

## MODELO PREDICTIVO NEURO-BORROSO DE LA ACELERACIÓN DE CABECEO DE UN BUQUE DE ALTA VELOCIDAD

M. Santos, R. López, J. M. de la Cruz

*Departamento de Arquitectura de Computadores y  
Automática  
Universidad Complutense de Madrid*

Resumen: Mediante técnicas de Inferencia Borrosa Neuro-Adaptativa se ha obtenido un modelo predictivo de la aceleración de cabeceo de un buque de alta velocidad, a partir de datos que provienen de experimentos con olas reales en mares de proa. El modelo se describe mediante Sistemas de Inferencia Borrosa y predice, conociendo el valor de la elongación de la ola en  $n$  instantes anteriores, el valor de la aceleración de cabeceo, parámetro que caracteriza el movimiento vertical del barco. El modelo inicial se ha mejorado buscando valores óptimos de  $n$  mediante técnicas de entrenamiento neuro-borroso. El modelo se ajusta satisfactoriamente a los datos y refleja correctamente el comportamiento dinámico del sistema marino. *Copyright © 2005 CEA-IFAC.*

Palabras clave: Modelado Neuro-Borroso, Sistemas Marinos, Movimiento Vertical, Buques de Alta Velocidad

### INTRODUCCIÓN

Como consecuencia del empleo de materiales ligeros y sistemas de propulsión cada vez más potentes, el desarrollo de buques de alta velocidad (HSC: High Speed Craft) está experimentando un gran crecimiento en la actualidad.

Las altas velocidades de navegación propias de los ferries hacen que se generen grandes aceleraciones verticales, que pueden incrementar la fatiga de la tripulación con el consiguiente riesgo para la seguridad del vehículo y, además, producir los efectos indeseados del mareo, comprometiendo el confort de los pasajeros y tripulación. (ISO, 1985), (O'Hanlon, 1974).

Una de las posibles estrategias para disminuir estas aceleraciones verticales es dotar al ferry de actuadores o superficies de control que, gobernados por un controlador adecuado, varíen el ángulo

de ataque que presentan al mar en su avance, generando así un momento de sentido opuesto al originado por las fuerzas verticales que actúan sobre el barco.

Es decir, se ha definido un problema de control en este ámbito marino que consiste en el amortiguamiento de las aceleraciones verticales. Para llevar a cabo el diseño, la evaluación y verificación de los controladores, es necesario desarrollar modelos orientados al control de la dinámica del buque y de las perturbaciones.

Este trabajo presenta un tipo de modelo neuro-borroso del comportamiento del barco y los métodos para su obtención. El modelo predice el valor de la aceleración vertical de cabeceo, a partir del conocimiento de los valores anteriores de un grupo de variables observables (olas).

El problema que se quiere abordar es complejo, con una dinámica fuertemente no lineal que de-

pende del entorno, que a su vez está sujeto a cambios (estado de la mar, viento, masa añadida, etc.), y de cuyo comportamiento no se poseen los conocimientos de un experto. Sin embargo, mediante técnicas de aprendizaje y entrenamiento neuronales, a partir de datos experimentales y de simulación se puede extraer información sobre su funcionamiento. Estas características justifican sobradamente el empleo de la Lógica Borrosa que ya ha demostrado ser muy eficaz en el modelado de sistemas de este tipo.

Aunque el modelado de la aceleración de cabeceo se ha abordado desde distintos enfoques, en el modelo aquí propuesto se aplican por primera vez técnicas neuro-borrosas para su obtención. El modelo generado tiene la ventaja de que se puede aplicar en un amplio rango de condiciones de navegación. Otros modelos propuestos en la literatura consisten en la combinación de modelos diferentes –lineales en la mayoría de los casos– para cada punto de operación (longitud de onda, velocidad del barco, etc). Así por ejemplo, en Andrés *et al.* (2000) se propone un modelo descrito por una función de transferencia diferente para cada velocidad del barco; de igual forma, en Cruz *et al.* (1998) se aplican técnicas de identificación y se obtienen modelos ARX de bajo orden con diferente estructura según el estado de la mar y la velocidad. También Aranda *et al.*, (2000a y 2000b) define modelos lineales con distintas estructuras según sea la velocidad del barco, como en Cruz *et al.* (1999). En estos trabajos se basa Esteban *et al.* (2000) al diseñar un entorno de simulación que selecciona un modelo u otro según las condiciones de navegación.

En la sección 1 se describe el conocimiento sobre la dinámica del sistema. En la 2 se presenta el diseño del modelo y los parámetros de su evaluación. En la sección 3 se explican las posibles mejoras que se han aplicado y se exponen los resultados. Las conclusiones finales resumen las principales aportaciones.

## 1. NOMENCLATURA Y DINÁMICA DEL SISTEMA MARINO

Para abordar el estudio del movimiento de sistemas marinos puede ser conveniente presentar brevemente la notación y descripción de los términos de este ámbito que aparecen en este trabajo. Se ha seguido la notación y sistemas de referencia usados para describir el movimiento de vehículos marinos que se presenta en (Fossen, 1994).

Además, aunque se utilicen las técnicas neuro-borrosas en la obtención del modelo, realizar un análisis previo de las ecuaciones del movimiento del sistema de navegación permite conocer la

forma de su solución dinámica y algunos datos característicos de la misma, y poder así evaluar los resultados del modelo.

