

IDENTIFIKASI SISTEM NONLINIER PADA PERGERAKAN MANUEVER KAPAL MENGGUNAKAN *RANDOM VECTOR FUNCTIONAL LINK NETWORK*

NONLINEAR SYSTEM IDENTIFICATION OF SHIP MANEUVERING MOTION USING RANDOM VECTOR FUNCTIONAL LINK NETWORK

Mohamad Imam Afandi^{1*}, Hendra Adinanta¹, Arga Iman Malakani¹, Laily Fajarwati¹,
Rio Dwi Sakti Wijaya¹, Yusron Feriadi¹, Endang Widjayati¹

*E-mail: moha036@brin.go.id

¹Pusat Riset Teknologi Hidrodinamika – Badan Riset dan Inovasi Nasional (PRTH-BRIN)

Abstrak

Perkembangan teknologi kecerdasan buatan atau AI (*Artificial Intelligent*) saat ini sudah sangat masif dalam berbagai bidang termasuk dalam sektor industri maritim, dimana salah satunya digunakan untuk mendukung teknologi kapal otonom. Untuk mengetahui dinamika pergerakan manuever kapal yang cukup kompleks maka diperlukan identifikasi sistem nonlinier. Jaringan Saraf Tiruan (JST) terbukti sangat teruji dalam mengatasi permasalahan sistem nonlinier. Sehingga dalam tulisan ini akan dibahas identifikasi sistem nonlinier berbasis jaringan saraf tiruan untuk pergerakan manuever kapal menggunakan *Random Vektor Functional Link Network* (RVFLN). RVFLN adalah varian pembelajaran cepat dari *Single Layer Feedforward Network* (SLFN) yang menggunakan metode *pseudo-inverse* atau *least square*. Tiga kali pengujian real pada mini-prototipe kapal untuk melakukan pergerakan manuever secara zigzag dengan *setpoint* yang sama telah didapatkan data respon kapal yang berbeda sehingga sistem adalah nonlinier. Hasil identifikasi sistem menunjukkan bahwa RVFLN mampu memodelkan pergerakan manuever kapal dengan tingkat akurasi hingga 99.43%, kesalahan maksimum sebesar 1.25%, dan waktu pembelajaran yang sangat cepat hingga dibawah 1 ms sehingga mendukung untuk aplikasi *real-time*. Hasil model RVFLN juga diuji kembali menggunakan masukan data sinyal *setpoint* secara *open-loop* dan *closed-loop* yang didapatkan bahwa model sistem kapal sesuai yang diharapkan. Sehingga dari hasil tersebut dapat digunakan untuk pengembangan lebih lanjut AI pembelajaran cepat untuk kendali kapal otonom.

Kata kunci: identifikasi sistem non linier, pergerakan manuever kapal, *Random Vektor Functional Link Network* (RVFLN), AI pembelajaran cepat, kapal otonom.

Abstract

The development of Artificial Intelligence (AI) technology is currently massive in various fields, including the maritime industry, one of which can be used to support autonomous ship technology. To understand the complex dynamics of ship maneuvering motion, nonlinear system identification is necessary. This paper discusses nonlinear system identification based on neural networks for ship maneuvering motion using the *Random Vector Functional Link Network* (RVFLN). RVFLN is a fast-learning variant of the *Single Layer Feed-forward Network* (SLFN) that utilizes the *pseudo-inverse* or *least-square* method. Three real tests on a mini prototype ship performing zigzag maneuvering motion with identical setpoints produced different ship response data, confirming that the system is nonlinear. The system identification results show that RVFLN is capable of modeling ship maneuvering motion with an accuracy up to 99.43%, maximum error 1.25%, and very fast learning time under 1 ms, thereby supporting real-time applications. The

resulting RVFLN model is further tested using specific signal inputs under both open-loop and closed-loop conditions. The ship model remains stable as expected, demonstrating its suitability for further development of fast-learning AI for autonomous ship control.

