	y_{t-12}	y_{t-13}	$\hat{y}_t$
0,338	0,238	0,386	0,293	0,469	0,182	0,476	0,407	0,387	0,421	0,254

Setelah normalisasi data dapat dilakukan langkah selanjutnya yaitu proses penentuan model terbaik.

Pembentukan Model Terbaik

Fungsi aktivasi yang digunakan adalah fungsi aktivasi sigmoid bipolar (tansig) pada lapisan tersembunyi dan fungsi aktivasi pure linear (purelin) pada lapisan output dengan algoritma pelatihan gradient descent dengan momentum dan adaptive learning rate (traingdx).

Pengaturan nilai-nilai parameter menggunakan algoritma pelatihan gradient descent dengan momentum dan adaptive learning rate yang ditunjukkan pada Tabel 1 berikut.

Tabel 1. Parameter Pembelajaran	
Parameter	Nilai
Maksimum <i>Epoch</i>	500
Target <i>Error</i>	1e-5
<i>Learning Rate</i>	0,01
Momentum	0,8
<i>Epoch Show</i>	50

Pada Tabel 1 ditunjukkan hasil nilai-nilai parameter pembelajaran yang diperoleh dengan nilai akurasi tertinggi dalam membentuk model terbaik untuk model ERNN digunakan jumlah maksimum *epoch* sebesar 500, dengan target *error* sebesar 1e-5; untuk *learning rate* 0.01; setelah itu digunakan momentum sebesar 0.8; dan *epoch show* sebesar 50.

Pemilihan model ERNN terbaik dilakukan dengan tahapan penentuan banyaknya neuron tersembunyi dengan cara *trial* dan *error*. Proses pelatihan ERNN dengan algoritma *backpropagation* dilakukan untuk menentukan banyaknya neuron tersembunyi dimulai dari 1 hingga 20 neuron tersembunyi. Model yang memiliki neuron tersembunyi terbaik dipilih berdasarkan kriteria MAPE, semakin kecil nilai MAPE maka semakin baik model tersebut, jadi untuk kriteria pemilihan neuron tersembunyi dipilih berdasarkan nilai MAPE terkecil namun tetap mempertimbangkan antara data *training* dan *testing*. Hasil model yang diperoleh pada data training dan testing ditunjukkan pada Tabel 2 berikut.

Tabel 2. MAPE Model ERNN

Model ERNN Untuk Data 2006-2022			Model ERNN Untuk Data 2006-2019		
Jumlah Neuron Tersembunyi	Training	Testing	Jumlah Neuron Tersembunyi	Training	Testing
1	0,4663	0,1489	1	0,4663	0,1489
2	0,4662	0,1486	2	0,4662	0,1486
3	0,4660	0,1485	3	0,4660	0,1485
4	0,4659	0,1483	4	0,4659	0,1483
5	0,4654	0,1482	5	0,4654	0,1482
6	0,4949	0,1481	6	0,4949	0,1481
7	0,4642	0,1480	7	0,4642	0,1480
8	0,4635	0,1479	8	0,4635	0,1479
9	0,4625	0,1478	9	0,4625	0,1478
10	0,4619	0,1477	10	0,4619	0,1477
11	0,4604	0,1476	11	0,4604	0,1476
12	0,4591	0,1475	12	0,4591	0,1475
13	0,4578	0,1474	13	0,4578	0,1474
14	0,4564	0,1473	14	0,4564	0,1473
15	0,4549	0,1472	15	0,4549	0,1472
16	0,4533	0,1472	16	0,4533	0,1472
17	0,4513	0,1471	17	0,4513	0,1471
18	0,4499	0,1470	18	0,4499	0,1470
19	0,4479	0,1469	19	0,4479	0,1469
20	0,4455*	0,1468*	20	0,4455*	0,1468*

Keterangan: * Model Terbaik

Pada Tabel 2 terlihat bahwa untuk model terbaik ERNN terbaik mendapatkan 2 neuron pada lapisan tersembunyi berdasarkan nilai MAPE. Model terbaik yang terbentuk pada model ERNN untuk data 2006-2022 adalah model dengan 20 neuron tersembunyi. Model terbaik yang terbentuk pada data 2008-2019 adalah model dengan 20 neuron tersembunyi.


Diketahui bahwa model terbaik sudah didapatkan berdasarkan Tabel 2 untuk data tahun 2006-2022 dan data tahun 2006-2019. Tabel 3 menjelaskan perbandingan antaran ketiga model terbaik, sehingga pembentukan model dan data yang nantinya dipakai untuk penelitian.

