

Desain Optimalisasi Peramalan Suku Cadang Berbasis Machine Learning

I Dewa Made Wikananda Surya Kusuma¹⁾, I Wayan Widhiada²⁾,
Anak Agung Istri Agung Sri Komaladewi³⁾

^{1,2)}Program Studi Teknik Mesin Universitas Udayana
Kampus Sudirman, Bali 80234

³⁾Program Studi Teknik Industri, Universitas Udayana
Kampus Bukit Jimbaran, Bali 80361

doi: <https://doi.org/10.24843/METTEK.2023.v09.i02.p01>

Abstrak

Di era perkembangan revolusi industri 4.0 dan era digitalisasi saat ini, persaingan dunia bisnis kian sangat ketat dan sengit. Perusahaan mulai berlomba-lomba menciptakan strategi agar konsumen tidak berpindah ke kompetitor lain. Salah satu strategi agar konsumen tidak berpindah adalah dengan melakukan peramalan suku cadang, karena dengan adanya peramalan maka kegiatan produksi maupun jasa yang ada di perusahaan akan terus berjalan, sehingga berdampak kepada kepuasan pelanggan. Seiring dengan perkembangan zaman, untuk memenangkan persaingan, strategi yang dilakukan perusahaan juga bervariasi, seperti penerapan *machine learning* yang banyak dilakukan perusahaan besar. Penelitian ini memiliki tujuan untuk mendesain optimalisasi model peramalan dengan menggunakan *machine learning*. Penelitian ini membandingkan enam jenis model peramalan dengan *dataset* yang sudah disediakan. Model peramalan dapat dikatakan terbaik, apabila memiliki nilai MAE (*Mean Absolute Error*) yang terendah. Hasil penelitian menunjukkan model peramalan yang terbaik adalah model *hybrid*, yaitu model *Optimize Neural Network (Autoencoder + LSTM)*, yang memiliki nilai MAE 0,5528.

Kata kunci: Indusri, Peramalan, *Machine Learning*, *Mean Absolute Error*

Abstract

In the era of the development of the Industrial Revolution 4.0 and the current era of digitalization, competition in the business world is becoming very tight and fierce. Companies started to compete to create strategies so that consumers do not move to other competitors. One of the strategies to keep consumers from moving is to forecast spare parts, because with forecasting, the production and service activities in the company will continue to run, which has an impact on customer satisfaction. Along with the times, to win the competition, the strategies carried out by companies also vary, such as the application of machine learning that many large companies do. This research aims to design a forecasting model optimization using machine learning. This research compares six types of forecasting models with the provided data set. The forecasting model can be said to be the best if it has the lowest MAE (Mean Absolute Error) value. The results show that the best forecasting model is a hybrid model, namely the Optimize Neural Network (Autoencoder + LSTM) model, which has an MAE value of 0.5528.

Keywords: Industry, Forecasting, *Machine Learning*, *Mean Absolute Error*

1. PENDAHULUAN

Era perkembangan revolusi industri 4.0, persaingan dunia bisnis kian ketat dan sengit. Perusahaan berlomba-lomba mengembangkan strategi agar konsumen tidak berpindah ke kompetitor. Perusahaan yang ingin bertahan di pasar akan berusaha semaksimal mungkin untuk

Penulis korespondensi,
Email: wikananda14@gmail.com

meningkatkan efisiensi, produktivitas, mudah, dan selalu menciptakan inovasi dan strategi [1]. Hal tersebut sangat susah dilakukan, karena perlu perencanaan produksi yang efektif dan efisien, oleh karena itu banyak perusahaan yang melakukan peramalan, terutama dalam ketersediaan bahan baku produk. Baik dalam kurun waktu panjang ataupun pendek, perusahaan harus bisa memperkirakan permintaan konsumen dimasa depan [2]. Dalam meningkatkan jumlah produksi dan nilai produk, peramalan sangat dibutuhkan [3].

