

# MODEL PREDIKSI SUHU PERMUKAAN LAUT PERAIRAN KOTA MANOKWARI KABUPATEN MANOKWARI MENGUNAKAN *DEEP NEURAL NETWORKS*

Elohansen Padang

Program Studi Fisika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Papua  
Jalan Gunung Salju, Amban, Manokwari Barat, Manokwari, Papua Barat 98314

Email: e\_padang@unipa.ac.id

**ABSTRACT:** In this research, we have been done developed a prediction model for Sea Surface Temperature (SST) in the sea of Manokwari City, Manokwari Regency using deep learning models, especially the Deep Neural Networks (DNN) model. The SST data used is ERA5 reanalysis data provided by the European Center for Medium-Range Weather Forecast (ECMWF) from 2000-2021 (8233 daily data). The SST data is divided into two parts, namely training and testing data with a proportion of 90% and 10%, respectively. The DNN model developed uses the hyperparameter optimizer adam, the ReLu activation function, the learning rate is 0.01, the Batch size is 30, the number of inputs is 10, the number of epochs is 100 and is equipped with early stops. Meanwhile, the number of hidden layers varied between 1 until 4. Likewise, the number of neurons in each hidden layer varies from 8, 16, 32, 64, or 128 neurons. Based on the test results, the DNN model with 2 hidden layers and 32 neurons per hidden layer gives more accurate results than the other models, with RMSE, MAE, and R2 values respectively 0.121; 0.015; and 0.935. Therefore, this DNN model can be recommended as a model to predict SST in sea of Manokwari city.

**Keywords:** Deep Neural Networks (DNN), Models, Predictions, Sea surface temperature, Sea of Manokwari city

## PENDAHULUAN

Salah satu parameter yang sangat penting dalam sistem keseimbangan energi di permukaan bumi dan menjadi indikator dalam mengukur panas air laut adalah Suhu permukaan laut (SPL). SPL memiliki peranan yang sangat penting dalam proses interaksi permukaan dan atmosfer bumi. Dua pertiga dari permukaan bumi ditempati oleh laut sehingga sistem pemanasan global dan sistem biologi sangat dipengaruhi oleh SPL. Oleh karena itu, prediksi SPL menjadi sangat penting dalam berbagai bidang, seperti untuk peramalan iklim dan cuaca laut, kegiatan lepas pantai seperti penambangan dan penangkapan ikan di laut, perlindungan lingkungan laut, militer angkatan laut dan sebagainya (Zhang dkk., 2017).

Beberapa dekade terakhir, telah dilakukan berbagai studi untuk mengestimasi atau memprediksi suhu permukaan laut (SPL). studi-studi tersebut dilakukan untuk mengevaluasi perubahan panas antara samudera dan atmosfer, perilaku arus laut dan samudra, serta perilaku pola-pola spesies akuatik (Anding dan Kauth, 1970). Secara historis, metode statistika, seperti regresi linear dan model *Autoregressive Integrated Moving Average* (ARIMA), secara luas telah digunakan untuk mengestimasi SPL (Zhang dkk., 2017). Dua sumber utama untuk mengevaluasi data SPL di laut dan samudra adalah pelampung (*buoy*) yang mengapung serta pengamatan menggunakan satelit.

Selain metode statistik, salah satu metode yang berpotensi dikembangkan untuk prediksi SPL adalah menggunakan metode atau teknik pembelajaran mendalam (*Deep Learning*). Pembelajaran mendalam merupakan salah satu bagian dari banyak bagian dari pembelajaran mesin (*machine learning*). Beberapa penelitian SPL yang berbasis pembelajaran mendalam telah dilakukan adalah menggunakan model *Long Short-Term Memory* (LSTM) (Kim dkk., 2021; Zhang, 2017; Padang, 2023). Keunggulan model LSTM adalah kemampuannya untuk menghindari terjadinya masalah ledakan gradien sehingga memberikan hasil prediksi yang akurat. Model pembelajaran mendalam lain yang berpotensi dikembangkan dan belum banyak dikembangkan untuk prediksi SPL adalah *Deep neural Networks* (DNN).

