

## ***Forecasting Sea Surface Salinity in the Eastern Madura Strait Using 1D Convolutional Neural Network***

Peramalan Salinitas Permukaan Air Laut di Selat Madura Bagian Timur Menggunakan 1D Convolutional Neural Network

**Fahrul Rozzy<sup>1</sup>, Dian Candra Rini Novitasari<sup>2</sup>, Dian Yulianti<sup>3</sup>, Puteri Permata Sani<sup>4</sup>**

<sup>1,2,3</sup>Matematika, UIN Sunan Ampel Surabaya, Indonesia

<sup>4</sup>Badan Meteorologi Klimatologi dan Geofisika, Indonesia

<sup>1</sup>fahrulrozzy547@gmail.com, <sup>2\*</sup>diancrini@uinsa.ac.id, <sup>3</sup>dian.yulianti@uinsa.ac.id,

<sup>4</sup>puteri.permata@bmgk.go.id

\*: *Penulis korespondensi (corresponding author)*

### ***Informasi Artikel***

*Received: January 2023*

*Revised: October 2023*

*Accepted: November 2023*

*Published: February 2024*

### ***Abstract***

*Purpose: The purpose of the research is to predict sea surface salinity in the Eastern Madura Strait using 1D-CNN. The performance of the 1D-CNN architecture model was also evaluated using MAPE and  $R^2$ . The best model is used for predictions for 6 days. Based on the prediction results, it can provide information to the public regarding the surface salinity conditions of the Eastern Madura Strait.*

*Design/methodology/approach: Before predicting sea surface salinity, the first to do is to predict the predictor variables. The predictor variables used are current speed (eastward & northward) and salinity at 2 different depths. This research uses the 1D-CNN method.*

*Findings/result: The 1D-CNN model was able to predict salinity very well. The model obtained the best MAPE and  $R^2$  of 2.86% and 0.931. The best model evaluation is at a dropout of 0.8 and a batch size of 64. Predictions for the next 6 days (every 12 hours) have decreased. The lowest predicted number touches 33,313 PSU.*

*Originality/value/state of the art: This research uses different parameters and methods from previous research. The results obtained were better than previous research.*

### ***Abstrak***

*Tujuan: Tujuan Penelitian adalah memprediksi salinitas permukaan air laut pada Selat Madura bagian Timur menggunakan 1D-CNN. Performa model arsitektur 1D-CNN juga dievaluasi menggunakan MAPE dan  $R^2$ . Model terbaik digunakan untuk prediksi selama 6 hari. Berdasarkan hasil prediksi, dapat memberi informasi ke*

*Keywords: 1D-CNN, Forecasting, Salinity*

*Kata kunci: 1D-CNN, Peramalan, Salinitas*

---

masyarakat perihal kondisi salinitas permukaan Selat Madura bagian Timur.

Perancangan/metode/pendekatan: Hal pertama yang perlu dilakukan adalah memprediksi variabel prediktor sebelum memprediksi salinitas permukaan. Variabel prediktor yang digunakan adalah kecepatan arus (*eastward & northward*) dan salinitas pada 2 kedalaman berbeda. Penelitian ini menggunakan metode 1D-CNN.

Hasil: Model 1D-CNN mampu memprediksi salinitas dengan sangat baik. Model memperoleh MAPE dan  $R^2$  terbaik sebesar 2.86% dan 0.931. Evaluasi model terbaik pada nilai *dropout* 0.8 dan *batchsize* 64. Prediksi untuk 6 hari ke depan (per 12 jam) mengalami penurunan. Angka terendah prediksi menyentuh 33.313 PSU.

Keaslian/ *state of the art*: Penelitian ini menggunakan parameter dan metode yang berbeda dengan penelitian sebelumnya. Hasil yang didapat lebih baik dari penelitian sebelumnya.

---

## 1. Pendahuluan

Perairan Selat Madura merupakan perairan strategis yang mencakup 11 Kabupaten atau Kota di Jawa Timur dengan kondisi perairan semi tertutup. Perairan ini dapat dibilang sebagai perairan yang cukup dangkal. Kondisi arus pada perairan ini cenderung tenang [1]. Didukung dengan lokasi yang strategis, pada 14 Mei 2016 dilakukan penelitian di Selat Madura bagian Timur oleh Purwangka dan Mubarok. Penelitian tersebut dilakukan tepat pada titik (*lat,long*) (-7.3867, 113.87) dan (-7.3814,113.904). Purwangka dan Mubarok meneliti kegiatan tangkap ikan menggunakan cantrang yang dilakukan pada titik koordinat tersebut. Setidaknya dapat terkumpul 549 tangkapan ikan yang terdiri dari 38 spesies ikan, hal ini menandakan bahwa perairan tersebut kaya akan biota laut. Berdasarkan penelitian tersebut diperoleh indeks kekayaan spesies dengan kategori baik untuk perairan Selat Madura [1].

Salinitas merupakan parameter penting dalam oseanografi. Salinitas berperan dalam mengendalikan kondisi dan kualitas air laut [2]. Distribusi salinitas juga mempengaruhi sifat kimia, biologi, dan fisika air laut. Sebagai salah satu karakteristik utama lautan, salinitas memiliki kemanfaatan bagi manusia dan biota laut. Persebaran organisme biota laut juga dipengaruhi oleh faktor salinitas air laut. Hal ini menjadikan salinitas sangat bermanfaat dalam aktivitas kemaritiman [3].

Berdasarkan penelitian yang dilakukan oleh Prihatno, jumlah mineral terlarut pada perairan Selat Madura berada antara 33.8 ppm hingga 35.1 ppm. Hal ini juga dibuktikan bahwa semakin tinggi salinitas air laut maka semakin tinggi pula jumlah mineral terlarut. Artinya kandungan salinitas air laut pada Selat Madura juga tergolong cukup tinggi [4]. Melihat potensi yang dimiliki perairan Selat Madura, menjadikan Selat Madura berperan penting dalam aktivitas kemaritiman (layaknya kegiatan tangkap ikan). Hal ini mengakibatkan informasi kondisi salinitas air laut menjadi sentral dalam aktivitas kemaritiman [5].

Proses pengukuran salinitas sendiri dilakukan dengan cara mengambil sampel air laut secara langsung yang tentunya membutuhkan waktu dan biaya yang lebih ekstra [6]. Peramalan salinitas perlu dilakukan guna membantu pemberian informasi kondisi salinitas pada masyarakat dengan cepat, tepat, dan mudah dipahami [7].

Ada beberapa parameter yang mempengaruhi salinitas, salah satunya adalah presipitasi yang mendominasi variabilitas salinitas pada skala temporal per-jam pada kedalaman *centimeter* pertama di bawah muka laut [8]. Faktor penting lain yang mempengaruhi salinitas adalah pola sirkulasi arus laut [3]. Sehingga peramalan salinitas pada penelitian ini akan menggunakan parameter yang berbeda dengan penelitian sebelumnya yang cenderung lebih banyak menggunakan presipitasi. Kecepatan arus laut pada tiga kedalaman yang berbeda dan salinitas air laut pada 2 kedalaman yang berbeda akan digunakan untuk memprediksi salinitas muka laut. Kecepatan arus laut merupakan salah satu faktor penting dalam variabilitas dan distribusi persebaran salinitas. Arus laut juga berperan dalam proses pencampuran air laut secara horizontal maupun vertikal, sehingga mendorong terjadinya pergeseran masa air yang juga membawa kadar salinitas yang berbeda [9].

Berdasarkan hasil penelitian yang dilakukan oleh Prayitno, salinitas, temperatur, dan kecepatan arus laut (*eastward* dan *northward*) mampu menghasilkan *database* Peta Arus. Pada penelitian tersebut, basisdata Fusi-Oceanografi yang lebih mutakhir dapat tercapai karena adanya Salinitas Absolut sebagai pembaruan variabel. Penelitian tersebut memperoleh RMSE salinitas sebesar 0.0038 psu hingga 0.1338 psu. Didapatkan pula nilai rata-rata RMSE dan korelasi salinitas berturut turut sebesar 0.0381 psu dan 0.9692 [10].

