



**ESCUELA SUPERIOR POLITÉCNICA DEL
LITORAL**
Instituto de Ciencias Matemáticas

Proyecto:
**“Un Modelo de Series Temporales para el Fenómeno
de El Niño”**

TESIS DE GRADO

Previa a la obtención del Título de:
INGENIERO EN ESTADÍSTICA INFORMÁTICA

Presentada por:
Ricardo Xavier Sánchez Firmat
GUAYAQUIL - ECUADOR

AÑO
2002

AGRADECIMIENTO

A Dios, por permitirme llevar a cabo este proyecto; a mis padres, por el apoyo incondicional que me brindaron; y a todos quienes hicieron posible la elaboración de esta tesis.

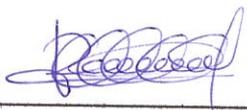
DEDICATORIA

A DIOS
A MIS PADRES
A MIS HERMANOS
A MIS AMIGOS

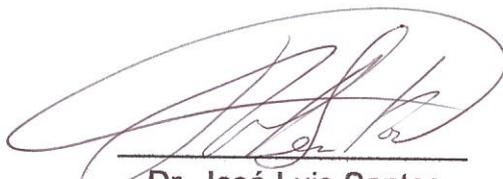
TRIBUNAL DE GRADUACIÓN



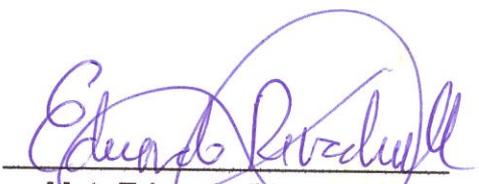
Ing. Luis Rodríguez
SUB-DIRECTOR DEL ICM



Mat. John Ramirez
DIRECTOR DE TESIS



Dr. José Luis Santos
VOCAL



Mat. Eduardo Rivadeneira
VOCAL

DECLARACIÓN EXPRESA

“La responsabilidad del contenido de esta tesis de grado, me corresponde exclusivamente; y el patrimonio intelectual de la misma a la ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL”

(Reglamento de graduación de la ESPOL)



Ricardo Xavier Sánchez Firmat

RESUMEN

El estudio del “Fenómeno del Niño”, sus causas y consecuencias, es de vital importancia debido a las repercusiones económicas y sociales que éste conlleva.

El siguiente estudio, tiene como objetivo primordial ayudar a aminorar los impactos negativos del Fenómeno de “El Niño”, en base a análisis de Modelos de Series de Tiempo de ciertas variables que sirven de referencia para determinar su aparición, y así tomar las medidas preventivas que sean necesarias para reducir su impacto.

En el 1er Capítulo, se hace referencia a conceptos básicos sobre el Fenómeno, para así conocer aspectos relativos a su formación y las consecuencia que éste conlleva.

El Capítulo 2 es el Marco Teórico, el cual detalla las herramientas estadísticas utilizadas en el análisis de los Modelos de Series Temporales.

En el 3er Capítulo se presentan diversos Modelos de Series Temporales para las diferentes variables de estudio.

En el 4to Capítulo se detallan las Conclusiones y Recomendaciones que se proponen producto del presente análisis.

INDICE GENERAL

	Pág.
RESUMEN	II
INDICE GENERAL	III
ABREVIATURAS	IV
SIMBOLOGÍA	V
INDICE DE GRÁFICOS	VI
INDICE DE FIGURAS	VII
INDICE DE TABLAS	VIII
INTRODUCCIÓN	1
1. EL FENÓMENO DE “EL NIÑO”	
1.1. Antecedentes	2
1.2. Diferencia entre Corriente y Fenómeno de “El Niño”	4
1.3. Oscilación Sur (OS)	6
1.4. Fases de un evento (ENOS)	7
1.5. Condiciones Normales y Condiciones “El Niño”	9
1.6. Efectos sobre la Biota	12
1.7. El Niño 1982 – 1983	14
1.7.1. Impacto de “El Niño” 1982-1983 en Ecuador	17
1.8. Temperatura Superficial del Mar	19
1.9. Variables de Estudio	20
1.10. Indicadores de la Presencia del Fenómeno de “El Niño”	23

2. MARCO TEÓRICO

2.1. Series de Tiempo	25
2.2. Procesos Estocásticos	26
2.3. Procesos Estacionarios	30
2.4. Procesos Lineales	32
2.5. Ecuaciones en Diferencias Finitas	33
2.6. Modelos Lineales	37
2.6.1. Modelos Autorregresivos (AR)	37
2.6.2. Modelos de Medias Móviles (MA)	41
2.6.3. Modelos Mixtos Autorregresivos-Medias Móviles	44
2.6.4. Modelos ARIMA(p,d,q)	45
2.7. Elaboración de Modelos	46
2.8. Identificación de Modelos Estacionarios	48
2.8.1. Función de Autocorrelación Estimada (FACE)	48
2.8.2. Función de Autocorrelación Parcial Estimada (FACPE)	49
2.9. Modelos para Series de Tiempo Estacionales	51
2.10. Pronósticos para Series No Estacionales	53
2.11. Pronósticos para Series Estacionales	54
2.12. Elección del Mejor Modelo	54

3. ANÁLISIS ESTADÍSTICO

3.1. Análisis Univariado	56
3.1.1. Variable: TSM Niño 1+2	56
3.1.2. Variable: TSM Niño 3	58
3.1.3. Variable: TSM Niño 3.4	60
3.1.4. Variable: TSM Niño 4	62
3.1.5. Variable: Temperatura del Aire	65
3.1.6. Variable: Precipitaciones	67
3.2. Series Temporales	69
3.2.1. Introducción	69
3.2.2. Variable: TSM Niño 1+2	70
3.2.3. Variable: TSM Niño 3	84
3.2.4. Variable: TSM Niño 4	97
3.2.5. Variable: TSM Niño 3.4	111
3.2.6. Variable: Temperatura del Aire (Guayaquil)	126
3.3. Correlaciones	138

4. CONCLUSIONES Y RECOMENDACIONES

4.1. Conclusiones	140
4.2. Recomendaciones	144

BIBLIOGRAFÍA

ABREVIATURAS

TSM	Temperatura Superficial del Mar
TA	Temperatura el Aire
FAC	Función de Autocorrelación
FACP	Función de Autocorrelación Parcial
AR	Autorregresivo
MA	Media Móvil
SAR	Autorregresivo Estacional
SMA	Media Móvil Estacional
MCE	Media Cuadrática del Error

SIMBOLOGÍA

Δ	Operador de Diferencias
L	Operador de Retardos
p	Parámetros autorregresivos estacionarios
q	Parámetros medias móviles estacionarios
P	Parámetros autorregresivos estacionales
Q	Parámetros medias móviles estacionales
d	Número de veces que se diferencia estacionariamente
D	Número de veces que se diferencia estacionalmente
s	Período de la estacionalidad
H_0	Hipótesis Nula
H_1	Hipótesis Alternativa
t	Estadístico de prueba t de student
Valor p	Mínimo valor de significancia donde H_0 es rechazada
γ_k	Covarianza entre Y_{t+k} y Y_t
ρ_k	Correlación entre Y_{t+k} y Y_t
ϕ_i	Coefficiente autorregresivo de Y_{t-i}
θ_i	Coefficiente media móvil de Y_{t-i}

λ_i	i-ésima raíz de ecuación homogénea
ϵ_t	Ruido blanco
r_k	Autocorrelación estimada
ϕ_{kk}	Autocorrelación parcial estimada
B	Operador de retardos
∇	Operador equivalente a $1-B$
ϕ_p	Polinomio de grado p
θ_P	Polinomio de grado P
Θ_q	Polinomio de grado q
Θ_Q	Polinomio de grado Q
φ_k	Coefficientes de ecuaciones diferenciales
ψ_k	Ponderaciones de errores
Π_k	Ponderaciones de observaciones

INDICE DE GRÁFICOS

	Pág
Gráfico 3.1 Promedio Mensual – TSM Niño 1+2	57
Gráfico 3.2 Promedio Mensual – TSM Niño 3	59
Gráfico 3.3 Promedio Mensual – TSM Niño 3.4	61
Gráfico 3.4 Promedio Mensual – TSM Niño 4	63
Gráfico 3.5 Promedio Mensual – Temperatura del Aire	66
Gráfico 3.6 Promedio Mensual – Precipitaciones	68
Gráfico 3.7 Serie de Tiempo – TSM Niño 1+2	70
Gráfico 3.8 FAC TSM Niño 1+2 Modelo ARIMA(0,0,0)	71
Gráfico 3.9 FACP TSM Niño 1+2 Modelo ARIMA(0,0,0)	71
Gráfico 3.10 FAC TSM Niño 1+2 SARIMA(0,0,0)x(0,1,0) ¹²	72
Gráfico 3.11 FACP TSM Niño 1+2 SARIMA(0,0,0)x(0,1,0) ¹²	72
Gráfico 3.12 FAC TSM Niño 1+2 SARIMA(1,0,0)x(0,1,1) ¹²	74
Gráfico 3.13 FACP TSM Niño 1+2 SARIMA(1,0,0)x(0,1,1) ¹²	74
Gráfico 3.14 FAC TSM Niño 1+2 SARIMA(1,0,1)x(0,1,1) ¹²	76
Gráfico 3.15 FACP TSM Niño 1+2 SARIMA(1,0,1)x(0,1,1) ¹²	76
Gráfico 3.16 FAC TSM Niño 1+2 SARIMA(2,0,0)x(0,1,1) ¹²	78
Gráfico 3.17 FACP TSM Niño 1+2 SARIMA(2,0,0)x(0,1,1) ¹²	78
Gráfico 3.18 Pronósticos TSM Niño 1+2 SARIMA(2,0,0)x(0,1,1) ¹²	82

Gráfico 3.19	Serie de Tiempo – TSM Niño 3	84
Gráfico 3.20	FAC TSM Niño 3 ARIMA(0,0,0)	85
Gráfico 3.21	FACP TSM Niño 3 ARIMA(0,0,0)	85
Gráfico 3.22	FAC TSM Niño 3 SARIMA(0,0,0)x(0,1,0) ¹²	86
Gráfico 3.23	FACP TSM Niño 3 SARIMA(0,0,0)x(0,1,0) ¹²	86
Gráfico 3.24	FAC TSM Niño 3 SARIMA(1,0,1)x(1,1,1) ¹²	87
Gráfico 3.25	FACP TSM Niño 3 SARIMA(1,0,1)x(1,1,1) ¹²	87
Gráfico 3.26	FAC TSM Niño 3 SARIMA(2,0,0)x(0,1,1) ¹²	89
Gráfico 3.27	FACP TSM Niño 3 SARIMA(2,0,0)x(0,1,1) ¹²	89
Gráfico 3.28	FAC TSM Niño 3 SARIMA(2,0,1)x(0,1,1) ¹²	91
Gráfico 3.29	FACP TSM Niño 3 SARIMA(2,0,1)x(0,1,1) ¹²	91
Gráfico 3.30	Pronósticos TSM Niño 3 SARIMA(2,0,1)x(0,1,1) ¹²	95
Gráfico 3.31	Serie de Tiempo – TSM Niño 4	97
Gráfico 3.32	FAC TSM Niño 4 ARIMA(0,0,0)	98
Gráfico 3.33	FACP TSM Niño 4 ARIMA(0,0,0)	98
Gráfico 3.34	FAC TSM Niño 4 ARIMA(0,1,0)	99
Gráfico 3.35	FACP TSM Niño 4 ARIMA(0,1,0)	99
Gráfico 3.36	FAC TSM Niño 4 SARIMA(0,1,0)x(0,1,0) ¹²	100
Gráfico 3.37	FACP TSM Niño 4 SARIMA(0,1,0)x(0,1,0) ¹²	100
Gráfico 3.38	FAC TSM Niño 4 SARIMA(2,1,0)x(0,1,1) ¹²	101
Gráfico 3.39	FACP TSM Niño 4 SARIMA(2,1,0)x(0,1,1) ¹²	101
Gráfico 3.40	FAC TSM Niño 4 SARIMA(2,0,2)x(0,1,1) ¹²	103

Gráfico 3.41	FACP TSM Niño 4 SARIMA(2,0,2)x(0,1,1) ¹²	103
Gráfico 3.42	FAC TSM Niño 4 SARIMA(3,0,1)x(0,1,1) ¹²	105
Gráfico 3.43	FACP TSM Niño 4 SARIMA(3,0,1)x(0,1,1) ¹²	105
Gráfico 3.44	Pronósticos TSM Niño 4 SARIMA(3,0,1)x(0,1,1) ¹²	109
Gráfico 3.45	Serie de Tiempo – Niño 3.4	111
Gráfico 3.46	FAC TSM Niño 3.4 ARIMA(0,0,0)	112
Gráfico 3.47	FACP TSM Niño 3.4 ARIMA(0,0,0)	112
Gráfico 3.48	FAC TSM Niño 3.4 ARIMA(0,1,0)	113
Gráfico 3.49	FACP TSM Niño 3.4 ARIMA(0,1,0)	113
Gráfico 3.50	FAC TSM Niño 3.4 SARIMA(0,1,0)x(0,1,0) ¹²	114
Gráfico 3.51	FACP TSM Niño 3.4 SARIMA(0,1,0)x(0,1,0) ¹²	114
Gráfico 3.52	FAC TSM Niño 3.4 SARIMA(1,1,2)x(0,1,1) ¹²	115
Gráfico 3.53	FACP TSM Niño 3.4 SARIMA(1,1,2)x(0,1,1) ¹²	116
Gráfico 3.54	FAC TSM Niño 3.4 SARIMA(1,0,2)x(0,1,1) ¹²	118
Gráfico 3.55	FACP TSM Niño 3.4 SARIMA(1,0,2)x(0,1,1) ¹²	118
Gráfico 3.56	FAC TSM Niño 3.4 SARIMA(3,0,1)x(2,1,3) ¹²	119
Gráfico 3.57	FACP TSM Niño 3.4 SARIMA(3,0,1)x(2,1,3) ¹²	120
Gráfico 3.58	Pronóstico TSM Niño 3.4 SARIMA(3,0,1)x(2,1,3) ¹²	124
Gráfico 3.59	Serie de Tiempo – Temperatura del Aire	126
Gráfico 3.60	FAC Temperatura del Aire ARIMA(0,0,0)	126
Gráfico 3.61	FACP Temperatura del Aire ARIMA(0,0,0)	127

Gráfico 3.62	FAC TA SARIMA(0,0,0)x(0,1,0)12	128
Gráfico 3.63	FACP TA SARIMA(0,0,0)x(0,1,0)12	128
Gráfico 3.64	FAC TA SARIMA(1,0,1)x(0,1,1)12	129
Gráfico 3.65	FACP TA SARIMA(1,0,1)x(0,1,1)12	129
Gráfico 3.66	FAC TA SARIMA(1,0,1)x(0,1,2)12	131
Gráfico 3.67	FACP TA SARIMA(1,0,1)x(0,1,2)12	131
Gráfico 3.68	FAC TA SARIMA(2,0,0)x(0,1,2)12	133
Gráfico 3.69	FACP TA SARIMA(2,0,0)x(0,1,2)12	133
Gráfico 3.70	Pronóstico TA SARIMA(1,0,1)x(0,1,1)12	137

INDICE DE FIGURAS

	Pág.
Figura 1.1 El Niño – Mapa del Mundo	3
Figura 1.2 Condiciones Normales	10
Figura 1.3 Condiciones “El Niño”	11
Figura 1.5 Mapa de Ubicación de áreas de observación TSM	21
Figura 1.6 Mapa Pacífico Sudeste (Niño 1+2)	22
Figura 2.1 Serie de Tiempo	25
Figura 2.2 Correlograma	31

INDICE DE TABLAS

		Pág.
TABLA I	Estadística Básica – TSM Niño 1+2	56
TABLA II	Promedio Mensual – TSM Niño 1+2	58
TABLA III	Estadística Básica – TSM Niño 3	58
TABLA IV	Promedio Mensual – TSM Niño 3	60
TABLA V	Estadística Básica – TSM Niño 3.4	60
TABLA VI	Promedio Mensual – TSM Niño 3.4	62
TABLA VII	Estadística Básica – TSM Niño 4	62
TABLA VIII	Promedio Mensual – TSM Niño 4	64
TABLA IX	Estadística Básica – Temperatura del Aire	65
TABLA X	Promedio Mensual – Temperatura del Aire	66
TABLA XI	Estadística Básica – Precipitaciones	67
TABLA XII	Promedio Mensual – Precipitaciones	69
TABLA XIII	Pronósticos TSM Niño 1+2 SARIMA(2,0,0)x(0,1,1) ¹²	81
TABLA XIV	Anomalías TSM Niño 1+2	83
TABLA XV	Pronósticos TSM Niño 3 SARIMA(2,0,0)x(0,1,1) ¹²	94
TABLA XVI	Anomalías TSM Niño 3	96

TABLA XVII	Pronósticos TSM Niño 4 SARIMA(2,0,0)x(0,1,1) ¹²	108
TABLA XVIII	Anomalías TSM Niño 4	110
TABLA XIX	Pronósticos TSM Niño 3.4 SARIMA(2,0,0)x(0,1,1) ¹²	123
TABLA XX	Anomalías TSM Niño 3.4	125
TABLA XXI	Pronósticos TA SARIMA(1,0,1)X(0,1,1)	136

INTRODUCCIÓN

El “Fenómeno del Niño” es una anomalía oceanográfico-meteorológica de gran escala que se desarrolla en el Pacífico con manifestaciones costeras muchas veces espectaculares.

Durante muchos años, a pesar de los esfuerzos que se han hecho, tanto en movilizaciones de medios económicos y en despliegues de un gran número de científicos pertenecientes a múltiples programas de estudios nacionales e internacionales, no se ha podido predecir con certeza su presencia con la debida anticipación.

Sin embargo, el alto grado de precisión y confiabilidad alcanzado por las técnicas de observación, así como medios modernos de procesamientos de datos, softwares y demás herramientas, han logrado que cada vez los pronósticos sean cada vez más acertados.

A continuación se detalla un Análisis de Series Temporales de diversas variables que sirven de referencia para determinar su aparición.

Capítulo 1

1. EL FENÓMENO DE “EL NIÑO”

1.1. Antecedentes

Durante muchos años, los pescadores del Ecuador y Perú, han relacionado el comienzo de la estación de lluvias, con el avance de una corriente de aguas cálidas hacia la costa, y como generalmente ocurre en las últimas semanas de Diciembre, el nombre que se le dio fue el de Corriente de “El Niño”, por la cercanía a la fecha del Nacimiento del Niño Jesús.

El objeto de nuestro estudio no es la Corriente de “El Niño”, sino el Fenómeno de “El Niño”, el cual ocurre irregularmente cada 4 o 5 años, y en ciertos casos, este tiempo se ha visto acortado a 2 años o prolongado hasta 10 años.

El Fenómeno de “El Niño” es una alteración climática que abarca grandes extensiones del planeta, por lo cual se dice que es un fenómeno de macroescala.

Abarca gran parte del Océano Pacífico, especialmente la Región Tropical y Subtropical, pero compromete también al Indico y al Atlántico.

Involucra en sus efectos amplias áreas continentales de Asia, Oceanía, Europa y principalmente América, especialmente el Pacífico Oriental y particularmente Perú y Ecuador.

Es un fenómeno de grandes repercusiones sobre la vida tanto del océano como del continente, ya que conlleva fuertes sequías e inundaciones.

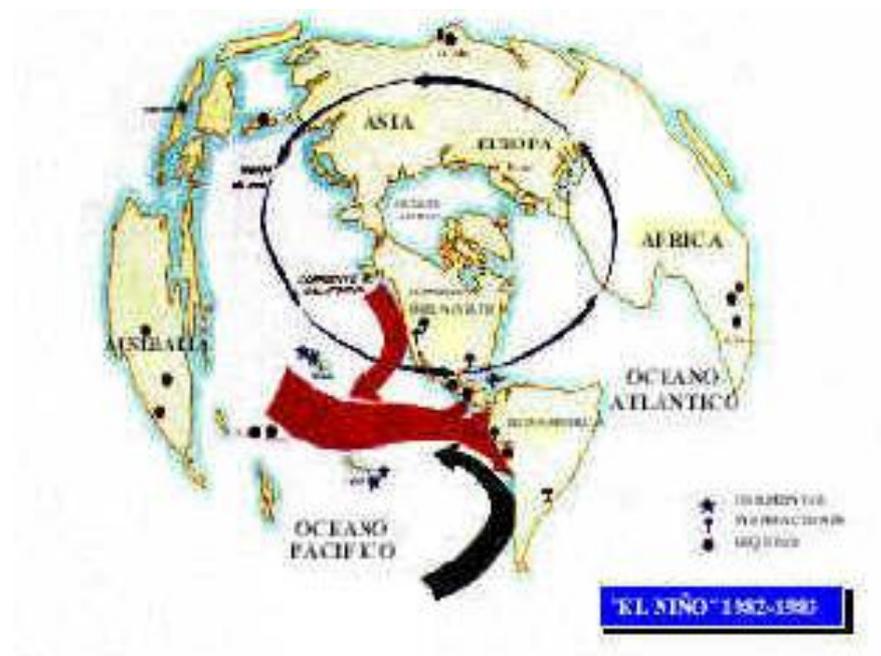


Figura 1.1 El Niño - Mapa del mundo

1.2. Diferencia entre Corriente y Fenómeno del Niño

La Corriente del Niño trata de un evento oceanográfico periódico y normal que sucede cada año durante los meses de Diciembre a Abril; esta tiene características de aguas cálidas que provienen del norte de la cuenca de Panamá y bajan por las costas de Sudamérica, la cual marca el inicio de la estación cálida y húmeda de la región costera del Ecuador.

En cambio, el Fenómeno del Niño o también conocido como evento ENOS (El Niño-Oscilación Sur) por su relación con la Oscilación del Sur, se trata de un evento aperiódico, por lo que este sucede hasta cierta forma de manera sorpresiva y sus consecuencias se dan a nivel global y no únicamente en las costas de Sudamérica como en el caso anterior.

Por su parte el evento ENOS se lo define científicamente como la respuesta dinámica del océano Pacífico al forzamiento prolongado de los vientos ecuatoriales, así como la presencia de aguas cálidas frente a las costas de Ecuador y Perú con anomalías (desviaciones de su valor normal) superiores a una desviación estándar por no menos de cuatro meses.

Cada evento ENOS varía notablemente entre uno y otro, principalmente en lo que se refiere a su intensidad y duración, por lo que se los ha clasificado en cuatro categorías de acuerdo a su intensidad, estas son: débil, moderado, fuerte y extremadamente fuerte. Cabe resaltar que el evento EL Niño más fuerte registrado en este siglo ha sido el de los años 1982-1983, el cual fue calificado como extraordinariamente fuerte por los efectos causados a nivel mundial.

En la actualidad, se pone una hipótesis que explica el patrón de formación de “El Fenómeno”.

Las corrientes marinas en el pacífico Oriental Tropical responden a la acción de los vientos alisios del SE y NE; cuando estos vientos son fuertes, las corrientes de Humboldt y Sur Ecuatorial incrementan su flujo y transporte de aguas hacia el Pacífico Occidental, de esta manera producen una acumulación de aguas en este sector del océano; la duración de esta actividad puede llegar hasta los 18 meses; posteriormente los vientos alisios decaen considerablemente produciéndose el retorno del agua acumulada en el Pacífico Occidental hacia el Pacífico Oriental.

Esta hipótesis ha sido valedera para los Fenómenos que ocurrieron en 1972-1973 y 1976, sin embargo, “El Niño” 1982-1983 respondió a un patrón de formación diferente, se presentó en forma sorpresiva y desfasado, con tres meses se adelantó al comienzo de la estación invernal en nuestra costa, por lo que se han abierto nuevas interrogantes sobre las causas de su formación que, indudablemente responden a problemas de interacción del océano y la atmósfera a gran escala.

1.3. Oscilación Sur (OS)

La contraparte atmosférica del Niño, es la Oscilación sur (OS), la cual está dada por la diferencia de presión atmosférica entre los centros de alta y baja presión del pacífico (Tahití – Darwin).

Este valor es también conocido como el Índice de Oscilación Sur y guarda una alta correlación con la ocurrencia con la ocurrencia de los eventos El Niño; así durante los Anti-El Niño (época fría) la OS presenta su fase positiva y durante El Niño la OS se presenta en su fase negativa. Esta relación entre el Niño y la OS se la conoce como los eventos ENOS (El Niño/Oscilación Sur).

Esta relación entre “El Niño” y la Oscilación del Sur provoca cambios climáticos en lugares distintos y lejanos de donde estos se producen conociéndoselos como Teleconexiones, de tal manera que durante un evento ENOS tenemos sequía en Australia, Indonesia, Noreste de Brasil, Africa Ecuatorial entre otros lugares, mientras que se producen copiosas lluvias en Ecuador, Perú, California por mencionar algunos.¹

1.4. Fases de un evento (ENOS)

Durante un típico evento ENOS (El Niño/Oscilación Sur), se reconocen cuatro fases:

- a) **Fase Precursora**, en la cual se presentan fuertes vientos ecuatoriales de este a oeste, así como corrientes ecuatoriales de superficie transportando agua hacia la región occidental del pacífico (región Australiana); la presencia de estos vientos favorece el ascenso hacia la superficie del mar de aguas frías y ricas en elementos nutritivos; el transporte de agua hacia la margen occidental del Pacífico incrementa el nivel medio del mar en ese lugar mientras que disminuye en la margen oriental (frente a las costas de Ecuador y Perú); la temperatura del mar

¹ Véase *Diagnóstico de “El Niño” 1997 INOCAR*

disminuye, se intensifica la corriente fría de Humboldt, el IOS se incrementa (valores positivos) y se presentan bajo valores de lluvias (tendencia a la sequía) en la costa de Sur América mientras que en la región de Australia y Nueva Zelandia se presentan lluvias torrenciales.

