

ESTUDIO DE LA APLICACIÓN DE REDES NEURONALES ARTIFICIALES EN LA PREDICCIÓN DE AMPLIFICACIÓN RÁPIDA DE LA AMPLITUD DE ROLL DE BUQUES EN OLAS

Jerver Elio Mañuico Vivanco¹, Marcelo de Almeida Santos Neves^{2,*}, Claudio Alexis Rodríguez Castillo³

¹COPPE/UFRJ, Rio de Janeiro, Brasil (jervermv@oceanica.ufrj.br)

²LabOceano – COPPE/UFRJ, Rio de Janeiro, Brasil (masn@laboceano.coppe.ufrj.br)

³LabOceano – COPPE/UFRJ, Rio de Janeiro, Brasil (claudiorc@laboceano.coppe.ufrj.br)

(*) Autor correspondiente

ABSTRACT

For a vessel which is in longitudinal waves, the wave passage, together with the vertical motions (heave and pitch), makes that the submerged geometry varies periodically with time, generating a variation of the ship's restoring properties and from a small perturbation, it can be developed a rapidly growing movement of progressive roll. To this end, we develop a system for predicting parametric resonance, starting from the analysis of the motion of the vessel, capable of detecting short-term appearance of it. The human being is endowed with complex brain neural circuitry. Thus, the idea of computationally modeling these neural connections to bring forth intelligent behavior also in machines. In this context emerges artificial neural networks (ANNs), inspired by the very nature of neural networks and biological synapse. In this work, we are trying to take advantage of ANNs to predict the behavior of ships, platforms and other floating devices, with emphasis on detection of dynamic amplification of ship's roll in parametric resonance conditions.

Keywords: parametric resonance; time series; artificial neural networks; combined input data.

RESUMEN

Para un navío que se encuentra en ondas longitudinales, el paso de la ola, conjuntamente con la variación de los movimientos verticales (heave y pitch), hace con que la geometría sumergida varíe periódicamente con el tiempo, generándose una variación de las características restaurativas y a partir de una pequeña perturbación, puede desenvolverse rápidamente en movimiento de roll en crecimiento progresivo. Con tal objetivo, queremos desarrollar un sistema de predicción de resonancia paramétrica que, a partir del análisis del movimiento del buque, sea capaz de detectar en el corto plazo la aparición de la misma. El ser humano es dotado de complejos circuitos neuronales cerebrales. Siendo así, surge la idea de conseguir modelar computacionalmente estas conexiones neuronales, para hacer surgir comportamientos también inteligentes en máquinas. En este contexto, surge las redes neuronales artificiales (RNAs) que son inspiradas en la propia naturaleza de las redes neuronales y sinapsis biológicos. En este trabajo, estamos queriendo aprovechar las ventajas de las RNAs para poder predecir el comportamiento del navío, plataformas, y otros artefactos fluctuante, con énfasis en la detección de procesos dinámicos de amplificación de roll de navíos en condiciones de resonancia paramétrica.

Palabras clave: resonancia paramétrica; series temporales; redes neuronales artificiales; datos de entrada combinados.

INTRODUCCIÓN

Modelar y predecir sistemas del mundo real es una tarea de alta demanda computacional y complejidad, Svarear (1994). Aquellos modelos convencionales muchas veces producen previsiones insatisfactorias. Muchos de los problemas reales es no tener información y/o condiciones iniciales suficientes para poder construir ecuaciones que gobiernen el comportamiento de las variables que queremos prever. En la ausencia de informaciones suficientes para generar las ecuaciones, es más atractivo usar un abordaje basado en Redes Neurales Artificiales (RNAs).

RNAs hacen el abordaje basado en modelos en la cual una red es entrenada para abstraer las ecuaciones generadoras de una serie temporal. Por tanto, en vez de deducir las ecuaciones que describen el comportamiento fundamental del sistema en estudio, es construido un modelo no lineal usando un algoritmo neural de aprendizaje para poder aproximar las ecuaciones ideales. Las redes neurales son atractivas para modelar sistemas no lineales porque ellas son inherentemente no lineales, debido a sus funciones de activación no lineal, Haykin (2001).

