

PENGEMBANGAN MODEL ENSEMBEL GELOMBANG LAUT MRI-III DAN WINDWAVE-05 MENGUNAKAN KECERDASAN BUATAN

*THE ENSEMBLE OF WAVE MODEL MRI-III AND WINDWAVE-05
USING ARTIFICIAL INTELLIGENCE*

Asteria S. Handayani*, Hastuadi Harsa, Roni Kurniawan, Wido Hanggoro, Sri Noviati
Pusat Penelitian dan Pengembangan BMKG, Jl. Angkasa I No. 2, Kemayoran, Jakarta Pusat
*E-mail: tya.lazuardi@gmail.com

Naskah masuk: 30 Agustus 2016; Naskah diperbaiki: 10 November 2017; Naskah diterima: 22 Desember 2017

ABSTRAK

Kondisi gelombang laut dimodelkan oleh MRI-III dan Windwaves-05. Penelitian ini mengembangkan model ensemble untuk menggabungkan output dua model tersebut. Proses ensemble dilakukan oleh jaringan syaraf tiruan menggunakan metode pembelajaran resilient propagation. Parameter input ensemble adalah ketinggian maksimum dan ketinggian signifikan gelombang yang dihasilkan oleh kedua model, sedangkan parameter output ensemble adalah ketinggian maksimum dan ketinggian signifikan gelombang. Target untuk melatih jaringan syaraf tiruan adalah data yang diperoleh dari perekaman data lapangan di dua lokasi: Sawarna dan Bengkulu. Hasil yang diperoleh menunjukkan bahwa model ensemble ini mampu memberikan output yang lebih mendekati nilai perekaman data langsung di lapangan dibanding output kedua model input secara individu.

Kata kunci: ensemble, gelombang laut, MRI-III, Windwaves-05, *resilient propagation*

ABSTRACT

MRI-III and Windwaves-05 produce ocean wave height model. This research developed an ensemble model combining the outputs of those models. The ensemble process was performed by utilizing artificial neural network with resilient propagation learning algorithm. The inputs of ensemble model were the maximum height and significant height produced by MRI-III and Windwaves and the outputs were also the maximum height and significant height. The target values as the guidance in the learning phase of neural network were the observation data obtained from two locations: Sawarna and Bengkulu. The results show that the ensemble model was able to deliver outputs nearer to the observation data than that of the two input models.

Keywords: wave, ensemble, MRI-III, Windwaves-05, resilient propagation

1. Pendahuluan

Gelombang akibat angin merupakan gelombang yang paling dominan terjadi di permukaan laut apabila dibandingkan dengan jenis gelombang lainnya, baik ditinjau dari frekuensi kejadian maupun energinya. Keberadaan gelombang akibat angin di permukaan laut mempengaruhi hampir semua kegiatan di laut. Oleh karena itu, informasi tentang gelombang merupakan bagian terpenting dalam pelayanan informasi meteorologi kelautan.

Berdasarkan peraturan WMO No. 702, data untuk keperluan analisa klimatologi gelombang dapat diperoleh melalui dua sumber utama, yaitu (a) hasil

pengukuran dan observasi, serta (b) hasil estimasi berdasar data angin (wave hindcast). Data hasil pengukuran dan observasi di lautan umumnya sangat terbatas dan tidak kontinyu. Oleh karena itu keberadaan model gelombang sangat diperlukan untuk mengisi ketiadaan data observasi, baik secara spasial maupun temporal.

Mengingat bahwa setiap model memiliki karakteristik tertentu, maka apabila terdapat lebih dari satu model untuk menggambarkan suatu fenomena, akan terdapat pula banyak alternatif output yang dapat digunakan. Pada banyak alternatif output itu, dapat dilakukan suatu proses untuk mendapatkan sebuah gambaran umum yang

diharapkan dapat mewakili output model-model yang telah tersedia. Proses tersebut dikenal dengan istilah ensemble.

Output model ensemble seringkali memiliki akurasi yang lebih baik daripada output model secara individu [1][2]. Berdasar hal tersebut maka penelitian ini mengembangkan model ensemble ketinggian gelombang laut dari output dua model gelombang laut yang telah ada. Dua model gelombang laut tersebut adalah MRI-III dan Windwaves-05 (selanjutnya disebut MRI dan WW). Tujuan pengembangan model ensemble ini adalah menyediakan sebuah model gelombang baru yang memiliki akurasi lebih baik daripada MRI dan WW. Model gelombang baru tersebut menggunakan output MRI dan WW sebagai inputnya. Inti dari model ensemble yang dikembangkan ini adalah menghitung bobot dan koreksi bias yang perlu diberikan kepada masing-masing output model input ensemble. Proses penghitungan bobot dan koreksi bias dikerjakan oleh jaringan syaraf tiruan (JST) terbimbing lapis banyak (supervised multi layer perceptron) dengan metode pembelajaran umpan balik error (resilient propagation/RPROP).

