

ANALISIS KINERJA METODE ARTIFICIAL NEURAL NETWORK DAN SUPPORT VECTOR REGRESSION UNTUK PREDIKSI SIGNIFICANT WAVE HEIGHT

¹Subhan Nooriansyah, ²Chastine Fatichah, ³Kriyo Sambodho

¹²Teknik Informatika, Fakultas, Institut Teknologi Sepuluh November Surabaya, Indonesia

³Teknik Kelautan, Fakultas, Institut Teknologi Sepuluh November Surabaya, Indonesia

Jl. Raya ITS, Keputih, Sukolilo, Keputih, Sukolilo, Surabaya, Jawa Timur 60111

Email : ¹subhan.nooriansyah@gmail.com, ²chastine@cs.its.ac.id, ³k_sambodho@oe.its.ac.id

Abstrak. Faktor tekanan angin pada laut dapat menghasilkan gelombang. Tinggi gelombang atau wave height (WH) adalah salah satu bagian dari bentuk gelombang. Significant wave height (SWH) salah satu jenis WH yang merupakan rata-rata nilai sepertiga WH tertinggi pada gelombang spektrum. Data SWH dapat diperoleh dari dua sumber yaitu dari situs resmi penyedia data historikal yang jumlahnya sangat besar dan dari hasil observasi satellite. Namun data dari hasil observasi satellite umumnya data kurang akurat. Prediksi SWH sangat penting dilakukan untuk mengukur kekuatan beban yang diterima oleh kapal dan bangunan diatas atau dalam laut. Metode prediksi yang digunakan oleh peneliti bidang kelautan umumnya adalah metode numerik dan statistik. Metode numerik memiliki kendala dalam memprediksi data skala besar dan hasil prediksi tidak akurat. Metode statistik terkendala pada penentuan parameter untuk menghasilkan prediksi yang akurat. Metode machine learning (ML) merupakan metode yang sering digunakan untuk memprediksi data berdasarkan data histori sehingga dapat digunakan sebagai metode untuk memprediksi nilai SWH. Kelebihan metode ML yaitu dapat memprediksi SWH skala besar, ML dapat memodelkan prediksi dengan mempelajari data. Metode ML yang biasanya digunakan untuk memprediksi data adalah artificial neural network (ANN) dan support vector regression (SVR). Paper ini melakukan analisis kinerja kedua metode tersebut untuk memprediksi nilai SWH. Dataset yang digunakan adalah data historikal SWH dari Brisbane, Australia. Dataset dirubah dengan Sliding Window (SW) untuk menyesuaikan dengan struktur ANN dan SVR. Hasil prediksi kedua metode dievaluasi menggunakan metode evaluasi yaitu mean absolute percentage error (MAPE). Dataset SWH berasal dari situs bmgk pemerintahan Australia. Berdasarkan hasil prediksi SWH menggunakan ANN dan SVR. Hasil evaluasi prediksi pada SW ukuran 3 yaitu ANN mendapatkan MAPE 6.88 % sedangkan hasil evaluasi prediksi SVR mendapatkan MAPE 8.51 %.

Kata Kunci: Wave Height, Significant Wave Height, Numerik, Statistik, Machine Learning, Artificial Neural Networks, Support Vector Regression, Prediksi, Data Historikal, Evaluasi, Mean Absolute Percentage Error, Sliding Window.

Faktor tekanan angin pada laut dapat menghasilkan gelombang. Ada tiga bagian dari gelombang yaitu panjang gelombang, periode gelombang dan tinggi gelombang atau wave height (WH). Salah satu dari bagian gelombang yang digunakan untuk memprediksi adalah WH. Kekuatan laut ditunjukkan besarnya nilai WH (Taylor, 1985). Significant wave height (SWH) salah satu jenis WH. SWH adalah rata-rata WH sepertiga tertinggi pada gelombang spectrum. Prediksi SWH sangat penting dilakukan oleh peneliti di bidang kelautan untuk memperkirakan kekuatan beban yang diterima oleh struktur bangunan di atas atau dalam laut (B. Smith, 2006). Contoh kapal, bangunan bor kilang minyak dan tambak ikan. Data SWH dapat diperoleh dari dua sumber. Pertama data historikal dari situs