Keywords: *Nonlinear system identification, ship maneuvering motion. Random Vector Functional Link Network (RVFLN), fast-learning AI, autonomous ship.*

1. PENDAHULUAN

Perkembangan teknologi kecerdasan buatan (AI) telah membuka peluang besar bagi otomatisasi di sektor maritim, khususnya dalam pengembangan kapal otonom. Salah satu tantangan utama dalam mewujudkan kapal otonom yang andal adalah kemampuan untuk memodelkan dan memprediksi pergerakan kapal secara akurat dan cepat. Kapal sebagai sistem dinamik memiliki karakteristik nonlinier yang kuat, terutama saat melakukan manuver seperti zigzag, membelok tajam, atau menghindari tabrakan [1]. Identifikasi sistem merupakan proses rekonstruksi model matematis suatu sistem dinamis berdasarkan data masukan dan keluaran. Dalam konteks pergerakan kapal, identifikasi sistem bertujuan untuk memperoleh model yang dapat memprediksi perilaku manuver kapal secara akurat [2].

Pengembangan desain kendali untuk kapal otonom memerlukan pemahaman yang akurat tentang karakteristik dinamika pergerakan kapal, terutama saat melakukan manuver nonlinier seperti zigzag. International Maritime Organization (IMO) telah merekomendasikan penggunaan uji model skala dan simulasi komputer untuk prediksi kemampuan manuver kapal sejak tahap desain awal [3]. Dalam pemodelan gerak kapal, terdapat tiga pendekatan utama, yaitu *white box*, *grey box*, dan *black box* [4]. Pendekatan *white box* mengestimasi parameter model fisika secara langsung dari data. Namun, pendekatan berbasis model fisika (*white box*) ini memiliki keterbatasan karena kompleksitas perhitungan hidrodinamika dan kebutuhan data validasi yang ekstensif dari uji coba skala penuh. Pendekatan *grey box* memberikan struktur model umum, kemudian mengestimasi parameter dari data. Adapun pendekatan *black box* menentukan struktur model sekaligus mengestimasi parameter sepenuhnya dari data, tanpa melibatkan hukum-hukum fisika.

Pemodelan sistem dengan pendekatan *black box* hadir sebagai alternatif yang lebih praktis. Secara umum, identifikasi sistem didefinisikan sebagai proses rekonstruksi model parameter melalui eksperimen berbasis data masukan dan keluaran. Berbagai algoritma cerdas dan teori pembelajaran mesin telah diusulkan dan diaplikasikan pada ketiga pendekatan identifikasi tersebut untuk model matematis gerak kapal. Wang dkk. [5] menyelidiki pemodelan *white box*, *grey box*, dan *black box* menggunakan ε – *support vector regression*. Mei dkk. [6] menggunakan hibrida *white* dan *black box* untuk identifikasi model berbasis RM-RF. Zhang dkk. [7] menerapkan pemodelan *black box* menggunakan *multi-output nu-support vector regression* dengan sinyal eksitasi acak. Wang dkk. [8] melakukan identifikasi dan prediksi gerak manuver kapal berdasarkan proses *Gaussian*. He dkk. [9] menyelidiki pemodelan *black box* berbasis jaringan saraf tiruan *backpropagation*. Xu dkk. [10] memprediksi gerak manuver kapal menggunakan kerangka *grey box* menggunakan SVM. Xue dkk. [11] melakukan identifikasi dan prediksi gerak manuver kapal berdasarkan proses *Gaussian* dengan propagasi ketidakpastian. Chen dkk. [12] memprediksi gerak manuver kapal menggunakan kerangka *grey box* menggunakan LS-SVM.

Meskipun metode-metode tersebut menunjukkan hasil yang menjanjikan, sebagian besar masih mengandalkan proses pelatihan iteratif yang memakan waktu dan berisiko terjebak pada *local minima*. Hal ini menjadi kendala serius untuk aplikasi *real-time* pada kapal otonom yang memerlukan adaptasi cepat terhadap perubahan lingkungan. Dalam tulisan ini mengusulkan penggunaan *Random Vector Functional Link Network* (RVFLN) untuk identifikasi sistem

nonlinier pergerakan manuver kapal. RVFLN merupakan varian dari *Single Layer Feedforward Network* (SLFN) dengan beberapa keunggulan utama sebagai berikut:

- Pembangkitan bobot secara acak pada lapisan tersembunyi yang bersifat tetap (tidak dilatih), sehingga menghilangkan kebutuhan iterasi.
- Sambungan langsung (*direct connection*) antara lapisan masukan dan lapisan keluaran, yang meningkatkan kemampuan generalisasi.
- Metode pelatihan analitik menggunakan *pseudo-inverse* atau *least square*, yang menyelesaikan proses pembelajaran dalam satu langkah tanpa iterasi.
- RVFLN mampu menyelesaikan proses pelatihan dengan cepat tanpa mengalami masalah *local minima* yang umum terjadi pada algoritma *backpropagation*.