Di dalam proses pengembangan model ensemble ini, digunakan acuan data observasi dari dua lokasi sebagai target pembentukan output model. Data observasi didapat dari kegiatan perekaman ketinggian gelombang di lapangan menggunakan alat pengukur ketinggian gelombang AWAC 600KHZ (Acoustic Wave and Current Meter) dengan mode Standing Alone pada kedalaman 30 meter di dasar laut. Dua lokasi pengambilan data observasi adalah Bengkulu (perairan Barat Sumatra) dan Sawarna (perairan Selatan Jawa), ditunjukkan oleh gambar 1. Kegiatan perekaman data untuk lokasi Bengkulu berada di $3,83^{\circ}\text{LS}$ dan $102,16^{\circ}\text{BT}$ pada tanggal 3-27 Juni 2015, dan untuk lokasi Sawarna berada di 7°LS dan $106,30^{\circ}\text{BT}$ pada tanggal 10-19 April 2015. Proses ensemble dilakukan terhadap dua parameter output MRI dan WW, yaitu: ketinggian maksimum (maximum height / HMAX) dan ketinggian signifikan (significant height / HSIG). Ensemble output MRI dan WW untuk dua parameter tersebut dilakukan pada masing-masing lokasi survei.

Model Windwave-05. Windwaves-05 adalah model gelombang generasi II yang dikembangkan dari model gelombang MRI-II (Marine Research Institute) milik Jepang dan telah dioperasikan di BMKG sejak 2004. Hasil verifikasi Windwaves-05 dengan data kapal menunjukkan nilai korelasi di atas 0,6 [3]. Windwaves-05 adalah model *Limited Area*, sehingga tidak memperhitungkan kondisi di luar domain yang dimodelkan. Sedangkan untuk memperoleh data yang baik diperlukan domain yang lebih luas dalam

proses pemodelannya sebagai bahan pertimbangan kemungkinan adanya perambatan energi gelombang dari wilayah di luar kajian.

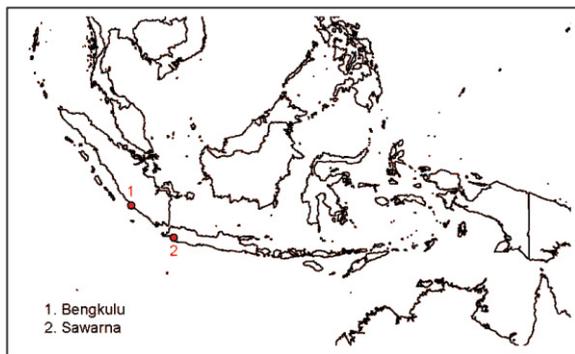
Model MRI-III. MRI-III adalah model gelombang generasi ke tiga yang dikembangkan oleh Meteorological Research Institute (MRI) – Japan Meteorological Agency (JMA) sebagai penyempurnaan dari model sebelumnya (MRI-II). Komponen di dalam output MRI-III di antaranya adalah spektrum frekuensi dan arah gelombang. Keduanya disajikan secara spatio-temporal.

Data model gelombang MRI-III dan Windwave-05 yang diolah dalam penelitian ini menggunakan data inisial GFS skala global dan regional pada bulan April dan Juni 2015 di kawasan Indonesia (90°BT - 141°BT , 12°LU - 15°LS). Data observasi gelombang diperoleh melalui survey di perairan Sawarna, Banten (10-19 April 2015) dan Bengkulu (3-27 Juni 2015) dengan meluncurkan *wave recorder* AWAC 600KHZ (*Acoustic Wave and Current Meter*) dengan mode *Standing Alone* pada kedalaman 30 km di bawah permukaan laut.

Ensemble. Proses ensemble terhadap beberapa model dapat dilakukan dengan berbagai cara. Salah satu cara yang sederhana adalah menghitung rata-rata output yang dihasilkan oleh seluruh model. Teknik ini telah digunakan oleh [4] dalam menghitung besar simpangan output model jalur siklon tropis.

Pada teknik ini, sebelum proses ensemble diterapkan pada output banyak model, diharapkan output model-model tersebut telah memiliki bias seminimal mungkin terhadap data target. Fungsi ensemble di sini adalah untuk mereduksi varian dan kemungkinan over fitting yang dimiliki oleh model input, sehingga didapatkan model yang mampu men-generalisir output yang dihasilkan oleh seluruh model yang digunakan.