Keunggulan metode pembelajaran mendalam, khususnya DNN, adalah DNN memiliki kemampuan untuk dilatih mempelajari pola-pola yang terkandung di dalam suatu data. DNN merupakan teknik yang paling sederhana dari pembelajaran mendalam. DNN sendiri merupakan pengembangan dari jaringan syaraf tiruan (JST) yang lapisan tersembunyi lebih dari satu lapisan dan operasi-operasi matematis meliputi fungsi linear dan nonlinear (LeCun dkk., 2015).

Sesuai dengan penjelasan di atas, model pembelajaran mendalam (*deep learning*) khususnya model DNN akan diterapkan dalam penelitian ini untuk mengestimasi atau memprediksi SPL. Perairan Manokwari akan digunakan sebagai lokasi penelitian. Pemilihan lokasi ini didasarkan pada lokasinya yang dekat dengan kota Manokwari sehingga perubahan SPL perairan tersebut dapat memengaruhi keadaan iklim kota Manokwari. Kemudian, SPL perairan umumnya lebih berfluktuasi jika dibandingkan dengan SPL Samudra yang relatif stabil sehingga menarik untuk diteliti. Selain itu, sejauh pengamatan penulis, penelitian tentang prediksi SPL

Perairan Kota Manokwari masih sangat terbatas.

## METODE PENELITIAN

Penelitian ini merupakan pemodelan berbasis mesin pembelajaran (*machine learning*) secara khusus menggunakan model *deep neural networks* (DNN). Penelitian dilaksanakan selama 4 bulan (November 2022 – Februari 2023), bertempat di Laboratorium Instrumentasi dan Energi, Jurusan Fisika, FMIPA, Universitas Papua, Manokwari.


Penelitian diawali dengan pengumpulan data Suhu Permukaan Laut Perairan Kota Manokwari, Kabupaten Manokwari, Provinsi Papua Barat. Dataset yang dipakai pada dalam penelitian ini bersumber dari *European Center for Medium-Range Weather Forecast* (ECMWF) berupa dataset SPL hasil reanalisis ERA5.

ERA5 adalah generasi kelima dari *ECMWF atmospheric reanalysis* iklim global. ERA5 merupakan lanjutan dari FGGE reanalysis tahun 1980-an, meliputi ERA-15, ERA-40, dan ERA-Interim. Reanalysis sendiri merupakan penggabungan model dan data pengamatan untuk memberikan penjelasan numerik terkait iklim sekarang. Ribuan peneliti dari seluruh dunia telah menggunakan data reanalisis dalam penelitian mereka. Hal ini didasari karena reliabilitas dan kontinuitas data masukan dalam melatih model merupakan faktor yang sangat penting (Kim dkk., 2020).

Dewasa ini, ECMWF menyediakan data-data terkait iklim, seperti kecepatan angin titik embun, hujan salju, dan SPL. Akan tetapi, pada penelitian ini difokuskan pada dataset SPL *EA5 reanalysis* (Mahmoodi dkk., 2019; Tarek dkk., 2020). Dataset yang tersedia di ECMWF merupakan data SPL perjam. Namun demikian, pada penelitian ini dikhususkan pada data pengukuran SPL siang hari tepat jam 12 siang. pemilihan data ini didasarkan pada alasan agar data yang digunakan dapat mempresentasikan nilai

SPL harian. Bentuk data SPL di ECMWF yang tersedia terdiri atas  $721 \times 1440$  titik data, dengan resolusi spasial  $0,25^0$  latitude dan  $0,25^0$  longitude.

Pada penelitian ini, Data SPL Perairan kota Manokwari yang terdiri atas satu piksel dengan titik koordinat 0,8 LS dan 134,2 BT dipilih sebagai wilayah target. Data SPL yang disediakan oleh ECMWF adalah data SPL tahun 1954-2021. Akan tetapi, demi efisiensi, maka data SPL yang digunakan dibatasi data 1 Januari 2000 sampai 31 Desember 2021 sehingga jumlah data sebanyak 8036 data SPL harian, seperti ditunjukkan pada Gambar 1 berikut.



**Gambar 1. Suhu Permukaan Laut (SPL) Perairan Kota Manokwari dalam rentang tahun 2000 – 2021**

Dataset SPL yang digunakan dalam penelitian ini dapat disitasi sebagai: *Copernicus Climate Change Service (C3S): ERA5: Fifth generation of ECMWF atmospheric reanalysis of the global climate. Copernicus Climate Change Service Climate Data Store (CDS), date of access. <https://cds.climate.copernicus.eu/cdsapp#!/dataset/reanalysis-era5-pressurelevels?tab=overview>*.

