

Klasifikasi Ketinggian Gelombang Laut Perairan Masalembu Berdasarkan Hasil Prediksi Parameter Meteorologi Maritim Menggunakan Metode *Backpropagation*

Nugroho Wahyu W¹, Dian C. Rini N², Ady Hermanto³

¹UIN Sunan Ampel Surabaya, *nugrohow7@gmail.com*

²UIN Sunan Ampel Surabaya, *diancrini@uinsby.ac.id*

³BMKG Perak II, *geomaritim@bmg.go.id*

Abstrak: Indonesia merupakan Negara maritim dengan kata lain banyak aktivitas sehari-hari dan perekonomian masyarakatnya bergantung di bidang perairan. Untuk menunjang kelancaran pada seluruh aktivitas pada bidang tersebut dibutuhkan peramalan cuaca, terutama ketinggian gelombang. Salah satu contoh kepulauan yang mengandalkan ramalan ketinggian gelombang adalah pulau Masalembu, dikarenakan pulau ini dikelilingi dengan perairan yang mengakibatkan hampir seluruh kegiatan sehari-hari dan perekonomian dilakukan di perairan. Oleh karena hal itu penelitian ini dilakukan untuk mengklasifikasikan ketinggian gelombang di perairan Masalembu apakah termasuk kelas bahaya atau tidak. Penelitian ini menggunakan metode *Backpropagation* untuk memprediksi parameter meteorologi seperti ketinggian gelombang, kecepatan angin dan kecepatan arus. Hasil dari prediksi parameter mendapatkan MAPE 1.4743 dengan arsitektur jaringan terbaik dari *learning rate* 0.3, kemudian hasil ini digunakan untuk proses klasifikasi dengan perhitungan akurasi menggunakan *confusion matrix*. Penelitian ini mendapatkan hasil akurasi sebesar 99.03 %.

Kata kunci: *Klasifikasi, Prediksi, Backpropagation, MAPE, Confusion Matrix.*

Abstract: *Indonesia is a maritime country in other words a lot of daily activities and people's economy depends on competition. To support the smoothness of all activities in the field required weather forecasting, especially for waves. One example of an archipelago that relies on wave height forecasts is the island of Masalembu, which is related to the island which discusses all daily activities and repairs carried out in the waters. Therefore this study was conducted to classify wave heights on Masalembu ships including hazard classes or not. This study uses the Backpropagation method to predict meteorological parameters such as wave height, wind speed and current speed. The results of the parameter prediction get MAPE 1.4743 with the best network architecture from the learning level of 0.3, then these results are used for the classification process with calculations using the confusion matrix. This study obtained results reaching 99.03%.*

Keywords: *Classification, Prediction, Backpropagation, MAPE, Confusion Matrix.*

1. Pendahuluan

Indonesia merupakan sebuah Negara maritim sehingga sebagian aktivitas sehari-hari dilakukan di bidang perairan [1]. Banyak faktor yang harus diperhatikan untuk menunjang kelancaran seluruh aktivitas tersebut. Salah satunya adalah ketinggian gelombang [2]. Gelombang yang terlalu tinggi dapat membahayakan pelayaran karena pelayaran membutuhkan waktu lebih lama di perairan dibandingkan di darat ataupun udara. Gelombang tinggi juga dapat menunda keberangkatan kapal [3]. Hal ini mampu menghambat aktivitas di perairan yang akan berdampak pada perekonomian. Oleh karena itu, masyarakat memerlukan prediksi tinggi gelombang yang akan terjadi di tengah laut [4].