Peramalan salinitas air laut juga dilakukan oleh Azizah [6]. Metode *backpropagation* yang digunakan oleh Azizah mampu memprediksi salinitas air laut dengan sangat baik. Model *backpropagation* mampu memperoleh MAPE sebesar 2.063% [6]. Penelitian yang serupa dilakukan oleh Jiayu Hu menggunakan metode dan variabel yang berbeda. Penelitiannya menggunakan *regular* RF dan ELM untuk memprediksi salinitas dalam satu hari ke depan. Model RF dan ELM yang digunakan oleh Jiayu Hu mampu memperoleh  $R^2$  berturut turut 0.95 dan 0.97 [11]. Penelitian serupa juga dilakukan oleh Zhou, menggunakan metode yang berbeda. Penelitian tersebut dilakukan untuk memprediksi salinitas muara dalam jangka pendek. Dihasilkan model ANN lebih efektif memprediksi untuk 1 hingga 3 hari ke depan [12]. Sementara itu WT-ANN memiliki akurasi yang lebih besar dari pada ANN [12]. Berdasarkan penelitian tersebut diperlukan penelitian lebih lanjut agar mampu meramalkan untuk jangka waktu yang lebih panjang [12].

Metode 1D CNN menjadi terobosan dalam memprediksi data deret waktu, sebagaimana pada penelitian yang dilakukan oleh Syarifudin. Penelitiannya mampu meramalkan jumlah *hotspot* harian maupun bulanan dengan cukup baik. MAAPE sebagai evaluasi model mendapatkan nilai sebesar 1.069 untuk prediksi harian, 0.5814 untuk prediksi bulanan, dan 0.6508 untuk waktu 12 bulan [13]. Metode CNN memiliki kemampuan prediksi dan konsistensi peramalan yang lebih baik dari pada model lain seperti LSTM dan GRU, hal ini dibuktikan pada penelitian yang dilakukan oleh Nazmoon [14]. Penelitiannya memprakirakan kasus COVID-19 baru dan kematian baru di tiap negara. MAPE untuk metode CNN pada kasus di negara Brazil, Rusia, dan UK berturut turut adalah 6.94%, 0.85%, dan 3.75% [14]. Berdasarkan penelitian yang dilakukan oleh Sindi, diperoleh bahwa metode CNN-1D dengan *random fully connected layer* mampu memecahkan masalah alokasi kerugian Z-bus dengan efisien dan

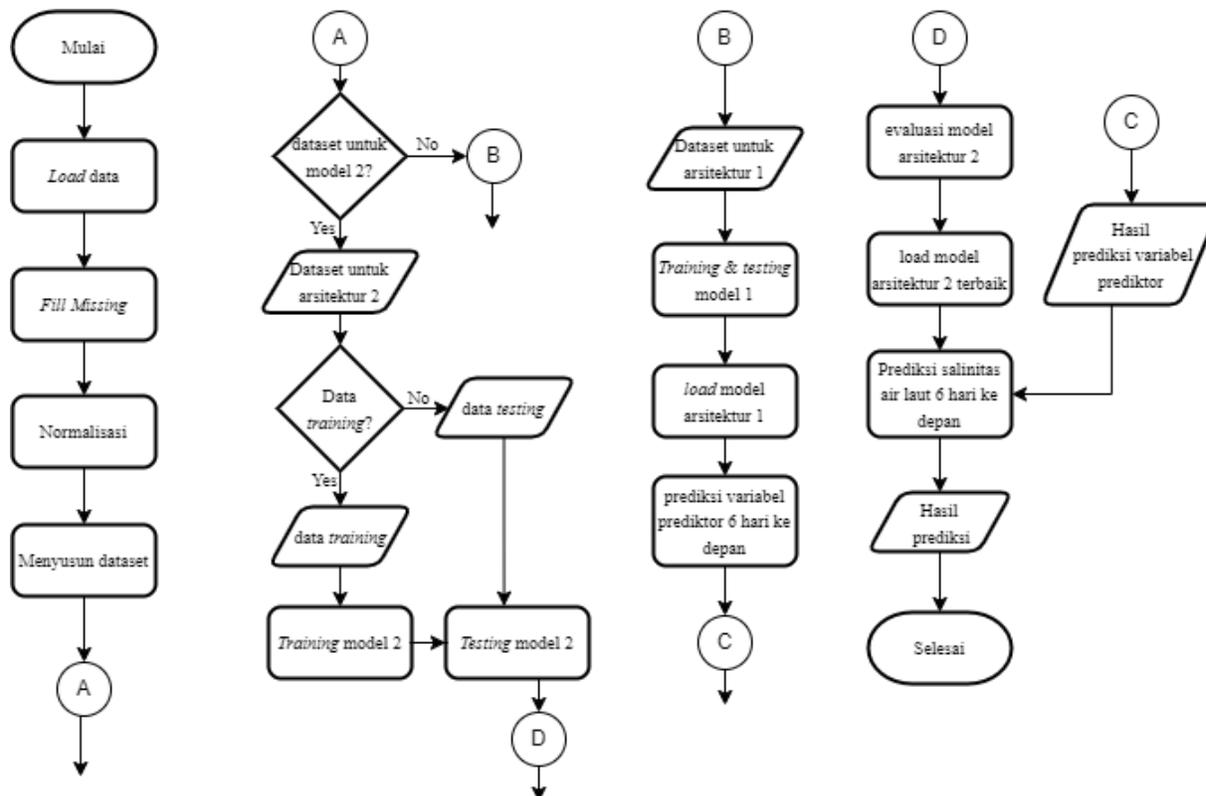
cepat [15]. Pada penelitian yang dilakukan oleh Sindi diperoleh nilai NME  $1.644 \times 10^{-5}$  dan waktu 0.016 sec [15].

Model CNN seringkali digunakan dalam permasalahan data citra, sehingga kurang efektif dalam permasalahan data sinyal [15]. Kendati demikian, dengan mengubah arsitektur CNN menjadi 1D, sinyal dapat diproses tanpa mengalami peningkatan kompleksitas komputasi [15]. Arsitektur 1D-CNN mampu memprediksi data sinyal dan time series dengan baik tidak terkecuali pula untuk data salinitas [13]. Penelitian kali ini mengusulkan peramalan salinitas air laut menggunakan model 1D-CNN dengan jangka waktu yang lebih panjang.

Diharapkan metode 1D-CNN mampu mendapatkan hasil prediksi yang baik. Sehingga penelitian ini mampu memberikan informasi kepada masyarakat akan kondisi salinitas air laut beberapa hari ke depan guna menunjang aktivitas kemaritiman layaknya tangkap ikan di perairan Selat Madura bagian Timur.

## 2. Metode/Perancangan

Penelitian ini dilakukan menggunakan bahasa pemrograman python 3.9 dan menggunakan *framework tensorflow* [16]. Terdapat beberapa tahapan yang perlu dilakukan dalam penelitian ini. Berikut tahapan dalam penelitian ini dapat dilihat pada gambar 1.



Gambar 1. Flowchart penelitian

Guna mencapai tujuan pada penelitian ini diperlukan tahapan tahapan yang harus dilalui, dimulai dengan pengambilan data pada database (*OPeNDAP*) milik BMKG (dapat diakses

pada link berikut: <https://maritim.bmkg.go.id/opensdap/>) [17]. Kemudian dilakukan *preprocessing* dengan menyelidiki banyaknya data kosong dan dilanjut koreksi menggunakan interpolasi linear sebagaimana pada persamaan (1). Lalu dilanjutkan dengan normalisasi dengan *minmaxscaller* sebagaimana pada persamaan (2).

Kemudian dilanjutkan dengan membuat dua model 1D-CNN. Model arsitektur pertama untuk memprediksi variabel prediktor dengan keluaran 8 *output* (seluruh variabel prediktor). Sedangkan model ke-dua merupakan model arsitektur untuk memprediksi variabel respon atau salinitas permukaan.

