

Un simulador de clima marítimo

JOSEP R. MEDINA (*)
MARCOS H. GIMENEZ (*)
ROBERT T. HUDSPETH (**)

RESUMEN. Se presenta una metodología para la simulación de series temporales bivariadas de altura y período de ola significantes. El procedimiento se aplica para estimar el correspondiente simulador de clima marítimo asociado a los datos obtenidos de la boya escalar COQUILLE fondeada en la costa de Oregon. Las dos propiedades estocásticas básicas del simulador de clima estimado resultan: a) Función de densidad lognormal con parámetros de periodicidad anual para describir $p(H_s)$ y $p(T_s)$, y b) Estructura estocástica autorregresiva bivariada de primer orden, para describir correlaciones.

ABSTRACT. A numerical methodology for simulating the time series of significant wave height and significant wave period is presented. The method is applied to estimate the corresponding wave climate simulator associated with the data obtained from the COQUILLE waverider buoy located at the coast of Oregon. The two basic stochastic properties of the estimated wave climate simulator are: a) Long-normal probability density functions with annual periodic parameters to describe $p(H_s)$ and $p(T_s)$, and b) Double-variable first-order autoregressive stochastic structure to describe correlations.

INTRODUCCION

La estimación cuantitativa de las evoluciones de playas inducidas por los temporales como función de las acciones naturales dependientes del tiempo ha demostrado ser una técnica muy potente que puede ser de gran utilidad en la planificación y diseño de obras marítimas. Por ejemplo, Larson et al. (1989) han presentado una formulación numérica y resultados experimentales del programa SBEACH, que es un modelo numérico para la simulación de cambios de perfil de playas inducidos por los temporales.

La entrada básica de los modelos numéricos para la simulación de cambios del perfil de playas la constituye la «evolución en el tiempo de las acciones»: la evolución en el tiempo de las variables de clima marítimo. Las variables fundamentales de clima que afectan la evolución en el tiempo del perfil de playa son: nivel medio del mar, altura de ola y período de ola significativo. Por consiguiente, resulta imprescindible desarrollar modelos numéricos capaces de sintetizar series temporales de nivel medio del mar, altura y período de ola significativo, para disponer de escenarios adecuados para estimar evoluciones de perfiles de playa y línea de costa.

Walton y Borgman (1990) presentan una metodología para simulación no estacionaria, no normal de los niveles de agua en los Grandes Lagos. Aunque el nivel medio del agua puede ser la variable de entrada princi-

pal para estimar la evolución de la línea de costa en algunos puntos, las series temporales de altura y período de ola significantes, $\{H_s, T_s\}$, son también muy importantes en otros casos y otras aplicaciones de Ingeniería Marítima. Por ejemplo, un método fiable para la simulación de series de $\{H_s, T_s\}$ puede resultar muy interesante para analizar el riesgo a largo plazo asociado a determinadas estructuras marítimas.

El objetivo principal de este artículo es definir una metodología razonable para construir modelos estocásticos apropiados para la simulación de la serie temporal bivariada de H_s y T_s asociados a un lugar específico. Una vez establecido el simulador de clima para un lugar específico de la costa, el modelo resulta ser el mejor descriptor del clima marítimo del lugar. En este artículo se determina el simulador usando datos recogidos por la boya COQUILLE situada en coordenadas geográficas N43°06,7-W124°30,0 a 70 metros de profundidad frente a la costa de Oregon. La metodología que se presenta en este artículo puede extenderse para incluir la variable «nivel medio del mar», con lo que el simulador de clima resultante sería ya el necesario para la alimentación de los programas numéricos de evolución de perfiles de playa.

IDENTIFICACION DEL MODELO

La modelación de un proceso estocástico bivariado para la simulación de series temporales de $\{H_s, T_s\}$ puede dividirse en dos partes: a) La modelación de la magnitud de las variables, y b) La modelación de la estructura estocástica. La modelación de la magnitud de las variables

(*) Laboratorio de Puertos y Costas, Universidad Politécnica de Valencia.

(**) Oregon State University, Corvallis, USA.

está relacionada con la descripción de características estadísticas como funciones de densidad de H_s y T_s , y estacionalidad de estadísticos. Por otro lado, la modelación de la estructura estocástica está relacionada con la estructura de correlaciones e interrelaciones entre las series temporales de $\{H_s\}$ y $\{T_s\}$.