Prediksi tinggi gelombang laut dapat dilakukan berdasarkan data tinggi gelombang laut itu sendiri, dan beberapa parameter maritim lainnya seperti ketinggian gelombang, kecepatan angin dan arus gelombang [5]. Prediksi dilakukan menggunakan data masa lalu untuk mendapatkan informasi di masa depan. Beberapa prediksi dalam kemaritiman pernah dilakukan sebelumnya diantara prediksi cuaca maritim di Laut Jawa menggunakan *hybrid method*, prediksi kecepatan arus laut [6] dan prediksi kecepatan angin. Sebagian besar prediksi dilakukan dengan bantuan kecerdasan buatan. Backpropagation merupakan salah satu metode yang digunakan untuk membangun sistem kecerdasan [7]. *Backpropagation* bagus digunakan untuk prediksi/peramalan. Algoritma ini bekerja berdasarkan pola data masa lalu dan juga melatih jaringan untuk mendapatkan keseimbangan antara kemampuan jaringan untuk mengenali pola yang digunakan selama pelatihan [5]. Data yang digunakan adalah data *time series* dari masing-masing parameter. Data tersebut diprediksi yang kemudian akan digunakan sebagai penentu dalam peramalan ketinggian gelombang.

Penelitian untuk prediksi ketinggian gelombang laut sudah pernah dilakukan sebelumnya. Diantaranya ialah prediksi ketinggian gelombang laut yang dilakukan oleh Megawati [8], prediksi ini dilakukan berdasarkan kecepatan angin menggunakan model fungsi transfer dan memperoleh hasil MAPE sebesar 18,7 %. Made dan Astra melakukan penelitiannya menggunakan arsitektur JST menunjukkan hasil yang lebih baik yaitu dengan perolehan rata-rata presentase kesalahan sebesar 1,97 %.

Berdasarkan dari beberapa penelitian sebelumnya, maka prediksi ketinggian gelombang laut dilakukan menggunakan perpaduan *time series* dengan metode *backpropagation* untuk prediksi parameter ketinggian gelombang yang kemudian dilakukan klasifikasi ketinggian gelombang laut dengan harapan dapat menghasilkan model jaringan arsitektur dan hasil peramalan yang baik. Sehingga dalam meminimalisir bahaya yang mungkin terjadi.

2. Tinjauan Pustaka

2.1 *Backpropagation*

Backpropagation merupakan salah satu algoritma pembelajaran dalam jaringan saraf tiruan yang paling umum digunakan. Metode ini melatih jaringan untuk mendapatkan keseimbangan antara kemampuan jaringan dalam mengenali pola selama proses pelatihan serta memberikan respon yang benar terhadap pola masukan yang serupa namun tidak sama dengan pola yang dipakai selama pelatihan. Algoritma yang digunakan dalam backpropagation yaitu pembelajaran terawasi dan banyak lapisan pada perceptron (Rufiyanti, 2015).

Backpropagation melakukan proses pembelajaran dengan penyesuaian bobot-bobot dari arsitektur jaringan saraf tiruan dengan arah mundur berdasarkan pada nilai

error. *Backpropagation* bekerja melalui proses iteratif dengan menggunakan sekumpulan data latih (*data training*) lalu membandingkan nilai prediksi dari jaringan yang telah dibangun dengan nilai sesungguhnya [9]. Algoritma pelatihan jaringan *backpropagation* meliputi [10]:

- a. Inisialisasi nilai bobot
 Pada langkah ini, nilai bobot pada setiap lapisan diinisialisasikan dalam sembarang nilai yang kecil.
- b. Propagasi maju
 Pada propagasi maju, sinyal masukan (x_i) dipropagasikan ke layar tersembunyi dengan menggunakan sebuah fungsi aktivasi yang telah ditentukan. Rumus untuk mencari keluaran unit tersembunyi pada hidden layer z_j ($j = 1, 2, \dots, p$) ditunjukkan pada Persamaan (1) dan (2).

$$z_{net\ j} = v_{j0} + \sum_{i=1}^n x_i v_{ji} \quad (1)$$

$$z_j = f(z_{net\ j}) \quad (2)$$

dimana:

- v_{j0} : bobot bias dari *input layer* ke *hidden layer* ($j = 1, 2, \dots, p$)
- x_i : unit masukan ke- i , ($i = 1, 2, 3, \dots, n$)
- v_{ji} : bobot unit masukan pada *input layer* ke *hidden layer*
- z_j : unit keluaran ke- j pada *hidden layer*
- $f(z_{net\ j})$: fungsi aktivasi

Hitung semua unit keluaran di *output layer* y_k ($k = 1, 2, \dots, m$) dengan menggunakan rumus Persamaan (3) dan (4).