Dilanjutkan dengan proses *training* dan *testing* pada masing masing arsitektur. Proses *training* dan *testing* dilakukan dengan beberapa kali percobaan dengan nilai parameter *batch size* dan *drop out* yang berbeda beda. Perbandingan data *training* dan *testing* adalah 90%:10%. Evaluasi model tiap arsitektur, dan dipilih model terbaik dengan melihat  $R^2$  dan MAPE terbaik. Melakukan prediksi salinitas menggunakan model terbaik.

### 2.1. Sumber Data

Data yang digunakan merupakan data *time series* dengan variabel kecepatan arus laut ke arah timur kedalaman 25 meter (sebagai variabel U25), 10 meter (sebagai variabel U10), dan arus laut ke arah timur pada permukaan (U), kecepatan arus arah Utara kedalaman 25 meter (sebagai variabel V25), 10 meter (sebagai variabel V10), dan arus arah utara pada permukaan (V), salinitas laut kedalaman 25 m (sebagai variabel S25), kedalaman 10m (sebagai variabel S10), dan salinitas permukaan laut (S). Sebanyak 2691 data diambil dari *OPeNDAP* milik BMKG dengan rentang waktu data per 12 jam dari 13 Mei 2019 07:00 WIB hingga 17 Januari 2023 07:00 WIB pada titik (-7.28,113.92) [17], [18]. Data sampel tersaji pada tabel 1. Trend data divisualisasikan pada gambar 2.

### 2.2. Salinitas Air Laut

Salinitas merupakan konsentrasi garam terlarut dalam air laut dengan satuan gram per liter, promill, atau dalam satuan *practical salinity unit* (PSU), yang mana besarnya tekanan osmotik berbanding lurus dengan dan dipengaruhi oleh salinitas [19], [20]. Salinitas permukaan laut merupakan salah satu parameter penting di laut. Mengamati kondisi salinitas air laut pada suatu daerah, dapat mengetahui kondisi siklus *global hidrology* [21].

### 2.3. Fill Missing

Nilai kosong yang ditemukan dalam data merupakan masalah yang besar dalam penelitian ini. Hal ini terjadi karena kesalahan dalam pengukuran sampel data dan hal lain. Permasalahan data kosong harus segera diatasi terutama pada penelitian yang menggunakan data *time-series*, karena memerlukan data yang kontinu [22]. Data yang kosong akan dikoreksi menggunakan interpolasi linear seperti pada persamaan (1).

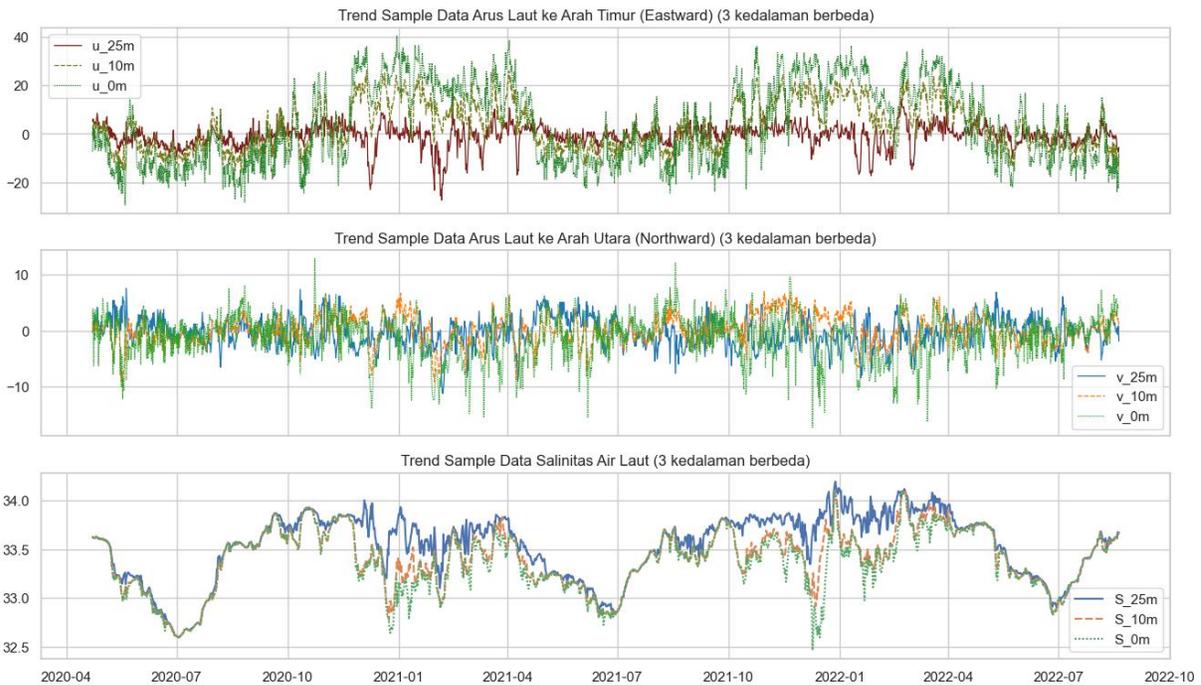
$$f(x) = f(x_0) + \frac{f(x_1) - f(x_0)}{x_1 - x_0} (x - x_0) \quad (1)$$

Dimana  $f(x)$  adalah data yang kosong,  $f(x_0)$  adalah data sebelum data kosong,  $f(x_1)$  adalah data setelah data data kosong,  $x_1$  adalah urutan data setelah urutan data kosong,  $x_0$  adalah urutan data sebelum urutan data kosong, dan  $x$  adalah urutan data kosong. Interpolasi linear dapat mengatasi data kosong meskipun data mempunyai fluktuasi yang cenderung konsisten. Metode interpolasi linear cocok digunakan pada penelitian ini karena variabel prediktif

maupun respon bersifat fluktuatif secara konsisten. Nilai yang hilang dapat diatasi oleh interpolasi linear hanya dengan titik titik data yang diketahui [23].

**Tabel 1.** Sampel data

Waktu	U25	U10	U	V25	V10	V	S25	S10	S
2019/5/13 07:00	-0,35	-1,25	-3,29	-0,85	-0,59	1,30	20	20	32,95
2019/5/13 19:00	NaN	NaN	NaN						
2019/5/14 07:00	-0,29	-0,79	-2,25	-2,1	-2,29	-0,99	32,93	32,93	32,93
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2022/11/25 07:00	-0,8	17,7	27,5	-1,2	2,2	0,4	33,745	33,571	33,546



**Gambar 2.** Trend data (variabel prediktor dan respon) tampak fluktuatif.

#### 2.4. Normalisasi

Normalisasi perlu dilakukan apabila dataset memiliki nilai *range* yang jaraknya terlalu jauh dan tidak sama. Normalisasi yang digunakan adalah *min max scaler* yang mana melakukan penskalaan ulang dalam *range* [0,1] dengan bentuk distribusi tetap sama [24]. Persamaan normalisasi *min max scaler* dapat dilihat pada persamaan (2).

$$\hat{x} = \frac{X_i - X_{min}}{X_{max} - X_{min}} ; i = 1, 2, 3, \dots, n \quad (2)$$

Dimana  $X_i$  data ke  $i$ ,  $n$  banyaknya data,  $X_{min}$  nilai minimum dalam data,  $X_{max}$  nilai maksimum dalam data.