- b) **Fase de Inicio**, alrededor de Octubre en el Pacífico Ecuatorial Central se debilitan los vientos del este y aparecen vientos del Oeste, eliminándose el ascenso de aguas frías hacia la superficie del océano, apareciendo en su lugar valores altos de temperatura superficial del mar; el IOS desciende a valores negativos, la zona de alta pluviosidad inicia su desplazamiento hacia el Este, mientras que frente a Ecuador y Perú se inicia el ascenso del nivel medio del mar y la profundización de las capas de aguas frías, la corriente de Humboldt se debilita y no alcanza las costas del Ecuador.
- c) **Fase Madura**, las altas temperaturas superficiales del mar alcanzan las costas de América entre los meses de Diciembre a Enero, al tiempo que el nivel del mar aumenta notablemente y se profundizan las aguas frías incrementándose el contenido de

calor en las capas superficiales; las altas precipitaciones se generalizan en toda la costa del Ecuador, mientras que en la región de Australia y Nueva Zelandia se presentan severas y prolongadas sequías; el IOS continúa negativo, (la presión es mucho más alta que el promedio de Darwin y mucho más baja que el promedio en Tahití) pudiendo incrementarse dependiendo de la magnitud del evento El Niño. Esta fase puede durar entre 10 y 15 meses.

- d) **Fase de Decaimiento**, en el Pacífico Central se comienzan a debilitar los vientos del Oeste; en el pacífico Oriental desciende la temperatura superficial del mar al igual que el nivel medio del mar, se fortalecen las corrientes ecuatoriales hacia el Oeste; el IOS recupera sus valores normales al igual que el patrón de precipitación y en general el Pacífico Tropical retorna a sus condiciones normales.

1.5. Condiciones Normales y Condiciones “El Niño”

En condiciones normales, las corrientes atmosféricas, desplazan ligeramente el volumen del agua del océano Pacífico hacia la costa este.

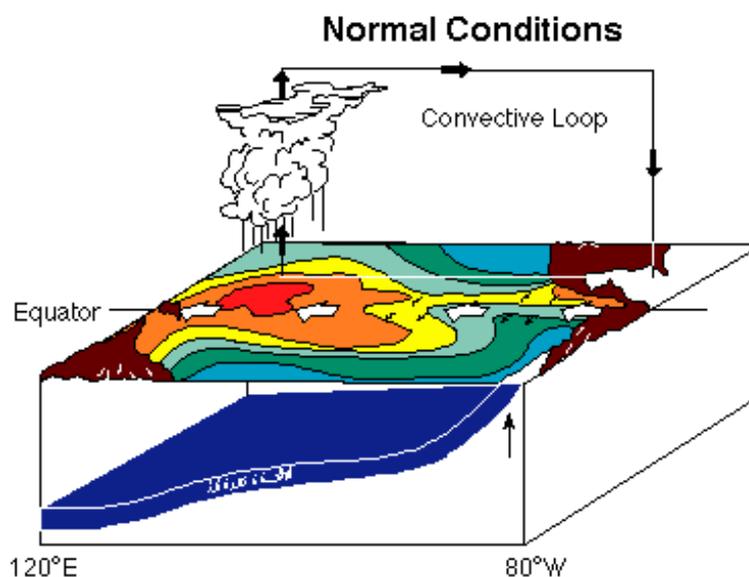


Figura 1.2 Condiciones Normales

En las condiciones del Niño, por algún motivo de origen incierto, las corrientes atmosféricas quedan alteradas, disminuyendo de intensidad en su dirección habitual (oeste-este) o incluso invirtiéndose.

Esta disminución o incluso inversión de la corriente superficial causa una variación del nivel del océano que en algunos Niños puede llegar a los 40 cm. Paralelamente se da un incremento de la temperatura superficial del océano (en el Niño de 1982 de hasta 8°C) y un descenso de la termoclina (línea que separa las aguas frías ricas en nutrientes, de las cálidas, más pobres) que conlleva importantes consecuencias sobre la vida marina.

En la costa, las aguas se mezclan por unas corrientes naturales originadas por el impacto de la masa acuática sobre el continente. Durante un periodo normal, las corrientes mezclan el agua fría con la cálida, pero durante el Niño, el descenso de la termoclina impide esta mezcla, ya que la corriente no desciende al descender la termoclina.

La anomalía térmica de la superficie oceánica altera el clima habitual de las regiones afectadas (costa de Sur América, especialmente Perú, Ecuador y archipiélagos del Pacífico como las Galápagos). Esta alteración se manifiesta en forma de fuertes inundaciones y sequías.

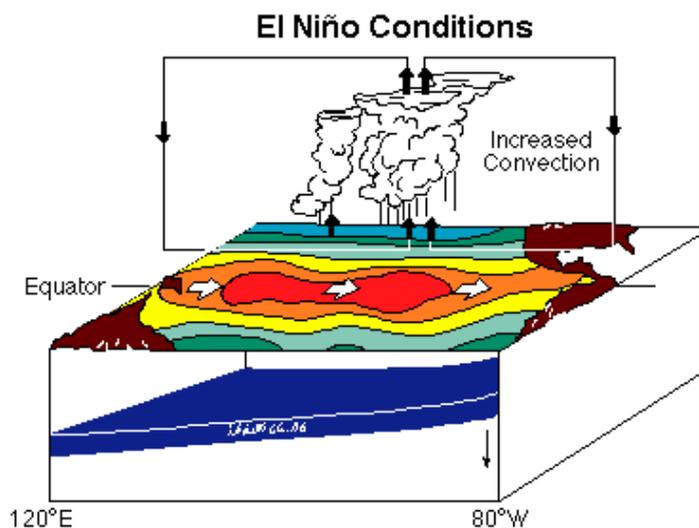


Figura 1.2 Condiciones El Niño

Áreas habitualmente húmedas del interior entran en un periodo de sequía, mientras el desierto florece a causa de las generosas precipitaciones. Lagunas andinas se secan totalmente, mientras en otras zonas, las lluvias torrenciales se llevan puentes, caminos, y en algunos casos vidas humanas.

1.6. Efectos sobre la Biota

Durante un Niño hay una mortandad enorme de especies marinas. El descenso de la termoclina y la consecuente disminución de la concentración de nutrientes en la superficie conlleva directamente a esta mortalidad tan elevada.

La disminución de los nutrientes afecta directamente a la producción de algas y fitoplancton, que disminuye fuertemente. Si la base de la cadena alimentaria se ve afectada por una fuerte disminución, es lógico y cabe esperar que tanto los herbívoros como los depredadores sufran una disminución equivalente.

Numerosas especies de peces migran a aguas del sur, más ricas en nutrientes, mientras especies tropicales empiezan a poblar esta área. Los bancos de peces que no migran, disminuyen en número

de individuos, y a su vez, estos quedan más flacos, débiles; la reproducción queda truncada. Lo mismo pasa con los moluscos, los peces depredadores, las aves marinas, y los mamíferos marinos.

En la costa las rocas pierden su cobertura de algas y animales pasturadores (erizos, mejillones), quedando desnudas de vida.

No todas las especies se ven afectadas negativamente. Un ejemplo de este hecho serían las iguanas de las Galápagos: Allí podremos encontrar dos tipos de iguanas, una marina y otra terrestre.

Durante el Niño, la marina ve como su alimento, las algas, disminuye drásticamente, sufriendo una disminución en el número de sus individuos. Mientras, la terrestre se beneficia del aumento de la vegetación al aumentar las precipitaciones, y por lo tanto empieza a expandir el número de individuos.

Esta situación se mantiene hasta el fin de “El Niño”, en la que la situación retorna a las condiciones normales. Estas condiciones normales conllevan a la recuperación de la especie marina, y también al secado de toda la nueva vegetación e incendios que la destruyen.

La especie terrestre sufre una fuerte disminución, recuperándose con el tiempo, cuando la situación ya vuelve a la normalidad en el ecosistema.

Cuando pasa el Niño, al igual que en las Galápagos, las áreas afectadas vuelven a la normalidad en un periodo de unos 2 años, empezando por las especies vegetales, y acabando por las especies depredadoras.

1.7. El Niño 1982-1983

En la segunda quincena de Octubre de 1982, la costa ecuatoriana sentía las primeras lluvias de lo que sería uno de los inviernos más crudos en las últimas décadas. Esta particularidad no se había observado desde el año 1972, cuando las lluvias aparecieron durante el último trimestre del año como una consecuencia del fenómeno "El Niño".

Para Noviembre de 1982, las lluvias se habían generalizado y alcanzaban valores significativos, en toda la costa nacional, a tal punto que para el mes siguiente las precipitaciones eran tan fuertes que comenzaron los desbordes de los ríos e inundaciones de ciudades, poblados y de gran parte de las zonas agrícolas

sobre todo de aquellas provincias ubicadas en el centro del litoral ecuatoriano. Decenas de vidas y miles de hectáreas de sembríos de maíz, arroz, caña de azúcar y otros productos se perdían por el temprano invierno y lo abundante de las lluvias, situación que se agravaba aún más por la destrucción de puentes, caminos vecinales y carreteras que componen la red vial de la costa lo que dificultaba las comunicaciones y el normal abastecimiento e intercambio de productos, en fin, el impacto y el perjuicio social-económico que sufría la nación como causa de las circunstancias climáticas que vivía el litoral ecuatoriano a fines de 1982 tenían características de catástrofe al punto que el gobierno tuvo que declarar el estado de emergencia en todas esas provincias.

Todo esto fue consecuencia de un fenómeno “El Niño” que tomó a todos los especialistas desprevenidos.²

“El Niño “ 1982-1983 se presentó a consecuencia de las fluctuaciones climáticas relacionadas con la Oscilación Sur (OS), la cual se describe en términos de la diferencia entre las anomalías de la presión superficial entre Darwin-Australia y Tahití en el Pacífico Central.

² Véase *Acta Oceanográfica del Pacífico Vol. 3 N°1 1986 INOCAR*

La presión para estas dos estaciones, mostraba que la Oscilación Sur a partir de Abril-Mayo de 1982, entraba en una fase negativa, lo que significa que las anomalías de presión en Darwin eran positivas y en Tahití negativas.

Las altas presiones en Darwin trajeron como consecuencia una alarmante sequía sobre la región Indo-Australiana y una reducción de las precipitaciones (valores bajo lo normal) para los meses de Junio, Julio y Agosto sobre una considerable área de Indonesia. Así mismo al Sureste de Australia se produjeron sequías que se agravaron por las altas temperaturas, especialmente durante Agosto. Complementariamente, las bajas presiones de Tahití provocaron un decaimiento de los vientos alisios y un aumento de las precipitaciones con valores superiores a los normales en el sector del Pacífico Central Ecuatorial.

El Niño 1982-1983 creó una serie de interrogantes, fundamentalmente por no seguir el patrón de formación conocido y porque sus efectos sobre el clima costero, sobre las pesquerías y en general sobre la condición socio-económica del país han sido de tal magnitud que han tenido características de catástrofe, y si

bien el fenómeno sobrevino como una consecuencia de las fluctuaciones climáticas del OS, en cambio no está bien entendido porqué causas el índice de presión Tahití-Darwin, que se mantuvo dentro de los valores normales a fines de 1981 y comienzos de 1982, descendió a valores negativos considerablemente bajos en los meses subsiguientes.

1.7.1. Impacto de “El Niño” 1982-1983 en Ecuador

A continuación mostraremos algunas cifras significativas, que nos muestran de una manera clara el impacto que sufrió nuestro país durante este período.³

Impacto Pluviométrico

Guayaquil

➤ Puvliometría medio (mm)	1016
➤ Período Oct. 82 – Sept. 83 (mm)	4600

Salinas

➤ Puvliometría medio (mm)	126
➤ Período Oct. 82 – Sept. 83 (mm)	2833

Machala

➤ Puvliometría medio (mm)	471
➤ Período Oct. 82 – Sept. 83 (mm)	3184

³ Véase *Bulletin de l'Institute Francais d' Etudes Andines Tome 27 N° 3 1998*

Impacto Social y Económico (estimaciones mínimas)

- 260 muertos
- 200 millones de dólares en pérdidas en la propiedad.
- 100 millones de dólares en pérdidas agrícolas.
- 250 millones de dólares en destrucción de infraestructuras agrícolas y viales.
- Ingresos de la flota pesquera nulos desde enero de 1983 y durante 2 años.

Impacto Ecológico en las Islas Galápagos

- Aniquilación de las crías de piqueros de patas azules.
- Disminución de la iguanas marítimas.
- Fuerte disminución de las tijeretas (de 20000 a menos de 100 en noviembre de 1983)
- Muerte de todos los juveniles de focas.
- Al contrario, auge de los pinzones y de la vegetación

1.8. Temperatura Superficial del Mar

Se hace necesario tomar en consideración la influencia de la TSM sobre la circulación atmosférica, y por ende, analizar las interacciones internas del binomio océano-atmósfera.

En las zonas más calientes, los movimientos ascendentes de aire húmedo dan nacimiento a extensas formaciones nubosas cuya condensación produce fuertes precipitaciones, mientras que en otras partes la subsistencia de aire seco y frío desde la tropósfera superior genera una especie de capa que impide la formación de nubes susceptibles de dar lluvias de consideración.

Durante un episodio ENSO, las TSM son más elevadas que el valor medio en el Pacífico Este, y en cambio siguen iguales e inclusive inferiores a la media en la zona oeste.

Por lo tanto, la gradiente Este-Oeste desaparece y la zona de precipitaciones máximas se mueve hacia el este, lo que produce fuertes lluvias en las islas del Pacífico central ecuatorial, y drásticas sequías en Indonesia y regiones adyacentes.

1.9. Variables de Estudio

Las variables a tomar en cuenta para nuestro análisis son:

➤ **Temperatura Superficial del Mar**

- Niño 1+2

- Niño 3

- Niño 4

- Niño 3.4

➤ **Temperatura del Aire (Guayaquil)**

➤ **Precipitaciones (Guayaquil)**

Las observaciones de las variables de la Temperatura Superficial del Mar son tomadas en cuatro diferentes áreas del Pacífico Ecuatorial.

Los datos obtenidos en estas áreas van desde el año 1950 hasta el año 2000, por lo que tendríamos 612 observaciones por cada variable de la Temperatura Superficial del Mar.

Las observaciones de la variable Temperatura del Aire, son tomadas de la ciudad de Guayaquil desde el año 1961, hasta el año 2000 por lo que tendríamos 480 observaciones.

Así mismo las observaciones de la variable precipitaciones son obtenidas de la ciudad de Guayaquil, desde el año 1961, hasta el año 2000 por lo que también tendríamos 480 observaciones.

A continuación detallamos la ubicación de las áreas de observación de las variables de la Temperatura Superficial del Mar en el Pacífico Ecuatorial:

El área de observación de la variable **TSM Niño 4** está ubicada entre los 160°E y 150°W – 5°N y 5°S.

El área de observación de la variable **TSM Niño 3** está ubicada entre los 150°W y 90°W – 5°N y 5°S.

El área de observación de la variable **TSM Niño 3.4** está ubicada entre los 170°W y 120°W – 5°N y 5°S.

El área de observación de la variable **TSM Niño 1+2** está ubicada entre los 90°W y 80°W – 0° y 10°S.

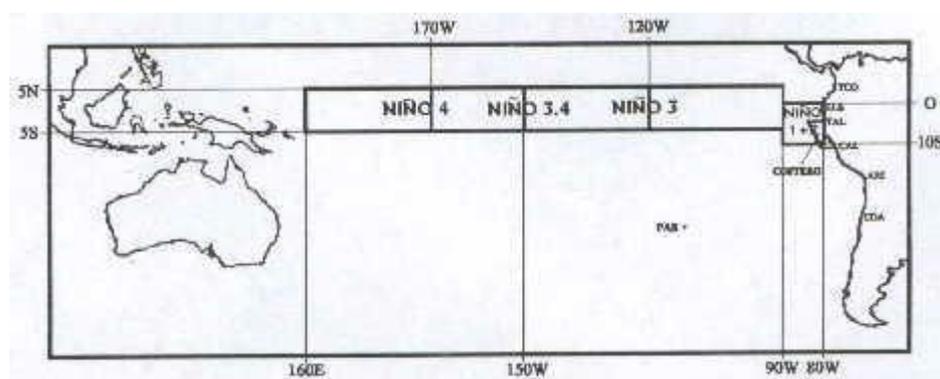


Figura 1.4 Mapa de Ubicación de áreas de observación de TSM

1.10. Indicadores de la Presencia del Fenómeno de “El Niño”

Los principales indicadores oceanográficos y meteorológicos que nos ayudan a determinar la presencia del Fenómeno de “El Niño” son:

- Temperatura superficial del mar en el Océano Pacífico Tropical.
- Índice de Oscilación del Sur.
- Intensidad de los Vientos Alisios.
- Anomalías Térmicas del Pacífico Tropical
- Profundidad de la Isoterma de 20°C
- Otros Índices Atmosféricos y Oceánicos.

En el presente estudio, para determinar la presencia del Fenómeno del Niño nos basaremos en las anomalías de la Temperatura Superficial del Mar en diversas áreas de observación del Pacífico Central (Niño 1+2, Niño 3, Niño 4, Niño 3.4).

Como pudimos anotar anteriormente, anomalías superiores a una desviación de su valor normal por no menos de cuatro meses en la TSM, son un indicador de una posible presencia del Fenómeno.

Cabe indicar que este indicador por si sólo no nos garantiza la presencia de dicho Fenómeno, pues deben converger además varios factores ya mencionados anteriormente.

Las anomalías de la TSM son obtenidas de la diferencia entre el valor real de la TSM en un determinado mes, y el valor que se esperó tome en dicho mes la TSM.

Para el presente estudio, las anomalías para los pronósticos de las diferentes Series de Tiempo para los años 2001 y 2002 se obtendrán de la diferencia entre dichos pronósticos y un valor promedio mensual histórico de la TSM que abarca el período 1950-2000.

Capítulo 2

2. MARCO TEÓRICO

2.1. Series de Tiempo

Una serie de tiempo es una realización de un proceso estocástico.

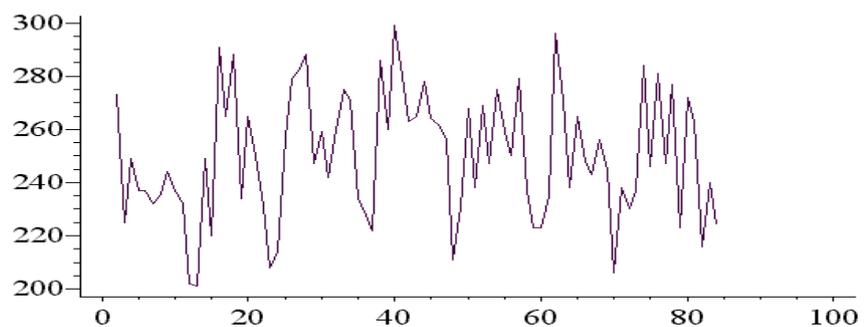


Figura 2.1 Serie de Tiempo

Toda serie temporal debe estar constituida por cuatro componentes:

Tendencia.- Componente dominante a través del tiempo a largo plazo.

Componente cíclica.- Comportamientos periódicos observados en períodos largos.

Componente oscilatoria.- Comportamientos irregulares que se desarrollan en períodos pequeños.

Componente aleatoria.- La parte estocástica del proceso.

Para poder emplear un modelo de análisis de series temporales es necesario referirnos a los procesos estocásticos, ya que la secuencia de observaciones se registra a través del tiempo de acuerdo a una ley de probabilidad.

2.2. Procesos Estocásticos

Un Proceso Estocástico se define como una familia de variables aleatorias (definidas en un espacio probabilístico (Ω, \mathcal{A}, p)) que corresponden a momentos sucesivos del tiempo. Se nota por $Y_{(t, \omega)}$ donde t es el tiempo y $\omega \in \Omega$, donde ω es la variable aleatoria.

El análisis de un proceso estocástico puede hacerse de 2 formas:

- 1) Mediante las funciones de distribución conjunta.
- 2) A partir de los momentos.

Notaremos ahora $Y_{(t, \omega)}$ por Y_t .¹

¹ Véase *Time Series Analysis*, George P. Box, Gwilyn Jenkins, and Gregory Reinsel

Para $t = t_i$ la función de distribución de la variable aleatoria Y_{t_i} es $F(Y_{t_i})$.

Para $t = t_i$ y $t = t_j$, la función de distribución conjunta es $F(Y_{t_i}, Y_{t_j})$.

En general para un conjunto finito de valores en el tiempo t_1, t_2, \dots, t_n la distribución conjunta es $F(Y_{t_1}, Y_{t_2}, \dots, Y_{t_n})$.

Se dice que un proceso estocástico está perfectamente caracterizado cuando se pueden determinar las funciones de distribución conjunta para cualquier conjunto finito de variables t del proceso, es decir, para cada valor finito de n se puede determinar:

$$F(Y_{t_1}, Y_{t_2}, \dots, Y_{t_n})$$

Este procedimiento en sí es muy complicado, por lo que se acostumbra a utilizar el método de los momentos.

En una distribución de probabilidades se puede calcular momentos de diverso orden, aunque los más utilizados son los de 1er orden y 2do orden.

En un proceso estocástico, la media o momento de 1er orden se define por:

$$\mu_t = E(Y_t)$$

Como momentos de segundo orden con respecto a la media, además de la varianza, se considera las covarianzas entre variables aleatorias referidas a distintos instantes de tiempo (autocovarianzas).

$$\gamma_{t,s} = \text{Cov}(Y_t, Y_s) = E[(Y_t - \mu_t)(Y_s - \mu_s)]$$

Cuando $t = s$ tenemos que:

$$\text{Var}(Y_t) = E[(Y_t - \mu_t)^2]$$

Los coeficientes de autocorrelación son:

$$\rho_{t,s} = \frac{\text{Cov}(Y_t, Y_s)}{\sqrt{\text{Var}(Y_t)\text{Var}(Y_s)}} \quad -1 < \rho_{t,s} < 1$$

Es preferible usar las autocorrelaciones pues estas carecen de unidades, es decir son medidas relativas a las que no afectan las unidades de medida.

La caracterización de un proceso estocástico por medio de los momentos de primero y segundo orden es en principio más incompleta que cuando se hace con funciones de distribución

conjunta. Ahora si el proceso es normal (gaussiano) este queda perfectamente caracterizado a través de los dos primeros momentos gaussianos.

$$Y_t \sim N(\mu_t, \sigma_t^2)$$

En una serie temporal se dispone de una observación para cada periodo de tiempo, por lo que se la puede considerar como una muestra de tamaño 1 tomada en periodos sucesivos de tiempo en un proceso estocástico.

A diferencia de un muestreo aleatorio simple donde cada extracción es independiente a las demás, en una serie temporal, el dato extraído para un período de tiempo, no será en general independiente de los datos de los períodos anteriores.

Si se dispone de n datos de una serie temporal con ellos hay que estimar n medias y n varianzas sin contar con las autocovarianzas, entonces tal como se plantea el problema, no tiene solución.

Para poder, a partir de una realización, efectuar inferencias sobre un proceso estocástico es preciso imponer restricciones a dicho proceso, las cuales son: que sea estacionario y ergódico.

2.3. Procesos Estacionarios

Se dice que un proceso estocástico es estacionario en sentido estricto cuando al realizar un mismo desplazamiento en el tiempo de todas las variables aleatorias de cualquier distribución conjunta finita, resulta que la distribución no varía, es decir:

$$F(Y_{t1}, Y_{t2}, Y_{t3}, \dots, Y_{tk}) = F(Y_{t1+n}, Y_{t2+n}, \dots, Y_{tk+n})$$

Se dice que un proceso estocástico es estacionario de 1er orden o en media si : $\dots_t E[Y_t] = \text{③}$

Es decir, la media permanece constante en el tiempo.

Se dice que un proceso estocástico es estacionario de 2 orden (o en sentido amplio) si se verifica :

$$1) \forall_t: \text{Var}(Y_t) = E[(Y_t - \mu_t)^2] = \sigma^2 < \infty$$

2) La autocovarianza entre dos períodos distintos de tiempo viene afectada únicamente por el lapso de tiempo transcurrido entre estos dos períodos.

$$\forall_t: E[(Y_{t+k} - \mu)(Y_t - \mu)] = \gamma_k$$

$$\text{Cov}[Y_{t+k}, Y_t] = \gamma_k$$

En un proceso estacionario en sentido amplio las autocorrelaciones están dadas por :

$$\rho_k = \frac{\gamma_k}{\gamma_0} \quad k \geq 0$$

La representación gráfica de ρ_k para valores de $k = 0, 1, 2, \dots$ se denomina Correlograma.

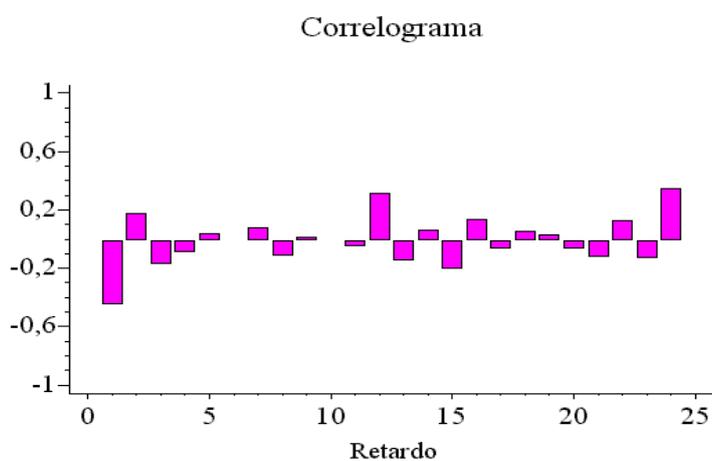


Figura 2.2.

Cuando el proceso estocástico es estacionario en sentido amplio, puede estimarse los parámetros ③, $\gamma_0, \gamma_1, \gamma_2, \dots$ a partir de una sola realización.