Karakteristik ini menjadikan RVFLN sangat cocok untuk aplikasi yang memerlukan adaptasi cepat, seperti pada kapal otonom yang harus merespon perubahan lingkungan secara *real-time*.

2. METODOLOGI


2.1 Desain Kapal

Spesifikasi kapal yang aslinya memiliki panjang 37 meter, lebar 7 meter, dan tinggi 4 meter dengan kecepatan hingga 18 knot serta koefisien blok sebesar 0.418. Untuk kemudahan dalam melakukan pengujian dan masih memenuhi standar pengujian IMO (*International Maritime Organization*), maka digunakan model mini prototipe kapal yang memiliki skala 1:24 dari ukuran aslinya, di mana ukuran mini prototipe kapal menjadi panjang 1.56 meter, lebar 0.29 meter, dan tinggi 0.16 meter dengan bentuk lambung kapal yang sama seperti aslinya seperti yang diberikan pada Gambar 1.



Gambar 1. Mini prototipe kapal

Untuk pengujian manuver, kapal ini dilengkapi dengan penggerak mekanik yang terdiri dari dua baling-baling (*propeler*) yang digabungkan dalam satu *gearbox* menggunakan satu motor BLDC dan dua bilah kemudi (*rudder*) menggunakan dua motor dc servo yang digerakkan bersama secara elektronik. Komponen elektronik dilengkapi dengan mikrokontroler sebagai pengendali utama, penguat driver motor *ESC*, dan sensor *gyroscope* seperti yang diberikan pada Gambar 2.



Gambar 2. Sistem elektronik dan mekanik pada mini prototipe kapal

Pada Gambar 2 dapat dijelaskan bahwa sudut haluan (*heading*) kapal didapatkan dengan mengambil data sudut yaw dari sensor *gyroscope* dan untuk mengubah sudut kemudi (*rudder*)

dilakukan dengan memberikan sinyal sudut ke motor servo *rudder* dengan sinyal umpan balik tegangan posisi potensiometer dari motor servo tersebut.

2.2 Pengujian Manuver Kapal Secara Zigzag


Desain kapal ini tergolong sebagai kapal cepat yang dituntut untuk mempunyai kemampuan berbelok atau berubah arah dengan respons yang sangat cepat dan tetap akurat mengikuti lintasan yang diinginkan. Untuk menguji kelincihan pergerakan manuver kapal, maka sesuai aturan standar dari IMO (*International Maritime Organization*) yang mempersyaratkan pengujian manuver kapal secara zigzag dengan sudut kemudi yang digunakan sebesar $10^\circ/10^\circ$ atau $20^\circ/20^\circ$ dengan mengikuti pola data parameter zigzag seperti yang diberikan pada Gambar 3.

Gambar 3. Pola data parameter zigzag sesuai standar IMO

Pada Gambar 3 dapat dijelaskan bahwa manuver zigzag dibuat dengan mengubah sudut kemudi (*rudder*) secara bergantian sebesar δ derajat ke kanan dan ke kiri jika sudut haluan kapal (*heading*) sebesar ψ derajat telah mencapai perubahan nilai yang sama dengan sudut kemudi (*rudder*). Pada saat kondisi awal, kapal berjalan pada keadaan tunak dengan sudut awal haluan (*heading*) kapal sama dengan nol. Kemudian kemudi (*rudder*) dibelokkan sebesar 20° ke arah kanan dan apabila sudut haluan (*heading*) kapal telah menyimpang sejauh 20° derajat dari arah semula, maka kemudi (*rudder*) dibalikkan secara cepat sebesar 20° ke arah kiri. Hal tersebut mengakibatkan sudut haluan (*heading*) kapal terus menurun hingga berubah arah dari sebelumnya. Pada saat sudut haluan (*heading*) kapal telah menyimpang sejauh 20° derajat dari kondisi awal maka kemudi (*rudder*) dibalikkan lagi sebesar 20° ke arah kanan. Prosedur ini dilakukan berulang secara periodik sehingga menghasilkan lintasan zigzag.