pengumpul data historikal resmi Queensland Government, Australia (Queensland Government, 2017). Kedua hasil observasi satellite menghasilkan gambar dan nilai interval SWH, tetapi data kurang akurat (Bertin, Prouteau, & Letetrel, 2013; Galanis et al., 2012). Metode prediksi yang digunakan oleh bidang kelautan pada umumnya menggunakan metode numerik dan statistik (Forristall, 1978). Metode numerik lebih sering digunakan untuk menghitung SWH dalam skala kecil, apabila SWH skala besar keakuratan prediksi dapat menurun (Thornton & Guza, 1983). Metode statistik dipengaruhi oleh ketepatan memilih parameter dan distribusi untuk menghasilkan model, tetapi hasil pemodelan sensitif pada satu wilayah (Mandal & Prabakaran, 2010). Machine learning (ML) adalah metode

prediksi yang dapat memodelkan data dengan melakukan pelatihan. Pengujian data dilakukan untuk menguji sensitifitas pemodelan, (Dietterich, 2009). Metode ML yang sering digunakan untuk memprediksi data yaitu *artificial neural network* (ANN) dan *support vector regression* (SVR) (Malekmohamadi, Bazargan-Lari, Kerachian, Nikoo, & Fallahnia, 2011). Data SWH diperoleh dalam bentuk satu baris, sebelum melakukan pelatihan data SWH harus dirubah menggunakan metode *sliding window* (SW).

Sliding Window

Data SWH harus disesuaikan dengan struktur metode ANN dan SVR. SW digunakan untuk merubah satu baris data SWH menjadi *vector* (Yin, Zou, & Xu, 2013). Ukuran window yang digunakan adalah 3 dan 5.

Artificial Neural Network

ANN adalah jenis dari metode *supervised learning* (Hastie, Tibshirani, & Friedman, 2009). ANN adalah metode yang terinspirasi dari jaringan syaraf manusia yang terkoneksi dengan neuron. Metode ANN melakukan pelatihan untuk menghasilkan pemodelan data (M. Bishop, 2006). Hasil pengujian data menghasilkan prediksi data. Jenis data latih yang sering digunakan untuk pelatihan yaitu iris (Cheng, Jiang, & Yuan, 2009), signal (Dyrløv Bendtsen, Nielsen, von Heijne, & Brunak, 2004) dan SWH (Rizianiza, 2015). Kelebihan ANN dapat melatih data historikal dan memberikan solusi *local optimum*. Metode pelatihan yang digunakan yaitu *multilayer perceptron* (MLP) feed forward backpropagation (Prahlada & Deka, 2015). Struktur MLP terdiri dari 3 layer yaitu *input layer*, *hidden layer* dan *output layer neuron*. Setiap layer terkoneksi satu sama lain. *Link* sebagai pembangkit nilai bobot dapat penghubung layer satu dengan layer yang lain. *Input layer* sebagai sumber masuk data latih. *Hidden layer* terdapat *activation function* (AF) berperan penting untuk mengubah nilai dibawah threshold 1 atau 0. Jenis AF yaitu *approximated sigmoid*, *sigmoid* dan *softplus* (Maas, Hannun, & Ng, 2013). Pemilihan AF yang tepat dapat mempercepat proses pelatihan MLP. *Output layer* pada prediksi

tidak menggunakan *threshold* seperti pada klasifikasi.