A más de la estacionariedad es necesario que el proceso estacionario sea ergódico.

Si un proceso estacionario es ergódico entonces:

$$\lim_{k \rightarrow \infty} \rho_k = 0$$

Si para valores altos de k , ρ_k también es alto, se tiene que al aumentar el tamaño de la muestra se añade poca información nueva, en consecuencia los estimadores obtenidos no serían consistentes.

2.4. Procesos Lineales

Son procesos estocásticos estacionarios en sentido amplio y ergódicos que consisten en combinaciones lineales de variables aleatorias

- Proceso puramente aleatorio: “ruido blanco”

$$Y_t = \epsilon_t \quad \text{donde} \quad \begin{cases} E[\epsilon_t] = 0 & \forall_t (\text{media} = 0) \\ E[\epsilon_t^2] = \sigma^2 & \forall_t (\text{var constante}) \\ E[\epsilon_{t_1}, \epsilon_{t_2}] = 0 & t_1 \neq t_2 \end{cases}$$

- Procesos Autorregresivos de orden p: AR(p)

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \epsilon_t$$

- Procesos de medias móviles de orden q MA (q)

$$Y_t = \epsilon_t - \theta_1 \epsilon_{t-1} - \theta_2 \epsilon_{t-2} - \dots - \theta_q \epsilon_{t-q}$$

- Procesos ARMA(p,q), combinación de los dos anteriores.

$$Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \epsilon_t - \theta_1 \epsilon_{t-1} - \dots - \theta_q \epsilon_{t-q}$$

2.5. Ecuaciones en Diferencias Finitas

Operador de diferencias: Δ

$$\Delta Y_t = Y_t - Y_{t-1}$$

$$\Delta(\Delta Y_t) = \Delta(Y_t - Y_{t-1})$$

$$\Delta^2 Y_t = (Y_t - Y_{t-1}) - (Y_{t-1} - Y_{t-2})$$

$$\Delta^n Y_t = f(Y_t, Y_{t-1}, \dots, Y_{t-n})$$

Operador de retardos: L

El operador L se puede usar para expresar un modelo con retardos:

$$Y_t - \phi_1 Y_{t-1} - \phi_2 Y_{t-2} - \dots - \phi_p Y_{t-p} = \epsilon_t$$

Equivale a:

$$[1 - \phi L - \phi_2 L^2 - \dots - \phi_p L^p] Y_t = \epsilon_t$$



Operador polinomial

$$\text{de retardos: } \phi(L) \quad \rightarrow \quad \phi(L) Y_t = \epsilon_t$$

Ecuaciones de 1er orden

$$Y_t - \phi_1 Y_{t-1} = 0$$

Asumamos que la solución es de la forma:

$$Y_t = \lambda^t$$

$$\begin{aligned} \lambda^t - \phi_1 \lambda^{t-1} &= 0 \\ / \lambda^{t-1} \quad \lambda - \phi_1 &= 0 & \implies \lambda = \phi_1 \\ & & \implies Y_t = \alpha(\phi_1)^t \end{aligned}$$

Si $t = 0$

$$Y_0 = \alpha(\phi_1)^0$$

$$Y_0 = \alpha$$

$$Y_t = Y_0(\phi_1)^t$$

Una condición suficiente y necesario para que el proceso estocástico sea estacionario es que :

$$|\phi_1| < 1$$

Puesto que:

$$\lim_{t \rightarrow \infty} Y_t = \lim_{t \rightarrow \infty} Y_0(\phi_1)^t = Y_0 \lim_{t \rightarrow \infty} \phi_1^t = 0$$

Alternativamente, se puede usar la ecuación polinomial de retardos:

$$Y_t - \phi_1 Y_{t-1} = 0$$

$$[1 - \phi_1 L] Y_t = 0$$

$$1 - \phi_1 L = 0$$

$$L = \frac{1}{\phi_1}$$

Como sabemos que:

$$|\phi_1| < 1$$

$$\left| \frac{1}{\phi_1} \right| > 1 \quad \implies \quad |L_1| > 1$$

Ecuaciones de 2do orden

$$Y_t - \phi_1 Y_{t-1} - \phi_2 Y_{t-2} = 0$$

$$\lambda^2 - \phi_1 \lambda - \phi_2 = 0 \quad \text{Ec. característica}$$

$$\lambda_{1,2} = \frac{\phi_1 \pm \sqrt{\phi_1^2 - 4\phi_2}}{2}$$

En una ecuación homogénea de 2do orden, cuando las raíces son reales y diferentes la condición de estacionariedad implica que:

$$|\lambda_1| < 1 \quad \text{y} \quad |\lambda_2| < 1$$

Si es raíz única:

$$|\lambda_u| < 1$$

Si son imaginarias o complejas se tiene que $r < 1$, es decir las raíces deben caer dentro del círculo unidad.

Como alternativa a la ecuación característica, se puede usar la ecuación polinomial de retardos:

$$1 - \phi_1 L - \phi_2 L^2 = 0$$

$$L_1 = \frac{1}{\lambda_1}$$

$$L_2 = \frac{1}{\lambda_2}$$

En este caso las raíces L_1 y L_2 deben caer fuera del círculo unidad.

2.6. Modelos Lineales

2.6.1. Modelos Autorregresivos (AR)

Un modelo de proceso estocástico será un AR de orden p , si se cumple que los valores presentes se los representa como p valores pasados.

Modelo AR (1)

$$Y_t = \phi_1 Y_{t-1} + \epsilon_t$$

Una condición necesaria y suficiente para que el proceso estocástico sea estacionario es que $|\phi_1| < 1$.

Si $|\phi_1| < 1$ entonces las autocovarianzas serían:

$$\gamma_0 = \frac{\sigma_\epsilon^2}{1 - \phi_1^2}$$

Para $k > 0$

$$\gamma_k = \phi_1 \gamma_{k-1}$$

Las autocorrelaciones estarían dadas por:

$$\rho_0 = 1$$

Para $k > 0$

$$\rho_k = \phi_1^k$$

Modelo AR(2)

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \epsilon_t$$

Para que un modelo AR(2) sea estacionario se tiene que dar:

$$\phi_1 + \phi_2 < 1$$

$$\phi_2 - \phi_1 < 1$$

$$\phi_2 > -1$$

Las autocovarianzas están dadas por:

$$\gamma_0 = \phi_1 \gamma_1 + \phi_2 \gamma_2 + \sigma_\epsilon^2$$

$$\text{Para } k > 0 \quad \gamma_k = \phi_1 \gamma_{k-1} + \phi_2 \gamma_{k-2}$$

Las autocorrelaciones están dadas por:

$$\rho_0 = 1$$

$$\rho_1 = \frac{\phi_1}{1 - \phi_2}$$

Para $k > 1$

$$\rho_k = \phi_1 \rho_{k-1} - \phi_2 \rho_{k-2}$$

Modelo AR(p)

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \epsilon_t$$

ó

$$\phi(L)Y_t = \epsilon_t \quad \text{con} \quad \phi(L) = 1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p$$

Para que el proceso sea estacionario se requieren que las raíces de la ecuación $\phi(L)=0$ estén fuera del círculo unidad.

Si tenemos que:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \epsilon_t$$

Y si multiplicamos esta ecuación por Y_{t-k} y a su vez tomamos esperanzas, tenemos que:

$$E[Y_t Y_{t-k}] = \phi_1 E[Y_{t-1} Y_{t-k}] + \phi_2 E[Y_{t-2} Y_{t-k}] + \dots + \phi_p E[Y_{t-p} Y_{t-k}] + E[\epsilon_t Y_{t-k}]$$

$$\gamma_k = \phi_1 \gamma_{k-1} + \phi_2 \gamma_{k-2} + \dots + \phi_p \gamma_{k-p} + E[\epsilon_t Y_{t-k}]$$

Si $k = 0$

$$\gamma_0 = \phi_1 \gamma_1 + \phi_2 \gamma_2 + \dots + \phi_p \gamma_p + \sigma_e^2$$

Para $k > 0$

$$\gamma_k = \phi_1 \gamma_{k-1} + \phi_2 \gamma_{k-2} + \dots + \phi_p \gamma_{k-p}$$

Si dividimos la última ecuación para γ_0 tenemos:

$$\rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} + \dots + \phi_p \rho_{k-p}$$

Tomando $\rho_0, \rho_1, \rho_2, \dots, \rho_{p-1}$ como condiciones iniciales determinadas a partir de $\phi_0, \phi_1, \phi_2, \dots, \phi_p$ (conocidos), la ecuación anterior nos permite calcular ρ_k para cualquier valor de $k \geq p$.

A la inversa, si se conocen $\rho_1, \rho_2, \dots, \rho_p$ utilizando la última ecuación para $k=1, 2, \dots, p$ se puede calcular $\phi_1, \phi_2, \dots, \phi_p$.

$$\text{Ecuaciones de Yule - Walker} \quad \left\{ \begin{array}{l} \rho_1 = \phi_1 + \phi_2 \rho_1 + \dots + \phi_p \rho_{p-1} \\ \rho_2 = \phi_1 \rho_1 + \phi_2 + \dots + \phi_p \rho_{p-2} \\ \vdots \\ \vdots \\ \rho_p = \phi_1 \rho_{p-1} + \phi_2 \rho_{p-2} + \dots + \phi_p \end{array} \right.$$

Matricialmente

$$\begin{bmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_p \end{bmatrix} = \begin{bmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{p-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{p-2} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ \rho_{p-1} & \rho_{p-2} & \rho_{p-3} & \dots & 1 \end{bmatrix}^{-1} \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_p \end{bmatrix}$$

2.6.2. Modelos de Medias Móviles (MA)

Modelo representado en términos de un ruido blanco correspondiente a ese tiempo y q valores pasados de ese ruido blanco.

$$Y_t = \epsilon_t - \theta_1 \epsilon_{t-1} - \theta_2 \epsilon_{t-2} - \dots - \theta_q \epsilon_{t-q}$$

Modelo MA(1)

$$Y_t = \epsilon_t - \theta_1 \epsilon_{t-1}$$

Las autocovarianzas están dadas por:

$$\gamma_0 = (1 + \theta_1^2) \sigma_\epsilon^2$$

$$\gamma_1 = -\theta_1 \sigma_\epsilon^2$$

$$\text{Si } k > 1 \quad \gamma_k = 0$$

Las autocorrelaciones están dadas por:

$$\rho_0 = 1$$

$$\rho_1 = \frac{-\theta_1}{1 + \theta_1^2}$$

$$\text{Si } k > 1 \quad \rho_k = 0$$

Modelo MA(2)

$$Y_t = \epsilon_t - \theta_1 \epsilon_{t-1} - \theta_2 \epsilon_{t-2}$$

Las autocorrelaciones están dadas por:

$$\gamma_0 = (1 + \theta_1^2 + \theta_2^2)\sigma_\epsilon^2$$

$$\gamma_1 = (-\theta_1 + \theta_1\theta_2)\sigma_\epsilon^2$$

$$\gamma_2 = -\theta_2\sigma_\epsilon^2$$

$$\text{Si } k > 2 \quad \gamma_k = 0$$

Las autocorrelaciones están dadas por:

$$\rho_0 = 1$$

$$\rho_1 = \frac{-\theta_1 + \theta_1\theta_2}{1 + \theta_1^2 + \theta_2^2}$$

$$\rho_2 = \frac{-\theta_2}{1 + \theta_1^2 + \theta_2^2}$$

$$\text{Si } k > 2 \quad \rho_k = 0$$

Modelo MA(q)

$$Y_t = \epsilon_t - \theta_1 \epsilon_{t-1} - \theta_2 \epsilon_{t-2} - \dots - \theta_q \epsilon_{t-q}$$

ó

$$Y_t = \theta(L) \epsilon_t \quad \text{con} \quad \theta(L) = 1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q$$

Las autocovarianzas están dadas por:

$$\gamma_0 = (1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2) \sigma_\epsilon^2$$

$$\gamma_k = \begin{cases} (-\theta_k + \theta_1 \theta_{k+1} + \theta_2 \theta_{k+2} + \dots + \theta_{q-k} \theta_q) \sigma_\epsilon^2 & k = 1, 2, \dots, q \\ 0 & k > q \end{cases}$$

Las autocorrelaciones están dadas por:

$$\rho_k = \begin{cases} \frac{-\theta_k + \theta_1 \theta_{k+1} + \dots + \theta_{q-k} \theta_q}{1 + \theta_1^2 + \dots + \theta_q^2} & k = 1, 2, \dots, q \\ 0 & k > q \end{cases}$$

2.6.3. Modelos Mixtos Autorregresivos-Medias Móviles

Modelos ARMA (p,q) es una combinación de las dos anteriores.

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \epsilon_t - \theta_1 \epsilon_{t-1} - \theta_2 \epsilon_{t-2} - \dots - \theta_q \epsilon_{t-q}$$

$$\phi(L)Y_t = \theta(L)\epsilon_t \quad \begin{cases} \phi(L) = 1 - \phi_1 L - \dots - \phi_p L^p \\ \theta(L) = 1 - \theta_1 L - \dots - \theta_q L^q \end{cases}$$

Para que el modelo sea estacionario se requiere que las raíces de $\phi(L) = 0$ caiga fuera del círculo unidad.

Modelo ARMA(1,1)

$$Y_t = \phi_1 Y_{t-1} + \epsilon_t - \theta_1 \epsilon_{t-1}$$

Las autocovarianzas están dadas por:

$$\gamma_0 = \phi_1 \gamma_1 + \sigma_\epsilon^2 - \theta_1 \sigma_\epsilon^2 (\phi_1 - \theta_1)$$

$$\gamma_1 = \phi_1 \gamma_0 - \theta_1 \sigma_\epsilon^2$$

$$\gamma_k = \phi_1 \gamma_{k-1} \quad k > 1$$

2.6.4. Modelo ARIMA(p,d,q)

A un proceso integrado Y_t se le denomina proceso ARIMA(p,d,q) si tomando diferencias de orden d, se obtiene un proceso estacionario W_t del tipo ARMA(p,q).

La I de la palabra ARIMA significa integrado.

Sea Y_t el modelo original (no estacionario) tomando diferencias de orden d se tiene un modelo estacionario W_t del tipo ARMA(p,q).

La representación de un proceso ARIMA(p,d,q) es:

$$\phi(L)(1-L)^d Y_t = \theta(L) \epsilon_t$$

Una clase considerablemente amplia de series se puede modelizar por medio de los procesos ARIMA gracias a que aplicando transformaciones de tipo no lineal, muchas series pasan a ser representables por medio de estos modelos.

Hay series en las que a lo largo de un periodo extenso de tiempo la varianza puede estar afectada por una tendencia la cual no desaparece al tomar diferencias.

Si se presenta esta característica la transformación adecuada puede consistir en la toma de logaritmos.

2.7. Elaboración de Modelos

Fase de Identificación

En la 1era etapa de esta fase se procede a efectuar un análisis de estacionariedad. En el caso en que la serie no sea estacionario se aplican las transformaciones adecuadas con objeto de convertirla en estacionaria.

Así, si se dispone de una serie Y_t , se eligirá valores para α y λ tales que sea estacionaria la serie:

$$W_t = (1-L)^d Y_t^{(\lambda)}$$

Tanto a Y_t , como a W_t se les puede centrar (restar el valor de la media) si se considera necesario.

En la 2da etapa, si procede a determinar el orden de la parte autorregresiva (es decir p) y el de la parte de medias móviles (es decir q) del proceso ARMA que se considere generador de la serie estacionaria W_t .

Fase de Estimación

En esta fase se obtienen valores estimados para los parámetros:

$$\hat{\phi}_1, \hat{\phi}_2, \dots, \hat{\phi}_p, \hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_q \wedge \hat{\mu}_w$$

Una vez concluida esta fase, se tiene conocimiento de un proceso que hipotéticamente, ha podido generar la serie temporal transformada W_t , a partir de la cual se puede obtener la serie original Y_t .

En consecuencia, la serie W_t , a partir de la expresión anterior, y conociendo los parámetros se puede expresar como:

$$\theta(L)(W_t - \mu_t) = \theta(L) \hat{\epsilon}_t$$

Se puede determinar el estimador de ϵ_t , y si el modelo fuera adecuado, debería ser una serie que se aproxima al ruido blanco.

Fase de Validación

Esta fase va dirigida a establecer si se produce o no esta adecuación entre datos y modelos.

Fase de Predicción

Aquí se analizan pronósticos en términos probabilísticos de valores futuros de la variable. Esta fase es la prueba de fuego del modelo.

2.8. Identificación de Modelos Estacionarios

Para la identificación de los modelos estacionarios se utilizará principalmente la función de autocorrelación estimada (FACE) y la función de autocorrelación parcial estimada (FACPE).

2.8.1. Función de Autocorrelación Estimada (FACE)

A partir de una muestra de tamaño N de valores de una serie estacionaria W_t se puede calcular un coeficiente de autocorrelación muestral de orden k.

$$r_k = \frac{\sum_{t=k+1}^N (W_t - \bar{W})(W_{t-k} - \bar{W})}{\sum_{t=1}^N (W_t - \bar{W})^2} \quad k = 1, 2, 3, \dots$$

Observaciones:

1) El proceso original Y_t se convierte en un proceso estacionario W_t al tomar diferencias. En cada diferencia que se toma se pierde una observación al comienzo de la serie (es decir en cada aplicación del operador Δ).

Si para obtener W_t se han tomado d diferencias, entonces la muestra original de tamaño T se ha reducido a una muestra de tamaño $N = T - d$.

- 2) r_k es el estimador de ρ_k de menor sesgo.
- 3) Para r_{N-1} se dispone de un solo sumando para el numerador, en cambio r_N no se puede calcular. Al disminuir el número de sumandos en el numerador se pierde eficiencia en la estimación, por lo que no se recomienda calcular coeficientes de autocorrelación para tamaños de k superiores a $1/3$ o $1/4$ de la muestra.

La secuencia de valores r_k para $k = 1, 2, 3, \dots$ constituye el correlograma estimado r_k (que es una forma gráfica de la FACE).

2.8.2. Función de Autocorrelación Parcial Estimada (FACPE)

La función de autocorrelación parcial estimada se la puede calcular de dos formas:

1) Mediante ecuaciones de Yule-Walker

$$\begin{aligned} \begin{bmatrix} \hat{\phi}_{11} \end{bmatrix} &= r_1 && \rightarrow \hat{\phi}_{11} \\ \begin{bmatrix} \hat{\phi}_{21} \\ \hat{\phi}_{22} \end{bmatrix} &= \begin{bmatrix} 1 & r_1 \\ r_1 & 1 \end{bmatrix}^{-1} \begin{bmatrix} r_1 \\ r_2 \end{bmatrix} && \rightarrow \hat{\phi}_{22} \\ \begin{bmatrix} \hat{\phi}_{31} \\ \hat{\phi}_{32} \\ \hat{\phi}_{33} \end{bmatrix} &= \begin{bmatrix} 1 & r_1 & r_2 \\ r_1 & 1 & r_2 \\ r_1 & r_2 & 1 \end{bmatrix}^{-1} \begin{bmatrix} r_1 \\ r_2 \\ r_3 \end{bmatrix} && \rightarrow \hat{\phi}_{33} \end{aligned}$$

El inconveniente de esta forma de cálculo es la obtención de la matriz inversa que implica un gran número de operaciones.

Procedimiento de Durbin.- Es un método recursivo que utiliza las ecuaciones:

$$\hat{\phi}_{kk} = \frac{r_k - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} r_{k-j}}{1 - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} r_j}$$

El inconveniente de esta forma de cálculo es que al ser recursiva acumula errores de redondeo por lo que se debe utilizar algoritmos de doble precisión:

$$\hat{\phi}_{kj} = \hat{\phi}_{k-1,j} - \hat{\phi}_{kk} \hat{\phi}_{k-1,k-j} \quad j = 1, 2, \dots, k-1$$

2) Por Regresión

$$Y_t = \hat{\phi}_{11} Y_{t-1}$$

$$Y_t = \hat{\phi}_{21} Y_{t-1} + \hat{\phi}_{22} Y_{t-2}$$

$$Y_t = \hat{\phi}_{k1} Y_{t-1} + \hat{\phi}_{k2} Y_{t-2} + \dots + \hat{\phi}_{kk} Y_{t-k}$$

La secuencia de valores estimados de ϕ_{kk} constituye el correlograma estimado ϕ_{kk} (que es una forma gráfica de la FACPE).

2.9. Modelos para Series de Tiempo Estacionales

Estacionalidad es la tendencia a repetir un modelo de conducta cada período o estación de referencia, el cual es generalmente de un año. Las series estacionales se caracterizan por revelar una fuerte correlación en el período estacional.

En general, a estos modelos se los puede expresar como:

$$\nabla^d \phi_p(B) (\nabla^S)^D \phi_p(B^S) Y_t = \Theta_q(B) \Theta_q(B^S) \epsilon_t$$

S es el período de la estacionalidad. Por ejemplo, si el período de estacionalidad es anual, S será 12; si el período de estacionalidad es trimestral, S será 4, etc

$$\nabla = 1 - B$$

$$\nabla^S = 1 - B^S$$

D = número de veces que se diferencia estacionalmente

d = número de veces que se diferencia estacionariamente

$\phi_p, \phi_P, \Theta_q, \Theta_Q$ son polinomios de grado p, P, q, Q con raíces de módulo superior a uno; ϵ_t es un ruido blanco.

Un proceso que satisface esta ecuación se lo denomina SARIMA[(p,d,q)x(P,D,Q)]s

El razonamiento que conduce a obtener un modelo SARIMA, consiste en aplicar en s series, obtenidas a partir de Y_t , poniendo para cada serie los meses idénticos, la misma transformación:

$$\frac{(\nabla^s)^D \phi_p(B^s)}{\theta_p(B^s)}$$

Y suponer que la serie obtenida :

$$\alpha_t = \frac{(\nabla^s)^D \phi_p(B^s)}{\theta_p(B^s)}$$

No tiene estacionalidades y es entonces modelizable por un ARIMA(p,d,q):

$$\nabla^d \phi_p(B) \alpha_t = \theta_q(B) \epsilon_t$$

De la combinación de las dos últimas ecuaciones, obtenemos la ecuación general para estos modelos estacionales, detallada al principio.

Las series estacionales pueden detectarse analizando las funciones de autocorrelación y de autocorrelación parcial estimadas, pues ellas presentan grandes valores en módulo para los índices múltiplos de s.

La identificación de los parámetros P, D y Q de los factores estacionales se hace de forma similar al procedimiento utilizado para la identificación de los parámetros de los proceso ARIMA.

2.10. Pronósticos para Series No Estacionales

Como expresamos anteriormente , un proceso ARIMA, lo podemos definir como:

$$\phi(L)(1-L)^d Y_t = \theta(L) \epsilon_t$$

$$\text{Si } \begin{aligned} \phi(L) &= \phi(L)(1-L)^d \\ \phi(L)Y_t &= \theta(L) \epsilon_t \end{aligned}$$

Ahora, una observación Y_{t+l} generado por un proceso ARIMA, donde $l \geq 1$, puede ser expresado de tres formas:

1) Directamente en términos de la ecuación diferencial

$$Y_{t+l} = \phi_1 Z_{t+l+1} + \dots + \phi_{p+d} Z_{t+l-p-d} - \theta_1 \epsilon_{t+l-1} - \dots - \theta_q \epsilon_{t+l-q} + \epsilon_{t+l}$$

2) Como una suma de ponderaciones de errores en curso y previos ϵ_j

$$Z_{t+l} = \sum_{j=0}^{\infty} \Psi_j \epsilon_{t+l-j}$$

Donde $\Psi_0 = 1$, y los pesos Ψ pueden ser obtenidos por la ecuación de coeficientes:

$$\phi(L) = (1 + \Psi_1 B + \Psi_2 B^2 + \dots) = \theta(B)$$

- 3) Como una suma de ponderaciones de observaciones previas, más un error aleatorio

$$Z_{t+1} = \sum_{j=1}^{\infty} \Pi_j Z_{t+1-j} + \epsilon_{t+1}$$

2.11. Pronósticos para Series Estacionales

Una función de pronósticos para Series Estacionales, puede ser representada mediante una función de senos y cosenos:

$$\hat{Z}_t(l) = b_0^{(t)} + \sum_{j=1}^{[s/2]} [b_{1j}^{(t)} \cos\left(\frac{2\pi jl}{s}\right) + b_{2j}^{(t)} \sin\left(\frac{2\pi jl}{s}\right)]$$

Donde las b , son coeficientes adaptativos, y donde $[s/2] = \frac{1}{2} S$, si s es par y $[s/2] = \frac{1}{2}(s-1)$ si s es impar.

2.12. Elección del Mejor Modelo

Seleccionar un modelo que capture de una gran forma la estructura de los datos de una serie, es sin lugar a dudas nuestro principal objetivo, por lo cual para llevar a cabo la elección de un buen modelo en el Análisis de Series de Tiempo que se detalla en el Capítulo 3, nos basaremos en dos criterios:

1) Prueba de Student de significancia de parámetros.

Esta prueba nos da a conocer si los parámetros del modelo son significativamente diferentes de cero, para lo cual se realiza el siguiente contraste de hipótesis:

$$H_0 : \theta_i = 0$$

vs.

$$H_1 : \theta_i \neq 0$$

Si el valor p es menor que 0.05, se tiene evidencia estadística para afirmar que el parámetro es significativamente diferente de cero, con un nivel de confianza del 95%.

2) Media Cuadrática del Error

La Media Cuadrática del Error del Modelo sin lugar a dudas va a ser un factor preponderante para decidir cual modelo captura de una mejor manera la estructura de los datos.

Un buen modelo tiene que lograr reducirla, para así poder ser un gran medio de predicción.

Capítulo 3

3. ANÁLISIS ESTADÍSTICO

3.1. Análisis Univariado

A continuación se detalla el análisis univariado de las diferentes variables que son objeto de estudio, para una mayor comprensión de las mismas.