2.3 Random Vector Functional Link Network (RVFLN)

Arsitektur RVFLN terdiri dari tiga lapisan utama yaitu lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan keluaran (*output layer*) seperti yang diberikan pada Gambar 4.



Gambar 4. Arsitektur RVFLN

Pada Gambar 4 dapat dijelaskan bahwa keunikan RVFLN terletak pada :

- bobot tersembunyi H dan nilai bias b diinisialisasi secara acak dan tidak dilatih,

- adanya koneksi langsung (*direct link*) dari masukan (*input*) ke keluaran (*output*),
- koneksi ke bobot keluaran dihitung secara analitik.

Untuk hubungan sinyal masukan (*input*) dan sinyal keluaran (*output*) dari sistem non linear prediktif dapat diekspresikan sebagai fungsi berikut :

$$y(k+1) = f(y(k), \dots, y(k-n_y), u(k), \dots, u(k-n_u)) \dots\dots\dots (1)$$

Dengan $y(k)$ adalah sinyal keluaran sistem, $u(k)$ adalah sinyal masukan sistem, k adalah waktu sampling data, n_y adalah orde waktu *lag* dari keluaran, dan n_u adalah orde waktu *lag* dari masukan. Fungsi persamaan tersebut lebih fokus pada sinyal keluaran sistem berikutnya karena dijadikan target keluaran untuk mengantisipasi setiap perubahan sistem yang disebabkan oleh perubahan sinyal masukan dan kondisi sinyal keluaran saat ini.

Susunan lapisan masukan (*input layer*) diperoleh dari $X = [y(k), \dots, y(k-n_y), u(k), \dots, u(k-n_u)]$ dengan jumlah bobot masukan $m = n_y + n_u$. Untuk susunan lapisan tersembunyi H dapat ditentukan secara acak dengan jumlah bobot tersembunyi sebanyak n dan susunan lapisan keluaran $Y = [y(k+1)]$ yang dijadikan target keluaran dengan jumlah bobot keluaran $p = 1$.

Proses pemodelan RVFLN, mengikuti langkah-langkah sebagai berikut :

Langkah 1: Susun dataset matriks bobot masukan X dan bobot keluaran Y

Langkah 2: Bangkitkan secara acak semua matriks bobot tersembunyi H dan bobot bias B

Langkah 3: Tentukan fungsi aktivasi g (dipilih antara sigmoid, ReLu, Tanh, linear, dsb)

Langkah 4: Hitung matriks lapisan tersembunyi:

$$W = g(X.H + B)$$

Langkah 5: Bentuk matriks koneksi langsung $D = [X \ W]$.

Langkah 6: Hitung matriks lapisan keluaran β menggunakan metode *pseudo-inverse*:

$$\beta = D^+ \cdot Y \quad \text{dengan} \quad D^+ = (D^T D + \lambda I)^{-1} D^T$$

Langkah 7: Hitung keluaran prediksi

$$P_1 = D \cdot \beta$$

2.4 Identifikasi Sistem Nonlinier Menggunakan RVFLN

Identifikasi sistem nonlinier pada pergerakan manuver kapal menggunakan RVFLN dengan penentuan fungsi aktivasi yang sering dipakai dalam RVFLN dapat dipilih sesuai tabel berikut :

Tabel 1. Fungsi Aktivasi g

Fungsi Aktivasi	Persamaan Matematis	Rentang Keluaran	Waktu Proses Relatif
Linear	$g(x) = x$	$(-\infty, \infty)$	1x (tercepat)
ReLU	$g(x) = \max(0, x)$	$(0, \infty)$	~1.5x
Leaky ReLU	$g(x) = \begin{cases} x & x > 0 \\ \alpha x & x \leq 0 \end{cases}$ $\alpha = 0.01$	$(-\infty, \infty)$	~1.6x

Sigmoid	$g(x) = \frac{1}{1 + e^{-x}}$	(0,1)	$\sim 8x$
Tanh	$g(x) = \tanh(x)$ $= \frac{e^x - e^{-x}}{e^x + e^{-x}}$	(-1,1)	$\sim 10x$

