

Pemodelan Prediksi Temperatur *Freezer* Menggunakan Pendekatan Machine Learning Berbasis *Framework TensorFlow*

Ahmad Davi^{1*}, Farkhan Jatmiko Sidiq¹, Muhammad Aziz Arrizal¹, Fahrizal Agil Wibowo¹, Taopik Sendy Gunawan¹, Andini Nur Aisyah², Alif Nur Hidayat¹

¹Program Studi Teknik Mesin, Universitas Singaperbangsa Karawang
Jl. H.S. Ronggowaluyo, Telukjambe Timur, Karawang, Jawa Barat 41361

²Program Studi Teknik Kimia, Universitas Singaperbangsa Karawang
Jl. H.S. Ronggowaluyo, Telukjambe Timur, Karawang, Jawa Barat 41361

Abstrak

Pengendalian temperatur dalam *freezer* sangat penting untuk menjaga kualitas dan keamanan produk, terutama di industri makanan dan farmasi. Fluktuasi temperatur yang tidak terkontrol dapat menyebabkan kerusakan produk, meningkatkan pemborosan, dan menurunkan kualitas. Teknologi *machine learning* menawarkan solusi yang efektif untuk memprediksi dan mengendalikan temperatur, memungkinkan pemantauan yang lebih akurat dan respons yang cepat terhadap perubahan kondisi. Penelitian ini bertujuan mengembangkan model *machine learning* menggunakan *framework TensorFlow* untuk memprediksi temperatur dalam *freezer*. Data temperatur dikumpulkan dari sensor-sensor yang dipasang di dalam *freezer* dan digunakan untuk melatih serta menguji beberapa arsitektur model *machine learning*, termasuk *long short-term memory* (LSTM) dan *Convolutional 1D* (Conv1D). Pengembangan model menggunakan TensorFlow memanfaatkan fitur canggih yang memungkinkan pembuatan, pelatihan, dan pengujian model secara efisien. Hasil penelitian menunjukkan bahwa model Conv1D dengan komposisi data 90% data latih, 5% data validasi, dan 5% data uji menghasilkan prediksi terbaik dengan nilai RMSE uji sebesar 0,02085°C, dan nilai MAPE uji sebesar 0,33522%. Model prediksi ini berpotensi digunakan sebagai sistem peringatan dini untuk mencegah kerusakan produk. Penelitian ini diharapkan memberikan kontribusi signifikan dalam pengembangan sistem pemantauan dan kontrol temperatur yang lebih efisien di *freezer*, dengan penerapan potensial dalam berbagai industri, termasuk makanan dan farmasi. Hasil penelitian juga memperkuat potensi besar penerapan *machine learning* dalam prediksi serta pemantauan lingkungan.

Kata kunci: Kontrol temperatur; *Machine learning*; TensorFlow; Prediksi temperatur; LSTM; Conv1D

Abstract

Temperature control in freezers is crucial to maintaining product quality and safety, particularly in the food and pharmaceutical industries. Uncontrolled temperature fluctuations can lead to product damage, increased waste, and reduced quality. Machine learning technology offers an effective solution for predicting and controlling temperature, enabling more accurate monitoring and rapid responses to changing conditions. This study aims to develop a machine learning model using the TensorFlow framework to predict freezer temperatures. Temperature data were collected from sensors installed inside the freezer and used to train and test several machine learning architectures, including Long Short-Term Memory (LSTM) and 1D Convolutional (Conv1D) networks. Model

*Corresponding author

Alamat email: ahmaddavi1256@gmail.com

<https://doi.org/10.35261/gijtsi.v5i02.12524>

Diterima 04 November 2024; Disetujui 29 November 2024; Terbit online 30 November 2024

development leveraged TensorFlow's advanced features, enabling efficient model creation, training, and testing. The results show that the Conv1D model with a data composition of 90% training, 5% validation, and 5% testing achieved the best predictions, with a test RMSE of 0.02085°C and a test MAPE of 0.33522%. This predictive model has the potential to be used as an early warning system to prevent product damage. This research is expected to significantly contribute to the development of more efficient temperature monitoring and control systems in freezers, with potential applications across industries such as food and pharmaceuticals. The findings also reinforce the substantial potential of machine learning in environmental prediction and monitoring.

