

Modelo para el pronóstico del índice multivariado del ENOS. (PMEI)

Autores: PAULO L. ORTIZ BULTÓ, ALINA RIVERO VALENCIA

Centro del Clima. Instituto de Meteorología .E-mail: paulo@met.inf.cu

Resumen.

Los índices relacionados con el ENOS, la Oscilación Cuasibienal (QBO) y otros, aportan suficiente información para el logro de los Modelos de Pronóstico Físico-Estadístico. En este trabajo se propone un modelo de pronóstico a partir del índice Multivariado del ENOS (MEI) desarrollado por Wolter, K and M. S Timlin (1993) de la NOAA-CIRES Climate Diagnostics Center (CDC) el cual describe adecuadamente las condiciones Océano-atmósfera en la región del Pacífico. Tomando como variable de entrada al MEI se logra ajustar un modelo Generalizado Autorregresivo Condicional Heterocedástico ((GARCH(p,q)) el cual permite simular y predecir el comportamiento de los valores del MEI y a partir del mismo avizorar si transitamos a la fase de eventos ENOS/AENOS. Los valores del índice pronosticado se nombran como Pronóstico del Índice Multivariado del ENOS (PMEI) el cual es capaz de predecir la ocurrencia de eventos ENOS/AENOS hasta con 4 meses de anticipación y según la ubicación de valores pronóstico en la estratificación por rango propuesta por Wolter podemos determinar la intensidad y evolución del fenómeno para los próximos meses.

Palabras claves: Pronóstico del Índice Multivariado del ENOS, índices pronóstico, ENOS, AENOS, modelos GARCH(p,q)

Introducción

Uno de los eventos más estudiados en las últimas décadas como elemento forzante de la variabilidad climática ha sido El Niño Oscilación del Sur (ENOS), el cual tiene un amplio espectro de impactos socio-económicos y medio ambientales que se han visto intensificado en las dos últimas décadas.

El ENOS es un evento que se desarrolla en etapas (Meulener, 1991) y su duración en la escala temporal es superior a un año, generalmente se hace referencia a 2 años por ejemplo: 76-77, 82-83, 97-98. En el año posterior a la ocurrencia del ENOS sus efectos contribuyen con mayor frecuencia al incremento de las precipitaciones en todas las regiones del país, existiendo una diferenciación en las regiones en sentido oeste – este las cuales se van manifestando y agudizando siendo observadas en las anomalías positivas en la región Occidental y negativas en la Oriental (Enfield, 1998).

En el siglo pasado a partir de la 2^{da} mitad de los años 90 se incrementó el desarrollo de los modelos de Circulación General de la Atmósfera y de los experimentos realizados en el Océano Pacífico reconociendo la primacía del estado del mar en los patrones de circulación de la atmósfera y de la ocurrencia de las anomalías de los elementos climáticos.

Estudios realizados por Enfield y Mayer en 1995 demostraron que las anomalías de la temperatura superficial del mar entre el Atlántico Norte y el Pací-

fico tienen una correlación significativa de 0.5 con un retardo de 4 a 5 meses, ocasionando dificultades a la hora de hacer estudios de predicción, si se parte de indicadores tradicionales como el índice de Oscilación del Sur (SOI) y las anomalías de la temperatura superficial del mar (ATSM), ya que las anomalías de los elementos climáticos responden de forma diferente a estos índices, hechos estos que pueden interpretarse como respuesta a los diferentes eventos oceánicos El Niño o La Niña.

Cárdenas y Naranjo (1998, 2000), construyeron un índice que permitió evaluar la ocurrencia de un evento ENOS (IE), donde entran 2 magnitudes: el índice de Oscilación del Sur (SOI) y la anomalía de la temperatura superficial del mar, en la región de Niño 3 (ATSM).

Existen diferentes índices para dar seguimiento al evento ENOS y su uso dependerá en gran medida de los objetivos y de la región que se desee monitorear. Sin embargo, hasta la fecha el indicador más completo debido a que integra más información que los otros índices clásicos utilizados es el Índice Multivariado de Eventos ENOS (MEI), propuesto por Wolter y Tirrini en 1993, el cual refleja la naturaleza del sistema océano-atmósfera, acoplado mejor que cualesquiera componente independiente.