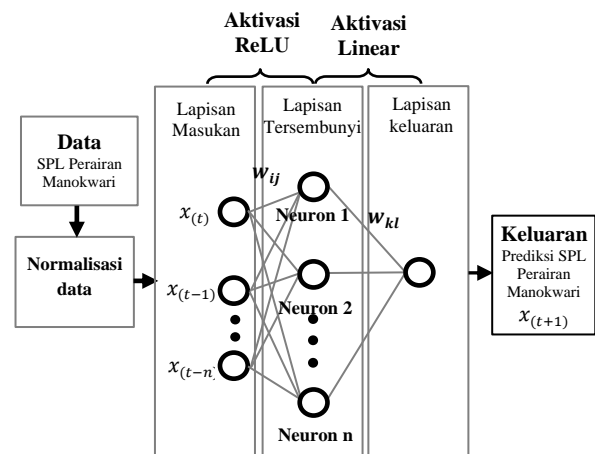
Setelah dataset SPL Perairan Manokwari diperoleh, tahapan selanjutnya adalah membagi dataset tersebut menjadi dua bagian, yaitu data pelatihan dan data pengujian. Jumlah dan persentase data yang digunakan untuk pelatihan dan pengujian model DNN adalah seperti ditampilkan pada Tabel 1. Data pelatihan digunakan untuk melatih jaringan DNN, sementara data pengujian merupakan

data yang digunakan untuk menguji model DNN, apakah jaringan DNN yang telah dilatih mampu memprediksi SPL Perairan kota Manokwari dengan akurat.

**Tabel 1. Pembagian Data SPL perairan Kota Manokwari untuk pelatihan dan pengujian model DNN**

Data	Persentase	Jumlah Data	Rentang Waktu
Pelatihan dan validasi	90%	6.430	1 Jan 2000 – 10 Oktober 2019
Pengujian	10%	803	11 Okt 2019 – 31 Des 2021

Setelah data SPL Perairan Kota Manokwari dibagi ke dalam data pelatihan dan pengujian, Langkah selanjutnya adalah membangun model DNN yang cocok untuk untuk memprediksi SPL Perairan Kota Manokwari. Pada penelitian ini, arsitektur untuk sistem pembelajaran mendalam ditampilkan pada Gambar 2. Jaringan DNN terdiri atas lapisan masukan, lapisan, tersembunyi, dan lapisan keluaran dan pada setiap lapisan terdiri atas neuron-neuron.



**Gambar 2. Arsitektur DNN untuk prediksi SPL Perairan Kota Manokwari**

Model DNN merupakan kombinasi dari *hyperparameter* yang memberikan hasil prediksi SPL terbaik. Proses pelatihan model DNN diawali dengan perhitungan bobot ( $w_{ijnm}$ ) dan bias ( $b_{ijnm}$ ) masukan menuju lapisan tersembunyi pertama seperti ditunjukkan pada persamaan berikut.

$$w_{ijnm} = \begin{bmatrix} w_{i_1j_1} & w_{i_1j_2} & \dots & w_{i_1j_m} \\ w_{i_2j_1} & w_{i_2j_2} & \dots & w_{i_2j_m} \\ w_{i_3j_1} & w_{i_3j_2} & \dots & w_{i_3j_m} \\ \dots & \dots & \dots & \dots \\ w_{i_nj_1} & w_{i_nj_2} & \dots & w_{i_nj_m} \end{bmatrix} \quad (1)$$

$$b_{ijnm} = [b_{i_1j_1} \quad b_{i_1j_2} \quad \dots \quad b_{i_1j_m}] \quad (2)$$

dengan  $w_{ijnm}$  dan  $b_{ijnm}$  secara berturut-turut adalah bobot dan bias antara lapisan masukan dan lapisan tersembunyi 1. Masukan  $i$  dan  $n$  menggambarkan masukan ke- $n$  sementara  $j$  dan  $m$  menggambarkan jalur menuju neuron pada lapisan tersembunyi 1.