Keywords: *Temperature control; Machine learning; TensorFlow; Temperature prediction; LSTM; Conv1D*

Pendahuluan

Temperatur merupakan salah satu parameter penting dalam kehidupan sehari-hari. Dengan terus berkembangnya masyarakat modern, mendorong banyak penelitian pada bidang kontrol temperatur [1], [2], [3]. Pemeliharaan pada alat kontrol temperatur menjadi faktor penting dalam memastikan kualitas produk yang disimpan. Model pemantauan saat ini memerlukan pengoptimalan secara *realtime*, seperti pemantauan secara *realtime* yang buruk dan masih banyaknya intervensi secara manual. Masalah-masalah ini membatasi pengelolaan pemantauan temperatur dan tidak dapat menjamin operasi yang efisien.

Kemajuan teknologi saat ini mendorong masifnya penggunaan *machine learning* dalam berbagai bidang [4]. *Machine learning* merupakan bidang interdisipliner yang memungkinkan komputer untuk meniru perilaku belajar manusia dengan mempelajari pola data dalam *dataset* untuk mengambil sebuah keputusan [5]. Dalam bidang pertanian, Alrowaily, dkk. [6] pada tahun 2024 menerapkan *machine learning* pada robot pertanian untuk mengurangi kesalahan manuver. Dalam bidang kesehatan, Dorraiki, dkk. [7] pada tahun 2024 menggunakan *machine learning* untuk memprediksi penyakit kardiovaskular dengan *dataset* kesehatan mental. Dalam bidang ekonomi, Garzon, dkk. Pada tahun 2024 menggunakan *machine learning* untuk klasifikasi laba dengan penjelasan dalam risiko kredit usaha kecil dalam pinjaman *peer-to-peer*. Novella, dkk. [8] pada tahun 2021 menggunakan *machine learning* untuk mengidentifikasi pembakaran pada mesin pengapian jet turbulen. Flores, dkk. pada tahun 2024 juga telah melakukan tinjauan kritis terhadap penggunaan *machine learning* pada komposit serat nanokomposit untuk menuju kontrol siklus dalam rantai proses industri. Oleh karena itu, berbagai bidang dapat menerapkan *machine learning* dalam optimasi, prediksi, dan pengambilan keputusan.

Untuk mengatasi pemantauan temperatur banyak peneliti yang telah melakukan upaya dalam pemantauan temperatur. Beberapa akademisi telah melakukan penelitian tentang *deep-learning* dalam memprediksi temperatur. Akbar, Santoso, dan Warsito [9] pada tahun 2022 melakukan pemodelan prediksi tingkat temperatur kota Semarang menggunakan metode LSTM. Data yang digunakan berasal dari website BMKG yang dinormalisasi agar seluruh variabel memiliki pengaruh terhadap model yang dibuat. Hasil prediksi menunjukkan bahwa model yang dikembangkan memiliki performa yang baik dalam memprediksi dengan RMSE sebesar 0,725 dan interval data uji sebesar 5,8. Yang, dkk. [10] pada tahun 2024 melakukan pemodelan prediksi temperatur air tinggi yang tidak normal di perairan dekat pantai di sekitar Semenanjung Korea menggunakan data ECMWF ERA5 dan model *deep-learning*. Hasil eksperimen dari model prediksi 1

hari untuk stasiun E, S, dan W di sekitar Semenanjung Korea menghasilkan RMSE rata-rata = 0,293, MAPE = 1,313 %. Dengan menggunakan data SST yang diprediksi untuk memperkirakan HWT, Skor F1 dari model prediksi 1 hingga 4 hari berada di atas 0,8, yang menunjukkan prediksi efektif suhu laut abnormal. Kebede, Yang, dan Huang [11] pada tahun 2024 melakukan penelitian prediksi temperatur pengerasan jalan secara *realtime* melalui *machine learning*. Dalam penelitiannya, model pembelajaran yang digunakan meliputi XGM, LGBM, RF, dan AdaBoost. Pada bidang otomotif, Gu, dkk. [12] pada tahun 2024 melakukan penelitian optimasi struktur dan prediksi temperatur baterai pada sistem manajemen termal baterai berdasarkan *machine learning*. Optimasi struktur yang dilakukan meningkatkan kinerja pembuangan panas baterai dan model *machine learning* yang digunakan untuk prediksi temperatur baterai memiliki kesalahan maksimum pada set validasi hanya sebesar 0,45. Model tersebut menunjukkan akurasi tinggi dengan R2 sebesar 0,998, MAE sebesar 0,104, MAPE sebesar 0,324 %, SMAPE sebesar 0,324 %, dan RMSE sebesar 0,131.