Support Vector Regression

Support *vector regression* (SVR) tergabung dalam *supervised learning* (SL). Metode SVR terinspirasi oleh pendekatan teori perhitungan statistik dan ruang lingkup permasalahan *nonlinear* (K. & Deka, 2015). SVR sama seperti metode SL yang lain melakukan proses pelatihan dan pengujian (M. Bishop, 2006). Dataset SVR dirubah menjadi *vector* dan dipetakan menjadi 1 dimensi atau lebih dari 1 dimensi, hal ini dipengaruhi karakteristik statistik dataset. Dataset dirubah menjadi *vector* untuk dipetakan dalam ruang dimensi, semakin tinggi dimensi semakin lama proses pelatihan dan pengujian yang dilakukan. Metode SVR telah berhasil digunakan untuk memprediksi dataset seperti konsumsi listrik turkey (Kavaklioglu, 2011), kecepatan angin (Wang, Chen, Liu, & Wu, 2015), WH (Mahjoobi & Adeli Mosabbeeb, 2009) dan SWH (Prahlada & Deka, 2015). Jenis kernel SVR yaitu *polynomial* dan *radial basis function*. SVR mempunyai *optimizer* untuk mengoptimalkan nilai bobot pada *vector* agar dapat bergerak mendekati data *target* atau data pengujian. Metode *optimizer* yaitu SVR *sequential minimal optimizing* (SMO) (Flake & Lawrence, 2002). Kekurangan dari SMO adalah proses pelatihan untuk menghasilkan model terjadi kompleksitas waktu yang tinggi. Peningkat SMO dilakukan dengan metode baru yaitu *improved sequential minimal optimizing* (ISMO) (Shevade, Keerthi, Bhattacharyya, & Murthy, 2000).

Metode Evaluasi

Metode evaluasi sering digunakan untuk mengetahui kesalahan prediksi sebuah metode. Ada tiga jenis metode evaluasi yang digunakan yaitu *mean absolute percentage error* (MAPE), *root mean square error* (RMSE) dan *mean square error* (MSE) (Hyndman & Koehler, 2006). Ketiga metode evaluasi yang sering digunakan untuk mengukur kinerja hasil prediksi terbaik adalah MAPE. Dua metode evaluasi tambahan menguji sensitifitas kedua metode terhadap SWH (Hyndman & Koehler, 2006). RMSE dan MSE lebih sering digunakan

untuk observasi proses pelatihan oleh ANN atau SVR.

Weka

Adalah salah satu alat ML untuk melakukan klasifikasi atau prediksi untuk keperluan *data mining* (Hall et al., 2009). Metode prediksi terkini sudah diimplementasikan seperti SVR ISMO di weka (Berbić, Ocvirk, Carević, & Lončar, 2017). Tiga metode evaluasi kesalahan prediksi sudah menjadi fungsi utama di weka. Weka menggunakan *library forecast* untuk menggunakan metode prediksi MLP dan SVR ISMO.

I. Metodologi

Prediksi Significant Wave Height

Sumber yang sering digunakan untuk memprediksi adalah data historikal atau hasil dari survei. Situs yang berbasis *opensource* dan resmi dari pemerintahan memberikan peluang besar keakurasian dataset lebih baik daripada *satellite*. Metode yang digunakan untuk memprediksi adalah ANN dan SVR. Metode pelatihan yang digunakan untuk ANN yaitu *multilayer perceptron* (MLP) (Altunkaynak, 2013). Metode pelatihan yang digunakan untuk *support vector regression improved sequential minimal optimizing* (SVR ISMO). Kedua metode akan melakukan prediksi dengan menggunakan dataset SWH. Prediksi dengan nilai MAPE terkecil adalah metode prediksi terbaik. RMSE dan MSE menunjukkan pemodelan dari hasil pelatihan dan pengujian.

Deskripsi Dataset

Lokasi data historikal SWH berasal dari tengah laut sebelah utara kota Brisbane. Dataset SWH yang digunakan berasal dari situs *opensource* pemerintahan Queensland Australia. Data SWH dipilih sebagai data prediksi dikarenakan jumlah dataset berjumlah diatas lebih dari 10.000 baris kolom yaitu sejumlah 17568. Jumlah dataset yang besar dapat mengukur kekuatan sebuah metode untuk memprediksi dataset yang besar. Manfaat data historikal dapat digunakan untuk memprediksi satu langkah kedepan. Data historikal dapat sebagai analisa lokal sebelum melakukan survei langsung, hal ini dapat mengurangi biaya

survei dibidang ilmu kelautan dan fokus pada analisa perhitungan dan perencanaan.

Dataset SWH akan disesuaikan dengan bentuk struktur ANN dan SVR menggunakan SW. Ukuran window yang digunakan adalah 3 dan 5. Kedua metode menggunakan Weka sebagai alat penerapan metode MLP dan SVR untuk melihat akurasi prediksi SWH terkecil.