Tabel 3. Perbandingan MAPE Model Terbaik 2 Data Training dan Testing


Data	Neuron Tersembunyi	Training	Testing
2006-2022	20	0,4455*	0,1468*
2006-2019	20	0,4455*	0,1468*

Berdasarkan Tabel 3, diketahui bahwa model terbaik yang dipertimbangkan untuk data training didapatkan dari data tahun 2006-2022 dengan nilai MAPE sebesar 44,55% begitu juga dengan model data testing dengan nilai MAPE paling seimbang untuk data testing sebesar 14,68%. Sebelum dilakukan prediksi, terlebih dahulu dilakukan evaluasi terhadap model ERNN terbaik yang sudah didapatkan. Bentuk evaluasi ini bertujuan untuk menentukan apakah model tersebut dapat digunakan untuk melakukan prediksi. Evaluasi ini dilakukan dengan melakukan pemeriksaan error pada output data training yang telah didapatkan bersifat white noise atau

tidak. Error dikatakan bersifat white noise jika tidak ada lag-lag yang signifikan atau melewati garis batas. Pemeriksaan ini dilihat melalui plot ACF dan PACF pada error data training. Model dikatakan baik jika error data training bersifat white noise. Hasil uji white noise untuk 2 model terbaik dapat dilihat pada Gambar 1 sampai dengan Gambar 2.



Gambar 1 Plot ACF & PACF Residual Data Tahun 2006 – 2022




Gambar 2 Plot ACF & PACF Residual Data Tahun 2006 – 2019

Dapat dilihat dari Gambar 1 dan Gambar 2 untuk residual data plot ACF dan PACF untuk data training 2006-2022, keduanya terlihat memiliki lag autokorelasi dan autokorelasi parsial tidak adanya lag autokorelasi yang berada diluar selang kepercayaan, ini berarti bahwa error bersifat acak atau white noise. Sedangkan untuk residual data plot ACF dan PACF untuk data training tahun 2006-2019 yang ditunjukkan oleh Gambar 13, menunjukkan adanya lag autokorelasi parsial yang berada diluar selang kepercayaan pada plot PACF sehingga tidak memiliki sifat white noise. Sehingga dapat dikatakan bahwa model terbaik ERNN didapatkan pada data tahun 2006-2022 dan model tersebut dapat digunakan sebagai model dalam memprediksi jumlah barang di bandara Soekarno Hatta.

Hasil Prediksi Jumlah Barang di Bandara Soekarno Hatta

Hasil prediksi jumlah barang di bandara Soekarno Hatta untuk bulan Januari 2023 adalah 16110. Untuk prediksi bulan Januari 2018 digunakan data yaitu 10 input data sebelumnya dimulai dari bulan Maret 2017 hingga Desember 2017, begitupun dengan prediksi bulan selanjutnya menggunakan data 10 bulan sebelumnya sebagai input. Setelah mendapatkan nilai pada bulan Januari, dilakukan proses yang sama dalam memprediksi jumlah barang di bandara Soekarno Hatta. Gambar menunjukkan hasil prediksi barang di bandara Soekarno Hatta untuk bulan Januari sampai Desember 2023.



Gambar 3 Plot Hasil Prediksi Jumlah Barang yang dimuat di Bandara Soekarno Hatta

Gambar 3 menunjukkan bahwa jumlah barang yang dimuat di Bandara Soekarno Hatta untuk 12 bulan di Tahun 2023. Prediksi menunjukkan bahwa jumlah barang yang dimuat di Bandara Soekarno Hatta paling sedikit di Desember 2023 sebanyak 16110 Ton sedangkan paling banyak pada bulan Januari 2023 sebanyak 16111 Ton.

Penelitian ini berhasil menunjukkan efektivitas penggunaan metode Elman Recurrent Neural Network (ERNN) dalam memprediksi jumlah barang di Bandara Soekarno-Hatta, dengan mencapai nilai MAPE sebesar 14,68% dalam data testing. Hasil ini menandakan keberhasilan model yang diterapkan, karena berhasil menghasilkan prediksi yang lebih akurat dibandingkan dengan penelitian terdahulu yang menunjukkan nilai MAPE lebih tinggi, seperti 20%. penelitian ini memberikan gambaran bahwa penggunaan ERNN dapat dioptimalkan lebih lanjut dengan menggabungkannya dengan arsitektur model lain seperti *Long Short-Term Memory* (LSTM) atau *Gated Recurrent Units* (GRU), serta meningkatkan teknik feature engineering dan analisis sensitivitas agar model dapat lebih adaptif terhadap perubahan data input yang mungkin terjadi. Dengan melakukan pengujian dan validasi lebih lanjut dengan dataset yang lebih bervariasi, penelitian selanjutnya diharapkan dapat terus meningkatkan akurasi dan efektivitas model ini, sehingga dapat berkontribusi lebih jauh dalam meningkatkan efisiensi operasional dan profitabilitas di sektor transportasi dan logistik.