Aunque son numerosos los estudios del comportamiento estocástico del Índice de Oscilación del Sur (Southern Oscillation, (SOI)) como se reporta en los trabajos de Wright (1977, 1985, 1988), Zwiers y Storch,

(1990), así como otros índices usados para el estudio de vigilancia del fenómeno El Niño, referidos a la clase de modelos de series de tiempo lineales en los cuales se incluyen las señales estacional y variaciones en el tiempo para el análisis de los indicadores del evento ENOS, son menos numerosos el uso de las series de tiempo no lineales para la modelación y predicción de los índices descriptores del evento ENOS y muy escasos los intentos de estos modelos para la modelación y pronósticos del índice MEI, aunque existen un gran número de modelos no lineales de series temporales que se reporta en la literatura (Tong, 1990 y Ruiz, E 1993). Luego en este trabajo se propone un modelo no lineal de series temporales, que permite hacer pronósticos de los valores del MEI para ser utilizados como indicador de la evolución futura del evento ENOS y su influencia en el clima de la región del Caribe.

1. Materiales y metodos

1.1 Datos empleados.

Se trabajó con la serie del Índice Multivariado del ENOS (MEI) desarrollado por Wolter, K., and M.S. Timlin de la NOAA-CIRES Climate Diagnostics Center (CDC) ya que integra más información que otros índices debido a que refleja la naturaleza de la interacción del sistema océano-atmósfera mejor que cualquier componente. Este índice numérico está compuesto por 6 variables observadas en el Pacífico Tropical, presión al nivel del mar, componente zonal y meridional del viento en superficie, temperatura superficial del mar, temperatura del aire en superficie y nubosidad expresada en porcentaje, oscilando entre valores positivos para la fase cálida y negativos para la fase fría, los cuales son actualizados mensualmente.

1.2 Método.

Los modelos autorregresivos heterocedásticos condicional (ARCH) fueron introducidos por Engle (1982) con el propósito de capturar ampliamente la dinámica temporal de la volatilidad de los procesos. Varios trabajos recientes como los de Bera, y Higgins (1995), Bollerslev, Chou y Kroner (1992), Bollerslev, Engle y Nelson (1994), Diebold y López (1995) y Palm (1996) muestran un número extenso e impresionante de desarrollos teóricos y aplicaciones dirigidas a series econométricas, que han tenido lugar en países desarrollados durante la última década. Los modelos Generalizados Autorregresivos Condicional Heterocedásticos (GARCH), le da nombre a la ampliación del modelo ARCH que fueron desarrollados por los anteriores autores para los ordenes p,q, y Taylor (1986), para el caso particular de orden (1,1).

Los procesos ARCH, son modelos genéricos que estiman la variación condicional como una función medida a partir de los valores anteriores o retardos, donde la dinámica de volatilidad es modelada explícitamente en tiempo discreto. Es decir tiene como finalidad determinar un patrón de comportamiento estadístico para la varianza dentro de la familia de modelos Autorregresivos.

El proceso ARCH(q) viene expresado por la siguiente ecuación:

$$y_t = \varepsilon_t \sigma_t \quad (1)$$

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i y_{t-i}^2$$

Donde: Epsilon (ε_t), es el término de error o ruido blanco y sigma (σ_t), es la varianza condicional del proceso.