Freezer saat ini sudah sangat umum digunakan sebagai tempat penyimpanan obat-obatan, penyimpanan gas cair, penyimpanan makanan, dll. [13], [14], [15]. Sebagai contoh, dalam industri pangan dan rumahan, *freezer* biasanya digunakan untuk menyimpan daging sapi, daging kambing, daging ayam, ikan, dll. yang berperan sebagai penghambat pertumbuhan bakteri yang dapat membuat daging menjadi busuk [16]. Fluktuasi temperatur pada *freezer* dapat menyebabkan kerusakan dan penurunan kualitas produk serta dapat membuat pemborosan [17]. Temperatur yang stabil dan terkontrol pada *freezer* sangat penting untuk menjaga kualitas barang yang ada di dalamnya. Oleh karena itu, pemantauan dan prediksi temperatur secara *realtime* menjadi suatu hal yang penting.

Penelitian ini akan berfokus pada pemodelan prediksi dalam pemantauan temperatur *freezer* menggunakan *machine learning*. Studi ini menggunakan *framework* TensorFlow untuk memprediksi temperatur *freezer* berdasarkan *time-series*. TensorFlow merupakan salah satu *framework machine learning* yang umum digunakan dalam prediksi data [18]. Prediksi data berdasarkan *time-series* dapat dijadikan sebagai acuan dalam pengambilan keputusan yang tepat. Kesuksesan metode diagnosis berbasis data ini didasari oleh kemampuan mempelajari pemetaan antara data aktual dengan informasi kesalahan dari data historis [19]. Hasil penelitian ini diharapkan dapat diterapkan dengan baik dalam pemantauan dan pengoptimalan temperatur dalam *freezer*.

Metode Penelitian

Dalam penelitian ini kami menerapkan metode pembelajaran menggunakan *layer long-short term memory* (LSTM) dan Conv1D. Pemodelan dilakukan dengan menggunakan *framework machine learning* TensorFlow untuk membuat model prediksi temperatur dalam *freezer*.

Dataset


Dataset diperoleh melalui pengukuran menggunakan sensor yang diletakan di dalam *freezer* selama 12 jam pada tanggal 13 Januari 2024 dan fluktuasi temperatur dalam *freezer* dicatat setiap detik, dengan begitu waktu akan menjadi prediktor berdasarkan apa yang telah dipelajari oleh model. Jumlah data temperatur yang dicatat adalah sebanyak 43.288 data dengan pembagian sebagai berikut:

Tabel 1. Komposisi *dataset*

No	Data latih	Data validasi	Data uji
1	70%	15%	15%
2	80%	10%	10%
3	90%	5%	5%

Tahapan Pemodelan

Pemodelan ini dimulai dengan persiapan data yang meliputi pengambilan data temperatur di dalam *freezer* selama 12 jam, membersihkan data dengan mengecek data yang kosong (*missing value*) dan memperbaiki data yang tidak sesuai, mengkonversi format data, dan membagi komposisi data latih dan data uji. Tahap kedua adalah mengembangkan model, melatih model, dan menguji model. Tahap ketiga adalah evaluasi model dengan melakukan perhitungan metrik evaluasi model.

**Gambar 1.** Diagram alir pemodelan

Machine Learning Network

a) Long short-term memory layer

Long short-term memory (LSTM) adalah turunan dari *recurrent neural network* (RNN). LSTM dirancang untuk menangani permasalahan *vanishing* dan *exploding* pada RNN [20]. Sel LSTM terdiri atas gerbang *input*, gerbang *forget*, dan gerbang *output* yang masing-masing berfungsi sebagai berikut [21]:

1. Gerbang masukan, i , memutuskan berapa banyak informasi baru dari masukan x_t saat ini yang akan ditambahkan ke status seluler c_t saat ini berdasarkan status tersembunyi sebelumnya h_{t-1} dengan Persamaan (1) dan (2):

$$i_t = \sigma(W_i \cdot x_t + U_i \cdot h_{t-1} + b_i) = \sigma(\hat{i}_t) \quad (1)$$

$$a_t = \tanh(W_c \cdot x_t + U_i \cdot h_{t-1} + b_c) = \tanh(\hat{a}_t) \quad (2)$$

Keterangan:

i_t : Output dari *input gate*, menunjukkan banyaknya informasi baru yang akan ditambahkan.