Nuestro interés es desenvolver un código computacional fundamentado en redes neurales artificiales, para evaluar la estabilidad de embarcaciones, tanto en mar regular como en mar irregular, Mahfouz (2004), siendo nuestro objetivo principal el de predecir la serie temporal en roll, teniendo como base de datos las series temporales de movimientos acoplados con seis grados de libertad, generados por el código computacional propuesto por Rodríguez (2010), de los cuales solo utilizaremos los movimientos de roll y pitch, para el entrenamiento de la red.

NAVÍO EN ESTUDIO

El navío en estudio es un portacontenedor ensayado por la MARINTEK como parte de un proyecto de la Universidad Técnica de Noruega (NTU). Esta embarcación, aquí denominada de portacontenedor NTU, fue ensayada en ondas regulares e irregulares de proa para diferentes velocidades de avance. Tratase de un navío de grande porte, cuyas formas son caracterizadas principalmente por una larga popa, plana y en balanço, con ángulos de flare de proa pronunciados. Las características principales del navío entrenado son mostradas en la tabla (1), y las formas del navío en la figura (1), vide Rodríguez (2010) para más detalles.

Fueron reproducidas numéricamente las series temporales para las mismas condiciones dadas en los ensayos experimentales, vide Rodríguez (2010). Los coeficientes hidrodinámicos para los seis grados de libertad de este navío, fueron obtenidos con base al software comercial WAMIT, con correcciones para la velocidad de avance aproximadas por la teoría bidimensional de Salvesen *et al.* (1970). Ya las restauraciones hidrostáticas no lineales (que incluyen las acciones no lineales de excitación de la ola), fueron calculados usando la metodología de los coeficientes analíticos, los cuales fueron obtenidos con auxilio de códigos numéricos desenvueltos en FORTRAN por Rodríguez, vide Rodríguez (2010). En su tesis, Rodríguez ha demostrado que su modelo numérico tiene buena capacidad para reproducir las amplificaciones paramétricas registradas en los experimentos realizados por la MARINTEK. Se menciona que el modelo de Rodríguez reproduce no solo condiciones de grande amplificación, como también condiciones sin amplificación. Así, los códigos numéricos desarrollados por Rodríguez, son percibidos como aceptables como herramienta numérica para la generación amplia y rápida de series numéricas, que sirvan al propósito de probar la eficacia de las RNAs en la predicción de la amplificación rápida por resonancia paramétrica.

Tabla 1: Características del navío NTU.

Denominación	Portacontenedor NTU
Eslora total [m]	293.51
Eslora entre perpendiculares [m]	286.00
Manga [m]	32.26
Puntal [m]	24.00
Calado [m]	11.75
Desplazamiento [t]	76582.75
Altura metacéntrica transversal [m]	1.84
Radio de giro transversal* [m]	13.52
Radio de giro longitudinal* [m]	69.44

*Valores en relación al CG del navío

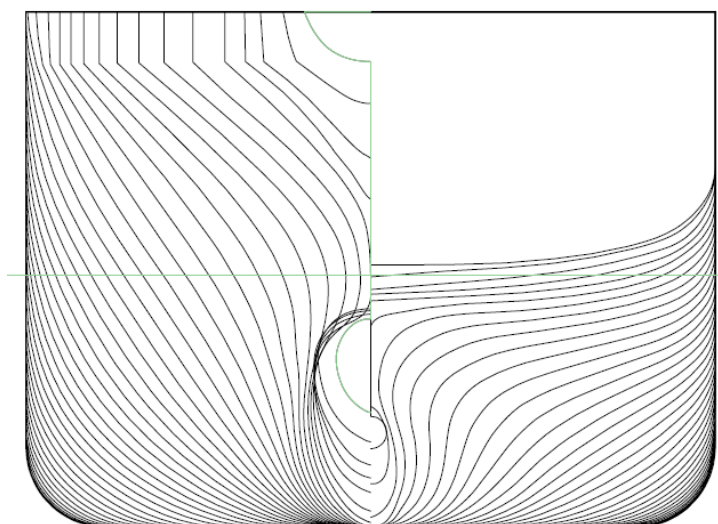


Figura 1: Líneas del portacontenedor NTU.