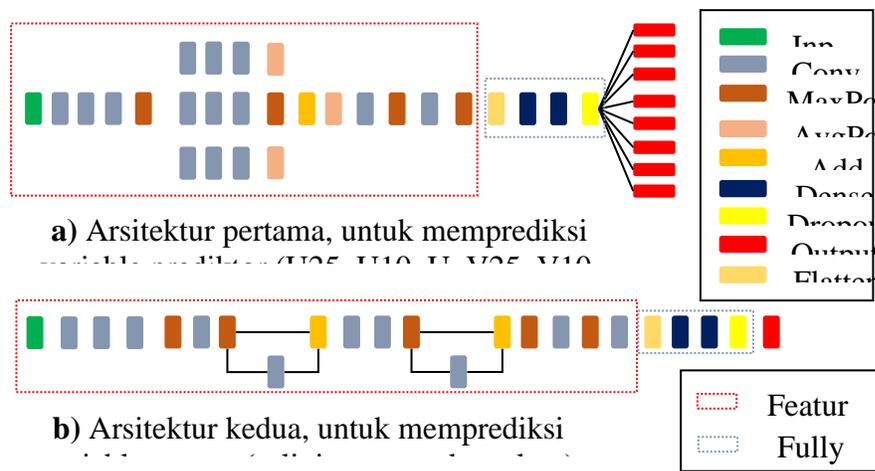
#### 2.5. Convolutional Neural Network

Berkembang dari *multilayer perceptron*, *Convolutional Neural Network* yang merupakan bagian dari *deep learning* paling populer digunakan sebagai klasifikasi pada data citra [25].

Dua bagian besar terbagi dalam model CNN yaitu ekstraksi fitur dan *fully connected layer*, pada ekstraksi fitur terdapat 2 jenis *layer*, yaitu *convolutional layer* dan *pooling layer* [13].

Dalam penelitian ini akan digunakan model CNN menggunakan 1D *convolution layer* dalam proses prediksi. Dalam beberapa kasus tertentu 1D CNN lebih disukai dan menguntungkan terutama untuk data deret waktu dan data sinyal 1D [13], [26]. Hal ini disebabkan karena sebagian besar model 1D CNN telah menggunakan konfigurasi yang lebih ringkas, sehingga dengan arsitektur yang lebih dangkal jauh lebih mudah dilatih dan diimplementasikan tanpa harus memerlukan perangkat keras khusus [26].

Penelitian ini menyediakan 2 model arsitektur CNN, dengan arsitektur pertama berfungsi untuk menghasilkan 8 output variabel prediktor. Dan model ke dua menghasilkan satu output variabel salinitas. Arsitektur yang digunakan tergambar pada gambar 3.



Gambar 3. Arsitektur 1D CNN

## 2.6. Koefisien Determinasi ( $R^2$ )

Koefisien determinasi ( $R^2$ ) merupakan proporsi varians yang memperlihatkan seberapa jauh variabel respon dapat dijelaskan oleh variabel prediktor. Umumnya koefisien determinasi memiliki nilai pada selang interval [0,1] dengan nilai terbaik mendekati 1. Berkaitan dengan model regresi, koefisien determinasi mampu menjelaskan hubungan timbal balik antara nilai aktual dengan nilai prediksi dari model. Hal ini menjadikan koefisien determinasi cocok digunakan sebagai salah satu evaluasi untuk menilai kemampuan model prediksi [27]. Persamaan koefisien determinasi dijelaskan pada persamaan (3).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

Banyaknya data disimbolkan dengan  $n$  dan  $y_i$  sebagai nilai aktual. Kemudian  $\hat{y}_i$  sebagai nilai prediksi, sedangkan  $\bar{y}$  sebagai rata-rata dari nilai aktual.

## 2.7. Mean Absolute Percentage Error

Pada penelitian ini, evaluasi model dilihat daripada MAPE yang dihasilkan. Hal ini menggunakan MAPE karena mampu mengetahui seberapa besar kesalahan peramalan

terhadap nilai aktual, selain itu evaluasi ini merupakan yang paling sering dilakukan dalam pengukuran akurasi [28], [29]. Evaluasi ini didapatkan dalam persamaan (4).

$$MAPE = \frac{\sum_{i=0}^n \left| \frac{a_i - f_i}{a_i} \right|}{n} \times 100\% \quad (4)$$

Dimana  $a_i$  sebagai data aktual ke  $i$ , dan  $f_i$  adalah data peramalan ke  $i$ . Semakin kecil MAPE yang didapatkan semakin baik pula kemampuan prediksinya [30], hal ini sesuai dengan kriteria kemampuan model dalam memprediksi yang terdapat pada pada tabel 2.

**Tabel 2.** Kriteria kemampuan prediksi menggunakan evluasi MAPE [23].

MAPE	<10%	10%-20%	20%-50%	>50%
Kemampuan	Sangat Baik	Baik	Cukup baik	Buruk

### 3. Hasil dan Pembahasan

Setelah melakukan pengambilan data dilanjutkan dengan memeriksa adanya data kosong dan berapa banyaknya data kosong tersebut. Agar tidak menimbulkan masalah pada proses prediksi diperlukan koreksi data kosong menggunakan persamaan (1). Sehingga diperoleh hasil seperti pada tabel 3.

**Tabel 3.** Data sampel setelah diinterpolasi linear

Waktu	U25	U10	U	V25	V10	V	S25	S10	S
2019/5/13 07:00	-0.350	-1.249	-3.299	-0.849	-0.599	1.301	32.937	32.934	32.954
2019/5/13 19:00	-0.324	-1.024	-2.774	-1.474	-1.449	0.151	32.937	32.934	32.943
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2022/11/25 07:00	-0,8	17,7	27,5	-1,2	2,2	0,4	33,745	33,571	33,546

Kemudian dilanjutkan dengan melakukan normalisasi data, dengan mengubah data menjadi rentang antara 0 hingga 1 dengan persamaan (2), dan didapatkan hasil seperti pada tabel 4.

**Tabel 4.** Data sampel setelah dinormalisasi

Waktu	U25	U10	U	V25	V10	V	S25	S10	S
2019/5/13 07:00	0.648	0.344	0.373	0.521	0.247	0.315	0.230	0.282	0.302
2019/5/13 19:00	0.648	0.349	0.381	0.501	0.224	0.296	0.230	0.282	0.295
...	...	...	...	...	...	...	...	...	...
2019/5/16 07:00	0.657	0.365	0.415	0.503	0.234	0.318	0.215	0.265	0.272

Membuat dataset untuk memprediksi variabel prediktor dan dataset untuk memprediksi variabel respon (salinitas permukaan laut). Untuk memprediksi variabel prediktor diperlukan pola deret waktu. Data *input* yang digunakan adalah data 28 waktu sebelumnya dari masing masing parameter. Jadi untuk *input* yaitu, arus *eastward* kedalaman 25m [ $U25_{t-27}, \dots, U25_t$ ], arus *eastward* kedalaman 10m [ $U10_{t-27}, \dots, U10_t$ ], arus *eastward* pada permukaan [ $U_{t-27}, \dots, U_t$ ], arus *northward* kedalaman 25m [ $V25_{t-27}, \dots, V25_t$ ], arus *northward*

kedalaman 10m [ $V10_{t-27}, \dots, V10_t$ ], arus *northward* pada permukaan [ $V_{t-27}, \dots, V_t$ ], salinitas kedalaman 25m [ $S25_{t-27}, \dots, S25_t$ ], salinitas kedalaman 10m [ $S10_{t-27}, \dots, S10_t$ ]. Sedangkan untuk *output* dihasilkan 8 output yaitu, [ $U25_{t+1}, U10_{t+1}, U_{t+1}, V25_{t+1}, V10_{t+1}, V_{t+1}, S25_{t+1}, S10_{t+1}$ ]. Data tiap parameter digabungkan menjadi satu vektor dengan 224 elemen [ $U25_{t-27}, \dots, U25_t, U10_{t-27}, \dots, U10_t, U_{t-27}, \dots, U_t, V25_{t-27}, \dots, V25_t, V10_{t-27}, \dots, V10_t, V_{t-27}, \dots, V_t, S25_{t-27}, \dots, S25_t, S10_{t-27}, \dots, S10_t$ ]. Untuk lebih jelas dapat dilihat pada tabel 5.