$$y_{net\ k} = W_{k0} + \sum_{j=1}^p z_j W_{kj} \quad (3)$$

$$y_k = f(y_{net\ k}) \quad (4)$$

dimana:

- W_{k0} : bobot bias dari *hidden layer* ke *output layer*
- z_j : unit keluaran ke- j pada *hidden layer* ($j = 1, 2, \dots, p$)
- W_{kj} : bobot unit masukan pada *input layer* ke *hidden layer*
- y_k : unit keluaran pada *hidden layer*
- $f(y_{net\ k})$: fungsi aktivasi

Selanjutnya keluaran tersebut dibandingkan dengan target yang harus dicapai (t_k). Selisih $t_k - y_k$ merupakan nilai kesalahan yang terjadi (*error*). Jika nilai nilai *error* lebih kecil dari batas toleransi yang telah ditentukan, maka iterasi akan dihentikan. Namun jika nilai *error* yang didapatkan masih lebih besar dari batas toleransi, maka bobot pada setiap penghubung akan dimodifikasi untuk mengurangi *error* yang terjadi (Rufiyanti, 2015).

- c. Propagasi mundur
 Berdasarkan pada nilai *error* $t_k - y_k$, dihitung faktor δ_k ($k = 1, 2, \dots, m$) yang digunakan untuk mendistribusikan kesalahan di unit y_k ke semua unit tersembunyi yang terhubung langsung dengan y_k menggunakan Persamaan (5).

$$\delta_k = (t_k - y_k)y_k(1 - y_k) \quad (5)$$

dimana:

δ_k : unit kesalahan ke-k
 t_k : target ke-k
 y_k : unit keluaran ke-k

Hitung suku perubahan bobot W_{kj} (yang akan digunakan untuk merubah bobot W_{kj}) dengan laju pembelajaran α menggunakan rumus Persamaan (6).

$$\Delta W_{kj} = \alpha \delta_k z_j ; k = 1, 2, \dots, m ; j = 0, 1, \dots, p \quad (6)$$

dimana:

ΔW_{kj} : suku perubahan bobot W_{kj}
 α : laju pembelajaran
 δ_k : unit kesalahan ke-k
 z_j : unit keluaran ke-j pada *hidden layer* ($j = 1, 2, \dots, p$)

Hitung faktor δ unit tersembunyi berdasarkan pada nilai error di setiap unit tersembunyi z_j ($j = 1, 2, \dots, p$) dengan menggunakan rumus Persamaan (7).

$$\delta_{net_j} = \sum_{k=1}^m \delta_k W_{kj} \quad (7)$$

Faktor δ unit tersembunyi dapat dicari dengan menggunakan rumus Persamaan (8).

$$\delta_j = \delta_{net_j} f'(z_{net_j}) = \delta_{net_j} z_j (1 - z_j) \quad (8)$$

Hitung suku perubahan bobot v_{ij} (yang akan digunakan untuk merubah bobot v_{ij}) dengan laju pembelajaran α dengan menggunakan Persamaan (9).

$$\Delta v_{ji} = \alpha \delta_j x_i ; j = 1, 2, \dots, p ; i = 0, 1, \dots, n \quad (9)$$

d. Perubahan bobot

Setelah semua faktor δ dihitung, bobot semua garis dimodifikasi bersamaan. Perubahan nilai bobot yang menuju ke unit keluaran dapat dihitung menggunakan rumus Persamaan (10).

$$W_{kj}(\text{baru}) = W_{kj}(\text{lama}) + \Delta W_{kj} \quad (k = 1, 2, \dots, m ; j = 0, 1, \dots, p) \quad (10)$$

Perubahan bobot yang menuju ke unit tersembunyi dapat menggunakan Persamaan (11).

$$v_{ji}(\text{baru}) = v_{ji}(\text{lama}) + \Delta v_{ji} \quad (j = 1, 2, \dots, p ; i = 0, 1, \dots, n) \quad (11)$$

Setelah tahap pelatihan selesai, tahap selanjutnya yaitu tahap pengujian jaringan. Pada tahap ini, langkah yang dilakukan hanya sampai pada fase I yaitu propagasi maju. Seluruh bobot masukan diambil dari nilai bobot terakhir dari tahap pelatihan. Pada tahap pengujian, jaringan diharapkan dapat mengenali pola berdasarkan data baru yang diberikan [11].