REDES NEURONALES ARTIFICIALES

La Red Neuronal Artificial (RNA) se basa en el funcionamiento del cerebro, con interés de entender el cerebro humano, simular aspectos de su funcionamiento, y poder desarrollar métodos que posibiliten al computador realizar bien las funciones, como reconocimiento de imágenes, reconocimiento de voz, predicción de series temporales. Un modelo de red neural es descrito como una unidad de procesamiento con una o varias entradas, y una salida que es accionada por medio de funciones de transferencia de entrada para salida, lo que es hecho por medio de conexiones, denominadas sinapsis, siendo estas conexiones ponderadas por pesos, permitiendo obtener funciones matemáticas altamente complejas, aplicables para la solución de diversos problemas prácticos.

Arquitectura de la red

La forma como las neuronas son organizadas en una red neuronal está intrínsecamente ligado al tipo de problema que será solucionado, y es el factor importante para la definición de los algoritmos de aprendizaje utilizados para entrenar la red. Así, una RNA está constituida por neuronas o elementos

procesadores, conectados con pesos asociados a estas. De una forma general, los pesos son los responsables por el almacenamiento del conocimiento de la red.

Las sinapsis son representadas por pesos w_{ij} , los cuales son responsables por la suma ponderada de las entradas x_i , y el núcleo de la célula es representado por una función de activación, usada para comparar las entradas x_i ponderadas por los pesos sinápticos w_{ij} , con el umbral θ_j , y el axón representado por la salida y_j de la neurona. El núcleo es expresado por:

$$y_j = F(u_j) = F\left(\sum w_{ij}x_i - \theta_j\right) \quad (1)$$

donde F es la función de activación de la neurona, w_{ij} son los pesos, $x_i (i = 1, 2, \dots, p)$ son las entradas, θ_j es el umbral de activación del núcleo que define si la salida será disparada, y y_j representa la salida de la neurona.




Figura 2: Modelo básico de la neurona artificial.

Según el tipo de conexión, las redes neuronales pueden ser clasificadas como redes en capas (*feedforward*) y redes recurrentes (*feedback*), esta arquitectura se diferencia por poseer por lo menos un lazo de retroalimentación. En este artículo, vamos trabajar con una red feedforward.

Redes Feedforward

Para ser considerado feedforward, el procesamiento se debe dar en sentido único, de entrada para la salida de la red, sin retroalimentación, en la cual las salidas se conecten solamente con las unidades de la próxima capa.

La red neuronal de capa única, conocida por perceptron, tiene el poder de aproximación relativamente limitada. El apareamiento del algoritmo de aprendizaje backpropagation, expandió las posibilidades de aplicación de perceptrons para el caso de múltiples capas (dando origen al perceptron de múltiples capas – MLP), figura (3). El potencial de aproximación de una MLP es bastante aceptado por el hecho de que esa red es un aproximador no lineal de funciones continuas y definidas en una región compacta, Timoszczuk (2004).

Básicamente, se puede definir una MLP como una red con una capa de entrada, una o más capas intermedias (u ocultas) y una capa de salida.




Figura 3: Arquitectura de una red perceptron de múltiples capas (MLP).

Retropropagación (Backpropagation)

El algoritmo de aprendizaje por retropropagación de error (backpropagation) es un método de estimación de los pesos sinápticos de una red feedforward de múltiples capas. El objetivo del algoritmo nada más es de minimizar la suma del error cuadrático medio; este tipo de red presenta soluciones para funciones linealmente no separables y necesita de un algoritmo de entrenamiento capaz de definir de forma automática los pesos. Que opera en una secuencia de dos pasos, en el primero, un patrón es presentado a la capa de entrada de la red, la señal resultante fluye a través de la red, capa por capa, hasta que la respuesta sea producida por la capa de salida. En el segundo paso la salida obtenida es comparada a la salida deseada para ese patrón particular. Si esta no está correcta, el error es calculado. Este error es propagado a partir de la capa de salida hasta la capa de entrada, y los pesos de las conexiones de las unidades de las capas internas van siendo modificados a medida que el error es retropropagado.