Dari Tabel 1 dapat dijelaskan bahwa fungsi aktivasi linear menjadi proses yang tercepat namun biasanya kurang cocok untuk sistem nonlinier. Untuk fungsi aktivasi Leaky ReLU sering menjadi pilihan untuk sistem nonlinier dengan waktu proses relatif cepat dan menjangkau semua nilai rentang keluaran. Perhitungan performansi yang digunakan untuk mengetahui tingkat akurasi model terhadap kondisi sebenarnya, terdiri dari :

- a. *Mean Square Error* (MSE)

$$MSE = \frac{1}{N} \sum_{i=1}^N (P_i - Y_i)^2$$

- b. *Root Mean Square Error* (RMSE)

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - Y_i)^2}$$

- c. *Mean Absolut Error* (MAE)


$$MAE = \frac{1}{N} \sum_{i=1}^j |P_i - Y_i|$$

dengan P = keluaran prediksi, Y = keluaran sebenarnya, dan N = jumlah data.

3. HASIL DAN PEMBAHASAN


3.1 Hasil Pengujian Manuver Kapal Secara Zigzag

Pengujian real manuver mini prototipe kapal secara zigzag dilakukan di laboratorium *Maneuvering Ocean Engineering Basin* (MOB), BRIN Surabaya, dengan pengkondisian air yang relatif tenang tanpa gangguan eksternal ombak dan angin dari luar seperti yang diberikan pada Gambar 6 berikut ini.



Gambar 6. Pengujian manuver zigzag pada mini prototipe kapal

Hasilnya telah didapatkan tiga data pengujian *real* manuver kapal secara zigzag dengan sudut kemudi (*rudder*) sebesar $20^{\circ}/20^{\circ}$ dan kecepatan sebesar 1.2 m/s yang mempunyai pola grafik seperti pada Gambar 7.




Gambar 7. Hasil data pengujian manuver zigzag

Dari Gambar 7 dapat dijelaskan bahwa dengan kecepatan yang sama ternyata menghasilkan pola data grafik yang sedikit berbeda dengan terjadi perbedaan waktu manuver zigzag di setiap pengujianya sehingga sistem cenderung nonlinier.


3.2 Hasil Pembelajaran dan Pengujian RVFLN

Inisialisasi parameter $ny = 3$ dan $nu = 3$ menjadi jumlah bobot masukan $m = ny + nu = 6$, jumlah bobot keluaran $p = 1$. Jumlah bobot tersembunyi (*hidden*) $n = 10$ yang setiap nilai bobot tersembunyi (*hidden*) dan nilai bias dibangkitkan secara acak dengan fungsi aktivasi menggunakan Leaky ReLU. Untuk rasio dataset pembelajaran 70% dan pengujian 30% dari pengujian manuver zigzag 1, didapatkan hasil sebagai berikut :



Gambar 8. Hasil pembelajaran dan pengujian RVFLN untuk zigzag 1

Dari Gambar 8 dapat dijelaskan bahwa untuk dataset pembelajaran 70% untuk zigzag 1, didapatkan hasil akurasi pembelajaran RVFLN mencapai 99.42% dan hasil akurasi pengujian RVFLN mencapai 99.33%. Hal tersebut dibuktikan dari hasil prediksi sudut haluan (*heading*) model RVFLN terlihat hampir mendekati sama dengan sudut haluan (*heading*) aktual. Hasil nilai *error* absolut juga terlihat sangat kecil dengan nilai maksimum *error* absolut sebesar 0.5° yang jika dibandingkan dengan rentang masukan sudut kemudi (*rudder*) sebesar $20^\circ/20^\circ$ atau amplitudo 40° , maka didapatkan prosentase maksimum *error* hanya 1.25%. Dalam dunia industri, untuk ketelitian dibawah 2% sudah termasuk kelas presisi tinggi. Untuk waktu proses pembelajaran dan dan pengujian RVFLN dapat diberikan pada Gambar 9 sebagai berikut.