### 1.1 Olas: Estados de la mar

A lo largo del artículo se habla frecuentemente de olas reales y regulares. Las olas regulares son señales sinusoidales que se caracterizan por su altura,  $H$ , y su longitud de onda,  $\lambda$ . Por el contrario, la mar real (olas reales) está formada por una combinación de olas regulares y resulta irregular y cambiante, aunque se puede observar que hay una frecuencia “dominante”: la frecuencia modal del espectro,  $\omega_0$ . En la figura 1 las tres series de arriba corresponden a olas regulares mientras que la de abajo es una serie de olas reales resultado de la superposición de las otras tres.

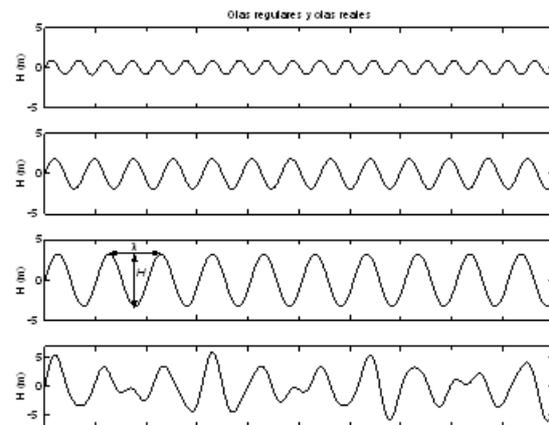


Figura 1. Olas regulares y olas reales

Una magnitud observable que sirve para caracterizar una serie de olas reales es su altura significativa o promedio de las alturas de las olas grandes, representada como  $H_{1/3}$ ; es decir, de todas las olas presentes, el tercio de las que son más altas.

En la representación espectral de Pierson-Moskowitz la frecuencia modal puede obtenerse a partir de la altura significativa mediante la expresión (Fossen, 1994):

$$\omega_0 = 0.4 \sqrt{\frac{g}{H_{1/3}}} = \frac{1.2526}{\sqrt{H_{1/3}}} \quad (1)$$

donde  $\omega_0$  es la frecuencia modal del espectro,  $H_{1/3}$  la altura significativa de las olas y  $g$  la aceleración de la gravedad.

Es importante hacer notar que una serie de olas reales es prácticamente irrepetible, por lo que a efectos de generalizar conclusiones, cualquier resultado que se obtenga con una serie debería comprobarse con otra distinta.

Según la altura significativa del oleaje, la Organización Meteorológica Mundial clasifica los posibles estados de la mar de acuerdo con la tabla 1, con un índice Estado de la mar "EM" que va de 1 a 9. La frecuencia modal de las olas,  $\omega_0$ , se ha estimado con (1).

EM	Olas					
	$H_{1/3}$ (m)			$\omega_0$ (rad/s)		
	Min	Max	Med	Min	Max	Med
0	-	-	-	-	-	-
1	0.00	0.10	0.05	3.96	-	5.60
2	0.10	0.50	0.30	1.77	3.96	2.29
3	0.50	1.25	0.88	1.12	1.77	1.34
4	1.25	2.50	1.88	0.79	1.12	0.91
5	2.50	4.00	3.25	0.63	0.79	0.69
6	4.00	6.00	5.00	0.51	0.63	0.56
7	6.00	9.00	7.50	0.42	0.51	0.46
8	9.00	14.00	11.50	0.33	0.42	0.37
9	14.00	-	14.00	-	0.33	0.33

Tabla 1. Estados de la mar

### 1.2 Frecuencia de Encuentro

Un parámetro significativo para describir el movimiento de un barco es la denominada frecuencia de encuentro. Es aquella con la que se encuentran las olas y el buque (figura 2).

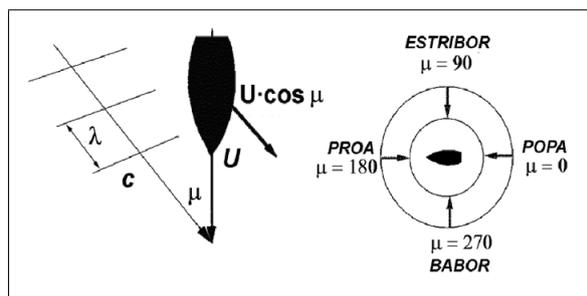


Figura 2. Elementos de la frecuencia de encuentro

Viene definida por la siguiente ecuación (Lloyd, 1989):

$$\omega_e = \omega_0 - \frac{\omega_0^2}{g} \times U \times \cos \mu \quad (2)$$

donde  $\omega_e$  es la frecuencia de encuentro,  $\omega_0$  es la frecuencia de la ola o frecuencia modal,  $U$  es la velocidad del barco,  $g$  es la aceleración de la gravedad y  $\mu$ , denominado *rumbo proa-olas*, es el ángulo relativo a la dirección de propagación de un tren de olas regulares (figura 2).