Teniendo como conjunto de entrenamiento, los datos de entrada y su posición respectiva de salida, los cuales son usados para entrenar la red durante la fase en que la red está aprendiendo un nuevo problema. Compuesto por un vector x con n entradas y un vector de salida exacto y_{ek} .

$$Y = \{x_k, y_{ek}\} \quad k=1, \dots, n \quad (2)$$

Se puede definir el error cuadrático medio sobre la ecuación (2):

$$E_R = \frac{1}{n} \sum_{k=1}^n (y_k - y_{ek})^2 \quad (3)$$

donde y_k es la salida generada por la red, y y_{ek} es el valor exacto correspondiente a la salida de la red. Pudiendo ser una expresión en funciones de los pesos, como se presenta. La ecuación (3) es de la forma de una función objetiva de un problema de optimización donde se desea minimizar E_R y cuyas variables son los pesos W_{ij} . El algoritmo de retropropagación implementado en el toolbox del software Matlab puede utilizar diferentes métodos de optimización. Para resolver este problema, utilizaremos el método de Levenberg-Marquardt, ecuación (4), que usa la matriz jacobiana como

aproximación de la hessiana con finalidad de balancear costo y eficiencia. Este último sugiere que los pesos sean ajustados según la expresión.

$$W(n+1) = W(n) - [J^T(n)J(n) + \lambda I]^{-1} J^T(n)e(n) \quad (4)$$

donde: I es la matriz identidad; λ es la constante del método de Levenberg-Marquardt.

n Número de iteración; J Matriz jacobiana de los errores en relación a los pesos sinápticos.

W(n+1) Matriz columna de pesos sinápticos que serán utilizados en la próxima iteración n+1;

W(n) Matriz columna de pesos sinápticos en la iteración n;

e(n) Matriz columna de error en la iteración n;

PROPUESTA DEL TRABAJO

Nuestra propuesta es aprovechar las ventajas de las RNAs para poder predecir el comportamiento del navío, plataformas, y de otros artefactos fluctuantes, por medio de estudio de las series temporales en roll, de manera similar a como propusieron Xing and McCue (2009) para la predicción del roll en olas de través. Con énfasis en la detección de procesos dinámicos de amplificación del movimiento de roll de navíos en condiciones de resonancia paramétrica, como usado por Miguez et al. (2010), que ha usado puramente series de roll como datos de entrenamiento. Considerando en algunas situaciones la resonancia paramétrica como una amplificación muy rápida, el uso de redes neuronales entrenadas aparece como un método eficaz para prevenir y corregir el posible apareamiento de la resonancia paramétrica, Bellec (2010), Galeazzi (2009).

Primero el entrenamiento de la red neuronal se hará solamente con datos de la serie temporal de roll, y después con el coeficiente de Fourier de pitch, para entrenar la red conjuntamente con roll. Los resultados obtenidos hasta ahora son para condiciones de mar regular, entrenando la red neuronal con series temporales de un navío específico. La red desarrollada será una red feedforward con algoritmo de retropropagación, y con método de optimización de Levenberg-Marquardt, conforme fue realizado por Bellec et al. (2011). La red consta de una capa inicial (entrada) y dos capas intermediarias (capas ocultas) de 50 neuronas cada una, con una función de activación tangente hiperbólica, y una capa de salida con función de activación lineal.