Selain teknik tersebut, terdapat pula teknik ensemble lain yang umum digunakan [5]. Di dalam teknik ensemble ini terdapat proses reduksi bias dan varian dari output banyak model. Tujuan utama teknik ensemble ini adalah untuk menguatkan model anggota ensemble yang memiliki kemampuan lemah. Penggunaan teknik ensemble ke dua di bidang meteorologi dan oseanografi di antaranya dilakukan oleh [6] untuk mengembangkan model prediksi banjir, [7] untuk prediksi ketinggian gelombang pada informasi olahraga selancar.



Gambar 1. Lokasi survei

JST Resilient Propagation. Sesuai dengan namanya, JST adalah pemodelan cara kerja sel otak manusia. Sejak diperkenalkan pertama kali oleh [8] tahun 1943, JST telah menjadi bagian tak terpisahkan dari hampir seluruh ilmu pengetahuan yang ada. Salah satu sebab mengapa model ini mampu diterima secara luas adalah kemampuannya untuk meminimalisir perhitungan kompleks yang mungkin diperlukan untuk menyelesaikan beragam persoalan yang rumit tanpa harus mendalami bidang ilmu terkait. Oleh karena itu seringkali model ini disebut dengan black box. JST telah digunakan untuk meningkatkan performa model gelombang WW dengan menggunakan gabungan / asimilasi antara data observasi satelit dan output model itu sendiri sebagai target [9].

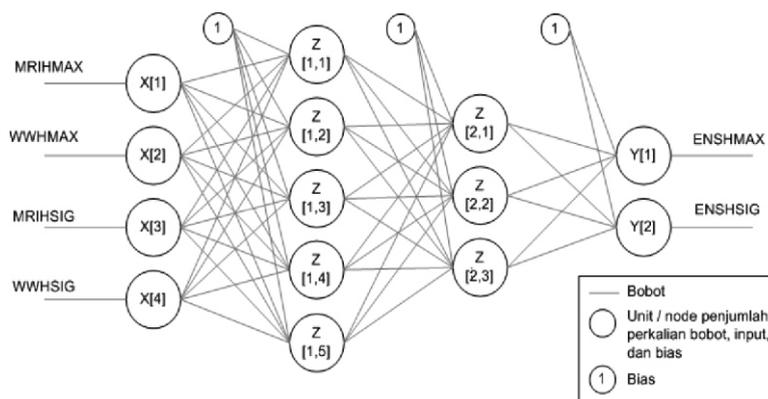
Secara umum JST digunakan untuk klasifikasi, clustering, dan prediksi. Dalam menyelesaikan permasalahan, JST melakukan pembelajaran pada data yang diberikan. JST memiliki jenis dan metode pembelajaran. Jenis pembelajaran JST di antaranya: terbimbing (supervised) dan tak terbimbing (unsupervised). Pada penelitian ini digunakan JST dengan jenis pembelajaran terbimbing.

Sampai saat ini, terdapat banyak metode pembelajaran JST. Metode pembelajaran yang digunakan di penelitian ini adalah RPROP, salah satu metode pembelajaran JST yang mengoptimalkan

metode pembelajaran JST sebelumnya: backpropagation (BP). Prinsip kerja dari BP adalah perbaruan sambungan (weight / bobot) antar sel (diistilahkan dengan node) secara mundur dari output ke input. Perbaruan bobot diberikan secara proporsional dengan kesalahan JST dalam menghasilkan output dibanding target yang seharusnya dihasilkan. Proses pembelajaran tersebut diulang hingga JST berada dalam kondisi konvergen atau batas maksimal iterasi pembelajaran terpenuhi.

Struktur JST yang dirancang untuk penelitian ini ditunjukkan pada gambar 2. Terdapat empat lapisan pada gambar tersebut, yaitu X, Z1, Z2, dan Y (X adalah lapisan input, Z lapisan tersembunyi, dan Y lapisan output). Setiap node adalah model sebuah sel. Tugas setiap node adalah menjumlahkan perkalian antara input-input yang diterimanya dengan bobot yang dilewati input tersebut. Pada awal JST bekerja, nilai bobot diinisialisasi dengan nilai acak. Hasil penjumlahan dari perkalian input dengan bobot kemudian dimasukkan ke dalam fungsi aktivasi. Nilai yang dihasilkan oleh output sebuah node tersebut kemudian menjadi input seluruh node di lapisan berikutnya. Setelah sampai pada lapisan output, JST membandingkan nilai-nilai di seluruh node output dengan masing-masing target yang harus dihasilkan oleh node-node tersebut. Selisih (error) antara nilai node-node output dengan masing-masing targetnya kemudian menjadi bahan koreksi seluruh bobot di dalam JST.