En este modelo se hace depender a la variable y_t del valor de su varianza multiplicada por un cierto término aleatorio que es el «ruido blanco» donde ω es la media del proceso en torno al cual se producirán ciertas variaciones, entendiéndose como el valor alrededor del cual se regresan las expectativas inmediatas a ser modificadas y el sumando $\alpha_i y_{t-i}^2$ es la innovación sobre la volatilidad que se produce en el periodo anterior (término ARCH)

El modelo ARCH(q) que se presenta en la ecuación 1, puede presentar dificultades a la hora de estimar estructuras dinámicas en el cuadrado de las series, motivando que el número de retardos a utilizar sea muy elevado y esto conllevaría a efectuar un número de iteraciones elevadas para lograr la solución al sistema pudiéndose dar el caso de que no se pueda encontrar nunca una solución. Por ello se efectuaron ciertas restricciones a dicho proceso los cuales condujeron a los modelos GARCH (p,q).

$$y_t = \varepsilon_t \sigma_t \quad (2)$$

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i y_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2$$

La ecuación 2, representa el valor actual de la varianza en el periodo t, de los valores que esta haya tenido en el momento anterior (t-1) y de las fluctuaciones aleatorias que también se sustentan en el pasado. Donde el sumando $\beta_j \sigma_{t-j}^2$ es la predicción de la varianza en el último periodo histórico conocido (término del GARCH)

De todo lo anterior se arriba a que el modelo ARCH(q) dado por la ecuación (1), no es más que un caso particular del Modelo GARCH descrito por la ecuación 2 (en el que todos los parámetros b, son iguales a cero).

1.3 Metodología de verificación.

Existen varios índices o estadígrafos para el análisis del ajuste o concordancia entre los valores reales de una serie y los valores simulados por el modelo, para ello se trabajó con el índice de Concordancia Di, dado por la ecuación siguiente:

$$D_i = 1 - \left(\frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (|P_i - \bar{O}| + |O_i - \bar{O}|)^2} \right) \quad (3)$$

Donde: $0 \leq D_i \leq 1$, P: es el valor pronóstico O: es el valor observado y \bar{O} : es la media de los valores observados.

Si $D_i \approx 0$, indica una mala concordancia entre los valores predicho y los observados por tanto el modelo no resulta adecuado para los objetivos que se diseñó.

Si $D_i \approx 1$, indica una buena concordancia entre los valores predicho y observados, luego el modelo resulta adecuado para los propósitos seleccionados.

Este índice es preferido al coeficiente de correlación r y de determinación r² ya que estos muestran frecuentemente magnitudes engañosas e irreales (Willmott 1982).

Conjuntamente con este indicador se usó el Factor Skill, el cual esta dado por la expresión siguiente:

$$\beta_i = 1 - \frac{Var(P_{obs_i} - P_{est_i})}{Var(P_{obs_i})} \quad (4)$$

Donde, $i=1, 2, \dots, n$, P_{obs_i} son las observaciones reales y P_{est_i} las estimadas por el modelo de predicción y Var es la varianza (Levezey, 1995).

Este índice de calidad se interpreta de la siguiente manera: Si $\beta_i \approx 1$, entonces no hay diferencias entre la situación pronosticada y la observada, sin embargo, si este índice toma valores muy próximos a

cero ($\beta_i \approx 0$), entonces, hay diferencias significativas entre los valores pronosticados y reales, por lo tanto el modelo no resulta adecuado.

2. Resultados.

Antes de presentar los resultados alcanzados de las predicciones con el modelo, expondremos los fundamentos que justifican la selección y uso de estos modelos en la simulación del índice MEI para su pronóstico, así como de la calidad del ajuste, la estimación de la componente autorregresiva y de la varianza condicional, considerando para los mismos dos períodos, uno para el ajuste y otro para la validación de los pronósticos, el primero abarca desde 1961 al 1999 y el segundo del 2000 al 2003.

Primeramente estimamos la componente autorregresiva de primero y segundo orden, la cual fue indicada por las características de la función de autocorrelación, los criterios de Akaike y Schwarz tal y como se puede contrastar con el test de Engles L-Jung-Box, es decir no hay ninguna dependencia entre el residuo y su valor en el período precedente para ordenes mayores que 3, resultando adecuado la selección y orden de los parámetros autorregresivos, (Tabla 1). Lo cual se corroboró también con la prueba de Dickey Fuller.

Tabla 1. Resultados que justifican lo adecuado de incluir una componente autorregresiva de segundo orden (AR(2)) para la modelación del MEI.