La información adicional de los datos de pitch pasa por el procesamiento de señales. $F_{w,s}(x)$ es el valor medio de Windowed Fourier Transform (WFT) de pitch descrito en la ecuación (5), que también es conocida como Transformada de Fourier de Corta Duración:

$$F_{w,s}(x) = \frac{1}{n} \sum_{i=1}^n \left(\int_R e^{-i\omega t} w(t - \xi_1) x(t) dt \right) \quad (5)$$

Donde WFT es la transformada de Fourier para analizar apenas una pequeña parte de la señal, la cual nos da información sobre el intervalo y la frecuencia, de un evento dado de una señal. Este método propone multiplicar la señal $x(t)$ por una ventana $w(t)$ no cero únicamente en el intervalo de tiempo en análisis antes del cálculo de la transformada de Fourier. La variación del parámetro ξ_1 define la localización del intervalo en interés, pudiendo así ser realizado el desplazamiento de la ventana, hasta completarse el análisis en toda la señal $x(t)$.

En la figura (4) se muestra el esquema que estamos proponiendo, la serie temporal de roll y la serie temporal de pitch, que pasa por la WFT, como datos de entrada. Las series temporales servirán para entrenar la red neuronal, formando la capa de entrada, luego, consta de dos capas ocultas, con

función de activación tangente hiperbólica, y al final se tiene una capa de salida con función de activación lineal, teniendo como señal de salida la predicción de la serie temporal de roll. Los datos entrenados son para una faja amplia de la amplitud de la ola (A_w) y para una frecuencia de la ola (ω_w).

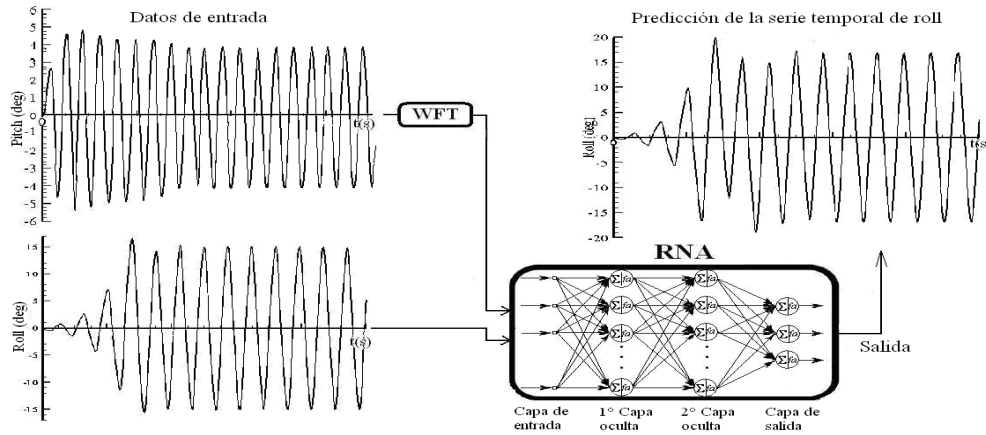


Figura 4: Red neuronal utilizada para obtener la predicción de roll con los datos de entrada, serie temporal de roll e información de la frecuencia de pitch.

A seguir una predicción de una serie temporal de roll; el entrenamiento de la RNA fue hecho para el navío portacontenedor NTU, con $GM=1.84$ m, $F_n=0.1022$, $T_w=13.54$ s, $\chi=180$ (mar de proa), ω_w constante e igual a 0.4764 rad/s, $\omega_e = 0.5844$ rad/s, $\omega_n = 0.294$ rad/s, que corresponde a una sintonía $\omega_e / \omega_n = 1.9877$, y A_w variando de 0.2 m a 5.75 m, conformando 21 datos de entrada. La serie temporal predicha es para $A_w=2.0$ m, para una predicción de 100 segundos, red con dos capas escondidas de 10 neuronas cada una y una capa de salida. En la figura (5) se muestra la comparación, considerando como dado de entrada apenas roll (predicción clásica), y la otra considerando las series temporales de roll y pitch (WFT de pitch), (predicción de Fourier). En la predicción de Fourier se tiene un buen acompañamiento durante toda la serie temporal, mejorando considerablemente el deficiente acompañamiento en las crestas de la predicción clásica.