Tabel 1. Sampel Dataset SWH

Tanggal (tahun-bulan-hari)	Waktu (Jam:Menit:Detik)	SWH (Meter)
2016-01-01	00:00:00	3.10
2016-01-01	00:30:00	3.35
2016-01-01	01:00:00	3.28
2016-01-01	01:30:00	3.22
2016-01-01	02:00:00	3.38
2016-01-01	02:30:00	3.25
2016-01-01	03:00:00	3.12
2016-01-01	03:30:00	3.10
2016-01-01	04:00:00	2.98
2016-01-01	04:30:00	3.15

Activation Function

MLP di weka mengimplementasikan 3 AF yaitu :

1. Approximate Sigmoid yaitu peningkatan kecepatan menghitung *sigmoid* di weka (1) (Berbić et al., 2017).

$$f(x) = \frac{1}{(1 + e^{-x})} \quad (1)$$

2. Sigmoid yaitu merubah nilai dari *input layer* menjadi mendekati 1 atau 0 (2) (Maas et al., 2013).

$$f(x) = K \left(\sum_i w_i g_i(x) \right) \quad (2)$$

3. Soft Plus yaitu merubah nilai dari *input layer* di *hidden layer* menjadi *smooth* dengan *logaritma* (Glorot, Bordes, & Bengio, 2011) (3).

$$f(x) = \log(1 + e^x) \quad (3)$$

Kernel

Pemodelan pada SVR ISMO ditentukan oleh kernel yang digunakan. Ada dua kernel yang digunakan yaitu *polynomial* (4)(5) (Weiße, Wellein, Alvermann, & Fehske, 2006) dan RBF (6) (Mahjoobi & Adeli Mosabbab, 2009).

1. Polynomial :

$$K(x, y) = \langle x, y \rangle^p \quad (4)$$

$$K(x, y) = (\langle x, y \rangle + 1)^p \quad (5)$$

2. RBF:

$$f(x) = \sum_{n=1}^N t_n h(x - x_n) \quad (6)$$

Konfigurasi Parameter

Pemilihan parameter berguna untuk membuat proses pelatihan menjadi lebih cepat. Berikut ini tabel konfigurasi parameter untuk MLP dan SVR. Konfigurasi berdasarkan parameter yang ada di weka.

Tabel 2 Konfigurasi MLP

Parameter	Nilai / Status
Activation Function	Approximate Sigmoid
	Sigmoid
	Soft Plus
Batch Size	100
Debug	False
Do not check capabilities	False
Loss Function	Squared Error
Number Decimal Places	2
Number Function	2
Number Threads	1
Pool Size	1
Ridge	0.01
Seed	1
Tolerance	1.0E-6
Use CGD	False

Tabel 3 Konfigurasi SVR

Parameter	Nilai/Status
Batch Size	100
C	1.0
Debug	False
Do not check capabilities	False
Filter Type	Normalize training data
Kernel	Polynomial
	Radial Basis Function
Number Decimal Places	2
Regression Optimizer	Support Vector Regression Improved Sequential Minimal

Pada Tabel 4 dan Tabel 5 menunjukkan konfigurasi parameter untuk *polynomial kernel* dan *RBF kernel*.

Tabel 4 Parameter Polynomial kernel

Parameter	Nilai/Status
Gamma	0.01
Cache Size	250007
Debug	False

Tabel 5 Parameter RBF Kernel

Parameter	Nilai/Status
Batch Size	100
C	1.0
Debug	False
Do not check capabilities	False
Filter Type	Normalize training data
Kernel	Polynomial
	Radial Basis Function
Number Decimal Places	2

Evaluasi Metode Prediksi

Evaluasi metode prediksi dilakukan untuk mengetahui perbedaan nilai prediksi diantara kedua metode. Ada tiga metode yang digunakan untuk melihat perbedaan tersebut MAPE, RMSE dan MSE.