Analizando la frecuencia de encuentro para distintas velocidades del barco,  $\omega_e$  es en general positiva, pero en el caso de mares de popa pueden obtenerse valores negativos para velocidades mayores de 20 nudos y frecuencias modales altas. En estos casos es el mar el que alcanza al barco y no al revés. (figura 3)

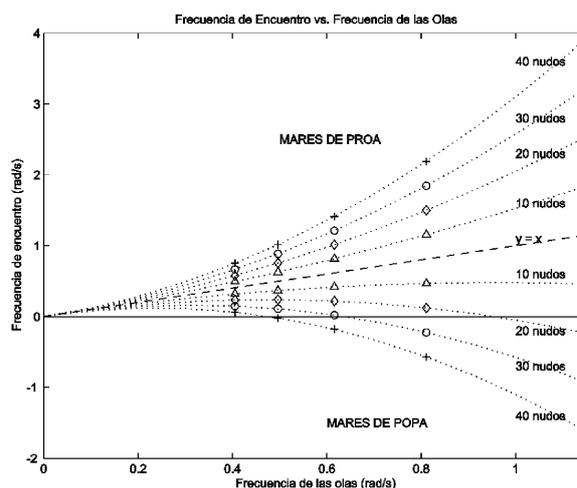


Figura 3. Análisis de  $\omega_e$  para distintas velocidades y frecuencias modales

### 1.3 Dinámica del sistema

El movimiento de un barco se puede estudiar como el de un sólido rígido con seis grados de libertad: tres traslaciones y tres rotaciones. Además de la propulsión del motor, las fuerzas y momentos que actúan sobre el barco son debidos a su propia inercia, a la inercia de la masa añadida, al amortiguamiento hidrodinámico, a las fuerzas de restauración, y también a elementos del entorno como la acción de las olas, el viento y las corrientes marinas. El sistema de ecuaciones que describe las características del movimiento es (Lloyd, 1989):

$$\sum_{j=1}^6 \left( A_{i,j} \frac{d^2 x_j}{dt^2} + b_{i,j} \frac{dx_j}{dt} + c_{i,j} x_j \right) = F_{\omega_{0i}} \times \text{sen}(\omega_e t + \gamma_i) \quad (i = 1, \dots, 6) \quad (3)$$

donde los coeficiente no son constantes ya que dependen de la frecuencia de las olas, de la velocidad del barco y de la forma del casco. Los coeficientes  $A_{ij}$  son la suma de la masa o inercia del vehículo ( $m_{ij}$ ) y la masa o inercia añadida ( $a_{ij}$ ), y dependen además, del ángulo *rumbo proa-olas*. Los coeficientes  $b_{ij}$  corresponden al amortiguamiento hidrodinámico y los  $c_{ij}$  a las fuerzas de sustentación.

Se puede comprobar que para el movimiento vertical de cabeceo la solución del sistema es una función sinusoidal:

$$x_5(t) = x_{50} \text{sen}(\omega_e t + \varphi_5)$$

donde  $x_{50}$  es la amplitud máxima del movimiento de cabeceo y  $\varphi_5$  la diferencia de fase.

Una característica importante de este movimiento es la frecuencia natural de oscilación del sistema que se puede estimar de forma aproximada cómo:

$$\omega_* = \sqrt{\frac{c_{55}}{a_{55}}} \quad (4)$$

dónde  $a_{55}$  se obtiene a partir de la frecuencia natural de oscilación sin amortiguamiento (Lloyd, 1989):

$$\omega_{0*} = \sqrt{\frac{c_{55}}{m_{55}}} \quad (5)$$

## 2. MODELO

La obtención de un modelo general de la dinámica de un buque es un objetivo ambicioso ya que es una tarea muy compleja.

Aunque hasta ahora se han hecho valiosos esfuerzos para obtener modelos mediante diferentes métodos (de Andrés, 2000), (Aranda, 2000a), (Aranda, 2000b), las soluciones se han logrado mediante aproximaciones fruto de hipótesis simplificadoras y no son generales. Se habla así de modelos para estado de la mar 5 y velocidad 40 nudos, por ejemplo, que no representan bien al sistema en otras condiciones de navegación. El problema sigue pues abierto.

En este artículo se van a usar técnicas neuro-adaptativas para obtener un modelo válido para cualquier estado de la mar y toda la gama de velocidades y *rumbos proa-olas*. El modelo es general en el sentido de que no se imponen simplificaciones para su obtención y se ha podido comprobar su validez para todos los experimentos disponibles, que se encuentran indicados en la tabla 2. Es decir, el mismo modelo representa bien los datos experimentales de muy distintas condiciones de navegación.

### 2.1 Datos

La investigación se ha centrado en un buque de alta velocidad llamado "Silvia Ana" (figura 4). Actualmente el "Silvia Ana" navega en el mar del Plata y en el mar Báltico. Es un barco monocasco construido en aluminio con dimensiones: 119 m de eslora, 14,696 m de manga y 2,405 m de calado, con 475 toneladas de peso muerto. Puede trasladar 1.250 pasajeros (Anonymous, 1996), (Anonymous, 1998).

El conocimiento requerido para la obtención del modelo borroso del ferry se extrae mediante técnicas de Inferencia Borrosa Neuro-Adaptativa a partir de un conjunto de datos obtenidos en experimentos realizados con una réplica a escala 1/25 del barco.



Figura 4. El buque "Silvia Ana"

Estos datos experimentales han sido proporcionados por el Canal de Experiencias Hidrodinámicas de El Pardo (CEHIPAR) (Cehipar, 2005).

Cada experimento o *carrera* consiste en medir mediante una serie de sensores varias variables (altura de la ola, aceleraciones y elongaciones de arfada y cabeceo, etc.) en diversos puntos de la réplica, mientras ésta navega a lo largo de un canal de 150 m de longitud y 5 m de profundidad, con una serie de olas reales de frecuencia modal conocida y a una velocidad constante, también conocida. El generador de olas irregulares del canal permite obtener longitudes de onda para estados de la mar 4, 5 y 6 según el espectro de JONSWAP. Las medidas se realizaron con un periodo de 0.25 segundos. El canal proporciona también un software específico para adquisición de datos que permite registrar y procesar las medidas. Para una información más detallada sobre los experimentos se puede consultar la página web del CEHIPAR.