LA MODELACION DE LA MAGNITUD DE LAS VARIABLES

Bajo el nombre genérico de clima marítimo, se han propuesto una variedad de métodos para estimar las funciones de densidad de H_s . Goda (1977) describe el problema y los métodos más comunes de resolución. Para la descripción estadística de H_s en el año (estación o mes) medio, se han propuesto funciones como la lognormal, Weibull, exponencial y otras. Un análisis preliminar del listado de datos $\{H_s\}$ de la boya COQUILLE mostró una estacionalidad clara de las características estadísticas de las dos variables a estudio. Se encontró que la función de distribución lognormal era adecuada para describir la $p(H_s)$ de los datos agrupados en meses.

La distribución lognormal es una de las más utilizadas para describir las magnitudes de H_s . Lawson y Abernethy (1975), con datos de Australia, y también Martín-Soldevila y Martínez-Aranzábal (1990), con datos de la costa española, han propuesto el uso de la distribución lognormal para las descripciones estadísticas de H_s . La función de densidad lognormal es cero para valores negativos de H_s , de acuerdo con las características físicas de la variable H_s . Además, para tener en cuenta los errores de observación impuestos por la variabilidad natural del oleaje (ver Medina y Hudspeth, 1990) es preferible analizar la transformación logarítmica de $\{H_s\}$. Por consiguiente se tomó la distribución lognormal como la mejor descriptora estadística de H_s en una época dada del año; para transformar las series temporales de H_s en series estacionarias normalizadas, se puede utilizar

$$x(n) = \frac{[\log(H_s)](n) - A1(n)}{B1(n)} \quad (1)$$

donde $x(n)$ es la serie temporal normalizada de $H_s(n)$, $A1(n)$ y $B1(n)$ son parámetros de la distribución lognormal de periodicidad anual y n es el contador de tiempo.

La modelación de $p(T_s)$ se ha tratado menos en la literatura científica que la modelación de $p(H_s)$. Una relación potencial entre H_s y T_s apoyaría también la distribución lognormal para el período de ola significativo. Ambos, los histogramas de H_s y de T_s de los datos de la boya COQUILLE, se ajustan bastante bien a la función de densidad lognormal. Por consiguiente, se tomó también la distribución lognormal para los períodos de ola significativos. De forma análoga, la ecuación utilizada para normalizar las series temporales de $T_s(n)$ ha sido

$$y(n) = \frac{[\log(T_s)](n) - A2(n)}{B2(n)} \quad (2)$$

donde $y(n)$ es la serie temporal normalizada de $T_s(n)$, $A2(n)$ y $B2(n)$ son parámetros de la distribución lognormal de periodicidad anual y n es el contador de tiempo.

LA MODELACION DE LA ESTRUCTURA ESTOCASTICA

Cuando el modelo estacional lognormal bivariado ha sido ya establecido como el apropiado para describir las magnitudes de las variables, es posible estudiar la estructura estocástica de la serie temporal bivariada, $\{H_s(n), T_s(n)\}$. La transformación logarítmica estacional proporcionada por las ecuaciones 1 y 2 deben transformar los datos de partida en series normales estacionarias $\{x(n), y(n)\}$ donde $E[x(n)] = E[y(n)] = 0$, y $\sigma[x(n)] = \sigma[y(n)] = 1$.

Para identificar el modelo estocástico apropiado entre la gran variedad de alternativas, es razonable calcular primero la correlación entre sucesivos H_s [$r_H(n)$], sucesivos T_s [$r_T(n)$] y la correlación cruzada entre H_s y T_s [$r_{HT}(n)$]. El listado de datos, $\{H_s(n), T_s(n), \text{tiempo}(n)\}$, obtenidos de la boya COQUILLE indica la existencia de períodos de tiempo irregulares sin datos. Sin embargo, el intervalo de tiempo entre datos consecutivos era alrededor de seis horas en la mayoría de los casos. Por consiguiente, se consideró en primer lugar el estudio de la autocorrelación y correlación cruzada de la pseudo-serie temporal bivariada tomada directamente del listado de datos, $\{H_s, T_s, n\}$, para poder identificar las características principales de la estructura de correlaciones.