**Tabel 5.** Dataset untuk memprediksi variabel prediktor

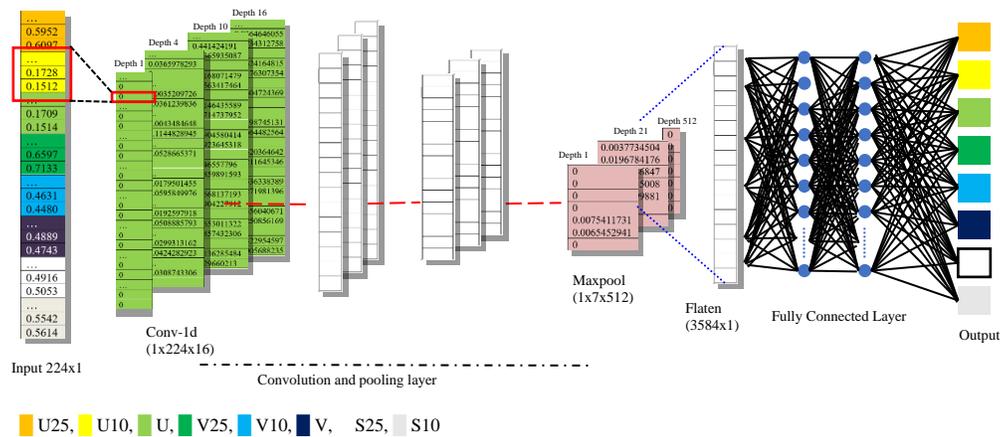
No	Dataset U 25m	...	Dataset S 10m	Output
1	$U25_1, \dots, U25_{28}$	...	$S10_1, \dots, S10_{28}$	$U25_{29}, \dots, S10_{29}$
2	$U25_2, \dots, U25_{29}$	...	$S10_2, \dots, S10_{29}$	$U25_{30}, \dots, S10_{30}$
⋮	⋮	⋮	⋮	⋮
2557	$U25_{2557}, \dots, U25_{2584}$	...	$S10_{2557}, \dots, S10_{2584}$	$U25_{2585}, \dots, S10_{2585}$

Proses prediksi variabel respon atau salinitas permukaan diperlukan pola deret waktu. Data *input* yang digunakan adalah data 28 waktu sebelumnya dari masing masing parameter. Jadi untuk *input* yaitu, arus *eastward* kedalaman 25m [ $U25_{t-27}, \dots, U25_t$ ], arus *eastward* kedalaman 10m [ $U10_{t-27}, \dots, U10_t$ ], arus *eastward* pada permukaan [ $U_{t-27}, \dots, U_t$ ], arus *northward* kedalaman 25m [ $V25_{t-27}, \dots, V25_t$ ], arus *northward* kedalaman 10m [ $V10_{t-27}, \dots, V10_t$ ], arus *northward* pada permukaan [ $V_{t-27}, \dots, V_t$ ], salinitas kedalaman 25m [ $S25_{t-27}, \dots, S25_t$ ], salinitas kedalaman 10m [ $S10_{t-27}, \dots, S10_t$ ], dan salinitas permukaan [ $S_{t-28}, \dots, S_{t-1}$ ]. Data tiap parameter digabungkan menjadi satu vektor dengan 252 elemen [ $U25_{t-27}, \dots, U25_t, U10_{t-27}, \dots, U10_t, U_{t-27}, \dots, U_t, V25_{t-27}, \dots, V25_t, V10_{t-27}, \dots, V10_t, V_{t-27}, \dots, V_t, S25_{t-27}, \dots, S25_t, S10_{t-27}, \dots, S10_t, S_{t-28}, \dots, S_{t-1}$ ]. Sedangkan untuk *output* dihasilkan  $S_t$ . Untuk lebih jelas dapat dilihat pada tabel 6.

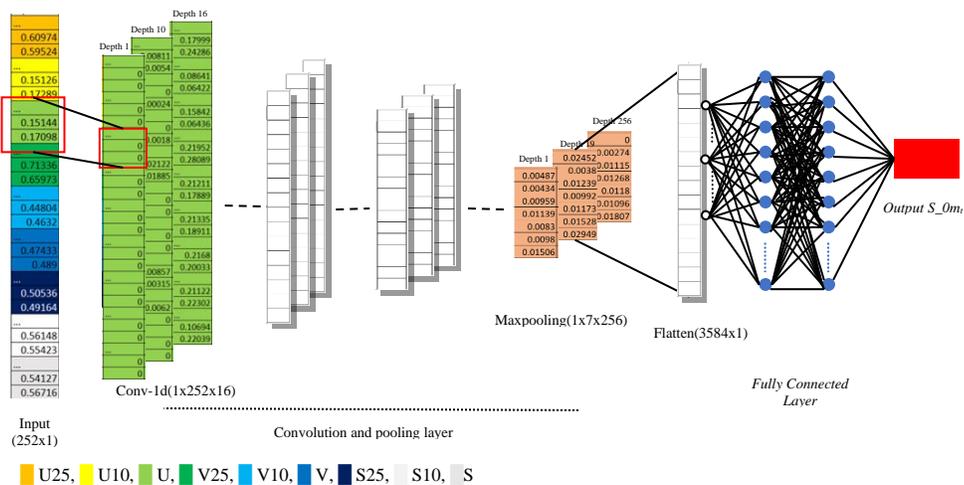
Dataset yang telah dibentuk kemudian dibagi menjadi data *training* dan data *testing*. Proporsi data *training* dan *testing* sebesar 90%:10%. Data *training* merupakan data sejak 13 Mei 2019 hingga 27 November 2022. Data *testing* merupakan data sejak 28 November 2022 hingga 17 Januari 2023. Uji coba dilakukan dengan melakukan *tuning* parameter yang berbeda, seperti *batch size* dan probabilitas *dropout*.

**Tabel 6.** Dataset untuk memprediksi salinitas permukaan laut

No	Dataset U 25m	...	Dataset S	Output
1	$U25_2, \dots, U25_{29}$	...	$S_1, S_2, \dots, S_{28}$	$S_{29}$
2	$U25_3, \dots, U25_{30}$	...	$S_2, S_3, \dots, S_{29}$	$S_{30}$
⋮	⋮	⋮	⋮	⋮
2557	$U25_{2558}, \dots, U25_{2585}$	...	$S_{2557}, \dots, S_{2584}$	$S_{2585}$



Gambar 4. Implementasi 1D CNN dalam proses prediksi variabel prediktor dan menghasilkan 8



Gambar 5. Implementasi 1D CNN arsitektur ke-2 untuk memprediksi salinitas permukaan laut

Hal pertama yang perlu dilakukan adalah memprediksi tiap parameter sebelum memprediksi salinitas permukaan [31]. Pada gambar 4 merupakan proses prediksi 8 variabel prediktor. Sedangkan untuk gambar 5 merupakan proses prediksi salinitas permukaan air laut.

Pada prosesnya dilakukan beberapa kali percobaan dengan parameter yang berbeda beda untuk tiap arsitektur, dan diperoleh hasil MAPE terbaik untuk arsitektur pertama adalah pada nilai *dropout* 0.8 *Batch Size* 32, sedangkan untuk arsitektur ke-2 diperoleh nilai MAPE dan  $R^2$  terbaik pada *dropout* 0.8 *Batch size* 64 dengan hasil kemampuan prediksi terbilang sangat baik.