Debido a la longitud limitada del canal, el número de muestras tomadas de cada variable se reduce al aumentar la velocidad de navegación de la réplica. Concretamente se dispone de datos para los siguientes experimentos, todos con olas de proa (*rumbo proa-olas 180°*):

EM	U (nudos)	Medidas
4	20	922
4	30	527
4	40	309
5	20	922
5	30	527
5	40	309
6	20	922
6	30	527
6	40	309

Tabla 2. Experimentos con olas reales

Además de éstos experimentos realizados en el canal con olas irregulares se dispone de un conjunto de datos procedentes de simulaciones realizadas con trenes de olas regulares, que han sido procesados mediante el programa de computación *Precal*, basado en elementos finitos (Cehipar, 1998). A partir de esta información se han podido extraer los valores de la masa añadida (coeficientes  $a_{ij}$ ) que se utilizan más adelante.

Tanto los datos resultantes de experimentos reales como los de simulación con *PreCAL* está descritos en (Aranda, 1999), y componen el conjunto de datos a los que se van a aplicar las técnicas neuroborrosas para obtener el modelo.

## 2.2 Obtención del modelo

La forma de las señales de elongación, aceleración, y fuerza o momento de arfada y cabeceo, dependen de las olas y de la velocidad del barco. Para una velocidad constante es lógico pensar que estas señales dependen exclusivamente de las olas. En otras palabras, la aceleración de cabeceo que sufre el barco a una velocidad de navegación constante  $U$  en un instante determinado  $t$  depende de cómo han sido las olas en  $n$  instantes anteriores medidos en intervalos de tiempo constantes  $\Delta t$ .

Una reformulación del problema puede ser:

$$\begin{aligned} \text{variable}(t) &= f(\text{ola}(t - n \times \Delta t), \dots, \\ &\quad \text{ola}(t - (n - 1) \times \Delta t), \text{ola}(t - \Delta t)) \end{aligned}$$

donde la variable que se quiere predecir (aceleración de cabeceo en este caso) puede expresarse como una función desconocida  $f$  del valor de la elongación de la ola en  $n$  instantes anteriores, donde  $n$  es también una incógnita.

El problema se reduce a obtener qué valores de  $\Delta t$  y  $n$  permiten predecir de la mejor manera el valor de la variable. Es decir, se desea definir un espacio de entradas adecuado para establecer una correspondencia a un espacio de salidas mediante un Sistema de Inferencia Borrosa.

Inicialmente se hicieron pruebas trabajando con  $n = 4, 6$  y  $8$  muestras inmediatamente anteriores al instante en que se quería prever el valor de la aceleración, utilizando  $\Delta t_e = 0.25$  s, periodo de muestreo de los experimentos; los resultados no fueron del todo satisfactorios. Se decidió entonces establecer un criterio para determinar el número de medidas de elongación de las olas a tener en cuenta. Se optó por el siguiente:

- (1) El intervalo de predicción,  $[0, n \times \Delta t]$ , debe cubrir, en el peor caso, el ciclo completo de una ola.
- (2) Además,  $n$  debe ser el menor entero posible para obtener un modelo eficiente desde el punto de vista computacional.

El primer criterio conduce a:

$$\Delta t = \frac{2\pi}{n \times \omega_0} \quad (6)$$

En cuanto a minimizar  $n$ , tras varias pruebas se halló que para determinar razonablemente una ola

real se necesitan al menos 9 puntos para describir bien su perfil.

Analizando la tabla de estados de la mar (tabla 1) se puede concluir que, para el rango de experimentos disponibles (estados de la mar 4 al 6), la menor frecuencia que se puede encontrar se da en el estado de la mar 6, con olas entre 4 y 6 metros de altura significativa. El valor de frecuencia modal en ese caso es de  $\omega_0 = 0.45$  rad/s, por lo que aplicando (6) se obtiene

$$\Delta t = \frac{13.96}{n} \quad (7)$$

Con  $n = 9$  se obtiene  $\Delta t = 1.55$  s. Como los valores se han calculado para olas con estado de la mar 6, eso significa que en este caso extremo se observará una única ola. Pero, por ejemplo, para estado de la mar 4 la observación alcanzará a más de una ola.

Dado que el periodo de muestreo de los experimentos es  $\Delta t_e = 0.25$  s, se elige un múltiplo para el valor  $\Delta t = 1.50$  s y  $n = 10$ .

## 2.3 Estructura del modelo

Por lo tanto, para generar el modelo predictivo hay que construir un Sistema MISO de Inferencia Borrosa con 13 variables de entrada que corresponden a: la frecuencia modal,  $\omega_0$ ; la velocidad del barco,  $U$ ; el rumbo proa-olas,  $\mu$ ; y las últimas 10 medidas de la elongación de la ola tomadas a intervalos de 1.5 s. La variable de salida es el valor de la aceleración de cabeceo.

La configuración utilizada para el sistema borroso tipo Sugeno es la siguiente: el producto para implementar la intersección, la función *probor* para la unión, el mínimo para la implicación, el máximo para la agregación y la media ponderada para la conversión final de la salida borrosa a un número concreto.