Después de agrupar los datos $\{H_s(n), T_s(n)\}$ por meses, las estimaciones de autocorrelaciones y correlaciones cruzadas no mostraron ningún signo de estacionalidad clara. En consecuencia, se consideró sólo una estructura estacionaria de correlaciones. Por otro lado, las funciones de autocorrelación mensuales de $\{\log[H_s(n)]\}$ mostraban claramente un comportamiento autorregresivo de primer orden del tipo: $r_H(0) = +1.00$, $r_H(1) = +0.86$, $r_H(2) = +0.71$, $r_H(3) = +0.60$,... (datos de enero). Las funciones de autocorrelación de $\{\log[T_s(n)]\}$ también mostraban el esquema AR(1) dado por: $r_T(0) = +1.00$, $r_T(1) = +0.53$, $r_T(2) = +0.29$, $r_T(3) = +0.14$,... (datos de enero). Finalmente, las correlaciones cruzadas de $\{\log[H_s(n)] \log[T_s(n)]\}$ mostraban el esquema: $\dots r_{HT}(-2) = +0.10$, $r_{HT}(-1) = +0.17$, $r_{HT}(0) = +0.26$, $r_{HT}(1) = +0.24$, $r_{HT}(2) = +0.20$,... (datos de enero). Aunque la variabilidad e intervalos de confianza de estas estimaciones de correlación son muy amplias, es evidente la existencia de una estructura de correlaciones fuerte entre $\{H_s(n)\}$ y $\{T_s(n)\}$.

Los datos analizados cubren el período 11/24/1981 a 6/22/1989 pero no en una secuencia perfecta de un registro cada seis horas. Por el contrario, solamente se disponía de 5,577 (55.4 %) registros listados con períodos de tiempo sin datos. Las labores de mantenimiento

y calibración periódicas, los daños, fallos del sistema y una amplia variedad de causas diversas son responsables de la intermitencia de los registros y la irregularidad de las estadísticas de oleaje. Esta situación ineludible hace que la evaluación de fiabilidades y cálculo de estadísticos resulte difícil y quede afectado el proceso de construcción del modelo. Esta realidad apoya el uso generalizado del «principio de parsimonia», que se realiza en este estudio para poder justificar uno de los modelos más simples que explica en gran medida las principales características estocásticas de las observaciones. El modelo estocástico descrito a continuación representa un modelo autorregresivo bivariado para $\{ \log[H_s(n)] \}$ y $\{ \log[T_s(n)] \}$, y dispone de tres parámetros independientes para ajustar $r_{HT}(k)$, $r_T(k)$ y $r_{HT}(0)$

$$x(n) = a \cdot x(n-1) + b \cdot v(n); n = 1, 2, 3, \dots \quad (3)$$

$$y(n) = c \cdot y(n-1) + d \cdot x(n) + e \cdot w(n); n = 1, 2, 3, \dots \quad (4)$$

donde n es el índice de tiempo, $\{x(n)\}$ y $\{y(n)\}$ son las series temporales normalizadas por las ecs. 1 y 2, y $\{v(n)\}$ y $\{w(n)\}$ son ruidos blancos independientes. Esta estructura estocástica tiene las siguientes propiedades:

$$E[x(n)] = E[y(n)] = E[v(n)] = E[w(n)] = 0 \quad (5)$$

$$\sigma[x(n)] = \sigma[y(n)] = \sigma[v(n)] = \sigma[w(n)] = 1 \quad (6)$$

$$E[v(n) \cdot v(n+k)] = E[w(n) \cdot w(n+k)] = 0; k \neq 0 \quad (7)$$

$$E[v(n) \cdot w(n+k)] = 0; \forall k \quad (8)$$

$$E[x(n) \cdot x(n+k)] = a^k \quad (9)$$

$$E[y(n) \cdot y(n+k)] = c^k \quad (10)$$

$$E[x(n) \cdot y(n)] = \frac{b \cdot d}{1 - a \cdot c} \quad (11)$$

$$a^2 + b^2 = c^2 + d^2 + e^2 = 1 \quad (12)$$

El modelo estocástico descrito por las ecs. 3 y 4 puede aplicarse para el análisis de series temporales con cualquier intervalo temporal. Los primeros términos de las ecs. 9, 10 y 11 pueden determinarse a partir de las observaciones disponibles y con ellos calcular los tres parámetros independientes de las ecs. 3 y 4, utilizando las ecs. 9 a 12.

ESTIMACION DEL MODELO

La modelación de la magnitud de las variables por las ecs. 1 y 2 requieren la estimación de la periodicidad anual de $A1(n)$, $A2(n)$, $B1(n)$, y $B2(n)$. En primer lugar, solamente se consideraron fiables los datos correspondientes a registros seguidos por otro registro en el intervalo de 5.5 a 6.5 horas (83 % del total). En segundo lugar, los datos $\{H_s, T_s\}$ se agruparon mensualmente para estimar los correspondientes parámetros de la log-normal para cada mes y variable. En tercer lugar, las estimaciones mensuales se consideraron nuevos datos correspondientes al 16° día de cada mes, estableciendo cuatro series temporales asociadas con H_s y T_s , $\{A1(n)$,

$A2(n)$, $B1(n)$, $B2(n)\}$. Finalmente, se realizó un análisis de Fourier para discriminar las componentes estacionales más significativas.