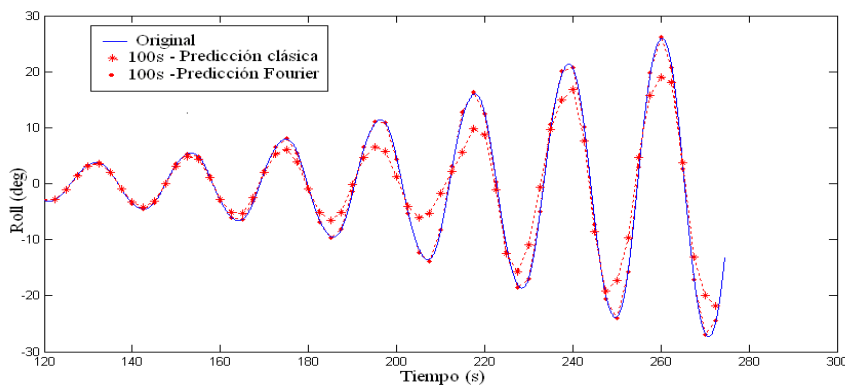


Figura 5: Predicción de serie temporal de roll, entrenada sin y con a WFT de pitch. Para $A_w=2.0$ m, y $\omega_e / \omega_n = 1.9877$.

RESULTADOS

Tabla 2: Series usadas para el entrenamiento de la RNA.

Serie Temporal	Aw (m)	Serie para entrenar	Serie para predicción
CS1170	0.25	X	
CS1171	0.5	X	
CS1172	0.75	X	
CS1173	1	X	
CS1174	1.25	X	
CS1175	1.5		X
CS1176	1.75	X	
CS1177	2	X	
CS1178	2.025	X	
CS1179	2.5	X	
CS1180	2.75		X
CS1181	3	X	
CS1182	3.25	X	
CS1183	3.5	X	
CS1184	3.75	X	
CS1185	4		X
CS1186	4.25	X	
CS1187	4.5	X	
CS1188	4.75	X	
CS1189	5	X	
CS1190	5.25	X	

En la tabla (2) son identificadas 21 series temporales (seis grados de libertad) obtenidas con el código numérico presentado por Rodríguez (2010), para el navío portacontenedor NTU, con: $GM=1.84$, $\omega_w=0.4893$ rad/s, $F_n=0.1022$, $T_w=12,48s$, $\xi=180$, con $\omega_e=0.6232$ rad/s, $\omega_n=0.294$ rad/s, que corresponde a una sintonía $\omega_e / \omega_n=2.1196$, y variando los valores de Aw. Las series que están en color negro, son las series que fueron usadas para entrenar la red, y las series temporales que están en color rojo, fueron usados para hacer la comparación con las series temporales que fueron predichas por la red neuronal.

Predicción de la serie CS1175: para una amplitud de ola Aw=1.5m, caso con no fuerte amplificación; fueron realizados con tres tiempos diferentes de predicción, 50, 100, 150 segundos, y que serán detallados en los siguientes gráficos.




Figura 6: Predicción de la serie CS1175, Aw=1.5m, con 50 segundos.

En la Figura (6) se muestra que la red neuronal con 50 segundos de tiempo de predicción hace un buen acompañamiento de la serie temporal original (generada por simulación numérica) desde el inicio hasta el fin, excelente predicción debido principalmente porque la serie temporal es bien

comportada, presentando valores pequeños de roll, por lo cual se puede ver que la serie original y la serie de la predicción para roll son prácticamente las mismas.




Figura 7: Predicción de la serie CS1175, $A_w=1.5m$, con 100 segundos.

Predicción de la serie CS1175, con 100 segundos de tiempo de predicción: figura (7). Ahora para esta serie se puede ver que la predicción de la serie temporal en roll, no consigue acompañar bien la serie temporal original al inicio, diferencia considerable para valores de la amplitud de roll, pero luego, aproximadamente a los 300 segundos, las dos series se van sobreponer, teniendo una buena predicción hasta el final de la serie temporal.