Contrastes aplicados.	Valor	Estadígrafo	Valor
LB _{log1}	471.43 (S)	Criterio de información Kaike	0.119419
LB _{log2}	875.61 (S)	Criterio de Schwarz	0.136100
LV	-28.27284	F-statistic	7255.553
Durbin-Watson stat	2.040920	Prob(F-statistic)	0.000000

LB.L-Jung-Box, LV: Logaritmo de la función de verosimilitud. S: significativo.

Los resultados de la aplicación del Test LM-ARCH para el contraste de la heterocedasticidad, corrobora la hipótesis de que debemos usar un modelo de la familia GARCH(p,q) para la simulación del proceso, ya que el mismo tomó valores claramente significativos (Tabla 2), corroborando que el indicador analizado presenta cambio de varianza en el tiempo, detectando la presencia de heteroscedasticidad condicional en la serie de los residuos y de residuos al cuadrado respectivamente, lo que justifica el empleo de este tipo de modelo, por lo tanto se decidió incluir los parámetros para modelar la varianza.

Tabla 2. Resultados del Contraste de hipótesis de linealidad del proceso.

Prueba de hipótesis para el ARCH:

Variable	Coefficientes	Error estándar	Valor del estadístico t	Probabilidad
Estadístico F	20.28096	Probabilidad		0.000000
R cuadrado observado	37.75379	Probabilidad		0.000000
C	0.054890	0.007079	7.753709	0.0000
RESID^2(-1)	0.251971	0.044588	5.651145	0.0000
RESID^2(-2)	0.358426	0.044587	1.310384	0.0000
R- cuadrado	0.274760	Media de la variable dependiente		0.079490
R- cuadradoajustado	0.261074	Desviación estándar de La variable dependiente		0.131591
Error estándar de la regresión	0.126829	Criterio de información de Akaike		1.386037
Suma de cuadrados de los residuos	8.074921	Criterio de Schwarz		1.360941
Logaritmo de la función de verosimilitud	327.7244	Estadístico F		20.28096
estadístico de Durbin-Watson	1.986596	Probabilidad del estadístico F		0.000000

Tabla 3. Modelo AR(p) x GARCH(p,q). Período de estudio 1961-1999.

Variables	Coefficientes	Error estándar	estadístico Z	p
AR(1)	0.363024	0.038757	35.16857	0.0000
AR(2)	-0.418931	0.037382	-11.20681	0.0000
Ecuación de la Varianza				
C	0.001023	8.14E 05	12.56250	0.0000
ARCH(1)	-0.501492	0.007634	-2.815067	0.0049
GARCH(1)	0.517027	0.008376	120.2216	0.0000
Estadígrafos de Calidad del Ajuste				
R cuadrado	0.934924	Media de la variable dependient		0.130938
R cuadrado ajustado	0.934405	Desviación estándar de La variable dependiente		1.003947
Error estándar de la regresión	0.257125	Criterio de información de Akaike		0.111740
Suma de cuadrado de los residuos.	33.18895	Criterio de Schwarz		0.153441
Logaritmo de la función de verosimilitud	-23.32606	Valor del estadígrafo F		1803.010
Estadígrafo de Durbin-Watson	2.031515	Probabilidad del estadígrafo F		0.000000

Como se muestra en la Tabla 2, el contraste es claramente significativo entre la relación cuadrática de los residuos y sus valores retardados; por lo que resulta evidente rechazar la hipótesis nula, aceptando que existen evidencias de no linealidad en la varianza del proceso, luego es conveniente la construcción de un modelo de la familia GARCH.

Teniendo en cuenta los análisis anteriores se procedió a estimar y ajustar el modelo final, cuyos resultados se muestran en la Tabla 3, la cual resume los resultados de las estimaciones de los parámetros del modelo GARCH (1,1), realizados sobre los residuos del modelo autorregresivo de segundo orden [AR(2)], ajustado a la serie de tiempo referida en el estudio, observándose que todos los parámetros son significativos por lo que se evidencia claramente la factibilidad y calidad obtenida por el modelo propuesto para predecir el comportamiento del índice MEI y poder dar seguimiento a la evolución futura de los eventos ENOS.