En este tipo de sistemas, las reglas se evalúan como

$$\text{si } x \text{ es } \mathbf{A} \text{ y } z \text{ es } \mathbf{B} \text{ entonces } v = p \times x + q \times z + r \quad (8)$$

donde  $x$  y  $z$  son los valores de las variables de entrada,  $\mathbf{A}$  y  $\mathbf{B}$  son conjuntos borrosos, y  $p$ ,  $q$  y  $r$  son constantes reales.

Las funciones de pertenencia que se utilizan para las variables de entrada son gaussianas y tienen dos parámetros cada una,  $\sigma$  y  $c$ .

$$f(x, \sigma, c) = \exp\left(\frac{-(x - c)^2}{2\sigma^2}\right)$$

Las funciones de pertenencia para la variable de salida son funciones lineales de los valores de la

entrada (8) y tienen un número de parámetros igual al número de variables de entrada + 1.

Para la obtención del modelo se ha utilizado el algoritmo *ANFIS* (Jang, 1991, Jang 1993), concretamente la implementación de Matlab (versión 5.3) ejecutada en un PC Pentium 4 CPU 2, 8GHz, 512Mb RAM.

El acrónimo *ANFIS* deriva su nombre de *Adaptive Neuro-Fuzzy Inference System*. Esta función construye un Sistema de Inferencia Borrosa de tipo Sugeno, con funciones de pertenencia cuyos parámetros se sintonizan usando el algoritmo de *propagación hacia atrás del error (backpropagation)* sólo o en combinación con el método de mínimos cuadrados, usando para ello un conjunto de datos de entrada y salida.

El uso de esta función permite suplir los conocimientos del experto con el conocimiento implícito de un conjunto de datos. No obstante, para obtener una generalización razonable es importante que el número de datos para entrenamiento sea varias veces mayor que el número de parámetros que se quiere estimar. Se ha impuesto el criterio de que el número de datos sea al menos 5 veces el de parámetros. Concretamente el modelo propuesto tiene 200 parámetros ajustables y las series disponibles para entrenamiento son 1,182.

El número de series de datos disponibles influye significativamente en los resultados del modelado, como se podrá comprobar más adelante. En efecto, los resultados del modelo para experimentos con velocidad de 40 nudos son sistemáticamente los peores debido a que el número de datos con los que se contaba para el entrenamiento en estas condiciones es sensiblemente menor que en los otros experimentos y, por lo tanto, están peor representados en el modelo.

#### 2.4 Estimación del error y resultados

Una vez dispuestos convenientemente los datos se ha generado y entrenado el Sistema de Inferencia Borrosa utilizando el primer tercio de los datos correspondientes a los experimentos. La generalización se ha hecho con el segundo tercio, reservando el tercer tercio para probar el modelo.

Para cada experimento se define un error no dimensional que es la media de los errores cometidos en cada instante  $i$  como:

$$error(i) = \frac{abs(ace_{exp}(i) - ace_{mod}(i))}{abs(ace_{exp}(i))} \quad (9)$$

donde  $ace_{exp}(i)$  y  $ace_{mod}(i)$  son los valores medidos en el experimento y previstos por el modelo, respectivamente, para la aceleración de cabeceo

en el instante  $i$ . Por lo tanto, el error para cada experimento vendrá dado por:

$$error_{exp} = \frac{\sum_{i=1}^{NumPtos} error(i)}{NumPtos} \quad (10)$$

El error del experimento se caracteriza, además, por la desviación standard  $\sigma_{exp}$  de la distribución (tabla 3). Estos errores permiten evaluar la bondad de cada modelo con respecto a su ajuste a los datos experimentales.

Para comparar los distintos modelos con los que se puede trabajar, es decir, modelos con distinto número de muestras  $n$ , se define un nuevo error que pondera que el modelo sea más preciso en los experimentos cuya frecuencia de encuentro,  $\omega_e$ , esté más próxima a la frecuencia natural de oscilación del sistema,  $\omega_*$ . Esta frecuencia natural se ha estimado usando (4) y (5) con los datos de *Precal*, obteniéndose un valor de 1.73 rad/s. El error del modelo se define mediante la siguiente expresión:

$$error_{mod} = \frac{\sum_{i=1}^{NumExper} \frac{error_{exp}(i)}{abs(\omega_* - \omega_e(i))}}{\sum_{i=1}^{NumExper} \frac{1}{abs(\omega_* - \omega_e(i))}} \quad (11)$$

donde  $error_{exp}(i)$  es el error evaluado con (10),  $\omega_e(i)$  es la frecuencia de encuentro para el experimento  $i$ , y  $NumExper$  es el número de experimentos.

En la tabla 3 se muestran los errores del modelo ( $n = 10$ ,  $\Delta t = 1.50$  s) al compararlos con los datos de los experimentos disponibles.

EM	U (nudos)	$\omega_e$ (rad/s)	$error_{exp}$	$\sigma_{exp}$
4	20	1.5715	0.42	0.04
4	30	1.9388	0.53	0.04
4	40	2.3061	0.63	0.16
5	20	1.0421	0.38	0.01
5	30	1.2490	0.46	0.02
5	40	1.4560	0.58	0.12
6	20	0.7281	0.27	0.03
6	30	0.8505	0.40	0.03
6	40	0.9730	0.49	0.10

Tabla 3. Errores del modelo en los experimentos

El error ponderado del modelo para este caso usando (11) es de 0.48 (como se muestra en la Tabla 4).

Por último, en las figuras 5, 6 y 7 se representan gráficamente el valor experimental de la aceleración de cabeceo y la previsión del modelo, para los tres experimentos cuya frecuencia de encuentro es la más próxima a la frecuencia natural de

oscilación, concretamente los correspondientes a estado de la mar 4 con velocidades 20 y 30 nudos, y estado de la mar 5 con velocidad de 40 nudos.