2.2 Backpropagation dalam Peramalan

Backpropagation sering digunakan untuk peramalan. Secara umum, masalah peramalan dapat dinyatakan sebagai (Rufiyanti, 2015):

- a. Telah diketahui data pada waktu sebelumnya atau biasa digunakan data runtun waktu (*time series*) x_1, x_2, \dots, x_n . Masalahnya yaitu memperkirakan berapa nilai x_{n+1} berdasarkan x_1, x_2, \dots, x_n .
- b. Rekaman data lampau digunakan sebagai data pelatihan untuk mencari bobot yang optimal. Periode ini ditentukan secara intuitif, misalnya seperti data debit air sungai dengan data bulanan, periode data dapat diambil selama satu tahun karena pergantian musim terjadi selama satu tahun.
- c. Jumlah data dalam satu periode akan digunakan sebagai jumlah masukan dalam backpropagation dengan tergetnya data bulan pertama setelah periode berakhir. Pada data bulanan dengan periode satu tahun, maka masukan backpropagation yang dapat digunakan yaitu terdiri dari 12 unit masukan dan 1 unit keluaran.
- d. Dalam backpropagation untuk peramalan, bagian tersulit adalah menentukan jumlah lapisan dan unitnya. Tidak ada teori yang dapat digunakan dengan pasti. Tetapi secara praktis dapat dicoba pada jaringan kecil terlebih dahulu (misalnya terdiri dari satu layar tersembunyi dengan beberapa unit didalamnya). Jika jaringan ini gagal (kesalahan tidak turun dalam epoch yang besar), maka jaringan dapat diperbesar dengan menambah unit atau lapisan tersembunyi.

2.3 Mean Absolute Percentage Error (MAPE)

Mean Absolutely Percentage Error (MAPE) merupakan suatu metode untuk menghitung nilai akurasi yang disajikan dalam bentuk persentase. Perhitungan akurasi dengan MAPE sering digunakan karena mudah dalam hal pembacaan hasil yang dalam bentuk persentase. Rumus Persamaan (13) merupakan rumus yang digunakan untuk menghitung nilai MAPE [8].

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100 \quad (13)$$

dimana,

n = banyaknya data

A_t = nilai asli data ke-t

F_t = nilai forecast data ke-t

Semakin kecil nilai MAPE yang dapat dikatakan model peramalan tersebut memiliki kemungkinan yang baik. Tabel 1 berisi keterangan tingkat signifikansi hasil MAPE (Hutasuhut, Anggraeni, & Tyasnurita, 2014)

Tabel 1. Keterangan Akurasi MAPE

MAPE	Signifikansi
<10%	Kemampuan peramalan sangat baik
10-20%	Kemampuan peramalan baik
20-50%	Kemampuan peramalan cukup
>50%	Kemampuan peramalan buruk

Sumber: (Ilmiah, 2018)