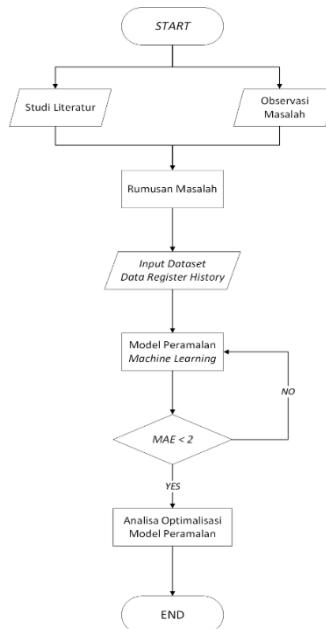
Peramalan dapat dikatakan baik apabila memiliki nilai *error* yang rendah. Salah satu cara mengukur tingkat keakuratan model peramalan adalah menggunakan MAE (*Mean Absolute Error*). Nilai MAE menunjukkan nilai rata-rata kesalahan multak atau *absolut* dari nilai sebenarnya dengan hasil peramalan [4]. Peramalan bertujuan untuk membuat ramalan yang dapat meminimumkan nilai *error* yang dapat diukur dengan MAE [5].

Seiring perkembangan zaman, strategi untuk memenangkan persaingan juga bervariasi, seperti pemasaran melalui sosial media, penjualan melalui *market place*, peramalan bahan baku, dan lainnya. Salah satu penerapan perkembangan zaman di perusahaan adalah dengan penerapan AI (*Artificial Intelligence*) yaitu *machine learning* dan saat ini sudah banyak digunakan oleh perusahaan besar. *Artificial intelligence* banyak digunakan untuk memecahkan berbagai permasalahan seperti bisnis [6]. Dengan *machine learning*, estimasi permintaan atas suatu produk dapat diprediksi dengan akurat [7]. Peramalan sangat membantu dalam memperkirakan langkah yang dibutuhkan dalam beberapa tahun kedepan, penggunaan model *machine learning* dalam peramalan menghasilkan *error* yang kecil [8]. Tujuan dari penelitian ini adalah untuk mendesain optimalisasi model peramalan suku cadang dengan menggunakan *machine learning*.

2. METODE

Semua pengolahan *dataset* beserta peramalan dengan *machine learning* dilakukan dengan menggunakan *google colab* merupakan salah satu produk dari *google research* yang digunakan untuk menunjang kebutuhan programer dalam mengolah *dataset* dengan *machine learning*.

2.1. Diagram Penelitian

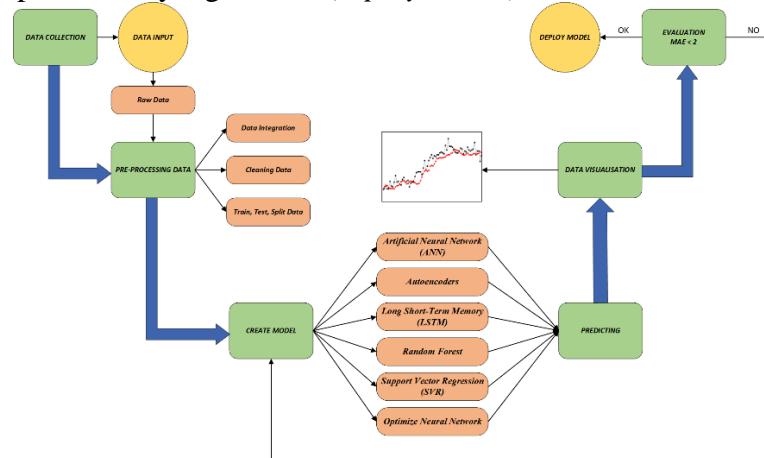


Gambar 1. Diagram Alir Desain Optimalisasi Peramalan Suku Cadang

2.2. Workflow Machine Learning

Dalam proses pengolahan data *machine learning*, terdapat *workflow* yang merupakan alur ketika *user* melakukan proses pengolahan data, yang dapat diliha pada Gambar 2, diantaranya

tahap pengumpulan data (*data collection*), tahap sebelum pengolahan data (*pre-processing data*), tahap pembuatan model peramalan (*create model*), tahap prediksi (*predicting*), tahap visualisasi (*data visualization*), tahap evaluasi model (*evaluation model*), hingga terakhir tahap menjalankan model peramalan yang terbaik (*deploy model*).



Gambar 2. Workflow Machine Learning

2.3. Dataset

Dataset yang digunakan berupa *data historical* pekerjaan jasa pada periode Januari 2021 hingga Desember 2022 yang sudah dilakukan proses *data integration*. Dataset pada penelitian ini dapat dilihat pada Tabel 1.