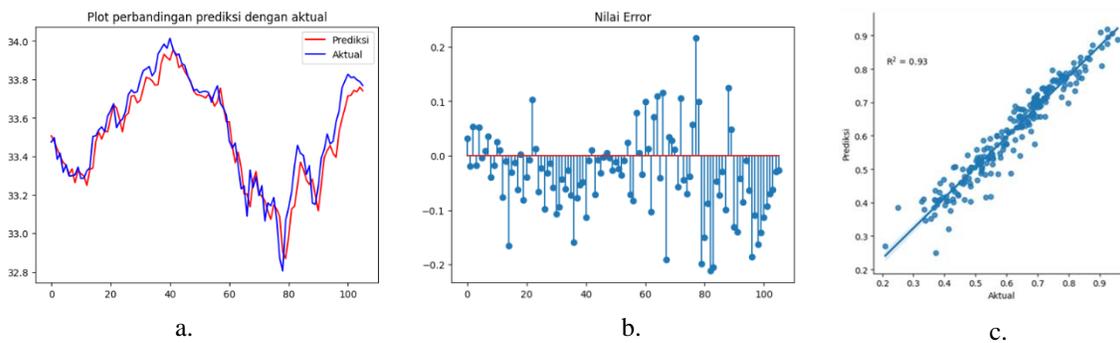
Diperoleh arsitektur pertama mampu memprediksi variabel U25, U10, V25, S25, S10 dengan sangat baik karena memiliki MAPE kurang dari 10%. Variabel prediktor yang lain terprediksi dengan cukup baik karena mape berada pada kisaran  $(20 \pm 1.5)\%$ . Arsitektur ke-dua mampu memprediksi salinitas muka laut dengan sangat baik. Sebagian besar hasil tuning parameter arsitektur ke-dua memperoleh MAPE kurang dari 5% dan  $R^2$  sebesar  $0.9 \pm 0.03$  Hasil evaluasi tertuang pada tabel 7 dan 8.

**Tabel 7.** Hasil evaluasi model untuk arsitektur pertama

Dropout	Batch Size	MAPE OUTPUT							
		U25	U10	U	V25	V10	V	S25	S10
0.9	8	6.38%	26.48%	21.69%	6.33%	26.49%	21.58%	4.38%	6.35%
	16	6.23%	24.83%	19.52%	6.26%	25.16%	19.64%	6.70%	6.61%
	32	7.51%	25.77%	21.74%	7.41%	25.61%	21.60%	5.14%	6.22%
0.8	8	7,51%	18,61%	18,10%	14,40%	8,98%	10,42%	6,90%	6,70%
	16	6.82%	23.86%	20.00%	6.75%	24.20%	19.90%	5.04%	5.65%
	32	<b>6.61%</b>	<b>21.16%</b>	<b>19.53%</b>	<b>6.95%</b>	<b>21.27%</b>	<b>19.52%</b>	<b>5.03%</b>	<b>5.30%</b>
0.7	8	6.95%	26.57%	22.47%	6.97%	26.83%	22.53%	4.53%	4.16%
	16	7.28%	23.77%	19.60%	7.37%	23.77%	19.89%	4.95%	6.61%
	32	6.76%	20.49%	19.19%	6.84%	20.43%	19.15%	6.82%	7.02%

**Tabel 8.** Hasil evaluasi arsitektur model ke-2 untuk memprediksi salinitas permukaan laut

Dropout	Batch Size	$R^2$	MSE	RMSE	MAPE	Time
0.9	8	0.91321	0,00061	0.02469	3,36%	23m 49,8s
	16	0.93107	0,00052	0.02323	2,96%	15m 8.7s
	32	0.90574	0,00071	0.02664	3,55%	13m 9,8s
	64	0.88278	0,00117	0.03420	4,77%	8m 51,1s
0.8	8	0.90834	0,00056	0.02366	3,04%	24m 57,3s
	16	0.92692	0,00071	0.02664	3,68%	31m 6,1s
	32	0.92845	0.00061	0.02469	3,21%	11m 23.3s
	<b>64</b>	<b>0.93179</b>	<b>0,00049</b>	<b>0.02213</b>	<b>2,86%</b>	<b>10m 10.7s</b>
0.7	8	0.91115	0,00104	0.03224	4,38%	17m 32,9s
	16	0.91875	0,00094	0.03065	4,14%	15m 39,2
	32	0.76650	0,00128	0.03577	5,56%	11m 44,4s
	64	0.88475	0,00063	0.02509	3,41%	10m 57,3s

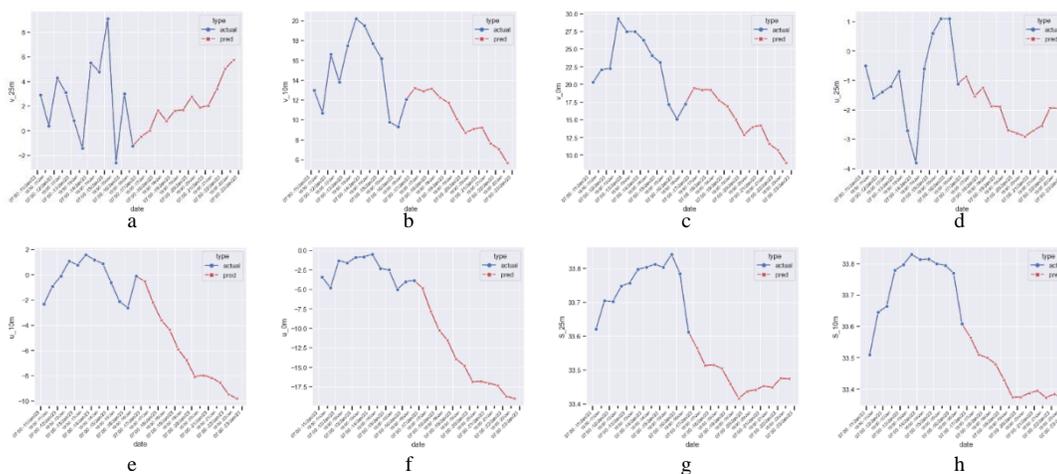


**Gambar 6.** a. Hasil testing perbandingan prediksi dengan aktual; b. Nilai error antara aktual dan prediksi; c. Plot hubungan antara prediksi dan aktual beserta koefisien determinasi.

Gambar 6 merupakan hasil testing dari 106 data yang belum dikenali oleh model arsitektur kedua (untuk memprediksi salinitas air laut). Sebagian besar nilai prediksi yang dihasilkan lebih kecil dibandingkan nilai aktual. Dari gambar 6 terlihat bahwa nilai error terbilang sangat bagus karena mendekati nol. Diperoleh nilai prediksi salinitas permukaan pada tanggal 15 Januari 2023 pukul 19.00 sebesar 33.742 PSU dengan galat 0.07004 PSU. Untuk hasil lebih jelasnya terdapat pada tabel 9.

**Tabel 9.** Perbandingan prediksi dan actual beserta galatnya

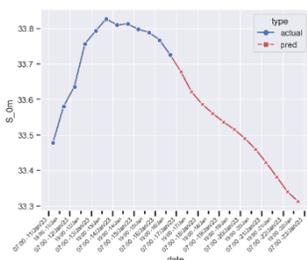
Tanggal	Aktual	Prediksi	Galat
15/01/2023 19.00	33.813	33.743	-0.070
16/01/2023 07.00	33.798	33.736	-0.062
16/01/2023 19.00	33.789	33.760	-0.029
17/01/2023 07.00	33.768	33.741	-0.027



**Gambar 7.** Hasil prediksi variabel prediktor untuk 6 hari kedepan, (a) prediksi V25, (b) prediksi V10, (c) prediksi V, (d) prediksi U25, (e) prediksi U10, (f) prediksi U, (g) prediksi S25, (h) prediksi S10

Berdasarkan gambar 7 menjelaskan bahwa arus *northward* kedalaman 25m (gambar 7a) terprediksi meningkat dengan nilai tertinggi  $5.747\text{ms}^{-1}$  pada 23 Januari 2023 pukul 07.00 WIB. Arus *northward* kedalaman 10m (gambar 7b) diprediksi penurunan daripada hari sebelumnya dengan nilai terendah  $5.689\text{ms}^{-1}$  pada 23 Januari 2023 pukul 07.00 WIB. Sedangkan arus *northward* pada permukaan (gambar 7c) diprediksi menurun dari  $19.477\text{ms}^{-1}$  hingga  $8.926\text{ms}^{-1}$ . Dengan demikian dapat dilihat bahwa arus *northward* yang lebih dalam memiliki kecepatan lebih kecil dari pada arus *northward* pada permukaan.