1. MAPE yaitu menghitung rata-rata presentasi kesalahan prediksi pada metode (7) (Hyndman & Koehler, 2006). $mean(|p_t|)$ (7)

2. RMSE yaitu menghitung akar kuadrat MSE (8) (Hyndman & Koehler, 2006). \sqrt{MSE} (8)

3. MSE yaitu menghitung rata-rata pangkat kesalahan prediksi (9) (Hyndman & Koehler, 2006). $mean(e_t^2)$ (9)

MAPE dapat menunjukkan kesalahan prediksi dalam bentuk presentase karena tidak setiap orang dapat memahami hasil evaluasi metode RMSE dan MSE.

Skenario Uji Coba

Pengujian prediksi metode MLP dan SVR dengan ISMO diskenariokan berdasarkan SW, AF dan Kernel. Pertama ukuran SW pada dataset SWH. Kedua penggunaan AF untuk MLP. Ketiga penggunaan kernel untuk SVR dengan ISMO. Pemilihan AF yang tepat pada MLP dapat memberikan peluang yang besar untuk

menghasilkan nilai prediksi yang mendekati nilai sebenarnya. Pemilihan kernel menjadi kunci hasil prediksi SVR.

Tabel 6 Skenario Uji Coba Metode MLP dan SVR

Metode	SW	AF/Kernel	Evaluasi
MLP	1, 3, 5	Approximated Sigmoid	MAPE, RMSE, MSE
		Sigmoid	
		Softplus	
SVR	1, 3, 5	Polynomial	Radial Basis Function
		Radial Basis Function	

Hal ini dilakukan untuk mengetahui hasil prediksi dan mengatur konfigurasi parameter yang telah digunakan untuk mengoptimalkan fungsi metode prediksi MLP dan SVR dengan ISMO.

II. Hasil dan Pembahasan

Pengujian metode MLP dan SVR ISMO menggunakan weka. Berdasarkan skenario yang dirancang MLP menggunakan 3 AF dan SVR menggunakan 2 kernel. MLP dilakukan proses pelatihan pada Tabel 7 dan pengujian pada Tabel 8 dengan dataset SWH.

Tabel 7 Hasil Pelatihan Evaluasi Metode MLP

AF	SW	MAPE (%)	RMSE	MSE
Approximated Sigmoid	1	4.67	0.11	0.01
	3	6.12	0.14	0.02
	5	7.52	0.17	0.02
Sigmoid	1	4.67	0.11	0.01
	3	6.15	0.14	0.02
	5	7.56	0.17	0.03
Soft Plus	1	4.59	0.11	0.01
	3	6.04	0.14	0.02
	5	7.38	0.17	0.03

Berdasarkan Tabel 7 menunjukkan penggunaan AF *soft plus* menghasilkan RMSE dan MSE relatif sama. Hasil MAPE memberikan hasil yang berbeda yaitu 6.038 % dengan ukuran SW 3 dan 5 lebih baik daripada *approximate sigmoid* dan *sigmoid*. Hal ini dikarenakan pemilihan bobot pada *softplus* dapat menghasilkan perkalian nilai bobot dengan AF yang optimal dibandingkan dengan kedua AF yang lain.

Tabel 8 Hasil Pengujian Evaluasi Metode MLP

AF	SW	MAPE (%)	RMSE	MSE
Approximate Sigmoid	1	6.22	0.09	0.01
	3	11.33	0.15	0.02
	5	17.25	0.22	0.05
Sigmoid	1	8.35	0.08	0.01
	3	15.83	0.12	0.01
	5	22.04	0.15	0.03
Soft Plus	1	4.58	0.09	0.01
	3	6.88	0.12	0.01
	5	9.25	0.16	0.02

Berdasarkan SVR dengan ISMO dilakukan proses pelatihan pada Tabel 9 dan pengujian pada Tabel 10.