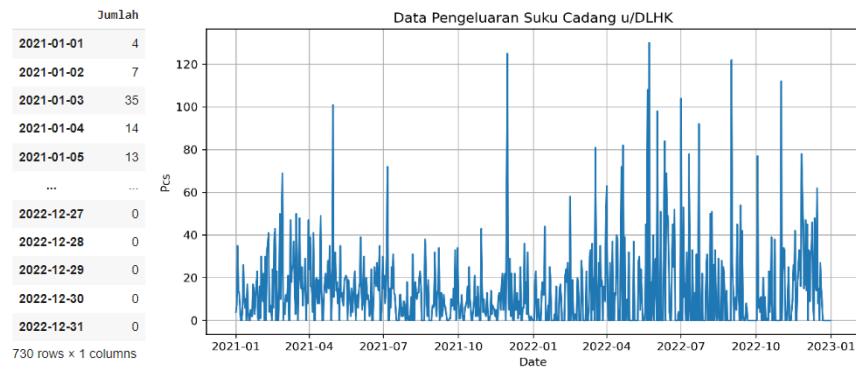
Tabel 1. Dataset 2021 2022

No.	Tanggal Masuk	Durasi / Hari	Tanggal Keluar	Instansi	Plat Nomor	Observasi	Jasa	Nama Suku Cadang	Jumlah
0	1 2021-01-01	0	2021-01-01	DLHK KOTA DENPASAR	DK 8753 A	Spion ocel	Jasa Ganti Spion	Kaca Spion	1.0
1	1 2021-01-01	0	2021-01-01	DLHK KOTA DENPASAR	DK 8753 A	Lampu main main	Jasa Ganti Putaran Kaca	Putaran Kaca	1.0
2	1 2021-01-01	0	2021-01-01	DLHK KOTA DENPASAR	DK 8753 A	NaN	Jasa Ganti Lampu Kabut	Lampu Kabut	1.0
3	1 2021-01-01	0	2021-01-01	DLHK KOTA DENPASAR	DK 8753 A	NaN	Jasa Ganti Lampu Stopan	Lampu Stopan	1.0
4	1 2021-01-01	0	2021-01-01	DLHK KOTA DENPASAR	DK 8753 A	NaN	Jasa Service Kelistrikan Lampu	NaN	NaN
...
2603	406 2022-12-21	0	2022-12-21	DLHK KOTA DENPASAR	DK 9457 A	Klakson mati	Jasa Service Lampu Depan	Per Pegangan Kampas	1.0
2604	406 2022-12-21	0	2022-12-21	DLHK KOTA DENPASAR	DK 9457 A	NaN	Jasa Service Klakson	Seleng Rem	1.0
2605	406 2022-12-21	0	2022-12-21	DLHK KOTA DENPASAR	DK 9457 A	NaN	NaN	Sekring	1.0
2606	406 2022-12-21	0	2022-12-21	DLHK KOTA DENPASAR	DK 9457 A	NaN	NaN	Lampu Spidometer	1.0
2607	406 2022-12-21	0	2022-12-21	DLHK KOTA DENPASAR	DK 9457 A	NaN	NaN	Minyak Rem	1.0

5174 rows × 10 columns

2.4. Cleaning Data

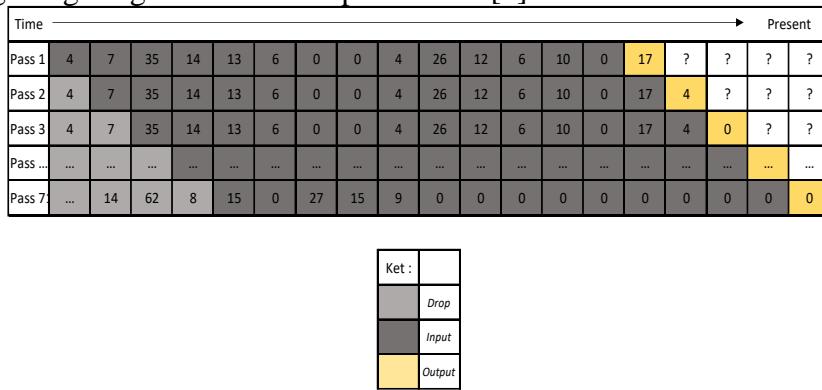
Dalam proses pembuatan model peramalan, tidak semua data yang terdapat dalam *dataset* digunakan, data yang digunakan hanya jumlah pengeluaran suku cadang beserta tanggal suku cadang dikeluarkan, yang dimana data dan grafik dapat dilihat pada Gambar 3.