Pada metode BP, penggunaan error sebagai informasi untuk perbaruan bobot dilakukan secara mundur dari lapisan output menuju seluruh lapisan tersembunyi hingga ke lapisan input menggunakan metode gradient descent. Detail mengenai JST backpropagation telah dijelaskan secara teknis oleh [10]. Dengan menggunakan output MRI dan WW sebagai input JST dan data AWAC sebagai target, maka JST akan berfungsi sebagai ensemble boosting bagi kedua model gelombang tersebut.



Gambar 2. Susunan node JST untuk ensemble model

Terdapat beberapa metode yang telah dikembangkan untuk optimasi BP. Tujuan utama optimasi tersebut adalah pengurangan waktu komputasi yang diperlukan oleh JST dalam mempelajari data. Resilient propagation (RPROP) mengoptimasi BP pada proses perbaruan bobot. Bila pada BP perbaruan bobot memiliki kecepatan pembelajaran (learning rate) yang sama untuk seluruh bobot, maka pada RPROP masing-masing bobot memiliki besar kecepatan pembelajaran yang berbeda, bergantung pada tanda positif atau negatif turunan fungsi kesalahan JST terhadap perubahan bobot. Selain itu, terdapat aturan untuk menentukan bagaimana bobot berubah berdasar informasi kondisi bobot di iterasi sebelumnya. Detail mengenai RPROP dijelaskan oleh [11].

2. Metode Penelitian

Penyusunan Data. Terdapat banyak parameter gelombang yang direkam oleh AWAC. Dari parameter tersebut, HMAX dan HSIG dipilih sebagai parameter acuan dalam pengembangan model ensemble. Interval waktu antar perekaman data AWAC adalah per tiga jam. Parameter MRI dan WW yang dipilih sebagai input ensemble adalah HMAX dan HSIG. Parameter output yang akan dihasilkan ditentukan sama dengan parameter input. Kerangka waktu (time frame) data MRI dan WW disesuaikan dengan kerangka waktu perekaman data AWAC.

Dalam proses pembelajaran oleh JST, hubungan antara parameter HMAX dan HSIG untuk input dan target diatur sehingga menyerupai karakteristik analisa multivariat. Dengan kata lain, HMAX dan HSIG digunakan secara simultan sebagai input JST untuk mendapatkan HMAX dan HSIG sesuai target secara bersamaan dalam satu proses penghitungan. Ukuran fitur data input ensemble yang terbentuk sebanyak empat, yaitu MRIHMAX, MRIHSIG, WWHMAX, dan WWHSIG. Keempat data tersebut merupakan bahan pembelajaran (data latih) JST untuk mengatur bobot dan bias jaringan sesuai dengan target HMAX dan HSIG pada data yang diberikan oleh AWAC. Susunan ini berlaku untuk masing-masing lokasi Bengkulu dan Sawarna.

Parameterisasi JST. JST untuk ensemble dua model gelombang MRI dan WW dikembangkan pada kedua lokasi, dan di masing-masing lokasi dikembangkan model ensemble tanpa menggunakan time lag dan dengan menggunakan time lag pada inputnya. Struktur JST tanpa dan dengan time lag ditunjukkan pada gambar 2. Sedangkan nilai parameter internal JST ditunjukkan pada tabel 1.

Tabel 1. Setting Parameter JST

Parameter JST	Nilai
Jumlah hidden layer	2
Jumlah node hidden layer 1	5
Jumlah node hidden layer 2	3
Iterasi maksimum	100000
Konstanta pembelajaran	-5 s/d 12

Uji Verifikasi dan Validasi model. Untuk meninjau performa model, dilakukan uji verifikasi dan uji cross validation (CV) terhadap model ensemble. Uji verifikasi adalah menghitung tingkat kecocokan output model ensemble menggunakan input dari data yang digunakan selama proses pengembangan model. Sedangkan uji validasi adalah menghitung tingkat kecocokan output model ensemble menggunakan input dari data yang tidak digunakan selama proses pengembangan model. Uji validasi yang dilakukan menggunakan 10 fold. Setiap fold tersusun dari 80% sampel data untuk pelatihan dan 20% sampel data untuk pengujian. Pemilihan sampel untuk pelatihan dan pengujian pada setiap fold dilakukan secara acak dan tanpa pengembalian.

Penyimpanan Bobot JST. Kondisi akhir hasil perbaruan bobot JST disimpan agar dapat digunakan melakukan proses ensemble secara berkesinambungan bilamana MRI dan WW menghasilkan output baru. Selain itu, bobot JST yang terbentuk juga dapat digunakan sebagai inisialisasi pembelajaran JST apabila terdapat data latih baru.