Este consiste de la obtención de las estadísticas básicas para las variables objeto de nuestro estudio como son: media, mediana, moda, desviación estándar, varianza, kurtosis, sesgo, rango, mínimo y máximo, además de los promedios mensuales de cada variable, detallados en diagramas de barras y tablas.

3.1.1. Variable: TSM Niño 1+2

TABLA I
Estadística Básica

TSM Niño 1+2	
Media	23.01
Mediana	22.75
Moda	21.07
Desviación Estándar	2.32
Varianza	5.40
Kurtosis	-0.93
Sesgo	0.26
Rango	10.34
Mínimo	18.80
Máximo	29.14

Como podemos observar en esta variable, el valor del sesgo es positivo, pero muy cercano a cero, por lo que la distribución de esta variable está apenas sesgada a la derecha, es decir hay una mayor concentración de datos a la izquierda, la cual no es muy grande con respecto a los datos que estarían a la derecha de la media.

El coeficiente de Kurtosis para esta variable es menor que 3, por lo que podemos afirmar que la distribución de esta variable es platicúrtica.

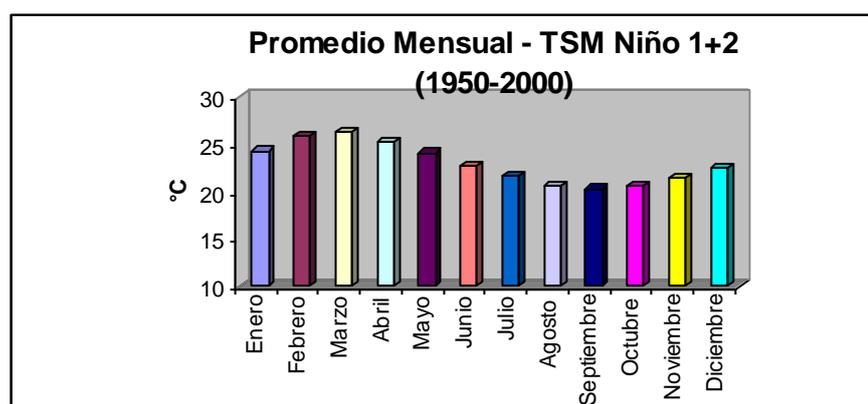


Gráfico 3.1.

En el gráfico notamos claramente una tendencia a la alza de la temperatura superficial del mar, que va desde el mes de Enero hasta el mes de Marzo, comenzando ahí un decrecimiento de la misma hasta el mes de Septiembre, en donde comienza una nueva alza en la temperatura.

Nótese que éstos son promedios históricos, los cuales nos dan una pauta para ver el comportamiento de la temperatura superficial del mar en un año.

A continuación se detalla una tabla de valores con los promedios históricos mostrados en el gráfico anterior.

TABLA II
Promedio Mensual (1950-2000)

TSM Niño 1+2	
Enero	24.34
Febrero	25.83
Marzo	26.30
Abril	25.33
Mayo	24.13
Junio	22.76
Julio	21.64
Agosto	20.67
Septiembre	20.33
Octubre	20.70
Noviembre	21.48
Diciembre	22.61

3.1.2. Variable: TSM Niño 3

TABLA III
Estadística Básica

TSM Niño 3	
Media	25.75
Mediana	25.78
Moda	25.12
Desviación Estándar	1.31
Varianza	1.72
Kurtosis	-0.59
Sesgo	0.17
Rango	6.46
Mínimo	22.70
Máximo	29.16

En esta variable, así mismo obtuvimos que el valor del sesgo es positivo, pero muy cercano a cero, por lo que la distribución de esta variable está apenas sesgada a la derecha, es decir hay una mayor concentración de datos a la izquierda, la cual no es muy grande con respecto a los datos que estarían a la derecha de la media.

La distribución es casi simétrica, y se puede comprobar esto, al verificar que el valor de la media de esta variable está muy cercana al valor de la mediana.

El coeficiente de Kurtosis para esta variable es menor que 3, por lo que podemos afirmar que la distribución es platicúrtica.

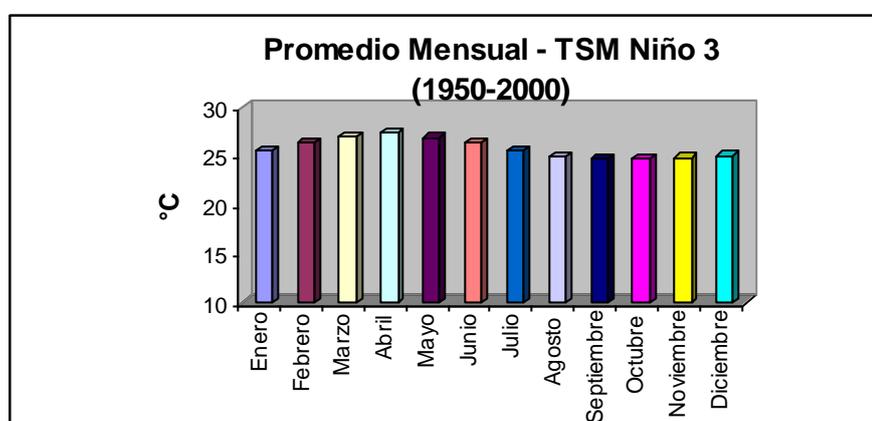


Gráfico 3.2

La Temperatura Superficial del Mar para la variable Niño 3, como se puede observar en el Gráfico 3.2, comienza con crecimiento en la TSM, tomando su máximo valor en el mes de

Abril, comenzando ahí un decrecimiento en su temperatura que se extiende hasta Septiembre, comenzando de nuevo un crecimiento en la misma.

En la Tabla IV se detallan los valores promedios de cada mes.

TABLA IV
Promedio Mensual (1950-2000)

TSM Niño 3	
Enero	25.49
Febrero	26.28
Marzo	27.01
Abril	27.35
Mayo	26.88
Junio	26.31
Julio	25.51
Agosto	24.87
Septiembre	24.67
Octubre	24.77
Noviembre	24.81
Diciembre	25.02

3.1.3. Variable: TSM Niño 3.4

TABLA V
Estadística Básica

TSM Niño 3.4	
Media	26.92
Mediana	26.94
Moda	26.71
Desviación Estándar	0.995
Varianza	0.991
Kurtosis	-0.26
Sesgo	-0.06
Rango	5.08
Mínimo	24.27
Máximo	29.35

A diferencia de las variables anteriores, el valor del sesgo de esta variable es negativo, pero de la misma forma es muy cercano a cero, por lo que la distribución de esta variable está apenas sesgada a la izquierda, es decir hay una mayor concentración de datos a la derecha, la cual no es muy grande con respecto a los datos que estarían a la izquierda de la media.

La distribución es casi simétrica, y se puede comprobar esto, al verificar que el valor de la media de esta variable está muy cercana al valor de la mediana.

El coeficiente de Kurtosis para esta variable es menor que 3, por lo que podemos afirmar que la distribución es platicúrtica.

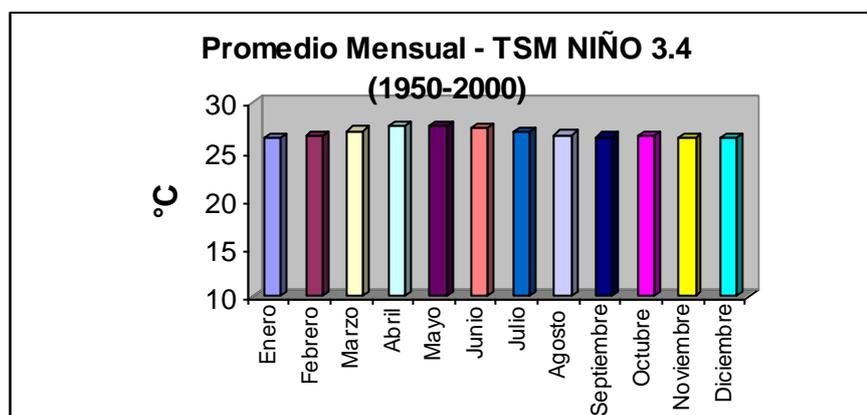


Gráfico 3.3

En el Gráfico 3.3 vemos claramente como para esta variable, hay una alza de la temperatura desde inicio de año hasta Mayo, donde comienza un decremento de la misma hasta Septiembre,

para después comenzar otro aumento de temperatura hasta fin de año.

A continuación se detalla los promedios mensuales de la TSM Niño 3.4.

TABLA VI
Promedio Mensual (1950-2000)

TSM Niño 3.4	
Enero	26.47
Febrero	26.68
Marzo	27.13
Abril	27.66
Mayo	27.68
Junio	27.53
Julio	27.08
Agosto	26.71
Septiembre	26.53
Octubre	26.58
Noviembre	26.47
Diciembre	26.47

3.1.4. Variable: TSM Niño 4

TABLA VII
Estadística Básica

TSM Niño 4	
Media	28.34
Mediana	28.38
Moda	28.36
Desviación Estándar	0.68
Varianza	0.46
Kurtosis	-0.28
Sesgo	-0.45
Rango	3.27
Mínimo	26.51
Máximo	29.78

De la misma manera, obtuvimos que el valor del sesgo de esta variable es negativo, y a su vez es muy cercano a cero, por lo que la distribución de esta variable está también apenas sesgada a la izquierda, es decir hay una mayor concentración de datos a la derecha, la cual no es muy grande con respecto a los datos que estarían a la izquierda de la media.

La distribución es casi simétrica, y se puede comprobar esto, al verificar que el valor de la media de esta variable está muy cercana al valor de la mediana.

El coeficiente de Kurtosis para esta variable es menor que 3, por lo que podemos afirmar que la distribución es platicúrtica.

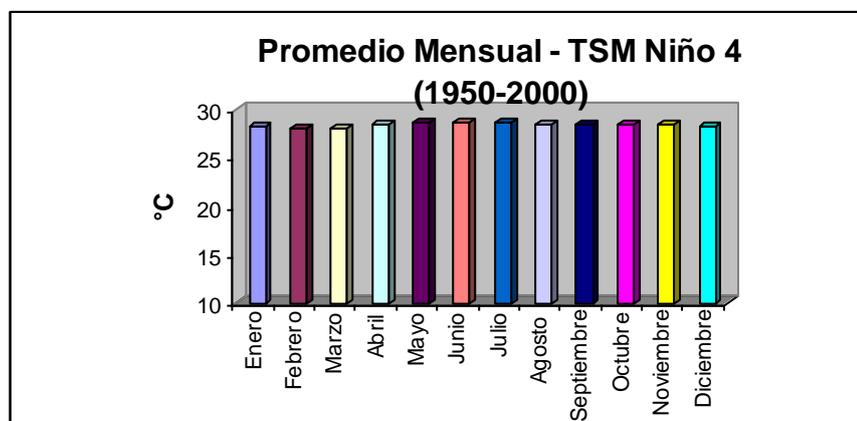


Gráfico 3.4

En el caso de esta variable, nos podremos dar cuenta en el Gráfico 3.4 que las temperaturas son muy similares a lo largo de todo el año, siendo éstas temperaturas elevadas.

Podemos decir que los meses con las temperaturas más altas son Mayo y Junio, y el mes con la temperatura más baja es Febrero.

Para el caso de esta variable, tenemos que la TSM desciende hasta el mes de febrero, de ahí comienza un incremento en la misma hasta Junio, a partir del cual comienza otra disminución en la temperatura.

Nótese que las variaciones en las temperaturas que se observan para cada mes, son muy pequeñas.

En la Tabla VII detallamos los valores promedios mensuales para esta variable.

TABLA VIII
Promedio Mensual (1950-2000)

TSM Niño 4	
Enero	28.11
Febrero	27.98
Marzo	28.03
Abril	28.34
Mayo	28.62
Junio	28.62
Julio	28.55
Agosto	28.42
Septiembre	28.40
Octubre	28.38
Noviembre	28.35
Diciembre	28.23

3.1.5. Variable: Temperatura del Aire

TABLA IX
Estadística Básica

Temperatura del Aire	
Media	25.23
Mediana	25.45
Moda	25.60
Desviación Estándar	1.30
Varianza	1.70
Kurtosis	-1.04
Sesgo	-0.12
Rango	5.70
Mínimo	22.30
Máximo	28

Para esta variable, obtuvimos que el valor del sesgo también es negativo, y a su vez muy cercano a cero, por lo que la distribución de esta variable está también apenas sesgada a la izquierda, es decir hay una mayor concentración de datos a la derecha, la cual no es muy grande con respecto a los datos que estarían a la izquierda de la media.

La distribución es casi simétrica, y se puede comprobar esto, al verificar que el valor de la media de esta variable está muy cercana al valor de la mediana.

El coeficiente de Kurtosis para esta variable es menor que 3, por lo que podemos afirmar que la distribución es platicúrtica.

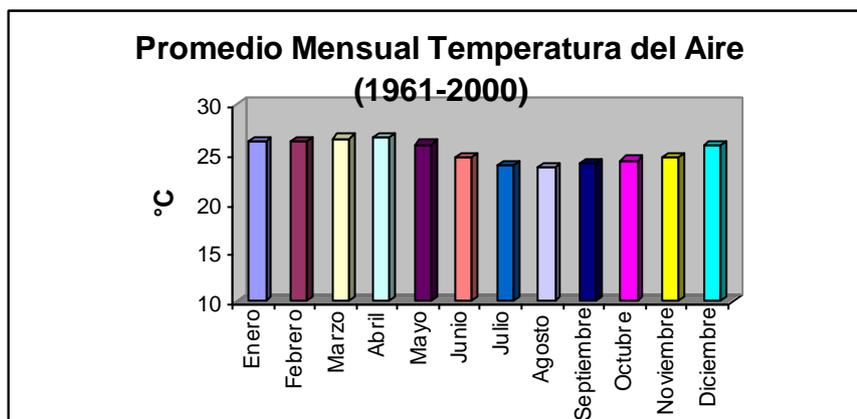


Gráfico 3.5

En este gráfico nos podemos dar cuenta claramente del comportamiento promedio de la TA en el período 1961-2000, comenzando con temperaturas altas a inicios de año, éstas se siguen incrementando hasta el mes de Marzo, a partir del cual comienza el decrecimiento de la TA, que llega a su valor mínimo en Agosto, desde ahí nuevamente la TA comienza a incrementarse.

TABLA X
Promedio Mensual (1961-2000)

Temperatura del Aire	
Enero	26.22
Febrero	26.23
Marzo	26.58
Abril	26.63
Mayo	25.97
Junio	24.73
Julio	23.81
Agosto	23.63
Septiembre	24.05
Octubre	24.37
Noviembre	24.75
Diciembre	25.80

3.1.6. Variable: Precipitaciones

TABLA XI
Estadística Básica

Precipitaciones	
Media	83.68
Mediana	4
Moda	0
Desviación Estándar	148.08
Varianza	21926.90
Kurtosis	5.56
Sesgo	2.35
Rango	827.80
Mínimo	0
Máximo	827.80

Para el caso de esta variable, a diferencia de las variables estudiadas anteriormente podemos darnos cuenta que tiene un sesgo significativo, el cual al ser positivo, nos da a conocer que la distribución de esta variable está sesgada a la derecha, es decir hay una mayor concentración de datos a la izquierda de la distribución, esto es con respecto a la media.

El coeficiente de Kurtosis para esta variable es mayor que 3, por lo que podemos afirmar que la distribución es leptocúrtica.

En el Gráfico 3.6 podemos darnos cuenta que la mayor parte de las precipitaciones que suceden en el año, se dan en los meses de Enero, Febrero, Marzo y Abril; siendo el mes de Marzo el

mes que ha tenido en promedio la mayor cantidad de precipitaciones.

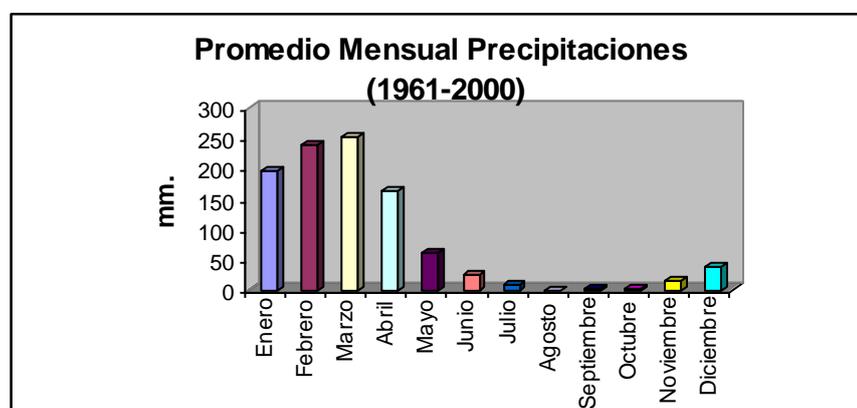


Gráfico 3.6

Como nos podemos dar cuenta, en los meses de Julio, Agosto, Septiembre y Octubre las precipitaciones son prácticamente nulas.

En Noviembre, se nota un leve incremento en las precipitaciones, el cual se extiende hasta Diciembre.

En el mes de enero es donde se nota realmente, un incremento en las precipitaciones, el cual llega como dijimos anteriormente a su nivel máximo en Marzo, para de ahí comenzar a decrecer.

Cabe notar que el mes con la menor cantidad de precipitaciones en promedio es Agosto.

Los valores promedios de las precipitaciones mensuales se detallan a continuación en la Tabla XII.

TABLA XII
Promedio Mensual (1961-2000)

Precipitaciones	
Enero	195.21
Febrero	239.28
Marzo	251.46
Abril	162.28
Mayo	60.85
Junio	26.94
Julio	9.20
Agosto	0.43
Septiembre	1.52
Octubre	2.05
Noviembre	15.38
Diciembre	39.59

3.2. Series Temporales

3.2.1. Introducción

Debido a la importancia de la Temperatura Superficial del Mar como indicador de la presencia del Fenómeno “El Niño”, el análisis de Series Temporales de esta variable, será la base del presente estudio.

El análisis de la Temperatura Superficial del Mar se realizará a partir de observaciones tomadas en 4 áreas del Pacífico Ecuatorial, las cuales son: Niño 1+2, Niño 3, Niño 4 y Niño 3.4. Además, se realizará un análisis de Series Temporales de la Temperatura del Aire de la ciudad de Guayaquil.

La variable Precipitaciones nos van a servir de base para poder ver la relación que existe entre esta variable y las demás descritas anteriormente.

3.2.2. Variable Niño 1+2

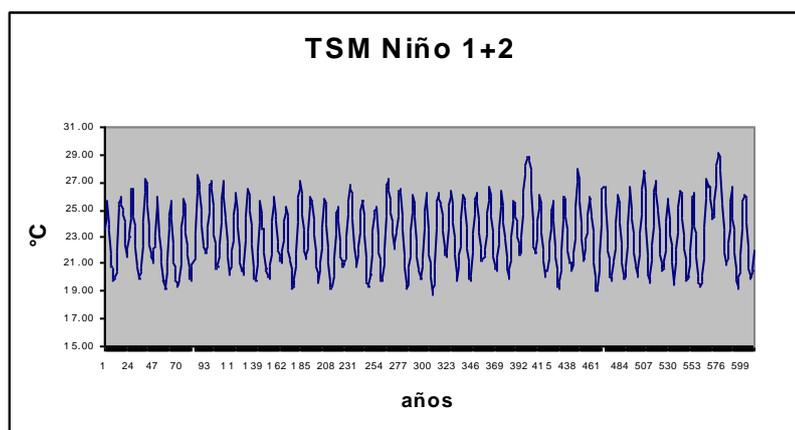


Gráfico 3.7

Como vemos en el gráfico anterior, la serie de esta variable nos podría estar dando a conocer una estacionariedad en la misma, por lo que podría no ser necesario diferenciarla.

Para obtener más información de la misma, obtendremos los gráficos de la Función de Autocorrelación y la Función de Autocorrelación Parcial, los cuales mostramos a continuación.

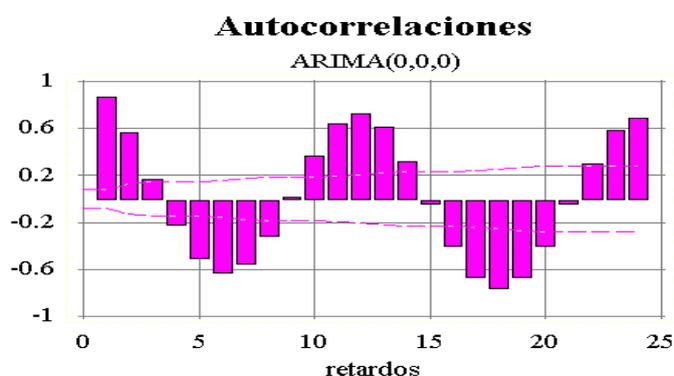


Gráfico 3.8

Como vemos en la FAC, las barras que representan las autocorrelaciones siguen un patrón de comportamiento cada 12 retardos, por lo que nos hace pensar que estaríamos hablando de una serie con una estacionalidad 12.

Si nos fijamos en el Gráfico 3.9 de la FACP, nos podríamos dar cuenta en cambio de dos barras muy significativas en los retardos 1 y 2 que cortan las bandas de confianza, por lo que ya nos podría sugerir que un modelo para esta serie puede estar conformado por 2 parámetros autorregresivos (AR).

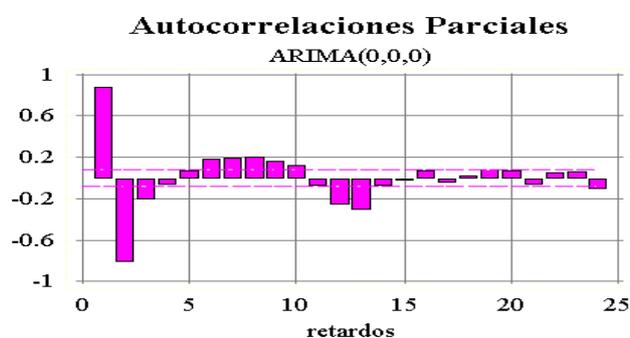


Gráfico 3.9

El primer paso a realizar, será diferenciar estacionalmente la serie; con esto logramos que las barras de las autocorrelaciones se suavicen, es decir, no corten las bandas de confianza de una manera tan grande, además de eliminar la periodicidad de las barras en la FAC.

Así pues al realizar una diferenciación estacional, nos podremos dar cuenta que nuestro modelo para la variable Niño 1+2 se trataría de un SARIMA.

Así pues, al realizar una diferenciación estacional la FAC y la FACP se mostrarían de la siguiente manera:

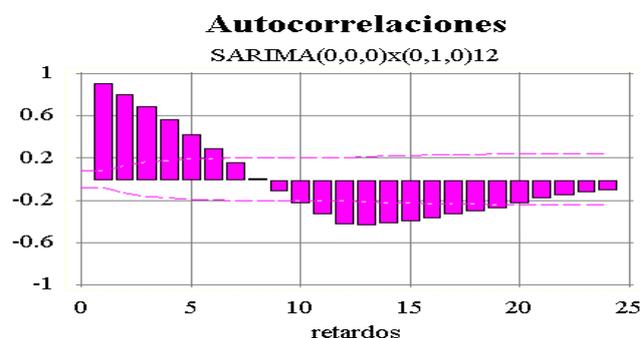


Gráfico 3.10

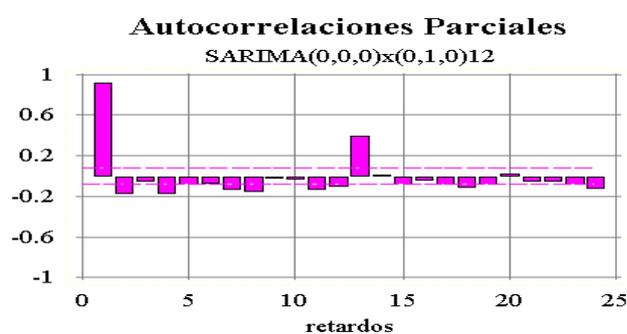


Gráfico 3.11

Como nos podemos dar cuenta, en el Gráfico 3.10 se logró eliminar la periodicidad, pero conservamos aún un número significativo de barras que cortan las bandas de confianza.

Cabe recordar que necesitamos que las barras de las autocorrelaciones estén dentro de las bandas de confianza, indicando que los residuos son independientes; requisito indispensable para hallar un buen modelo.

En el Gráfico 3.11 correspondiente a la FACP observamos que 2 barras cortan las bandas de confianza de una manera significativa.

La primera lo hace en el retardo 1, y la segunda en el retardo 13, por lo que nos podría estar sugiriendo la utilización de un parámetro estacional en el modelo.

Así pues, después de este análisis, podemos sugerir los siguiente modelos:

SARIMA(1,0,0)x(0,1,1)12

Como nos podemos dar cuenta, este modelo de estacionalidad 12, consta de un parámetro AR estacionario, y un parámetro MA estacional.

Cabe recordar que hemos diferenciado estacionalmente en una ocasión.

A continuación se muestra los gráficos de la FAC y de la FACP del modelo mencionado.