Gambar 3. Cleaning Data

2.5. Train Test Split Data

Pada tahapan ini *dataset* sebelumnya harus melalui *sliding window*, yang bertujuan mengidentifikasi *pattern* yang berharga, sehingga algoritma dapat menentukan keputusan yang penting. *Sliding window algorithm* merupakan teknik pembentukan struktur pada time series data, untuk mengurangi tingkat kesalahan aproksimasi [9].

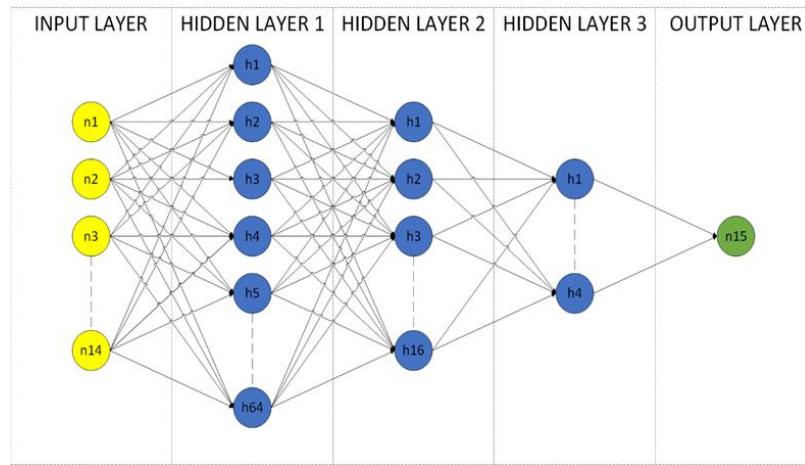


Gambar 4. Sliding Window Dataset

Ilustrasi *sliding window* dapat dilihat pada Gambar 4, dimana mengambil 14 *window* dengan 1 *step*, sehingga menghasilkan 716 data. *Dataset* tersebut baru bisa dilakukan *split data*, dimana data yang terbaik dibagi menjadi 80% *training data* dan 20% *test data* [10]. Dalam 716 data, *training data* menjadi 572 data dan *test data* menjadi 144 data.

2.6. Artificial Neural Network (ANN)

Model ini merupakan model yang mencoba miniru *neuron* yang ada tubuh manusia. Model *ANN* merupakan suatu upaya untuk mensimulasikan data rumit dengan elemen pemrosesan *neuron* yang berlapis-lapis [11]. Pada penelitian ini terdapat arsitektur yang dalam dalam model peramalan *ANN*, dapat dilihat pada Gambar 5.

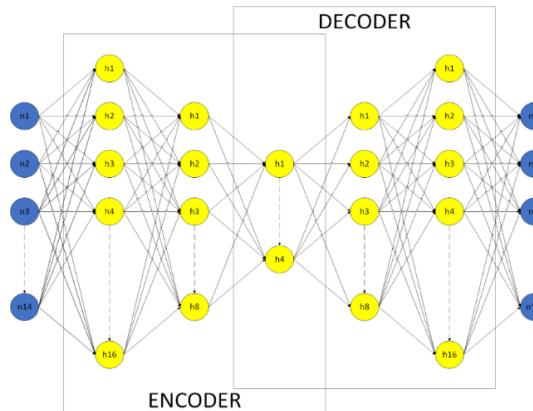


Gambar 5. Arsitektur Model *Artificial Neural Network*

Pada arsitektur model ANN diatas, terdapat beberapa parameter yang ditentukan untuk membuat model *ANN* yang sesuai, diantaranya *Input Layer* yang terdiri dari empat belas *window sliding*, *Fully Connected Layer* yang merupakan algoritma yang terdapat pada seluruh *hidden layer*, dan *Output Layer* yang merupakan nilai ke-15 dari *window sliding*.

2.7. Autoencoders

Model ini merupakan model turunan dari *ANN*, dimana untuk proses *output* merupakan rekonstruksi dari *input* pada pemodelan ini. Model *autoencoder* merupakan turunan model *neural network* yang mempelajari data *input* dan berusaha untuk melakukan rekonstruksi terhadap data *input* tersebut [12]. Model peramalan ini pun memiliki arsitektur, dapat dilihat pada Gambar 6.