3. Discusión.

3.1 Interpretación de los resultados del modelo.

Un aspecto muy importante en la modelación, es la comprensión física de la ecuación que se ha propuesto, de manera que se comprenda de manera adecuada el fenómeno estudiado y la simulación de su evolución en el tiempo, al lograrse este aspecto, brinda la posibilidad de lograr mejores ecuaciones para la simulación y predicción de los procesos climáticos.

En este caso la componente autorregresiva que se ha propuesto en el modelo, está describiendo la memoria del proceso, la cual es de segundo orden, es decir el modelo aprende de los dos bimestres anteriores.

La componente ARCH esta simulando la variabilidad del índice que se produce en el bimestre anterior, mientras que el término GARH esta simulando el último periodo histórico en que se presentó el cambio en varianza, en este caso a consecuencia de la presencia de un evento frío o cálido, según sea el caso. Por tanto mediante este modelo se puede recoger la señal de variabilidad dada por el patrón de variación bimensual que se produce regularmente la cual queda expresada mediante la componente autorregresiva. Mientras que el cambio en la señal de variabilidad de un proceso a otro queda recogido en la componente de la varianza, la cual es pronosticada.

3.2 Calidad del Modelo

Contar con un modelo con una buena calidad en sus ajustes, no necesariamente garantiza efectuar extrapolaciones, pues esto dependerá mucho de la habilidad del modelo para predecir, en particular de la función pronóstico que se logre de los ajustes efectuados, de manera que se pueda poner en practica los resultados del mismo, por ello se hace necesario efectuar la evaluación de las predicciones por diferentes métodos, que nos permitan tener un criterio de certeza sobre las predicciones, resultando de vital importancia el análisis del comportamiento de la función pronóstico aspecto que discutiremos a continuación.

Tabla. 4 Medidas Cuantitativas para evaluar la calidad del comportamiento de los pronósticos bimensuales del MEI (PMEI) frente a los valores observados durante el período 2000 al 2003.

Indicador	Valor del Factor Skill (β_i)	Valor del Índice de concordancia. D_i	ECM	%ECM
PMEI/MEI	0.948147	0.952366	0.007	0.7447

ECM: Error cuadrático medio

Estos resultados confirman lo planteado por Tong, (1990) de que los modelos de pronóstico con varianza condicional son preferibles a los incondicionales ya que los errores de predicción son menores, obteniéndose mejores resultados como observa en la Tabla 4 y la Figura 1, donde queda claro el alto nivel de concordancia entre los valores reales y pronosticados durante el período analizado.

Otro aspecto a señalar es que los errores de pronósticos que se obtienen con este modelo son inferiores a las variaciones bimestrales propias del MEI, las cuales oscilan entre ± 0.01 .

Según los valores pronósticos para los próximos meses Figura 2, se observa claramente el regreso a las condiciones normales en el Pacífico. Sin embargo, a pesar de la rapidez del cambio a valores negativos, lo cual puede asociarse con el comienzo de un evento de enfriamiento, todavía resulta muy temprano para efectuar tal afirmación, resultado este que se confirma al evaluar los valores pronósticos con los rangos en que se ubican los mismos (condición neutral).




Figura 1. Comportamiento de los valores reales del MEI y el PMEI. Para el período enero/2001 a mayo/2003