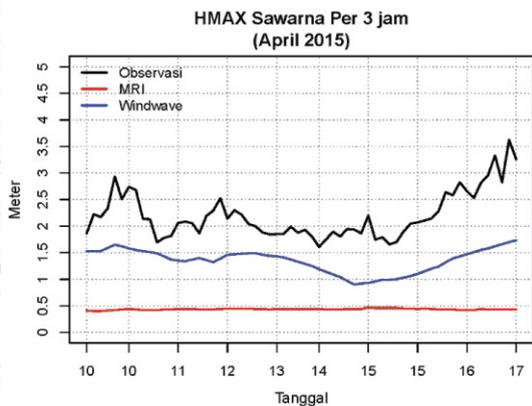
3. Hasil Dan Pembahasan

Kondisi Input dan Fungsi Alih. JST memiliki prasyarat bahwa nilai yang diproses, baik nilai input maupun nilai target, berada pada interval antara -1 sampai dengan 1. Bila nilai data tidak berada pada rentang tersebut, maka diperlukan suatu fungsi alih (*transfer function*) untuk mengubah nilai-nilai input ke dalam rentang tersebut. Fungsi alih yang digunakan untuk mengubah nilai input JST (MRI dan WW) ke rentang -1 sampai 1 adalah fungsi akumulasi kerapatan peluang (*cumulative distribution function*) data. Fungsi alih ini diperoleh dengan menghitung peluang kemunculan nilai pada seluruh data kemudian menjumlahkan nilai peluang tersebut secara akumulatif.

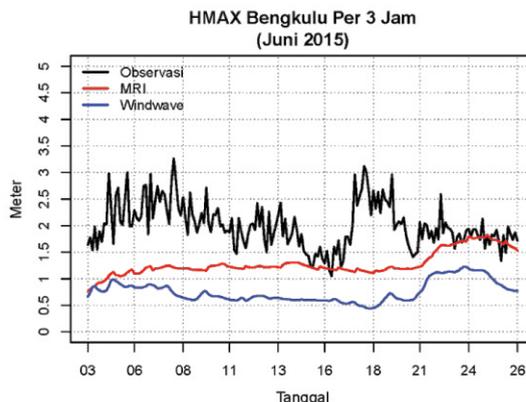
Dengan kondisi awal data seperti ditunjukkan pada gambar 3.a untuk parameter HMAX lokasi Sawarna dan gambar 3.b untuk lokasi Bengkulu, serta gambar 3.c untuk parameter HSIG untuk lokasi Sawarna dan 3.d untuk lokasi Bengkulu, maka fungsi alih untuk masing-masing lokasi ditunjukkan pada gambar 3.e

dan gambar 3.f. Nilai output JST juga berada pada rentang -1 sampai 1. Sehingga perlu dilakukan proses pembalikan (*inverse*) untuk mendapatkan nilai gelombang dari output JST. Proses *inverse* ini adalah

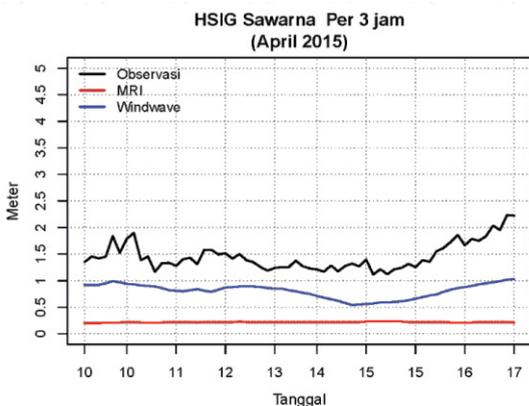
menentukan nilai tinggi gelombang dalam meter dari nilai output JST -1 sampai 1 berdasar fungsi transfer data observasi.