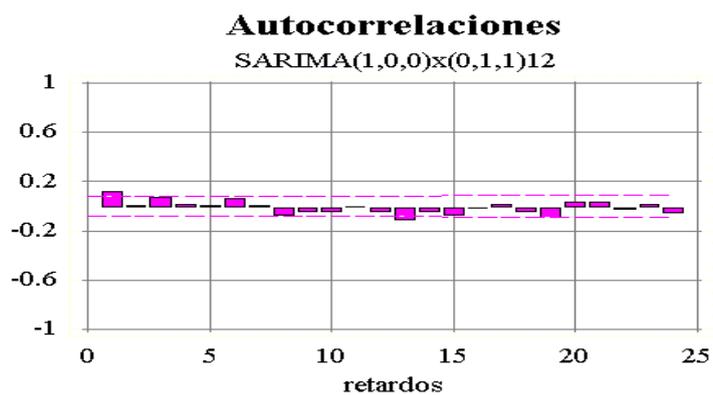


Gráfico 3.12

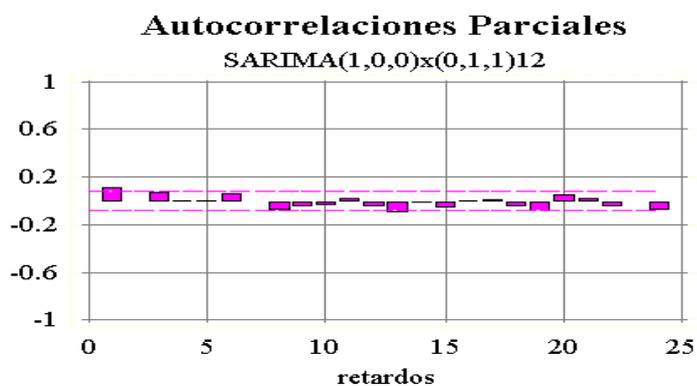


Gráfico 3.13

Nótese que se ha logrado reducir las autocorrelaciones considerablemente.

Ahora, nos interesa saber si los parámetros del modelo son significativamente diferentes de cero.

Al realizar esta prueba obtuvimos:

Prueba de los Parámetros del Modelo

Parámetro	Estimación	Error Estándar	t	Valor p
AR(1)	0.907101	0.0170828	53.1003	0
MA(1)	0.963251	0.00521445	184.727	0

Nótese que tanto el valor p de los parámetros AR y MA son menores que 0.5, lo cual nos indica que son significativamente diferentes de cero.

Para este modelo tenemos que:

$$\mathbf{MCE = 0.235734}$$

Un modelo intermedio para esta variable estaría dado por:

SARIMA(1,0,1)x(0,1,1)

Como podemos observar, este modelo además de un parámetro AR estacionario y un parámetro MA estacional, estaría conformado también por un parámetro MA estacionario.

Los gráficos de la FAC y de las FACP del modelo se detallan a continuación.

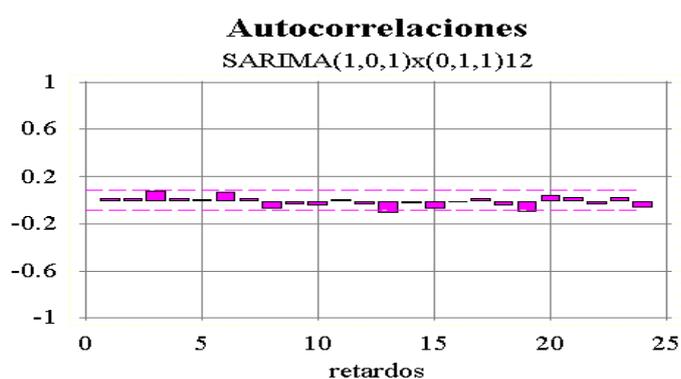


Gráfico 3.14

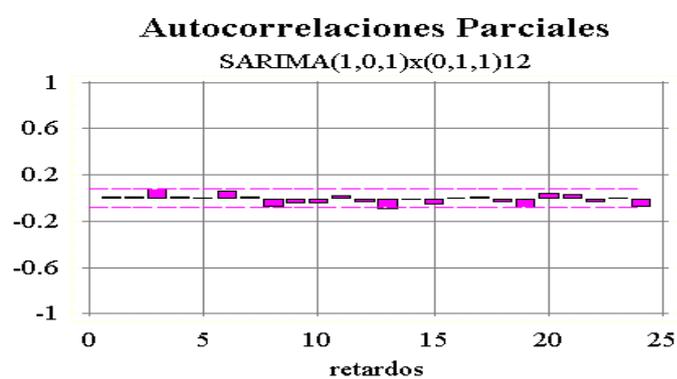


Gráfico 3.15

De la misma manera, observamos la reducción de las barras de las autocorrelaciones en los dos gráficos, las cuales están dentro de las bandas de confianza.

Así mismo, la prueba de los parámetros del modelo para comprobar la significancia de los mismos se detalla a continuación.

Prueba de los Parámetros del Modelo

Parámetro	Estimación	Error Estándar	t	Valor p
AR(1)	0.887666	0.0207398	42.8002	0
MA(1)	-0.118799	0.0447368	-2.6555	0.00813
SMA(1)	0.962694	0.00535212	179.871	0

Podemos notar claramente que los parámetros AR, MA y SMA pasan la prueba de significancia, puesto que los valores p de los mismos son menores que 0.05, con lo que podemos afirmar que son significativamente diferentes de cero.

La Media Cuadrática del Error para este modelo es de:

$$\text{MCE} = 0.232418$$

Un último modelo a sugerir para esta variable sería:

SARIMA(2,0,0)x(0,1,1)₁₂

Nótese que a diferencia de los modelos anteriores, éste modelo consta de dos parámetros AR estacionarios, y un parámetro MA estacional.

En los Gráficos 3.16 y 3.17 vemos cómo se han reducido significativamente las autocorrelaciones en este modelo.

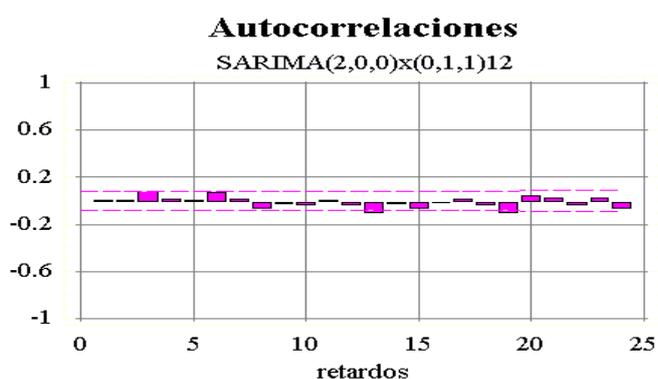


Gráfico 3.16

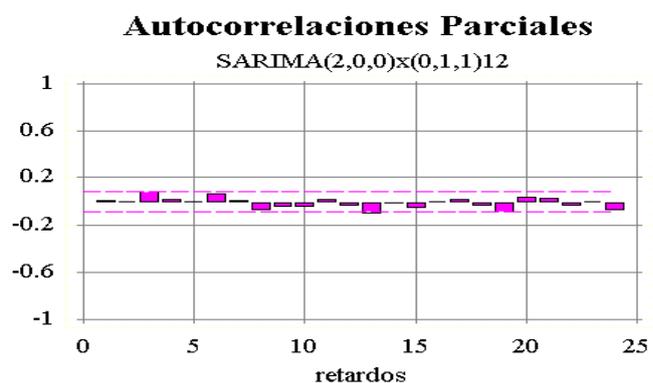


Gráfico 3.17

Para verificar la significancia de los parámetros de este modelo, procedemos a realizar la siguiente prueba.

Prueba de los Parámetros del Modelo

Parámetro	Estimación	Error Estándar	t	Valor p
AR(1)	1.01304	0.0406591	24.9155	0
AR(2)	-0.115861	0.0405637	-2.85627	0.00443
SMA(1)	0.962877	0.00494049	194.895	0

Como podemos observar, los parámetros del modelo pasan la prueba de significancia, puesto que el valor p para los tres parámetros es menor que 0.05, por lo que podemos decir que éstos son significativamente diferentes de cero.

La Media Cuadrática del error para este modelo es de:

$$\mathbf{MCE = 0.232382}$$

Como hemos podido observar, se han sugerido 3 modelos para esta variable, los cuales pasan la prueba de significancia de los parámetros, por lo que se tomará en consideración para escoger al mejor modelo el que tenga la menor media Cuadrática del Error (MCE).

Por este motivo, podemos afirmar que el modelo SARIMA(2,0,0)x(0,1,1)₁₂ captura de una mejor manera la estructura de los datos.

En la Tabla XIII, así como el Gráfico 3.18, podemos apreciar claramente los pronósticos de dicho modelo para los años 2001 y 2002.

Como pudimos anotar anteriormente, anomalías superiores a una desviación por no menos de cuatro meses en la Temperatura Superficial del Mar, es un buen indicador de una posible presencia de el Fenómeno de “El Niño”, por lo que si nos fijamos en la Tabla XIV correspondiente a las anomalías de la TSM Niño 1+2, podemos darnos cuenta que no existe evidencia para afirmar que en el año 2002, tendremos la presencia de este Fenómeno.

Cabe anotar que para obtener las anomalías correspondientes a las variables de la Temperatura Superficial del Mar, se tuvo que tomar la diferencia entre los valores pronosticados de cada mes y sus valores promedios históricos.

Tabla XIII (Ver archivo Pronósticos)

Gráfico 3.18 (Ver archivo Gráficos)

Tabla XIV (Ver archivo Anomalías)

3.2.3. Variable Niño 3

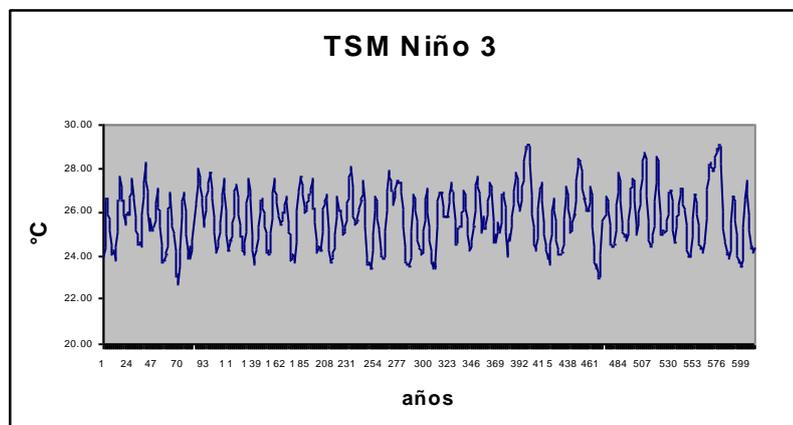


Gráfico 3.19

Como podemos notar en el Gráfico 3.19, ésta variable parece tener un comportamiento estacionario, lo cual nos abre la posibilidad de que no sea necesario diferenciar esta serie de datos.

En la FAC detallada en el Gráfico 3.20, podemos notar la estacionalidad de la serie, que del mismo modo que la variable anterior es 12.

En el Gráfico 3.21 observemos que las dos primeras barras cortan las bandas de confianza de manera significativa, por lo que de la misma forma que la variable anterior, podría sugerir un modelo con 2 parámetros autorregresivos.

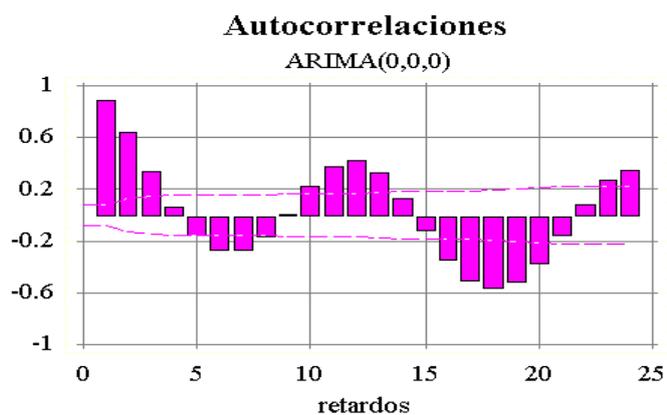


Gráfico 3.20

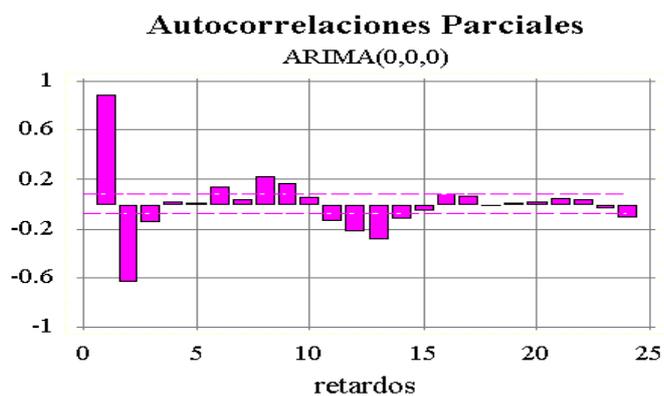


Gráfico 3.21

Si diferenciamos una vez estacionalmente la serie, para así reducir los grandes valores de las autocorrelaciones expresados en las barras que cortan las bandas de confianza, además de eliminar la periodicidad de la serie, encontramos que la FAC y la FACP tomarían los valores que se muestran en los Gráficos 3.22 y 3.23.

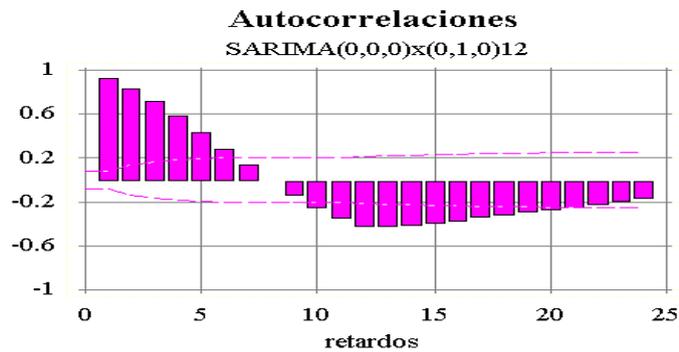


Gráfico 3.22



Gráfico 3.23

Como podemos ver, las barras que anteriormente se mostraban siguiendo un patrón cada 12 retardos en la FAC, ahora tienden a disminuir gradualmente; y en la FACP ahora 2 barras cortan las bandas de confianza pero ya no en los primeros retardos, sino en los retardos 1 y 13, indicando que se podría sugerir la utilización de un parámetro estacional en el modelo.

Después de este análisis podemos sugerir un primer modelo el cual es:

SARIMA(1,0,1)x(1,1,1)12

Este modelo está compuesto por un parámetro AR estacionario, un parámetro MA estacionario, un parámetro AR estacional y un parámetro MA estacional.

La FAC y FACP del modelo mencionado muestran claramente cómo se han logrado reducir las autocorrelaciones, éstas dentro de las bandas de confianza.

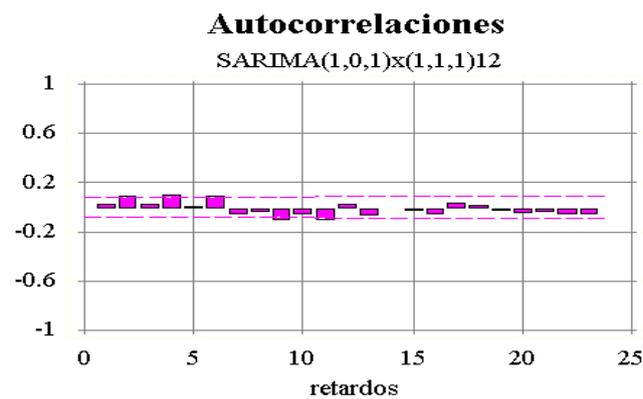


Gráfico 3.24

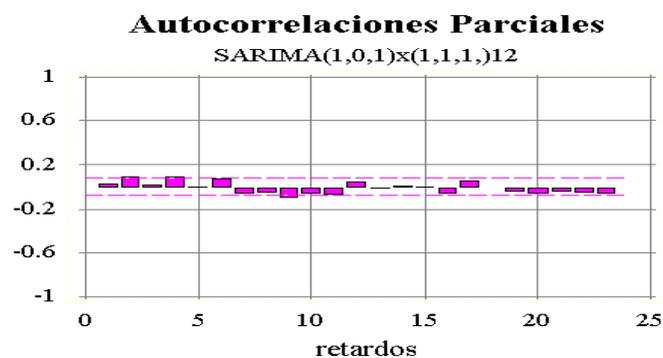


Gráfico 3.25

Al realizar la prueba de significancia de los parámetros del modelo, se obtuvo:

Prueba de los Parámetros del Modelo

Parámetro	Estimación	Error Estándar	t	Valor p
AR(1)	0.905145	0.0186736	48.4719	0
MA(1)	-0.12422	0.0442833	-2.80511	0.00519
SAR(1)	-0.107922	0.0422353	-2.55524	0.01085
SMA(1)	0.947585	0.0103292	91.7386	0

Podemos notar que los valores p de los parámetros del modelo son menores que 0.05, por lo que nos indica que los mismos son significativamente diferentes de cero.

El valor de la Media Cuadrática del Error es:

$$\mathbf{MCE = 0.127056}$$

Un modelo intermedio estaría dado por:

SARIMA(2,0,0)X(0,1,1)₁₂

Este modelo estacional consta de 2 parámetros AR estacionarios, y un parámetro MA estacional.

Los gráficos 3.26 y 3.27 muestran la FAC Y FACP del modelo sugerido.

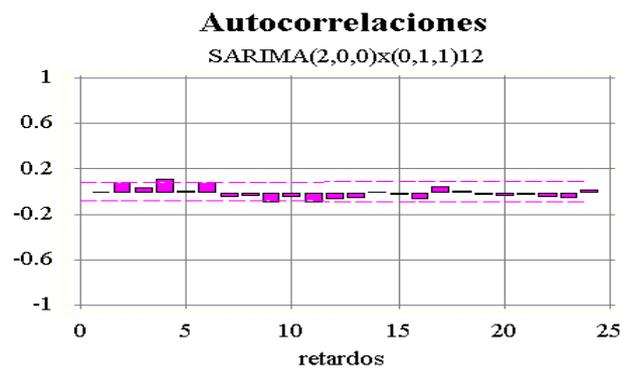


Gráfico 3.26

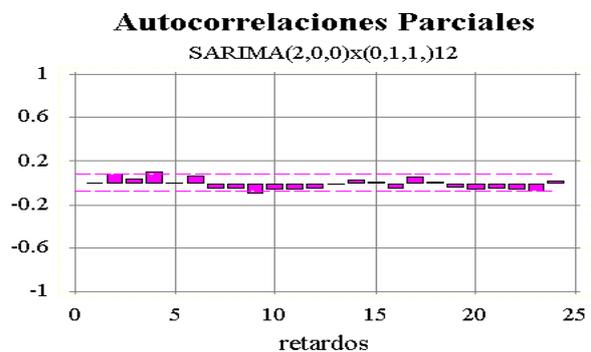


Gráfico 3.27

A continuación procedemos a realizar la prueba de significancia de los parámetros del modelo.

Prueba de los Parámetros del Modelo

Parámetro	Estimación	Error Estándar	t	Valor p
AR(1)	1.06296	0.0404399	26.2849	0
AR(2)	-0.151369	0.0402	-3.7653	0.00018
SMA(1)	0.954875	0.00669004	142.731	0

Para el modelo analizado, notamos que sus parámetros son significativamente diferentes de cero, puesto los valores p de los mismos son menores a 0.05.

La Media Cuadrática del Error para esta variable es de:

$$\mathbf{MCE = 0.127412}$$

Un tercer modelo sugerido sería:

SARIMA(2,0,1)X(0,1,1)12

Este modelo estacional, consta de 2 parámetros AR estacionarios, 1 parámetro MA estacionario, y un parámetro MA estacional.

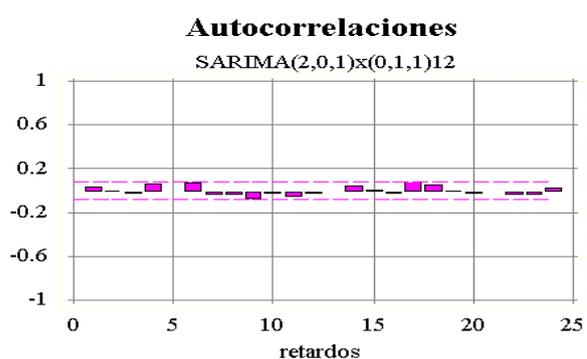


Gráfico 3.28

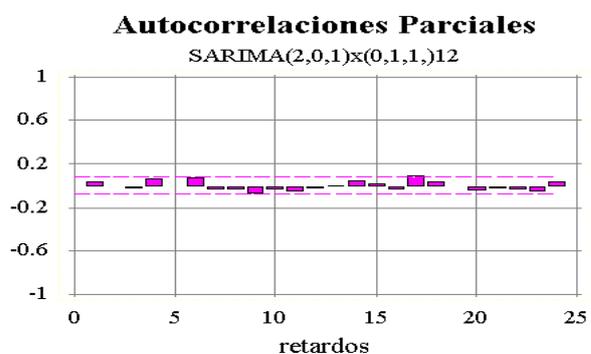


Gráfico 3.29

En los Gráficos 3.28 y 3.29 observamos que las autocorrelaciones de la FAC y de la FACP se han reducido considerablemente.

La prueba de significancia de los parámetros se nos muestra los siguientes resultados:

Prueba de los Parámetros del Modelo

Parámetro	Estimación	Error Estándar	t	Valor p
AR(1)	1.84624	0.0418143	44.1532	0
AR(2)	-0.871236	0.0369246	-23.595	0
MA(1)	0.861494	0.0603081	14.2849	0
SMA(1)	0.948122	0.00815845	116.213	0

Nótese que podemos afirmar que los parámetros del modelo son significativamente diferentes de cero, puesto que los valores p de los mismos son menores que 0.05.

La Media Cuadrática del Error del modelo en estudio es:

$$\mathbf{MCE = 0.123104}$$

Todos los modelos propuestos hasta ahora pasan la prueba de significancia de los parámetros, y observando la MCE de este último modelo, notamos que ésta es menor que las MCE de los modelos anteriormente propuestos, por lo que nos estaría indicando un modelo más eficiente.

Por lo tanto el modelo que captura de una mejor manera la estructura de los datos de la Variable Niño 3 sería el modelo SARIMA(2,0,1)x(0,1,1)₁₂.

Los pronósticos de este modelo para los años 2001 y 2002 se detallan con claridad en la TABLA XV y en el Gráfico 3.30.

Aquí podemos observar un pequeño aumento en la TSM para el año 2002 en comparación con el 2001.

Si nos fijamos en las anomalías de los pronósticos de este modelo descritos en la Tabla XVI podemos darnos cuenta que de la misma forma que para la TSM Niño 1+2 no hubo evidencia para suponer la presencia de “El Niño”, en este caso también podríamos afirmar lo mismo, puesto que las anomalías de la TSM Niño 3 no alcanzan los valores que determinarían su presencia.

Recordemos que anomalías superiores a una desviación por no menos de cuatro meses en la TSM, nos podría estar indicando la presencia de “El Niño”

Tabla XIV (Ver archivo Pronósticos)

Gráfico 3.30 (Ver archivo Gráficos)

Tabla XVI (Ver archivos Anomalías)

3.2.4. Variable Niño 4

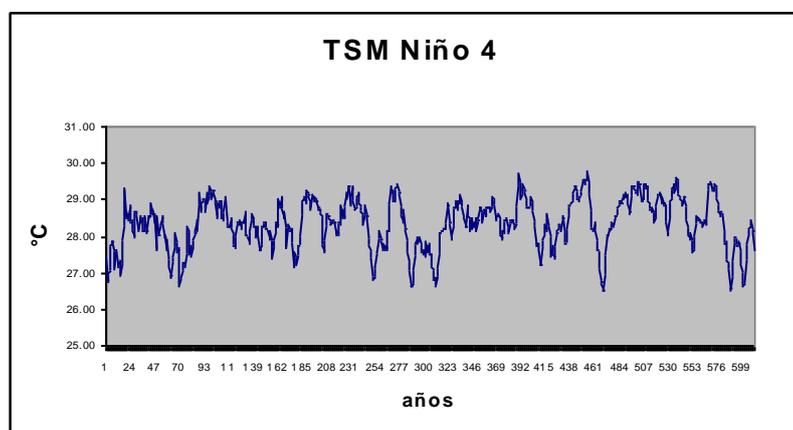


Gráfico 3.31

En el gráfico anterior podemos notar que la serie parece no ser estacionaria, por lo que deberíamos aplicar una diferenciación estacionaria a la serie.

Cabe indicar que hasta mientras las 2 primeras variables de la Temperatura Superficial del Mar analizadas recientemente resultaron ser estacionarias.

Para obtener más información de la serie, a continuación graficamos la Función de Autocorrelación y la Función de Autocorrelación Parcial.

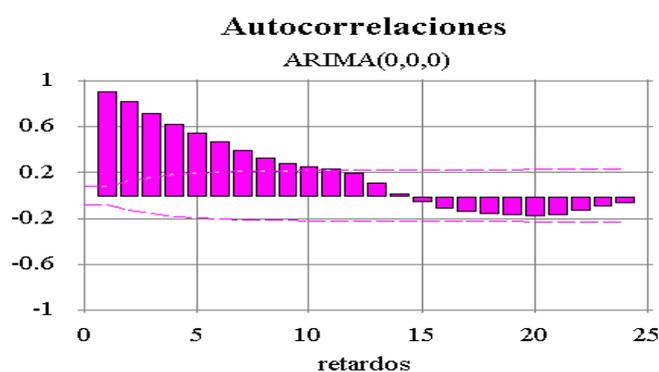


Gráfico 3.32

Aquí vemos que las autocorrelaciones son significantes para un número grande de retrados, pero las autocorrelaciones significantes que están a partir del retardo 2, quizás sean debido a la propagación de la autocorrelación el retardo 1.

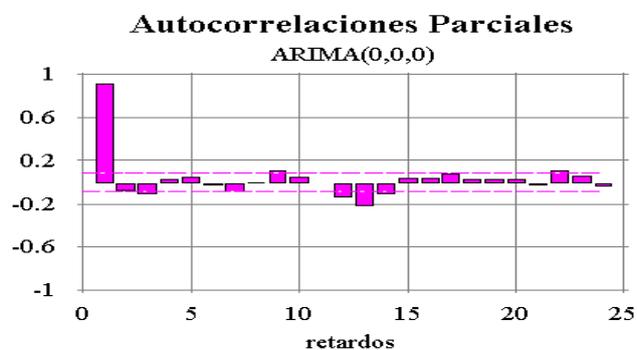


Gráfico 3.33

Aquí notamos claramente como en el retardo 1, la barra de autocorrelación corta las bandas de confianza significativamente, por lo que podríamos sugerir un modelo con un parámetro autorregresivo.