2.5 Confusion Matrix

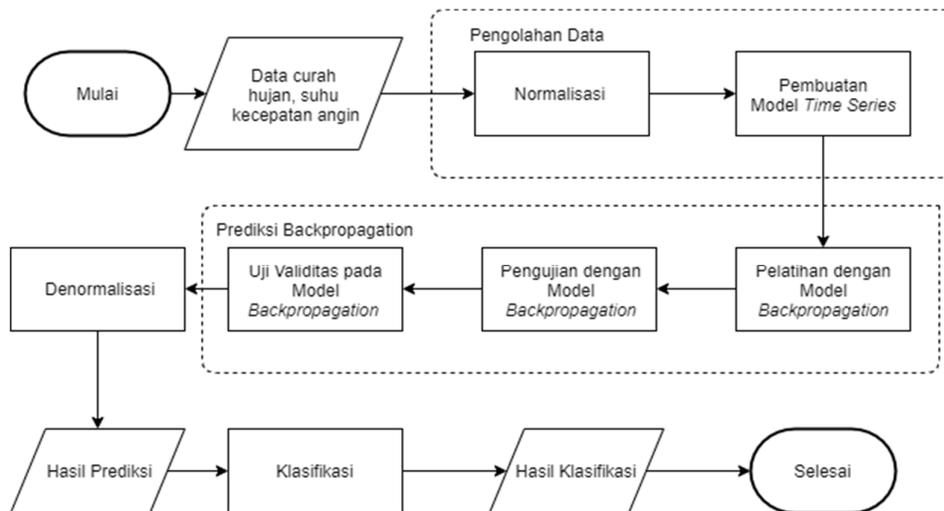
Confusion matrix merupakan suatu metode yang biasa digunakan untuk melakukan perhitungan akurasi pada konsep data mining. Evaluasi dengan *confusion matrix* menghasilkan nilai akurasi, presisi dan *recall*. Akurasi dalam klasifikasi adalah presentase ketepatan *record* data yang diklasifikasikan secara benar setelah dilakukan pengujian pada hasil klasifikasi. Presisi ialah proporsi kasus yang diprediksi positif dengan hasil positif pula pada data sebenarnya. *Recall* merupakan proporsi kasus positif yang sebenarnya diprediksi dengan benar [12].

Tabel 2. Model *Confusion Matrix*

<i>Correct Classification</i>	<i>Classified as</i>	
	+	-
+	<i>True Positive (A)</i>	<i>False Positive (B)</i>
-	<i>False Positive (C)</i>	<i>True Positive (D)</i>

3. Metode Penelitian

Penelitian ini merupakan penelitian kuantitatif. Jenis penelitian kuantitatif yang dimaksud karena penggunaan data kuantitatif yang berupa numerik atau angka. Data yang digunakan merupakan tinggi gelombang, kecepatan angin dan arus gelombang. Seluruh data tersebut diambil dari tanggal 01 Januari - 31 Mei 2019. Data yang digunakan merupakan data yang diambil setiap satu jam sekali. Pada penelitian ini data yang digunakan dibagi menjadi dua, yaitu data *training* dan *testing*. Pembagian data *training* sebesar 80% dari total data dengan sebaran data 1 Januari – 30 April 2019, sedangkan data *testing* sebanyak 20% dari total data dengan rincian data 1 Mei – 31 Mei 2019. Tahapan pada penelitian ini termuat dalam Gambar 1.



Gambar 1. Flowchart

Gambar 1 merupakan langkah yang dilakukan peneliti dalam melakukan penelitian ini. Pada penelitian ini dilakukan normalisasi dan denormalisasi data yang berfungsi untuk memudahkan perhitungan dengan mengubah data asli menjadi data yang

memiliki nilai antara 0 sampai 1. Setelah mendapatkan nilai normalisasi dibuat model *time series* untuk dijadikan model pelatihan pada *backpropagation*, hasil prediksi yang diperoleh dilakukan proses denormalisasi, kemudian hasil tersebut diklasifikasikan, lalu hasil klasifikasi tersebut dihitung akurasinya dengan model *confusion matrix*.

4. Hasil dan Pembahasan

Tahapan pertama pada ini ialah prediksi parameter meteorologi. Dalam pengoptimalan hasil prediksi dengan *Backpropagation* ini menggunakan 3 *input*, 1 *output*, nilai *learning rate* mulai dari 0.1 sampai dengan 0.5, serta satu *hidden layer* dengan jumlah *node hidden layer* sebanyak 14 dan 20 untuk training, serta membagi data *training* 80% dan 20% untuk data *testing*. Berdasarkan hasil perhitungan yang telah dilakukan didapat nilai MAPE terkecil pada setiap masing-masing tahapan *training* yang dapat dilihat pada Tabel 3.