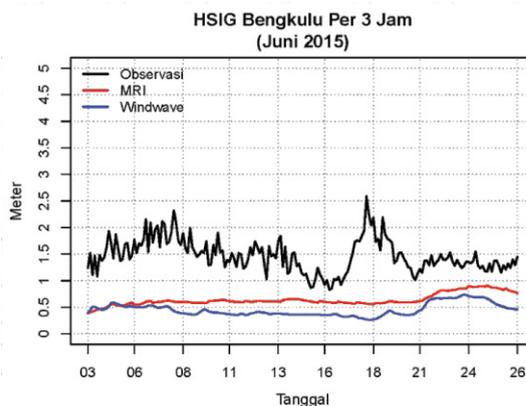
a



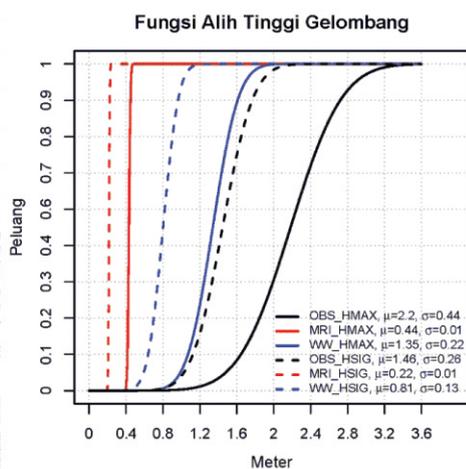
b



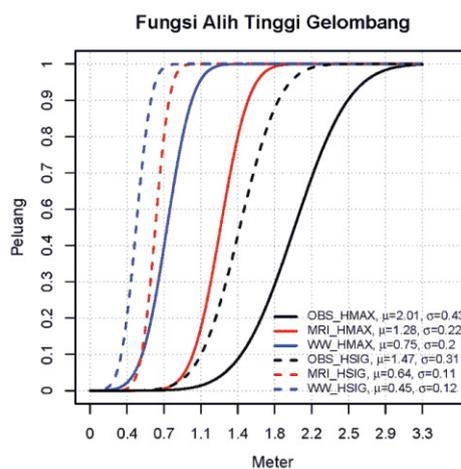
c



d

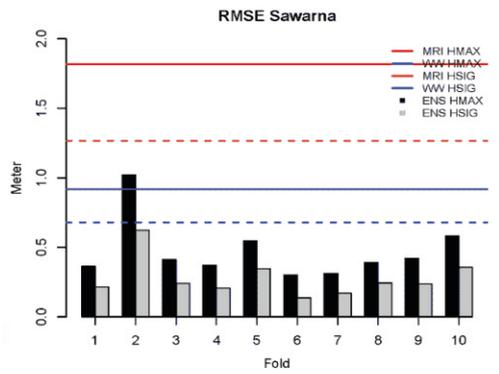


e

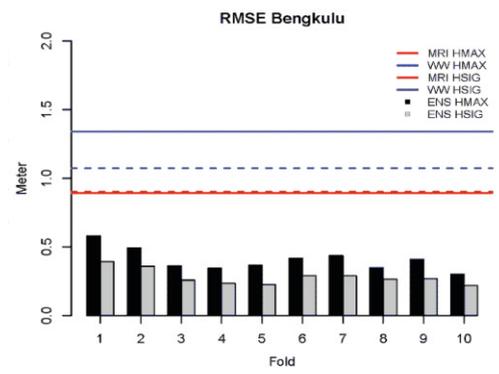


f

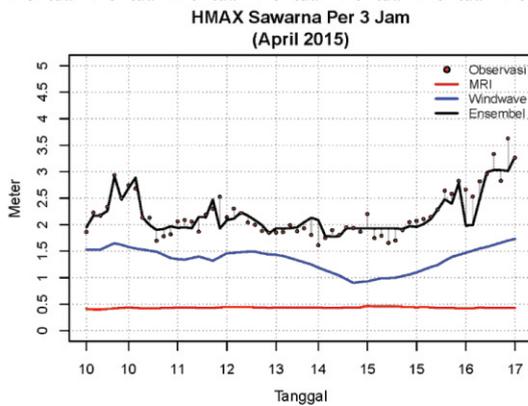
Gambar 3. Kondisi awal data input parameter HMAX (a dan b), HSIG (c dan d) untuk lokasi Sawarna (a) dan Bengkulu (b) serta fungsi alih yang terbentuk untuk Sawarna (e) dan Bengkulu (f).