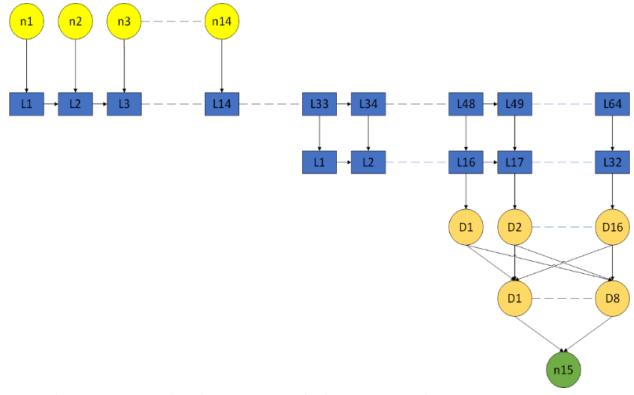


Gambar 6. Arsitektur Model *Autoencoders*

Pada arsitektur model *autoencoders*, terdapat beberapa parameter yang ditentukan untuk membuat model ini, dimana untuk jumlah *output* harus sama dengan jumlah *input*, dimana model berusaha melakukan rekonstruksi dari *input* yang berjumlah empat belas *window sliding*.

2.8. Long Short-Term Memory (LSTM)

Model *LSTM* merupakan model yang bertujuan memprediksi data berdasarkan informasi lampau yang disimpan dalam jangka waktu yang lama. Model *LSTM* sangat cocok untuk membuat prediksi yang akurat berdasarkan data *time series*, karena mungkin ada kelangkaan durasi yang tidak diketahui didalam data [13]. Dengan arsitektur model *LSTM* pada Gambar 7.

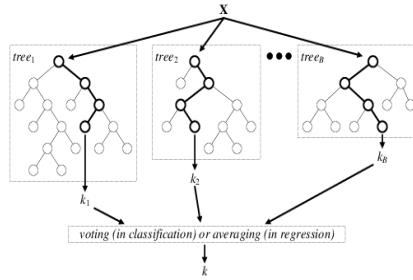


Gambar 7. Arsitektur Model *Long Short-Term Memory*

Arsitektur model *LSTM* memiliki beberapa parameter penting dalam proses model tersebut, diantaranya *Input Layer* yang terdiri dari empat belas *window sliding*, *LSTM Layer* yang terdiri dari beberapa blok memori yang disebut *cell*, *Fully Connected Layer* yang merupakan algoritma pada seluruh *hidden layer*, dan *Output Layer* yang merupakan nilai ke-15 dari *window sliding*.

2.9. Random Forest

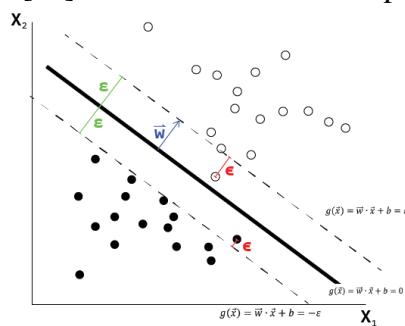
Model *random forest* merupakan salah satu algoritma *supervised learning*. *Random forest* merupakan model yang menggunakan pohon keputusan (*decision tree*) yang dilakukan secara acak untuk mendapatkan hasil prediksi [14]. Dengan arsitektur pada Gambar 8.



Gambar 8. Arsitektur Model *Random Forest*

2.10. Support Vector Regression (SVR)

Model SVR merupakan penerapan *Support Vector Machine (SVM)* dalam regresi. *SVM* diterapkan untuk klasifikasi menghasilkan *output* berupa bilangan bulat, sedangkan SVR menghasilkan *output* berupa bilangan *real*. Tujuan model algoritma SVR yaitu untuk menemukan suatu garis *hyperplane* yang terbaik. *Hyperplane* terbaik dapat ditemukan dari mengukur *margin* dari *hyperplane* [15]. Ilustrasi model SVR dapat dilihat pada Gambar 9.