Figura 8: Predicción de la serie CS1175, $A_w=1.5m$, con 150 segundos.

Predicción de la serie CS1175, con 150 segundos de tiempo: figura (8). Debido al largo intervalo de tiempo de actualización de datos originales, la predicción de la serie temporal no consigue acompañar tanto en el inicio como al final del tiempo de la serie original, presentando valores levemente inexactos para la predicción de los valores de la amplitud en roll en todo el intervalo de la serie temporal.

Predicción de la serie CS1180, para una amplitud de ola $A_w=2.75m$, grande amplificación: para esta serie temporal la predicción de la red neuronal hace una buena aproximación con referencia a la serie temporal original para los tres tiempos de predicción, presentándose una amplificación rápida de roll, aumentando en 20 grados de los 500 segundos a los 600 segundos (en 4 periodos), hasta valores próximos a 30 grados. Figuras (5,4), (5,5), (5,6).




Figura 9: Predicción de la serie CS1180, $A_w=2.75 m$, con 50 segundos.

Predicción de la serie CS1180, con 50 segundos de tiempo: figura (9), la serie original y la serie de predicción están sobrepuestas, la red hace una óptima predicción para la serie temporal que es bien comportada. El aprendizaje de la serie temporal es muy bueno tanto en los picos como en los valles.

Predicción de la serie CS1180, con 100 segundos de tiempo: figura (10), la red también hace una buena predicción, debido a que el comportamiento de la serie temporal es muy suave. Pequeñas diferencias en los picos.




Figura 10: Predicción de la serie CS1180, $A_w=2.75$ m, con 100 segundos.




Figura 11: Predicción de la serie CS1180, $A_w=2.75$ m, con 150 segundos.

Predicción de la serie CS1180, con 150 segundos de tiempo: figura (11), no presenta mucha diferencia en comparación de los demás tiempos de predicción. Buena predicción.

Predicción de la serie CS1185, para una amplitud de ola $A_w=4.0$ m: para esta serie temporal, la predicción consigue acompañar satisfactoriamente la serie original, con pequeñas diferencias en el inicio de la serie temporal; se presenta una amplificación de roll de 0 a 20 grados de 600 s, a 800 s, (9 periodos). Figuras (12), (13), (14).




Figura 12: Predicción de la serie CS1185, $A_w=4.0$ m, con 50 segundos.

Predicción de la serie CS1185, con 50 segundos de tiempo: figura (12), la red neuronal hace una buena aproximación de la serie temporal original en todo el intervalo de la serie.

Predicción de la serie CS1185, con 100 segundos de tiempo: figura (13), también no presenta cambios con respecto a la predicción con 50 segundos. Buena aproximación, pequeña diferencia en los picos a partir de los 900 s.




Figura 13: Predicción de la serie CS1185, $A_w=4.0$ m, con 100 segundos.




Figura 14: Predicción de la serie CS1185, $A_w=4.0$ m, con 150 segundos.

Predicción de la serie CS1185, con 150 segundos de tiempo: figura (14), la predicción acompaña satisfactoriamente la serie original hasta los 800 s, presenta diferencias considerables en los picos de 800 s a 900 s.

CONCLUSIONES

Las RNAs son buenas herramientas para auxiliar a los especialistas en la toma de decisiones. En el caso de los navíos es importante conocer las posibles respuestas de estos y las consecuencias a la que podrían llevar estas respuestas no deseadas, como es el caso de la resonancia paramétrica. Por tanto, es importante la previsión del movimiento del navío, y así poder tomar las medidas correctivas. En este contexto, surgen las RNAs como una tecnología para prever la serie temporal y trazar nuevas alternativas para aplicaciones reales, en especial para sistemas inteligentes a bordo.