Setelah bobot dan bias diperoleh, selanjutnya umpan maju dari lapisan masukan menuju lapisan tersembunyi 1 ( $FF_{i_1}$ ) dihitung menggunakan persamaan berikut,

$$FF_{i_1} = \sum \left( \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} \times w_{j_m k_n} \right) + [b_{ijnm}] \quad (3)$$

Kemudian, fungsi aktivasi digunakan untuk mengaktifkan atau menonaktifkan (*deactivate*) neuron-neuron pada lapisan. Fungsi ini akan mentransformasi masukan kedalam suatu bentuk masukan spesifik. Beberapa fungsi aktivasi yang umumnya digunakan pada DNN antara lain tanh, softmax, ReLU.

Pada penelitian ini, fungsi ReLU digunakan sebagai fungsi aktivasi. Pemilihan fungsi aktivasi ReLU didasarkan pada kemampuan fungsi aktivasi ini memberikan hasil yang lebih baik dibanding fungsi aktivasi lainnya (Nwankpa dkk., 2018). Langkah selanjutnya adalah menghitung bobot ( $w$ ) dan bias ( $b$ ) dari lapisan tersembunyi 1 menuju lapisan tersembunyi 2. Proses yang sama seperti antara lapisan masukan dan lapisan tersembunyi 1 diulang lagi antara lapisan tersembunyi 1 dan lapisan tersembunyi 2, demikian seterusnya hingga lapisan tersembunyi terakhir. Dari lapisan tersembunyi terakhir menuju keluaran menggunakan fungsi aktivasi linear, yaitu  $f(x) = x$ .

Metode adam optimizer dipakai sebagai fungsi optimasi untuk meminimumkan fungsi rugi (loss) selama pelatihan dan laju pelatihan ditala sebesar 0.001. Pelatihan DNN dilakukan dilakukan sebanyak 100 epoch dan strategi penghentian awal (*early stopping*) diterapkan selama pelatihan untuk menghindari terjadinya *overfitting* akibat penggunaan *hyperparameter* yang sangat kompleks. Proses pelatihan akan dimonitoring untuk setiap iterasi, dan *early stopping* akan bekerja jika tidak terdapat perubahan signifikan rugi validasi (*validation loss*) yang dicapai selama periode waktu yang telah ditentukan.

Pada saat umpan maju pelatihan menghasilkan hasil estimasi atau prediksi dari jaringan DNN pada lapisan keluaran, hasil estimasi ini keluaran akan dibandingkan dengan target yang diharapkan dengan menggunakan sebuah fungsi yang disebut sebagai fungsi rugi (*loss function*). Fungsi rugi ini digunakan untuk mengukur kinerja dari model DNN dalam melakukan prediksi terhadap target.

Pada model DNN, umumnya beberapa *hyperparameter* seperti jumlah lapisan, jumlah neuron, fungsi aktivasi dan dropout digunakan untuk memperoleh model terbaik. Hyper-parameter tersebut ditala dengan mengidentifikasi kombinasi hyper-parameter optimal untuk memperoleh kinerja terbaik dari model DNN. Pada penelitian ini, metode *trial dan error* di gunakan untuk memperoleh kombinasi *hyperparameter* model yang memberikan hasil terbaik. Jumlah lapisan tersembunyi diubah-ubah dengan variasi 1, 2, 3, dan 4 lapisan tersembunyi. Sementara, jumlah neuron pada tiap lapisan diubah-ubah dengan variasi 8, 16, 32, 64, dan 128 (Tabel 2)

Tabel 2. Variasi jumlah lapisan tersembunyi dan neuron

No	Lapisan tersembunyi	Jumlah neuron tiap lapisan tersembunyi
1	1	
2	2	
3	3	8, 16, 32, 64, dan 128
4	4	

Kriteria statistik, seperti kuadrat rata-rata kesalahan (*root mean square error*, RMSE), kesalahan kuadrat rata-rata (*mean squared error*, MSE), dan koefisien korelasi ( $R^2$ ) digunakan untuk mengevaluasi kinerja model DNN untuk memprediksi SPL. kriteria-kriteria tersebut secara matematis dapat dihitung menggunakan persamaan persamaan berikut:

$$R^2 = 1 - \frac{\sum_i^n (SPL_i^{akt} - SPL_i^{pred})^2}{\sum_i^n (SPL_i^{akt} - \overline{SPL}^{akt})^2} \quad (4)$$

$$MSE = \frac{\sum_i^n (SPL_i^{akt} - SPL_i^{pred})^2}{n} \quad (5)$$

$$RMSE = \left( \frac{\sum_i^n (SPL_i^{akt} - SPL_i^{pred})^2}{n} \right)^{1/2} \quad (6)$$

dengan  $SPL^{akt}$  adalah nilai SPL sebenarnya dan  $SPL^{pred}$  adalah nilai SPL hasil prediksi menggunakan model DNN.