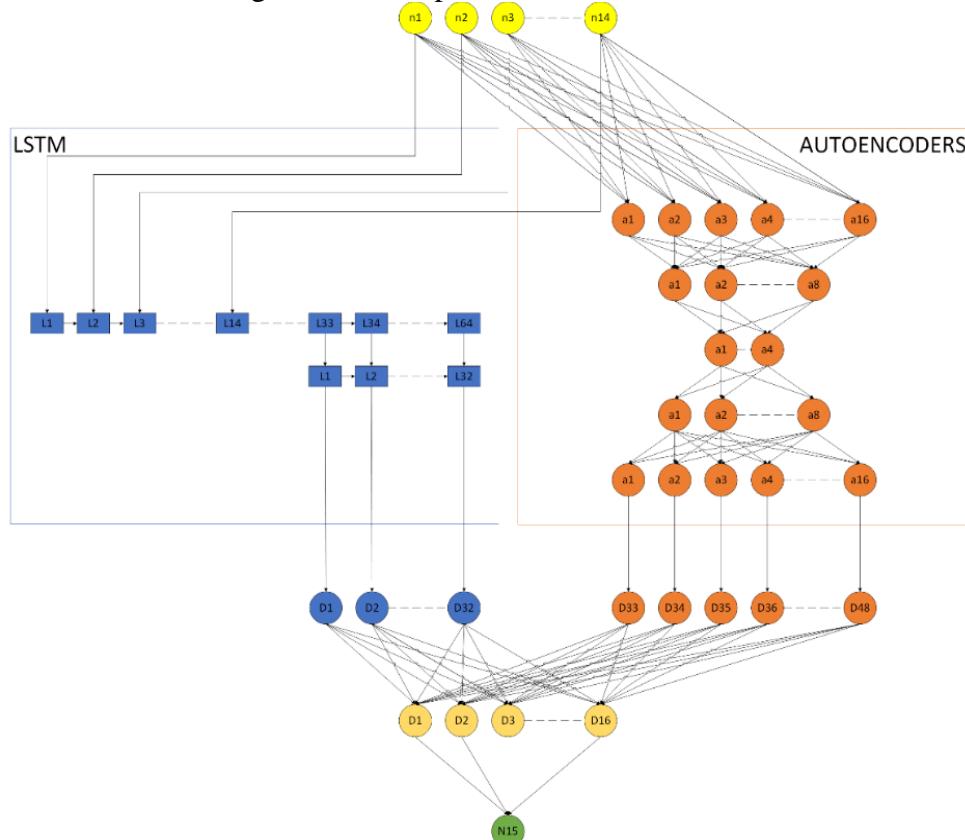


Gambar 9. Model *Support Vector Regression*

2.11. Optimize Neural Network Model

Model ini merupakan model *hybrid* gabungan dari dua model peramalan yaitu *Autoencoder* dan *Long Short-Term Memory*, dua model tersebut dipilih karena nilai MAE yang rendah dibandingkan dengan model lainnya. Kinerja peramalan dengan model *hybrid* lebih baik dan akurat dibandingkan dengan model individu dalam meramalkan jumlah penumpang maskapai

penerbangan [16]. Dimana dengan arsitektur pada Gambar 10.



Gambar 10. Arsitektur Model *Optimize Neural Network Model*

3. HASIL DAN PEMBAHASAN

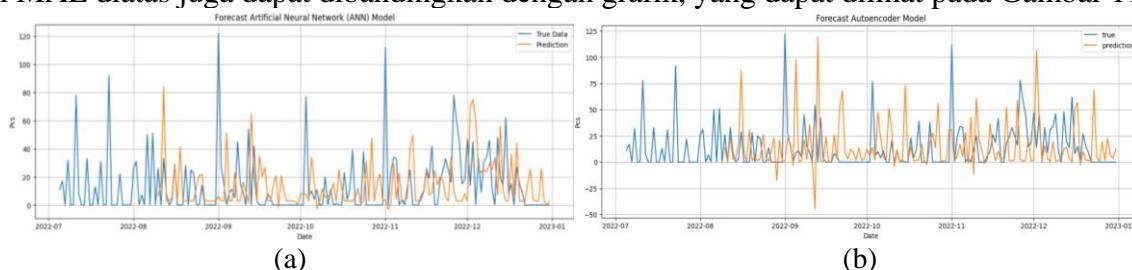
Pada sub ini akan dijelaskan bagaimana hasil *MAE* dari semua model peramalan berserta dengan grafik dari setiap model, sebagai berikut.