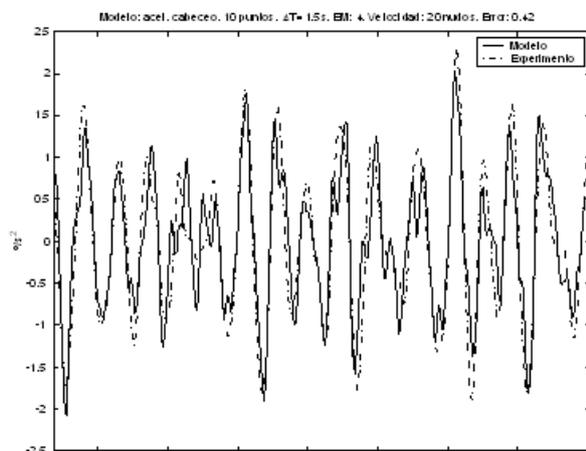


Figura 5. Resultados  $n = 10$ , 1.5 seg., EM 4, U=20 nudos

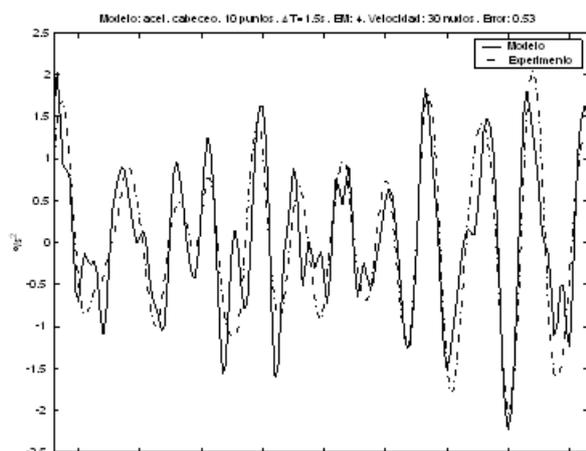


Figura 6. Resultados  $n = 10$ , 1.5 seg., EM 4, U=30 nudos

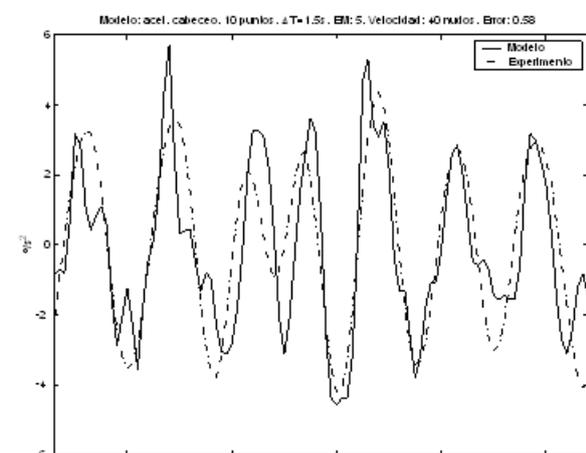


Figura 7. Resultados  $n = 10$ , 1.5 seg., EM 5, U=40 nudos

Puede observarse que las previsiones del modelo ajustan bastante bien con los resultados de los

experimentos para olas reales. El modelo aplicado es el mismo para todos los casos, es decir, es un único modelo general.

### 3. MEJORAS DEL MODELO

Ya que el método de trabajo ha permitido obtener un modelo neuro-borroso predictivo con buenos resultados para distintas condiciones de navegación, se han investigado otras alternativas para los valores de  $n$  y  $\Delta t$  que lo pudieran mejorar.

La condición de que el número de series de datos sea al menos cinco veces el de parámetros ajustables y que cubra como mínimo el perfil de una ola (6), imponen una limitación al conjunto de posibles valores de  $n$  y  $\Delta t$  que se refleja en la tabla 4.

Para cada uno de estos casos posibles se ha obtenido y evaluado el modelo correspondiente. Los resultados se presentan en la tabla 4 y en la figura 8.

$n$	$\Delta t$	error	$n$	$\Delta t$	error
9	1.75	0.67	<b>12</b>	<b>1.25</b>	<b>0.35</b>
9	2.00	0.75	12	1.50	0.50
9	2.25	0.69	12	1.75	0.78
9	2.50	0.75	<b>13</b>	<b>1.25</b>	<b>0.36</b>
10	1.50	0.48	13	1.50	0.52
10	1.75	0.71	13	1.75	0.79
10	2.00	0.78	14	1.25	0.46
10	2.25	0.69	14	1.50	0.52
11	1.50	0.50	<b>15</b>	<b>1.00</b>	<b>0.33</b>
11	1.75	0.69	<b>16</b>	<b>1.00</b>	<b>0.32</b>
11	2.00	0.81			

Tabla 4. Modelos analizados y error obtenido

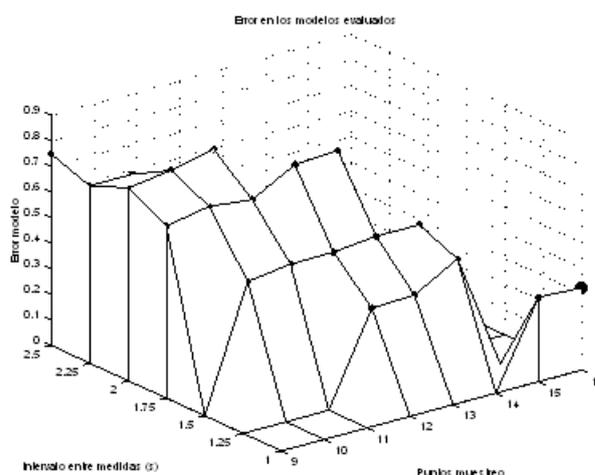


Figura 8. Error en los modelos evaluados

El modelo que proporciona mejores resultados con los criterios establecidos es el de 16 medidas de ola espaciadas en 1 segundo, que tiene un error de 0.32. Los errores que produce este modelo para

cada experimento se presentan en la tabla 5. Las gráficas del modelo para los experimentos más próximos a la frecuencia de encuentro se muestran en las figuras 9, 10 y 11.