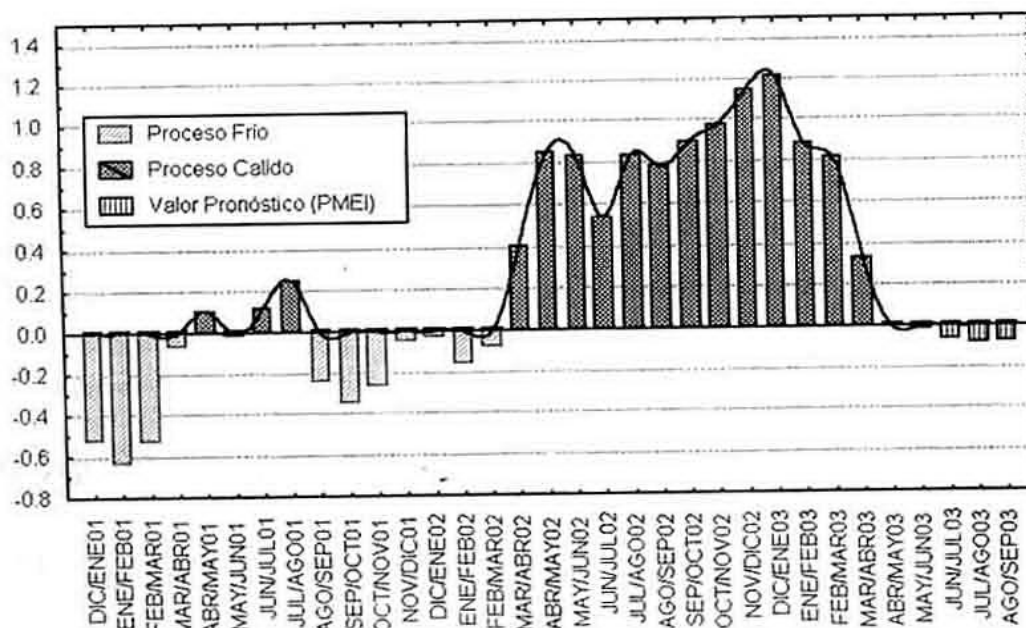


Figura 2 Valores reales del MEI y del PMEI para el período mayo - Septiembre del 2003

Conclusiones.

El presente artículo aborda un problema de gran interés para la literatura climatológica, la predicción de índices de eventos ENOS en particular el MEI, en el que se incluye su cambio de varianza en el tiempo. Desde el enfoque de los distintos trabajos dirigidos a esta temática, se ha propuesto un modelo con el fin de ganar en la calidad predictiva del fenómeno en estudio.

Los resultados alcanzados con este modelo con términos no lineales, parecen sugerir una mayor capacidad predictiva de las componentes que proceden de la volatilidad implícita por el fenómeno, pudiendo este recoger adecuadamente la volatilidad en el largo plazo.

Los pronósticos efectuados durante el período 2000-2003 con el uso de este modelo concuerdan con los efectuados por otros Centros regionales a partir de otros índices de eventos ENOS, sin embar-

go en cuanto a los niveles de incertidumbre de los pronósticos realizados son más bajos que los hasta ahora alcanzados por el SOI u otros índices.

El PMEI propuesto tiene dos características principales, en correspondencia con lo planteado por Cárdenas y Naranjo (1998, 2000) para el área y país en particular. Es consistente con el fenómeno físico que trata de describir y presenta ventajas en su utilización práctica.

Finalmente con este estudio se evidencia que las especificaciones teóricas que usan la varianza del proceso son adecuadas como medida de probabilidad para medir el riesgo de aparición del fenómeno ENOS, luego estas simulaciones deben ser realizadas mediante el uso de los modelos de varianza condicional.

Referencias:

- Bera, A.K. and M.L. Higgins (1995).** «On ARCH models : properties, estimation and testing», In L. Exley, D.A.R. George, C.J. Roberts and S.Sawyer (eds), *Surveys in Econometrics*. (Basil Blackwell : Oxford).
- Bollerslev, T, Y.C. Chou and K. Kroner (1992).** «ARCH Modelling in Finance a Selective Review of the Theory and Empirical Evidence», *Journal of Econometrics* 52, 201-224.
- Bollerslev, T., R. Engle and D. Nelson (1994).** «ARCH Models», In R.F.Engle and D. McFadden (eds.). *Handbook of Econometrics, Volume IV*, (North-Holland, Amsterdam).
- Cárdenas. P. y Naranjo. L. (1998).** «Un índice empírico de ocurrencia de ENOS». Papel en la predecibilidad de los elementos climáticos. Ciudad de la Habana. Cuba. Reporte de investigación.
- _____. (2000). «El Niño, La Oscilación del sur y el ENOS. Papel en la predecibilidad de elementos climáticos». *Anales de Física* Vol.95, 203-212.
- Diebold, F.X. and J.A. Lopez (1995),** «Modelling Volatility Dynam-ics», in K. Hoover (ed), *Macroeconomics : Developments, Tensions and Prospects*.
- Enfield, D. Y Mayer, D.A. (1995).** «Tropical Atlantic SST Variability and its relation to El Niño-Southern Oscillation». Submitted to *Geophys.Res.(Oceans)*.
- Enfield, . David B T (1998).** The dependence of Caribbean rainfall on the interaction of the Tropical Atlantic and Pacific Oceans.
- Engle R. F (1982).** Autorregressive Conditional Heteroscedasticity with Estimates of the Variance of U.K. Inflation. *Econometrica*; 50. Pgs:987-1008.
- Livezey R.E (1995).** The evaluation of forecasts. In: Von Storch H, Navarra A (eds) *Analysis of climate variability*, Sprenger-Verlag Berlin. p 177-196.
- Meulenert, A. R. (1991).** Efecto del evento El Niño Oscilación del Sur sobre el estado del tiempo en Cuba. INSMET. Editorial Academia.
- Palm, F.C. and Nijman, Th. (1984).** Missing Observations in the Dy-namic Regression Model», *Econometrica* 52, 1415-1435.26.
- Ruiz, E (1993).** Modelos para series temporales heterocedásticos. Cuadernos Económicos. ICE, 56pp: 73-108
- Tong, H (1990).** Non-Linear time series a Dynamical System approach. Oxford University. Oxford. Clarendon Press.
- Taylor, S. (1986).** Modelling Financial Time Series. Wiley .New York.
- Zwiens and Storch.(1990.** Regime Dependent Autoregressive time Series Modeling of the Souther Oscilation. *American Meteorological Society*, p 1347-1363.
- Wright, P.B (1997).** The Sothern Oscillation-Patterns and Mechanisms of the teleconnections and persistence. Hawaii. Institute of Geophysics Publ. 77-13.
- _____, (1985). The Southern Oscillation: An ocean-atmosphere feedback system. *Bull. Amer. Meteor. Soc.* 66, 398-412.
- _____, **J.M Wallace, T.P Mitchell and C. Deser (1988).** Correlation structure of the El Niño/Southern Oscillation phenomenon, *J. Climate*, 1, 609-625.
- Willmott,C J (1982),** Some component on the evaluation of model performance. *Bull.Am.Meteorol.Soc.* 63, 1309-1313.
- Wolter, K and M. S Timlin (1993).** Monitoring ENSO in COADS with a seasonally adjusted principal component index. Proc of the 17th Climate diagnostics workshop, Norman, OK, NOAA/CIMMS/CAC, NSSL, Oklahoma Clim. Survey, CIMMS and the School of Meteor. Univ. Of Oklahoma. 52-57.

Abstract:

El Niño/Southern Oscillation (ENSO) is the most important coupled ocean-atmosphere phenomenon to cause global climate variability on interannual time scales. The relationship indexes between El Niño/Southern Oscillation (ENOS), Quasi Biennial Oscillation (QBO), and others, contribute with enough information for the construction of Physical-Statistical Forecast Models. In this work a model starting from Multivariate ENSO Index (MEI) developed by Wolter, K and M.S, Timlin (1993) of the NOAA-CIRES Climate Diagnostics Center (CDC) which describes coupled Ocean-Atmosphere in the Pacific region. Taking as threshold MEI variab-les it is possible to fit the Generalized Autoregressive Conditional Heteroscedasticity model with non constant variance [GARCH (p, q)], which allows to simulate and to predict the behaviour of MEI values and, index MEI values, to determine if there is transition ENSO/AENSO phase. The values of the forecasted indexes are named as Prediction of the Multivariate of the event ENSO (PMEI) Index. This model gives the possibility to predict the occurrence of ENSO/AENSO events with 4 months of anticipation. Using the approach for ranges of stratification propose by Wolter, can determine the intensity and evolution of the phenomenon for next months.

Key words: predict of the multivariate ENSO index, PMEI, forecast index, and model GARCH(p,q)