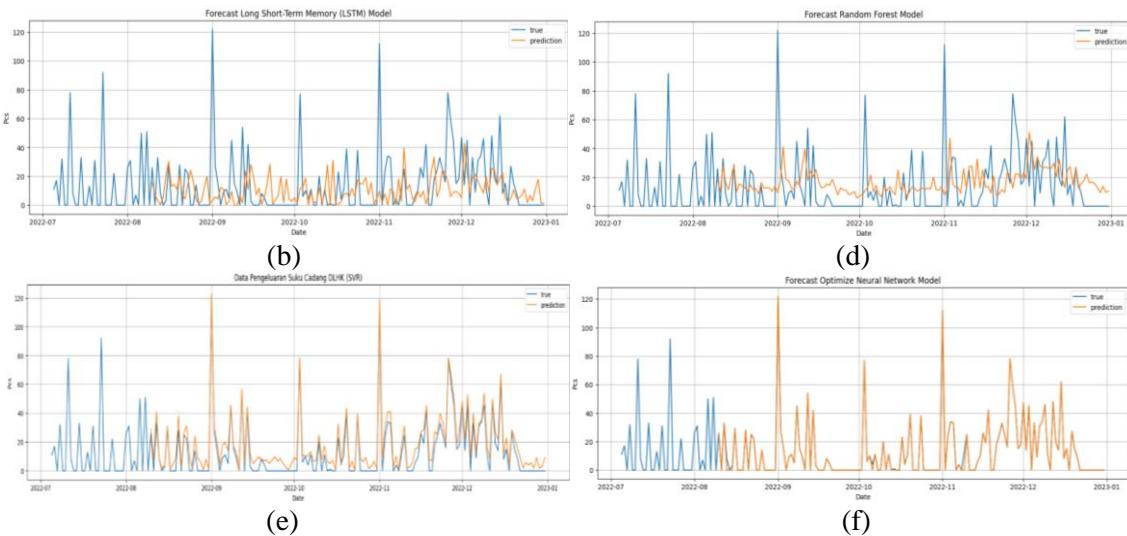
3.1. Summary

Tabel 2. *Summary*

Model Name	MAE
Artificial Neural Network (ANN)	3.3111
Autoencoder	2.5525
Long Short-Term Memory (LSTM)	2.6363
Random Forest	5.0241
Support Vector Regression	5.1793
Optimize Neural Network (LSTM+Autoencoder)	0.5528

Tabel 2, merupakan *MAE* dari seluruh model dengan dataset yang sudah diolah, semakin kecil nilai *MAE*, maka semakin bagus model yang digunakan untuk melakukan peramalan. Hasil *MAE* diatas juga dapat dibandingkan dengan grafik, yang dapat dilihat pada Gambar 11.





Gambar 11. Grafik Seluruh Model

Dari grafik diatas, grafik berwarna biru merupakan data aktual, sedangkan grafik orange merupakan hasil model melakukan peramalan. Gambar 11 (a)(b)(c)(d)(e) menunjukkan adanya jarak antara grafik biru dan orange, hasil ini sama dengan nilai MAE, dimana model tersebut dapat dikatakan belum sesuai keinginan user. Model hybrid pada Gambar 11 (f) menunjukkan bahwa model tersebut memiliki nilai MAE yang rendah, hal ini didukung dari jarak antara grafik biru dan orange, dimana grafik orange hampir menyerupai grafik biru.

4. SIMPULAN

Berdasarkan hasil penelitian, maka disimpulkan bahwa dari beberapa model peramalan yang digunakan untuk *dataset*, model yang memiliki nilai *error* yang rendah adalah model *hybrid* yaitu *Optimize Neural Network (Autoencoder + LSTM)*. Model peramalan tersebut memiliki nilai MAE (*Mean Absolute Error*) 0,5528 yang menunjukkan model *hybrid* tersebut merupakan model peramalan yang paling terbaik untuk melakukan peramalan dengan *dataset*.

UCAPAN TERIMA KASIH

Puji syukur kehadapan Tuhan Yang Maha Esa, dimana atas anugerahnya diberikan kesehatan dapat menyelesaikan penelitian ini. Terimakasih saya ucapkan kepada Bapak I Wayan Widhiada dan Ibu A.A. Istri A. Sri Komaladewi selaku dosen pembimbing, beserta Bapak I Gusti Ngurah Priambadi, Bapak Made Widiyarta, dan Bapak I Ketut Adi Atmika selaku dosen yang memberikan saran agar penelitian yang dilakukan berjalan lancar, serta semua pihak yang membantu dalam penulisan ini yang tidak dapat saya sebutkan satu persatu.