- W_i : Matriks bobot untuk masukan (x_t) pada gerbang *input*.
 x_i : Nilai spesifik dari dimensi i di dalam input x_t .
 U_i : Matriks bobot untuk keadaan tersembunyi sebelumnya ($h_t - 1$) pada gerbang *input*.
 h_{t-1} : *Hidden state* dari waktu sebelumnya ($t - 1$).
 b_i : Nilai bias pada gerbang *input*.
 a_t : Informasi baru yang dihasilkan dari masukan saat ini x_t dan keadaan tersembunyi sebelumnya $h_t - 1$.
 W_c : Matriks bobot untuk masukan (x_t) pada gerbang *cell state*.
 b_c : Nilai bias pada gerbang *cell state*.

2. *Forget gate*, f , memutuskan informasi apa dari status seluler sebelumnya c_{t-1} yang akan dihapus, dan bagaimana status seluler sebelumnya c_{t-1} diperbarui ke status seluler saat ini c_t dengan Persamaan (3) dan (4):

$$f_t = \sigma (W_f \cdot x_i + U_f \cdot h_{t-1} + b_f) = \sigma(\hat{f}_t) \quad (3)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot a_t \quad (4)$$

Keterangan:

- f_t : *Output* dari *forget gate*, menunjukkan banyaknya informasi lama yang akan dilupakan.
 W_f : Matriks bobot untuk masukan (x_t) pada gerbang *forget*.
 x_i : Nilai spesifik dari dimensi i di dalam input x_t .
 U_f : Matriks bobot untuk keadaan tersembunyi sebelumnya ($h_t - 1$) pada gerbang *forget*.
 h_{t-1} : *Hidden state* dari waktu sebelumnya ($t - 1$).
 b_f : Nilai bias pada gerbang *forget*.
 c_t : *Cell state* pada waktu t .
 c_{t-1} : *Cell state* dari waktu sebelumnya ($t - 1$).
 i_t : *Output* dari *input gate*, menunjukkan banyaknya informasi baru yang akan ditambahkan.
 a_t : Informasi baru yang dihasilkan dari masukan saat ini x_t dan keadaan tersembunyi sebelumnya $h_t - 1$.

3. Gerbang keluaran, o , memutuskan bagaimana keadaan seluler saat ini c_t mempengaruhi keadaan tersembunyi keluaran saat ini h_t dengan Persamaan (5) dan (6):

$$o_t = \sigma (W_o \cdot x_i + U_o \cdot h_{t-1} + b_o) = \sigma(\hat{o}_t) \quad (5)$$


$$h_t = o_t \cdot \tanh(c_t) \quad (6)$$

Keterangan:

- o_t : *Output* dari *output gate*, menunjukkan banyaknya informasi *cell state* yang memengaruhi *hidden state*.
 W_o : Matriks bobot untuk masukan (x_t) pada gerbang *output*.
 x_i : Nilai spesifik dari dimensi i di dalam input x_t .
 U_o : Matriks bobot untuk keadaan tersembunyi sebelumnya ($h_t - 1$) pada gerbang *output*.
 h_{t-1} : *Hidden state* dari waktu sebelumnya ($t - 1$).
 b_o : Nilai bias pada gerbang *output*.

h_t : *Hidden state* pada waktu t .

dimana W , U , b adalah matriks bobot gerbang, matriks bobot status tersembunyi, dan bias gerbang; a_t menggambarkan status seluler di bawah masukan saat ini; t mewakili langkah waktu saat ini; $\odot$ adalah *element-wise product operation* dan σ mewakili fungsi aktivasi sigmoid.



Gambar 2. Sel LSTM [21]

b) Conv1D layer

Lapisan 1 dimensi konvolusional, atau yang biasa dikenal sebagai Conv1D, merupakan jenis lapisan yang digunakan pada model *deep-learning* dalam domain data sekuensial atau data satu dimensi. Lapisan ini adalah bagian dari jaringan syaraf konvolusional dan dirancang untuk menangkap pola, fitur dan hubungan sekuensial satu dimensi [22].

Layer ini melakukan perkalian elemen demi elemen dengan segmen input yang ditumpangkan dan kemudian menjumlahkan hasilnya. Pendekatan ini digunakan untuk membedakan dan memperkuat pola local atau kerumitan temporal dalam suatu urutan. Operasi konvolusi 1 dimensi divisualisasikan pada gambar 3. Lapisan konv1D memproses urutan input melalui serangkaian filter yang masing-masing dirancang untuk mengekstraksi fitur temporal tertentu. Diberikan urutan *input* 1D $x[n]$, di mana n adalah indeks waktu diskrit, dan filter $h[k]$, di mana k adalah indeks filter diskrit, operasi konvolusi diskrit didefinisikan sebagai [23]:

$$y[m] = (x * h)[m] = \sum_{n=-\infty}^{\infty} x[n] \cdot h[m - n] \quad (7)$$


Keterangan:

$y[m]$: Output hasil operasi konvolusi pada indeks waktu m .