Tabel 9 Hasil Pelatihan SVR ISMO Polynomial

c	e	SW	MAPE (%)	RMSE	MSE
1.0	1.0	1	4.61	0.11	0.01
		3	5.95	0.14	0.02
		5	7.21	0.18	0.03
1.0	2.0	1	5.75	0.15	0.02
		3	8.70	0.43	0.19
		5	16.53	7.42	55.0

Tabel 10 Hasil Pengujian SVR ISMO Polynomial

c	e	SW	MAPE (%)	RMSE	MSE
1.0	1.0	1	5.22	0.87	0.01
		3	8.51	0.14	0.02
		5	12.07	0.19	0.03
1.0	2.0	1	25.45	0.44	0.20
		3	39.21	0.59	0.35
		5	38.74	0.54	0.30

Tabel 11 Hasil Pelatihan SVR ISMO Radial Basis Function

Gamma	SW	MAPE (%)	RMSE	MSE
0.01	1	4.64	0.11	0.01
	3	5.98	0.14	0.02
	5	7.24	0.18	0.03


Tabel 12 Hasil Pengujian SVR ISMO Radial Basis Function

Gamma	SW	MAPE (%)	RMSE	MSE
0.01	1	6.77	0.10	0.01
	3	12.44	0.17	0.03
	5	18.57	0.25	0.06

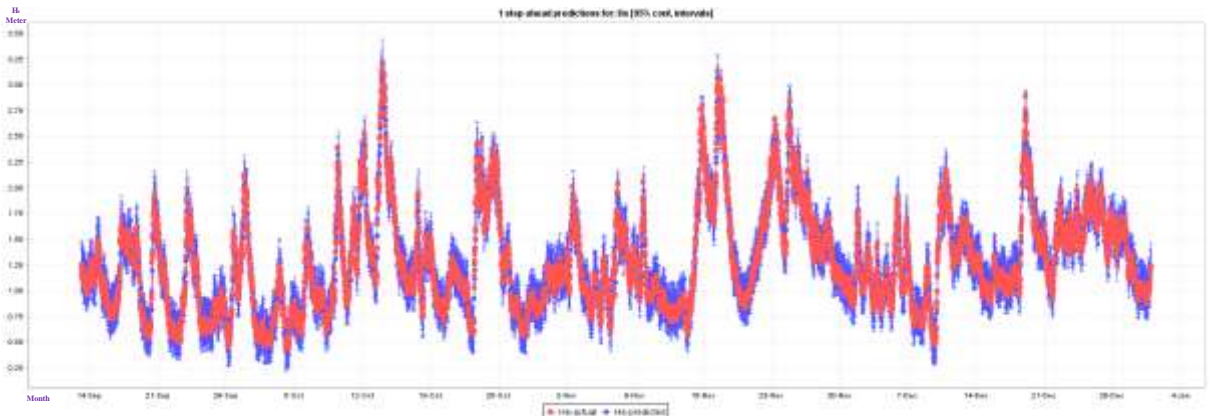
Berdasarkan hasil pelatihan MLP menggunakan AF *soft plus* menunjukkan

hasil MAPE lebih baik dibandingkan menggunakan metode MLP dengan AF *approximate sigmoid* dan *sigmoid*. Hasil grafik pelatihan MLP *soft plus* Gambar 1

terhadap SWH Brisbane 2016. Hasil pengujian MLP *soft plus* terhadap SWH Brisbane 2016 Gambar 2.



Gambar 1 Pelatihan MLP *soft plus* SWH Brisbane 2016



Gambar 2 Pengujian MLP *soft plus* SWH Brisbane 2016

Perbandingan hasil pengujian prediksi terbaik di antara ke dua metode ditunjukkan pada Tabel 13.

Tabel 13 Perbandingan Hasil Pengujian Prediksi Terbaik

Metode	SW	MAPE (%)	RMSE	MSE
MLP	3	6.88	0.12	0.01

Perbandingan hasil pengujian prediksi terbaik di antara ke dua metode ditunjukkan pada Tabel 13.

Tabel 13 hasil pertama MLP *sigmoid* menunjukkan MAPE 6.88 % lebih kecil dibandingkan SVR ISMO dengan *polynomial* kernel yaitu 8.51 %. Hasil kedua MLP *softplus* MAPE 9.25 % dan SVR ISMO dengan kernel *polynomial* yaitu 12.07 %. Berdasarkan RMSE dan MSE pada

(Softplus)	5	9.25	0.16	0.02
SVR ISMO	3	8.51	0.14	0.02
(Polynomial)	5	12.07	0.19	0.03

Berdasarkan

MLP *sigmoid* menunjukkan nilai rata-rata kesalahan prediksi yang lebih kecil. MLP *softplus* yaitu RMSE 0.14 dan MSE 0.02 berada dibawah dari SVR ISMO dengan *polynomial*. Prediksi dengan MLP *sigmoid* menghasilkan presentase yang mendekati nilai sebenarnya. Hasil RMSE dan MSE dapat digunakan sebagai nilai pembantu observasi untuk memastikan metode prediksi digunakan semakin dekat.