Tabel 3. Hasil *Training* Prediksi Parameter

Parameter	Nodes	Learning Rate	MSE (10^{-5})		MAPE	
			Training	Testing	Training	Testing
Kecepatan angin	14	0.1	1.916		2.2396	
		0.2	1.158		1.4743	
		0.3	1.5373		1.9887	
		0.4	1.3639		2.300	
		0.5	1.0095		2.1229	
	20	0.1	1.5729		1.7338	
		0.2	1.5754		1.7756	
		0.3	1.7983		1.9250	
		0.4	1.7611		1.7223	
		0.5	1.5729		1.7803	
Tinggi Gelombang	14	0.1	4.9064		2.0265	
		0.2	6.6271		2.2545	
		0.3	8.1143		2.1758	
		0.4	4.4949		1.9638	
		0.5	6.8667		2.2241	
	20	0.1	7.9618		2.5440	
		0.2	5.3447		2.4178	
		0.3	6.1069		2.3525	
		0.4	6.1069		1.8706	
		0.5	5.8499		2.1984	
Arus Gelombang	14	0.1	8.0998		1.1447	
		0.2	4.4908		1.8764	
		0.3	1.1252		1.1084	
		0.4	6.2547		1.3223	
		0.5	5.2425		1.7124	
	20	0.1	8.2831		1.4410	
		0.2	6.1572		1.8163	
		0.3	8.9456		9.1104	
		0.4	7.4824		1.4035	
		0.5	8.2037		1.7065	

Seperti yang dapat dilihat pada Tabel 3 bahwa untuk seluruh parameter mendapatkan arsitektur jaringan terbaik pada jumlah *nodes* 14 dengan nilai *learning rate* berbeda-beda, untuk kecepatan angin dengan *learning rate* 0,2, tinggi gelombang dengan nilai 0,4, sedangkan arus gelombang pada nilai 0,3. Lakukan proses *testing* menggunakan 20 % data menggunakan arsitektur jaringan terbaik masing-masing parameter yang didapat. Hasil *testing* yang diperoleh dilakukan proses *training* klasifikasi dengan percobaan *learning rate* 0,1 – 0,5 dengan hasil yang didapat seperti pada Tabel 4.

Tabel 4. Hasil *Training* Klasifikasi Ketinggian Gelombang

<i>Nodes</i>	<i>Learning Rate</i>	MSE	MAPE
		<i>Training</i>	<i>Training</i>
3	0.1	7.6138	2.2396
	0.2	1.0844	1.4743
	0.3	6.5365	1.9887
	0.4	8.2214	2.300
	0.5	3.6141	2.1229

Pada Tabel 4 ini diperoleh hasil *training* arsitektur terbaik untuk klasifikasi ketinggian gelombang dari nilai *input* masing-masing parameter yang didapat pada proses prediksi sebelumnya. Pada percobaan *training* ini didapatkan arsitektur terbaik menggunakan 3 jumlah *nodes* dan nilai *learning rate* sebesar 0,2. Kemudian dilakukan proses *testing*, dari hasil *testing* dilakukan proses perhitungan akurasi dengan membandingkan nilai *target* yang diperoleh dari *confusion matrix*. Hasil akurasi yang diperoleh pada penelitian ini sebesar 99.03% ditunjukkan pada Tabel 5.

Tabel 5. Hasil Akurasi Klasifikasi dengan *Confusion Matrix*

Akurasi = 99.03%	<i>True 0</i>	<i>True 1</i>	<i>Class Precision</i>
Prediksi 0	653	3	99.39%
Prediksi 1	4	62	95.38%
<i>Class Recall</i>	91.32%	42.85%	

Pada Tabel 5, prediksi 0 merupakan klasifikasi dengan label ketinggian gelombang normal, untuk prediksi 1 bermakna bahwa klasifikasi dengan label ketinggian gelombang tinggi. Pada hasil klasifikasi menggunakan *backpropagation* didapat bahwa hasil label gelombang tinggi normal memiliki nilai benar sebanyak 653 sesuai data *target* dan sebaliknya bernilai salah sebanyak 3 tidak sesuai dengan data *target*. Sedangkan pada hasil klasifikasi pada label gelombang laut tinggi, bernilai benar sesuai *target* sebanyak 62, dan bernilai salah sebanyak 3 tidak sesuai dengan *target*.