En la figura 5 es mostrada la importancia de considerar la WFT de pitch como dato de entrada de la red neuronal conjuntamente con los datos de roll, debido a que se tiene una mejora considerable en la predicción de la serie temporal para roll, haciendo un mejor acompañamiento de la serie temporal en los picos. Todos los demás resultados fueron entrenados considerando la WFT de pitch como dato de entrada, conjuntamente con los datos de las series temporales de roll, debido a esa mejor predicción de la red neuronal artificial.

De los resultados obtenidos para el caso donde ω_w es constante y variando A_w para el navío NTU en condiciones de mar regular, se puede concluir que la determinación de una RNA para diferentes intervalos de predicción es una buena herramienta a ser utilizada en la predicción de la serie temporal de roll. El aprendizaje de la RNA depende mucho del tipo de comportamiento de las series temporales usados para el entrenamiento.

En los casos analizados en este trabajo se confirma que, siendo el período natural de roll del buque igual a 21,4 segundos, las buenas predicciones obtenidas para más de 86 segundos ofrecen más de cuatro periodos de oscilación para una toma de decisión. Esos cuatro períodos son considerados como el umbral de tiempo mínimo necesario para mensurar la eficacia de un modelo de previsión. Por tanto, las buenas previsiones obtenidas para fuertes amplificaciones en hasta 150 segundos son indicadores de que las RNAs, siendo bien entrenadas, son algoritmos rápidos y poderosos para resolver el problema de detección de amplificación paramétrica.

El método presentado puede ser extendido para aplicaciones de RNAs para la predicción de series temporales de roll de un navío en estudio para condiciones de mar irregular, que sería nuestro objetivo futuro, visto que son las condiciones reales en la cual navega un navío.

RECONOCIMIENTOS

Los autores expresan su reconocimiento al importante soporte financiero aportado por ANP, COPPE/UFRJ y CNPq.

REFERENCIAS

- Bellec, J.-R., 2010, Parametric Rolling of a Containership Hull, Real-Time prediction Using Neural networks and a Differential Equation Model. Research Report, Ecole Polytechnique/COPPE UFRJ, Rio de Janeiro, RJ, Brasil.
- Bellec, J.-R., Neves, M. A. S., Rodríguez, C. A., 2011, “An Investigation on Parametric Rolling Prediction Using Neural Networks”. International Maritime Association of the Mediterranean (IMAM 2011), Genoa, Itália.
- Galeazzi, R., 2009, Autonomous Supervision and Control of Parametric Roll Resonance. Thesis PhD, Department of Electric Engineering, Technical University of Denmark
- Gheyas, I. A, Smith, L. S., 2009, A Neural Network Approach to Time Series Forecasting Proceedings of the World Congress on Engineering Vol. II (WCE 2009), July 1-3, London, U.K.
- Haykin, S., 2001, Redes Neurais, Princípios e Prática, 2 ed. São Paulo, Brasil, Bookman.
- Mahfouz, A. B., 2004, “Identification of the Nonlinear Ship Rolling Motion Equation Using the Measured Response at Sea”, Ocean Engineering, v. 31, pp.2139-2156.
- Míguez, N., Pena, F, Casas, V., e Neves, M., 2010, “An Artificial Neural Network Approach for Parametric Rolling Prediction.”, In PRADS Conference, September, Rio de Janeiro, Brazil.
- Rodríguez, C. A., 2010, Sobre a Dinâmica Não Linear do Balanço Paramétrico. Tese D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- Salvesen, N., Tuck, O. E., Faltisen, O., 1970, “Ship Motions and Sea Loads”, Transactions of SNAME, v. 78, pp. 250-287.
- Svarer, C., 1994, Neural Networks for Signal Processing., PhD thesis, Electric Institute, Technical University Denmark.
- Timosczuk, A. P., 2004, Reconhecimento Automático do Locutor com Redes Neurais Pulsadas., Tese D.Sc., USP, São Paulo, SP, Brasil.
- Xing, Z., McCue, L., 2009, “Parameter Identification for two Nonlinear Models of Ship Rolling Using Neural Networks”. Proc. 10th Int. Conf. on Stability of Ships and Ocean Vehicles STAB 2009, St.Petersburg, Russia.