Como resultado del análisis de Fourier realizado anteriormente, se encontró que el primer armónico (período de 12 meses) explicaba más del 95 % de la varianza de $A1(n)$ y de $A2(n)$. La figura 1 muestra los datos mensuales de $A1(n)$ y $2 \cdot A2(n)$ y las estimaciones utilizando sólo el primer armónico (las H_s están en centímetros y las T_s en segundos). Despreciando el resto de los cinco armónicos (menos del 5 % de varianza), las dos estimaciones resultaron casi en fase con un máximo alrededor del 22 de enero. El modelo para la estimación horaria de $A1$ y $A2$ quedó establecida en

$$A1(n) = 2,260 + 0,154 \cdot \cos \left[\frac{2\pi n}{8,766} - 0,376 \right] \quad (13)$$

$$A2(n) = 0,959 + 0,084 \cdot \cos \left[\frac{2\pi n}{8,766} - 0,347 \right] \quad (14)$$

Por otro lado, el análisis de Fourier sobre las estimaciones mensuales de $B1$ y $B2$ no proporcionó un resultado tan claro. Se necesitaron los primeros dos armónicos para explicar más del 75 % de la varianza de $B1(n)$ y $B2(n)$. El modelo finalmente estimado resultó

$$B1(n) = 0,170 + 0,014 \cdot \cos \left[\frac{2\pi n}{8,766} + 0,147 \right] + 0,012 \cdot \cos \left[\frac{4\pi n}{8,766} + 1,617 \right] \quad (15)$$

$$B2(n) = 0,125 + 0,011 \cdot \cos \left[\frac{2\pi n}{8,766} + 0,079 \right] + 0,008 \cdot \cos \left[\frac{4\pi n}{8,766} + 2,310 \right] \quad (16)$$

Para estimar los tres parámetros independientes del modelo estocástico definido por las ecs. 3 y 4, se estimaron los coeficientes de correlación $r_{HT}(6)$, $r_T(6)$ y $r_{HT}(0)$ de los datos de partida para cada mes. Los coeficientes de correlación mostraron una amplia variabilidad, pero ninguna estacionalidad aparente. Se calcularon los siguientes valores medios: $r_{HT}(6) = +0,85$, $r_T(6) = +0,60$, y $r_{HT}(0) = +0,27$. Así pues, el modelo estocástico para las series temporales normalizadas de $\{x(n)$, $y(n)\}$ resultó

$$x(n) = a \cdot x(n-1) + \sqrt{1-a^2} \cdot v(n) \quad (17)$$

$$y(n) = c \cdot y(n-1) + d \cdot x(n) + \sqrt{1-(c^2+d^2)} \cdot w(n) \quad (18)$$

donde $a = (0,85)^{1/6}$, $b = (0,60)^{1/6}$, $d = 0,27(1-ac)/(1-a^2)^{1/2}$ y $\{v(n), w(n)\}$ son ruidos blancos independientes de varianza unidad.




FIGURA 1. Modelo estacional de A1 y A2 con el primer armónico.

VERIFICACION DEL MODELO

Durante las fases de identificación y estimación, se han tomado muchas decisiones: hipótesis de estacionariedad interanual, selección de distribuciones lognormal, variación estacional de parámetros, estructura estocástica estacionaria autorregresiva de primer orden y bivarida, etc. Por tanto, es necesario verificar si el modelo estimado es adecuado para describir la serie de observaciones original. Las ecs. 1, 2 y 13 a 18 pueden utilizarse para calcular los residuos asociados a los datos de partida, $\{v'(n), w'(n)\}$. Pueden verificarse para cualquier intervalo de tiempo entre datos consecutivos utilizando las ecs. 17 y 18: $a' = (0,85)^{dt/6}$, $c' = (0,60)^{dt/6}$, y $d' = 0,27(1 - a'c')/(1 - a'^2)^{1/2}$, donde dt es la variable intervalo temporal (en horas) de las observaciones de oleaje. El análisis de los residuos nos proporciona una indicación objetiva de la calidad del modelo de simulación de clima estimado.