Perangkat lunak Python digunakan untuk membangun jaringan DNN yang digunakan dalam penelitian ini. Perangkat lunak ini dijalankan secara *online* menggunakan platform *Google Colaboratory* yang dapat diakses melalui (<https://colab.research.google.com/>). Platform *Google Colaboratory* sendiri merupakan layanan komputasi awan (*cloud computation*) yang dikembangkan oleh tim Google untuk kepentingan pendidikan dan penelitian mesin pembelajaran. *Google colaboratory* berbasis *Jupyter Notebooks*. Platform ini menyediakan runtime yang sepenuhnya didedikasikan untuk pembelajaran mendalam, open source dan gratis (Carneiro dkk., 2018).

**HASIL DAN PEMBAHASAN**

Pengembangan model prediksi SPL perairan kota Manokwari menggunakan DNN diawali dengan pengembangan perangkat lunak model DNN, kemudian dilanjutkan dengan pelatihan dan validasi model DNN, dan diakhiri dengan pengujian

model DNN untuk memprediksi SPL. Pada bagian ini akan dijelaskan tiap tahapan.

**Pengembangan perangkat lunak model DNN**

Salah tahapan yang paling penting dalam pengembangan model DNN untuk memprediksi data runtun waktu, seperti data SPL adalah pengembangan perangkat lunak yang akan dipakai dalam melakukan prediksi. Seperti telah dijelaskan sebelumnya, perangkat lunak yang digunakan pada penelitian ini dijalankan secara online pada platform *Colaboratory Google*. Platform ini merupakan salah satu *environment* Phyton yang memiliki format notebook.

Jaringan DNN dibangun menggunakan Library Keras yang dijalankan diatas platform Tensorflow. Keras merupakan API mesin pembelajaran yang memungkinkan proses komputasi yang cepat dan program DNN yang sederhana. Script program yang digunakan dalam penelitian ini dapat dijalankan melalui:

[https://colab.research.google.com/drive/1H4bA85DHNf-4x3xTCF5EKHWeu9xvfQDs#scrollTo=k-ZlvyaY\\_4RN](https://colab.research.google.com/drive/1H4bA85DHNf-4x3xTCF5EKHWeu9xvfQDs#scrollTo=k-ZlvyaY_4RN)

**Pelatihan dan Validasi Model DNN**

Setelah perangkat lunak untuk model DNN berhasil dikembangkan, tahapan selanjutnya adalah pelatihan dan validasi model DNN dengan memasukkan data pelatihan dan pengujian seperti telah dijelaskan sebelumnya (Tabel 2). Tahapan pelatihan diawali dengan normalisasi data untuk menstandarisasi informasi yang terkandung dalam data dengan harapan nantinya hasil prediksi nantinya menjadi lebih akurat.

Untuk memperoleh *hyperparameter* yang optimal, pada penelitian ini, penentuan *hyperparameter* dilakukan dengan metode coba-coba (*trial and error*). metode ini umum digunakan dalam pembelajaran mendalam karena banyaknya *hyperparameter* yang disetting dan belum


ada metode yang benar-benar efektif dalam pemilihan *hyperparameter*. Adapun *hyperparameter* yang dipakai dalam pelatihan DNN untuk prediksi SPL perairan kota Manokwari adalah seperti adalah seperti ditampilkan pada Tabel 3 berikut.

Tabel 3. *Hyperparameter* yang dipakai untuk melatih jaringagn DNN memprediksi SPL perairan Kota Manokwari

<b>Hyperparameter</b>	<b>Setting</b>
Jumlah masukan	10
Jumlah lapisan tersembunyi	bervariasi
Jumlah neuron	bervariasi
Batch Size	30
Algoritma optimisasi	Adam
Jumlah Epoch	100
fungsi aktivasi	ReLU
laju pelatihan	0,01
<i>Early stopping</i>	Ya

Dari Tabel 3 terlihat jika jumlah lapisan tersembunyi dan jumlah neuron pada tiap lapisan tersembunyi bervariasi, jumlahnya sesuai dengan Tabel 2 yang telah dijelaskan sebelumnya. Kemudian, batch size disetting 30 dan algoritma optimisasi menggunakan optimizer. Selanjutnya jumlah epoch pelatihan ditetapkan sebanyak 100 epoch dan dilengkapi dengan *early stopping* untuk menghindari terjadinya *overfitting* selama pelatihan. fungsi aktivasi dipilih ReLu dan laju pelatihan ditala sebesar 0,01.