Arus *eastward* kedalaman 25m (gambar 7d) mengalami peningkatan juga mengalami penurunan untuk hari selanjutnya. Diprediksi arus *eastward* kedalaman 25m tertinggi  $2.905\text{ms}^{-1}$  pada 21 Januari 2023 pukul 07.00. Arus *eastward* kedalaman 10m (gambar 7e) diprediksi mengalami peningkatan dengan tertinggi  $9.797\text{ms}^{-1}$  pada tanggal 23 Januari 2023 pukul 07.00 WIB. Arus *eastward* permukaan juga diramalkan meningkat dengan tertinggi  $18.980\text{ms}^{-1}$  pada 23 Januari 2023 pukul 07.00 WIB.



**Gambar 8.** Hasil prediksi salinitas permukaan laut untuk 6 hari ke depan

Pada gambar 8 diperoleh prediksi salinitas muka laut dengan grafik yang menurun dari pada hari sebelumnya. Hal ini juga terjadi pada kedalaman yang berbeda (gambar 7g dan 7h). salinitas kedalaman 25m diprediksi menurun untuk 6 hari kedepan dengan terendah 33.47 PSU pada 22 dan 23 Januari 2023. Sedangkan salinitas kedalaman 10m diprediksi mengalami penurunan hingga kisaran 33.37 PSU. Salinitas permukaan laut (Gambar 8) diprediksi menurun hingga kisaran 33.67 PSU sampai 33.31 PSU. Hasil prediksi secara rinci dapat dilihat pada tabel 10.

**Tabel 10.** Hasil prediksi seluruh variabel untuk 6 hari ke depan

Waktu	U25	U10	U	V25	V10	V	S25	S10	S
17/01/2023 19.00	-0.861	-0.501	-4.831	-0.478	13.201	19.477	33.565	33.565	33.679
18/01/2023 07.00	-1.545	-2.175	-7.786	0.010	12.894	19.267	33.513	33.510	33.622
18/01/2023 19.00	-1.241	-3.593	-10.244	1.667	13.172	19.259	33.516	33.500	33.587
19/01/2023 07.00	-1.874	-4.348	-11.518	0.786	12.242	17.769	33.504	33.480	33.560
19/01/2023 19.00	-1.891	-5.893	-13.891	1.621	11.745	16.932	33.460	33.430	33.537
20/01/2023 07.00	-2.698	-6.757	-14.773	1.700	10.104	15.035	33.416	33.374	33.516
20/01/2023 19.00	-2.788	-8.057	-16.831	2.755	8.708	12.865	33.437	33.375	33.491
21/01/2023 07.00	-2.905	-7.946	-16.800	1.881	9.092	13.991	33.442	33.388	33.461
21/01/2023 19.00	-2.706	-8.151	-17.033	2.045	9.242	14.226	33.453	33.395	33.423
22/01/2023 07.00	-2.538	-8.535	-17.334	3.388	7.648	11.597	33.449	33.373	33.383
22/01/2023 19.00	-1.935	-9.456	-18.690	5.029	7.070	10.728	33.475	33.385	33.341
23/01/2023 07.00	-1.946	-9.797	-18.980	5.747	5.689	8.926	33.474	33.370	33.313

Tidak lupa pada penelitian ini juga mencantumkan hasil prediksi salinitas air laut menggunakan metode pada penelitian sebelumnya sebagai pembandingan. Dilihat dari tabel 11 dengan menggunakan data *OPeNDAP* didapatkan bahwa 1D CNN sama tidak kalah akuratnya dengan metode yang diusulkan oleh penelitian lain. Metode 1D CNN mendapatkan nilai  $R^2$  yang lebih besar dengan selisih 0.1 hingga 0.2 daripada 3 metode yang diusulkan oleh penelitian sebelumnya. Nilai MAE, MSE, dan RMSE pada 1D CNN juga lebih kecil dibandingkan metode yang lain dengan selisih yang cukup jauh. Berdasarkan hal tersebut 1D CNN memiliki kemampuan prediksi salinitas air laut yang lebih baik dari pada 3 metode yang diusulkan pada penelitian sebelumnya.

**Tabel 11.** Tabel perbandingan dengan penelitian ini

Metode	$R^2$	MAE	MSE	RMSE	MAPE	Penulis
RF	0.8801	0.0795	0.0127	0.1129	0.23%	Hu J, Liu B, Peng S (2019) [11]
ELM	0.7606	0.1167	0.0254	0.1595	0.35%	Hu J, Liu B, Peng S (2019) [11]
<i>backpropogation</i>	0.7762	0.1299	0.0237	0.1542	0.38%	Azizah A, Novitasari D, Intan P, dkk (2021) [6].
1D-CNN	0.9317	0.0277	0.0004	0.0221	2.86%	Penelitian ini.

#### 4. Kesimpulan dan Saran

Dari penelitian yang dilakukan dapat disimpulkan bahwa model 1D CNN mampu memprediksi salinitas permukaan air laut dengan sangat baik, diperoleh nilai MAPE sebesar 2.86% dan  $R^2$  sebesar 0.931 pada *dropout* 0.8 dengan *batchsize* 64. Adapun hasil prediksi salinitas permukaan air laut untuk tanggal 17 Januari 2023 pukul 19:00 hingga 23 Januari 2023 pukul 07:00 dengan rentang waktu per 12 jam adalah mengalami penurunan hingga menyentuh angka 33.313 PSU.

Guna memperbaiki segala kekurangan pada penelitian ini, alangkah baiknya dibandingkan dengan metode lain yang sekiranya mampu memprediksi secara baik dalam jangka waktu pendek maupun panjang, seperti metode RNN, LSTM, dan GRU [32]. Perlu memperluas rentang waktu prediksi untuk melihat apakah kemampuan model mampu memprediksi secara konsisten dan efektif dalam jangka waktu yang lebih panjang.

#### Daftar Pustaka

- [1] F. Purwangka and H. Ainul Mubarak, "Komposisi Ikan Hasil Tangkapan Menggunakan Cantrang di Selat Madura," *Albacore*, vol. 2, no. 2, pp. 239–252, 2018.
- [2] J. Zhao *et al.*, "Sea Surface Salinity Variability in the Bering Sea in 2015–2020," *Remote Sens (Basel)*, vol. 14, no. 3, Feb. 2022, doi: 10.3390/rs14030758.
- [3] S. Tubalawony, D. E. Kalay, W. G. Hukubun, and R. D. Hukubun, "Distribusi Spasial Suhu dan Salinitas di Perairan Selat Haruku," *Jurnal Sumberdaya Akuatik Indopasifik*, vol. 7, no. 1, pp. 13–22, Feb. 2023, doi: 10.46252/jsai-fpik-unipa.2023.vol.7.no.1.213.
- [4] H. Prihatno, R. F. Abida, and S. L. Sagala, "Korelasi Antara Konduktivitas Air Laut dengan Jumlah Mineral Terlarut pada Perairan Selat Madura," *Jurnal Kelautan Nasional*, vol. 16, no. 3, pp. 211–222, 2021.
- [5] H. Hidayat and Hambali, "Rancang Bangun Alat Kontrol Salinitas Air Otomatis pada Budidaya Udang Vaname," *Ranah Research : Journal of Multidisciplinary Research and Development*, vol. 4, no. 2, pp. 135–143, 2022.
- [6] A. N. Azizah, D. C. R. Novitasari, P. K. Intan, F. Setiawan, and G. I. P. Sari, "Prediction of salinity based on meteorological data using the backpropagation neural network method," *Ilmu Kelaut*, vol. 26, no. 3, pp. 207–214, Sep. 2021, doi: 10.14710/ik.ijms.26.3.207-214.
- [7] BMKG, "BMKG Maritim Tanjung Perak Surabaya." Accessed: Jan. 19, 2023. [Online]. Available: <http://maritimjatim.info/index.php>