Los residuos calculados de la manera indicada anteriormente deberían ser independientes y con distribución normal de media cero y varianza unidad, $N(0,1)$. Se seleccionaron los primeros 241 registros de cada mes para calcular dos series de 240 residuos por mes, $\{v'(n), w'(n)\}$. Los residuos de $H_s(n)$, $\{v'(n)\}$, de algunos meses pasaron con éxito los tests de la autocorrelación

estimada, de la normalidad $N(0,1)$ de la f.d.f., y del periodograma acumulado. Sin embargo, el número de tests fallados indica que el modelo estimado no es plenamente satisfactorio. Por otro lado, los residuos de $T_s(n)$, $\{w'(n)\}$, no pudieron pasar los tests de aleatoriedad en la mayoría de los casos.

Los resultados de la verificación del modelo realizado anteriormente podría sugerir algunas modificaciones en la estimación para mejorar el modelo de clima. Sin embargo, el número de alternativas es demasiado alto y la calidad de los datos demasiado baja para encontrar un modelo simple que pase todos los tests de aleatoriedad. Es necesario tener presente una gran cantidad de errores en los datos debido a la variabilidad natural del oleaje, al proceso de medición y a otros aspectos ineludibles de los datos de partida. Por ejemplo, los periodos de oleaje se dan en segundos (error mínimo 0,5 seg.) y los errores inducidos pueden distorsionar significativamente los residuos aunque el modelo sea satisfactorio. Por consiguiente, parece razonable esperar los resultados de la aplicación de la presente metodología en otros lugares para introducir nuevas restricciones al modelo. Mientras tanto, se pueden emplear simulaciones numéricas para verificar la calidad de los tests y los modelos.




FIGURA 2. Salida del simulador de clima, $\{H_m, T_s\}$, enero 1993.

SIMULACION DE CLIMA MARITIMO

Las ecs. 1, 2, 17 y 18 se pueden utilizar para simular series temporales horarias de $\{H_m, T_s\}$ del tipo de las representadas en la figura 2. Si el intervalo temporal deseado no fuera una hora sino p horas, los parámetros a utilizar en las ecs. 17 y 18 serían $\alpha' = (0.85)^{p/6}$, $c' = (0.60)^{p/6}$ y $d' = 0.27(1 - \alpha'c')/((1 - \alpha'^2)^{1/2})$. La figura 2 representa una salida típica del simulador de clima estimado para las primeras horas de 1993 ($p = 1$).

CONCLUSIONES

Se presenta una metodología para determinar simuladores de clima marítimo. Se justifica un modelo estocástico bivariado lognormal autorregresivo de primer orden para describir las series de $\{H_m, T_s\}$ obtenidas de la boya COQUILLE instalada en la costa de Oregón. Esta metodología parece una razonable primera aproximación a los modelos estocásticos multivariados de mayor complejidad que tendrán que ser desarrollados en un futuro cercano para poder alimentar los nuevos modelos numéricos de evolución de perfiles y plantas de playa.

AGRADECIMIENTOS

Los autores manifiestan su agradecimiento al soporte financiero proporcionado por las siguientes instituciones españolas y norteamericanas: la Dirección General de Investigación

Científica y Técnica, proyecto N.º PB88-0353; la Office of Naval Research-University Research Initiative (ONR-URI), contrato N.º N00014-86-K-0687; la Oregon Sea Grant and the National Oceanic and Atmospheric Administration, Office of Sea Grant, Dept. of Commerce, contrato N.º NA55AA-D-5G095 (proyecto N.º R/CE-21), y de la Oregon State Legislature. Los datos fueron proporcionados por el U.S. Army Corps of Engineers.

REFERENCIAS

- GODA, Y. (1977). «A Review on Statistical Interpretation of Wave Data», *Report of the Port and Harbour Research Institute*, 18(1), 5-32.
- LARSON, M., KRAUS, N. C., y BYRNES, M. R. (1989). «SBEACH: Numerical Model for Simulating Storm-Induced Beach Changes», *Technical Report*, CERC-89-9.
- LAWSON, N. V., y ABERNETHY, C. L. (1975). «Long Term Wave Statistics off Botany Bay», *Proc. 2nd Australian Conf. on Coastal and Ocean Engrg.*, 167-176.
- MARTIN-SOLDEVILLA, M. J., y MARTINEZ-ARANZABAL, J. (1990). «Análisis Medio y Extremal del Oleaje», *Report of the CEDEX*, C22, 5-72.
- MEDINA, J. R., y HUDSPETH, R. T. (1990). «A Review of the Analyses of Wave Groups», *Coastal Engineering*, 14(1990), 515-542.
- WALTON, T. L., y BORGMAN, L. E. (1990). «Simulation of Nonstationary, Non-Gaussian Water Levels on Great Lakes», *Journal of Waterway, Port, Coastal and Ocean Engrg.*, 116(6), 664-685.