Tahapan selanjutnya adalah proses pelatihan DNN untuk memprediksi SPL Perairan Kota Manokwari. *Hyperparameter* yang sebelumnya telah ditetapkan dimasukkan ke dalam program. data yang digunakan untuk pelatihan adalah data SPL 1 Januari 2000 sampai 10 Oktober 2019 (90% data) seperti yang telah dijelaskan pada Tabel 1 sebelumnya. pada Gambar 3 ditampilkan evolusi nilai fungsi loss dan validasi selama pelatihan DNN.



**Gambar 3. Contoh grafik fungsi loss pada proses pelatihan dan validasi model DNN**

Sesuai dengan grafik pada Gambar 3, kurva loss turun secara drastis pada epoch ke-2 dan selanjutnya semakin mendekati nol. pelatihan jaringan DNN dilengkapi dengan fungsi *early stopping* sehingga walaupun epoch pelatihan ditata 100 epoch, proses pelatihan DNN akan dihentikan jika proses pelatihan tidak menunjukkan perkembangan, seperti nilai loss tetap dan atau meningkat. Pada pembelajaran mendalam, seperti DNN, *early stopping* berfungsi untuk menghentikan pelatihan ketika nilai fungsi loss tidak menunjukkan penurunan secara signifikan walaupun proses pelatihan belum mencapai epoch yang telah ditentukan. *early stopping* berguna untuk menghindari terjadinya *overfitting* pelatihan.

**Pengujian Model DNN**

Pada Tabel 4 ditampilkan hasil pengujian untuk arsitektur jaringan DNN yang jumlah lapisan tersembunyi dan neuron yang berbeda-beda. Berdasarkan tabel dapat dilihat bahwa secara umum kinerja masing-masing model DNN dalam memprediksi SPL perairan Manokwari tidak berbeda signifikan. Nilai RMSE berada dalam rentang 0,121-0,271, Nilai MSE dalam rentang 0,015-0,094, dan koefisien korelasi ( $R^2$ ) dalam rentang 0,840-0,935.

Tabel 4. Hasil pengujian model DNN untuk memprediksi SPL kota perairan Manokwari


Lapisan	Neuron	RMSE	MSE	R2
1	8	0,156	0,024	0,928
	16	0,148	0,022	0,901
	32	0,177	0,031	0,910
	64	0,135	0,018	0,931
	128	0,141	0,019	0,922
2	8	0,139	0,019	0,905
	16	0,240	0,058	0,935
	<b>32</b>	<b>0,121</b>	<b>0,015</b>	<b>0,935</b>
	64	0,141	0,020	0,923
	128	0,166	0,028	0,933
3	8	0,139	0,019	0,930
	16	0,179	0,031	0,869
	32	0,169	0,028	0,915
	64	0,271	0,073	0,919
	128	0,139	0,094	0,929
4	8	0,168	0,028	0,860
	16	0,197	0,039	0,840
	32	0,174	0,030	0,850
	64	0,156	0,024	0,930
	128	0,125	0,016	0,926

Secara umum, dapat nyatakan bahwa tiap model DNN cukup akurat untuk memprediksi SPL perairan Manokwari. Hal ini ditandai dengan nilai RMSE dan MSE yang cukup kecil. Nilai RMSE dan MSE yang kecil mengindikasikan bahwa SPL hasil prediksi DNN hampir berimpit dengan nilai SPL sebenarnya. Demikian halnya koefisien korelasi ( $R^2$ ) yang nilainya hampir 1 menggambarkan bahwa nilai SPL hasil prediksi DNN sangat terkait dengan nilai SPL sebenarnya.

Namun demikian, model DNN dengan jumlah lapisan tersembunyi 2 lapisan, dan neuron pada masing-masing lapisan tersembunyi sebanyak 32 memberikan hasil prediksi SPL yang lebih baik dibanding model-model DNN lain yang diujikan pada penelitian ini. Hal ini ditandai dengan Nilai RMSE, MSE, dan  $R^2$  pengujian secara berurutan sebesar 0,121; 0,015; dan 0,935. Oleh karena itu, pada pembahasan


selanjutnya model ini DNN ini akan dibahas secara khusus.