SIMPULAN

Model terbaik dihasilkan dengan variabel input lag 10, 20 neuron pada lapisan tersembunyi, dan 1 variabel output dengan fungsi aktivasi pure linear. Nilai MAPE pada data training sebesar 44,55% dan nilai MAPE data testing sebesar 14,68%. Prediksi menunjukkan bahwa jumlah barang yang dimuat di Bandara Soekarno Hatta paling sedikit di Desember 2023 sebanyak 16110 Ton sedangkan paling banyak pada bulan Januari 2023 sebanyak 16111 Ton.

Saran :

1. Untuk Bandara Soekarno-Hatta: Analisis pengaruh musiman dan dampak krisis global (seperti COVID-19) terhadap volume barang perlu diteliti lebih lanjut. Optimasi rute pengiriman barang menggunakan algoritma pembelajaran mesin, integrasi model prediksi dengan sistem manajemen bandara real-time, dan kolaborasi dengan pemangku kepentingan di industri penerbangan dan logistik juga sangat penting untuk meningkatkan efisiensi operasional dan manajemen alur barang. Evaluasi kinerja model dengan berbagai metrik dan simulasi berbasis komputer untuk mengidentifikasi bottleneck juga disarankan.
2. Untuk Peneliti Selanjutnya: Perluasan penelitian dengan fokus pada analisis musiman, optimasi rute pengiriman, integrasi real-time dengan sistem manajemen bandara, dan

dampak krisis global. Pemanfaatan data historis untuk perencanaan kapasitas infrastruktur, kolaborasi dengan pemangku kepentingan, dan evaluasi dampak kebijakan/regulasi juga penting. Penggunaan berbagai metrik evaluasi dan simulasi berbasis komputer untuk mengidentifikasi bottleneck juga direkomendasikan.

DAFTAR PUSTAKA

- Cryer, J. D., & Chan, K. S. (2008). *Time Series Analysis with Applications in R*. Springer.
- Fairbanks, C. (2012). Global aviation industry trends. *Journal of Air Transport Management*, 25, 15-22.
- Gurney, K. M. (1997). *An Introduction to Neural Networks*. UCL Press.
- Hanke, J. E., & Wichern, D. W. (2005). *Modeling Time Series Data*. Pearson Education.
- Hanke, J. E., & Wichern, D. W. (2014). *Business Forecasting* (9th ed.). Pearson.
- Kusumadewi, A. (2004). *Jaringan Syaraf Tiruan dan Aplikasinya*. Bandung: Informatika.
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1999). *Forecasting: Methods and Applications* (3rd ed.). Wiley.
- Manullang, R. (2020). Prediksi kedatangan wisatawan menggunakan Long Short-Term Memory (LSTM). *Jurnal Teknologi dan Sistem Komputer*, 8(2), 105-112.
- Maind, J., & Wankar, V. (2014). *Artificial Neural Networks: A Primer*. Indian Journal of Science and Technology, 7(3), 96-101.
- MCCulloch, W., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5, 115-133.
- Radjabaycolle, S., & Pulungan, J. (2016). Prediksi penggunaan bandwidth menggunakan Elman Neural Network. *Jurnal Teknologi Informasi*, 12(1), 45-52.
- Sitinjak, E. (2023). Prediksi persediaan barang dengan algoritma Elman Recurrent Neural Network. *Jurnal Teknik Informatika*, 9(1), 23-30.
- Suleistyowati, L. (2018). Peramalan jumlah penumpang dan volume kargo di Indonesia menggunakan model hibrida. *Jurnal Transportasi*, 10(2), 89-98.
- Talahatu, E., et al. (2015). Prediksi pergerakan harga saham dengan Elman RNN. *Jurnal Keuangan dan Perbankan*, 19(4), 567-576.
- Wei, W. W. S. (2006). *Time Series Analysis: Univariate and Multivariate Methods*. Pearson Education.
- Yanti, S., et al. (2019). Prediksi radiasi matahari menggunakan Elman Neural Network. *Jurnal Teknologi dan Sistem Komputer*, 7(1), 1-9.