DAFTAR PUSTAKA

- [1] A. Y. Fitrianto, B. Sudaryanto, and J. Manajemen, “The Effect of Supply Chain Management on Outlet Operational Performance,” *Diponegoro J. Manag.*, vol. 5, no. 2, pp. 1–11, 2016.
- [2] Hernadewita, Y. K. Hadi, M. J. Syaputra, and D. Setiawan, “Peramalan Penjualan Obat Generik Melalui Time Series Forecasting Model Pada Perusahaan Farmasi di Tangerang: Studi Kasus,” *J. Ind. Eng. Manag. Res. (Jiemar)*, vol. 1, no. 2, pp. 35–49, 2020, [Online]. Available: <https://jiemar.org/index.php/jiemar/article/view/38>
- [3] D. R. Indah and E. Rahmadani, “Sistem Forecasting Perencanaan Produksi dengan Metode Single Eksponensial Smoothing pada Keripik Singkong Srikandi Di Kota Langsa,” *J. Penelit. Ekon. Akunt.*, vol. 2, no. 1, pp. 10–18, 2018, [Online]. Available: <https://ejurnalunsam.id/index.php/jensi/article/view/930>

- [4] A. A. Suryanto, Muqtadir, and A. Jurusan, “Penerapan Metode Mean Absolute Error (Mea) Dalam Algoritma Regresi Linear Untuk Prediksi Produksi Padi,” *Saintekbu*, vol. 11, no. 1, pp. 78–83, 2019, doi: 10.32764/saintekbu.v11i1.298.
- [5] H. Rusdiana, A., B. A. Saebani, and H. Ali Rammdhani, Moh., *Manajemen Operasi*. Bandung: CV. Pustaka Setia, 2014. [Online]. Available: <http://digilib.uinsgd.ac.id/8788/1/Buku Manajemen Operasi.pdf>
- [6] D. Sudaryono, U. Rahardja, and A. Roihan, “Design of Business Intelligence in Learning Systems Using iLearning Media,” *Univers. J. Manag.*, vol. 5, no. 5, pp. 227–235, 2017, doi: 10.13189/ujm.2017.050502.
- [7] P. Bajari, D. Nekipelov, S. P. Ryan, and M. Yang, “Machine learning methods for demand estimation,” *Am. Econ. Rev.*, vol. 105, no. 5, pp. 481–485, 2015, doi: 10.1257/aer.p20151021.
- [8] T. Jaelani, M. Yamin, and C. P. Mahandari, “MACHINE LEARNING UNTUK PRODUKSI GULA NASIONAL,” *JMPM (Jurnal Mater. dan Proses Manufaktur)*, vol. 6, no. 1, pp. 31–36, Aug. 2022, doi: 10.18196/jmpm.v6i1.14897.
- [9] P. Arsi, T. Astuti, D. Rahmawati, and P. Subarkah, “Implementasi Sliding Window Algorithm Pada Prediksi Kurs Berbasis Neural Network,” *J. Comput. Inf. Technol.*, vol. 6, no. 1, pp. 51–59, 2022.
- [10] A. Gholamy, V. Kreinovich, and O. Kosheleva, “Why 70/30 or 80/20 Relation Between Training and Testing Sets : A Pedagogical Explanation,” *Dep. Tech. Reports*, vol. 1209, pp. 1–6, 2018.
- [11] B. Suhada, “Peramalan Produksi Gula Nasional Melalui Pendekatan Artificial Neural Network,” *50 | Deriv.*, vol. 3, no. 1, pp. 50–63, 2009.
- [12] F. S. Nugraha and H. F. Pardede, “Autoencoder untuk Sistem Prediksi Berat Lahir Bayi,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 2, p. 235, 2022, doi: 10.25126/jtiik.2022923868.
- [13] A. Yadav, C. K. Jha, and A. Sharan, “Optimizing LSTM for time series prediction in Indian stock market,” *Procedia Comput. Sci.*, vol. 167, no. 2019, pp. 2091–2100, 2020, doi: 10.1016/j.procs.2020.03.257.
- [14] L. Breiman, *Random Forests*. Manufactured in The Netherlands, 2021. doi: 10.1109/ICCECE51280.2021.9342376.
- [15] M. R. Rifqi, B. Darma Setiawan, and F. A. Bachtiar, “Support Vector Regression Untuk Peramalan Permintaan Darah: Studi Kasus Unit Transfusi Darah Cabang-PMI Kota Malang,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 10, pp. 3332–3342, 2018, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [16] M. Arumsari and A. T. R. Dani, “Peramalan Data Runtun Waktu menggunakan Model Hybrid Time Series Regression – Autoregressive Integrated Moving Average,” *J. Siger Mat.*, vol. 2, no. 1, pp. 1–12, 2021, doi: 10.23960/jsm.v2i1.2736.