EM	U (nudos)	$\omega_e$ (rad/s)	$error_{exp}$	$\sigma_{exp}$
4	20	1.5715	0.14	0.07
4	30	1.9388	0.39	0.04
4	40	2.3061	0.53	0.12
5	20	1.0421	0.12	0.01
5	30	1.2490	0.38	0.04
5	40	1.4560	0.50	0.09
6	20	0.7281	0.11	0.01
6	30	0.8505	0.33	0.03
6	40	0.9730	0.48	0.23

Tabla 5. Errores en los experimentos (16 puntos, 1 segundo)

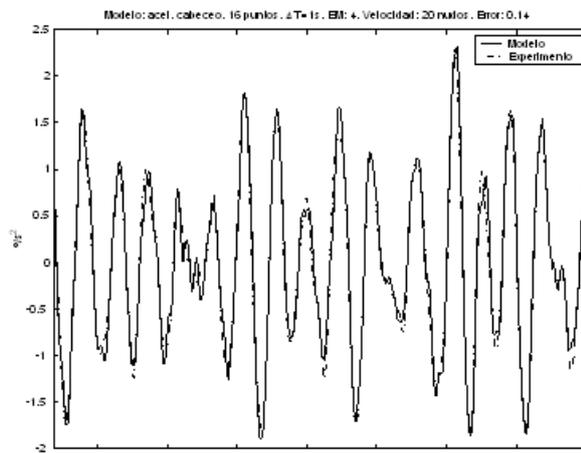


Figura 9. Resultados  $n = 16$ , 1 seg., EM 4, U=20 nudos

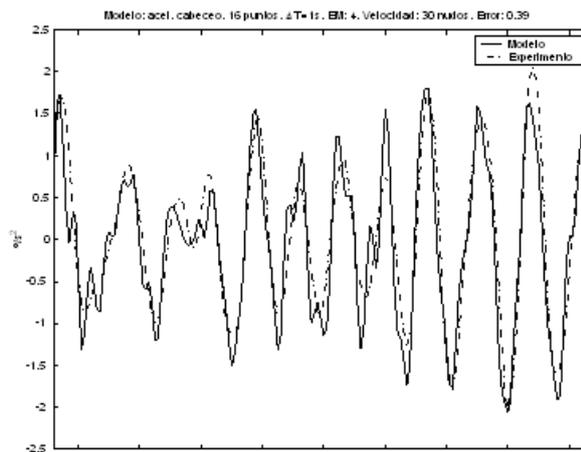


Figura 10. Resultados  $n = 16$ , 1 seg., EM 4, U=30 nudos

El hecho de que se obtenga el menor error con el mayor número de puntos y el menor intervalo de observación ( $n = 16$ ,  $\Delta t = 1$  s) no es concluyente. De hecho, con los modelos para ( $n = 12$ ,  $\Delta t = 1.25$  s), ( $n = 13$ ,  $\Delta t = 1.25$  s) y ( $n = 15$ ,  $\Delta t = 1$  s) se obtienen errores muy similares con la ventaja

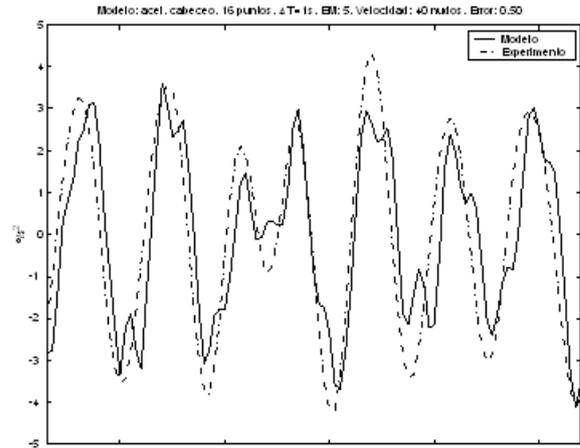


Figura 11. Resultados  $n = 16$ , 1 seg., EM 5, U=40 nudos

de que el número de parámetros del Sistema de Inferencia Borrosa es menor.

Aunque de la tabla 4 y la figura 8 no se puede inferir con rigor ninguna regla, con los datos disponibles, sometidos a (6) y a que el número de series sea, al menos, cinco veces el número de parámetros, parece que el error del modelo disminuye al disminuir  $\Delta t$ , es decir, al hacer más tupida la red de observaciones, y que para un valor determinado  $\Delta t$  es prácticamente independiente de  $n$ .

Por otro lado el error en los experimentos es mayor cuanto mayor es la velocidad, es decir, cuanto menor es el número de series disponibles para entrenamiento, lo que es significativo y concuerda con el criterio establecido para el entrenamiento.