Gambar 9. Hasil waktu proses pembelajaran dan pengujian RVFLN


Perlu diketahui bahwa hasil proses identifikasi secara *offline* ini dijalankan pada komputer prosesor *intel core i7 gen 11th speed 2.80 Ghz* menggunakan aplikasi *free and opensource* GNU Octave 11.1 yang mempunyai kemampuan komputasi numerik, analisis data, dan visualisasi plot grafik yang mirip dengan aplikasi berbayar Matlab. Pada Gambar 9 dapat dijelaskan bahwa hasil waktu proses pembelajaran per iterasi hanya mencapai waktu tertinggi 1.4 ms dan waktu proses pengujian per iterasi yang mencapai waktu tertinggi 1.15 ms dengan rata-rata waktu pembelajaran 0.6042 ms dan rata-rata waktu pengujian 0.5918 ms. Hasil dari kedua waktu proses tidak terlalu berbeda karena pembelajaran RVFLN tidak menggunakan *backpropagation* yang membutuhkan proses perulangan iterasi yang lama, namun menggunakan perhitungan proyeksi *pseudo-inverse* yang cepat tanpa proses perulangan iterasi.

Selain itu, pada Gambar 9 terlihat juga bahwa waktu proses pembelajaran dan pengujian terdapat fluktuasi waktu yang tidak rata dan cenderung ada sedikit kenaikan waktu setelah beberapa detik waktu tertentu. Hal tersebut terjadi karena ada sedikit perbedaan alokasi penggunaan memori dan komputasi numerik RVFLN pada setiap waktu prosesnya.

Nantinya, saat diaplikasikan pada *embedded system* atau mikrokontroler 32 bit seperti ESP32, STM32, Raspberry Pi, dan/atau mini PC dengan spesifikasi lebih rendah untuk identifikasi/kontrol secara *online*, maka pastinya akan mengalami perlambatan waktu proses pembelajaran RVFLN. Jika mengalami perlambatan waktu proses pembelajaran sebesar 10 – 20 kali hingga menjadi 6 – 12 ms, maka dalam hal ini masih dapat direkomendasikan untuk aplikasi secara *real-time* karena masih dibawah waktu sampling sistem sebesar 20 ms.


3.3 Hasil Validasi Pengujian RVFLN

Hasil parameter pembelajaran RVFLN pada zigzag 1 selanjutnya digunakan untuk validasi pengujian RVFLN pada zigzag 2 yang mendapatkan hasil berikut ini.



Gambar 10. Hasil validasi pengujian RVFLN untuk zigzag 2

Dari Gambar 10 terlihat jelas bahwa hasil validasi pengujian RVFLN untuk zigzag 2 sangat mendekati nilai aktual nya dengan tingkat akurasi mencapai 99.2% dan kesalahan maksimum sekitar 0.5° . Kemudian untuk hasil validasi pengujian RVFLN untuk zigzag 3 berikut ini.




Gambar 11. Hasil validasi pengujian RVFLN untuk zigzag 3

Dari Gambar 11 terlihat jelas bahwa hasil validasi pengujian RVFLN untuk zigzag 3 juga sangat mendekati nilai aktual dengan tingkat akurasi mencapai 99.27% dan kesalahan maksimum dibawah 0.4° . Kedua hasil validasi pengujian ini sangat melebihi ekspektasi karena mendapatkan tingkat akurasi yang sangat baik, sehingga pemodelan RVFLN sangat direkomendasikan untuk pemodelan sistem nonlinier.


3.4 Hasil Evaluasi Pemodelan RVFLN

Hasil performansi dari pembelajaran dan pengujian RVFLN untuk ketiga data pengujian zigzag dapat diberikan sebagai berikut:



Gambar 12. Hasil performansi pembelajaran dan pengujian RVFLN

Dari Gambar 12 didapatkan hasil performansi pembelajaran yaitu $MSE = 0.0076$, $RMSE = 0.0872$, $MAE = 0.0551$ dan hasil performansi untuk tiga pengujian yaitu $MSE = 0.0138$, $RMSE = 0.1176$, $MAE = 0.0662$.



Gambar 13. Hasil pengujian *setpoint step* pada pemodelan RVFLN

Dari gambar 13 dapat dijelaskan bahwa untuk *setpoint step* secara *open loop* menyebabkan sudut haluan (*heading*) semakin terus meningkat hingga sudutnya akan kembali sebelumnya dan terus meningkat lagi sehingga akan memberikan hasil pergerakan manuver berputar (*turning*). Sedangkan untuk *setpoint step* secara *closed loop* dengan penambahan penguatan 10 kali pada masukan sudut kemudi (*rudder*) yang dibatasi maksimum sudutnya hanya $\pm 60^\circ$ maka didapatkan hasil respon sudut haluan (*heading*) dengan sedikit osilasi sebelum mendekati nilai *setpoint*-nya hingga sudut haluan (*heading*) menjadi stabil dengan sedikit *error* terhadap nilai *setpoint*-nya.