$x[n]$: Masukan 1 dimensi (1D *input*) pada indeks waktu n .

$h[m - n]$: Nilai filter atau *kernel* konvolusi setelah digeser sebesar $m - n$.

- m : Indeks waktu pada *output* $y[m]$ yang menunjukkan posisi elemen hasil konvolusi.
- n : Indeks waktu pada *input* $x[n]$ yang digunakan dalam pergeseran filter selama proses konvolusi.



Gambar 3. Arsitektur CNN-1D [23]

Dalam konteks lapisan Conv1D pada *neural network*:

1. Urutan dan filter memiliki panjang terbatas, sehingga membatasi penjumlahan tak terbatas pada panjang urutan.
2. Istilah bias sering diperkenalkan, yang menambahkan *offset* pada hasil konvolusi.
3. Fungsi aktivasi diterapkan per elemen pada *output*, yang memperkenalkan non-linearitas pada model.

$$y[m] = \sigma \left(\sum_{n=0}^{N-1} x[n] \cdot h[m-n] + b \right) \quad (8)$$

Keterangan:

- σ : fungsi aktivasi seperti ReLU, sigmoid, atau tanh
- $x[n]$: Masukan 1 dimensi (1D *input*) pada indeks waktu n .
- $h[m-n]$: Nilai filter atau *kernel* konvolusi setelah digeser sebesar $m-n$.
- b : istilah bias
- N : panjang urutan *input*
- n : Indeks waktu pada *input* $x[n]$ yang digunakan dalam pergeseran filter selama proses konvolusi.

Metrik Evaluasi Model

Metode untuk mengevaluasi kinerja model adalah dengan menghitung nilai evaluasi metriknya seperti nilai *root mean square error* (RMSE) dan nilai *mean absolute percentage error* (MAPE). Nilai *root mean square error* (RMSE) adalah rata-rata kuadrat dari jumlah kesalahan pada model yang dibuat. Rumusan kuadratur dalam RMSE menekan kontribusi selisih yang lebih besar sebagai bentuk fungsional yang sama seperti

simpangan baku, ini membuat nilainya sebanding langsung dengannya [24]. Berikut adalah rumusan dari *root mean square error* (RMSE) [25]:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\tilde{y}_i - y_i)^2} \quad (9)$$

Keterangan:

N : Jumlah data
 $\tilde{y}_i$: Nilai prediksi
 y_i : Nilai aktual

Sedangkan, nilai *mean absolute percentage error* (MAPE) adalah persentase rata-rata kesalahan model yang dibuat. MAPE sangat cocok digunakan untuk membandingkan antara kumpulan data yang memiliki skala yang berbeda [26]. Berikut ini adalah rumusan dari *mean absolute percentage error* (MAPE) [27]:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{\tilde{y}_i - y_i}{y_i} \right| \cdot 100\% \quad (10)$$

Keterangan:

N : Jumlah data
 $\tilde{y}_i$: Nilai prediksi
 y_i : Nilai aktual

Hasil dan Pembahasan

Percobaan ini adalah mencari model yang memiliki kinerja terbaik dalam memprediksi. Dalam menemukan model dengan kinerja terbaik, pengujian dilakukan dengan membandingkan nilai prediksi dengan nilai aktual dari *dataset*. Kinerja model akan direpresentasikan oleh metrik evaluasi model, yaitu, *root mean square error* (RMSE) dan *mean absolute percentage error* (MAPE). Pengujian ini akan dibagi menjadi beberapa skenario atau model dengan parameter komposisi *dataset* (P1) dan jenis *layer* syaraf (P2).