Ahora veamos el efecto que tiene en la FAC y la FACP al diferenciar a la serie estacionariamente.

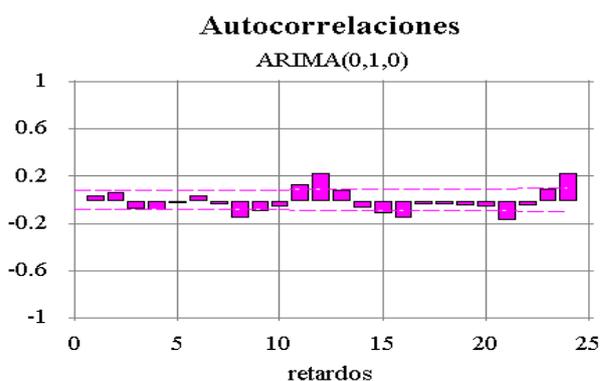


Gráfico 3.34

Nótese que se han logrado reducir las autocorrelaciones en la FAC, sucediendo de la misma forma en la FACP (Gráfico 3.35), sin embargo, podemos observar que las barras de las autocorrelaciones muestran un patrón de comportamiento, por lo que nos estaría indicando una estacionalidad en la serie que sería 12.

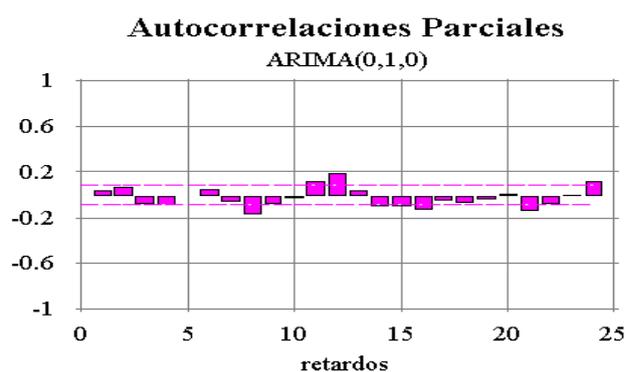


Gráfico 3.35

Por este motivo podríamos diferenciar estacionalmente a la serie para eliminar este patrón.

La FAC y la FACP de la serie diferenciada estacionariamente y estacionalmente se muestran a continuación:

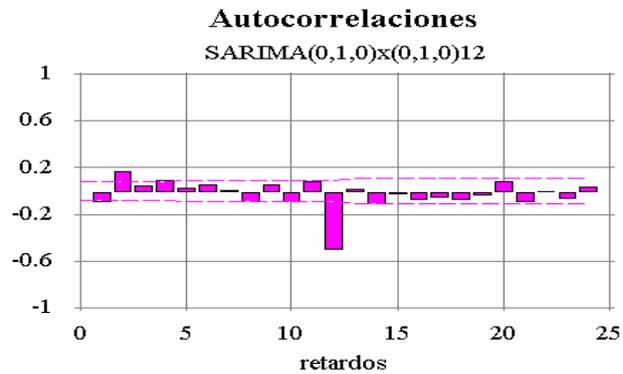


Gráfico 3.36

Observamos en este gráfico, como la barra del retardo 12 corta las bandas de confianza significativamente, por lo que podríamos necesitar parámetros estacionales para disminuir la misma.

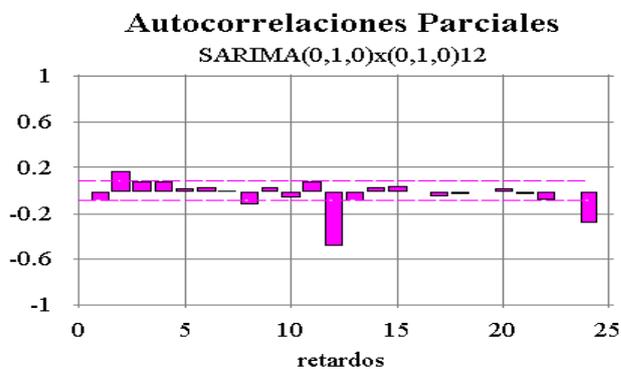


Gráfico 3.37

Algo muy parecido sucede en la FACP, pero en este caso son dos las barras que cortan significativamente las bandas de confianza, en el retardo 12 y 24.

Como dijimos anteriormente parámetros estacionales generalmente reducen estas autocorrelaciones.

Después de haber realizado este análisis podemos sugerir el modelo:

SARIMA(2,1,0)x(0,1,1)₁₂

Este modelo estaría compuesto por dos parámetros AR, y un parámetro SMA.

La FAC y la FACP del modelo sugerido se presentan a continuación.

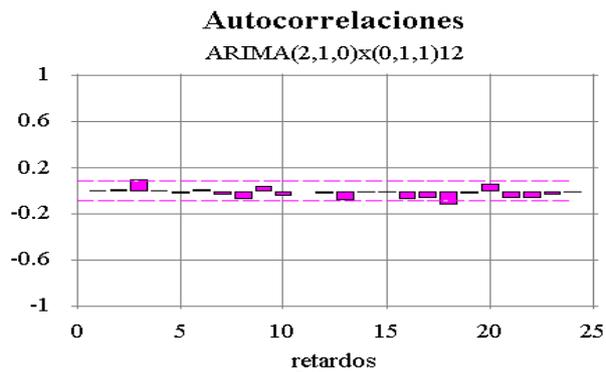


Gráfico 3.38

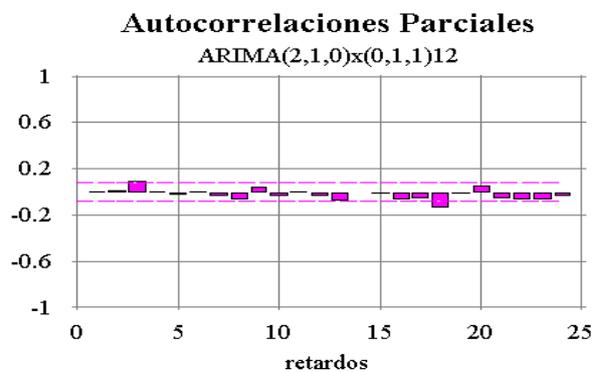


Gráfico 3.39

Nótese que las autocorrelaciones han disminuido considerablemente.

Ahora, nos trataremos de enfocarnos en averiguar si los parámetros del modelo sugerido son significantes, para esto se realiza la prueba que se detalla a continuación:

Prueba de los Parámetros del Modelo

Parámetro	Estimación	Error Estándar	t	Valor p
AR(1)	-0.117587	0.0407655	-2.88448	0.00406
AR(2)	0.117362	0.0407576	2.87951	0.00412
SMA(1)	0.960333	0.00621852	154.431	0

Observamos que los valores p para cada parámetro del modelo es menor a 0.05, por lo que podemos afirmar que dichos parámetros son significativamente diferentes de cero.

Ahora observemos el valor de la Media Cuadrática del Error de este modelo, para que nos sirva de referencia para escoger el mejor modelo.

MCE = 0.0604468

Ahora bien, nosotros pudimos observar que la serie era estacional, por este motivo se podría sugerir modelos diferenciados estacionalmente sin que éstos hayan sido diferenciados estacionariamente como en el modelo anterior para ver el comportamiento de los mismos.

Un modelo que podríamos sugerir es:

SARIMA(2,0,2)x(0,1,1)₁₂

Este modelo está compuesto por 2 parámetros AR y 2 parámetros MA, además de un parámetro estacional SMA.

A continuación se muestra la FAC y la FACP del modelo.

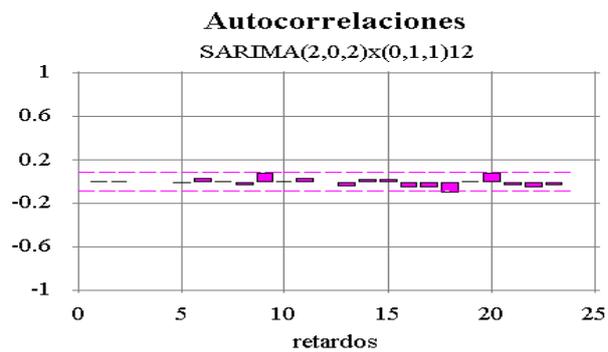


Gráfico 3.40

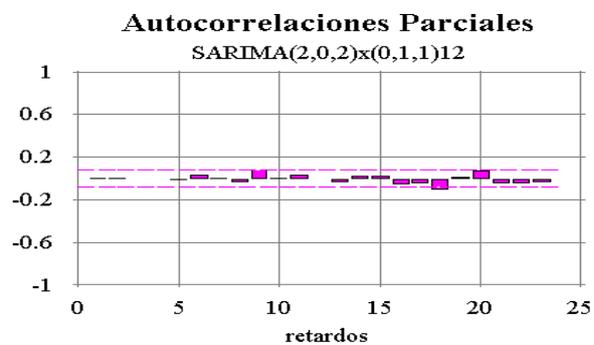


Gráfico 3.41

Las autocorrelaciones del modelo como podemos observar en los gráficos, se han logrado reducir de manera significativa, estando las mismas dentro de las bandas de confianza, indicando independencia de los residuos.

Ahora nos encargaremos de verificar la significancia de los parámetros del modelo.

Prueba de los Parámetros del Modelo

Parámetro	Estimación	Error Estándar	t	Valor p
AR(1)	1.59816	0.134487	11.8834	0
AR(2)	-0.640022	0.125551	-5.0977	0
MA(1)	0.770654	0.134213	5.742	0
MA(2)	-0.237924	0.0429707	-5.53689	0
SMA(1)	0.957153	0.00606782	157.743	0

Podemos observar en la prueba que los valores p de los parámetros del modelo son menores que 0.05, por lo que podemos decir que éstos son significativamente diferentes de cero.

La Media Cuadrática del Error del Modelo en cuestión es:

$$\mathbf{MCE = 0.0571133}$$

Nótese que se ha logrado reducir la MCE, con este modelo diferenciado estacionalmente.

Otro modelo que podríamos sugerir es:

$$\mathbf{SARIMA(3,0,1)\times(0,1,1)_{12}}$$

Este modelo consta de 3 parámetros AR, un parámetro MA, y un parámetro estacional SMA.

La FAC y la FACP del modelo se detallan a continuación.

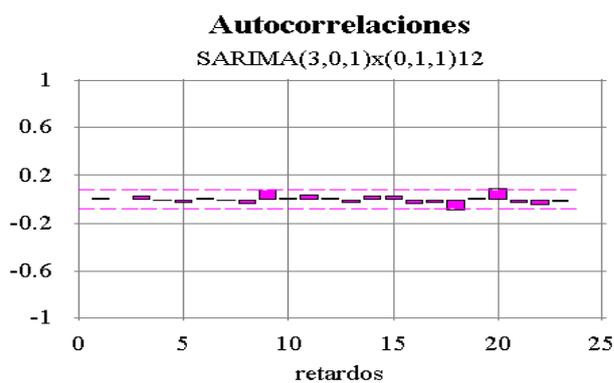


Gráfico 3.42

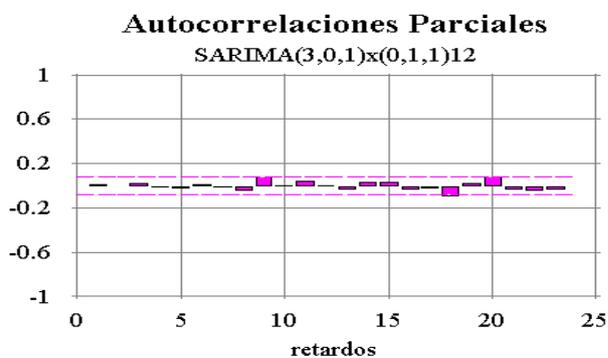


Gráfico 3.43

Podemos observar que la autocorrelaciones se han logrado reducir significativamente, encontrándose éstas dentro de las bandas de confianza, indicando independencia en los residuos del modelo.

A continuación verificamos la significancia de los parámetros del modelo.

Prueba de los Parámetros del Modelo

Parámetro	Estimación	Error Estándar	t	Valor p
AR(1)	1.47939	0.114856	12.8803	0
AR(2)	-0.290113	0.127727	-2.27136	0.0234
AR(3)	-0.223325	0.0401922	-5.55641	0
MA(1)	0.660315	0.116599	5.66312	0
SMA(1)	0.955767	0.00597012	160.092	0

Esta prueba nos da como resultado que los parámetros del modelo son significativamente diferentes de cero, puesto que sus valores p son menores que 0.05.

A continuación mostramos el valor de la Media Cuadrática del Error del Modelo en estudio.

$$\mathbf{MCE = 0.0570501}$$

Aunque todos los modelos sugeridos pasan la prueba de significancia de los parámetros, podemos notar que el último modelo analizado, es quien tiene la menor Media Cuadrática del Error, por lo que podemos decir que el modelo SARIMA(3,0,1)x(0,1,1)¹² es quien mejor captura la estructura de los datos.

Los pronósticos de este modelo para los años 2001 y 2002 se muestran en la Tabla XVII y en el Gráfico 3.44.

De igual manera que las variables anteriores, encontramos que las anomalías (Tabla XVIII), no nos indican presencia del Fenómeno, pues como vemos los valores de los pronósticos de este modelo, llegan a ser muy cercanos a los valores promedios.

Cabe recordar que para el presente estudio las anomalías correspondientes a los pronósticos de la TSM se las obtiene comparando con los valores promedios históricos que obtuvimos en base al periodo 1950-2000; estos valores serían un valor representativo al valor que se espera tenga la TSM cada mes en los años 2001 y 2002.

Tabla XVIII (Ver archivo Pronósticos)

Gráfico 3.44 (Ver archivo Gráficos)

Tabla XVIII (Ver archivo anomalías)

3.2.5. Variable Niño 3.4

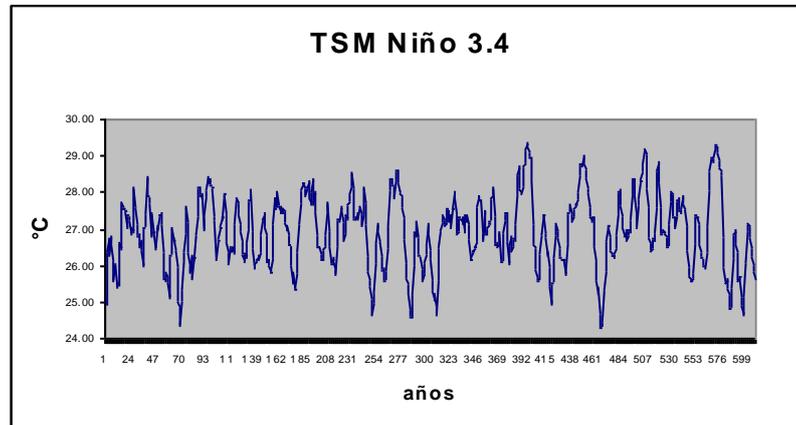


Gráfico 3.45

El gráfico de la serie de esta variable nos estaría dando a conocer que ésta no es estacionaria, lo cual nos indicaría la necesidad de diferenciar a la serie estacionariamente.

Antes de realizar esto, veamos el comportamiento de la FAC y la FACP.

Graficando la FAC (Gráfico 3.46) podemos notar que algunas barras cortan las bandas de confianza significativamente, mientras que en la FACP (Gráfico 3.47) de la serie podemos darnos cuenta que la barra en el retardo 1 es muy grande por lo que tendríamos un autocorrelación muy alta, la cual tendríamos que reducir.

Esta barra que cortan de manera significativa las bandas de confianza, podrían delatar un modelo con 1 parámetro autorregresivo.

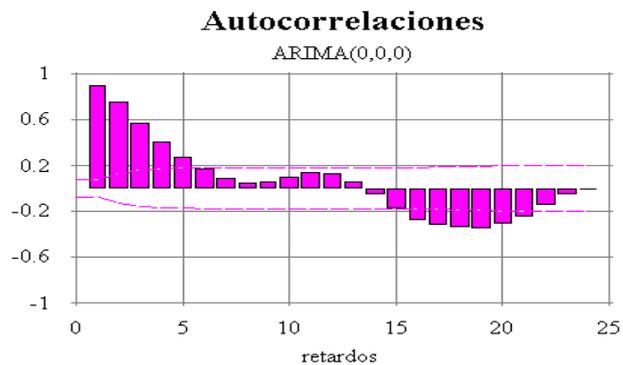


Gráfico 3.46

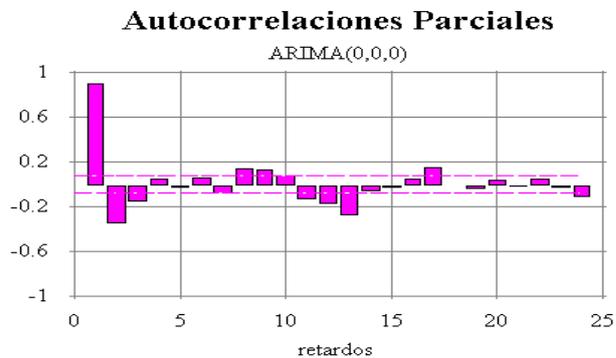


Gráfico 3.47

Ahora si diferenciamos a la serie en una ocasión de manera estacionaria, podemos darnos cuenta claramente que las autocorrelaciones de la serie toman otros valores por lo que los correlogramas de la FAC y la FACP se detallan a continuación.

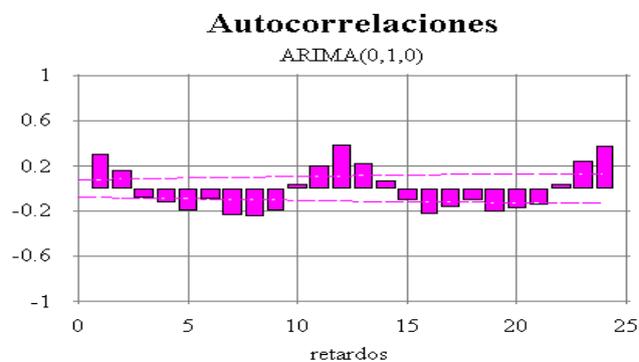


Gráfico 3.48

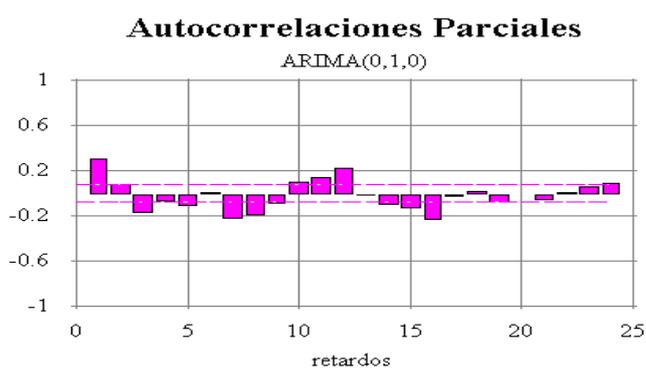


Gráfico 3.49

Podemos notar en el Gráfico 3.48 que las barras de las autocorrelaciones siguen un patrón lo cual nos estaría indicando una estacionalidad.

En esta serie, al igual que en las anteriores la estacionalidad es 12, lo cual es lógico por lo que este tipo de variables tienen un comportamiento similar cada año, es decir cada 12 meses.

Al diferenciar estacionaria y estacionalmente a la serie, la FAC y la FACP se mostrarían de la siguiente manera:

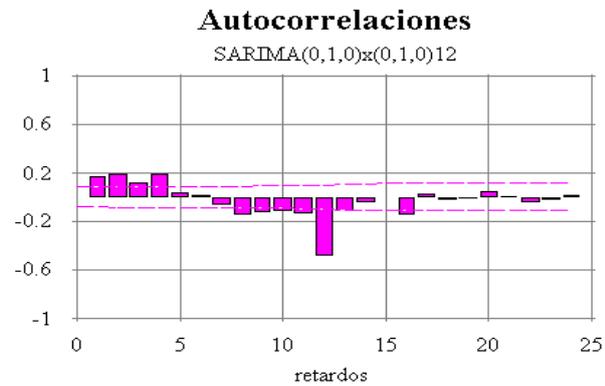


Gráfico 3.50

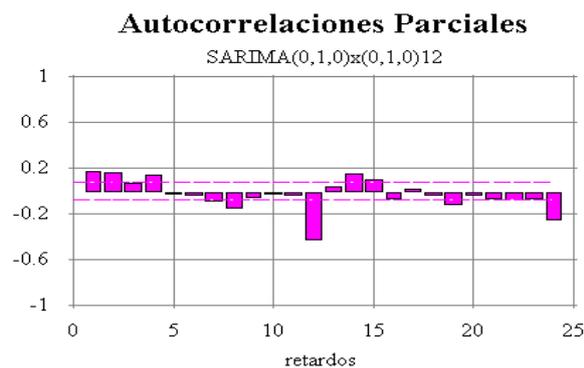


Gráfico 3.51

En los 2 gráficos anteriores tenemos que aunque algunas barras aún cortan las bandas de confianza, en la FAC en el retardo 12 y en la FACP en el retardo 12 y 24 las cortan de una manera muy significativa.

Generalmente estas autocorrelaciones altas son reducidas añadiendo parámetros estacionales al modelo.

De este modo podemos sugerir un primer modelo para esta serie, el cual sería:

SARIMA(1,1,2)x(0,1,1)₁₂

Este modelo diferenciado estacionaria y estacionalmente consta de un parámetro AR y 2 MA estacionarios, y un parámetro estacional SMA.

La FAC y FACP del presente modelo se detallan a continuación.

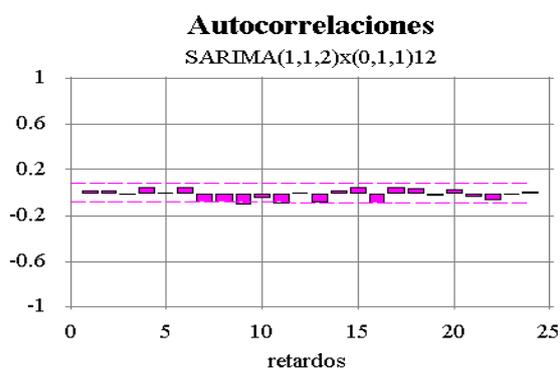


Gráfico 3.52

Nótese que se han logrado reducir significativamente las barras de la autocorrelaciones del modelo sugerido, estando entre las bandas de confianza, indicando independencia entre los residuos.

De la misma forma, en la FACP (Gráfico 3.53), podemos notar algo similar que en la FAC (Gráfico 3.52) puesto también se han logrado reducir las autocorrelaciones del modelo.

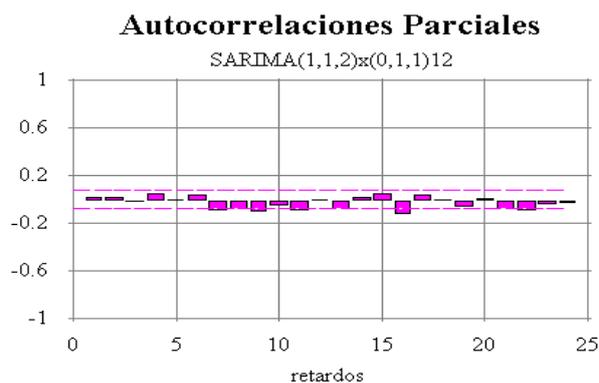


Gráfico 3.53

Así pues, después de ver los gráfico de la FAC y la FACP del modelo, nos toca verificar si los parámetros del modelo son significativamente diferentes de cero.

Prueba de los Parámetros del Modelo

Parámetro	Estimación	Error Estándar	t	Valor p
AR(1)	0.623898	0.232179	2.68714	0.0074
MA(1)	0.583668	0.233207	2.50279	0.01258
MA(2)	-0.0992872	0.0464586	-2.13711	0.0329
SMA(1)	0.961054	0.0068363	140.58	0

Al observar los valores p de cada uno de los parámetros del modelo, nos damos cuenta que éstos son menores que 0.05, por lo que podemos decir que éstos son significativamente diferentes de cero.

A continuación mostramos el valor de la Media Cuadrática del Error del modelo:

$$\mathbf{MCE = 0.107256}$$

Como hemos visto en el modelo anterior, la serie ha sido diferenciada estacionaria y estacionalmente, pero si analizamos la serie diferenciándola solo estacionalmente podremos darnos cuenta que nos da como resultado un mejor modelo.

Con lo que podemos sugerir los siguientes modelos:

$$\mathbf{SARIMA(1,0,2)x(0,1,1)12}$$

Esta serie diferenciada estacionalmente, está compuesta por un parámetro AR, dos parámetros MA estacionarios y un parámetro estacional SMA.

En los Correlogramas de la FAC (Gráfico 3.54) y la FACP (Gráfico 3.55) del modelo en estudio podemos observar que se han logrado reducir significativamente las barras de las autocorrelaciones.

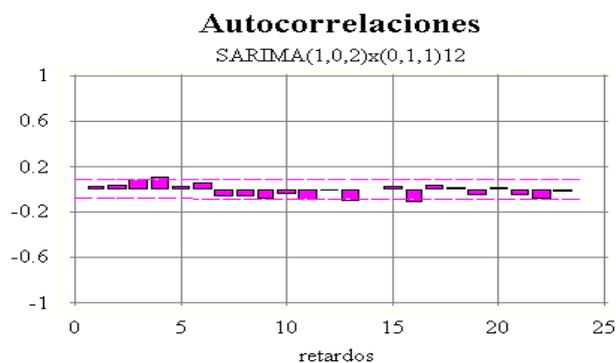


Gráfico 3.54

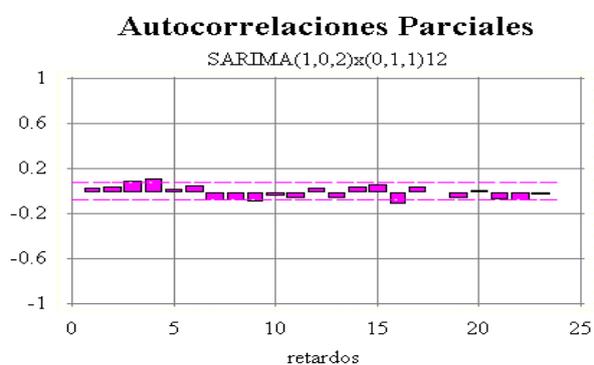


Gráfico 3.55

A continuación verificamos si los parámetros del modelo son significativamente diferentes de cero.