- [8] A. Supply, J. Boutin, G. Reverdin, J. L. Vergely, and H. Bellenger, “Variability of satellite sea surface salinity under rainfall,” in *Advances in Global Change Research*, vol. 69, Springer, 2020, pp. 1155–1176. doi: 10.1007/978-3-030-35798-6\_34.
- [9] S. D. Wardhani, A. A. D. Suryo, W. Atmodjo, E. Indrayanti, and B. Rochaddi, “Pengaruh Arus terhadap Sebaran Horizontal Suhu dan Salinitas pada 3 Kedalaman yang Berbeda di Perairan Samudera Hindia Bagian Selatan Pulau Jawa,” *Indonesian Journal of Oceanography*, vol. 03, no. 02, 2021.
- [10] T. Prayitno, W. S. Pranowo, and A. A. Surya, “Salinitas Absolut dan Arus Sebagai Pembaruan Variabel untuk Peutakhiran Basisdata Sistem Fusi-Oseanografi,” *urnal Hidropilar*, vol. 7, no. 2, pp. 95–106, 2021.
- [11] J. Hu, B. Liu, and S. Peng, “Forecasting salinity time series using RF and ELM approaches coupled with decomposition techniques,” *Stochastic Environmental Research and Risk Assessment*, vol. 33, no. 4–6, pp. 1117–1135, Jun. 2019, doi: 10.1007/s00477-019-01691-1.
- [12] F. Zhou, B. Liu, and K. Duan, “Coupling wavelet transform and artificial neural network for forecasting estuarine salinity,” *J Hydrol (Amst)*, vol. 588, Sep. 2020, doi: 10.1016/j.jhydrol.2020.125127.
- [13] M. A. Syarifudin *et al.*, “Hotspot Prediction Using 1D Convolutional Neural Network,” in *Procedia Computer Science*, Elsevier B.V., 2021, pp. 845–853. doi: 10.1016/j.procs.2021.01.073.
- [14] K. N. Nabi, M. T. Tahmid, A. Rafi, M. E. Kader, and M. A. Haider, “Forecasting COVID-19 cases: A comparative analysis between recurrent and convolutional neural networks,” *Results Phys*, vol. 24, May 2021, doi: 10.1016/j.rinp.2021.104137.
- [15] H. Sindi, M. Nour, M. Rawa, Ş. Öztürk, and K. Polat, “Random fully connected layered 1D CNN for solving the Z-bus loss allocation problem,” *Measurement (Lond)*, vol. 171, Feb. 2021, doi: 10.1016/j.measurement.2020.108794.
- [16] Martín Abadi *et al.*, “TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems.” 2015. [Online]. Available: <https://www.tensorflow.org/>
- [17] BMKG, “Opendap BMKG.” Accessed: Feb. 24, 2024. [Online]. Available: <https://maritim.bmkg.go.id/opendap/>
- [18] BMKG, “Pusat Meteorologi Maritim.” Accessed: Jan. 18, 2023. [Online]. Available: <peta-maritim.bmkg.go.id>
- [19] B. Hamuna, R. H. Tanjung, H. K. Maury, and Alianto, “Kajian Kualitas Air Laut dan Indeks Pencemaran Berdasarkan Parameter Fisika-Kimia Di Perairan Distrik Depapre, Jayapura,” *Jurnal Ilmu Lingkungan*, vol. 16, no. 1, pp. 35–43, 2018, doi: 10.14710/jil.16.135-43.
- [20] A. Mulyani, D. Kurniadi, and M. A. Musadad, “Rancang Bangun Aplikasi Pengenalan Rukun Islam Sebagai Media Pembelajaran Menggunakan Teknologi Augmented Reality,” *Jurnal Algoritma*, vol. 19, no. 1, pp. 50–61, 2021.

- 
- [21] J. Reagan, T. Boyer, J. Antonov, and M. Zweng, "Comparison analysis between Aquarius sea surface salinity and World Ocean Database in situ analyzed sea surface salinity," *J Geophys Res Oceans*, vol. 119, no. 11, pp. 8122–8140, 2014, doi: 10.1002/2014JC009961.
- [22] E. A. Kusnanti, D. C. R. Novitasari, F. Setiawan, A. Fanani, M. Hafiyusholeh, and G. I. Permata Sari, "Predicting Velocity and Direction of Ocean Surface Currents using Elman Recurrent Neural Network Method," *Journal of Information Systems Engineering and Business Intelligence*, vol. 8, no. 1, pp. 21–30, Apr. 2022, doi: 10.20473/jisebi.8.1.21-30.
- [23] W. Liu *et al.*, "A Novel Hybrid Model to Predict Dissolved Oxygen for Efficient Water Quality in Intensive Aquaculture," *IEEE Access*, vol. 11, pp. 29162–29174, 2023, doi: 10.1109/ACCESS.2023.3260089.
- [24] D. D. Pramesti, D. C. R. Novitasari, F. Setiawan, and H. Khaulasari, "Long-Short Term Memory (LSTM) for Predicting Velocity and Direction Sea Surface Current on Bali Strait," *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, vol. 16, no. 2, pp. 451–462, Jun. 2022, doi: 10.30598/barekengvol16iss2pp451-462.
- [25] A. Karatzoglou, N. Schnell, and M. Beigl, "A Convolutional Neural Network Approach for Modeling Semantic Trajectories and Predicting Future Locations," in *Artificial Neural Networks and Machine Learning – ICANN 2018*, 2018, pp. 61–72. doi: 10.1007/978-3-030-01418-6\_7.
- [26] S. Kiranyaz, O. Avci, O. Abdeljaber, T. Ince, M. Gabbouj, and D. J. Inman, "1D convolutional neural networks and applications: A survey," *Mech Syst Signal Process*, vol. 151, Apr. 2021, doi: 10.1016/j.ymsp.2020.107398.
- [27] D. Chicco, M. J. Warrens, and G. Jurman, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation," *PeerJ Comput Sci*, vol. 7, pp. 1–24, 2021, doi: 10.7717/PEERJ-CS.623.
- [28] E. R. S. Putri *et al.*, "Prediksi Kasus Aktif Kumulatif Covid-19 di Indonesia Menggunakan Model Regresi Linier Berganda," *Jurnal Pendidikan Matematika dan Matematika*, vol. 5, no. 2, pp. 567–577, 2021.
- [29] I. I. Zulfa, D. C. R. Novitasari, F. Setiawan, A. Fanani, and Moh. Hafiyusholeh, "Prediction of Sea Surface Current Velocity and Direction Using LSTM," *IJEIS (Indonesian Journal of Electronics and Instrumentation Systems)*, vol. 11, no. 1, p. 93, Apr. 2021, doi: 10.22146/ijeis.63669.
- [30] B. Yuwa Phiadelvira, D. Zatusiva Haq, D. C. Rini Novitasari, and S. Fajar, "Prediksi Besar Daya Listrik Tenaga Gelombang Laut Metode Oscillating Water Column (PLTGL-OWC) di Banyuwangi Menggunakan Extreme Learning Machine (ELM)," *UNNES Journal of Mathematics*, vol. 11, no. 1, pp. 1–7, 2022, [Online]. Available: <http://journal.unnes.ac.id/sju/index.php/ujm>
-

- [31] D. C. R. Novitasari *et al.*, “Forecasting Sea Surface Temperature in Java Sea Using Generalized Regression Neural Networks,” in *Smart Innovation, Systems and Technologies*, Springer, 2021, pp. 249–257. doi: 10.1007/978-981-15-5224-3\_24.
- [32] H. F. Nurrohman, D. C. R. Novitasari, F. Setiawan, Rochimah, A. Taufiq, and A. Hamid, “Rainfall Prediction Using Gated Recurrent Unit Based on DMI and Nino3.4 Index,” in *2022 IEEE International Conference on Industry 4.0, Artificial Intelligence, and Communications Technology (IAICT)*, IEEE, Jul. 2022, pp. 191–196. doi: 10.1109/IAICT55358.2022.9887474.