III. Simpulan

Metode ANN dan SVR merupakan metode ML yang sering digunakan untuk memprediksi. Penggunaan data SWH sebagai data pengujian prediksi menunjukkan metode ANN menghasilkan nilai MAPE yang lebih baik yaitu 6.88% dengan ukuran window 3 dibandingkan SVR yaitu 8.51%. Proses pelatihan ANN lebih cepat dibandingkan SVR. SVR proses pelatihan lebih lama dan hasil prediksi SVR menjadi tidak lebih baik dari ANN dengan pelatihan MLP.

IV. Daftar Pustaka

- [1] Altunkaynak, A. (2013). Prediction of significant wave height using genomultilayer perceptron. *Ocean Engineering*, 58, 144–153. <https://doi.org/10.1016/j.oceaneng.2012.08.005>
- [2] B. Smith, C. (2006). *Extreme Waves*. Washington, D.C.: Joseph Henry Press. <https://doi.org/10.17226/11635>
- [3] Berbić, J., Ocvirk, E., Carević, D., & Lončar, G. (2017). Application of neural networks and support vector machine for significant wave height prediction. *Oceanologia*, 59(3), 331–349. <https://doi.org/10.1016/j.oceano.2017.03.007>
- [4] Bertin, X., Prouteau, E., & Letetrel, C. (2013). A significant increase in wave height in the North Atlantic Ocean over the 20th century. *Global and Planetary Change*, 106, 77–83. <https://doi.org/10.1016/j.gloplacha.2013.03.009>
- [5] Cheng, Y., Jiang, M., & Yuan, D. (2009). Novel clustering algorithms based on improved artificial fish swarm algorithm. *6th International Conference on Fuzzy Systems and Knowledge Discovery, FSKD 2009*, 3, 141–145. <https://doi.org/10.1109/FSKD.2009.534>
- [6] Dietterich, T. G. (2009). Machine learning in ecosystem informatics and sustainability. *IJCAI International Joint Conference on Artificial Intelligence*. <https://doi.org/10.1145/242224.242229>
- [7] Dyrlov Bendtsen, J., Nielsen, H., von Heijne, G., & Brunak, S. (2004). Improved Prediction of Signal Peptides: SignalP 3.0. *Journal of Molecular Biology*, 340(4), 783–795. <https://doi.org/10.1016/j.jmb.2004.05.028>
- [8] Flake, G. W., & Lawrence, S. (2002). Efficient SVM regression training with SMO. *Machine Learning*, 46(1–3), 271–290. <https://doi.org/10.1023/A:1012474916001>
- [9] Forristall, G. Z. (1978). On the statistical distribution of wave heights in a storm. *Journal of Geophysical Research*, 83(C5), 2353. <https://doi.org/10.1029/JC083iC05p02353>
- [10] Galanis, G., Hayes, D., Zodiatis, G., Chu, P. C., Kuo, Y. H., & Kallos, G. (2012). Wave height characteristics in the Mediterranean Sea by means of numerical modeling, satellite data, statistical and geometrical techniques. *Marine Geophysical Research*, 33(1), 1–15. <https://doi.org/10.1007/s11001-011-9142-0>
- [11] Glorot, X., Bordes, A., & Bengio, Y. (2011). Deep sparse rectifier neural networks. *AISTATS '11: Proceedings of the 14th International Conference on Artificial Intelligence and Statistics*, 15, 315–323. <https://doi.org/10.1.1.208.6449>
- [12] Hall, M. A., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., & Witten, I. H. (2009). The WEKA data mining software: an update. *SIGKDD Explorations*, 11(1), 10–18. <https://doi.org/10.1145/1656274.1656278>
- [13] Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning*. Springer New York USA HuberW, 18, 764. <https://doi.org/10.1007/978-0-387-84858-7>
- [14] Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>
- [15] K., A., & Deka, P. C. (2015). Forecasting of Significant Wave Height Using Support Vector Regression. *2015 Fifth International Conference on Advances in Computing and Communications (ICACC)*, 50–53. <https://doi.org/10.1109/ICACC.2015.109>
- [16] Kavaklioglu, K. (2011). Modeling