#### 4. CONCLUSIONES

Usando datos experimentales -que provienen de experimentos reales realizados con una replica a escala de un buque de alta velocidad con olas irregulares- se ha obtenido un modelo neuro-borroso predictivo para la aceleración de cabeceo.

El modelo estima el valor de dicha aceleración a partir de una serie de medidas de la elongación de la ola registradas en instantes anteriores. Los datos se han tratado aplicando técnicas neuro-borrosas adaptativas.

Este modelo se ha mejorado procurando optimizar sus parámetros para que el número de estos sea el mínimo posible y que la inferencia sea más rápida.

Se ha mostrado también la influencia sobre la precisión del modelo del número de series disponibles para el entrenamiento así como de la combinación de valores de los parámetros del mismo.

Los resultados obtenidos muestran un buen ajuste del modelo a los datos experimentales, especial-

mente en las situaciones de navegación más frecuentes.

Además, este modelo es general en el sentido de que no se han impuesto limitaciones para su obtención y representa al sistema para muy distintas condiciones de navegación. Se ha comprobado para el rango de experimentos disponibles.

## 5. AGRADECIMIENTOS

Los autores quieren expresar su agradecimiento por la ayuda recibida del CICYT (Proyectos TAP97-0607-C03-01 y DPI 2000-0386-C03-01), y la colaboración del personal del CEHIPAR.

Este artículo es un pequeño homenaje "in memoriam" a Cristóbal López Urrea (q.e.p.d).

## 6. REFERENCIAS

- Andrés, B.; Esteban, S.; Girón Sierra, J.M.; de la Cruz, J.M. (2000). "Modelling the Motions of a Fast Ferry with the Help of Genetic Algorithms". Proc. 3rd IMACS MATHMOD. Viena, 783-786.
- Anonymous. (1996). "126 m Long Spanish Fast Ferry Launched". Fast Ferries, Sept, 19-20.
- Anonymous. (1998). "Silvia Ana: Results of First Year's Service". Ship & Boat Int, Jan, 15-16.
- Aranda, J; de la Cruz, J.M.; de Andrés, B; Díaz, J.M.; Esteban, S.; Girón, J.M.; Grau, L.; López, J.A.; Ruipérez, P. (1999). "Datos utilizados en la identificación de modelos lineales de la dinámica vertical del buque TF-120". Informe Técnico del Proyecto TAP97-0607-C03-01. Documento N° CRIBAV-01-01.
- Aranda, J.; de la Cruz, J.M.; Díaz, J.M.; de Andrés, B.; Ruipérez, P.; Girón, J.M. (2000a). "Modelling of a High Speed Craft by a Non-Linear Least Squares Method with Constraints.". 5th IFAC Conference on Manoeuvring and Control of Marine Crafts MCMC2000. Aalborg, 227-232.
- Aranda, J; de la Cruz, J.M.; Díaz, J.M; Ruipérez, P. (2000b). "Interval Modelling of a High Speed Craft for Robust Control". 2nd International Congress on Maritime Technological Innovations and Research. Cádiz.
- CEHIPAR. (1998). "Informe OTI-2135-CM-2 de los resultados del programa de comportamiento en la mar 'Precal' del Ferry TF-120 para investigación de control". Canal de Experiencias Hidrodinámicas del Pardo, Madrid.
- CEHIPAR. (2005). www.cehipar.es
- Cruz, J.M. de la, Aranda, J., Díaz, J.M; Ruipérez, P., Marón, A. (1998). "Identification of the vertical plane motion model of a high speed craft by model testing in irregular waves". Proc. of IFAC Conference CAMS'98 Control Applications in Marine Systems (K. Jimima, Ed.), Fukuoka, Japan, 277-282.
- Cruz, J.M., Aranda, J., Díaz, J.M; Ruipérez, P., (1999), "Identificación de modelos lineales con intervalos de confianza de la dinámica vertical de un buque de alta velocidad". Actas XX Jornadas de Automática. CEA-IFAC, 279-283.
- Esteban, S., Girón-Sierra, J.M., de la Cruz, J.M., de Andrés, B., Díaz, J.M., Aranda, J. (2000). "Fast Ferry Vertical Acceleration Reduction with Active Flaps and T-Foil". Proc. 5th IFAC Conf. on Manoeuvring and Control of Marine Crafts MCMC 2000. Aalborg, 233-238.
- Fossen Thor I. (1994). "Guidance and Control of Ocean Vehicles". John Wiley, N.Y.
- ISO International Standard 2631/3. (1985). "Evaluation of human exposure to whole-body vibration - Part 3 : Evaluation of whole-body z-axis vertical vibration in the frequency range 0.1 to 0.63 Hz".
- Jang, J.S.R. (1991), "Fuzzy Modeling Using Generalized Neural Networks and Kalman Filter Algorithm," Proc. of the Ninth National Conf. on Artificial Intelligence (AAAI-91), 762-767.
- Jang, J.S.R. (1993), "ANFIS: Adaptive-Network-based Fuzzy Inference Systems", IEEE Transactions on Systems, Man, and Cybernetics, Vol. 23, No. 3, pp. 665-685.
- Lloyd, A. R. J. M. (1989). "SEAKEEPING: Ship Behaviour in Rough Weather". Ellis Horwood (Ed), RPM, Sussex, UK.
- O'Hanlon, J.F., McCawley, M.E. (1974). "Motion sickness incidence as a function of acceleration of vertical sinusoidal motion". Aerospace Medicine, 45 (4), 366-369.