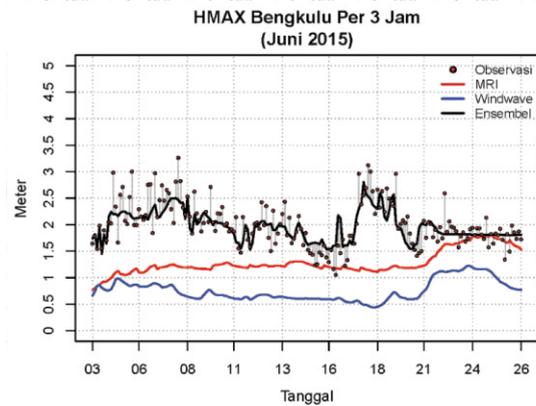
a



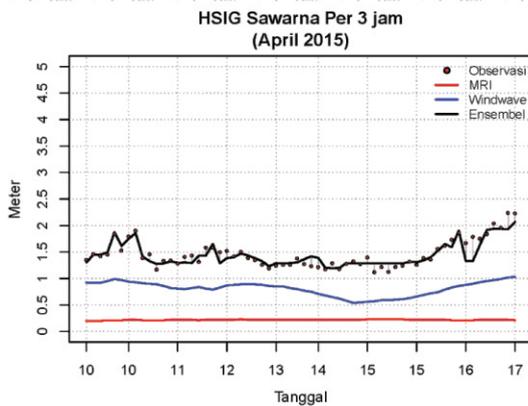
b



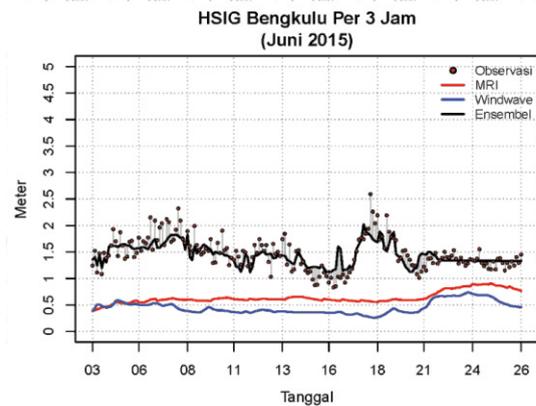
c



d



e



f

Gambar 4. Hasil RMSE antara MRI, WW, dan ensembel terhadap data observasi untuk lokasi Sawarna (a) dan Bengkulu (b) serta penerapan bobot JST pada seluruh data input dari fold yang memiliki RMSE terkecil untuk parameter HMAX (c, d), HSIG (e, f) di lokasi Sawana (c, e) dan Bengkulu (d, f).

Evaluasi Model Gelombang MRI-III dan Windwaves-05 terhadap Observasi. Output hasil ensembel ditunjukkan pada gambar 4. Pada gambar tersebut tampak bahwa nilai output MRI dan WW seluruhnya berada di bawah kondisi lapangan, atau dengan kata lain terdapat bias yang signifikan dari kedua model gelombang terhadap kondisi gelombang hasil perekaman AWAC. Selain itu, variasi output kedua model juga lebih rendah dibanding variasi data AWAC.

Berdasarkan hasil pengamatan lapangan dan *running* model MRI-III dan Windwaves-05 di wilayah perairan Selatan Jawa pada tanggal 10-19 April 2015, tinggi gelombang hasil luaran model MRI-III dan Windwaves-05 lebih rendah daripada data observasi. Hasil pengamatan lapangan dan *running* model MRI-III dan Windwaves-05 di wilayah perairan Barat Sumatera pada tanggal 3-27 Juni 2015 diperlihatkan pada gambar 3. Tinggi gelombang hasil luaran model MRI-III dan Windwaves-05 menunjukkan nilai lebih rendah dari data observasi.

Tabel 2. Nilai RMSE hasil *cross validation*

Fold	HMAX		HSIG	
	Sawarna	Bengkulu	Sawarna	Bengkulu
1	0.241	0.358	0.128	0.247
2	0.475	0.354	0.284	0.260
3	0.273	0.294	0.151	0.214
4	0.214	0.296	0.119	0.219
5	0.291	0.293	0.169	0.211
6	0.263	0.305	0.145	0.217
7	0.251	0.350	0.121	0.227
8	0.266	0.319	0.141	0.234
9	0.286	0.315	0.172	0.225
10	0.313	0.304	0.194	0.220

Model ensemble ini dikembangkan dengan menggunakan dua data titik sebagai acuan. Sedangkan output model gelombang sebagai input model ensemble berupa data spasial. Sehingga dalam penggunaan model ensemble ini perlu dipertimbangkan ke dalam wilayah perairan mana sebuah grid spasial output dua model gelombang lebih dekat (Sawarna atau Bengkulu). Selain itu, validitas ensemble hanya berlaku untuk dua lokasi pengambilan data lapangan.

Untuk penggunaan model ensemble di suatu grid spasial dari output model gelombang, perlu ditekankan asumsi bahwa kondisi perairan di grid tersebut memiliki karakteristik yang kurang lebih sama dengan karakteristik kondisi perairan di mana data lapangan diambil. Oleh karena itu, salah satu hal yang perlu dilakukan adalah memperbanyak lokasi pengambilan data lapangan. Sehingga semakin banyak pula perbandingan referensi data sebagai acuan dalam pengembangan model ensemble. Alternatif lain yang mungkin dapat dilakukan adalah pemanfaatan data observasi

spasial, seperti citra satelit atau radar. Secara kuantitatif, nilai RMSE ditunjukkan pada tabel 2. Pada tabel tersebut nilai RMSE terendah dari setiap fold anggota *cross validation* dicetak tebal dan RMSE tertinggi diberi warna merah. Secara umum model ensemble Sawarna memiliki nilai RMSE HMAX berada di kisaran 0.214 sampai dengan 0.475 meter dan 0.293 sampai dengan 0.358 meter untuk Bengkulu. Sedangkan nilai RMSE HSIG model ensemble Sawarna berada di kisaran 0.119 sampai dengan 0.284 meter dan 0.211 sampai dengan 0.260 meter untuk Bengkulu.