Skenario percobaan dibuat atas parameter yang telah disediakan untuk membandingkan kinerja masing-masing model yang disajikan pada tabel di bawah ini:

Tabel 2. Parameter skenario percobaan

	1	2	3
P1	70/15/15	80/10/10	90/5/5
P2	LSTM	Conv1D	

Tabel 3. Skenario percobaan

Skenario	Parameter eksperimen
1	[P1.1], [P2.1]
2	[P1.1], [P2.2]
3	[P1.2], [P2.1]
4	[P1.2], [P2.2]
5	[P1.3], [P2.1]
6	[P1.3], [P2.2]

Dalam penelitian ini, model prediksi dikembangkan menggunakan *framework deep learning* TensorFlow yang dijalankan dengan bahasa pemrograman python versi 3.8. Percobaan dilakukan sebanyak 6 kali sama seperti skenario yang tersaji pada Tabel 3. Prediksi terbaik didasarkan pada nilai metrik evaluasi model yang didapatkan. Semakin kecil nilai metrik evaluasi yang didapatkan, maka, semakin kecil juga tingkat kesalahan prediksi yang dilakukan oleh model. Nilai RMSE dan MAPE dari keseluruhan skenario tersaji pada Tabel 4.


Tabel 4. Hasil percobaan

Skenario	Parameter eksperimen	Validation		Test	
		RMSE (°C)	MAPE (%)	RMSE (°C)	MAPE (%)
1	[P1.1], [P2.1]	0.02894	0.60918	0.11261	1.94834
2	[P1.1], [P2.2]	0.02299	0.49445	0.02226	0.40450
3	[P1.2], [P2.1]	0.02935	0.60533	0.12248	2.29502
4	[P1.2], [P2.2]	0.02162	0.44121	0.02254	0.39132
5	[P1.3], [P2.1]	0.05069	1.05433	0.11024	2.18681
6	[P1.3], [P2.2]	0.01887	0.32968	0.02085	0.33522

Hasil percobaan terbaik dalam penelitian ini didapatkan pada skenario 6 dengan nilai *root mean square error* (RMSE) validasi sebesar 0,01887°C, nilai *mean absolute percentage error* (MAPE) validasi sebesar 0,32968%, nilai *root mean square error* (RMSE) uji sebesar 0,02085°C, dan nilai *mean absolute percentage error* (MAPE) uji sebesar 0,33522%. Perbandingan hasil prediksi dan data aktual temperatur dalam *freezer* dapat dilihat melalui Tabel 5 dan plot grafik pada Gambar 4.

Tabel 5. Hasil prediksi skenario 6

Index	Waktu	Temperatur aktual (°C)	Temperatur prediksi (°C)	MAPE (%)
0	17:25:27	-4,639	-4,629	0,20945
1	17:25:28	-4,608	-4,635	0,58682
2	17:25:29	-4,585	-4,626	0,89667
3	17:25:30	-4,608	-4,606	0,02614
4	17:25:31	-4,639	-4,604	0,75349
...	...	...	...	...
2156	18:01:23	-5,081	-5,055	0,49884
2157	18:01:24	-5,097	-5,062	0,67235
2158	18:01:25	-5,112	-5,079	0,63261
2159	18:01:26	-5,097	-5,091	0,09839
2160	18:01:27	-5,112	-5,097	0,28480



Gambar 4. Plot grafik perbandingan hasil prediksi dan aktual model 6

Berdasarkan komposisi datanya, model dengan *layer* Conv1D lebih stabil terhadap kuantitas data ujinya, hal tersebut terlihat ketika semakin banyak komposisi data pelatihannya maka nilai metrik evaluasinya relatif menurun. Berbeda dengan model yang menggunakan *layer* LSTM, di mana nilai metrik evaluasinya berfluktuasi seiring bertambahnya komposisi data pelatihannya. Model dengan *layer* Conv1D dapat dengan baik mengenali pola lokal dalam data sekuensial karena menggunakan *kernel* konvolusi yang memungkinkan model untuk mengekstrak fitur penting dari data secara efisien. Model Conv1D memungkinkan proses konvolusi dapat dilakukan secara paralel yang meningkatkan efisiensi komputasi. Sehingga, dalam tahap pelatihan modelnya bisa selesai dalam waktu yang singkat.

Kesimpulan

Dalam penelitian ini, model dikembangkan atas parameter komposisi data dan jenis *layer*. *Layer* LSTM dan Conv1D diimplementasikan pada model prediksi temperatur freezer yang dilatih menggunakan *dataset time-series* temperatur freezer yang telah dipersiapkan. Berdasarkan enam skenario percobaan yang dibuat atas dua parameter percobaan, didapatkan model dengan kinerja terbaik pada skenario percobaan 6. Dalam skenario ini, komposisi data uji, data validasi, dan data tes yang digunakan berturut-turut adalah 90%, 5%, dan 5% menggunakan *layer* Conv1D. Komposisi data pelatihan yang lebih besar membantu Conv1D menghasilkan prediksi yang lebih akurat. Nilai evaluasi metrik pengujian yang didapatkan pada model ini sangat baik dibanding model lainnya. Nilai RMSE yang didapat sebesar 0,02085°C dan nilai MAPE yang didapatkan sebesar 0,2848%. Selain itu, model yang menggunakan *layer* Conv1D secara konsisten memiliki kinerja yang lebih baik di semua komposisi jika dibandingkan dengan model yang menggunakan *layer* LSTM. Secara keseluruhan, model dengan *layer* Conv1D unggul dalam mengekstraksi fitur secara efisien dalam data sekuensial, kecepatan pelatihan, dan stabilitas kinerja prediksi.