5. Kesimpulan

Berdasarkan hasil penelitian mengenai klasifikasi ketinggian gelombang laut di perairan Masalembu dari hasil prediksi parameter meteorologi dengan menggunakan metode *Backpropagation* dapat disimpulkan, bahwa klasifikasi ketinggian gelombang menggunakan metode ini mendapatkan hasil arsitektur jaringan yang paling optimal pada terletak pada *learning rate* 0.2 dengan MAPE sebesar 1.47 dan hasil akurasi klasifikasi *confusion matrix* sebesar 99,03 %, hal ini menyatakan bahwa kemampuan peramalan pada prediksi parameter meteorologi maritim untuk proses klasifikasi sangat baik karena nilai error kurang dari 10%.

Daftar Pustaka

- [1] S. Kharisma and L. Widomurti, “Analisis Hujan Lebat dengan Menggunakan Data Citra Satelit di Kabupaten Banjarnegara,” *Mater. dan Energi Indones.*, vol. 08, no. 01, pp. 29–35, 2018.
- [2] E. Firdianty, M. Bettiza, and N. Ritha, “Implementasi Adaptive Neuro Fuzzy Inference System (ANFIS) untuk Prediksi Ketinggian Gelombang Laut,” pp. 1–7, 2016.
- [3] P. Wellyantama, “Prediksi Ketinggian Gelombang Laut Perairan Laut Jawa Bagian Barat Sebelah Utara Jakarta dengan Metode Jaringan Syaraf Tiruan Propagasi Balik,” *Positron*, vol. V, no. 2301–4970, pp. 30–35, 2015.
- [4] L. Handayani and M. Adri, “Penerapan JST (Backpropagation) untuk Prediksi Curah Hujan (Studi Kasus : Kota Pekanbaru),” *Semin. Nas. Teknol. Informasi, Komun. dan Ind.*, no. November, pp. 238–247, 2015.
- [5] L. Handayani and M. Adri, “Penerapan JST (Backpropagation) untuk Prediksi Curah Hujan (Studi Kasus : Kota Pekanbaru),” *Semin. Nas. Teknol. Informasi, Komun. dan Ind.* 7, no. November, pp. 238–247, 2015.
- [6] D. D. Kartika, D. C. Rini, and F. Setiawan, “Prediksi Kecepatan Arus Laut di Perairan Selat Bali Menggunakan Metode Exponential Smoothing Holt-Winters,” *J. Mat.*, vol. 2, no. 1, 2020.
- [7] D. C. Rini, F. Febrianti, and F. Setiawan, “Analisis Kecepatan Angin pada Pasang Surut Air Laut dengan Menggunakan Algoritma Forward-Backward dalam Hidden Markov Model di Wilayah Pelabuhan Tanjung Perak Surabaya,” *J. Has. Penelit. Mat. Stat. dan Apl.*, vol. 4, no. 1, 2018.
- [8] F. Megawati, “Peramalan Tinggi Gelombang Berdasarkan Kecepatan Angin di Perairan Pesisir Semarang Menggunakan Model Fungsi Transfer,” 2015.
- [9] C. Oktaviani and Afdal, “Prediksi Curah Hujan Bulanan Menggunakan Jaringan Syaraf Tiruan dengan Beberapa Fungsi Pelatihan (Studi Kasus : Stasiun Meteorologi Tabing Padang , Tahun 2001-2012),” *Fis. Unand*, vol. 2, no. 4, pp. 228–237, 2013.
- [10] L. Wati, N. Nikentari, and N. Ritha, “Prediksi Ketinggian Gelombang Laut PerairanPulau Bintan Menggunakan Gramatical Evolution,” 2015.
- [11] M. A. Raharja and I. M. T. G. Astra, “Prediksi Ketinggian Gelombang Laut Menggunakan Metode Backpropagation pada Pantai Lebih Gianyar,” *Ilmu Komput.*, vol. XI, no. 1979–5661, pp. 19–26, 2018.
- [12] D. Adaptive, G. Bpgdag, and N. Chamidah, “Pengaruh Normalisasi Data pada Jaringan Syaraf Tiruan Backpropagasi Gradient Descent Adaptive Gain (BPGDAG) untuk Klasifikasi,” *ITSMART*, vol. 1, no. 1, 2012.