Dilihat dari rentang nilai RMSE tersebut, model ensemble Bengkulu memberikan performa lebih stabil dibanding model ensemble Sawarna. Hal ini kemungkinan disebabkan oleh jumlah data yang

tersedia lebih banyak untuk lokasi Bengkulu dibanding Sawarna. Namun secara keseluruhan, model ensemble pada kedua lokasi tersebut memberikan performa yang baik, ditunjukkan dengan nilai RMSE yang lebih rendah dibanding kedua model input (MRI dan WW).

4. Kesimpulan

Telah dikembangkan model ensemble untuk mendapatkan sebuah model gelombang baru dari dua model gelombang yang telah tersedia: MRI dan WW. Proses ensemble terhadap dua model gelombang tersebut dilakukan oleh jaringan syaraf tiruan dengan algoritma pembelajaran *resilient backpropagation*. Data yang digunakan sebagai acuan oleh JST pada proses ensemble diperoleh dari perekaman langsung oleh AWAC di dua lokasi perairan: Bengkulu dan Sawarna. Output model ensemble yang dihasilkan mampu lebih mendekati data observasi dibanding output MRI dan WW secara individu. Ensemble Model Gelombang MRI-III dan Windwave-05 yang dikembangkan dalam penelitian ini terbukti menunjukkan performa yang lebih baik dibanding performa model secara individu. Sebagai tambahan, jaringan syaraf tiruan telah teruji dapat digunakan untuk menggabung beberapa model untuk mendapatkan model baru dengan performa lebih baik, sehingga dapat direkomendasikan sebagai alternatif untuk operasional layanan meteorologi maritim di BMKG.

Daftar Pustaka

- [1] D. Opitz and R. Maclin, "Popular Ensemble Methods: An Empirical Study," *Journal of Artificial Intelligent Research*, vol. 11, pp. 169–198, 1999.
- [2] L. K. Hansen and P. Salamon, "Neural Network Ensembles," *IEEE Transactions on Pattern*

- Analysis and Machine Intelligence*, vol. 12, no. 10, pp. 993–1001, 1990.
- [3] Suratno. 1997. *Model Numerik Prakiraan Gelombang Permukaan laut untuk Perairan Indonesia dan Sekitarnya*. Tesis, Program studi Fisika, Fakultas MIPA, Universitas Indonesia. Jakarta.
- [4] S. Kumar, A. Routray, G. Tiwari, R. Chauhan, and I. Jain, *Simulation of Tropical Cyclone 'Phailin' Using WRF Modeling System, in Tropical Cyclone Activity over the North Indian Ocean*, M. Mohapatra, B. Bandyopadhyay, and L. Rathore, Eds. Cham: Springer International Publishing, 2017, pp. 307–316.
- [5] Z.-H. Zhou, *Ensemble Methods: Foundations and Algorithms*, 1st ed. Chapman & Hall/CRC, 2012.
- [6] S. Li, K. Ma, Z. Jin, and Y. Zhu, “A new flood forecasting model based on SVM and boosting learning algorithms,” in *2016 IEEE Congress on Evolutionary Computation (CEC). IEEE, jul 2016*, pp. 1343–1348.
- [7] M. Carney, J. Dowling, and C. Lee, “Predicting Probability Distributions for Surf Height Using an Ensemble of Mixture Density Networks,” in *ICML '05 Proceedings of the 22nd international conference on Machine learning. Bonn, Germany: ACM New York, NY, USA, 2005*, pp. 113–120.
- [8] W. S. McCulloch and W. Pitts, “A logical calculus of the ideas immanent in nervous activity,” *The Bulletin of Mathematical Biophysics*, vol. 5, no. 4, pp. 115–133, 1943.
- [9] Z. Zhang, “Incorporation of artificial neural networks and data assimilation techniques into a third-generation windwave model for wave forecasting,” *Journal of Hydroinformatics*, vol. 8, no. 1, pp. 65–76, 2006.
- [10] R. R. Gonzalez, “Neural networks referees in 1993,” *Neural Networks*, vol. 7, no. 1, pp. xiii–xiv, 1994.
- [11] M. Riedmiller and H. Braun, “A direct adaptive method for faster backpropagation learning: the RPROP algorithm,” *IEEE International Conference on Neural Networks*, vol. 1993-January. IEEE, 1993, pp.