Prueba de los Parámetros del Modelo

Parámetro	Estimación	Error Estándar	t	Valor p
AR(1)	0.903274	0.0199149	45.3566	0
MA(1)	-0.084262	0.0438935	-1.91971	0.05537
MA(2)	-0.145088	0.0429578	-3.37745	0.00077
SMA(1)	0.95361	0.0076610	124.475	0

En la prueba anterior nos podemos dar cuenta que los parámetros AR(1), MA(2) y SMA(1) del modelo son significativamente diferentes de cero, puesto que sus valores p son menores que 0.05, pero el parámetro MA(1) no pasa la prueba de significancia puesto que su valor p es de 0.05537.

Al calcular la Media Cuadrática del Error del modelo se tiene que :

$$\text{MCE} = 0.102987$$

A continuación se sugiere un último modelo para la serie en estudio:

$$\text{SARIMA}(3,0,1)\times(2,1,3)_{12}$$

El presente modelo diferenciado estacionalmente consta de tres parámetros AR , un parámetro MA, dos parámetros SAR y tres parámetros SMA.

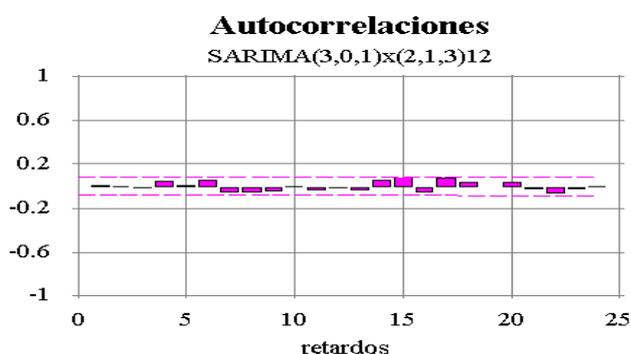
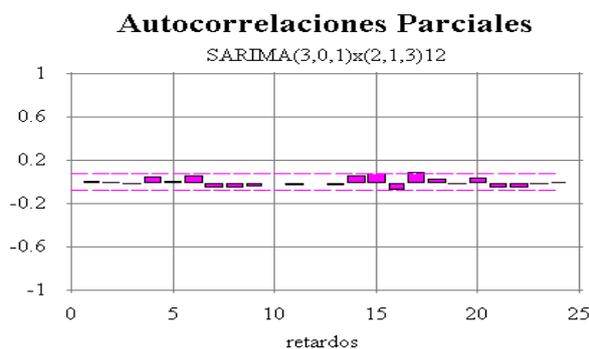


Gráfico 3.56

**Gráfico 3.57**

Las barras de las autocorrelaciones en los Gráfico 3.56 y 3.57 se han logrado reducir de tal manera que éstas se encuentran dentro de las bandas de confianza.

A continuación realizamos la prueba de significancia de los parámetros.

Prueba de los Parámetros del Modelo

Parámetro	Estimación	Error Estándar	t	Valor p
AR(1)	1.71056	0.0796385	21.4791	0
AR(2)	-0.645473	0.116525	-5.53936	0
AR(3)	-0.103634	0.048505	-2.1365	0.03304
MA(1)	0.742055	0.0713268	10.4036	0
SAR(1)	-0.474861	0.0907847	-5.23063	0
SAR(2)	-0.863773	0.0584931	-14.7671	0
SMA(1)	0.404815	0.0826439	4.8983	0
SMA(2)	-0.38598	0.0758154	-5.09106	0
SMA(3)	0.866764	0.0492561	17.5971	0

En este modelo notamos que los valores p de los parámetros que forman parte del modelo son menores que 0.05, lo cual nos indica que éstos son significativamente diferentes de cero.

La media Cuadrática del Error del Modelo es:

$$\mathbf{MCE = 0.0979295}$$

Para la variable Niño 3.4 nos podemos dar cuenta que hemos logrado reducir la MCE del modelo al diferenciar estacionalmente a serie, sin necesidad de hacerlo estacionariamente.

El primer modelo sugerido aunque pasó la prueba de los parámetros, su MCE es mucho mayor que la de los dos modelos después sugeridos.

El segundo modelo aunque logró reducir la MCE con respecto al primer modelo, éste no pasó la prueba de los parámetros, por lo que no había evidencia para afirmar que los parámetros que forman parte del modelo eran significativamente diferentes de cero.

El tercer modelo, SARIMA(3,0,1)x(2,1,3)₁₂ al pasar la prueba de significancia de parámetros y tener la menor MCE, es el modelo el cual captura de una mejor manera la estructura de los datos.

Los pronósticos para los años 2001 y 2002 de este modelo se podrán apreciar de una forma detallada en la Tabla XIX y en el Gráfico 3.58.

De la misma manera que en los pronósticos obtenidos para las variables anteriormente estudiadas, se nota un leve aumento de temperaturas para el año 2002 en relación con el 2001, lo cual al revisar la Tabla XX correspondiente a las anomalías nos indica que no guarda relación con la presencia de “El Niño”, pues estos valores aun se los puede considerar dentro de los parámetros normales.

Así pues, podemos darnos cuenta que en los pronósticos realizados para las 4 áreas de observación en el Pacífico central coinciden en mostrarnos anomalías que sugieren un comportamiento normal en estas áreas de gran influencia.

Tabla XIX (Ver archivo Pronósticos)

Gráfico 3.58 (Ver archivo Gráficos)

Tabla XX (Ver archivo Anomalías)

3.2.6. Variable Temperatura del Aire (Guayaquil)

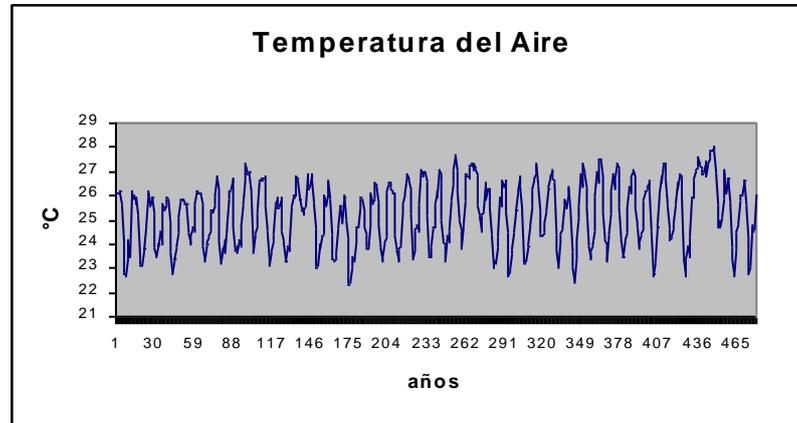


Gráfico 3.59

Vemos en este gráfico que la serie de la variable Temperatura del Aire tiende a ser estacionaria en el tiempo.

La diferenciación estacionaria, en este caso no sería necesaria, por lo que proseguimos graficando la FAC y la FACP de la serie.

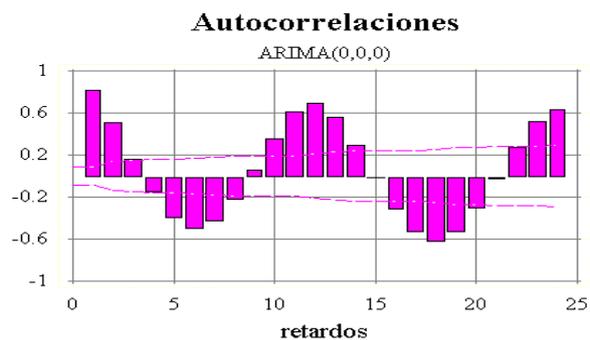


Gráfico 3.60

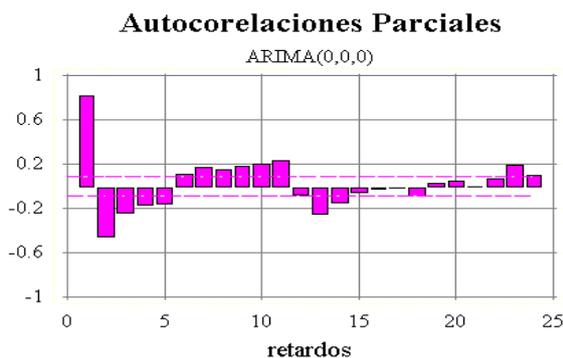


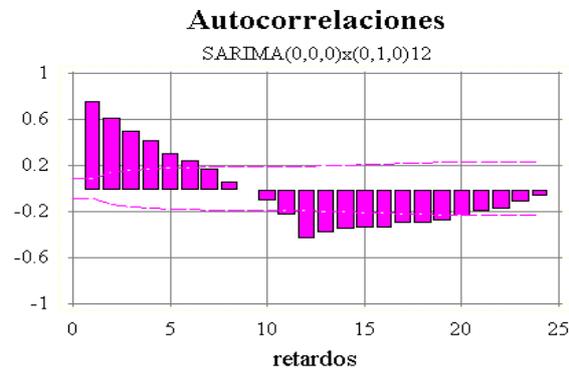
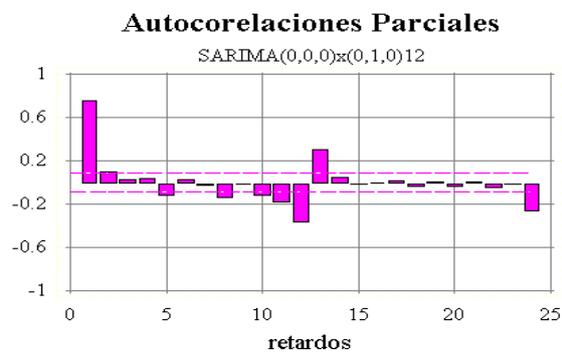
Gráfico 3.61

En la FAC de esta serie (Gráfico 3.60), nos podemos dar cuenta que existe una estacionalidad en la serie.

Al igual que en las variables de la Temperatura Superficial del Mar anteriormente analizadas, esta serie resultó ser estacional, lo cual es algo muy comprensible, puesto que esta variable atmosférica también tiene un tipo de comportamiento que es semejante cada año, por lo que esta serie también resulta con una estacionalidad 12.

En la FACP (Gráfico 3.61) vemos que la primera barra corta de una manera significativa las bandas de confianza, la segunda también lo hace pero en menor grado, por lo que podríamos estar hablando de la posibilidad de que un modelo para esta serie podría estar compuesto por uno o dos parámetros AR.

A continuación, para disminuir o suavizar las barras de autocorrelaciones mostradas en la FAC, eliminando a su vez la periodicidad de aparición de las mismas, procedemos a diferenciar estacionalmente la serie.

**Gráfico 3.62****Gráfico 3.63**

Notamos en el gráfico 3.62 correspondiente a la FAC, que se ha eliminado la periodicidad que mostraban las barras, pero conservando aún un gran número de barras que cortan las bandas de confianza, con un decrecimiento continuo de las mismas, lo cual puede ser debido a la propagación de la autocorrelación en el retardo 1.

En la FACP podemos notar que hay autocorrelaciones positivas en los retardos 1 y 13, y autocorrelaciones negativas en los retardos 12 y 24 que cortan significativamente las bandas de confianza.

Estas autocorrelaciones se disminuyen generalmente añadiendo parámetros estacionales, por lo que el uso de éstos será indispensable para encontrar un modelo óptimo.

A partir del análisis realizado podemos sugerir un primer modelo:

SARIMA(1,0,1)x(0,1,1)₁₂

Este modelo está compuesto por un parámetro AR y un parámetros MA, además de un parámetro estacional SMA.

La FAC y la FACP de este modelo tienen el siguiente comportamiento:

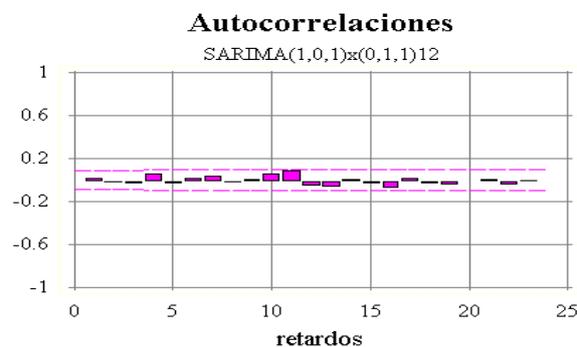


Gráfico 3.64

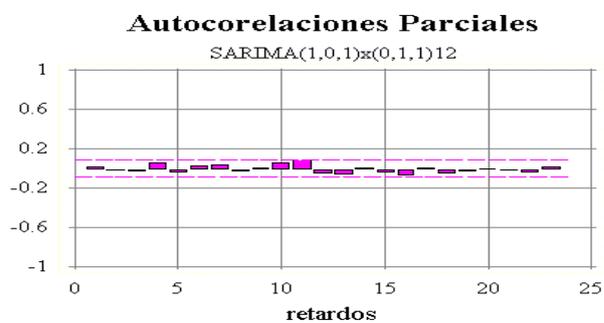


Gráfico 3.65

En la FAC y la FACP del modelo observadas en los gráficos anteriores notamos claramente cómo las barras de las autocorrelaciones han sido reducidas considerablemente, encontrándose éstas dentro de las bandas de confianza, por lo cual podemos decir que los residuos del modelo son independientes.

A continuación verificaremos si los parámetros del modelo son significativamente diferentes de cero.

Prueba de los Parámetros del Modelo

Parámetro	Estimación	Error Estándar	t	Valor p
AR(1)	0.83546	0.0328602	25.4247	0
MA(1)	0.14257	0.0587619	2.4262	0.01563
SMA(1)	0.947359	0.0101248	93.5685	0

Al verificar que los valores p de los parámetros del modelo son menores que 0.05, podemos afirmar que los parámetros son significativamente diferentes de cero.

La Media Cuadrática del Error resultante de este modelo es de:

$$\mathbf{MCE = 0.211903}$$

Un modelo intermedio para la serie en estudio podría estar dado por.

SARIMA(1,0,1)x(0,1,2)12

Este modelo está compuesto por un parámetro AR, 21 parámetros MA, y dos parámetros estacionales SMA.

Para verificar que los residuos del modelo sean independientes graficamos la FAC y la FACP, las cuales mostramos a continuación.

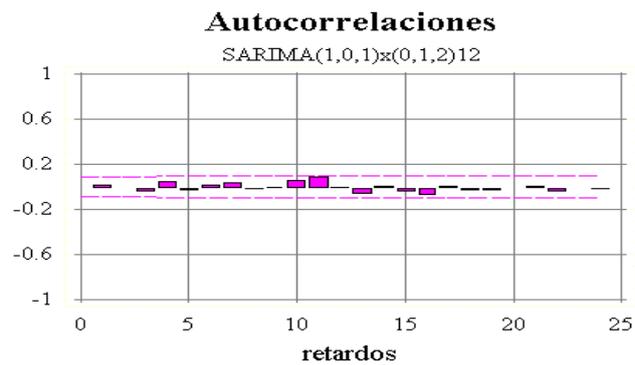


Gráfico 3.66

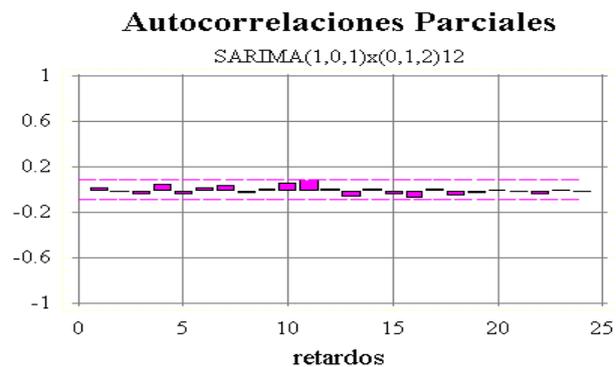


Gráfico 3.67

Claramente notamos, que las barras de las autocorrelaciones están dentro de las bandas de confianza, confirmando así la independencia de los residuos del modelo.

Verificando si los parámetros del modelo son significativamente diferentes de cero obtuvimos:

Prueba de los Parámetros del Modelo

Parámetro	Estimación	Error Estándar	t	Valor p
AR(1)	0.83854	0.0325116	25.792	0
MA(1)	0.142249	0.0583748	2.43682	0.01519
SMA(1)	1.00984	0.0469672	21.501	0
SMA(2)	-0.062569	0.0460819	-1.3577	0.17519

Para este modelo notamos que el parámetro SMA(2) no pasa la prueba de significancia, puesto que su valor p es mayor que 0.05, por lo que no podemos afirmar que es significativamente diferente de cero.

Los demás parámetros pasan sin problemas la prueba de significancia.

Aunque este modelo, tiene un parámetro que no pasa la prueba de significancia, hay que resaltar que éste ha logrado reducir la Media Cuadrática del Error, la cual es de:

$$\text{MCE} = 0.211342$$

Un último modelo sugerido para la serie en estudio es:

$$\text{SARIMA}(2,0,0)\times(0,1,1)_{12}$$

Este modelo consta de dos parámetros AR estacionarios y un parámetro MA estacional.

La FAC y la FACP el modelo se muestran a continuación:

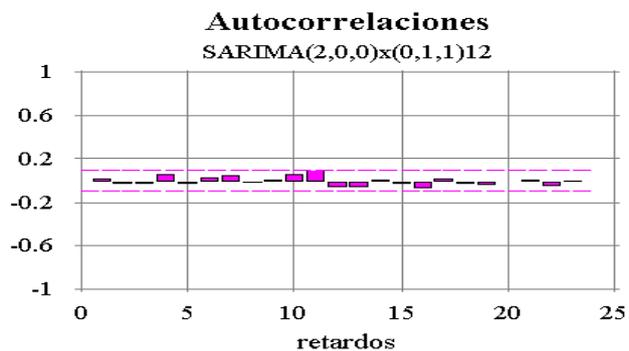


Gráfico 3.68

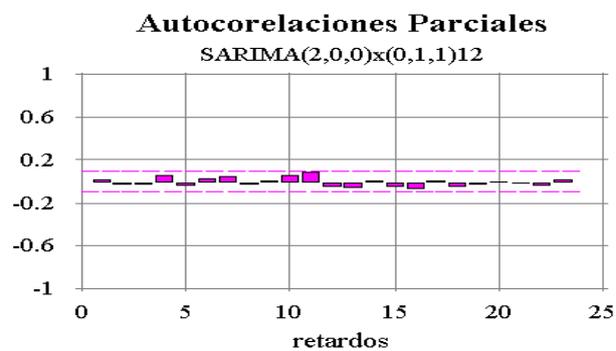


Gráfico 3.69

Podemos observar que las barras de las autocorrelaciones se encuentran dentro de las bandas de confianza, por lo que podremos decir que los residuos del modelo son independientes.

A continuación realizamos la prueba de significancia de los parámetros.

Prueba de los Parámetros del Modelo

Parámetro	Estimación	Error Estándar	t	Valor p
AR(1)	0.69684	0.0461703	15.0928	0
AR(2)	0.107101	0.0461555	2.32044	0.02074
SMA(1)	0.947541	0.00872971	108.542	0

Vemos claramente que todos los parámetros del modelo son menores que 0.05, por lo que podemos afirmar que éstos son significativamente diferentes de cero.

La Media Cuadrática del Error del modelo es:

$$\mathbf{MCE = 0.212013}$$

Para seleccionar el mejor modelo, para nuestra serie de datos de la Temperatura del Aire en Guayaquil, tenemos que fijarnos que el modelo SARIMA(1,0,1)x(0,1,2)₁₂ es quien tiene la menor

MCE, pero no pasa la prueba de significancia de los parámetros.

Los dos modelos restantes pasan la prueba de significancia, siendo entre los dos el de menor MCE el modelo SARIMA(1,0,1)x(0,1,1)₁₂.

Por lo que analizando estos resultados, seleccionamos el modelo SARIMA(1,0,1)x(0,1,1)₁₂, como un modelo que captura de una mejor manera la estructura de los datos, puesto que aunque no es el modelo con la menor MCE, ganamos en significancia, puesto que la prueba nos dio como resultado que sus parámetros si eran significativamente diferentes de cero.

Los pronósticos para los 2 siguientes años es decir 2001 y 2002 de este modelo se presentan en detalle en la Tabla XXI y en el Gráfico 3.70.

Tabla XXI (Ver archivo Pronósticos)

Gráfico 3.70 (Ver archivo Gráficos)

3.3. Correlaciones

Para poder darnos una mejor idea de la relación existente entre las variables que forman parte del presente estudio, realizaremos a continuación un análisis de correlaciones, para lo cual obtendremos la matriz de correlación de los datos de las diferentes variables analizadas anteriormente.

Primero codificaremos las diferentes variables, con un nombre que tenga una longitud mucho menor que la original para facilitarnos el manejo de las mismas en la matriz, por lo que tendríamos:

Variable X1 = Temperatura Superficial del Mar Niño 1+2

Variable X2 = Temperatura Superficial del Mar Niño 3

Variable X3 = Temperatura Superficial del Mar Niño 4

Variable X4 = Temperatura Superficial del Mar Niño 3.4

Variable X5 = Temperatura del Aire

Variable X6 = Precipitaciones

Para poder obtener las correlaciones, se tomó las observaciones de cada variable desde el año 1961 hasta el 2000, para así tener la misma cantidad de datos en cada variable, y poder calcular la matriz de correlaciones.

MATRIZ DE CORRELACIONES

	X1	X2	X3	X4	X5	X6
X1	1	0.8082	0.0824	0.4586	0.8700	0.7224
X2	0.8082	1	0.4913	0.8652	0.6716	0.5150
X3	0.0824	0.4913	1	0.8161	0.1073	-0.0419
X4	0.4586	0.8652	0.8161	1	0.3681	0.2509
X5	0.8700	0.6716	0.1073	0.3681	1	0.5327
X6	0.7224	0.5150	-0.0419	0.2509	0.5327	1

Podemos notar que la variable X1, tiene una fuerte correlación positiva con la variables X2, X5 y X6; con la variable X4 también existe una correlación positiva pero en menor grado.

La variable X2 está correlacionada con las variables X5, X6 y de manera mucho más fuerte con la variable X4, con la variable X3 podemos decir que no hay correlación.

La variable X3 no está correlacionada con la variable X5, ni con la variable X6, pero si lo está con la variable X4.

La variable X4 podremos decir que no está correlacionada con las variables X5 y X6.

La variable X5 podemos decir que tiene una débil correlación positiva con la variable X6

Capítulo 4

4. CONCLUSIONES Y RECOMENDACIONES

4.1. Conclusiones

- 1) En el análisis realizado, podemos notar claramente que el uso de modelos estacionales, ha sido el común denominador en todas las variable de estudio.
- 2) La longitud de la estacionalidad en todos los casos ha sido 12, lo que claramente nos confirma que cada año, es decir cada 12 meses, los datos de estas variables tienen un comportamiento semejante.
- 3) Para la variable Niño 1+2, encontramos que el modelo SARIMA(2,0,0)x(0,1,1)₁₂ es quien mejor captura la estructura de los datos, teniendo una MCE de 0.232382.
- 4) En la variable Niño 3 encontramos un buen modelo a partir de un SARIMA(2,0,1)x(0,1,1)₁₂ con una MCE de 0.1231.

- 5) Notamos que tanto para la variable Niño 1+2, como para la variable Niño 3 se tiene dos parámetros AR estacionarios que forman parte del modelo.
- 6) Para las variables Niño 4 y Niño 3.4, nos damos cuenta que se hace uso de tres parámetros AR estacionarios en los modelos SARIMA seleccionados para cada una de estas variables.
- 7) Para la variable Niño 4 se seleccionó el modelo $SARIMA(3,0,1) \times (0,1,1)_{12}$ con una MCE de 0.0570501, y para la variable Niño 3.4 el modelo $SARIMA(3,0,1) \times (2,1,3)_{12}$
- 8) Para la variable Temperatura del Aire tenemos que el modelo $SARIMA(1,0,1) \times (0,1,1)_{12}$ es quien captura la estructura de los datos de una mejor manera, siendo su MCE de 0.211903.
- 9) Los Modelos SARIMA analizados recientemente son de gran ayuda para pronosticar anomalías de las diferentes variables relacionadas con el Fenómeno de “El Niño”.

- 10) Las anomalías correspondientes a los pronósticos de la Temperatura Superficial del Mar en las cuatro áreas de observación en el Pacífico ecuatorial, nos permite determinar que no existe evidencia para afirmar que en el año 2002 tendremos la presencia del Fenómeno de “El Niño”.

- 11) Cabe señalar que los pronósticos basados en modelos SARIMA, son confiables en el corto plazo, pero tienden a perder eficiencia con el paso del tiempo, puesto que se desactualizan muy rápidamente, por lo que se requiere un proceso continuo de análisis.

- 12) Debido a que “El Niño” es un Fenómeno cuyo inicio y terminación ocurren de una manera repentina, no cíclica, el mejor modelo explicativo pasa por un conocimiento global y en tiempo real de todos los procesos que se suceden en los océanos y en la atmósfera, y que en gran medida influyen en las diferentes variables meteorológicas.