Daftar Pustaka

- [1] Y. Hu dan B. Shen, "Experimental insights into thermoelectric freezer systems: Feasibility and efficiency," *Energy Convers. Manag.* X, vol. 23, no. June, 2024, doi: 10.1016/j.ecmx.2024.100676.
- [2] P. Yang *dkk.*, "Performance improvement of a household freezer with a microchannel flat-tube evaporator," *Case Stud. Therm. Eng.*, vol. 49, no. August, 2023, doi: 10.1016/j.csite.2023.103394.
- [3] J. Liu dan Y. Liu, "Experimental investigation of a bypass two-circuit cycle refrigerator-freezer with low GWP zeotropic refrigerants," *Case Stud. Therm. Eng.*, vol. 54, no. January, 2024, doi: 10.1016/j.csite.2024.104071.
- [4] O. Surucu, S. A. Gadsden, dan J. Yawney, "Condition Monitoring using Machine Learning: A Review of Theory, Applications, and Recent Advances," *Expert Syst. Appl.*, vol. 221, no. October 2021, 2023, doi: 10.1016/j.eswa.2023.119738.
- [5] S. Russel dan P. Norvig, *Artificial Intelligence: A Modern Approach*, 4 th. Cambridge: e press synd icate o f the un ivers ity o f cambr idge, 2021.
- [6] M. A. Alrowaily, O. Alruwaili, M. Alghamdi, M. Alshammeri, M. Alahmari, dan G. Abbas, "Application of extreme machine learning for smart agricultural robots to reduce manoeuvring adaptability errors," *Alexandria Eng. J.*, vol. 109, no. May, hal. 655–668, 2024, doi: 10.1016/j.aej.2024.09.062.
- [7] M. Dorraki *dkk.*, "Improving Cardiovascular Disease Prediction With Machine Learning Using Mental Health Data: A Prospective UK Biobank Study," *JACC Adv.*, vol. 3, no. 9, 2024, doi: 10.1016/j.jacadv.2024.101180.
- [8] R. Novella, B. Pla, P. Bares, dan A. Aramburu, "Identification of Adequate Combustion in Turbulent Jet Ignition Engines using Machine Learning Algorithms," hal. 102–107, 2021, doi: <https://doi.org/10.1016/j.ifacol.2021.10.148>.
- [9] R. Akbar, R. Santoso, dan B. Warsito, "Prediksi Tingkat Temperatur Kota Semarang Menggunakan Metode Long Short-Term Memory (Lstm)," *J. Gaussian*, vol. 11, no. 4, hal. 572–579, 2023, doi: 10.14710/j.gauss.11.4.572-579.
- [10] H. Yang, S. Yoon, H. T. Lee, K. S. Kim, H. J. Han, dan Y. J. Park, "Abnormal high water temperature prediction in nearshore waters around the Korean Peninsula using ECMWF ERA5 data and a deep learning model," *J. Sea Res.*, vol. 202, no. September, 2024, doi: 10.1016/j.seares.2024.102546.
- [11] Y. B. Kebede, M. Der Yang, dan C. W. Huang, "Real-time pavement temperature prediction through ensemble machine learning," *Eng. Appl. Artif. Intell.*, vol. 135, no. November 2023, 2024, doi: 10.1016/j.engappai.2024.108870.
- [12] X. Gu, W. Lei, J. Xi, dan M. Song, "Structural optimization and battery temperature prediction of battery thermal management system based on machine learning," *Case Stud. Therm. Eng.*, vol. 62, no. September, 2024, doi: 10.1016/j.csite.2024.105207.
- [13] A. Augusto *dkk.*, "A novel seaweed-based biodegradable and active food film to reduce freezer burn in frozen salmon," *Food Hydrocoll.*, vol. 156, no. June, 2024, doi: 10.1016/j.foodhyd.2024.110332.
- [14] H. Jouhara *dkk.*, "Low-temperature heat transfer mediums for cryogenic applications mid InfraRed Instrument," *J. Taiwan Inst. Chem. Eng.*, vol. 148, no. January, hal. 104709, 2023, [Daring]. Tersedia pada: <https://doi.org/10.1016/j.jtice.2023.104709>
- [15] Q. Xu, B. Deng, Y. Wang, W. Liu, dan G. Chen, "Small, affordable, ultra-low-temperature vapor-compression and thermoelectric hybrid freezer for clinical applications," *Cell Reports Phys. Sci.*, vol. 4, no. 12, 2023, doi: 10.1016/j.xcrp.2023.101735.
- [16] D. Eriksson *dkk.*, "Survival of *Campylobacter jejuni* in frozen chicken meat and risks associated with handling contaminated chicken in the kitchen," *Food Control*, vol.