Gambar 4 ditampilkan hasil pengujian model DNN dengan 2 lapisan tersembunyi dan 32 neuron tiap lapisan tersembunyi untuk memprediksi SPL Perairan Manokwari. Dari grafik dapat dilihat bahwa secara umum nilai SPL hasil prediksi DNN cukup berimpit dengan nilai SPL aktual. Hal ini menunjukkan bahwa model DNN yang diajukan cukup akurat dalam memprediksi SPL perairan Manokwari.



**Gambar 4. Hasil prediksi SPL menggunakan model DNN 2 lapisan tersembunyi dan 32 neuron pada tiap lapisan**

Selanjutnya, pada Gambar 5 ditampilkan grafik korelasi antara nilai SPL hasil prediksi dengan SPL aktual pada tahap pengujian untuk model DNN 2 lapisan tersembunyi dan 32 neuron pada tiap lapisan tersembunyi. Dari grafik dapat dilihat bahwa titik-titik data tersebar disekitar garis lurus (berwarna merah). Grafik korelasi tersebut mengonfirmasi nilai koefisien korelasi ( $R^2$ ) sebesar 0,935. Nilai korelasi yang mendekati satu menunjukkan bahwa secara umum SPL ada ketergantungan yang kuat antara nilai prediksi DNN dan nilai SPL atau dengan kata lain nilai prediksi DNN dapat mengikuti trend perubahan nilai SPL aktual.



**Gambar 5.** Korelasi antara SPL hasil prediksi DNN DNN 2 lapisan tersembunyi dan 32 neuron tiap lapisan dengan SPL aktual.

## KESIMPULAN

Berdasarkan hasil dan pembahasan di atas dapat disimpulkan bahwa model DNN cukup akurat untuk prediksi SPL perairan kota Manokwari. Model DNN dengan jumlah lapisan tersembunyi 2 lapisan, dan jumlah neuron setiap lapisan tersembunyi 32 memberikan hasil yang lebih akurat dibanding model lainnya, dengan nilai RMSE, MAE, dan  $R^2$  secara berurutan adalah 0,121; 0,015; dan 0,935.

Pada penelitian ini masih menggunakan data *univariat* dengan masukan dan keluaran adalah SPL. Untuk penelitian selanjutnya disarankan dengan menggunakan parameter masukan yang berbeda (*multivariat*), misal masukan berupa kelembaban dan curah hujan sementara keluaran SPL.

## DAFTAR PUSTAKA

- Anding, D., & Kauth, R. (1970). *Estimation of Sea Surface Temperature from Space*.
- Carneiro, T., da Nobrega, R. V. M., Nepomuceno, T., Bian, G. bin, de Albuquerque, V. H. C., & Filho, P. P. R.

(2018). Performance Analysis of Google Colaboratory as a Tool for Accelerating Deep Learning Applications. *IEEE Access*, 6, 61677–61685.

Padang, E., 2023. Model *Long Short-Term Memory* (LSTM) Untuk Memprediksi Suhu Permukaan Laut Perairan Kota Manokwari, Kabupaten Manokwari. Laporan Penelitian. Jurusan Fisika, FMIPA, Universitas Papua.

Kim, M., Yang, H., & Kim, J. (2020). Sea surface temperature and high water temperature occurrence prediction using a long short-term memory model. *Remote Sensing*, 12(21), 1–21.

Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. Dalam *Nature* (Vol. 521, Nomor 7553, hlm. 436–444). Nature Publishing Group.

Mahmoodi, K., Ghassemi, H., & Razminia, A. (2019). *Temporal and Spatial Characteristics of Wave Energy in the Persian Gulf based on the ERA5 Reanalysis Dataset*. <https://www.sciencedirect.com/science/article/pii/S0360544219316858>

Tarek, M., Brissette, F. P., & Arsenault, R. (2020). Evaluation of the ERA5 reanalysis as a potential reference dataset for hydrological modelling over North America. *Hydrology and Earth System Sciences*, 24(5), 2527–2544.

Zhang, Q., Wang, H., Dong, J., Zhong, G., & Sun, X. (2017). Prediction of Sea Surface Temperature Using Long Short-Term Memory. *IEEE Geoscience and Remote Sensing Letters*, 14(10), 1745–1749.