- 13) Podemos notar que la Temperatura Superficial del Mar Niño 1+2 y las Precipitaciones, están relacionadas positivamente, es decir, un aumento de la Temperatura Superficial del Mar en el área Niño 1+2, indicaría un incremento en las Precipitaciones, y viceversa.
- 14) También verificamos que existe relación entre la Temperatura Superficial del Mar Niño 1+2 y la Temperatura del Aire, puesto que, una elevación de la Temperatura Superficial del Mar tiende a incrementar la Temperatura del Aire mediante el ascenso de aire caliente y húmedo.
- 15) La Temperatura Superficial del Mar Niño 3.4, está relacionada con la Temperatura Superficial del Mar Niño 3 y Niño 4, pero podemos decir que éstas dos últimas no están relacionadas.
- 16) La Temperatura Superficial del Mar Niño 1+2 está relacionada con la Temperatura Superficial de Mar Niño 3, y ésta a su vez en menor grado con la Temperatura del Aire.

4.2. Recomendaciones

- 1) Pronósticos en base a modelos matemáticos, como los SARIMA, tienden a ser mucho más eficientes en el corto plazo, por lo que se recomienda realizarlos cada año, pues estas predicciones son muy confiables.
- 2) La utilización de la tecnología satelital para el monitoreo en tiempo real del comportamiento de las variables que intervienen en el Fenómeno de “El Niño”, es hoy en día la herramienta más utilizada para pronosticar su aparición, por lo que el Ecuador, debe estar cada día más inmiscuido con las nuevas técnicas de análisis.
- 3) Tener a las estaciones de mediciones, equipadas con los mejores equipos de obtención de datos, además de tener un buen sistema de comunicaciones y un moderno sistema informático.
- 4) Incrementar el número de centros que se dedican al estudio del Fenómeno. Cabe recordar que el Ecuador se encuentra en la zona de mayor impacto, y es relevante un mayor conocimiento del mismo.

- 5) Solicitar asistencia técnica de institutos internacionales encargados del monitoreo del Fenómeno “El Niño”.
- 6) Buscar medios de financiación, para así poder mejorar las herramientas con que se cuenta para el monitoreo de las diferentes variables que alertan la presencia del Fenómeno.
- 7) Implantar un Sistema de Prevención contra los estragos que pueda causar la presencia de “El Niño”.

BIBLIOGRAFIA

1. Acta de la Reunión de Trabajo sobre el Fenómeno conocido como el Niño. (Organización de las Naciones Unidas para la Agricultura y Alimentación) FAO 1976.
2. INOCAR, Diagnóstico de “El Niño” 1997
3. INOCAR, Acta Oceanográfica del Pacífico. Volumen 3 N°1.
4. <http://www.pmel.noaa.gov/tao/elnino>, Temas sobre el Fenómeno de “El Niño”
5. <http://www.imarpe.gob.pe>, El Fenómeno de “El Niño”
6. <http://www.inocar.mil.ec>, Boletín de Alerta Climático versión digital.
7. Carlos Vacacela Alvarez, Ecuador El Hombre y su Mar.
8. George P. Box, Gwilyn Jenkins, and Gregory Reinsel, Time Series Analysis, Prentice Hall 1994.

9. William Mendenhall, Estadística Matemática con Aplicaciones, 1994, Grupo Editorial Iberoamérica S.A.

10. Bulletin de l'Institut Français d'Etudes Andines Tome 27 N° 3, 1998, Variations climatiques et ressources en eau en Amérique du Sud: Importance et conséquences des événements El Niño.

11. Boletín de Alerta Climático, Estudio Regional del Fenómeno de "El Niño" (ERFEN), Comisión Permanente de Pacífico Sur, 2001.

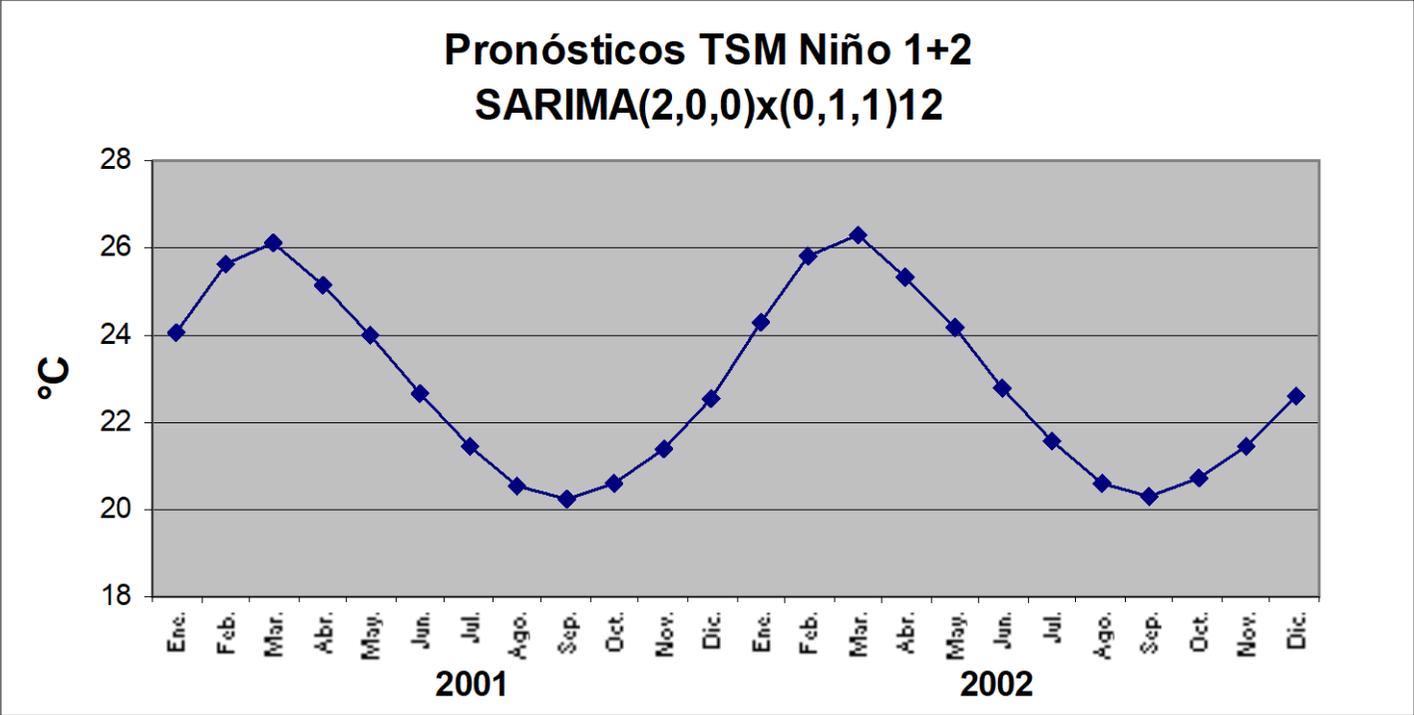


Gráfico 3.18

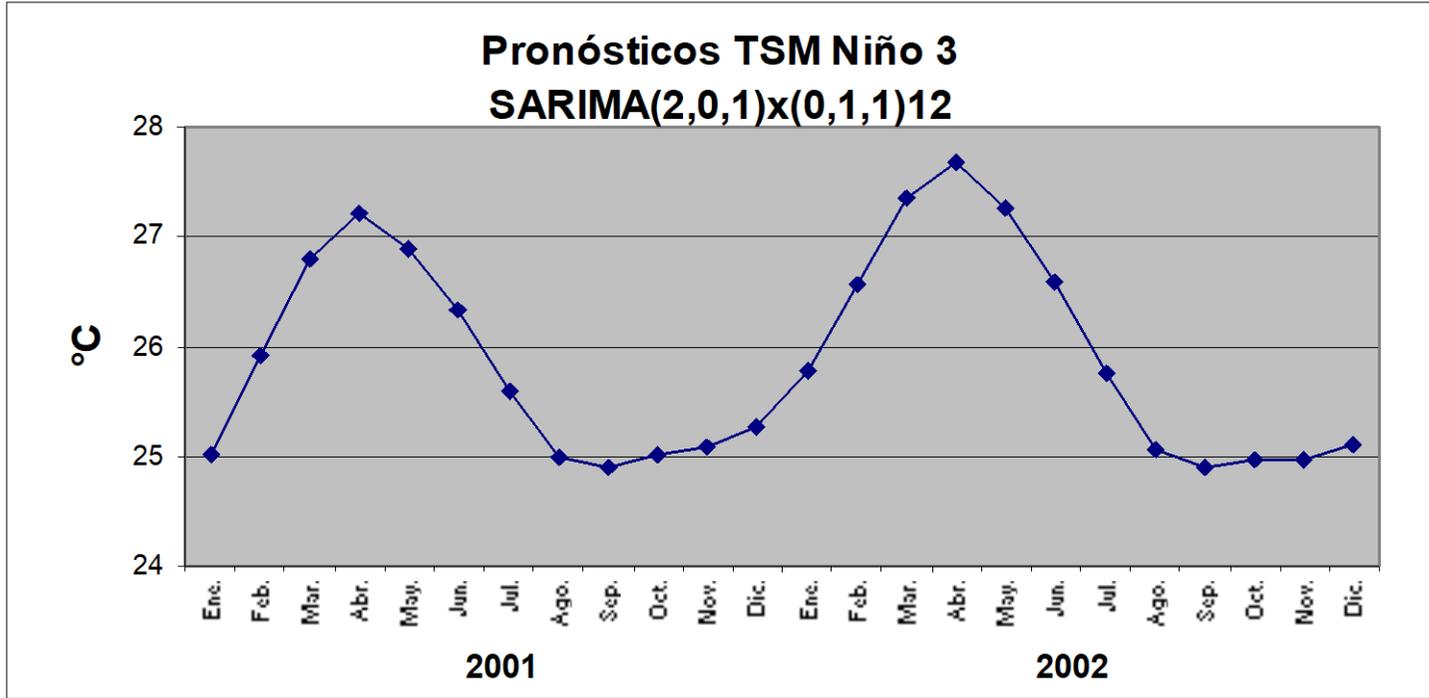


Gráfico 3.30

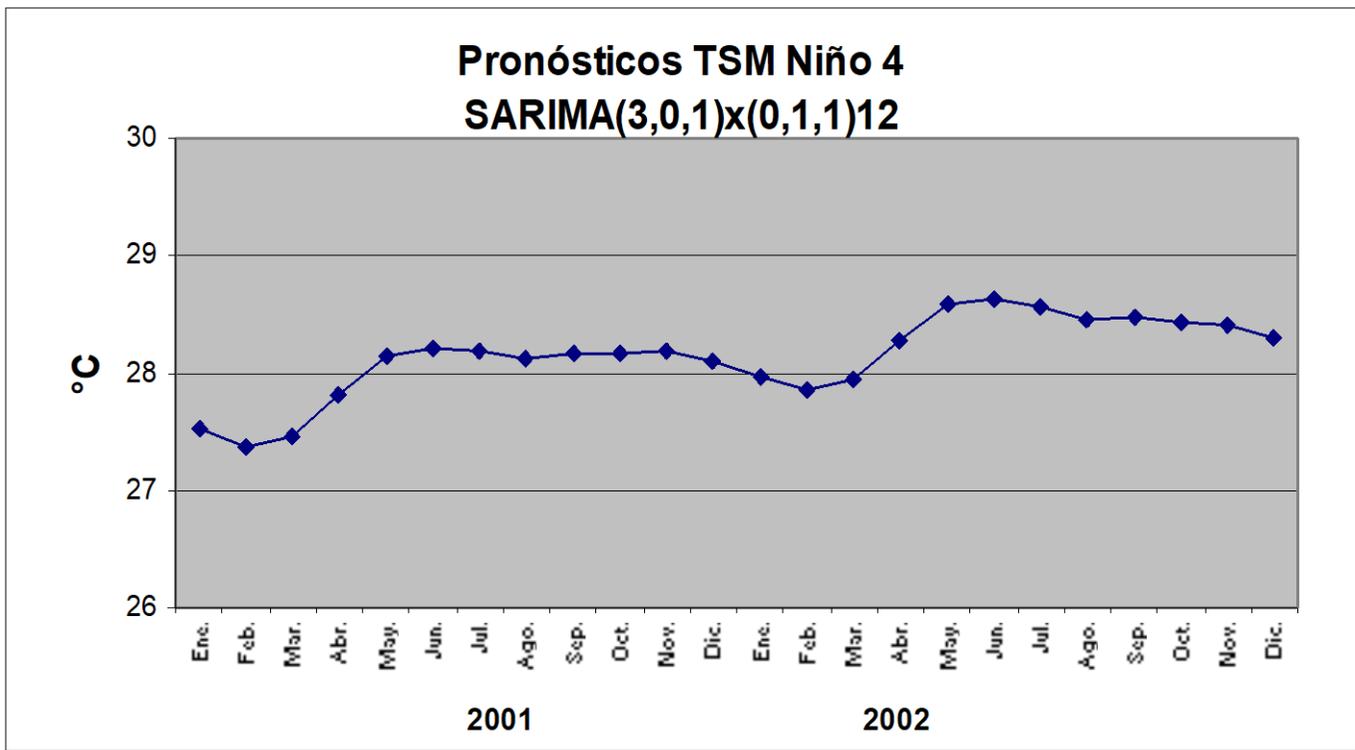


Gráfico 3.44

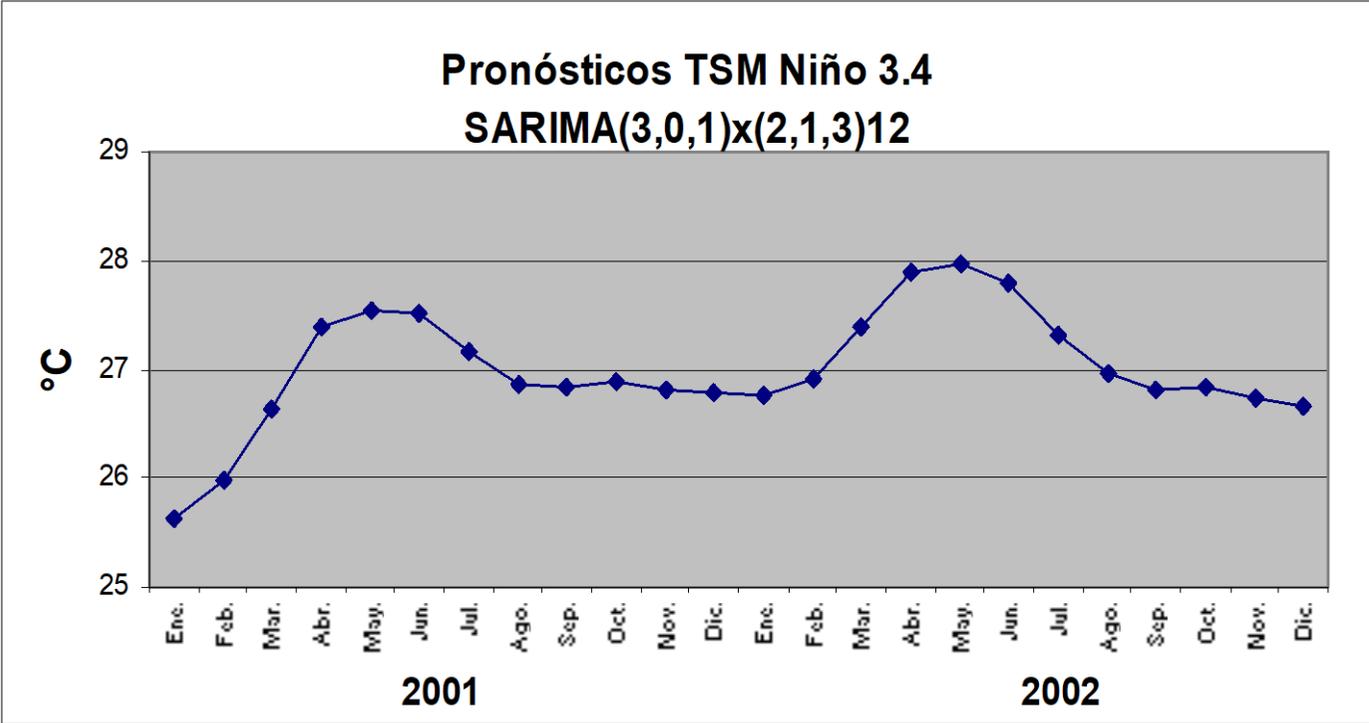


Gráfico 3.58

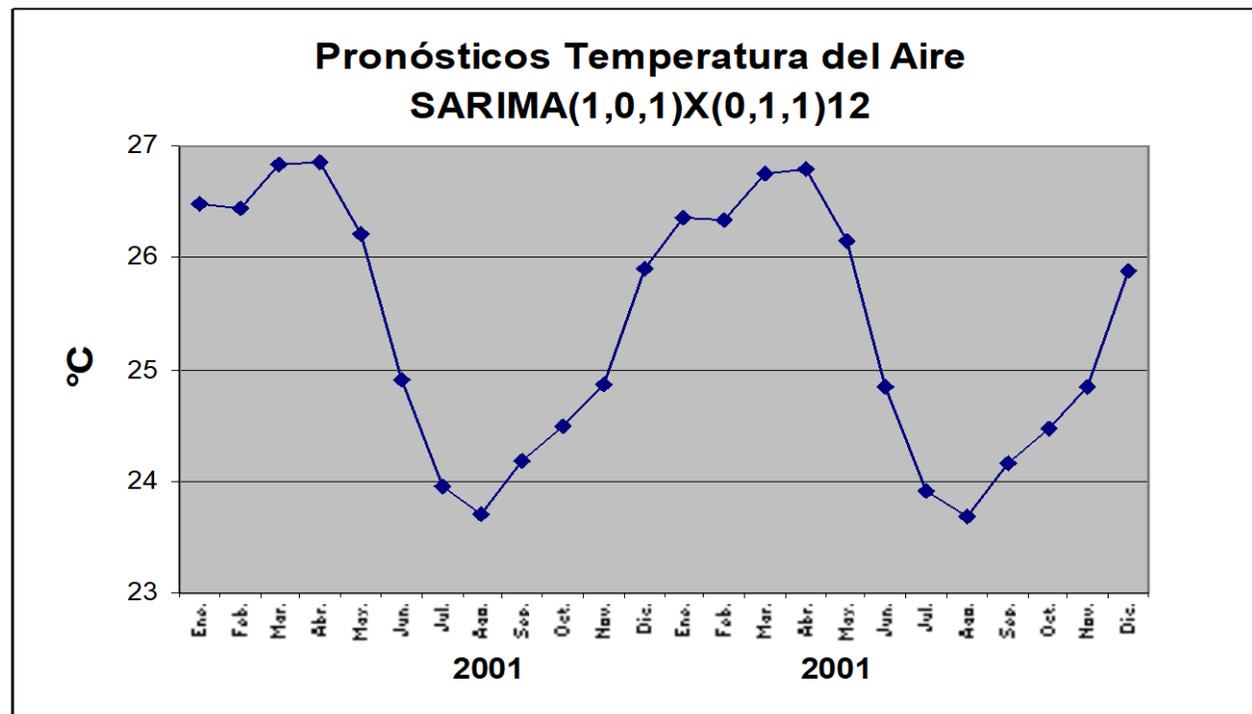


Gráfico 3.70

TABLA XIII

PRONÓSTICOS TSM Niño 1+2 (2001 – 2002) SARIMA(2,0,0)x(0,1,1)₁₂

Mes	Pronóstico	Límites de Confianza 95%	
		Inferior	Superior
Enero	24.0358	23.0786	24.9931
Febrero	25.6144	24.2518	26.977
Marzo	26.1069	24.4894	27.7243
Abril	25.1508	23.3592	26.9424
Mayo	24.0038	22.0877	25.9199
Junio	22.6453	20.6377	24.6529
Julio	21.4807	19.4048	23.5567
Agosto	20.5236	18.396	22.6511
Septiembre	20.2134	18.0466	22.3802
Octubre	20.6253	18.4285	22.8222
Noviembre	21.3911	19.1712	23.611
Diciembre	22.5691	20.3315	24.8068
Enero	24.3057	22.0501	26.5612
Febrero	25.8461	23.5762	28.116
Marzo	26.3104	24.0293	28.5914
Abril	25.3301	23.0405	27.6198
Mayo	24.1619	21.8655	26.4582
Junio	22.7847	20.4831	25.0862
Julio	21.6036	19.298	23.9091
Agosto	20.6319	18.3232	22.9405
Septiembre	20.3089	17.9978	22.6199
Octubre	20.7095	18.3966	23.0225
Noviembre	21.4653	19.1509	23.7797
Diciembre	22.6345	20.319	24.9501

TABLA XV

PRONÓSTICOS TSM Niño 3 (2001 – 2002) SARIMA(2,0,1)x(0,1,1)₁₂

Mes	Pronóstico	Límites de Confianza 95%	
		Inferior	Superior
Enero	25.0196	24.3179	25.7213
Febrero	25.9156	24.9308	26.9004
Marzo	26.7946	25.6066	27.9826
Abril	27.2206	25.8784	28.5628
Mayo	26.9013	25.4414	28.3612
Junio	26.3277	24.7792	27.8762
Julio	25.5915	23.9782	27.2047
Agosto	24.9958	23.337	26.6546
Septiembre	24.9009	23.2119	26.5899
Octubre	25.0233	23.3157	26.7308
Noviembre	25.0837	23.366	26.8014
Diciembre	25.2769	23.5546	26.9992
Enero	25.7744	24.0489	27.5
Febrero	26.5713	24.8449	28.2977
Marzo	27.3476	25.6212	29.074
Abril	27.6703	25.9436	29.397
Mayo	27.2497	25.5217	28.9777
Junio	26.5792	24.8486	28.3098
Julio	25.7522	24.0177	27.4868
Agosto	25.0735	23.3338	26.8132
Septiembre	24.9043	23.1586	26.6499
Octubre	24.9618	23.2097	26.7139
Noviembre	24.9673	23.2086	26.726
Diciembre	25.1155	23.3505	26.8805

TABLA XVII

PRONÓSTICOS TSM Niño 4 (2001 – 2002) SARIMA(3,0,1)x(0,1,1)₁₂

Mes	Pronóstico	Límites de Confianza 95%	
		Inferior	Superior
Enero	27.5299	27.0537	28.006
Febrero	27.376	26.7605	27.9916
Marzo	27.4675	26.7115	28.2235
Abril	27.8123	26.9427	28.6819
Mayo	28.1399	27.1737	29.1062
Junio	28.2031	27.157	29.2491
Julio	28.191	27.0799	29.302
Agosto	28.1138	26.9508	29.2768
Septiembre	28.1648	26.9611	29.3685
Octubre	28.168	26.9331	29.4029
Noviembre	28.177	26.9188	29.4353
Diciembre	28.098	26.8228	29.3732
Enero	27.975	26.6847	29.2652
Febrero	27.8655	26.565	29.1659
Marzo	27.949	26.6413	29.2567
Abril	28.2833	26.9708	29.5958
Mayo	28.5877	27.2721	29.9032
Junio	28.6212	27.3038	29.9386
Julio	28.5745	27.2561	29.8929
Agosto	28.46	27.1411	29.7788
Septiembre	28.4722	27.1531	29.7913
Octubre	28.4367	27.1175	29.7558
Noviembre	28.4081	27.0889	29.7272
Diciembre	28.2932	26.974	29.6124

TABLA XIX

PRONÓSTICOS Niño 3.4 (2001 – 2002) SARIMA(3,0,1)x(2,1,3)₁₂

Mes	Pronóstico	Límites de Confianza 95%	
		Inferior	Superior
Enero	25.6308	25.0041	26.2576
Febrero	25.9798	25.1072	26.8523
Marzo	26.6464	25.568	27.7249
Abril	27.3806	26.1329	28.6283
Mayo	27.5486	26.1636	28.9336
Junio	27.5209	26.0279	29.014
Julio	27.1578	25.583	28.7327
Agosto	26.8696	25.2359	28.5033
Septiembre	26.8375	25.1641	28.5109
Octubre	26.8902	25.1924	28.5881
Noviembre	26.8108	25.0998	28.5219
Diciembre	26.7881	25.0713	28.5049
Enero	26.7718	25.0485	28.495
Febrero	26.9184	25.193	28.6438
Marzo	27.3863	25.6605	29.1121
Abril	27.8894	26.1636	29.6152
Mayo	27.9702	26.2437	29.6966
Junio	27.7813	26.053	29.5096
Julio	27.3265	25.5952	29.0579
Agosto	26.9705	25.2348	28.7061
Septiembre	26.8185	25.0778	28.5592
Octubre	26.8308	25.0846	28.5769
Noviembre	26.7273	24.9758	28.4789
Diciembre	26.6711	24.9145	28.4277

TABLA XXI

PRONÓSTICOS Temperatura del Aire (2001 – 2002)

Mes	Pronóstico	Límites de Confianza 95%	
		Inferior	Superior
Enero	26.472	25.5537	27.3904
Febrero	26.4386	25.3193	27.558
Marzo	26.8352	25.5905	28.0798
Abril	26.8528	25.5301	28.1756
Mayo	26.208	24.8344	27.5816
Junio	24.8972	23.4899	26.3045
Julio	23.9536	22.5237	25.3834
Agosto	23.7123	22.2672	25.1573
Septiembre	24.1898	22.7344	25.6451
Octubre	24.4922	23.0299	25.9546
Noviembre	24.8645	23.3975	26.3316
Diciembre	25.8919	24.4216	27.3622
Enero	26.3553	24.8794	27.8313
Febrero	26.335	24.8557	27.8144
Marzo	26.7504	25.2688	28.2321
Abril	26.7827	25.2994	28.266
Mayo	26.1501	24.6657	27.6345
Junio	24.8493	23.3642	26.3344
Julio	23.914	22.4284	25.3996
Agosto	23.6796	22.1936	25.1656
Septiembre	24.1627	22.6765	25.649
Octubre	24.4699	22.9835	25.9563
Noviembre	24.8461	23.3596	26.3326
Diciembre	25.8766	24.39	27.3632