Dari hasil kedua respon tersebut telah membuktikan bahwa pemodelan RVFLN sesuai dengan yang diharapkan dan digunakan sebagai fungsi alih model yang mendekati kondisi real sebenarnya. Selanjutnya dari pemodelan RVFLN ini dapat digunakan untuk pengembangan analisis kontrol lebih lanjut untuk kendali kapal otonom.

4. KESIMPULAN DAN SARAN

Berdasarkan hasil identifikasi sistem untuk pergerakan manuver secara zigzag pada mini prototipe kapal dapat disimpulkan bahwa RVFLN mampu memodelkan pergerakan manuver kapal dengan tingkat akurasi hingga 99.43%, kesalahan maksimum sebesar 1.25%, dan waktu pembelajaran yang sangat cepat hingga dibawah 1 ms sehingga mendukung untuk aplikasi *real-time*. Hasil model RVFLN juga diuji kembali menggunakan masukan data sinyal *setpoint* secara *open-loop* dan *closed-loop* yang didapatkan bahwa model sistem kapal sesuai yang diharapkan. Sehingga hasil pemodelan RVFLN tersebut dapat digunakan untuk pengembangan analisis kontrol lebih lanjut untuk kendali kapal otonom.

5. DAFTAR RUJUKAN

- [1] Ringbom, H., Rosaeg, E., and Solvang, T., 2021. *Autonomous Ship and The Law*. First Edition. London and New York: Routledge Taylor and Francis Group.
- [2] Fossen, T., 2021. *Handbook of Marine Craft Hydrodynamics and Motion Control*. Wiley: Hoboken, NJ, USA.
- [3] Alexandersson, M., Mao, W., Ringsberg, J.W., 2022. *System Identification of Vessel Manoeuvring Models*. Ocean Eng., 266, 112940.
- [4] Haranen, M., Pakkanen, P., Kariranta, R., Salo, J., 2016. *White, Grey and Black-Box Modelling in Ship Performance Evaluation*. NAPA Ltd.: Helsinki, Finland.
- [5] Wang, Z., Zou, Z., Guedes Soares, C., 2019. *Identification of Ship Manoeuvring Motion Based on Nu-Support Vector Machine*. Ocean Eng., 183, 270–281.
- [6] Mei, B., Sun, L., Shi, G., and Liu, X., 2019. *Ship Maneuvering Prediction Using Grey Box Framework Via Adaptive Rm-Svm with Minor Rudder*. Polish Maritime Research 3 (103), Vol. 26, 115-127.
- [7] Zhang, Y.-Y.; Wang, Z.-H.; Zou, Z.-J. 2022. *Black-Box Modeling of Ship Maneuvering Motion Based on Multi-Output Nu-Support Vector Regression with Random Excitation Signal*. Ocean Eng., 257, 111279.
- [8] Wang, S., Wang, L., Im, N., Zhang, W., Li, X., 2022. *Real-Time Parameter Identification of Ship Maneuvering Response Model Based on Nonlinear Gaussian Filter*, Ocean Eng., 247, 110471.
- [9] He, H.-W., Wang, Z.-H., Zou, Z.-J., Liu, Y., 2022. *Nonparametric Modeling of Ship Maneuvering Motion Based on Self-Designed Fully Connected Neural Network*. Ocean Eng., 251, 111113.
- [10] Xu, H., Hinostroza, M.A., Hassani, V., Guedes Soares, C., 2019. *Real-Time Parameter Estimation of a Nonlinear Vessel Steering Model Using a Support Vector Machine*. J. Offshore Mech. Arct. Eng., 141, 061606.

- [11] Xue, Y., Liu, Y., Xue, G., and Chen, G., 2021. *Identification and Prediction of Ship Maneuvering Motion Based on a Gaussian Process with Uncertainty Propagation*, Journal of Marine Science and Engineering, 9(8), 804.
- [12] Chen, L., Yang, P., Li, S., Tian, Y., Liu, G., Hao, G., 2022. *Grey-Box Identification Modeling of Ship Maneuvering Motion Based on LS-SVM*. Ocean Eng., 266, 112957.