- 145, no. June 2022, 2023, doi: 10.1016/j.foodcont.2022.109471.
- [17] J. Ullah, P. S. Takhar, dan S. S. Sablani, "Effect of temperature fluctuations on ice-crystal growth in frozen potatoes during storage," *Lwt*, vol. 59, no. 2P1, hal. 1186–1190, 2014, doi: 10.1016/j.lwt.2014.06.018.
 - [18] S. S. Sorour, C. A. Saleh, dan M. Shazly, "A review on machine learning implementation for predicting and optimizing the mechanical behaviour of laminated fiber-reinforced polymer composites," *Helicon*, vol. 10, no. 13, 2024, doi: 10.1016/j.helicon.2024.e33681.
 - [19] Y. G. Lv, Y. T. Wang, T. Meng, Q. W. Wang, dan W. X. Chu, "Review on thermal management technologies for electronics in spacecraft environment," *Energy Storage Sav.*, vol. 3, no. 3, hal. 153–189, 2024, doi: 10.1016/j.enss.2024.03.001.
 - [20] L. Wiranda dan M. Sadikin, "Penerapan Long Short Term Memory pada Data Time Series untuk Memprediksi Penjualan Produk PT. Metiska Farma," *J. Nas. Pendidik. Tek. Inform.*, vol. 8, no. 3, hal. 184–196, 2019.
 - [21] F. Le Peng, Y. K. Qiao, dan C. Yang, "A LSTM-RNN based intelligent control approach for temperature and humidity environment of urban utility tunnels," *Helicon*, vol. 9, no. 2, 2023, doi: 10.1016/j.helicon.2023.e13182.
 - [22] I. Elafi, N. Zrira, A. Kamal-Idrissi, H. A. Khan, dan A. Ettouhami, "STA-SST: Spatio-temporal time series prediction of Moroccan Sea surface temperature," *J. Sea Res.*, vol. 200, no. May, 2024, doi: 10.1016/j.seares.2024.102515.
 - [23] M. H. Zafar, S. M. S. Bukhari, M. A. Houran, M. Mansoor, N. M. Khan, dan F. Sanfilippo, "DeepTimeNet: A novel architecture for precise surface temperature estimation of lithium-ion batteries across diverse ambient conditions," *Case Stud. Therm. Eng.*, vol. 61, no. February, 2024, doi: 10.1016/j.csite.2024.105002.
 - [24] M. W. Liemohn, A. D. Shane, A. R. Azari, A. K. Petersen, B. M. Swiger, dan A. Mukhopadhyay, "RMSE is not enough: Guidelines to robust data-model comparisons for magnetospheric physics," *J. Atmos. Solar-Terrestrial Phys.*, vol. 218, no. March, 2021, doi: 10.1016/j.jastp.2021.105624.
 - [25] Z. Mustaffa dan M. H. Sulaiman, "Battery remaining useful life estimation based on particle swarm optimization-neural network," *Clean. Energy Syst.*, vol. 9, no. May, 2024, doi: 10.1016/j.cles.2024.100151.
 - [26] A. Hightower, A. Ziedan, J. Guo, X. Zhu, dan C. Brakewood, "A comparison of time series methods for post-COVID transit ridership forecasting," *J. Public Transp.*, vol. 26, no. May, 2024, doi: 10.1016/j.jpubtr.2024.100097.
 - [27] T. Zhang, Y. Pan, L. Huang, dan X. Zhong, "An empirical study of combinational load forecasting in a city power company of China," *Energy Reports*, vol. 11, no. December 2023, hal. 637–650, 2024, doi: 10.1016/j.egyr.2023.12.015.