- and prediction of Turkey's electricity consumption using Support Vector Regression. *Applied Energy*, 88(1), 368–375.
<https://doi.org/10.1016/j.apenergy.2010.07.021>
- [17] M. Bishop, C. (2006). *Pattern Recognition and Machine Learning*.
- [18] Maas, A. L., Hannun, A. Y., & Ng, A. Y. (2013). Rectifier Nonlinearities Improve Neural Network Acoustic Models. *Proceedings of the 30 Th International Conference on Machine Learning*, 28, 6. Retrieved from https://web.stanford.edu/~awni/papers/relu_hybrid_icml2013_final.pdf
- [19] Mahjoobi, J., & Adeli Mosabbeb, E. (2009). Prediction of significant wave height using regressive support vector machines. *Ocean Engineering*, 36(5), 339–347.
<https://doi.org/10.1016/j.oceaneng.2009.01.001>
- [20] Malekmohamadi, I., Bazargan-Lari, M. R., Kerachian, R., Nikoo, M. R., & Fallahnia, M. (2011). Evaluating the efficacy of SVMs, BNs, ANNs and ANFIS in wave height prediction. *Ocean Engineering*, 38(2–3), 487–497.
<https://doi.org/10.1016/j.oceaneng.2010.11.020>
- [21] Mandal, S., & Prabaharan, N. (2010). Ocean Wave Prediction Using Numerical and Neural Network Models. *The Open Ocean Engineering Journal*, 3, 12–17.
<https://doi.org/10.2174/1874835X01003010012>
- [22] Prahlada, R., & Deka, P. C. (2015). Forecasting of Time Series Significant Wave Height Using Wavelet Decomposed Neural Network. *Aquatic Procedia*, 4(Icwrcoe), 540–547.
<https://doi.org/10.1016/j.aqpro.2015.02.070>
- [23] Queensland Government. (2017). *Coastal Data System - Waves Data* (Brisbane). Retrieved May 16, 2017, from <https://data.qld.gov.au/dataset/coastal-data-system-waves-brisbane/resource/dc366f6a-957c-4d47-b582-05768f3c02b9>
- [24] Rizianiza, I. (2015). Prediction of Significant Wave Height in The Java Sea Using Artificial Neural Network, 5–10.
- [25] Shevade, S. K., Keerthi, S. S., Bhattacharyya, C., & Murthy, K. R. K. (2000). Improvements to the SMO algorithm for SVM regression. *IEEE Transactions on Neural Networks*, 11(5), 1188–1193.
<https://doi.org/10.1109/72.870050>
- [26] Taylor, R. E. (1985). Dynamics of offshore structures. *Engineering Structures* (Vol. 7).
[https://doi.org/10.1016/0141-0296\(85\)90054-9](https://doi.org/10.1016/0141-0296(85)90054-9)
- [27] Thornton, E. B., & Guza, R. T. (1983). Transformation of wave height distribution. *Journal of Geophysical Research*, 88(C10), 5925.
<https://doi.org/10.1029/JC088iC10p05925>
- [28] Wang, G., Chen, S., Liu, J., & Wu, T. (2015). A Short-Term Prediction Model Based on Support Vector Regression Optimized by Artificial Fish-Swarm Algorithm, 8(7), 237–250.
- [29] Weiße, A., Wellein, G., Alvermann, A., & Fehske, H. (2006). The kernel polynomial method. *Reviews of Modern Physics*, 78(1), 275–306.
<https://doi.org/10.1103/RevModPhys.78.275>
- [30] Yin, J. C., Zou, Z. J., & Xu, F. (2013). Sequential learning radial basis function network for real-time tidal level predictions. *Ocean Engineering*, 57, 49–55.
<https://doi.org/10.1016/j.oceaneng.2012.08.012>